

PREDIKSI SIKLUS MATAHARI MENGGUNAKAN EVOLVING RECURRENT NEURAL NETWORKS SOLAR CYCLE PREDICTION USING EVOLVING RECURENT NEURAL NETWORKS

Khairul Azhar¹, Agung Toto Wibowo², Untari Novia Wisey³

¹Teknik Informatika, Fakultas Teknik Informatika, Universitas Telkom

Abstrak

Prediksi siklus matahari merupakan tugas yang sulit dan penting. Prediksi ini menjadi sulit disebabkan karena sifat chaotic yang dimilikinya dan rentang antar siklus kira-kira 11 tahun lamanya. Kemudian, prediksi ini menjadi penting karena pengaruhnya yang berdampak kepada kehidupan dibumi seperti, satelit, cuaca, sistem telekomunikasi dan jaringan listrik.

Teorema embedding Taken adalah alat penting yang digunakan untuk menganalisa sistem yang bersifat chaotic dengan mengubahnya kedalam phase space. Sistem chaotic yang diubah ke dalam phase space membuat sistem ini menjadi deterministik dan memperlihatkan informasi yang tersembunyi sehingga lebih mudah untuk diprediksi.

Evolving Recurrent Neural Networks (ERNN) adalah sebuah metode yang diusulkan untuk menemukan model Elman-RNN yang optimal melalui algoritma optimasi Evolutionary Programming (EP) untuk prediksi siklus matahari. Elman-RNN telah menunjukkan hasil yang bagus dalam kasus prediksi. Hal ini karena Elman-RNN mampu menangkap dinamika sistem melalui unit yang disebut context layer. Sedangkan EP adalah salah satu algoritma optimasi Evolutionary Algorithms (EAs) yang panjang kromosomnya dapat berbeda-beda. Sehingga EP cocok digunakan untuk menemukan bobot yang tepat dengan arsitektur Elman-RNN yang dirancang dinamis.

Model Elman-RNN terbaik yang diperoleh memiliki rata-rata satu buah neuron hidden. Dengan model ini diperoleh nilai NMSE training $2,6 \times 10^{-3}$ dan testing $6,5 \times 10^{-4}$.

Kata Kunci : prediksi, siklus matahari, Evolutionary Programming, Elman Neural Networks, sunspot, teorema embedding Taken, chaotic, time series.



Abstract

Solar cycle prediction is difficult and important task. This prediction is difficult because it shows chaotic behaviour and has 11-years cycle approximately. Then, this prediction is important because its impact to earth like satellite, weather, telecommunication system, and electric transmission.

Embedding's Taken theorem is important tool to analyse chaotic system by transforming it into phase space. In phase space, chaotic system shows deterministic and unfolds hidden information. So, it makes solar cycle is easy to predict.

Evolving Recurrent Neural Networks (ERNN) is proposed method to find optimum Elman-RNN model by using optimization algorithm of Evolutionary Programming to predict solar cycle. In recent years, Elman-RNN has showed good result in prediction. It caused Elman-RNN can find dynamical of system through unit called context layer. On the other hand, EP is one of optimization algorithm of Evolutionary Algorithms (EAs) that its chromosome length can be different size. So, EP is good to find proper weights and proper Elman architecture.

The best Elman-RNN model has one neuron in hidden layer mostly. The proposed method yields NMSE for training $2,6 \times 10^{-3}$ and testing $6,5 \times 10^{-4}$.

Keywords : prediction, solar cycle, Evolutionary Programming, Elman Neural Networks, sunspot, Taken's embedding theorem, chaotic, time series.



1. Pendahuluan

1.1 Latar belakang

Matahari adalah sumber energi utama untuk sistem tata surya pada umumnya dan bumi pada khususnya. Aktivitas matahari yang terjadi tentu akan mempengaruhi planet disekitarnya baik itu pengaruh positif atau negatif. Salah satu pengaruh positifnya adalah matahari dimanfaatkan sebagai sumber energi pembangkit listrik dan salah satu pengaruh negatifnya adalah badi magnetik yang dapat mempengaruhi kehidupan di bumi. Tingkat aktivitas matahari dapat diamati dalam preode siklus 11 tahun matahari. Dalam periode 11 tahun, siklus matahari terdiri dari priode aktivitas matahari maksimum dan matahari minimum [24-26]. Pada saat matahari maksimum akan terjadi jumlah *flare* yang lebih sering dan lebih kuat, bilangan *sunspot* yang semakin bertambah, dan menyebabkan gangguan medan magnet bumi yang semakin besar juga. Apabila medan magnet bumi terganggu maka ionosfer juga akan terganggu yang besar gangguannya sebanding dengan aktivitas matahari [26]. Aktivitas matahari yang tinggi akan memberikan dampak dibumi dalam hal iklim, cuaca, samudera, satelit, misi antariksa, sistem telekomunikasi (kabel dan nirkabel), dan jaringan transmisi tenaga listrik [24,8,1,3,4,20,27]. Ada beberapa indikasi yang bisa digunakan untuk mengukur aktivitas matahari seperti bilangan *sunspot(sunspot numbers)*.

Salah satu indikasi yang bagus untuk memprediksi siklus matahari [24,8,1,3,4] danyang paling umum digunakan [31,32] adalah bilangan *sunspot* dalam hal ini menggunakan *sunspot time series*. *Sunspot time series* merupakan sekumpulan data tentang bilangan *sunspot* dari tahun 1700 hingga sekarang. *Sunspot time series* memiliki sifat *nonlinear*, *non-stationary* atau *chaotic*[8,1,32,40,21,33] dan mengandung *noise* [8]. Sifat *Nonlinear* berarti prediksi tidak bisa menggunakan metode yang konvensional yang hanya dapat digunakan untuk masalah *linear* dan tentunya akan lebih sulit memprediksi kasus *nonlinear*[28]. Sifat *chaotic* berarti sistem yang dibangun oleh *time series* tersebut sangat sensitif pada kondisi awal dimana perubahan kecil pada kondisi awal akan mempengaruhi *trend* dari sistem secara substansi dan setelah beberapa iterasi, sistem menjadi tidak dapat diprediksi atau proses ini disebut *Butterfly effect* [1]. Karena sifat dari *sunspot time series* dan dampak dari siklus matahari ini membuat prediksi siklus matahari menjadi hal yang menantang, sulit, dan penting untuk dilakukan.

Beberapa metode telah diusulkan untuk memodelkan nilai yang akan datang dari *sunspot time series* seperti *linear regression*, *autoregressive moving average* (ARMA), dan metode Kalman filtering-based. Metode ini mudah diterapkan namun tidak memberikan hasil yang bagus dalam memprediksi *sunspot time series* karena secara teori beberapa metode tersebut hanya cocok untuk kasus *linear*[28] bukan *nonlinear*. *neural networks* telah menunjukkan potensi yang luar biasa dalam memprediksi kasus *nonlinear* [1,3,4,20,27,22,16]. *Neural networks* memiliki kemampuan untuk memperkirakan berbagai fungsi *nonlinear* secara universal [20,22,27] dan juga sering *robust* terhadap data yang bersifat *noise* [11]. *Neural networks* dapat dikategorikan ke dalam *dynamic networks* seperti *Recurrent Neural Networks* (RNN) dan *static networks* atau *feedforward networks* seperti

Multi-Layer Perceptron neural networks (MLPNN) [1]. Penggunaan MLPNN untuk memprediksi chaotic time series memiliki *inherent limitation*, semenjak tidak dapat menemukan *finite nonlinear autoregressive* (NAR) yang tepat dan performansi terbatas dalam memodelkan sistem yang dinamik [20,28,22]. Sebaliknya RNN dapat memproyeksikan sifat dinamik dari sistem secara otomatis dan memiliki kemampuan memasukkan pengalaman masa lalu dari *time series* kedalam *internal recurrence*, sehingga RNN secara komputasi lebih *powerful*, efisien dan dapat mengatasi *inherent limitation* daripada MLPNN untuk menghasilkan prediksi yang lebih baik dalam memprediksi *nonlinear time series* [24,20,28,27,22]. Walaupun RNN memberikan hasil yang terbaik dalam prediksi *nonlinear time series*, dalam merancang RNN merupakan sesuatu yang sulit. dibutuhkan usaha yang cukup keras dan waktu yang cukup lama untuk menemukan arsitektur dan parameter yang optimal dari RNN [43]. Karena performansi dari RNN tergantung dari arsitektur dan parameter jaringan tersebut.

Teorema *embedding* Taken digunakan untuk memaksimalkan kinerja dari RNN dalam memprediksi *nonlinear chaotic time series*. Teorema ini digunakan untuk mempermudah dalam membaca *chaotic time series*. Prosesnya adalah dengan mengubah *sunspot time series* ke dalam *phase space* menggunakan dua parameter *time delay* (T) dan *embedding dimension* (D) [8,1]. Namun, untuk menggunakan teorema taken secara efisien, diperlukan nilai T dan D yang tepat sesuai dengan kondisi dari *chaotic time series* sendiri. Jika nilai T dan D yang dipilih tepat, maka data time series dapat dibagun ke dalam *phase space* sehingga dapat memperlihatkan informasi yang tersembunyi pada sistem [1]. Metode sebelumnya, *false nearest neighbour* untuk menentukan D dan *mutual information* untuk menentukan T , tidak hanya kompleks dalam menghitungnya tetapi juga akan memperoleh hasil yang tidak sesuai.

Pada penggeraan Tugas Akhir (TA), *Evolving Recurrent Neural Networks* (ERNN) digunakan dalam menyelesaikan permasalahan prediksi siklus matahari. ERNN adalah metode yang mengombinasikan antara RNN dengan *Evolutionary Algorithms* (EAs) dimana EAs yang dikenal sebagai metode global untuk optimalisasi [8], membantu RNN untuk memberikan hasil prediksi yang baik dengan cara mengoptimalkan parameter dan struktur RNN dan juga menentukan nilai T dan D pada teorema *embedding* Taken. Metode ini terinspirasi dari penelitian sebelumnya yang dilakukan oleh Qian-Li Ma et al. (2007) [22]. Performasi dari metode ini memberikan hasil yang cukup baik [8,1]. Namun pada penelitian yang dilakukan, tidak disebutkan secara spesifik EAs yang digunakan sehingga ini membuka peluang bagi peneliti lain untuk memakai metode ini dengan menggunakan jenis EAs yang lain. Namun pada penggeraan TA ini, peneliti menggunakan EAs jenis *Evolutionary Programming* (EP) dan menggunakan RNN jenis Elman-RNN.

1.2 Perumusan masalah

Berdasarkan penjelasan pada paragraf sebelumnya, maka masalah yang akan dirumuskan dalam penggeraan TA adalah sebagai berikut :

1. Bagaimakah mengimplementasikan ERNN untuk menghasilkan model RNN dan parameter *embedding* yang optimal untuk memprediksi siklus matahari?
2. Bagaimakah menentukan parameter EP sehingga didapat kromosom yang terbaik untuk kasus prediksi siklus matahari?
3. Bagaimakah performansi dari ERNN dan cara mengukur performansi dari ERNN dalam prediksi siklus matahari?
4. Berapa langkah prediksi yang akan dilakukan untuk melihat kehandalan ERNN?

1.3 Tujuan

Tujuan yang ingin dicapai dalam pengerojan TA ini adalah sebagai berikut :

1. Membangun sistem ERNN untuk menghasilkan model RNN dan parameter *embedding* yang optimal untuk memprediksi siklus matahari.
2. Menganalisis parameter EP yang optimal sehingga didapat kromosom yang terbaik untuk membangun Elman-RNN dalam memprediksi siklus matahari.
3. Menganalisis dan mengukur performansi ERNN untuk menghasilkan model RNN dan parameter *embedding* yang optimal untuk memprediksi siklus matahari.
4. Menerapkan dan menganalisis model RNN dan parameter *embedding* yang dihasilkan pada prediksi satu/beberapa langkah kedepan.

1.4 Batasan masalah

Batasan masalah dalam TA ini adalah sebagai berikut :

1. Data yang digunakan adalah *monthly smoothed sunspot time series* yang berasal dari *Solar Influences Data Analysis Centre* (SIDC) yang dulunya bernama Sunspot Index Data Centre. SIDC dapat diakses melalui situs <http://sidc.oma.be/index.php3>.
2. Algoritma optimasi EP hanya berfokus pada pencarian model RNN dan parameter *embedding* yang optimal. Pada pencarian model RNN yang optimal, dalam hal ini Elman-RNN, hanya berfokus pada pencarian model arsitektur dan nilai-nilai parameternya. Pada model arsitektur berfokus pada jumlah *input*, jumlah *neuron* pada *hidden layer*, dan jumlah *neuron* pada *output layer* yang dibuat dinamis. Sedangkan jumlah *layer* pada *hidden layer* hanya menggunakan satu *layer*. Untuk nilai-nilai parameter optimal Elman-RNN hanya berfokus pada nilai-nilai *weights* saja. Pada pencarian parameter *embedding* yang optimal berfokus pada parameter *embedding dimension(D)* dan parameter *time delay (T)*. Berdasarkan teorema *embedding* Taken, jumlah input dan neuron output Elman-RNN, serta jumlah dimensi dari *phase space (D)* memiliki nilai yang sama.
3. Ada beberapa komponen Elman-RNN yang tidak digunakan diantaranya penggunaan bias.
4. *Transfer function* atau fungsi aktivasi yang digunakan pada *neural networks* adalah *hyperbolic tangent sigmoid* atau *hyperbolic tangent (tansig)* dan fungsi *linear* atau *purelin*.

5. Pada penelitian ini tidak menangani masalah *overfitting* dan *underfitting* yang disebabkan oleh sistem ERNN.

1.5 Metodologi penyelesaian masalah

Metode penyelesaian masalah dalam penggerjaan TA adalah sebagai berikut :

1. Studi literatur, yaitu mencari dan mempelajari berbagai referensi seperti jurnal, *textbook*, web resmi, dan TA *repository* IT Telkom. Jurnal yang dijadikan acuan Penulis adalah jurnal yang sebagian besar memiliki rantang tahun 2007-2012 dengan tujuan untuk mengetahui perkembangan dari prediksi siklus matahari telah sejauh mana dan metode apa saja yang telah digunakan. Studi literatur juga dimaksudkan untuk mendalami konsep EP, Elman-RNN, dan teorema *embedding* Taken.
2. Konsultasi dan diskusi, yaitu melakukan konsultasi dan diskusi dengan pembimbing TA, Lembaga Penerbangan dan Antariksa Nasional (LAPAN), dan para pakar lainnya.
3. Perancangan ERNN, yaitu menganalisa kebutuhan yang diperlukan dalam merancangan ERNN. Perancangan ERNN direpresentasikan dengan diagram blok.
4. Implementasi ERNN, yaitu mengimplementasikan perancangan ERNN yang telah dibuat dengan melakukan *coding* menggunakan *toolsMatlab* versi R2012b.
5. Tes, analisa hasil, dan kesimpulan, yaitu melakukan pengujian pada sistem yang telah di *training* dengan menggunakan data *testing*. Kemudian hasilnya akan dianalisa sesuai dengan parameter-parameter pengujian yang telah ditetapkan sebelumnya. Dari hasil analisa akan diperoleh sistem yang optimal kemudian sistem ini akan di uji keandalannya untuk melakukan prediksi satu langkah ke depan. Hasil keseluruhan pengujian kemudian akan dibandingkan dengan metode lain yang disebutkan dalam literatur [8,1,22]. Setelah itu ditarik kesimpulan dan hasil analisa.
6. Penyusunan laporan, yaitu membuat dokumentasi dan laporan hasil penggerjaan TA, sesuai dengan kaidah dan sistematika penulisan yang telah ditetapkan oleh institusi.



5. Kesimpulan dan Saran

5.1 Kesimpulan

Kesimpulan yang diperoleh dari penggerjaan TA ini adalah :

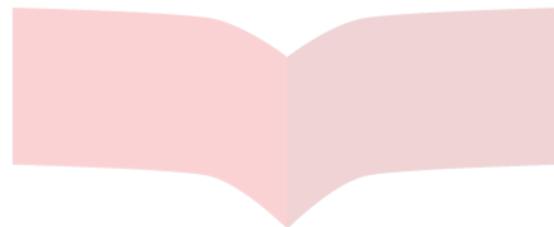
1. Parameter EP yang paling berpengaruh adalah ra-rb mutasi
2. Nilai inisialisasi *context layer* sangat berpengaruh pada hasil prediksi
3. Perhitungan *error* saat masih dalam *phase space* sangat berpengaruh pada prediksi satu langkah kedepan atau beberapa langkah kedepan
4. Nilai NMSE untuk data skala dan asli tetap sama.
5. Nilai NMSE terbaik yang pernah dicapai adalah NMSE *training* $2,8 \times 10^{-3}$ dan NMSE *testing* $2,3 \times 10^{-3}$.
6. Pada skenario satu, kombinasi nilai parameter dari EP yang terbaik adalah ukuran populasi 20, ra-rb initPop [-1,1], ra-rb mutasi [-3,3], dan alfa 0,2. Sedangkan untuk skenario dua ukuran populasi 100 dan alfa 0,2.
7. Model yang dihasilkan bagus untuk digunakan uji prediksi satu langkah kedepan. Namun untuk 131 langkah kedepan dengan menggunakan metode *iterated* masih jelek.
8. Sifat ke-chaotic-an pada *sunspot time series* belum bisa ditangkap oleh sistem yang diusulkan.

5.2 Saran

Beberapa saran yang diberikan untuk pengembangan selanjutnya adalah :

1. Sulitnya memprediksi nilai puncak pada time series coba menggunakan *residual analysis* seperti yang dilakukan pada referensi [1].
2. Strategi prediksi banyak output bagus digunakan untuk prediksi beberapa langkah kedepan / jangka panjang seperti yang disebutkan referensi [44].
3. Perhitungan MSE sebaiknya dilakukan ketika masih *phase space* agar semua individu menghasilkan prediksi beberapa langkah kedepan yang bagus dari pada metode *iterated*.
4. Coba pakai idikasi index aa atau ap (indeks geomagnetik) sebagai indikasi untuk prediksi siklus matahari karena menurut Pesnell dan beberapa peneliti yang lain lebih erat hubungannya daripada *sunspot numbers*.
5. Permasalahan *overfitting* pada ERNN ditangani agar individu yang dihasilkan bagus.
6. Ra-rb mutasi dan ra-rb initPop coba diproporsionalkan agar hasil kombinasi bagus. Karena pada penggerjaan TA ini misalnya tidak adil bagi ra-rb initPop -1,1 saat diubah ke ra-rb mutasi -10,10 dibanding yang ra-rb initPopnya -5,5.
7. Coba ditambah *local search* seperti penelitian yang dilakukan oleh Ma et al referensi [22].
8. Coba pada mutasi, *classical* EP yaitu $N(0,1)$ diganti dengan *fast* EP yaitu menggunakan mutasi *cauchy* lihat referensi [43] halaman 226.
9. Inisialisasi *context layer* untuk data training tidak dengan angka nol tetapi dicari pada EP.

10. Analisa hubungan yang menyebabkan pergerakan ekstrim dan perlahan pada *fitness*. Apakah ada hubungannya dengan perubahan panjang kromosom.
11. Proporsionalkan jumlah statistik penambahan, pengurangan, atau tetap pada panjang kromosom setelah dimutasi.



Telkom
University

Referensi

- [1] Ardalani-Farsa, Muh. Dan Zolfaghari, Saeed. 2010, 'Chaotic time series prediction with residual analysis method using hybrid elman-NARX neural networks', *Neurocomputing*, vol. 73, hh. 2540-2553.
- [2] Assaad, Moh., Bone, R., dan Cardot, H. 2008, 'A new boosting algorithm for improved time-series forecasting with recurrent neural networks', *Information Fusion*, vol. 9, hh. 41-55.
- [3] Badjate, S.L. dan Dudul, S.V. 2009, 'Multi step ahead prediction of north and south hemisphere sunspot chaotic time series using focused time lagged recurrent neural networks model', *WSEAS Trans. On Information Science and Applications*, vol. 6, no. 4, hh. 684-693.
- [4] Badjate, S.L. dan Dudul, S.V. 2009, 'Novel FTLRNN with gamma memory for short-term and long-term predictions of chaotic time series', *Applied Computational Intelligence and Soft Computing*, vol. 2009, h. 21.
- [5] Baker, D.N., 2000, 'Effects of the sun on the earth's environment', *Journal of Atmospheric and Solar-Terrestrial Physics*, vol. 62, hh. 1669-1681.
- [6] Basharat, A., Shah, Mubarak., 2009, 'Time series prediction by chaotic modelling of nonlinear dynamical systems', *Int. Conf. on Computer Vision (ICCV)*.
- [7] Berlinti, Rosalina 2006, *Peramalan time series indeks harga saham gabungan menggunakan Elman-RNN dengan algoritma BPTT*, IT Telkom, Bandung.
- [8] Chandra, R. dan Zhang, M. 2012, 'Cooperative coevolution of elman recurrent neural networks for chaotic time series prediction', *Neurocomputing*, vol. 86, hh. 116-123.
- [9] Cherif, A., Cardot, H., dan Bone, R. 2011, 'SOM time series sistemng66e and prediction with recurrent neural networks', *Neurocomputing*, vol. 74, hh. 1936-1944.
- [10] Dabas, R.S. dan Sharma, K. 2010, 'Prediction of solar cycle 24 using Geomagnetic precursors: validation and update', *Solar Physics*, vol. 266, hh. 391-403.
- [11] Donate, J.P., Li, X., Sanchez, G.G., dan Miguel, A.S. 2011, 'Time series forecasting by evolving artificial neural networks with genetic algorithms, differential evolution, and estimation of distribution algorithm', *Neural Computation and Application*, Springer.
- [12] Dragomir, O.E., Dragomir, F., dan Minca, E. 2010, 'Medium term load forecasting using ANFIS predictor', *Mediterranean Conf. on Control & Automation*, vol. 18, h. 6.
- [13] Eddy, J.A., 2009, *The sun, the earth, and near-earth space : a guide to the sun-earth system*, NASA.
- [14] Elman, J.L. 1990, 'Finding structure in time', *Cognitive Science*, vol. 14, hh. 179-211.
- [15] Frazier, C. dan Kockelman, K.M. 2004, 'Chaos theory and transportation system : an instructive example', *Transportation Research Record*, vol.

- 1897, hh. 9-17.
- [16] Garcia-Pedrero, A. dan Gomez-Gil, P. 2010, 'Time series forecasting using recurrent neural networks and wavelet reconstructed signals', *IEEE*, vol. 10.
- [17] Gomez-Gil, P., Garcia-Pedrero, A., dan Ramirez-Cortes, J.M. 2011, 'Composite recurrent neural networks for long-term prediction of highly-dynamic time series supported by wavelet decomposition', *Soft Computing for Intelligent Control and Mobile Robotics*, vol. 318, hh. 253-268.
- [18] Gomez-Gil, P., Ramirez-cortes, J.M., Hernandez, S.E.P. dan Alarcon-Aquino, V. 2011, 'A neural network scheme for long-term forecasting of chaotic time seris', *Neural Process 67od*.
- [19] Javaraiah, J., Rozelot, J.P., dan Bertello, Luca 2012, 'The solar cycle', *Advances in Astronomy*, vol. 2012, h. 2.
- [20] Kim, T.-H., Park, D.-C., Woo, D.-M., dan Lee, Y. 2011, 'Sunspot series prediction using a multiscale recurrent neural networks', *IEEE*, vol.11.
- [21] Lawrence, J.K., Cadavid, A.C., dan Ruzmaikin, A.A. 1995, 'Turbulent and chaotic dynamics underlying solar magnetic variability', *The Astrophysical Journal*, vol. 455, hh. 366-375.
- [22] Ma, Q.-L., Zheng, Q.-L., Peng, Hong., Zhong, T.-W., dan Xu, L.-Q. 2007, 'Chaotic time series prediction based on evolving recurrent neural networks', *Int. Conf. on Machine Learning and Cybernetics*, vol. 6, hh. 3496-3500.
- [23] Manurung, Fernando 2008, *Enkripsi gambar dengan menggunakan algoritma enhance 1-D chaotic key based (ECKBA)*, IT Telkom, Bandung.
- [24] Mirmomeni, M., Lucas, C., Araabi, B.N., dan Moshiri, B. 2007, 'Forecasting solar activity using coevolution of models and tests', *Int. Conf. on Intelligent System Desaign and Applications*, vol. 7, hh. 629-634.
- [25] Moldwin, Mark, 2008, *An introduction to space weather*, Cambridge University Press, Cambridge.
- [26] Muslim, Buldan 2001, 'Pemodelan runtut waktu linear aktivitas matahari dan prediksi siklus maksimum ke-23', *Warta Lapan*, vol. 3, no. 1, h. 1-6.
- [27] Park, D.-C. 2011, 'Prediction of sunspot series using a recurrent neural networks', *IEEE*, vol. 11, h. 5.
- [28] Park, D.-C. Dan Woo, D.-M. 2009, 'Prediction of sunspot series using bilinear recurrent neural network', *Int. Conf. on Information Management and Engineering*, vol. 9, hh. 94-98.
- [29] Parlitz, Ulrich 1998, 'Nonlinear time-series analysis', *Nonlinear Modelling-Advanced Black-Box Techniqques*, hh.209-239.
- [30] Peralta, J., Gutierrez, G., dan Sanchis, A. 2010, 'Time series forecasting by evolving artificial neural networks using shuffle, cross-validation, and ensembles', *Int. Conf. Artificial Neural Networks(ICNN)*, vol. 6352, hh. 50-53.
- [31] Pesnell, W.D. 2008, 'Prediction of solar cycle 24', *Solar Physics*, vol. 252, hh. 209-220.
- [32] Pesnell, W.D. 2012, 'Solar cycle prediction (invited review)', *Solar*

- Physics.*
- [33] Qin, Zhang 1996, ‘A nonlinear prediction of the smoothed monthly sunspot numbers’, *Astronomy & Astropysis*, vol. 301, hh. 645-650.
 - [34] Rapoport, A., ‘Lyapunov exponent’, *Weizmann Institute of Science*, [Online] Tersedia di : <http://www.wisdom.weizmann.ac.il/~gannar/>.
 - [35] Rosenstein, M.T., Collins J.J., dan Luca, C.J.D., 1993, ‘A practical method for calculating largest Lyapunov exponents from small data sets’, *Physica D*, vol. 65, hh. 117-134.
 - [36] Rutka, G. 2006, ‘Neural network models for internet traffic prediction’, *Electronics and Electrical Engineering*, hh. 55-58.
 - [37] Samin, R.E., Kasmani, R.M., Khamis, A., dan Isa, S. 2010, ‘Forecasting sunspot numbers with recurrent neural networks (RNN) using sunspot neural forecaster system’, *Int. Conf. on Advances in Computing, Control, and Telecommunication Technologies*, vol. 2, hh. 10-14.
 - [38] Santosa, Budi. 2007, *Data mining : teknik pemanfaatan data untuk keperluan bisnis*, Graha Ilmu, Yogyakarta.
 - [39] Saputra, Ricky 2011, *Prediksi jumlah panggilan operator menggunakan Elman-RNN*, IT Telkom, Bandung.
 - [40] Sello, S. 2001, ‘Solar cycle forecasting: a nonlinear dynamics approach’, *Astronomy & Astropysics*, vol. 377, hh. 312-320.
 - [41] Soelaiman. R., Martoyo, A., Purwananto, Y., dan Purnomo, M.H. 2009, ‘Implementation of recurrent neural network and boosting method for time-series forecasting’, *IEEE*.
 - [42] Sorjamaa, A., Hao, J., Reyhani, N., Ji, Y., dan Lendasse, A. 2007, ‘Methodology for long-term prediction of time series’, *Neurocomputing*, h. 9.
 - [43] Suyanto 2008, *Evolutionary computation : Computation based on Evolution and Genetic*, Infomatika Publishing, Bandung.
 - [44] Taieb, S.B., Sorjamaa, A., Lendasse, A., dan Bontempi, G. 2010, ‘Multiple-output sistemng for multi-step-ahead forecasting’, h. 22.
 - [45] Takens, Florish 1981, ‘Detecting strange attractor in sistemng68e’, in *Dynamical Systems and Turbulence, Lecture Notes in Mathematics 898*, Springer-Verlag, Berlin, Germany, hh. 366-381.
 - [46] Wang, H.N., Cui. Y.M., Li, R., Zhang, L.Y., dan Han, H. 2008, ‘Solar flare forecasting model supported with artificial neural network techniques’ *Advances in Space Research*, vol. 42, hh. 1464-1468.
 - [47] Wolf, A., Swift, J.B., Swinney, H.L., dan Vastano, J.A., 1984, ‘Determining lyapunov exponent from a time series’, *Physica D*, vol. 16, hh. 285-317.