

# 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 badai 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 periode 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 di bumi 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] yang 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 dibangun 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 pengerjaan 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]. performansi 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 pengerjaan 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 pengerjaan TA adalah sebagai berikut :

1. Bagaimanakah mengimplementasikan ERNN untuk menghasilkan model RNN dan parameter *embedding* yang optimal untuk memprediksi siklus matahari?
2. Bagaimanakah menentukan parameter EP sehingga didapat kromosom yang terbaik untuk kasus prediksi siklus matahari?
3. Bagaimanakah 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 pengerjaan 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 pengerjaan 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 *tools* Matlab 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 pengerjaan TA, sesuai dengan kaidah dan sistematika penulisan yang telah ditetapkan oleh institusi.