

**PREDIKSI BILANGAN *SUNSPOT* MENGGUNAKAN *SUPPORT VECTOR  
REGRESSION (SVR)***

**SKRIPSI**



**UIN SUNAN AMPEL  
S U R A B A Y A**

Disusun Oleh  
**SUWANTO**  
**H72216070**

**PROGRAM STUDI MATEMATIKA  
FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL  
SURABAYA**

**2019**

## PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : Suwanto  
NIM : H72216070  
Program Studi : Matematika  
Angkatan : 2016

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul " PREDIKSI BILANGAN *SUNSPOT* MENGGUNAKAN *SUPPORT VECTOR REGRESSION (SVR)* ". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, Desember 2019

Yang menyatakan,



Suwanto

NIM. H72216070

## LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

Nama : Suwanto

NIM : H72216070

Judul Skripsi : PREDIKSI BILANGAN *SUNSPOT* MENGGUNAKAN  
*SUPPORT VECTOR REGRESSION (SVR)*

telah diperiksa dan disetujui untuk diujikan.

Surabaya, Desember 2019

Pembimbing



---

Dian Candra Rini Novitasari, M.Kom  
NIP. 19851124014032001

## PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama : Suwanto  
NIM : H72216070  
Judul Skripsi : PREDIKSI BILANGAN *SUNSPOT* MENGGUNAKAN  
*SUPPORT VECTOR REGRESSION (SVR)*

Telah dipertahankan di depan Tim Penguji  
pada tanggal Desember 2019

Mengesahkan,  
Tim Penguji

Penguji I



Dian Candra Rini Novitasari, M.Kom  
NIP. 19851124014032001

Penguji II



Yuniar Farida, M.T  
NIP. 197905272014032002

Penguji III



Aris Fanani, M.Kom  
NIP. 198701272014031002

Penguji IV



Nurissardah Ulinnuha, M.Kom  
NIP. 199011022014032004

Mengetahui,

Dekan Fakultas Sains dan Teknologi  
UIN Sunan Ampel Surabaya



  
Dr. Eni Purwati, M.Ag

NIP. 196512211990022001



KEMENTERIAN AGAMA  
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA  
PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300  
E-Mail: perpus@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI  
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : SUWANTO  
NIM : 1192216090  
Fakultas/Jurusan : SAINS & TEKNOLOGI / SAINS  
E-mail address : to.wans.og@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Sekripsi  Tesis  Desertasi  Lain-lain (.....)

yang berjudul :

PREDIKSI BILANGAN SUNSPOT MENGGUNAKAN SUPPORT VECTOR  
REGRESSION (SVM).

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya,

Penulis

SUWANTO

nama terang dan tanda tangan









2.7. <i>Support Vector Regression (SVR)</i> . . . . .	26
2.8. Evaluasi hasil . . . . .	31
<b>III METODE PENELITIAN</b> . . . . .	<b>34</b>
3.1. Jenis penelitian . . . . .	34
3.2. Pengumpulan data . . . . .	34
3.3. Analisis data . . . . .	35
3.4. Pengujian dan evaluasi . . . . .	35
<b>IV HASIL DAN PEMBAHASAN</b> . . . . .	<b>39</b>
4.1. Pembentukan struktur data <i>time series</i> . . . . .	39
4.2. Prediksi Menggunakan <i>Support Vector Regression (SVR)</i> . . . . .	50
4.2.1. Algoritma SVR . . . . .	50
4.2.2. Pemilihan Kernel . . . . .	55
4.2.3. Penggunaan Kernel linear . . . . .	56
4.2.4. Penggunaan Kernel <i>gaussian</i> . . . . .	57
4.2.5. Penggunaan Kernel RBF . . . . .	57
4.2.6. Penggunaan Kernel <i>polynomial</i> . . . . .	58
4.2.7. Hasil Prediksi . . . . .	59
4.3. Pembahasan . . . . .	61
<b>V PENUTUP</b> . . . . .	<b>63</b>
5.1. Simpulan . . . . .	63
5.2. Saran . . . . .	64
<b>DAFTAR PUSTAKA</b> . . . . .	<b>65</b>









dibanding area lain pada permukaan matahari(Maspupu , 2011). Awal mula muncul sunspot berukuran kecil namun, jika konfigurasinya menjadi sempurna maka medan magnet akan tidak stabil yang akan berdampak akan munculnya *flare* dan CME(Chattopadhyay and Chattopadhyay , n.d.). *Sunspot* juga memiliki dampak pada cuaca yang ada di bumi(Basyaruddin dan Effendy , 2007). Pengamatan indeks *sunspot* utamanya bilangan *sunspot* amat penting karena besaran bilangan *sunspot* akan merepresentasikan tingkat aktivitas yang terjadi pada matahari. Jika bilangan *sunspot* banyak maka aktivitas yang ada pada matahari tinggi, dan sebaliknya jika jumlah bilangan *sunspot* kecil maka aktivitas matahari juga rendah(Hasan, Sutrisno, & Setiahadhi , 2015).

Beberapa penelitian yang mengangkat bilangan sunspot sebagai subjek penelitian antara lain, penelitian tentang keterkaitan antara cuaca di Indonesia dengan fenomena bintik matahari (*sunspot*) oleh Basyaruddin dan S. Effendy (2007). Penjelasan pada penelitian tersebut pengaruh dari *sunspot* terhadap cuaca di Indonesia disebutkan nyata adanya karena terdapat keterkaitan antara aktivitas matahari yang salah satunya adalah *sunspot* dengan suhu udara dan kelembaban udara Indonesia. Pengaruh *sunspot* terhadap cuaca Indonesia juga disebutkan memiliki bentuk persamaan nonlinear-kubik, densitas elektron lapisan atmosfer bumi pada ketinggian sekitar 225 km memiliki variasi yang dipengaruhi oleh siklus 11-tahunan fenomena *sunspot*(Basyaruddin dan Effendy , 2007). *Sunspot* pada penelitian Gkana dan zachilas dijelaskan bahwa sangat berbahaya untuk manusia dan perangkat elektronik dan akan berimbas negatif juga pada perekonomian karena terganggunya komunikasi via telekomunikasi *wireless* atau hingga padamnya aliran listrik. Penelitian tersebut dilakukan dengan menggunakan data *sunspot* bulanan dari bulan Januari 1949 hingga Juni 2013 yang kemudian

dilakukan prediksi menggunakan *neural network-type core algorithm* (Gkana and Zachilas , 2015). Penelitian *sunspot* dilakukan beberapa peneliti diatas karena fenomena *sunspot* tersebut memiliki pengaruh pada iklim dan cuaca di Bumi sehingga berdampak pada aktivitas penghuni Bumi, utamanya aktivitas manusia.

Dampak akibat terjadinya fenomena *sunspot* dapat diminimalkan jika informasi dini tersedia. Penyediaan informasi awal tersebut dapat dilakukan dengan prediksi. Prediksi merupakan perkiraan sesuatu yang mungkin dapat terjadi pada waktu yang akan datang berdasarkan kumpulan data dari masa lampau atau masa yang sedang terjadi. Beberapa penelitian dengan topik prediksi diantaranya: prediksi bilangan *sunspot* menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) oleh H. I. Abdel-Rahman dan B. A. Marzouk. Data yang digunakan adalah data bilangan *sunspot* dari tahun 1991-2017 yang disediakan oleh *National Oceanic and Atmospheric Administration* (NOAA). Hasil prediksi menggunakan ARIMA kemudian akan dibandingkan dengan data bilangan *sunspot* internasional yang diprediksi oleh NOAA agar diketahui tingkat akurasi model prediksi (Abdel-Rahman and Marzouk , 2018). Prediksi bilangan *sunspot* oleh (Zufar , 2018) dalam penelitiannya mengenai perbandingan metode ARIMA dan RBFNN dilakukan dengan menggunakan data dari BPAA LAPAN Pasuruan, Jawa Timur. Untuk mengetahui set data input dari prediksi pada penelitian tersebut dilakukan uji korelasi ACF dimana pada metode ARIMA *set data input* untuk memprediksi  $X_t$  adalah  $X_{t-1}, X_{t-2}, \dots, X_{t-11}$  dan  $X_{t-1}, X_{t-2}, \dots, X_{t-19}$  merupakan *set data input* untuk memprediksi  $X_t$  dengan menggunakan metode RBFNN, dimana X adalah bilangan *sunspot*. Hasil prediksi bilangan *sunspot* dari ARIMA cenderung menjauh dari data real, berbeda dengan RBFNN cenderung menjauh pada periode-periode tertentu. Goutami dan Surajit

juga melakukan penelitian prediksi bilangan *sunspot* dengan data *sunspot* bulanan. Proses prediksi dilakukan menggunakan tiga metode berbeda yaitu *Autoregressive* (AR), *Autoregressive Moving Average* (ARMA), dan *Autoregressif Neural Network* (ARNN). Berdasarkan data bilangan *sunspot* dari tahun 1992-2008 dengan  $X_{t-1}, X_{t-2}, X_{t-3}$  sebagai variabel independen dan  $X_t$  sebagai variabel dependen. Dari ketiga metode yang digunakan dapat diketahui bahwa metode *Autoregressif Neural Network* (ARNN) merupakan metode dengan kinerja yang paling optimal dibanding *Autoregressive* (AR) dan *Autoregressive Moving Average* (ARMA) (Chattopadhyay and Chattopadhyay, n.d.).

Permasalahan prediksi bilangan *sunspot* selain menggunakan beberapa metode seperti yang tertuang pada paragraf sebelumnya juga dapat diterapkan dengan metode *Support Vector Regression* (SVR). SVR ialah cabang dari *Support Vector Machine* (SVM) yang menggunakan konsep *loss function*. Beberapa jenis *loss function* pada SVR yaitu  $\varepsilon$ -insensitive, quadratic, Huber dan Laplace. Pengaplikasian SVR sebagai metode prediksi diantaranya: prediksi *link load* pada jaringan oleh (Priyadarshini, Acharya, and Mishra, 2011), pada penelitian tersebut sampel *training* direkonstruksi menjadi  $G = (X_t, d_t), t = 1, 2, 3, \dots, n - p$  dimana  $X_t = (X_t, X_{t+1}, \dots, X_{t+p-1}), d_t = X_{t+p}$ . Data yang digunakan untuk proses pelatihan adalah sebanyak 100 data kemudian 200 data untuk proses pengujian. Penelitian tersebut dilakukan menggunakan tiga metode yang berbeda yaitu *Support Vector Regression* (SVR), *Auto-Regressive* (AR), & *Moving Average* (MA). Perbandingan *Mean Square Error* (MSE), *Normalized Mean Square Error* (NMSE), & *Root Mean Square Error* (RMSE) dari ketiga metode yang digunakan bahwa SVR memiliki error yang paling kecil dibanding dengan *Auto Regressive* atau *Moving Average*. Septiningrum & tim melakukan prediksi harga saham



gabungan menggunakan *Support Vector Regression* (SVR) dengan algoritma grid search. Data yang digunakan pada penelitian tersebut adalah data Indeks Harga Saham Gabungan (IHSG), data masukan (*input*) yang digunakan dicari dengan menggunakan plot PACF. Hasil yang didapat adalah tingkat akurasi sebesar 90.981% dan error MAPE sebesar 0.613 (Septiningrum, Yasin, & Sugito, 2015). (Radhika and Shashi, 2009) menerapkan *Support Vector Regression* (SVR) dan *Multi Layer Perceptron* (MLP) untuk memprediksi suhu atmosfer. Pada penelitian tersebut dilakukan Analisa mengenai *time series* data dari suhu maksimum harian di suatu tempat untuk memprediksi suhu pada hari berikutnya. Data masukan untuk memprediksi suhu hari berikutnya adalah sebanyak  $n$  data hari sebelumnya, nilai  $n$  didapatkan dengan melakukan eksperimen hingga diperoleh struktur yang terbaik. Berdasarkan dua metode yang digunakan, kinerja dari SVR mendapatkan hasil yang lebih baik daripada MLP. Selain dapat digunakan untuk prediksi SVR juga dapat digunakan untuk peringkasan dokumen berdasarkan posisi kalimat (Fanani et al., 2019). Dari beberapa penelitian tersebut SVR merupakan metode prediksi yang bagus, hal terpenting yang berpengaruh pada bagusnya prediksi dengan SVR diantaranya, karena SVR dapat mengenali atau mempelajari berbagai macam pola data (*generalisasi*), *curse of dimensionality*, serta relatif mudah untuk diimplementasikan (*feasibility*).

Berdasarkan pemaparan kondisi tersebut, penulis akan melakukan penelitian dengan judul "**Prediksi Bilangan Sunspot menggunakan Support Vector Regression (SVR)**". Tujuan yang diharapkan dari penelitian ini agar didapatkan hasil model *Support Vector Regression* (SVR) untuk memprediksi bilangan *sunspot* berdasarkan data bilangan *sunspot* dari *Sunspot Index and Long-term Solar Observations* (SILSO) serta diharapkan dapat memberikan

















fotosfer diantaranya 0,1% elemen-elemen seperti karbon, oksigen, nitrogen dan neon, 5,9% helium, serta, 94% hidrogen.

#### 5. Kromosfer

Lapisan ini terdapat diatas lapisan fotosfer yang disebut dengan atmosfer matahari. Lapisan kromosfer menjulang 1200 km diatas lapisan sebelumnya (fotosfer) dan memiliki ketebalan sekitar 2500 km dengan temperatur pada area atas dapat tercapai lebih dari  $10000^{\circ}$  K. Lapisan ini cahaya yang dipancarkan tidak sekuat seperti lapisan fotosfer sehingga tidak dapat dilihat oleh manusia, namun pada saat gerhana matahari total lapisan ini dapat terlihat oleh manusia, dimana bentuk dari lapisan kromosfer seperti cincin kecil dengan nyala merah kuat. Unsur penyusun terbesar pada atmosfer ini adalah hidrogen.

#### 6. Korona

Atmosfer bola pijar pusat tata surya yang berada di atas kromosfer merupakan lapisan korona. Lapisan ini berada jauh dari inti matahari tetapi lapisan ini memiliki temperatur tertinggi dibandingkan kromosfer, ahli-ahli astronomi memprediksi temperatur pada lapisan korona mencapai  $2.000.000^{\circ}$  Kelvin pada bagian luar. Hal tersebut berakibat adanya pemaksaan perpindahan energi secara konveksi pada lapisan fotosfer dan kromosfer akibatnya korona berkembang sangat cepat pada ruang hampa.

Lapisan korona dapat dilihat dengan bantuan teleskop koronagraf yang dilengkapi dengan suatu cakram gelap yang dapat menutupi cahaya dari lapisan fotosfer, sehingga tidak perlu menunggu terjadinya gerhana matahari total. Alat teleskop akan membuat gerhana matahari total buatan dan membuat lapisan fotosfer tertutup dan akan terlihat sebuah *shape* mahkota







dikenal dengan badai proton *Solar Proton Event* (SPE) dan *Corona Mass Ejection* (CME). Partikel ini sangat berbahaya untuk wahana ruang angkasa berawak, operasional satelit (komunikasi, GPS, internet) serta penerbangan lintas kutub. Walaupun Bumi dilindungi “perisai” berupa lapisan magnetosfer yang mampu menghadang partikel energi tinggi dari matahari tetapi partikel ini mampu menembus ke atmosfer Bumi melalui kutub-kutub Bumi. Oleh karena itu, negara-negara yang berada di dekat kutub (daerah lintang tinggi) memiliki potensi bahaya yang lebih besar akibat badai matahari dibandingkan dengan negara-negara yang berada di dekat ekuator. Potensi bahaya yang dimaksud adalah gangguan pada transformator listrik akibat adanya penambahan beban dari partikel energi tinggi, reaksi kimia pada saluran pipa minyak yang dapat menyebabkan karat, serta terganggunya komunikasi radio HF akibat interaksi lapisan ionosfer dengan partikel-partikel tersebut. (Melati, 2015).

### 3. Granula

Granula (gumpalan matahari) berasal dari kepulan gas panas yang menggumpal pada lapisan fotosfer. Granula memiliki sifat kebalikan dari bintik matahari yaitu granula akan terlihat lebih terang dibanding dengan area sekelilingnya karena suhu granula yang lebih panas. Terlihat tidak meratanya lapisan permukaan matahari karena disebabkan oleh adanya granula. Granula atau gumpalan matahari dapat bertahan sekitar delapan menit dan terjadi karena aliran gas dari dalam yang menuju ke permukaan fotosfer (Surdijani & Sumala, 2006).















waktu yang akan datang merupakan (*forecasting*). Ramalan merupakan suatu keadaan yang diperkirakan dapat terjadi mendatang. Penaksiran memerlukan suatu kumpulan data dari masa lampau atau masa yang sedang terjadi guna mendapat perkiraan data yang akan terjadi di masa mendatang(Umar , 2003).

Peramalan sangat berguna untuk pengambilan keputusan. Keputusan yang baik adalah keputusan yang berdasar pada pertimbangan atas segala sesuatu yang telah terjadi. suatu prediksi atau peramalan tidak akan terlepas dari suatu kesalahan. sehingga yang perlu diperhatikan adalah usaha untuk memperkecil kesalahan dari ramalan tersebut. Peramalan terbagi atas dua macam atau jenis yaitu peramalan kualitatif yang merupakan penentuannya didasari pendapat, pengetahuan serta pengalaman penyusun dan kuantitatif yang berdasar pada pengukuran pada masa lampau dan hasil peramalan bergantung dengan metode yang digunakan.

## **2.5. Artificial Intelligence (AI)**

Kecerdasan buatan (Artificial Intelligence) adalah berbagai ide untuk membuat suatu perangkat lunak komputer yang memiliki kecerdasan sehingga dapat melakukan suatu pekerjaan yang menyerupai sesuatu yang dilakukan oleh manusia, atau bisa dikatakan komputer dapat memiliki nalar layaknya manusia. Membuat komputer lebih cerdas serta membuat mesin dapat bekerja seperti manusia merupakan tujuan dari kecerdasan buatan. Kecerdasan buatan dapat membantu meringankan beban kerja manusia seperti ketika akan mencari informasi secara akurat, membuat komputer mudah digunakan dengan tampilan yang mudah dipahami, atau membuat keputusan. Cara kerja kecerdasan buatan adalah mengeluarkan output berupa suatu keputusan dari proses oleh sistem yang mendapatkan masukan data input.

*Artificial Intelligence* (kecerdasan buatan) secara garis besar terbagi menjadi dua sub-bagian yaitu AI Konvensional dan AI Komputasional (*Computational Intelligence*). (Kaplan and Haenlein, 2019). Metode-metodenya meliputi:

1. *Expert system*. Peran komputer pada *expert system* digunakan untuk menyimpan pengetahuan para pakar, sehingga komputer akan memiliki keahlian untuk menyelesaikan permasalahan dengan meniru keahlian pakar.
2. *Natural Language Processing*. Pengolahan bahasa natural bertujuan agar pengguna dapat berkomunikasi dengan komputer menggunakan bahasa sehari-hari.
3. *Speech Recognition*. Pengenalan ucapan bertujuan supaya manusia dapat berkomunikasi dengan komputer dengan menggunakan suara.
4. Robotika & Sistem Sensor (*Robotics & Sensory Systems*).
5. *Computer Vision*, visualisasi gambar atau obyek-obyek melalui komputer.
6. *Intelligent Computer-aided Instruction*. Komputer dapat digunakan sebagai tutor yang dapat melatih dan mengajar.
7. *Game Playing*.

*Machine learning* merupakan bagian dari *AI expert system* dimana suatu keputusan akan muncul berdasarkan informasi dari data-data yang dimasukkan ke dalam sistem. Banyak metode yang termasuk pada bagian *Machine learning*, *Support Vector Machine* merupakan salah satu diantaranya.





















### 3.3. Analisis data

Data bilangan sunspot dipecah menjadi dua komponen. komponen pertama digunakan untuk training, dan komponen kedua untuk proses testing. Capaian tujuan dalam penelitian ini, analisis data perlu dilakukan dengan berbagai langkah menggunakan beberapa tahap, yaitu proses rekonstruksi data menjadi data timeseries dan proses prediksi.

Langkah awal yang dilakukan adalah pembentukan data atau rekonstruksi data menjadi data timeseries. Setelah terbentuknya pola data timeseries, kemudian data hasil rekonstruksi dibagi menjadi dua bagian data yaitu untuk pelatihan (training) dan untuk pengujian (testing).

### 3.4. Pengujian dan evaluasi

Pengujian diawali dengan eksperimen atau uji coba untuk menentukan variabel *independent*, Setelah didapatkan konstruksi data input dari variabel *independent* dilakukan prediksi menggunakan SVR, dan dilakukan pengukuran kerja prediktor dengan mencari besaran *error*. Tujuan penelitian ini akan tercapai jika langkah-langkah urut serta sistematis dilaksanakan, representasi dari alur prediksi bilangan *sunspot* menggunakan SVR termuat pada Gambar 3.1.













**Tabel 4.4 Sampel Data Empat Variabel Input**

$X_{t-3}$	$X_{t-2}$	$X_{t-1}$	$X_t$	$X_{t+1}$ (target)
0	0	0	0	0
0	0	0	0	0
0	0	0	0	16
0	0	0	16	14
0	0	16	14	12

**Tabel 4.5 Sampel Data Lima Variabel Input**

$X_{t-4}$	$X_{t-3}$	$X_{t-2}$	$X_{t-1}$	$X_t$	$X_{t+1}$ (target)
0	0	0	0	0	0
0	0	0	0	0	16
0	0	0	0	16	14
0	0	0	16	14	12
0	0	16	14	12	16

Sama halnya dengan tabel sebelumnya pada Tabel 4.5 dan Tabel 4.6 untuk mendapatkan estimasi bilangan *sunspot* diwaktu yang mendatang dengan menggunakan data masukan sebanyak lima hari untuk Tabel 4.5 dan enam data sebelumnya untuk Tabel 4.6.

**Tabel 4.6 Sampel Data Enam Variabel Input**

$X_{t-5}$	$X_{t-4}$	$X_{t-3}$	$X_{t-2}$	$X_{t-1}$	$X_t$	$X_{t+1}$ (target)
0	0	0	0	0	0	0
0	0	0	0	0	0	16
0	0	0	0	0	16	14
0	0	0	0	16	14	12
0	0	0	16	14	12	16

**Tabel 4.7 Sampel Data Tujuh Variabel Input**

$X_{t-6}$	$X_{t-5}$	$X_{t-4}$	$X_{t-3}$	$X_{t-2}$	$X_{t-1}$	$X_t$	$X_{t+1}$ (target)
0	0	0	0	0	0	0	16
0	0	0	0	0	0	16	14
0	0	0	0	0	16	14	12
0	0	0	0	16	14	12	16
0	0	0	16	14	12	16	14

Uji coba yang terakhir untuk prediksi bilangan *sunspot* harian, digunakan data masukan sebanyak tujuh hari atau satu minggu sebelumnya untuk melakukan prakiraan besarnya bilangan *sunspot* satu hari kedepan.

Selanjutnya pada data total bilangan *sunspot* bulanan akan dilakukan uji coba dalam penyusunan data deret waktu dengan struktur  $\{X_t, X_{t+1}\}$ ,  $\{X_{t-2}, X_{t-1}, X_t, X_{t+1}\}$ ,  $\{X_{t-3}, X_{t-2}, X_{t-1}, X_t, X_{t+1}\}$ ,  $\{X_{t-5}, X_{t-4}, X_{t-3}, X_{t-2}, X_{t-1}, X_t, X_{t+1}\}$ ,  $\{X_{t-8}, X_{t-7}, X_{t-6}, X_{t-5}, X_{t-4}, X_{t-3}, X_{t-2}, X_{t-1}, X_t, X_{t+1}\}$ , dan  $\{X_{t-11}, X_{t-10}, X_{t-9}, X_{t-8}, X_{t-7}, X_{t-6}, X_{t-5}, X_{t-4}, X_{t-3}, X_{t-2}, X_{t-1}, X_t, X_{t+1}\}$ . Susunan data tersebut untuk variabel  $X_{t+1}$  merupakan variabel keluaran atau









Tabel 4.13 Sampel Data bulanan 12 Variabel Input

$X_{t-11}$	$X_{t-10}$	$X_{t-9}$	$X_{t-8}$	$X_{t-7}$	$X_{t-6}$	$X_{t-5}$	$X_{t-4}$	$X_{t-3}$	$X_{t-2}$	$X_{t-1}$	$X_t$	$X_{t+1}$ (target)
7.1	7.7	6.9	163.0	19.5	28.5	24.0	10.4	13.9	18.8	25.2	29.6	36.4
7.7	6.9	163.0	19.5	28.5	24.0	10.4	13.9	18.8	25.2	29.6	36.4	33.6
6.9	163.0	19.5	28.5	24.0	10.4	13.9	18.8	25.2	29.6	36.4	33.6	34.4
163.0	19.5	28.5	24.0	10.4	13.9	18.8	25.2	29.6	36.4	33.6	34.4	24.5
19.5	28.5	24.0	10.4	13.9	18.8	25.2	29.6	36.4	33.6	34.4	24.5	27.3





Tabel 4.17 Sampel Data Tahunan 10 Variabel Input

$X_{t-9}$	$X_{t-8}$	$X_{t-7}$	$X_{t-6}$	$X_{t-5}$	$X_{t-4}$	$X_{t-3}$	$X_{t-2}$	$X_{t-1}$	$X_t$	$X_{t+1}$ (target)
211.1	191.8	203.3	133.0	76.1	44.9	25.1	11.6	28.9	88.3	136.3
191.8	203.3	133.0	76.1	44.9	25.1	11.6	28.9	88.3	136.3	173.9
203.3	133.0	76.1	44.9	25.1	11.6	28.9	88.3	136.3	173.9	170.4
133.0	76.1	44.9	25.1	11.6	28.9	88.3	136.3	173.9	170.4	163.6
76.1	44.9	25.1	11.6	28.9	88.3	136.3	173.9	170.4	163.6	99.3



Tabel 4.18 Data time series total bilangan *sunspot*

X	Y
211.1	191.8
191.8	203.3
203.3	133.0
133.0	76.1
76.1	44.9
44.9	25.1
25.1	11.6
11.6	28.9
28.9	88.3
88.3	136.3
136.3	173.9
173.9	170.4
170.4	163.6
163.6	99.3
99.3	65.3
65.3	45.8
45.8	24.7
24.7	12.6
12.6	4.2
4.2	4.8
4.8	24.9
24.9	80.8
80.8	84.5









bilangan *sunspot* terbesar terjadi pada tahun 1991 hal tersebut menunjukkan bahwa pada tahun tersebut aktivitas matahari sedang berada pada kondisi tertinggi, kemudian mengalami penurunan hingga pada tahun 1996 mencapai puncak yang rendah dan mengalami kenaikan aktivitas kembali hingga puncaknya terjadi pada tahun 2000, penurunan kemudian terjadi kembali hingga tercapai kondisi terendah pada tahun 2008. Prediksi Bilangan *sunspot* pada daerah-daerah ekstrim memiliki galat yang sangat ekstrim pula, misal pada tahun 1991 bilangan *sunspot* adalah sebesar 203.3 sedangkan pada hasil prediksinya hanya tercapai besaran bilangan *sunspot* sebesar 174.43. Kondisi paling ekstrim terjadi pada tahun 2000 dengan bilangan *sunspot* sebesar 173.9 dan nilai prediksinya sebesar 105.21, hal tersebut merupakan penyebab besarnya nilai error prediksi.

#### 4.2.2. Pemilihan Kernel

Konsep dari SVR adalah pendekatan dengan *hyperplane* linear yang merepresentasikan sebuah garis regresi, akan tetapi tidak semua data dapat didekati secara linear. Untuk mengatasi data yang tidak dapat didekati secara linear tersebut dapat digunakan trik berupa *kernel function*. Seperti yang telah dijelaskan pada kajian pustaka bahwa kernel merupakan fungsi pemetaan yang memetakan fitur data dari dimensi saat ini menjadi fitur baru dengan dimensi yang lebih tinggi.

Penelitian ini akan menggunakan beberapa kernel diantaranya *linear*, *gaussian*, *RBF*, dan *polynomial*. Berdasarkan variabel-variabel masukan yang telah ditentukan pada sub bab sebelumnya, maka perbedaan hasil *error* MSE, RMSE, dan MAAPE dari penggunaan berbagai macam kernel tersebut akan terlihat.













2008-2009. Perbedaan tersebut berakibat pada besarnya error akan tetapi error yang didapat dengan menggunakan kernel RBF ini merupakan yang paling kecil dibandingkan dengan penggunaan kernel-kernel lain.

Prediksi dengan SVR apabila menggunakan *non-linear* kernel nilai *weight* ( $w$ ) atau  $\beta$  sukar untuk ditampilkan secara eksplisit karena sulitnya proses penghitungan. Smola pada penelitiannya telah menyatakan bahwa "Even when evaluating  $f(x)$  we need not compute  $w$  explicitly" (Smola & Scholkopf, 2004).

### 4.3. Pembahasan

Besar kecilnya bilangan *sunspot* merupakan cerminan dari aktivitas yang sedang terjadi di matahari. *Sunspot* merupakan sumber asal ledakan matahari (*flare*) dan semburan partikel enerjetik (CME) yang dapat membahayakan teknologi tinggi serta iklim di Bumi. Apabila aktivitas matahari yang ditandai dengan besarnya bilangan *sunspot* sedang pada fase tinggi atau hingga terjadi badai matahari akan memiliki berbagai dampak buruk. Dampak yang paling terasa di bumi adalah Dampak yang mungkin terjadi yang adalah peningkatan aktivitas aurora di Kutub Utara atau Selatan Bumi. Ini disebabkan pengaruh pertukaran dan interaksi partikel atmosfer Bumi daerah kutub dengan terganggunya lapis selimut magnet bumi. Akan tetapi tidak semua *sunspot* yang muncul dipermukaan matahari akan menyebabkan ledakan (*flare*) di matahari. Selain itu, besar kecilnya ledakan tergantung bentuk dan kompleksitas magnetik dari *sunspot*.

Mengutip dari penelitian yang dilakukan oleh Zulkarnain dan Andika Putriani di tahun 2017 dipaparkan bahwa "Rata-rata bilangan *sunspot* dan indeks flare memiliki korelasi positif yang ditandai dengan hasil fitting kurva antara indeks flare dan bilangan *sunspot* diperoleh koefisien korelasi (R) sebesar 0,878.

Kondisi ini dapat dikatakan bahwa bilangan *sunspot* dan indeks flare memiliki korelasi yang cukup kuat. Produktivitas terjadinya flare dapat dilihat berdasarkan parameter *sunspot* seperti bilangan *sunspot*. Flare dapat terjadi pada saat bilangan *sunspot* mencapai nilai maksimum” (Zulkarnain dan Putriani , 2017). Dari paparan tersebut dengan memperhatikan data bilangan *sunspot* mulai tahun 1989 hingga 2018, informasi yang dapat diambil adalah badai matahari dapat mengancam seisi bumi di tahun 1991, 2000, dan 2014 karena pada tahun-tahun tersebut bilangan *sunspot* menunjukkan berada diposisi yang tinggi dengan nilai 203.3, 173.9, dan 113.3.

Berdasar pada paparan paragraf diatas untuk mengetahui terjadinya badai matahari dapat dilakukan pengamatan pada bintik matahari *sunspot*. Antisipasi dampak buruk yang akan terjadi mendatang, hasil prediksi bilangan *sunspot* seperti yang dilakukan pada penelitian ini dapat dijadikan sebagai tolak ukur serta informasi awal atau *early warning*.



3. Berdasarkan hasil prediksi terbaik yaitu prediksi bilangan sunspot tahunan dengan perbandingan data training testing 80:20. Model yang dihasilkan dengan menggunakan kernel linear adalah  $\beta$  sebesar 16.06192 dan bias  $b$  sebesar 69.7491. Kemudian untuk model prediksi dengan kernel *non-linear* (*gaussian*, RBF, *polynomial*) tidak dapat ditampilkan secara eksplisit mengenai nilai  $\beta$ , dan bias.

## 5.2. Saran

Setelah membahas dan mengimplementasikan SVR untuk memprediksi total bilangan sunspot, penulis ingin menyampaikan beberapa saran untuk pengembangan serta penyempurnaan penelitian ini.

1. Dilakukan pengecekan data masukan *time series* menggunakan plot autokorelasi ACF dan PACF.
2. Menggunakan proses normalisasi data karena data jarak atau *range* data yang cukup jauh.
3. Menggunakan metode prediksi lain seperti *deep learning* untuk meningkatkan performa prediksi dalam memprediksi besarnya bilangan sunspot pada waktu yang akan datang.





- Maspupu, J., 2011, *Prediksi Bintik Matahari Untuk Siklus 24 Secara Numerik*, Prosiding Seminar Nasional Penelitian, (p. 25), Yogyakarta.
- McFadden, L. A., Weissmen, P. R., & Johnson, T. V., 2007, *Encyclopedia of the Solar System*, Canada: Academic Press.
- Mehedintu, A., Sterpu, M., and Soava, G., 2018, *Estimation and Forecasts for the Share of Renewable Energy Consumption in Final Energy Consumption by 2020 in the European Union*, Sustainability, 1-22.
- Melati, A., 2015, *Analisis Pengaruh Flare dan CME Terhadap Indeks DST Pasca Gerhana Bulan Total*, Kaunia, XI(1), 53.
- Nachrowi, N. D., & Usman, H., 2004, *Teknik Pengambilan Keputusan*, Grasindo.
- Peter, I. & Papics, 2007, *Solar Prominences, Solar Flares and Coronal Mass Ejections*, A Solar Physics Report, 1-10.
- Priyadarshini, D., Acharya, M., and Mishra, A. P., 2011, *Link Load Prediction using Support Vector Regression and Optimization*, International Journal of Computer Applications, 22-25.
- Radhika, Y. and Shashi M., 2009, *Atmospheric Temperature Prediction using Support Vector Machines*, International Journal of Computer Theory and Engineering, 55-58.
- Rukhansah, N., Muslim, M. A., & Arifudin, R., 2015, *Fuzzy Time Series Markov Chain dalam Meramalkan Harga Saham*, Seminar Nasional Ilmu Komputer (SNIK 2015), 310.
- Santosa, B., (n.d.), *Tutorial Support Vector Machines*, Surabaya: ITS.

- Septiningrum, L., Yasin, Y., & Sugito, 2015, *Prediksi Indeks Harga Saham Gabungan Menggunakan Support Vector Regression (SVR) Dengan Algoritma Grid Search*, Jurnal Gaussian, 315-321.
- Setiahadi, B., 2001, Hasil Uji Simulasi MHD Matahari-Bumi, *Observation Matahari Watukosek*, LAPAN.
- Smola, A. J., & Scholkopf, B., 2004, *A Tutorial on Support Vector Regression*, Statistics and Computing, 199-222.
- Subagyo, A., 2008, *Studi Kelayakan Teori dan Aplikasi*, Jakarta: PT Eka Media Komputindo.
- Surdijani, D., & Sumala, 2006, *Be Smart : Ilmu Pengetahuan Alam*, Grafindo Media Pratama.
- Umar, H., 2003, *Business an Introduction*, Jakarta: PT Gramedia Pustaka Utama.
- Wang, T., 2016, *Forecast of Economic Growth by Time Series and Scenario Planning Method—A Case Study of Shenzhen*, Scientific Research Publishing, 7, 212-222.
- Zufar, M. A., 2018, *Perbandingan Metode ARIMA dengan RBFNN dalam Peramalan Rata-rata Banyaknya Bilangan Sunspot*, Malang: Universitas Islam Negeri Maulana Malik Ibrahim.
- Zulkarnain dan Putriani, A., 2017, *Korelasi Bilangan Sunspot sebagai Parameter Produktivitas Flare pada Siklus Matahari Ke 24*, Proseding Seminar Nasional Fisika Universitas Riau 2017, 104-107.