

MULTIFRAKTALITAS DAN STUDI KOMPARATIF PREDIKSI INDEKS DENGAN METODE ARIMA DAN ARTIFICIAL NEURAL NETWORK (ANN)

Harjum Muharam¹; Muhammad Panji²

^{1,2} Fakultas Ekonomi, Universitas Diponegoro,
Jln. Prof. Sudharto SH, Tembalang, Semarang 50147 Jawa Tengah

ABSTRACT

This paper discusses technical analysis widely used by investors. There are many methods that exist and used by investor to predict the future value of a stock. In this paper we start from finding the value of Hurst (H) exponent of LQ 45 Index to know the form of the Index. From H value, we could determinate that the time series data is purely random, or ergodic and ant persistent, or persistent to a certain trend. Two prediction tools were chosen, ARIMA (Auto Regressive Integrated Moving Average) which is the de facto standard for univariate prediction model in econometrics and Artificial Neural Network (ANN) Back Propagation. Data left from ARIMA is used as an input for both methods. We compared prediction error from each method to determine which method is better. The result shows that LQ45 Index is persistent to a certain trend therefore predictable and for outputted sample data ARIMA outperforms ANN.

Keywords: LQ45, multifraktality, ARIMA, artificial neural network

ABSTRAK

Makalah ini membahas analisis teknis yang banyak digunakan oleh investor. Banyak metode yang ada dan digunakan oleh investor untuk memprediksi nilai saham masa depan. Dalam tulisan ini kita mulai dari mencari nilai Hurst (H) eksponen dari Indeks LQ 45 untuk mengetahui bentuk Indeks. Dari nilai H, kita bisa tahu adalah data time series murni acak, atau ergodic dan semut terus-menerus, atau gigih untuk sebuah tren tertentu. Dua alat untuk prediksi dipilih, ARIMA (Auto Regresif Integrated Moving Average) yang merupakan standar de facto untuk model prediksi univariat dalam ekonometri dan Jaringan Syaraf Tiruan (JST) Back Propagation. Yang tertinggal dari ARIMA digunakan sebagai masukan untuk dua metode. Kami membandingkan kesalahan prediksi dari setiap metode untuk mengetahui metode mana yang lebih baik. Hasil investigasi menunjukkan bahwa Indeks LQ45 yang gigih untuk sebuah tren tertentu yang berarti dapat diprediksi dan untuk sampel data yang keluar ARIMA lebih baik dr JST.

Kata kunci: LQ45, multifraktalitas, ARIMA, jaringan syaraf tiruan

PENDAHULUAN

Telah banyak diyakini bahwa data *return* akan memiliki sifat multifraktal (Turiel, 2002). Sifat multifraktal ini penting untuk memperlihatkan pola *self-similarity* dalam data deret waktu. Hal ini semakin menegaskan bahwa perubahan nilai data dengan volatilitas tinggi tidaklah sepenuhnya acak.

Beberapa perangkat statistik telah dikembangkan untuk mengukur tingkat pengaruh di antara data. Salah satu perangkat yang telah berkembang cukup lama adalah model otokorelasi. Dalam perkembangan lebih lanjut, model dasar ini dikembangkan dengan memperhatikan selang waktu. Data tidak lagi dianggap sebagai satu kelompok yang utuh, tetapi dikelompokkan menjadi beberapa bagian. Keuntungan dalam model ini adalah terhindar prasangka awal bahwa seperangkat data dalam satu selang waktu memiliki karakteristik yang sama, misalnya nilai rata-rata. Dengan dipecahnya data menjadi beberapa kelompok data, memungkinkan untuk memperlakukan data secara lebih baik (Hariadi dan Surya, 2003).

Analisis R/S (*Rescaled Range Analysis*) mampu membedakan data runtun waktu acak dengan runtun waktu tidak acak, tanpa memperhatikan distribusi data runtun waktu tersebut. (Yao dkk, 1999). Analisis R/S digunakan untuk mendeteksi efek memori jangka panjang (*long memory effects*) pada data runtun waktu yang digunakan selama periode penelitian.

Jaringan Syaraf Tiruan (Jaringan Syaraf Tiruan) atau dikenal dengan *Artificial Neural Network* (ANN) atau disebut juga *Simulated Neural Network* (SNN) adalah jaringan dari sekelompok unit pemroses kecil yang dimodelkan berdasarkan jaringan syaraf manusia. JST merupakan sistem adaptif yang dapat merubah strukturnya untuk memecahkan masalah berdasarkan informasi eksternal maupun internal, yang mengalir melalui jaringan tersebut. Secara sederhana, JST merupakan salah satu alat permodelan data statistik non-linier. JST dapat digunakan untuk memodelkan hubungan yang kompleks antara masukan (*input*) dan keluaran (*output*) untuk menemukan pola-pola data.

Beberapa penelitian yang telah dilakukan di pasar modal Indonesia, sebagian besar hanya melakukan kajian yang berkaitan dengan analisis fundamental saja; misalnya penelitian Mas'ud Machfoed (1994), Mamduh Hanafi (1997), Parawiyati dan Zaki Baridwan (1998), Wiwik Utami dan Suharmadi (1998), Triyono dan Jogiyanto Hartono (1999), Syahib Natarsyah (2000), dan Nur Fadjrih Asyik (2000), tetapi sangat sedikit sekali yang melakukan kajian terhadap analisis teknikal. Salah satunya adalah penelitian Dedhy Sulistiawan (2001), tetapi penelitian ini hanya bersifat suatu tinjauan teori saja. Penelitian Taylor dan Aller (1992) dan Fernandez-Rodriguez *et al.* (1999) menyatakan bahwa lebih dari 90% investor memberikan bobot yang lebih tinggi pada penggunaan analisis teknikal dibandingkan analisis fundamental dalam membeli dan menjual saham. Hal ini dapat terjadi karena investor cenderung berorientasi jangka pendek dalam membeli atau menjual saham.

Penelitian ini diawali dengan mencari sifat multifraktal pada *return* saham objek penelitian dengan analisis *rescaled range* (untuk mendapatkan *eksponen Hurst*) untuk mengetahui apakah data *return* tersebut bersifat acak atau terdapat pengulangan *trend* sehingga dapat dilakukan analisis teknikal. Selanjutnya akan dilakukan prediksi terhadap *return* saham tersebut dengan metode ARIMA (*Auto Regressive Integrated Moving Average*) dan Jaringan Syaraf Tiruan (*Artificial Neural Network*) untuk kemudian akan dilakukan komparasi metode mana yang memiliki kesalahan lebih kecil dalam memprediksi Indeks LQ 45.

Pemilihan Indeks LQ45 dilakukan karena LQ 45 lebih mampu menjelaskan pergerakan harga saham daripada IHSG (Indeks Harga Saham Gabungan) (Agus Sartono dan Sri Zulaihati, 1998), bahkan secara empiris telah dibuktikan oleh Bima Putra (2001) bahwa Indeks LQ 45 lebih baik digunakan sebagai *proxy* pasar saham dibandingkan IHSG.

Pertanyaan yang akan dijawab dalam penelitian ini adalah (1) Apakah terdapat sifat multifraktal pada data deret waktu Indeks LQ 45; dan (2) Metode mana yang memiliki performa lebih baik dalam memprediksi Indeks LQ 45.

Razdan (2002) meneliti multifraktalitas pada Indeks *Bombay Stock Exchange* (BSE) dan mengambil kesimpulan bahwa data deret waktu Indeks BSE berifat monofraktal dan dapat direpresentasikan oleh gerak brown sebagian.

Yoon dan Choi (2005) melakukan penelitian pada pasar nilai tukar won terhadap dolar dan KOSPI (*Korean Stock Price Index*) dengan menggunakan analisis R/S dan mengambil kesimpulan bahwa data tersebut memiliki kecenderungan efek *trend* yang bertahan dalam jangka panjang.

Hariadi dan Surya (2003) melakukan penelitian pada 3 saham BEJ, yaitu Telkom, Indosat, dan HM Sampoerna serta mendapatkan hasil bahwa saham-saham tersebut memiliki kecenderungan *trend* jangka pendek, yang artinya perubahan nilai saham tidak dipengaruhi oleh perubahan nilai saham yang terpisah dalam selang waktu lama. Nilai dimensi fraktal yang lebih dari 1,5 mendukung pernyataan pertama bahwa ketiga saham tidak memiliki kecenderungan untuk bertahan pada *trend* tertentu.

Fernandez-Rodriguez *et al.* (1999) melakukan penelitian mengenai teknikal analisis pada *Madrid Stock Exchange* dengan menggunakan *moving average* dengan periode yang berbeda-beda. Hal ini dilakukan untuk mengatasi kelemahan yang ada pada penelitian Brock *et al.* (1999). Hasil pada penelitian tersebut bahwa *technical trading rules* memiliki kemampuan untuk mempredisi *return* saham. Pada penelitian Fernandez-Rodriguez *et al.* (1999) ini juga digunakan metode ARIMA, menggabungkan metode rata-rata bergerak dan autoregresi. Hasilnya adalah bahwa metode ARIMA dapat meningkatkan akurasi dalam memprediksi harga saham.

Fernandez-Rodriguez (2001) melakukan penelitian lagi mengenai penerapan analisis teknikal di pasar saham *Madrid Stock Exchange*. Penelitian ini dilakukan dengan penelitian-penelitian yang telah dilakukan sebelumnya kebanyakan masih menggunakan satu indikator saja yaitu *moving average*, untuk memperbaiki penelitian yang telah ada tersebut maka juga dipergunakan indikator *moving average* yang lain, yaitu *Generalized Moving Average* seperti *double moving average*. ARIMA akan bekerja dengan baik apabila data runtut waktu yang digunakan bersifat dependen atau berhubungan satu sama lain secara statistik (Sugiarto dan Harijono, 2000).

Suhartono (2005) melakukan studi pada tingkat inflasi di Indonesia. Studi ini melakukan perbandingan terhadap metode Jaringan Syaraf Tiruan, ARIMA, dan ARIMAX (ARIMA dengan analisis intervensi dan variasi kalender). Hasil studi ini menunjukkan bahwa FFNN (*Feed Forward Neural Network*) dengan input model ARIMAX memberikan hasil terbaik untuk melakukan peramalan inflasi di Indonesia. Penelitian ini juga menunjukkan bahwa akurasi peramalan dengan model ARIMAX mirip dengan hasil FFNN dengan input yang berasal dari ARIMAX.

Nachrowi dan Usman (2007) melakukan studi pada IHSG dengan menggunakan model GARCH dan ARIMA. Hasil dari studi ini menunjukkan bahwa model ARIMA (1,1,0) mempunyai kesalahan lebih kecil dalam memprediksi gerakan IHSG bila dibandingkan dengan model GARCH (2,2). Hal ini disebabkan karena sulitnya mengidentifikasi variabel dominan yang dapat menjelaskan IHSG. Model ARIMA cenderung lebih unggul karena metode ini hanya memerlukan variabel penjelas yang merupakan variabel itu sendiri di masa lalu. Bila pergerakan variabel masa lalu sudah dapat mencerminkan semua informasi yang dapat mempengaruhi variabel itu, variabel penjelas lain peranannya menjadi sangat kecil.

Chiang *et al.* (1996) menggunakan FFNN dengan *Backpropagation* (BP) untuk melakukan peramalan nilai aset bersih/*Net Asset Value* (NAV) *mutual funds*. Prediksi dilakukan dengan menggunakan informasi ekonomi historis. Mereka membandingkan dengan hasil yang didapatkan dari

peramalan dengan teknik ekonometrika tradisional dan menyimpulkan bahwa NN “melampaui model regresi secara signifikan” ketika tersedia data dalam jumlah terbatas.

Trafalis (1999) menggunakan FFNN dengan BP dan perubahan mingguan pada 14 indikator untuk meramal perubahan pada indeks saham S&P 500 selama beberapa pekan. Di samping itu, sebuah metode untuk melakukan *pre-processing* digunakan, yang mengikutsertakan diferensiasi dan normalisasi data, berhasil diimplementasikan. Tulisan tersebut mengajak pembaca melalui proses NN.

Garliauskas (1999) melakukan penelitian pada peramalan data runtun waktu pasar saham menggunakan algoritma komputasional NN, dihubungkan dengan pendekatan fungsi kernel dan metode prediksi *error* rekursif. Ide utama pembelajaran NN dengan fungsi kernel adalah bahwa fungsi tersebut menstimulasi perubahan bobot, dalam kaitannya untuk mencapai konvergensi target dan fungsi keluaran peramalan. Dia menyimpulkan bahwa peramalan data keuangan runtun waktu dengan Jaringan Syaraf Tiruan lebih baik daripada statistika klasik dan metode lainnya.

Chan *et al.* (2000) meneliti peramalan data keuangan runtun waktu menggunakan FFNN dan data perdagangan harian dari Bursa Efek Shanghai (*Shanghai Stock Exchange*). Untuk memperbaiki kecepatan dan konvergensi, mereka menggunakan algoritma pembelajaran gradien konjugasi dan regresi linear berganda/*Multiple Linear Regression* (MLR) untuk inisialisasi bobot. Mereka menyimpulkan bahwa NN dapat memodelkan runtun waktu secara memuaskan dan pendekatan pembelajaran serta inisialisasi mengarah pada perbaikan pembelajaran dan penurunan biaya komputasi.

Surya dan Situngkir (2003a) menggunakan permodelan Jaringan Syaraf Tiruan untuk tujuan peramalan (*forecasting*) data keuangan deret waktu PT Telkom Indonesia selama tahun 2000 dan menghasilkan analisis regresi (kecocokan linier) dari data yang di-*training* keakuratan data yang diaproksimasi dan diprediksi telah sangat baik (garis kecocokan linier berimpit dengan garis yang memetakan hasil aproksimasi dan target data yang diaproksimasi), tetapi perlu ditambahkan data untuk training jaring syaraf untuk memperkuat hasil analisis.

Surya dan Situngkir (2003b) melakukan prediksi pada fluktuasi harga saham (*closing*) PT Telkom untuk data deret waktu dari tahun awal 1993 hingga pertengahan 2003 dengan menggunakan metode Jaringan Syaraf Tiruan, yang dilengkapi dengan peta *Poincaré* dalam persepsi model jaring syaraf yang dibuat untuk tujuan prediksi, menghasilkan hasil aproksimasi dan prediksi sangat baik dengan gradient mendekati 1 ($\sim 0,966$).

Populasi objek penelitian adalah nilai harian seluruh Indeks yang ada di BEJ. Nilai Indeks yang menjadi sampel dalam penelitian ini adalah nilai Indeks LQ 45 periode Januari 1997 hingga April 2007.

Data tersebut dibagi menjadi 2 bagian, yaitu periode model dan estimasi. Periode model ditetapkan selama 216 hari perdagangan (80% sampel), sedangkan periode estimasi ditetapkan selama 54 hari (20% sampel). Pada metode JST, data pada periode model dibagi menjadi 2, yaitu periode training (60% dari total sampel) dan evaluasi (20% dari total sampel).

Data pada periode model digunakan untuk menghasilkan model yang digunakan untuk melakukan peramalan, sedangkan data pada periode estimasi digunakan untuk melihat tingkat kesalahan (*error*) yang dihasilkan oleh metode-metode yang digunakan. Semakin kecil *error* yang dimiliki sebuah model, semakin baik model tersebut digunakan dalam melakukan peramalan dalam analisis teknikal.

Ide dasar pengembangan eksponen Hurst adalah model otokorelasi. Pada otokorelasi biasa menggunakan data sebagai satu kesatuan deret waktu, sedangkan pada analisis R/S (*Rescaled range*

Analysis, sebutan untuk mendapatkan eksponen Hurst) data dipecah menjadi beberapa bagian, dan analisis R/S dilakukan terhadap masing-masing data yang terpecah. Misalkan kita memiliki data deret waktu Y_1, \dots, Y_N , data ini kemudian dipecah menjadi beberapa bagian dengan panjang yang sama, dengan masing-masing terdiri atas y_1, \dots, y_t .

Nilai R diperoleh dari persamaan:

$$R_N = \text{Maks}X_{(t,N)} - \text{min}X_{(t,N)}$$

Nilai X diperoleh dari persamaan:

$$X_{t,N} = \sum_{u=1}^t (x_u - \mu_N)$$

Di mana μ_N adalah rata-rata deret waktu selama periode N. Nilai S merupakan deviasi standar data deret waktu yang kita miliki. Dapat diperoleh dengan persamaan:

$$S_N = \left[\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_N)^2 \right]^{\frac{1}{2}}$$

Rasio R/S dari R dan Deviasi Standard S dari deret waktu utama dapat dihitung dengan hukum empiris sebagai berikut (Yao dkk, 1999) : $R/S = N^H$. Nilai Eksponen Hurst dapat dihitung sebagai berikut :

$$H = \log(R/S)/\log(N)$$

Di mana nilai H berada di antara 0 dan 1 ($0 < H < 1$). Estimasi nilai H dapat diperoleh dengan melakukan perhitungan slope grafik $\log R/S$ terhadap N menggunakan regresi.

Nilai eksponen Hurst (H) menggambarkan probabilitas bahwa 2 event konsekutif dapat muncul. Jika nilai $H = 0,5$, maka data deret waktu bertipe acak, terdiri atas event-event yang tidak berhubungan. Nilai H selain 0,5 menggambarkan bahwa objek observasi tidak independen, Ketika $0 \leq H < 0,5$, sistem yang diteliti merupakan deret ergodic dan antipersisten dengan frekuensi pembalikan yang tinggi dan volatilitas yang tinggi. Di samping kelaziman yang ada mengenai konsep pembalikan rata-rata pada literatur ekonomi dan keuangan, hanya ditemukan beberapa deret waktu antipersisten. Bagi kondisi ketiga ($0,5 < H \leq 1,0$), H mendeskripsikan deret persisten dan adanya *trend* yang ditunjukkan oleh efek ingatan jangka panjang (*long memory effects*). Kekuatan bisa bergantung pada seberapa besar nilai H di atas 0,5. Semakin rendah nilai H, lebih banyak *noise* pada sistem dan deret lebih mendekati keacakan.

Tabel 1 Ringkasan Arti Nilai H

Nilai H	Arti
$0 \leq H < 0,5$	<i>Ergodic</i> dan antipersisten, frekuensi pembalikan dan volatilitas tinggi
$H = 0,5$	Sepenuhnya acak
$0,5 < H \leq 1$	Persisten dan kecenderungan pembentukan tren dengan adanya efek ingatan jangka panjang (<i>long memory effects</i>)

Sumber: Yao dkk, 1999 diringkas

Langkah-langkah penerapan metode ARIMA secara berturut-turut, yaitu identifikasi model, estimasi parameter model, *diagnostic checking*, dan peramalan (*forecasting*). *Pertama*, identifikasi model. Seperti yang dijelaskan sebelumnya bahwa model ARIMA hanya dapat diterapkan untuk deret waktu yang stasioner. Oleh karena itu, pertama kali yang harus dilakukan adalah menyelidiki apakah data yang kita gunakan sudah stasioner atau belum. Jika data tidak stasioner, yang perlu dilakukan adalah memeriksa pada perbedaan beberapa data akan stasioner, yaitu menentukan berapa nilai d . Proses ini dapat dilakukan dengan menggunakan koefisien ACF (*Auto Correlation Function*), atau uji akar-akar unit (*unit root test*) dan derajat integrasi. Jika data sudah stasioner sehingga tidak dilakukan perbedaan terhadap data runtun waktu, maka d diberi nilai 0.

Di samping menentukan d , pada tahap ini juga ditentukan berapa jumlah nilai lag residual (q) dan nilai lag dependen (p) yang digunakan dalam model. Alat utama yang digunakan untuk mengidentifikasi q dan p adalah ACF dan PACF (*Partial Auto Correlation Function*/Koefisien Autokorelasi Parsial), dan *correlogram* yang menunjukkan plot nilai ACF dan PACF terhadap lag.

Koefisien autokorelasi parsial mengukur tingkat keeratan hubungan antara X_t dan X_{t-k} , sedangkan pengaruh dari time lag 1, 2, 3, ..., $k-1$ dianggap konstan. Dengan kata lain, koefisien autokorelasi parsial mengukur derajat hubungan antara nilai-nilai sekarang, dengan nilai-nilai sebelumnya (untuk time lag tertentu), sedangkan pengaruh nilai variabel time lag yang lain dianggap konstan. Secara matematis, koefisien autokorelasi parsial berorde m didefinisikan sebagai koefisien *autoregressive* terakhir dari model AR (m).

Tabel 2 Pola ACF dan PACF

Tipe Model	Pola Tipikal ACF	Pola tipikal PACF
AR(p)	Menurun secara eksponensial menuju nol	Signifikan pada semua lag p
MA(q)	Signifikan pada semua lag p	Menurun secara eksponensial menuju nol
ARMA(p,q)	Menurun secara eksponensial menuju nol	Menurun secara eksponensial menuju nol

Sumber: Gujarati 2003

Kedua, estimasi parameter model. Setelah menetapkan model sementara dari hasil identifikasi, yaitu menentukan nilai p , d , dan q . Langkah berikutnya adalah melakukan estimasi *parameter autoregressive* dan *moving average* yang tercakup dalam model (Firmansyah, 2000). Jika teridentifikasi proses AR murni, maka parameter dapat diestimasi dengan menggunakan kuadrat terkecil (*Least Square*). Jika sebuah pola MA diidentifikasi, maka *maximum likelihood* atau estimasi kuadrat terkecil. Keduanya membutuhkan metode optimisasi non-linier (Griffiths, 1993). Hal ini terjadi karena adanya unsur *moving average* yang menyebabkan ketidaklinieran parameter (Firmansyah, 2000). Namun, saat ini sudah tersedia berbagai piranti lunak statistik yang mampu menangani perhitungan tersebut sehingga kita tidak perlu khawatir mengenai estimasi matematis.

Ketiga, *diagnostic checking*. Setelah melakukan estimasi dan mendapatkan penduga parameter, agar model sementara dapat digunakan untuk peramalan, perlu dilakukan uji kelayakan terhadap model tersebut. Tahap ini disebut *diagnostic checking*, di mana pada tahap ini diuji apakah spesifikasi model sudah benar atau belum. Pengujian kelayakan ini dapat dilakukan dengan beberapa cara, yaitu (1) Setelah estimasi dilakukan, maka nilai residual dapat ditentukan. Jika nilai-nilai koefisien autokorelasi residual untuk berbagai time lag tidak berbeda secara signifikan dari nol, maka

model dianggap memadai untuk dipakai sebagai model peramalan; (2) Menggunakan statistik Box-Pierce Q, yang dihitung dengan formula sebagai berikut.

$$Q = n \sum_{k=1}^m \hat{\rho}_k^2$$

Di mana :

n = jumlah sampel

m = jumlah lag, dan

$\hat{\rho}_k$ = nilai koefisien autokorelasi time lag k. Jika nilai Q hitung lebih kecil daripada χ^2 kritis dengan derajat kebebasan m, maka model dianggap memadai; 3) Menggunakan varian dari statistik Box-Pierce Q, yaitu statistik Ljung-Box(LB), yang dapat dihitung dengan:

$$LB = n(n+2) \sum_{k=1}^m \left(\frac{\hat{\rho}_k^2}{n-k} \right)$$

Sama seperti Q statistik, statistik LB mendekati χ^2 kritis dengan derajat kebebasan m. Jika statistik LB lebih kecil dari nilai χ^2 kritis, maka semua koefisien autokorelasi dianggap tidak berbeda dari nol, atau model telah dispesifikasikan dengan benar. Statistik LB dianggap lebih unggul secara statistik daripada Q statistik dalam menjelaskan sampel kecil; (4) Menggunakan t statistik untuk menguji apakah koefisien model secara individu berbeda dari nol. Apabila suatu variabel tidak signifikan secara individu, berarti variabel tersebut seharusnya dilepas dari spesifikasi model lain, kemudian diduga dan diuji. Jika model sementara yang dipilih belum lolos uji diagnostik, maka proses pembentukan model diulang kembali. Menemukan model ARIMA yang terbaik merupakan proses iteratif.

Keempat, peramalan (*forecasting*). Setelah model terbaik diperoleh, selanjutnya peramalan dapat dilakukan. Dalam berbagai kasus, peramalan dengan metode ini lebih dipercaya daripada peramalan yang dilakukan dengan model ekonometri tradisional. Namun, hal ini tentu saja perlu dipelajari lebih lanjut oleh para peneliti yang tertarik menggunakan metode serupa. Berdasarkan ciri yang dimilikinya, model runtun waktu seperti ini lebih cocok untuk peramalan dengan jangkauan sangat pendek, sementara model struktural lebih cocok untuk peramalan dengan jangkauan panjang (Mulyono, 2000 dalam Firmansyah, 2000).

Algoritma standar yang digunakan dalam pelatihan Jaringan Syaraf Tiruan *Feed Forward Back Propagation*, yaitu *gradient conjugate* dan *gradient conjugate with momentum* seringkali terlalu lambat untuk keperluan praktis. Oleh karena itu, pada penelitian ini akan digunakan Algoritma *Gradient Conjugate With Adaptive Learning Rate and Momentum*(traingdx). Algoritma ini merupakan penggabungan dari *Algoritma Gradient Conjugate with Adaptive Learning*(traingda) dan *Gradient Conjugate With Momentum*(traingdm).

Pada *standard backpropagation*, perubahan bobot didasarkan atas gradien yang terjadi untuk pola yang dimasukkan saat itu. Modifikasi yang dapat dilakukan adalah melakukan perubahan bobot yang didasarkan atas arah gradien pola terakhir dan pola sebelumnya (disebut momentum) yang dimasukkan, jadi tidak hanya pola masukan terakhir saja yang diperhitungkan (Siang, 2005).

Penambahan momentum dimaksudkan untuk menghindari perubahan bobot yang mencolok akibat adanya data yang sangat berbeda dengan yang lain (*outlier*). Apabila beberapa data terakhir yang diberikan ke jaringan memiliki pola yang serupa (berarti arah gradien sudah benar), maka perubahan bobot dilakukan secara cepat. Namun, apabila data terakhir yang dimasukkan memiliki pola yang berbeda dengan pola sebelumnya, maka perubahan dilakukan secara lambat (Siang, 2005).

Dengan penambahan momentum, bobot baru pada waktu ke (t+1) didasarkan atas bobot pada waktu t dan (t-1). Di sini harus ditambahkan 2 variabel baru yang mencatat besarnya momentum untuk 2 iterasi terakhir. Jika μ adalah konstanta ($0 \leq \mu \leq 1$) yang menyatakan parameter momentum, maka bobot baru dihitung berdasarkan persamaan:

$$w_{kj}(t+1) = w_{kj}(t) + \alpha \delta_k z_j + \mu(w_{kj}(t) - w_{kj}(t-1))$$

dan

$$v_{ji}(t+1) = v_{ji}(t) + \alpha \delta_j x_i + \mu(v_{ji}(t) - v_{ji}(t-1))$$

Algoritma *gradient descent* dengan *adaptive learning rate*, dasarnya sama dengan algoritma *gradient descent* standar dengan beberapa perubahan. Pertama-tama, dihitung terlebih dahulu nilai output jaringan dan *error* pelatihan. Pada setiap *epoch*, bobot-bobot baru dihitung dengan menggunakan *learning rate* yang ada. Kemudian, dihitung kembali output jaringan dan *error* pelatihan. Jika perbandingan antara *error* pelatihan yang baru dengan *error* pelatihan lama melebihi maksimum kenaikan kinerja (*max_perf_inc*), maka bobot-bobot baru tersebut akan diabaikan, sekaligus nilai *learning rate* akan dikurangi dengan cara mengalikannya dengan *lr_dec*. Sebaliknya, apabila perbandingan antara *error* pelatihan baru dengan *error* pelatihan lama kurang dari maksimum kenaikan kinerja, maka nilai bobot-bobot akan dipertahankan, sekaligus nilai *learning rate* akan dinaikkan dengan cara mengalikannya dengan *lr_inc*.

Dengan cara ini, apabila *learning rate* terlalu tinggi dan mengarah ke ketidakstabilan, maka *learning rate* akan diturunkan. Sebaliknya, jika *learning rate* terlalu kecil untuk menuju konvergensi, maka *learning rate* akan dinaikkan. Dengan demikian, maka algoritma pembelajaran akan tetap terjaga pada kondisi stabil.

Algoritma *gradient descent with momentum and adaptive learning*(*traingdx*) merupakan penggabungan antara algoritma *gradient descent with adaptive learning*(*traingda*) dan algoritma *gradient descent with momentum*(*traingdm*). Algoritma ini merupakan algoritma default yang digunakan oleh MATLAB karena memiliki performa kecepatan pelatihan yang tinggi.

Simulasi dilakukan baik pada periode training maupun periode testing. Salah satu cara yang dapat digunakan untuk melakukan evaluasi terhadap jaringan syaraf yang digunakan adalah dengan menggunakan analisis regresi terhadap respon jaringan dan target yang diharapkan. Analisis ini akan dilakukan dengan fungsi *postreg* yang terdapat pada MATLAB.

Dalam statistik, *Mean Squared Error* (MSE) sebuah estimator adalah nilai yang diharapkan dari kuadrat *error*. *Error* yang ada menunjukkan seberapa besar perbedaan hasil estimasi dengan nilai yang akan diestimasi. Perbedaan itu terjadi karena adanya keacakan pada data atau karena estimator tidak mengandung informasi yang dapat menghasilkan estimasi yang lebih akurat

$$MSE = \frac{1}{N} \sum_{t=h}^N (y_t - \hat{y}_t)^2$$

Di mana:

- MSE = *Mean Squared Error*
- N = Jumlah Sampel
- y_t = Nilai Aktual Indeks
- \hat{y}_t = Nilai Prediksi Indeks

PEMBAHASAN

Nilai Eksponen Hurst Sebesar 0,514 menunjukkan adanya kecenderungan deret waktu untuk persisten terhadap *trend* dan memiliki efek memori jangka panjang (*long memory effect*), di mana nilai saham pada saat ini dipengaruhi oleh nilai-nilai sebelumnya dalam jangka waktu yang cukup panjang. Dengan demikian, dapat dilakukan prediksi pada harga Indeks LQ45 karena nilai yang ada tidak sepenuhnya acak.

Hasil ini berbeda dengan penelitian yang dilakukan oleh Hariadi dan Surya (2003) yang melakukan penelitian mengenai multifraktalitas pada 3 saham yang diperdagangkan di BEJ (Telkom, Indosat, dan HM Sampoerna). Hariadi dan Surya mendapati nilai eksponen Hurst untuk ketiga saham tersebut lebih kecil dari 0.5, yang berarti saham-saham tersebut tidak memiliki kecenderungan untuk bertahan pada *trend* tertentu dan memiliki efek memori jangka pendek. Perbedaan hasil penelitian ini mungkin disebabkan oleh perbedaan jenis data di mana Indeks LQ45 merupakan agregasi 45 saham terlikuid di bursa, perubahan yang terjadi di pasar cenderung saling menutup satu sama lain, kenaikan pada satu sektor akan menutup penurunan pada sektor lainnya sehingga Indeks LQ45 akan berada pada level yang relatif sama atau persisten pada tren tertentu.

Di sisi lain, penelitian ini sejalan dengan penelitian yang dilakukan oleh Yao, *et al.* (1999). Penelitian tersebut mendapati nilai eksponen Hurst KLCI (*Kuala Lumpur Composite Index*) sebesar 0,88. Hasil ini menunjukkan kecenderungan Indeks untuk bertahan pada tren tertentu.

Peramalan yang dilakukan dengan metode ARIMA menunjukkan hasil yang cukup menjanjikan, di mana MSE terkecil pada periode *modelling* berada pada titik 5×10^{-10} , sedangkan MSE terbesar berada pada titik 1,9518191759. Sedangkan pada periode peramalan nilai MSE terkecil sebesar $2,185 \times 10^{-7}$ sedangkan nilai MSE terbesar 9,8656474674. Dua hasil peramalan tersebut menunjukkan bahwa model ARIMA (24,1,11) dapat meramalkan Indeks LQ45 dengan baik karena hasil peramalan yang didapatkan relatif mendekati harga aktual Indeks LQ45.

Hasil peramalan metode Jaringan Syaraf Tiruan dengan arsitektur 2 – 10 – 5 – 1 dengan input dari metode ARIMA menunjukkan hasil yang cukup baik. Meskipun pada periode testing hasil yang didapatkan tidak begitu akurat, dan pada beberapa titik selisih dan rata-rata kuadrat *error* yang didapatkan terlalu besar, tetapi gradien dan koefisien regresi yang didapatkan menunjukkan bahwa metode ini dapat mengenali pola data yang ada dengan cukup baik.

Dari kedua metode peramalan yang digunakan, yaitu ARIMA dan Jaringan Syaraf Tiruan Propagasi Balik, menunjukkan bahwa pada periode training metode Jaringan Syaraf Tiruan memiliki nilai MSE dan selisih terkecil yang lebih rendah dibandingkan metode ARIMA, sedangkan pada periode testing justru sebaliknya, di mana hasil peramalan metode ARIMA lebih unggul, dengan nilai terkecil selisih dan MSE lebih rendah dibanding metode Jaringan Syaraf Tiruan.

Dengan Input yang sama, didapatkan bahwa metode ARIMA dapat mengenali pola data dan melakukan prediksi lebih baik dibandingkan metode Jaringan Syaraf Tiruan. Namun, hasil penelitian ini tidak dapat digunakan untuk melakukan generalisasi bahwa metode ARIMA lebih unggul dibandingkan metode Jaringan Syaraf Tiruan. Perlu dilakukan penelitian lanjutan mengenai performa metode Jaringan Syaraf Tiruan jika melakukan prediksi dengan input yang berasal dari indikator teknikal seperti Moving Average, *Relative Strength Index* (RSI), dan Momentum.

PENUTUP

Hasil penelitian mengenai sifat statistika Indeks LQ45 dan komparasi metode peramalan Indeks LQ45 dengan metode ARIMA dan Jaringan Syaraf Tiruan ini, dapat disimpulkan sebagai berikut. *Pertama*, Indeks LQ 45 bersifat multifraktal, hal ini didapatkan dari nilai Eksponen Hurst Indeks LQ 45 sebesar 0,514. Nilai eksponen Hurst yang lebih besar dari 0,5 menunjukkan bahwa terdapat kecenderungan pada data untuk persisten terhadap *trend* tertentu. Hal ini berimplikasi bahwa data yang ada tidak sepenuhnya acak dan dapat diprediksi karena adanya persistensi *trend* dan adanya pengulangan *trend* masa lalu pada periode yang akan datang. *Kedua*, metode ARIMA dapat digunakan untuk melakukan peramalan dengan baik, baik pada periode training maupun testing. Hal ini ditunjukkan dengan selisih yang kecil antara nilai aktual dan nilai estimasi dan nilai MSE yang relatif kecil. *Ketiga*, metode Jaringan Syaraf Tiruan dengan input ARIMA menunjukkan bahwa ANN lebih baik dalam mengenali data pada periode training. Hal ini ditunjukkan dengan nilai MSE pada periode training yang jauh lebih kecil dibandingkan nilai MSE pada metode ARIMA. Dengan menggunakan masukan yang sama, metode ARIMA dapat melakukan peramalan lebih baik pada periode *testing*, sedangkan pada periode Training ANN dapat melakukan peramalan dengan lebih akurat dibandingkan ARIMA. Performa kedua metode yang ada menunjukkan bahwa analisis teknikal dapat digunakan untuk melakukan prediksi Indeks LQ45.

Hasil penelitian ini masih memerlukan penelitian lanjutan dengan mempertimbangkan pembatasan periode testing pada metode ARIMA. Hal ini sesuai dengan *nature* metode ARIMA yang ditujukan untuk melakukan peramalan jangka pendek. Selain itu, untuk mendapatkan hasil yang lebih akurat, penelitian lanjutan dapat menggunakan metode-metode yang dapat menangani non-linearitas pada data seperti kalman filtering. Pada metode Jaringan Syaraf Tiruan, dapat dilakukan penelitian lanjutan dengan menggunakan input indikator teknikal seperti *moving average*, *Relative Strength Index* (RSI) atau momentum.

DAFTAR PUSTAKA

- Ang, R. (1997). *Buku pintar pasar modal Indonesia*, Jakarta: Mediasoft Indonesia.
- Anonim. (2004). *Membangun jaringan syaraf tiruan (menggunakan MATLAB dan Excel Link)*, Yogyakarta: Graha Ilmu.
- Archelis, S. (2000). *Technical analysis from A to Z*, Equis International.
- Fadjrih Asyik, N. (1999). Tambahan kandungan informasi arus kas. *Jurnal Riset Akuntansi Indonesia*, 2(2).
- Fernandez-Rodriguez, F., Gonzales-Martel, C., and Sosvilla-Rivero, S. (1999). Technical analysis in the Madrid stock exchange. *Fundacion de Estudios Economia Aplicada Working Paper*, April 1999.
- Fernandez-Rodriguez, F., Gonzales-Martel, C., and Sosvilla-Rivero, S. (2000). Technical analysis in foreign exchange markets: Linear versus nonlinear trading rules. *Fundacion de Estudios Economia Aplicada Working Paper*, September 2000.
- Fernandez-Rodriguez, F., Gonzales-Martel, C., and Sosvilla-Rivero, S. (2001). Optimization of technical trading rules by genetic algorithms: Evidence from the Madrid stock exchange. *Fundacion de Estudios Economia Aplicada Working Paper*, August 2001.

- Firmansyah. (2000). Peramalan inflasi dengan metode Box-Jenkins (ARIMA): Studi kasus tingkat inflasi kota Semarang dan Yogyakarta 1994-2000. *Media Ekonomi dan Bisnis*, 12(2), Desember 2000.
- Gujarati, D.N (2003). *Basic econometric*, 4th ed., McGraw Hill, Inc.
- Hanafi, M. (1997). Informasi laporan keuangan: Studi kasus pada emiten BEJ. *Kelola*, 16(6), 1997.
- Huang, S.C. (1990). *Timing the stock market for maximum profit*, Chicago, Illinois: Probus publishing company.
- Kusumadewi, S. (2003). *Artificial intelligence (teknik dan aplikasinya)*. Yogyakarta: Graha Ilmu.
- Machfoed, M. (1994). Financial ratio analysis and the prediction of earnings changes in Indonesia. *Kelola*, 7(3), 114-134, 1994.
- Natarsyah, S. (2000), Analisis pengaruh beberapa faktor fundamental dan risiko sistematis terhadap harga saham: Kasus industri barang konsumsi yang go public di pasar modal Indonesia. *Jurnal Ekonomi dan Bisnis Indonesia*, 15(3), 294-312.
- Parawiyati dan Baridwan, Z. (1998). Kemampuan laba dan arus kas dalam memprediksi laba dan arus kas perusahaan go public di Indonesia. *Jurnal Riset Akuntansi Indonesia*, 1(1), 1-10, Januari.
- Parisi, F., and Vasques, A. (2000). Simple technical trading rules of stock returns: Evidence from 1987 – 1998 in Chile. *Emerging Market Review*, 1.
- Qizam, I. (2001). Analisis kerandoman perilaku laba perusahaan di bursa efek Jakarta, *Simposium Nasional Akuntansi IV IAI-KAPd*, Agustus.
- Sartono, A., dan Zulaihati, S. (1998). Rasionalitas investor terhadap pemilihan saham dan penentuan portofolio optimal dengan indeks tunggal di BEJ. *Kelola*, 17, Juli.
- Seiler, M.J., and Rom, W. (1997). A historical analysis of market efficiency: Do historical returns follow a random walk. *Journal of Financial and Strategic Decision*, 10(2).
- Sekaran, U. (1992). *Research methods for business: Skill building approach*, 2nd ed., John Wiley & Sons, Inc.
- Sharpe, W.F., Gordon, J.A., and Bailey, V. (1995). *Investment*, New York: Prentice Hall.
- Siang, J.J. (2005). Jaringan syaraf tiruan dan pemrogramannya menggunakan MATLAB, Yogyakarta: Andi Offset.
- Trisna, D.Q. (2003). *Pengujian penerapan analisis teknikal dalam memprediksi indeks LQ45 di bursa efek Jakarta*. Tesis tidak dipublikasikan, Semarang: MAKSI UNDIP.
- Trisnawati, R. (1999). Pengaruh informasi prospektus pada return saham di pasar modal. *Simposium Nasional Akuntansi II dan Rapat Anggota II, Ikatan Akuntan Indonesia, Departemen Akuntan Pendidik*, 1-13, 24-25 September.
- Triyono dan Hartono, J. (2000). Hubungan kandungan informasi arus kas, komponen arus kas dan laba akuntansi dengan harga saham atau return saham. *Jurnal Riset Akuntansi Indonesia*, 2(1).

- Utama, S., dan Budi Santoso, A.Y. (1998). Kaitan antara price/book value dan imbal balik saham pada bursa efek Jakarta. *Jurnal Riset Akuntansi Indonesia*, 1(1), 127-139, Januari.
- Utami, W., dan Suharmadi. (1998). Pengaruh informasi penghasilan perusahaan terhadap harga saham di bursa efek Jakarta. *Jurnal Riset Akuntansi Indonesia*, 1(2), 255-268, Juli.
- Yao, J., Lim Tan, C., and Jean-Lee, P. (1999). Neural networks for technical analysis: A study on KLCI. *International Journal of Theoretical and Applied Finance*, 2(2), 221-241.