

Neural Networks Multiscale Autoregressive untuk Peramalan Data Time Series

¹BRODJOL SUTIJO, ¹SUHARTONO & ¹ALFONSUS J. ENDHARTA

¹Jurusan Statistika FMIPA Institut Teknologi Sepuluh Nopember

ABSTRAK

Transformasi wavelet yang banyak digunakan untuk peramalan time series adalah *Maximal Overlap Discrete Wavelet Transform* (MODWT). Penggunaan MODWT adalah untuk mengatasi keterbatasan *discrete wavelet transform* (DWT), yang membutuhkan $N=2^J$ dimana J adalah bilangan bulat positif. Praktis, data time series jarang memenuhi kondisinya tersebut. Skala dan koefisien wavelet yang diberikan oleh MODWT akan digunakan untuk peramalan time series. Ada beberapa penelitian yang berkaitan dengan NN-MAR untuk peramalan time series, biasanya berfokus pada bagaimana untuk mendapatkan model NN-MAR yang sesuai untuk peramalan data time series. Tujuan dari penelitian ini adalah untuk mengembangkan prosedur yang tepat untuk pemodelan NN-MAR data time series musiman, dan untuk membandingkan akurasi ramalan antara NN-MAR, ARIMA, dan MAR (multiscale Autoregressive). Studi empiris data penumpang pesawat yang digunakan menunjukkan bahwa prosedur yang dikembangkan tidak baik dalam pembentukan model NN-MAR cocok untuk peramalan data time series musiman. Perbandingan ketepatan ramalan menunjukkan bahwa model NN-MAR harus digunakan sebagai model untuk peramalan data karena data nonlinier.

Kata Kunci: Transformasi wavelet, NN-MAR, Time Series

1 Pendahuluan

Pada dekade ini, jaringan syaraf tiruan telah diusulkan dalam banyak penelitian. Ada banyak jenis neural network diterapkan untuk menyelesaikan banyak masalah. Sebagai contoh, Teknik Feedforward Neural Network (FFNN) diterapkan dalam peramalan permintaan listrik, General Regression Neural Network araf (GRNN) digunakan dalam peramalan nilai tukar (Leung et al, 2000.) (Taylor et al, 2006.), dan Recurrent Neural Network (GRNN) telah diterapkan dalam mendeteksi perubahan dalam proses autokorelasi untuk pemantauan kualitas (Pacella dan Semeraro, 2007). Berbeda dengan penelitian terdahulu, di sini, prediktor atau input bukan lag dari variabel-variabel atau variabel data, namun berupa koefisien dari transformasi wavelet.

Sebuah pengembangan baru yang terkait dengan aplikasi transformasi wavelet untuk analisis time series telah diusulkan. Sebagai gambaran umum ini dapat dilihat pada Nason dan Von Sachs (1999). Pada awalnya, sebagian besar penelitian wavelet untuk analisis time series difokuskan pada analisis periodogram atau scalogram periodisitas dan evaluasi siklus (lihat Priestley, 1996; Morretin, 1997; Gao, 1997; Percival dan Walden, 1999). Bjorn (1995), Soltani et al. (2000), dan Renaud et al. (2003) adalah beberapa kelompok peneliti pertama membahas wavelet untuk prediksi time series berdasarkan model autoregressive. Dalam hal ini, transformasi wavelet memberikan dekomposisi baik dari serangkaian sinyal atau waktu, sehingga struktur dapat dievaluasi dengan model parametrik atau nonparametrik

Neural Network Multiscale Autoregressive (NN-MAR) model adalah jaringan syaraf tiruan dengan fungsi wavelet digunakan untuk memproses atau sebagai fungsi transfer dari input. Dalam kasus peramalan time series, input yang digunakan dalam NN-MAR adalah koefisien wavelet dalam waktu tertentu dan resolusi. Sampai saat ini, hanya ada beberapa artikel membahas NN-MAR khusus untuk peramalan time series dan penyaringan, beberapa dari mereka adalah Bashir dan El-Hawary (2000), Renaud et al. (2003), Murtagh et al. (2004), dan Chen et al. (2006)

Transformasi wavelet yang banyak digunakan untuk peramalan time series adalah *Maximal Overlap Discrete Wavelet Transform* (MODWT). Penggunaan MODWT adalah untuk mengatasi keterbatasan *discrete wavelet transform* (DWT), yang membutuhkan $N=2^J$ dimana J adalah bilangan bulat positif. Praktis, data time series jarang memenuhi kondisinya tersebut. Skala dan koefisien wavelet yang diberikan oleh MODWT akan digunakan untuk peramalan time series. Ada beberapa penelitian yang berkaitan dengan NN-MAR untuk peramalan time series, biasanya berfokus pada bagaimana untuk mendapatkan model NN-MAR yang sesuai untuk peramalan data time series. Tujuan dari penelitian ini adalah untuk mengembangkan prosedur yang tepat untuk pemodelan NN-MAR data time series musiman, dan untuk membandingkan akurasi ramalan antara NN-MAR, ARIMA, dan MAR (multiscale Autoregressive).

2 Wavelet

Wavelet berarti gelombang kecil, sebaliknya, sinus dan cosinus adalah gelombang besar (Percival dan Walden, 2000). Pada umumnya, wavelet adalah fungsi yang memiliki karakteristik jika terintegralkan pada $(-\infty, \infty)$ hasilnya adalah nol, dan integral fungsi kuadrat sama dengan 1.

Ada dua fungsi dalam transformasi wavelet, fungsi skala yaitu (ayah wavelet) dan wavelet ibu. Kedua fungsi memberikan sebuah fungsi keluarga yang dapat digunakan untuk merekonstruksi sinyal. Beberapa keluarga wavelet yang Haar wavelet, yang merupakan wavelet paling tua dan paling sederhana, selain itu ada Meyer Wavelet, Wavelet Daubechies, Mexican Hat Wavelet, Wavelet Coiflet, dan Asymmetric Terakhir (Daubechies, 1992)

Persamaan Skala menunjukkan fungsi skala mengalami kontraksi (dilatasi) dan translasi (Debnath, 2002), dimana fungsi skala skala mengalami kontraksi atau diterjemahkan dalam sumbu waktu dengan l langkah.

Pada DWT, misalkan data memenuhi 2^j . Pada umumnya data tidak mengikuti konsep DWT. Pada MODWT memiliki keuntungan, yang dapat menghilangkan kehadiran reduksi data ke setengah (downsampling). Sehingga dalam MODWT ada N wavelet dan koefisien skala di setiap tingkat MODWT (Percival dan Walden, 2000).

2.1 Wavelet Time Series

Umumnya, peramalan deret waktu yang diberikan dengan menggunakan wavelet adalah suatu peramalan dengan menggunakan data yang mengalamai pemrosesan melalui transformasi wavelet, khususnya melalui MODWT. Dengan adanya dekomposisi multiskala seperti wavelet, keuntungan secara otomatis memisahkan komponen-komponen data, seperti komponen trend dan komponen tidak teratur dalam data. Dengan demikian, peramalan data stasioner (mengandung komponen tidak teratur saja) atau data non-stasioner (trend mengandung dan komponen tidak teratur).

Sebagai contoh, anggaplah bahwa sinyal stasioner $X = (X_1, X_2, \dots, X_t)$ dan menganggap nilai X_{t+1} yang akan diperkirakan. Ide dasarnya adalah menggunakan koefisien yang dibangun dari dekomposisi, yaitu (Renaud et al, 2003.)

$$w_{j,t-2^j(k-1)} \text{ untuk } k = 1, 2, \dots, A_j \quad j = 1, 2, \dots, J$$

dan


$$v_{j,t-2^j(k-1)} \text{ untuk } k = 1, 2, \dots, A_j$$

Poin pertama yang harus dipahami adalah berapa banyak koefisien wavelet digunakan dalam skala masing-masing.

Untuk menjelaskan masukan, ramalan data ke $(t + 1)$ dan prosedur pemodelan dengan menggunakan wavelet, Renaud et al. (2003) memperkenalkan proses input dari model wavelet seperti ilustrasi pada Gambar 1. tersebut merupakan bentuk umum dari pemodelan wavelet dengan tingkat J , = 4 order $A_j = 2$ dan $N = 16$. Angka itu menggambarkan bahwa jika data ke-18 akan diperkirakan, variabel masukan adalah tingkat koefisien wavelet 1 pada $t = 17$ dan $t =$ tingkat koefisien 15, wavelet 2 pada $t = 17$ dan $t = 13$, tingkat koefisien wavelet 3 pada $t = 17$ dan $t =$ tingkat koefisien 9, wavelet 4 pada $t = 17$ dan $t = 1$. Dan tingkat koefisien halus 4 pada $t = 17$ dan $t = 1$. Dengan demikian, kita dapat menyimpulkan bahwa input kedua di tiap tingkatan adalah.

Ide dasar dari dekomposisi multiskala adalah pengaruh tren frekuensi rendah (L) komponen yang cenderung deterministik; Sementara, frekuensi tinggi (H) komponen masih stokastik. Poin kedua yang should dipahami dalam pemodelan wavelet untuk peramalan adalah mengetahui fungsi yang digunakan untuk proses input, koefisien wavelet yaitu untuk output seperti proyeksi periode ke $(t + 1)$ periode th . Umumnya, ada dua macam fungsi yang dapat digunakan dalam proses input-output, seperti fungsi linier dan fungsi nonlinier.

Renaud et al. (2003) mengembangkan model linier wavelet dikenal sebagai multiskala Autoregressive (MAR) model. Selain itu, Renaud et al. (2003) juga memperkenalkan kemungkinan menggunakan model nonlinier dalam memproses input-output model wavelet, khususnya Feed-Forward Neural Network (FFNN). Selain model kedua dikenal sebagai Jaringan Syaraf - multiskala Autoregressive (NN-MAR) model. Kedua pendekatan adalah model menggunakan tertinggal dari koefisien wavelet sebagai masukan, yaitu skala dan koefisien halus seperti pada Gambar 1.

Gambar 1 Wavelet modeling illustration for $J=4$ and $A_f=2$

2.2 Multiscale Autoregressive (MAR)

Sebuah proses autoregresif dengan p order yang dikenal sebagai AR (p). Dengan menggunakan dekomposisi koefisien wavelet, Renaud et al. (2003) menjelaskan bahwa prediksi AR dalam cara ini menjadi model multiskala Autoregressive (MAR). Model Neural Networks - Multiscale Autoregressive (NN-MAR), mendasarkan pada model JST-MAR dengan menggunakan koefisien yang ditemukan oleh dekomposisi seperti pada Gambar 1, untuk memperoleh nilai ramalan dengan arsitektur jaringan neural tertentu. Renaud et al. (2003) memperkenalkan Multilayer Perceptron (MLP) arsitektur jaringan saraf atau dikenal sebagai Feed-Forward Neural Network (FFNN) yang akan memproses koefisien wavelet. FFNN arsitektur yang digunakan terdiri dari satu lapisan tersembunyi dengan neuron P . Dalam FFNN, fungsi aktivasi pada lapisan output adalah linier. Model JST_MAR selanjutnya dikenal sebagai wavelet Jaringan Syaraf (WNN) atau multiresolusi Jaringan Syaraf (MNN).

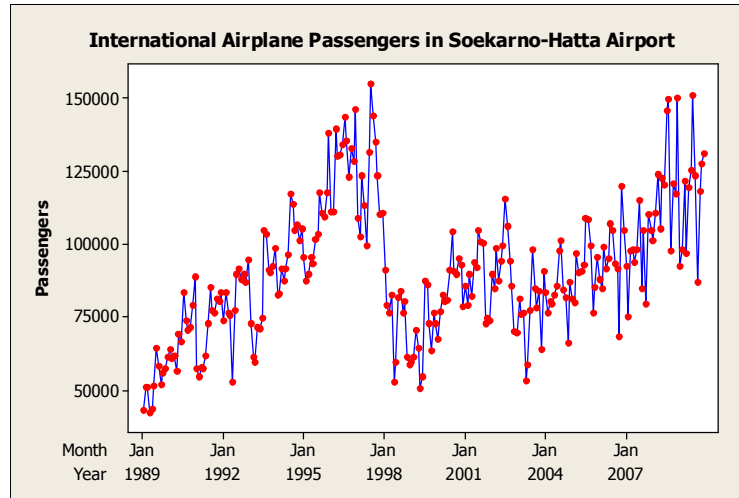
3 Metodologi Penelitian

Data penelitian adalah jumlah penumpang pesawat memasuki bandara interna-sional Soekarno-Hatta dan Bandara Ngurah Rai, dari Januari 1989 hingga Desember 2009. Data in-sampel 240 observasi pertama dan 12 observasi terakhir adalah out sampel. Tahap awal analisis adalah dengan menerapkan dekomposisi MODWT. Berdasarkan nilai skala dan koefisien wavelet dengan menggunakan dekomposisi MODWT serta pada pola yang dihasilkan, maka prosedur FFNN umum untuk peramalan data deret waktu dapat dilakukan. Pemilihan model NN-MAR terbaik adalah dilakukan oleh kombinasi penambahan kontribusi statistik inferensi dalam skema forward untuk penentuan jumlah optimal unit neuron pada lapisan tersembunyi dan uji Wald di belakang skema untuk pemilihan unit input yang optimal. Sebagai tambahan dalam penelitian ini ada lag musiman, karena data berpola musiman. Ada empat prosedur peodelan, yaitu prosedur pertama dan kedua untuk data stasioner, sedangkan ketiga dan keempat prosedur digunakan untuk data yang memiliki trend. Oleh karena itu, dalam penelitian ini hanya prosedur keempat diterapkan. Stepwise metode yang digunakan untuk menyederhanakan proses dalam menemukan masukan yang signifikan.

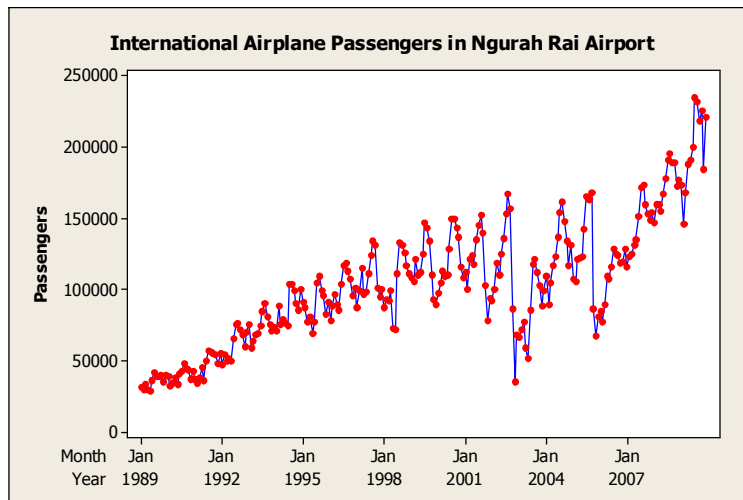
Langkah awal sebelum menerapkan NN-MAR prosedur pembentukan model adalah penentuan tingkat atau J di MODWT. Dalam hal ini, semua skala dan koefisien wavelet kelambatan dari MAR (2) dan tambahan musiman kelambatan yang signifikan dengan menggunakan metode stepwise, digunakan. Berbeda dari model wavelet linear atau MAR yang membagi pemodelan untuk dua bagian aditif (pemodelan yaitu kecenderungan koefisien wavelet dan pemodelan MAR dari perbedaan data dan koefisien wavelet dan koefisien skala kelambatan), dalam model NN-MAR tersebut pemodelan dilakukan secara bersamaan dengan menggunakan skala dan koefisien wavelet lags. Hal ini didasarkan pada kenyataan bahwa NN-MAR adalah model nonlinier diharapkan mampu menangkap karakteristik data secara bersamaan dengan menggunakan skala dan koefisien wavelet dari MODWT.

4 Hasil dan Pembahasan

Plot data diperlihatkan pada Gambar 2 dan Gambar 3. Plot menunjukkan bahwa data yang memiliki pola musiman dan trend. Dengan demikian, perbandingan selanjutnya adalah antara NN-MAR dan model MAR. Sebagai langkah awal, fokus pemodelan adalah dalam penentuan jumlah yang sesuai neuron dalam lapisan tersembunyi. Sehingga dalam penelitian ini, skala dan wavelet input lag koefisien diasumsikan menjadi seperti input lag dalam pengujian nonlinieritas pada langkah pertama. Hal ini berasal dari penelitian terakhir bahwa perbandingan antara model linier dan skala dan input koefisien wavelet akurasi peramalan sama.



Gambar 2 penumpang pesawat memasuki bandara Internasional Soekarno-Hatta



Gambar 3 penumpang pesawat memasuki Internasional Ngurah Rai Bandara

Seperti penjelasan pada bagian sebelumnya, setiap prosedur yang diusulkan dimulai dengan menggunakan uji nonlinieritas dalam data. Dalam hal ini, Terasvirta tes digunakan (lihat Suhartono, 2007). Hasil uji Terasvirta menggunakan skala dan koefisien wavelet tertinggal sebagai masukan, yang diusulkan oleh Renaud et al. (2003), menunjukkan bahwa ada hubungan nonlinear antara koefisien dan data pada waktu t . Dengan demikian, penggunaan model linier untuk peramalan data, termasuk model NN-MAR benar. Langkah selanjutnya adalah pemilihan jumlah yang sesuai neuron pada lapisan tersembunyi. Langkah ini dimulai dengan melibatkan sedikitnya jumlah neuron, mulai dari 1 sampai kontribusi Selain tidak signifikan.

Ringkasan hasil jumlah neuron seleksi untuk data penumpang pesawat di bandara internasional Soekarno-Hatta, yang sesuai dengan model NN-MAR menggunakan input lag diusulkan oleh Renaud et al. (2003) dan input lag tambahan, dapat dilihat pada Tabel 1 untuk Daubechies (4) wavelet keluarga atau D (4) dan Tabel 2 untuk

keluarga wavelet Haar. Berdasarkan hasil ringkasan dalam Tabel 1, dan 2 model NN-MAR terbaik untuk meramalkan jumlah penumpang pesawat memasuki bandara internasional Soekarno-Hatta memiliki satu neuron pada lapisan tersembunyi untuk D (4) dan dua neuron pada lapisan tersembunyi Haar. Dalam hal ini, masukan adalah kelambatan skala dan koefisien wavelet dari MAR (2) dan multiplikatif musiman kelambatan, yang signifikan dikenal dengan metode stepwise (lihat Prasetyo, 2009).

Tabel 1. Ringkasan Pemilihan Banyak Neuron, menggunakan wavelet D(4) untuk data Soekarno-Hatta airport

Number of neurons	RMSE of in-sample	RMSE of out-sample	R^2	$R^2_{\text{increment}}$	F	P-value
1	12818.5	25609.5	0.150186	-	-	-
2	12815.2	25592.2	0.150277	0.000091	0.003442	1
3	12814.5	25571.8	0.149962	0.000315	0.011541	1
4	12814.6	25555.6	0.149624	0.000338	0.011981	1
5	12814.9	25539.8	0.149242	0.000382	0.013085	1
6	12811.6	25695.0	0.151765	0.002523	0.083708	1
7	12811.2	25697.8	0.151837	0.000072	0.002304	1
8	12811.3	25693.0	0.151786	0.000051	0.001572	1
9	12811.3	25697.3	0.151829	0.000043	0.001275	1
10	12811.1	25698.7	0.151868	0.000039	0.001110	1

Tabel 2. Ringkasan Pemilihan Banyak Neuron menggunakan Wavelet Haar data Soekarno-Hatta airport

Number of neurons	RMSE of in-sample	RMSE of out-sample	R^2	$R^2_{\text{increment}}$	F	P-value
1	11815.3	23865.3	0.239635	-	-	-
2	10999.3	26427.6	0.326966	0.087331	1.372694	0
3	10948.6	26726.1	0.330281	0.003315	0.047414	1
4	10833.8	27694.2	0.341287	0.011006	0.143340	1
5	10835.6	27543.6	0.340720	0.000567	0.006518	1
6	10829.1	27804.2	0.341755	0.001035	0.010344	1
7	10830.2	27668.9	0.341337	0.000418	0.003541	1
8	10829.1	27759.8	0.341753	0.000416	0.002894	1
9	10828.3	27815.4	0.341627	0.000126	0.000685	1
10	10967.9	26323.3	0.330210	0.011417	0.04396	1

Demikian pula, ringkasan untuk model NN-MAR dari penumpang pesawat di bandara internasional Ngurah Rai ditunjukkan pada Tabel 3 dan Tabel 4. Dari tabel ini, yang NN-MAR model yang cocok untuk data di bandara Ngurah Rai memiliki satu neuron dalam lapisan tersembunyi untuk kedua keluarga wavelet Haar D (4) dan keluarga Haar Wavelet.

Tabel 3. Ringkasan Pemilihan Banyak Neuron menggunakan Wavelet D(4) data Ngurah Rai airport

Number of neurons	RMSE of in-sample	RMSE of out-sample	R ²	R ² _{increment}	F	P-value
1	13241.2	21048.9	0.196989	-	-	-
2	12864.5	21139.5	0.227205	0.030216	0.640632	1
3	12733.2	20847.5	0.239425	0.012220	0.247181	1
4	12720.3	20837.4	0.240584	0.001159	0.021953	1
5	12688.0	20794.9	0.243407	0.002823	0.049941	1
6	12705.6	20818.0	0.241889	0.001518	0.024798	1
7	12725.8	20846.6	0.240074	0.001815	0.027191	1
8	12687.4	20789.9	0.243593	0.003519	0.048312	1
9	12678.4	20776.1	0.244318	0.000725	0.009004	1
10	12682.9	20786.7	0.243996	0.000322	0.003571	1

Tabel 4. Ringkasan Pemilihan Banyak Neuron menggunakan Wavelet haar data Ngurah Rai airport

Number of neurons	RMSE of in-sample	RMSE of out-sample	R ²	R ² _{increment}	F	P-value
1	13094.8	21522.4	0.196989	-	-	-
2	12766.5	21835.0	0.227205	0.030216	0.640632	1
3	12577.3	21318.5	0.239425	0.012220	0.247181	1
4	12573.9	21343.1	0.240584	0.001159	0.021953	1
5	12569.9	21343.5	0.243407	0.002823	0.049941	1
6	12566.4	21339.8	0.241889	0.001518	0.024798	1
7	12565.2	21338.8	0.240074	0.001815	0.027191	1
8	12556.5	21320.9	0.243593	0.003519	0.048312	1
9	12562.5	21332.9	0.244318	0.000725	0.009004	1
10	12561.4	21330.9	0.243996	0.000322	0.003571	1

Tabel 5. Ringkasan Pemilihan Banyak Neuron

Data	Model	RMSE of in-sample	RMSE of out-sample
Soekarno Hatta	NN-MAR(2), Haar, 2 neurons	10999.3	26427.6
	NN-MAR(2), D(4), 1 neuron	12818.5	25609.5
	MAR($J=4$;[1,3,11,25],[1,11,12],[1,13,23,49], [13],[1,35,37,48,49])-Haar	10666.6	15818.7
	MAR($J=4$;[23],[5,11],[1],0,0)-D(4)	12485.3	21501.2
Ngurah Rai	NN-MAR(2), Haar, 1 neuron	13094.8	21522.4
	NN-MAR(2), D(4), 1 neuron	13241.2	21048.9

MAR($J=4$;[1,36],[11,36],[12,37,47,49], [24],[1,12,13,35]-Haar	11342.2	19694.7
MAR($J=4$;[36],[5,11,23,35,47,48],[1,23,25] , 0,[1]-D(4)	11617.3	20420.6

Berdasarkan hasil pada Tabel 5, dapat ditunjukkan bahwa model MAR dengan tingkat dekomposisi MODWT 4 dengan metode stepwise dalam pemilihan variabel adalah model dengan RMSE terendah in-sampel dan RMSE terendah keluar-sampel. Padahal, model ini bukan model terbaik karena pola antara input dan data respon tidak linier. Oleh karena itu, jumlah penumpang pesawat internasional di Bandara Soekarno-Hatta akan menjadi yang terbaik diperkirakan dengan menggunakan NN-MAR (2) dengan D (4) keluarga wavelet dan 2 neuron pada lapisan tersembunyi. Jumlah penumpang pesawat internasional yang masuk bandara Ngurah Rai akan baik diperkirakan dengan menggunakan NN-MAR (2) dengan keluarga wavelet yang sama tetapi hanya 1 neuron pada lapisan tersembunyi. Model ini dibandingkan berdasarkan RMSE out-sampel.

5 Kesimpulan

Berdasarkan hasil pada bagian sebelumnya, studi empiris data penumpang pesawat menunjukkan bahwa prosedur yang dikembangkan tidak baik dalam pembentukan model NN-MAR cocok untuk peramalan data time series musiman. Perbandingan ketepatan ramalan menunjukkan bahwa model NN-MAR harus digunakan sebagai model untuk peramalan data karena data nonlinier.

Daftar Pustaka

- Bashir, Z. and El-Hawary, M.E., 2000, *Short term load forecasting by using wavelet neural networks*, Canadian Conference on Electrical and Computer Engineering, 163–166.
- Bjorn, V., 1995, *Multiresolution methods for financial time series prediction*, in Proc. IEEE/IAFE 1995 Conf. Computational Intelligence for Financial Eng. 97.
- Chen, Y., Yang, B., and Dong, J., 2006, *Time-series prediction using a local wavelet neural network*, Neurocomputing, **69**, 449–465.
- Damayanti, I., 2008, *Wavelet method for forecasting of nonlinear time series*, Unpublished Master Thesis, Department of Statistics, Institut Teknologi Sepuluh Nopember, Indonesia.
- Daubechies, I., 1992, *Ten Lectures on Wavelets*, Society for Industrial and Applied Mathematics, Philadelphia: SIAM.
- Debnath, L., 2002, *Wavelet Transform and Their Application*, Birkhauser, Boston.
- Gao, H.-Y., 1997, *Choice of thresholds for wavelet shrinkage estimate of the spectrum*, J. Time Series Anal., **18**, 231-251.
- Li, D., 2003, *Empirical Study of Investment Behaviour in equity Markets using Wavelet Methods*, Thesis, Rensselaer Polytechnic Institute, Troy, New York.
- Morettin, P.A., 1997, *Wavelets in statistics*, Resenhas, **3**, 211-272.
- Murtagh, F., Starck, J.L., and Renaud, O., 2004, *On neuro-wavelet modeling*, Decision Support Systems, **37**, 475–484.
- Nason, G.P. and von Sachs, R., 1999, *Wavelets in time series analysis*, Phil. Trans. R. Soc. Lond. A, **357**, 2511-2526.
- Percival, D.B. and Walden, A.T., 1999, *Wavelets Methods for Time Series Analysis*, Cambridge: Cambridge Univ. Press.
- Prasetyo, M. D., 2009. *The Application of Wavelet Method to Multiscale Autoregressive Model for Forecasting The Seasonal Time Series*. Unpublished Bachelor Project, Department of Statistics, Sepuluh Nopember Institute of Technology, Indonesia.
- Priestley, M.B., 1996, *Wavelets and time-dependent spectral analysis*, J. Time Series Analysis, **17**, 85-104.
- Renaud, O., Stark, J.L. and Murtagh, F., 2003, *Prediction based on a Multiscale Decomposition*, Int. Journal of Wavelets, Multiresolution and Information Processing, **1**(2), pp. 217-232.
- Soltani, S., Boichu, D., Simard, P., and Canu, S., 2000, *The long-term memory prediction by multiscale decomposition*, Signal Processing, **80**, 2195–2205.
- Subanar and Suhartono, 2008a, *New Procedures for Model Selection in Feedforward Neural Network for Time Series Forecasting*, Presented at 7th World Congress in Probability and Statistics, National University of Singapore, Singapore.

- Subanar and Suhartono, 2008b, *Wavelet Neural Network for Financial Time Series Forecasting*, Working Paper, Fundamental Research, Department of Mathematics, Gadjah Mada University, Indonesia.
- Suhartono, 2007, *Feedforward Neural Network for Time Series Modeling*, Unpublished PhD Dissertation, Department of Mathematics, Gadjah Mada University, Indonesia.