

APLIKASI JARINGAN SARAF TIRUAN DAN *PARTICLE SWARM OPTIMIZATION* UNTUK PERAMALAN INDEKS HARGA SAHAM BURSA EFEK INDONESIA

Desy Wartati dan Nur Aini Masruroh

Departemen Teknik Mesin dan Industri

Universitas Gadjah Mada

Email: aini@ugm.ac.id

ABSTRACT

Jakarta Composite Index (JCI) is the main stock index in Indonesia Stock Exchange, which indicates the movement of the performance of all stocks listed. The data of stock price index often experience rapid fluctuations in a short time, so it is needed to carry out an analysis to help investor making the right investment decisions. Forecasting JCI is one of the activities that can be done because it helps to predict the value of the stock price in accordance with the past patterns, so it can be a consideration to make a decision. In this research, there are two forecasting models created to predict JCI, which are Artificial Neural Network (ANN) model with (1) Backpropagation algorithm (BP) and (2) Backpropagation algorithm model combined with Particle Swarm Optimization algorithm (PSO). The development of both models is done from the stage of the training process to obtain optimal weights on each network layer, followed by a stage of the testing process to determine whether the models are valid or not based on the tracking signals that are generated. ANN model is used because it is known to have the ability to process data that is nonlinear such as stock price indices and PSO is used to help ANN to gain weight with a fast computing time and tend to provide optimal results. Forecast results generated from both models are compared based on the error of computation time and forecast error. ANN model with BP algorithm generates computation time of training process for 4,9927 seconds with MSE of training and testing process is respectively 0,0031 and 0,0131, and MAPE of forecast results is 2,55%. ANN model with BP algorithm combined with PSO generates computation time of training process for 4,3867 seconds with MSE of training and testing process is respectively 0,0030 and 0,0062, and MAPE of forecast result is 1,88%. Based on these results, it can be concluded that ANN model with BP algorithm combined with PSO provides a more optimal result than ANN model with BP algorithm.

Keywords: *Artificial Neural Network; Indonesia Stock Exchange; Jakarta Composite Index; Particle Swarm Optimization.*

ABSTRAK

Dalam pasar saham Bursa Efek Indonesia, Indeks Harga Saham Gabungan (IHSG) merupakan indeks saham utama yang mengindikasikan pergerakan kinerja semua saham yang terdaftar. Data indeks harga saham ini sering mengalami fluktuasi yang cepat dalam waktu yang singkat, sehingga diperlukan suatu analisis agar investor dapat mengambil keputusan investasi yang tepat. Peramalan IHSG merupakan salah satu kegiatan yang dapat dilakukan karena membantu untuk memprediksi nilai harga saham sesuai dengan pola yang terbentuk dari masa lalu, sehingga dapat dijadikan pertimbangan pengambilan keputusan. Pada penelitian ini, terdapat 2 model peramalan yang dibuat untuk memprediksi IHSG, yaitu model Jaringan Saraf Tiruan (JST) dengan algoritma *Backpropagation* (BP) dan model algoritma *Backpropagation* yang dikombinasikan dengan algoritma *Particle Swarm Optimization* (PSO). Pembuatan kedua model dilakukan dari tahap proses pelatihan untuk mendapatkan bobot optimal pada setiap *layer* jaringan, dilanjutkan dengan tahap proses pengujian untuk mengetahui apakah model yang dibuat sudah valid atau belum berdasarkan *tracking signal* yang dihasilkan. Adapun pemilihan model JST karena dikenal memiliki kemampuan untuk memproses data yang bersifat nonlinear seperti data indeks harga saham dan PSO digunakan untuk membantu JST mendapatkan bobot dengan waktu komputasi yang cepat dan hasil yang optimal. Hasil peramalan yang dilakukan dengan kedua model yang telah dibuat dibandingkan berdasarkan waktu komputasi, *error* model,

dan *error* peramalan. Model JST dengan algoritma BP menghasilkan waktu komputasi proses pelatihan selama 4,9927 detik dengan MSE proses pelatihan dan pengujian masing-masing 0,0031 dan 0,0131, serta MAPE hasil peramalan sebesar 2,55%. Model JST dengan algoritma BP yang dikombinasikan dengan PSO menghasilkan waktu komputasi proses pelatihan selama 4,3867 detik dengan MSE proses pelatihan dan pengujian masing-masing 0,0030 dan 0,0062, serta MAPE hasil peramalan sebesar 1,88%. Berdasarkan hasil tersebut, diperoleh bahwa model JST dengan algoritma BP yang dikombinasikan dengan PSO memberikan hasil yang lebih optimal dibandingkan model JST dengan algoritma BP.

Kata Kunci: *Backpropagation; Bursa Efek Indonesia; Indeks Harga Saham Gabungan; Jaringan Saraf Tiruan; Particle Swarm Optimization.*

PENGANTAR

Pasar saham merupakan salah satu pilihan investasi yang selalu memiliki daya tarik dari waktu ke waktu (Khirbat *dkk.*, 2013). Selain sebagai sarana pendanaan perusahaan, investasi di pasar saham mampu memberikan keuntungan yang menarik bagi para investor. Ketertarikan investor terhadap pasar saham salah satunya terjadi di pasar modal sekaligus pasar saham Indonesia yang dikenal dengan nama Bursa Efek Indonesia (BEI). Hal ini dapat direpresentasikan dari jumlah investor yang tercatat di BEI yang mengalami peningkatan sebanyak 26% dari Juli 2015 hingga Juli 2016 (Kustodian Sentral Efek Indonesia, 2016). Adanya peningkatan tersebut antara lain disebabkan oleh penerbitan Undang-Undang No.11 Tahun 2016 tentang pengampunan pajak serta sosialisasi dan edukasi pasar modal yang terus dilakukan oleh BEI (Sadono, 2016).

Pada pasar saham, faktor penting yang akan mempengaruhi keputusan investasi adalah harga saham dan pergerakannya. Untuk mengetahui pergerakan harga saham apakah turun, stabil, atau naik maka dibutuhkan indeks harga saham sebagai indikator yang dapat merepresentasikan hal tersebut. Indeks harga saham utama di BEI adalah Indeks Harga Saham Gabungan (IHSG) karena indeks ini merupakan indeks yang mencerminkan kinerja semua saham yang terdaftar.

Indeks harga saham termasuk IHSG sering mengalami fluktuasi yang cepat dalam waktu singkat, sehingga perlu dilakukan analisis untuk membantu investor dalam pertimbangan pengambilan keputusan yang tepat. Salah satu pendekatan yang dapat digunakan adalah analisis teknikal, yaitu suatu pendekatan yang didasarkan pada prinsip Teori Dow yang meramalkan pergerakan indeks harga saham berdasarkan data historis (Kurniawati *et al.*, 2013). Analisis teknikal dapat dilakukan dengan *quantitative forecasting models* berbasis data *time series* karena indeks harga saham erat kaitannya dengan data historis, yaitu berkaitan dengan pengaruh nilai masa lalu terhadap nilai masa kini. *Time series* akan menganalisis pola hubungan antara variabel yang akan diramalkan dengan variabel waktu.

Metode *time series* yang umum digunakan untuk melakukan peramalan indeks harga saham salah satunya pada IHSG adalah metode Box-Jenkins Autoregressive Integrated Moving Average (ARIMA). Aplikasi ARIMA salah satunya terdapat dalam penelitian Adebiyi *et al.* (2014) yang melakukan peramalan saham *New York Stock Exchange* (NYSE) dan *Nigeria Stock Exchange* (NSE). Pada penelitian tersebut, data yang akan diolah adalah data historis berupa harga saham kedua negara. Harga saham terdiri dari empat unsur, yaitu harga pembuka, harga tertinggi, harga terendah, dan harga penutup. Dari keempat unsur harga saham, harga penutup dipilih untuk diolah karena merupakan data yang dapat merepresentasikan indeks dari semua kegiatan perdagangan. Hasil penelitian menunjukkan bahwa model ARIMA memiliki potensi kuat dalam meramalkan saham untuk jangka pendek. Penelitian lain (Banarjee, 2014) menggunakan ARIMA dalam peramalan *Indian Stock* dan menghasilkan ARIMA (1,0,1) sebagai model terbaik. Model ARIMA yang dihasilkan tidak bisa digunakan jika sewaktu-waktu terjadi fluktuasi pada data yang digunakan karena model tidak dapat mengakomodasi adanya perubahan pola data. Selain model yang tidak *robust*, data yang diolah diasumsikan linear sedangkan pada kenyataannya hal tersebut sangat jarang

terjadi. Oleh sebab itu, ketika menggunakan model untuk meramalkan data dengan pola nonlinear hasil yang diperoleh menjadi tidak efektif.

Penggunaan metode ARIMA fokus pada data empiris yang bersifat normal, linear, dan diasumsikan stasioner (Chen, 1994). Metode ini tidak dapat mengolah suatu data runtun waktu dengan variabilitas yang tinggi sehingga tidak efektif untuk meramalkan indeks harga saham yang bersifat random, nonlinear dan nonstasioner. Berdasarkan hal tersebut, beberapa penelitian selanjutnya mengkombinasikan metode ARIMA dengan *Support Vector Machine* untuk meminimalisir resiko dari data yang fluktuatif.

Support Vector Machine (SVM) merupakan algoritma pembelajaran yang berbasis teori pembelajaran statistik yang diperkenalkan oleh Cortes dan Vapnik (1995). SVM berfungsi mengklasifikasikan dua set data dari kelas yang berbeda secara efisien dengan memetakan data dari dimensi yang rendah ke dimensi yang tinggi menggunakan *nonlinear kernel function* (Devi dkk., 2015). Salah satu aplikasi yang mengkombinasikan ARIMA dengan SVM adalah pada penelitian Sirijunyapong *et al.* (2014) yang melakukan peramalan pada Bursa Efek Thailand. Peramalan saham fokus pada sektor keuangan tiga bank penting Thailand yaitu *Bangkok Bank Public Company Limited* (BBL), *Siam Commercial Bank Public Company Limited* (SCB), dan *Kasikornbank Public Company Limited*. Semua data terkait harga saham ketiga bank didapatkan dari *Smart Portal* (Version 4.6.1). Data tersebut berubah setiap hari dikarenakan faktor ekonomi, politik dan *gross domestic product*. Berdasarkan informasi tersebut, diperoleh bahwa terdapat faktor eksternal yang tidak dapat dikontrol. Faktor-faktor tersebut mempengaruhi perubahan data harga saham sehingga karakteristik data menjadi tidak jelas dan tidak pasti. Oleh karena itu, dalam penelitian ini digunakan SVM untuk mengolah data yang tidak pasti dan memiliki dimensi tinggi dengan cara menerapkan *kernel function* untuk meningkatkan akurasi model peramalan. Penelitian menunjukkan

bahwa SVM memberikan hasil yang lebih baik daripada ARIMA.

Peramalan harga saham dengan menggunakan SVM terus dikembangkan seperti pada penelitian Abolhassani dan Yaghoobi (2010) yang melakukan peramalan *New York Stock Exchange* dengan mengintegrasikan *Support Vector Machine* dan *Particle Swarm Optimization*. Pada penelitian tersebut indikator yang bervariasi dari analisis teknikal digunakan sebagai *input*, seperti korelasi antara harga saham dari perusahaan yang berbeda yakni DJI, S&P 500 dan Nasdaq-100. *Particle Swarm Optimization* (PSO) digunakan untuk memilih *input* yang paling informatif dari semua indikator analisis teknikal. Hasil penelitian menunjukkan bahwa konsep korelasi dan penggunaan PSO mampu meningkatkan kinerja SVM secara signifikan. PSO juga dapat dikombinasikan dengan *Type-2 Fuzzy Time Series*. Kombinasi metode tersebut diaplikasikan pada penelitian yang dilakukan Singh dan Borah (2014) pada perusahaan Google untuk menyesuaikan panjang interval dalam peramalan tanpa meningkatkan jumlah interval. Hasil penelitian menunjukkan bahwa akurasi peramalan model dapat ditingkatkan secara efektif dengan hibridisasi PSO dan *Type-2 Fuzzy Time* melalui utilisasi frekuensi interval bobot dengan defuzifikasi.

Metode lain yang digunakan untuk mengakomodasi kekurangan ARIMA adalah metode peramalan modern Jaringan Saraf Tiruan (JST). Kombinasi ARIMA dengan JST diaplikasikan pada penelitian Rathanaka *et al.* (2015) dalam melakukan peramalan *Colombo Stock Exchange* yang memiliki pola data tidak stabil dan fluktuasi yang bergejolak tinggi. Peramalan pertama dilakukan dengan menerapkan ARIMA dan JST secara terpisah. Pada tahap berikutnya, dilakukan peramalan dengan mengintegrasikan ARIMA dengan JST. Dari kedua tahap penelitian tersebut, didapatkan bahwa metode yang diintegrasikan memberikan solusi terbaik untuk memprediksi harga saham dengan fluktuasi data yang bergejolak tinggi dibandingkan dengan metode yang diterapkan secara terpisah. Pada penelitian lain yang dilakukan oleh Nugraha

dan Azhari (2014) dalam meramalkan tingkat inflasi di Indonesia, digunakan JST sebagai metode peramalan. Berdasarkan penelitian tersebut didapatkan masalah *overfitting* saat proses pembelajaran JST dengan menggunakan algoritma *Backpropagation* sehingga akhirnya tidak dapat menggeneralisasi masalah. Oleh karena itu, maka perlu dilakukan kombinasi suatu metode lain untuk mengatasi kekurangan JST, salah satunya yaitu *Particle Swarm Optimization* yang merupakan salah satu metode *Artificial Intelligence* terbaik untuk optimasi dan perkiraan parameter (Neto *et al.*, 2009). Dengan menggunakan PSO maka akan membantu proses pembelajaran pada JST.

Berdasarkan uraian beberapa penelitian di atas dapat ditarik kesimpulan bahwa penelitian peramalan harga saham terus dikembangkan. Penelitian dilakukan dengan mengkombinasikan beberapa metode untuk saling melengkapi kekurangan dari setiap metode yang diterapkan. Pada penelitian ini, peneliti akan melakukan peramalan Indeks Harga Saham Gabungan dengan mengkombinasikan Jaringan Saraf Tiruan dan *Particle Swarm Optimization*.

Metode

Objek penelitian yang digunakan adalah data Indeks Harga Saham Gabungan pada Maret 2016 sampai Februari 2017. Dari empat jenis harga pasar pada indeks harga saham, data yang digunakan untuk melakukan peramalan adalah harga penutupan karena harga ini merupakan harga yang dapat dijadikan acuan untuk memprediksi harga pembuka di hari berikutnya sehingga membantu dalam mempertimbangkan keputusan investasi. Data selanjutnya akan dibagi menjadi dua kelompok yaitu data untuk pelatihan dan pengujian model dengan komposisi 60% data untuk pelatihan dan 40% data untuk pengujian model. Tahapan pertama dalam pembangunan model adalah menentukan arsitektur dan parameter model. Arsitektur yang dibutuhkan untuk membuat JST adalah jumlah *layer* dan *neuron* di *input*, *hidden*, dan *output layer* sedangkan parameter yang dibutuhkan meliputi *learning rate* dan momentum. Adapun parameter pada

Particle Swarm Optimization (PSO) yaitu jumlah partikel dan konstanta *learning factor* 1 dan *learning factor* 2. Masing-masing parameter JST dan PSO dicari menggunakan *Design of Experiment* dan analisis regresi sehingga diperoleh kombinasi parameter yang optimal. Setelah arsitektur dan parameter model ditentukan, tahapan selanjutnya adalah membangun model. Terdapat dua model yang dibuat, yaitu model JST dengan menggunakan algoritma pembelajaran *Backpropagation* (BP) dan model JST yang dikombinasikan dengan metode metaheuristik PSO. Model BP digunakan untuk pelatihan dan pengujian data sedangkan model kombinasi BP dan PSO hanya digunakan untuk pelatihan data. Model yang dibangun selanjutnya dilakukan validasi untuk membandingkan hasil yang diperoleh dari model dengan kondisi nyata sehingga dapat diketahui apakah model yang dibuat memberikan *error* yang kecil atau tidak. Validasi dilakukan pada tahap proses pengujian, kemudian data hasil pengujian dibuat *tracking signal* untuk melihat persebaran *error* masih dalam batas kendali atau tidak. Setelah model dinyatakan valid, selanjutnya dijalankan untuk mendapatkan hasil peramalan indeks harga saham. Hasil *run* dari dua model dibandingkan berdasarkan waktu dan nilai *error* untuk mengetahui model yang memberikan hasil peramalan yang lebih akurat.


HASIL DAN PEMBAHASAN

Analisis Data


Berdasarkan pola datanya harga penutupan IHSG membentuk pola tren naik seperti terlihat pada Gambar 1. Adanya pola tren memberikan efek yang tidak diinginkan pada kinerja prediksi Jaringan Saraf Tiruan (Tseng *dkk.*, 2002). Oleh karena itu, pola tren naik harga penutupan IHSG diubah menjadi pola stasioner dengan melakukan *differencing*.

Dari hasil *differencing* selanjutnya dilakukan identifikasi data berdasarkan lag-lag signifikan pada partial autocorrelation function (PACF) atau plot fungsi autokorelasi parsial untuk menentukan input dan target. Hasil plot fungsi autokorelasi menunjukkan


bahwa lag yang signifikan adalah lag 29 dan lag 60, sehingga kedua lag tersebut masing-masing akan dijadikan sebagai input 1 dan input 2 pada arsitektur jaringan.



(i)



(ii)



(iii)

Gambar 1

Pola Data (i) Harga Penutupan IHSIG Maret 2016-Februari 2017; (ii) *Differencing-1*; (iii) Autokorelasi Parsial Data *Differencing-1*

Data input dan target yang telah didapatkan kemudian dinormalisasi agar data berada

pada suatu range tertentu sehingga tidak terdapat dominasi data yang bernilai besar terhadap data yang bernilai kecil dan untuk memfasilitasi proses pembelajaran jaringan.

Model Jaringan Syaraf Tiruan – *Back Propagation*

Peramalan IHSIG dengan metode Jaringan Saraf Tiruan akan dilakukan dengan algoritma pembelajaran *Backpropagation* (BP). Algoritma ini akan melakukan pembelajaran terhadap input dan target dengan melakukan adaptasi sesuai parameter-parameter yang telah ditentukan. Proses pembuatan model peramalan dengan menggunakan metode Jaringan Saraf Tiruan diawali dengan menyusun arsitektur dan parameter *Backpropagation*. Arsitektur *Backpropagation* terdiri dari jumlah *layer* dan jumlah neuron pada *input*, *hidden*, dan *output layer*. Arsitektur yang dibuat pada penelitian ini terdiri dari 2 *input layer* dengan 183 neuron, 1 *hidden layer* dengan k neuron, dan 1 *output layer* dengan 183 neuron.

Parameter *Backpropagation* terdiri dari jumlah *epoch*, *learning rate*, momentum, toleransi atau *error goal*, fungsi pelatihan, dan fungsi aktivasi. Penyusunan parameter dalam membuat model peramalan bertujuan untuk mendapatkan bobot yang optimal untuk setiap *layer*. Pada penelitian ini dilakukan *Design of Experiment* (DOE) untuk menentukan kombinasi parameter yang sesuai untuk mendapatkan bobot yang optimal. DOE dilakukan terhadap beberapa parameter yang sangat berpengaruh pada optimasi bobot dengan algoritma *Backpropagation* yaitu *learning rate*, momentum dan jumlah neuron di *hidden layer* (Hsu, 2011). Dalam penyusunan DOE digunakan tiga level (*low*, *medium*, *high*) yang berarti terdapat 3^n *factorial design*, maka ada 27 *design* kombinasi parameter. Untuk algoritma *Backpropagation*, level DOE diambil dari beberapa hasil penelitian yaitu Jabin (2014), Chen dkk., (2013), dan Hsieh dkk., (2011) setelah diuji terlebih dahulu. Tabel 1. merupakan level DOE untuk parameter BP.

Tabel 1.
Level DOE Parameter *Backpropagation*

Parameter	Level		
	Low	Medium	High
Jumlah neuron di <i>hidden layer</i> (nH)	1	6	9
<i>Learning rate</i> (α)	0,25	0,40	0,60
Momentum (Mc)	0,20	0,40	0,95

Berdasarkan analisis DOE didapatkan parameter optimal untuk algoritma *Backpropagation* yaitu jumlah neuron di *hidden layer* sama dengan 1, *learning rate* 0,6 dan momentum 0,2.

Setelah mendapatkan nilai parameter optimal, langkah selanjutnya adalah menjalankan proses pelatihan untuk memperoleh bobot yang optimal dengan menggunakan parameter yang telah didapatkan dari tahap sebelumnya. Adapun beberapa parameter lain nilainya diatur tetap berdasarkan karakteristik jaringan yang akan dibuat. Tabel 2. menunjukkan semua parameter yang akan digunakan untuk membuat model.

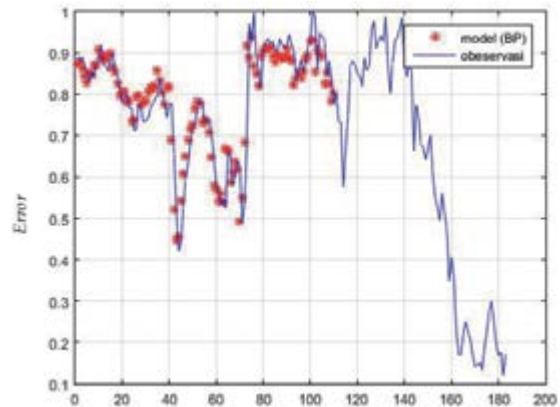
Tabel 2.
Parameter Pelatihan Menggunakan *Backpropagation*

Parameter	Spesifikasi
Arsitektur jaringan	1 <i>hidden layer</i>
Inisialisasi bobot	Nilai acak
Fungsi aktivasi ke <i>hidden layer</i>	Sigmoid bipolar
Fungsi aktivasi ke <i>output layer</i>	Linier
Fungsi pelatihan	<i>Traingd</i>
<i>Learning rate</i>	0,6
Momentum	0,2
Jumlah iterasi (epoch)	60000
Toleransi (MSE)	0,0035

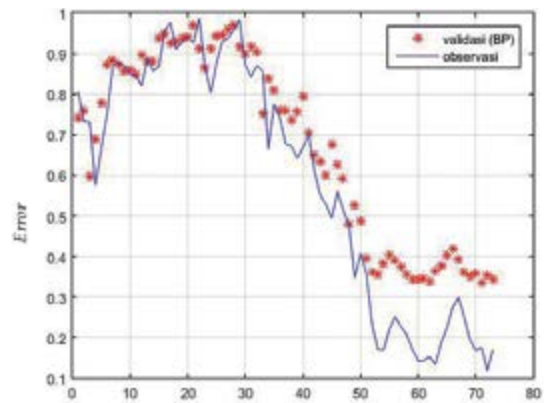
Berdasarkan pelatihan dengan *Backpropagation*, diperoleh hasil MSE 0,0031 dengan waktu komputasi selama 4,9927 detik serta bobot *input* 1 dan 2 ke *hidden layer* masing-masing -0,7890 dan 0,0147, bobot *hidden* ke

output layer -1,4202 dan bias pada *hidden* dan *output layer* masing-masing -0,2166 dan -0,2723.

Setelah proses pelatihan selanjutnya dilakukan pengujian model dengan menggunakan 40% data yang belum digunakan dalam proses pelatihan dengan menggunakan bobot yang telah didapatkan dari hasil pelatihan dan diperoleh MSE pengujian sebesar 0,0131. Gambar 2 menunjukkan hasil pelatihan dan pengujian model.



Hasil Pengujian (i)



Hasil Pengujian (ii)

Gambar 2.
Hasil (i) Pelatihan dan (ii) Pengujian Menggunakan Bobot dari BP

Model Jaringan Syaraf Tiruan – BP+Particle Swarm Optimization

Model yang dibuat dengan algoritma *Particle Swarm Optimization* (PSO) menggunakan parameter *Particle Swarm Optimization* dan arsitektur jaringan dari algoritma *Back-*

propagation. Proses pembuatan model peramalan dengan menggunakan algoritma *Particle Swarm Optimization* diawali dengan menentukan parameter PSO. Parameter *Particle Swarm Optimization* terdiri dari bobot inersia, jumlah partikel, dan *learning factor*. Penyusunan parameter dalam membuat model peramalan bertujuan untuk mendapatkan bobot yang optimal untuk setiap *layer*. Pada penelitian ini dilakukan *Design of Experiment* (DOE) untuk menentukan kombinasi parameter yang sesuai untuk mendapatkan bobot yang optimal. DOE dilakukan terhadap beberapa parameter yang sangat berpengaruh pada optimasi bobot dengan algoritma *Particle Swarm Optimization* yaitu jumlah partikel dan *learning factor*. Dalam penyusunan DOE digunakan 3 level (*low, medium, high*) yang berarti terdapat 3ⁿ factorial design, maka ada 27 design kombinasi parameter. Untuk algoritma *Particle Swarm Optimization*, level DOE diambil dari beberapa hasil penelitian yaitu Asriningtias *et al.* (2015), dan Deng *et al.* (2016) setelah diuji terlebih dahulu. Parameter optimal untuk algoritma *Particle Swarm Optimization* yaitu jumlah partikel sama dengan 11, *learning factor* 1 1,3 dan *learning factor* 2 1,5.

Setelah menentukan parameter optimal, tahap selanjutnya adalah melakukan pelatihan data. Proses pelatihan dilakukan untuk membuat model *Particle Swarm Optimization* dengan menggunakan parameter optimal yang telah didapatkan. Tabel 2. menunjukkan semua parameter yang akan digunakan untuk membuat model.


Tabel 3. Parameter Pelatihan Menggunakan *Particle Swarm Optimization*

Parameter	Spesifikasi
Jumlah partikel	11
<i>Learning factor</i> 1	1,3
<i>Learning factor</i> 2	1,5
Posisi awal partikel	Nilai acak
Kecepatan awal partikel	Nilai acak
Bobot inersia awal	Nilai acak
Bobot inersia minimum	0,4
Bobot inersia maksimum	0,9
Jumlah iterasi	20

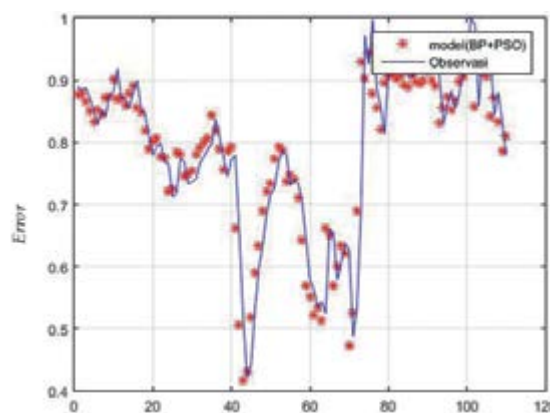
Setelah memasukkan semua parameter pada pelatihan jaringan, dilakukan pelatihan

terhadap 60% data *input* dan target. Berdasarkan pelatihan dengan *Particle Swarm Optimization*, diperoleh hasil MSE 0,0030 dengan waktu komputasi selama 4,3867 detik serta bobot *input layer* 1 dan 2 ke *hidden layer* masing-masing -2,1027 dan 0,2994, bobot *hidden* ke *output layer* -1,8687 dan bias pada *hidden* dan *output layer* masing-masing 0,1801 dan 1,1444. Hasil pelatihan dapat dilihat pada Gambar 3(i).

Setelah proses pelatihan selanjutnya dilakukan pengujian model dengan menggunakan 40% data yang belum digunakan dalam proses pelatihan dengan menggunakan bobot yang telah didapatkan dari hasil pelatihan dan diperoleh MSE pengujian sebesar 0,0062. Gambar 3(ii) menunjukkan hasil pengujian model.



Hasil Pengujian (i)



Hasil Pengujian (ii)

Gambar 3. Hasil (i) Pelatihan dan (ii) Pengujian Menggunakan Bobot dari BP-PSO

Peramalan Out Sample

Berdasarkan dua model peramalan yang telah dibuat, yaitu dengan algoritma *Back-propagation* dan algoritma *Particle Swarm Optimization*, dilakukan perbandingan terhadap

hasil yang didapatkan, yaitu waktu komputasi dan *error* yang dihasilkan. Perbandingan hasil dari kedua model peramalan dapat dilihat pada Tabel 4.

Tabel 4
Perbandingan Hasil BP dan Kombinasi BP dengan PSO

	Waktu Komputasi Proses Pelatihan (detik)	MSE Proses Pelatihan	MSE Proses Pengujian	MAPE Hasil Peramalan (%)
BP	4,9927	0,0031	0,0131	2,5472
BP dengan PSO	4,3867	0,0030	0,0062	1,8823

Melalui hasil yang didapatkan untuk kedua model, dapat diketahui bahwa model yang dibuat dengan kombinasi algoritma BP dan PSO menghasilkan waktu komputasi, *error* model, dan *error* peramalan yang lebih kecil daripada model BP. Apabila dilihat dari nilai MAPE, peramalan yang dilakukan dengan kedua model tersebut termasuk *highly accurate* karena MAPE yang dihasilkan lebih kecil daripada 10%. Oleh karena itu, kedua model BP dan kombinasi BP dengan PSO dapat digunakan untuk melakukan peramalan IHSG, akan tetapi perlu dilakukan pengaturan parameter yang berbeda karena akan menentukan performa algoritma terhadap kasus yang diselesaikan.

SIMPULAN

Peramalan indeks harga saham Bursa Efek Indonesia, telah berhasil dibuat model peramalan IHSG menggunakan metode Jaringan Saraf Tiruan (JST) dengan algoritma *Backpropagation* (BP) dan algoritma *Backpropagation* yang dikombinasikan dengan algoritma *Particle Swarm Optimization* (PSO). Pembuatan model dilakukan dengan mengatur parameter yang telah disesuaikan untuk mendapatkan hasil waktu komputasi, *error* model dan *error* peramalan yang minimal. Melalui analisis yang telah dilakukan pada bab hasil dan pembahasan, didapatkan model BP dengan PSO menghasilkan waktu komputasi dan *error* model yang lebih kecil daripada model BP yaitu 4,3867 detik dengan MSE proses pelatihan dan pengujian masing-masing 0,0030 dan 0,0062. Berdasarkan hasil tersebut, diperoleh bahwa model BP dengan PSO

memberikan hasil yang lebih baik dibandingkan model BP. Adapun peramalan yang dilakukan dengan kedua model tersebut termasuk *highly accurate* karena MAPE yang dihasilkan lebih kecil daripada 10% yaitu 2,55% untuk BP dan 1,88% untuk BP dengan PSO.

DAFTAR PUSTAKA

- Abdulmajeed, A.A., Narhi, T.O., Vallitu, P.K., and Lassila L.V., 2011, The Effect of High Fiber Fraction on Some Mechanical Properties of Unidirectional Glass Fiber-Reinforced Composite. *J. Dent. Materials*. 27 : 313-321.
- Abolhassani, A.T., dan Yaghoobi, M., 2010, Stock Price Forecasting Using PSO SVM, *Advanced Computer Theory and Engineering*, pp. 352-356.
- Adebiyi, A.A., Adewumi, A.O., dan Ayo, C.K., 2014, Stock Price Prediction Using The ARIMA Model, *Computer Society*, pp. 106-112.
- Asriningtias, S.R., Dachlan, H.S., dan Yudaningtyas, E., 2015, Optimasi Training Neural Network Menggunakan Hybrid Adaptive Mutation PSO-BP, *Jurnal Electrics, Electronics, Communications, Controls, Informatics, Systems*, 9(1), pp. 79-84.
- Banarjee, D., 2014, Forecasting of Indian Stock Market Using Time-Series ARIMA Model, *Business and Information Management*, pp. 131-135.
- Chen, C.H., 1994, Neural Networks for Financial Market Prediction, *Neural Networks*, 2, pp. 1199-1202.

- Chen, M.Y., Fan, M.H., Chen, Y.L., dan Wei, H.M., 2013, Design of Experiments on Neural Network's Parameters Optimization for Time Series Forecasting in Stock Markets, *Neural Network World*, 23(4), pp. 369-393.
- Cortes, C. dan Vapnik, V., 1995, Support Vector Networks, *Machine Learning*, 20(3), pp. 273-295.
- Deng, W., Wang, G., Zhang, X., Xu, J., dan Li, G., 2016, A Multi-Granularity Combined Prediction Model Based on Fuzzy Trend Forecasting and Particle Swarm Techniques, *Neurocomputing*, 173(3), pp. 1671-1682.
- Devi, K.N., Bhaskaran, V.M., dan Kumar, G.P., 2015, Cuckoo Optimized SVM for Stock Market Prediction, *2015 International Conference on Innovations in Information, Embedded and Communication Systems Proceedings*, pp. 1-5.
- Hsieh, L.F., Hsieh, S.C., dan Tai, P.H., 2011, Enhanced Stock Price Variation Prediction Via DOE and BPNN-based Optimization, *Expert Systems with Application*, 38(11), pp. 14178-14184.
- Hsu, C.M., 2011, Forecasting Stock/Futures Prices by Using Neural Networks with Feature Selection, *International Information Technology and Artificial Intelligence 2011 Conference Proceedings*, pp. 1-7.
- Jabin, S., 2014, Stock Market Prediction Using Feed-forward Artificial Neural Network, *International Journal of Computer Applications*, 99(9), pp. 4-8.
- Khirbat, G., Gupta, R., dan Singh, S., 2013, Optimal Neural Network Architecture for Stock Market Forecasting, *Communication Systems and Network Technologies 2013 Proceedings*, pp. 557-561.
- Kurniawati, L.Y., Tjandrasa, H., dan Arieshanti, I., 2013, Prediksi Pergerakan Harga Saham Menggunakan Support Vector Regression, *Jurnal Teknologi Informasi dan Komunikasi*, 8(2), pp. 11-21.
- Kustodian Sentral Efek Indonesia, 2016, *Raih Rekor Baru, Jumlah Investor Tercatat Naik 26%*, <http://www.ksei.co.id>, (diakses 16 Desember 2016).
- Neto, M., Petry, G.G., Aranildo, R.L., dan Ferreira, T.A., 2009, Combining Artificial Neural Network and Particle Swarm System for Time Series Forecasting, *International Joint Conference on Neural Networks*, pp. 2230-2237.
- Nugraha, H.G., dan Azhari, S.N., 2014, Optimasi Bobot Jaringan Saraf Tiruan Menggunakan Particle Swarm Optimization, *Indonesian Journal of Computing and Cybernetics Systems*, 8(1), pp. 25-36.
- Ratyanaka, R.M.K.T., Seneviratne, D.M.K.N., Jianguo, W., dan Arumawadu, H.I., 2015, A Hybrid Statistical Approach for Stock Market Forecasting Based on Artificial Neural Network and ARIMA Time Series Models, *Behavioral, Economic, and Socio-Cultural Computing*, pp. 54-60.
- Sadono, Y.A., 2016, *BEI: Jumlah Investor Pasar Modal Domestik Mencapai 500.037*, <http://www.antaranews.com/berita/584991/bei-jumlah-investor-pasar-modal-domestik-mencapai-500037>, (diakses 4 Desember 2016).
- Singh, P., dan Borah, B., 2014, Forecasting Stock Index Price Based on M-factors Fuzzy Time Series and Particle Swarm Optimization, *International Journal of Approximate Reasoning*, 55(3), pp. 812-833.
- Sirijunyapong, W., Leelasantitham, A., Kiattisin, S., dan Wongseree, W., 2014, Predict The Stock Exchange of Thailand-Set, *Information and Communication Technology, Electronic and Electrical Engineering*, pp. 978-982.
- Tseng, F.M., Yu, H.C., dan Tzeng, G.H., 2002, Combining Neural Network Model with Seasonal Time Series ARIMA Model, *Technological, Forecasting, and Social Change*, 69(1), pp. 71-87.