

PERAMALAN KUNJUNGAN WISATAWAN MENGUNAKAN *EMPIRICAL MODE DECOMPOSITION* DAN *CASCADE FORWARD BACKPROPAGATION*

Sri Herawati

Fakultas Teknik, Universitas Trunojoyo
Jl. Raya Telang Po. Box 2 Kamal, Bangkalan, 69162
e-mail : sriherawati@trunojoyo.ac.id

Abstract

The growth of tourism demand is an important source for economic development, jobs, tax revenues, and incomes. Forecasting is needed to monitor fluctuations in tourism demand. Most tourism demand influenced by several factors, such as economic conditions, seasonal variation, or politics. Thus, the task of forecasting was quite difficult to accommodate these factors. One method of forecasting tourism demand is the integration of Empirical Mode Decomposition (EMD) with a neural network-based Feedforward Neural Network (FNN). To accelerate learning process and improve the accuracy of forecasting, this research using Cascade Forward Backpropagation (CFN). Data tourist visits was decomposed using EMD. Then, all the results from the decomposition (IMF and residues) are used as inputs in the CFN. Outcomes of CFN merged using Adaptive Linear Neural Network (Adaline) to obtain the final forecasting value . Results of this research was accelerated the learning process and improved the accuracy of forecasting tourism demand better than EMD and FNN.

Keywords: *Forecasting, Tourism Demand, Empirical Mode Decomposition, Cascade Forward Backpropagation, Adaptive Linear Neural Network.*

Abstrak

Pertumbuhan kunjungan wisatawan menjadi sumber penting untuk pembangunan ekonomi, lapangan kerja, penerimaan pajak, dan pendapatan. Peramalan dibutuhkan untuk memantau fluktuasi kunjungan wisatawan. Sebagian besar kunjungan wisatawan ini dipengaruhi beberapa faktor, seperti: kondisi ekonomi, variasi musiman, atau politik. Sehingga, tugas peramalan cukup sulit untuk mengakomodasi faktor-faktor tersebut. Salah satu metode yang ditujukan untuk meramalkan kunjungan wisatawan adalah integrasi Empirical Mode Decomposition(EMD) dengan jaringan syaraf tiruan berbasis Feedforward Neural Network (FNN). Untuk mempercepat proses pembelajaran dan meningkatkan akurasi peramalan, penelitian ini menggunakan Cascade Forward Backpropagation (CFN). Data kunjungan wisatawan didekomposisi menggunakan EMD. Kemudian, semua IMF dan residu hasil dekomposisi dijadikan masukan pada CFN. Hasil keluaran CFN digabung menggunakan Adaptive Linear Neural Network (Adaline) untuk memperoleh nilai peramalan. Hasil penelitian menggunakan integrasi EMD dan CFN dapat mempercepat proses pembelajaran dan meningkatkan akurasi peramalan kunjungan wisatawan yang lebih baik daripada EMD dan FNN.

Kata Kunci : *Peramalan, Kunjungan Wisatawan, Empirical Mode Decomposition, Cascade Forward Backpropagation, Adaptive Linear Neural Network.*

1. PENDAHULUAN

Pertumbuhan kunjungan wisatawan menjadi sumber penting dari pembangunan ekonomi (Coshall & Charlesworth, 2011; Chen, 2011; Andrawis et al, 2011), lapangan kerja (Pai et al, 2014), penerimaan pajak, dan pendapatan (Chen et al, 2012; Claveria & Torra, 2014). Peramalan dibutuhkan untuk memantau dan mengantisipasi tren kunjungan wisatawan. Oleh karena itu, peramalan yang akurat sangat penting bagi instansi dan industri terkait di sektor pariwisata seperti : perhotelan (Guizzardi & Stacchini, 2015) dan transportasi.

Peramalan tentang kunjungan wisatawan telah dilakukan oleh beberapa penelitian sebelumnya, seperti peramalan yang mengintegrasikan *Empirical Mode Decomposition(EMD)* dengan *Backpropagation Neural Network (FNN)* (Chen et al, 2012). Sebagian besar kunjungan wisatawan dipengaruhi oleh beberapa faktor, seperti: kondisi ekonomi, variasi musiman atau politik, sehingga EMD dapat

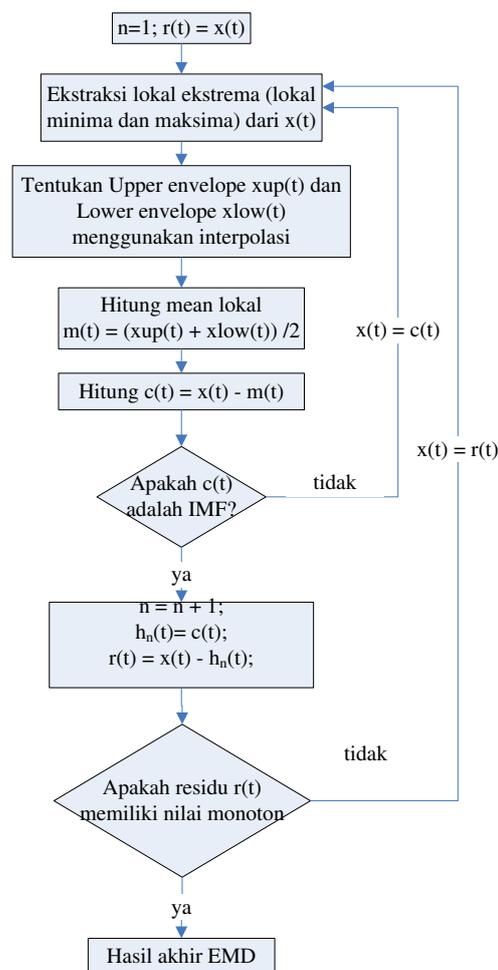
mengakomodasi fluktuasi dan kompleksitas faktor tersebut. Hasil penelitian tersebut menunjukkan peramalan yang baik. Demikian juga dengan penelitian bidang lain yang memanfaatkan EMD dan FNN menunjukkan hasil peramalan yang lebih akurat, seperti: peramalan harga saham (Herawati, 2013) dan harga minyak mentah (Herawati, 2014; Herawati & Latif, 2015). Namun, proses pembelajaran FNN cukup lama melakukan proses pembelajaran. Sehingga, penelitian ini mengusulkan untuk menggunakan Cascade Forward Backpropagation (CFN).

Sebenarnya CFN mirip dengan FNN, tetapi CFN memiliki koneksi bobot dari masukan ke setiap lapisan dan dari setiap lapisan ke lapisan berikutnya (Lashkarbolooki et al, 2013). Lapisan tersembunyi memiliki bobot yang berasal dari masukan dan lapisan keluaran memiliki bobot yang berasal dari lapisan masukan dan sebelumnya. Hubungan antara lapisan input dan lapisan keluaran menyebabkan CFN lebih efisien dibandingkan FNN (Filik & Kurban, 2007). Oleh karena itu, penelitian mengintegrasikan EMD dan CFN untuk mempercepat proses pembelajaran dan meningkatkan akurasi peramalan.

2. TINJAUAN PUSTAKA

2.1 Empirical Mode Decomposition (EMD)

Empirical Mode Decomposition merupakan metode untuk menguraikan serangkaian waktu menjadi sejumlah *Intrinsic Mode Functions* (IMFs) dan residu berdasarkan pemisahan skala (Huang, 1998). Skala didefinisikan sebagai jarak antara dua ekstrem lokal minimum atau maksimum yang berurutan. EMD telah terbukti cukup fleksibel mengekstraksi sinyal dari data yang mempunyai karakteristik *nonlinier* dan *nonstasioner*. Trnka & Hofreiter (2011) menggunakan EMD ini untuk analisis data runtun waktu dengan hasil yang baik. Proses algoritma EMD dapat dilihat pada Gambar 1.



Gambar 1. Flowchart Algoritma EMD

Berdasarkan Gambar 1 dapat dijelaskan bahwa algoritma EMD melakukan dekomposisi sinyal data aktual menjadi IMF dan residu, sehingga data aktual $x(t)$ diperoleh seperti pada Pers. (1).

$$x(t) = \sum_{i=1}^n c_i(t) + r(t) \quad (1)$$

Dimana n menyatakan jumlah IMF, $c_i(t)$ menyatakan IMF ke- i , dan $r(t)$ menyatakan residu.

2.2 Cascade Forward Backpropagation (CFN)

Secara umum pembelajaran CFN mirip dengan FNN. Fungsi kinerja galat dalam CFN untuk penelitian ini menggunakan *Root Mean Squared Error (RMSE)*, *Mean Square Error (MSE)*, *Mean Absolute Deviation (MAD)*, dan *Mean Absolute Percentage Error (MAPE)*. Persamaan untuk RMSE, MSE, MAD, dan MAPE seperti ditunjukkan pada Pers. (2), Pers. (3), Pers. (4), dan Pers. (5). Dimana A_t menyatakan data aktual pada waktu t , F_t adalah data peramalan pada waktu t , dan n merupakan jumlah data.

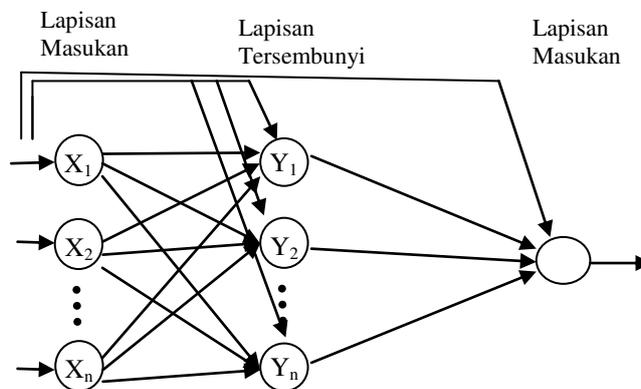
$$RMSE = \sqrt{\sum_{t=1}^n (F_t - A_t)^2} \quad (2)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (F_t - A_t)^2 \quad (3)$$

$$MAD = \frac{1}{n} \sum_{t=1}^n |A_t - F_t| \quad (4)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{A_t} \times 100\% \quad (5)$$

Arsitektur jaringan CFN dapat dilihat pada Gambar 2. Berdasarkan Gambar 2 dapat dijelaskan bahwa arsitektur CFN memiliki tiga lapisan yaitu lapisan masukan, lapisan tersembunyi dan lapisan keluaran. Perbedaan antara FNN dan CFN bahwa CFN memiliki koneksi bobot dari masukan ke setiap lapisan dan dari setiap lapisan ke lapisan berikutnya.



Gambar 2. Arsitektur Cascade Forward Backpropagation

3. METODE PENELITIAN

Tahap desain metode penelitian peramalan kunjungan wisatawan dilakukan dengan mengintegrasikan EMD dan CFN. Secara keseluruhan, tahapan dilakukan seperti dalam Gambar 3.

3.1 Data kunjungan wisatawan

Data kunjungan wisatawan merupakan data runtun waktu yang ditampilkan berdasarkan waktu dan terjadi berurutan. Data runtun waktu dapat digunakan untuk memperkirakan kejadian masa yang akan datang, karena pola perubahan data pada beberapa periode masa lalu dapat berulang kembali pada masa akan datang.

3.2 Dekomposisi Data dengan EMD

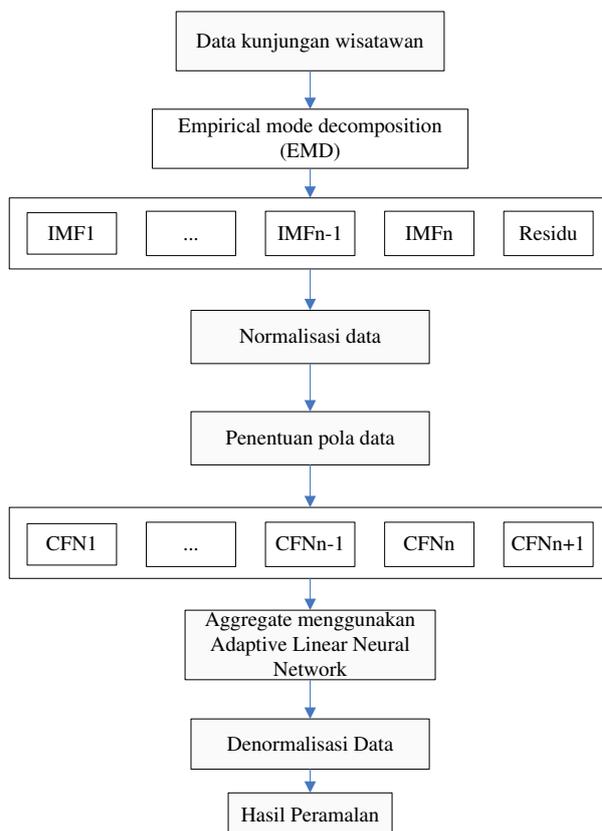
Tahapan dekomposisi data menggunakan EMD. Pada dasarnya proses ini berkaitan dengan dekomposisi data kunjungan wisatawan menjadi beberapa IMF dan residu.

3.3 CFN

Sebelum proses pelatihan dan pengujian menggunakan CFN, data dilakukan proses normalisasi. Normalisasi data bertujuan untuk memenuhi persyaratan dari fungsi aktivasi yang digunakan dalam penelitian ini. Normalisasi akan ditransformasikan ke interval yang lebih kecil yaitu interval 0,1 sampai 0,9. Kemudian, penentuan pola data digunakan untuk penentuan jumlah masukan, tersembunyi, dan target jaringan.

3.4 Aggregate menggunakan adaptive linear neural network (Adaline)

Proses selanjutnya adalah data hasil pengujian untuk masing-masing IMF dan residu digabung menggunakan Adaline. Langkah terakhir dilakukan denormalisasi terhadap data keluaran Adaline. Denormalisasi akan mengembalikan data hasil peramalan menjadi angka sebenarnya, karena nilai peramalan memiliki jangkauan antara 0 sampai 1.



Gambar 3. Desain Metode Penelitian

4. HASIL DAN PEMBAHASAN

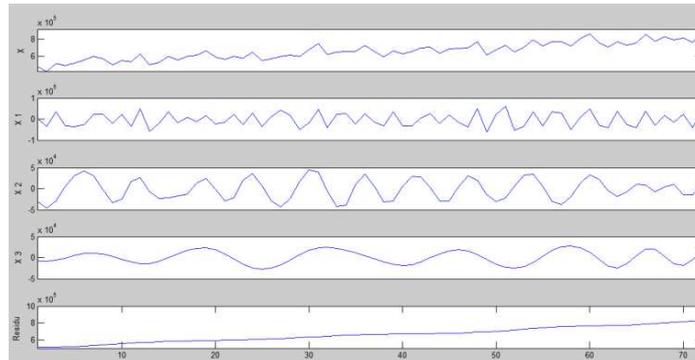
4.1. Data Uji Coba

Penelitian ini menggunakan data sekunder yang diperoleh dari Pusdatin Kemenparekraf dan Badan Pusat Statistika (BPS) Republik Indonesia. Data sekunder yang digunakan adalah data banyaknya kunjungan wisatawan Mancanegara perbulan ke Indonesia menurut pintu masuk dan kebangsaan. Data dimulai dari Januari 2009 sampai Desember 2014 sebanyak 72 data. Data pertama sebanyak 85%

digunakan untuk proses pelatihan untuk membangun model peramalan, sedangkan 15% sisanya digunakan untuk keperluan pengujian kinerja dari model peramalan.

4.2. Analisis dan Hasil Uji Coba

Uji coba penelitian dilakukan dengan dekomposisi data kunjungan wisatawan menggunakan EMD. Dekomposisi menghasilkan tiga IMF dan satu residu seperti pada Gambar 4.



Gambar 4. Hasil Dekomposisi EMD

Setelah itu, data untuk masing-masing IMF dan residu dinormalisasi untuk memenuhi persyaratan fungsi aktivasi jaringan syaraf. Kemudian ditentukan pola data jaringan yang meliputi; jumlah neuron lapisan masukan, tersembunyi, dan keluaran. Penelitian menggunakan tiga neuron masukan yang mengakomodasi peramalan per kuartal. Jumlah neuron lapisan tersembunyi menggunakan jangkauan dari satu sampai dengan lima, karena tidak ada teori umum untuk pemilihannya. Jaringan hanya mempunyai satu neuron keluaran yaitu jumlah kedatangan wisatawan mancanegara.

Proses uji coba untuk FNN dan CFN untuk masing-masing jenis pola data dilakukan dengan menggunakan jumlah iterasi sebanyak 10.000 kali, laju pembelajaran sebesar 0,1, dan toleransi kesalahan sebesar 0,0001. Kinerja hasil peramalan untuk metode EMD-FNN dan EMD-CFN ditunjukkan pada Tabel 1 dan Tabel 2.

Tabel 1. Perbandingan Hasil Peramalan untuk EMD-FNN.

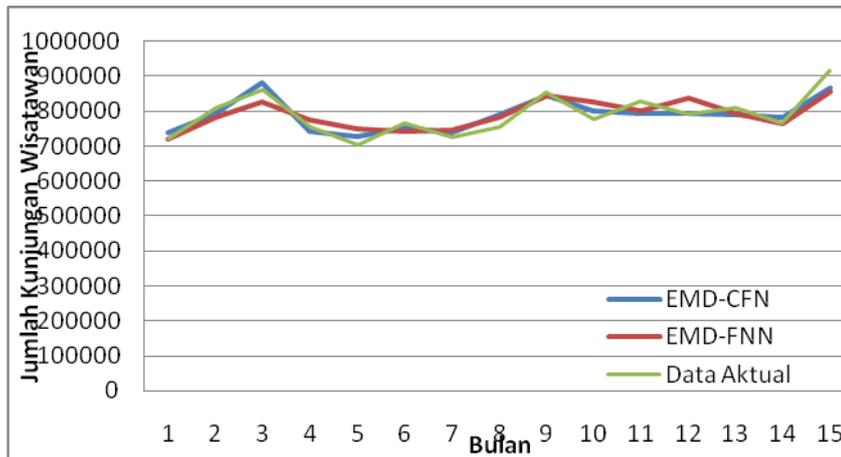
Pola Data	RMSE	MSE	MAD	MAPE
3-1-1	0,1895	0,0359	40599,06	5,12
3-2-1	0,1192	0,0142	26908,95	3,39
3-3-1	0,1531	0,0234	26935,84	3,40
3-4-1	0,1567	0,0246	30802,78	3,91
3-5-1	0,1374	0,0189	34025,75	4,29

Tabel 2. Perbandingan Hasil Peramalan untuk EMD-CFN.

Pola Data	RMSE	MSE	MAD	MAPE
3-1-1	0,0957	0,0092	20631,95	2,61
3-2-1	0,0880	0,0077	20369,12	2,57
3-3-1	0,1190	0,0142	29636,23	3,80
3-4-1	0,1318	0,0174	31919,04	4,09
3-5-1	0,1268	0,0161	30161,00	3,84

Berdasarkan Tabel 1 dapat dilihat bahwa hasil peramalan EMD-FNN terbaik diperoleh untuk pola data 3-2-1 dengan nilai RMSE, MSE, MAD, dan MAPE berturut-turut sebesar 0,1192, 0,0142, 26908,95, dan 3,39%. Sedangkan Tabel 2 dapat dilihat bahwa hasil peramalan EMD-CFN terbaik diperoleh untuk pola data 3-2-1 dengan nilai RMSE, MSE, MAD, dan MAPE berturut-turut sebesar 0,0880, 0,0077, 20369,12 dan 2,57%. Dari Tabel 1 dan Tabel 2 dapat diamati bahwa hasil peramalan EMD-CFN lebih baik dibandingkan EMD-FNN berdasarkan nilai RMSE, MSE, MAD, dan MAPE. Semakin kecil nilai kesalahan, maka semakin akurat hasil peramalan yang dihasilkan.

Jumlah kunjungan wisatawan aktual dan hasil peramalan dari EMD-FNN, EMD-CFN ditunjukkan pada Gambar 5. Dari Gambar 5 dapat dilihat gambaran seberapa dekat data hasil proses peramalan dengan data aktual untuk kedua metode yang dibandingkan. Grafik tersebut dihasilkan dengan menggunakan data untuk pengujian (sebesar 15% terakhir dari data yang digunakan). Seperti terlihat dalam gambar tersebut, metode peramalan EMD-FNN maupun EMD-CFN menunjukkan kedekatan hasil yang cukup akurat terhadap data aktual kunjungan wisatawan. Namun seperti ditunjukkan dalam Tabel 1 dan 2, hasil peramalan EMD-CFN lebih baik dengan nilai RMSE, MSE, MAD, dan MAPE yang lebih kecil dibandingkan hasil peramalan EMD-FNN.



Gambar 5. Grafik perbandingan hasil peramalan dengan data aktual

5. KESIMPULAN

Dari hasil dan pembahasan dapat disimpulkan bahwa metode peramalan yang mengintegrasikan metode EMD dengan CFN (EMD-CFN) dalam penelitian memberikan hasil yang lebih baik dibandingkan dengan EMD dan FNN (EMD-FNN). Kesimpulan ini didasarkan pada nilai RMSE, MSE, MAD, dan MAPE yang lebih kecil. Nilai RMSE, MSE, MAD, dan MAPE terbaik berturut-turut sebesar 0,0880, 0,0077, 20369,12 dan 2,57%. Nilai tersebut diperoleh dengan pola data 3-2-1 (tiga neuron lapisan masukan, dua neuron lapisan tersembunyi dan satu neuron lapisan keluaran).

DAFTAR PUSTAKA

- Andrawis, R.R., Atiya, A. F., & El-Shishiny, H. 2011. Combination of Long Term and Short term Forecasts, with Application to Tourism Demand Forecasting. *International Journal of Forecasting* 27, pp. 870 – 886.
- Chen, C. F., Lai, M.C., Yeh, C.C., 2012. Forecasting Tourism Demand Based on Empirical Mode Decomposition and Neural Network. *Knowledge-Based Systems* 26, pp. 281 - 287.
- Chen, K.Y. 2011. Combining Linear and Nonlinear Model in Forecasting Tourism Demand. *Expert Systems with Applications* 38, pp. 10368 – 10376.
- Claveria, O., Torra, S. 2014. Forecasting Tourism Demand to Catalonia : Neural Network vs. Time Series Models. *Economics Modelling* 36, pp. 220 – 228.
- Coshall, J.T. & Charlesworth, R., 2011. A Management Orientated Approach to Combination Forecasting of Tourism Demand. *Tourism Management* 32, pp. 759 – 769.
- Filik, U.B. & Kurban, M. 2007. A New Approach for the Short-Term Load Forecasting with Autoregressive and Artificial Neural Network Models, *International J. Computational Intelligence Research* 3.
- Guizzardi, A. & Stacchini, A., 2015. Real-time Forecasting Regional Tourism with Business Sentiment Surveys. *Tourism Management* 47, pp. 213 -223.

- Herawati, S. & Latif, M. (2015, Juni). Peramalan Harga Minyak Mentah menggunakan Ensemble Empirical Mode Decomposition dan Resilient Backpropagation. Makalah disajikan dalam Seminar Teknologi dan Rekayasa, Malang : Universitas Muhammadiyah Malang.
- Herawati, S. 2013. Peramalan Harga Saham Menggunakan Integrasi Empirical Mode Decomposition Dan Jaringan Syaraf Tiruan. Mikrotek, Vol. 1, No.1.
- Herawati, S. 2014. Peramalan Harga Minyak Mentah Menggunakan Gabungan Metode Ensemble Empirical Mode Decomposition dan Jaringan Syaraf Tiruan. Simantec, Vol. 4, No. 1.
- Huang, N.E., Shen, Z., & Long, S.R.1998. The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Nonstationary Time Series Analysis. *Process of the Royal Society of London, A* 454, pp. 903–995.
- Lashkarbolooki, M., Shafipour, Z.S., & Hezave, A.Z. 2013. Trainable Cascade-Forward Back-propagation Network Modeling of Spearmint Oil Extraction in a Packed Bed Using SC-CO₂. *The Journal of Supercritical Fluids* 73, pp. 108 – 115.
- Pai, P.F., Hung, K.C., & Lin, K.P., 2014. Tourism Demand Forecasting Using Novel Hybrid System. *Expert Systems with Applications* 41, pp. 3691 – 3702.
- Trnka, P. & Hofreiter, M. 2011. The Empirical Mode Decomposition in Real-Time. 18th International Conference on Process Control, Tatranska Lomnica, Slovakia, June 14-17 2011, pp. 284 – 289.