



# Prediksi Pola Konsumsi Energi Listrik Menggunakan *Support Vector Machine* Untuk Manajemen Energi Listrik Di PT Olifant

Sutriyono<sup>1\*</sup>

<sup>1\*</sup>Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Pamulang, Kota Tangerang Selatan, Indonesia

Email : <sup>1\*</sup>[dosen02346@unpam.ac.id](mailto:dosen02346@unpam.ac.id)

(\* : coressponding author)

**Abstrak** – PT Olifant sebagai salah satu perusahaan yang bergerak di bidang manufaktur beralamat di desa Pasir Jaya, Kecamatan Jatiuwung, Kota Tangerang melakukan manajemen energi berupa perencanaan pemakaian energi (*energy planning*) yaitu proses prediksi pemakaian energi dengan menggunakan nilai rata-rata dari data historis. Namun, ternyata tidak memiliki akurasi yang tinggi terutama jika di dalam periode tersebut terdapat anomali data. Untuk mendapatkan akurasi yang lebih baik, perlu dilakukan klasifikasi dari data yang menjadi acuan (data latih) agar dapat dipilah mana data yang perlu digunakan dan mana data yang tidak perlu. Proses klasifikasi ini dapat dilakukan dengan *Support Vector Machine (SVM)* yang merupakan salah satu penerapan dari Machine Learning. Dengan menggunakan SVM, terbukti memiliki kemampuan yang baik pada data historis yang terbatas. Langkah-langkah yang akan digunakan dalam penelitian ini yaitu mengumpulkan data konsumsi listrik melalui studi pustaka dokumen atau catatan konsumsi energi dan observasi ke lapangan. Data yang didapat akan diolah menggunakan metode *Support Vector Machine (SVM)* yang terdiri dari 2 fase; Pertama, Fase *Training* untuk mengenali pola konsumsi energi dari data historis tersebut. Data input akan diklasifikasi dan akan direpresentasikan menjadi sebuah formula. Kedua, Fase *Testing* untuk penerapan formula hasil fase training tersebut ke data aktual konsumsi energi listrik. Data prediksi akan diuji dengan data aktual untuk melihat penyimpangan yang terjadi. Hal ini menjadi tolak ukur keberhasilan yang dipantau yaitu tingkat akurasi prediksi pola konsumsi energi listrik yang dihasilkan dari pengenalan pola konsumsi energi listrik di fase *training*.

**Kata Kunci:** Klasifikasi; Prediksi; Perencanaan Energi; *Machine Learning*; *Support Vector Machine*

**Abstract** – PT Olifant, as a company operating in the manufacturing sector, has its address in Pasir Jaya village, Jatiuwung District, Tangerang City, carries out energy management in the form of energy usage planning, namely the process of predicting energy usage using average values from historical data. However, it turns out that it does not have high accuracy, especially if there are data anomalies within that period. To get better accuracy, it is necessary to classify the reference data (training data) so that it can be sorted out which data needs to be used and which data is not necessary. This classification process can be done with *Support Vector Machine (SVM)*, which is one application of *Machine Learning*. By using SVM, it is proven to have good capabilities on limited historical data. The steps that will be used in this research are collecting electricity consumption data through literature studies of documents or energy consumption records and field observations. The data obtained will be processed using the *Support Vector Machine (SVM)* method which consists of 2 phases; First, the *Training Phase* to recognize energy consumption patterns from historical data. The input data will be classified and will be represented in a formula. Second, the *Testing Phase* is for applying the formula from the training phase to actual data on electrical energy consumption. Predicted data will be tested with actual data to see any deviations that occur. This is a measure of success that is monitored, namely the level of accuracy in predicting electrical energy consumption patterns resulting from the introduction of electrical energy consumption patterns in the training phase.

**Keywords:** Classification, Prediction, Energy Planning, *Machine Learning*; *Support Vector Machine*

## 1. PENDAHULUAN

### 1.1 Latar Belakang

Di dunia sektor industri menggunakan energi lebih besar dari sektor lain yaitu sebesar satu setengah dari total penggunaan energi dunia (The International Energy Outlook 2013 p.127). Dan untuk Indonesia konsumsi energi untuk sektor industri sebesar 33% (Indonesia



Energy Outlook 2012 hal.34). Para peneliti di dunia segera menangkap hal tersebut dan telah melakukan penelitian tentang metode penghematan energi di sektor industri. Usaha tentang hal tersebut dapat dikategorikan ke dalam beberapa hal berikut (Cao Vinh Le and Chee Khiang Pang and Oon Peen Gan : 2012 p.1916) :

- a. Kebijakan Energi, dilakukan oleh Pemerintah dengan cara membuat perundangan, pajak, dan denda dalam penggunaan energi;
- b. Manajemen Energi, contohnya Audit Energi, Program pelatihan efisiensi energi, Tata kelola
- c. Teknologi yang langsung dapat meningkatkan efisiensi energi pada sistem manufaktur.

Manajemen energi digunakan untuk membuat panduan pelaksanaan efisiensi energi sedangkan teknologi digunakan untuk penyediaan data energi yang digunakan untuk analisa keberhasilan penerapan program efisiensi energi.

Dalam penerapan manajemen energi, *International Standard Organization (ISO)* pada tahun 2011 memperkenalkan seri ISO 50001 tentang *Energy Management Systems (EnMS)* yang filosofi dan pendekatannya konsisten dengan seri sebelumnya, yaitu ISO 9000 (*Quality Management Systems*) dan ISO 14001 (*Environmental Management Systems*).

Salah satu tahap di dalam ISO 50001 adalah tahap Perencanaan Energi (Energy Planning). Pada tahap ini sebuah organisasi diharuskan untuk menentukan tolak ukur energi (Energy Baseline), Indikator Performa Energi (Energy Performance Indicator), Sasaran (Objectives), Target (Targets), dan Rencana Kerja (Action Plans). Dalam hal menentukan tolak ukur ini, organisasi dapat menggunakan data historis sebagai acuannya. Ketepatan dalam mengenali pola dari data historis inilah yang menentukan tolak ukur keberhasilan perencanaan energi.

PT Olifant sebagai salah satu perusahaan yang bergerak di bidang manufaktur beralamat di desa Pasir Jaya, Kecamatan Jatiuwung, Kota Tangerang dalam kegiatan usahanya juga menerapkan efisiensi untuk meningkatkan daya saing. Dari beberapa komponen yang menjadi pengguna biaya terbesar, maka biaya konsumsi energi dipilih untuk dilakukan aktifitas efisiensi. Dalam hal ini perusahaan melakukan perencanaan pemakaian energi (energy planning) yaitu proses prediksi pemakaian energi hanya dengan mencari nilai rata-rata dari data historis di periode sebelumnya, misal : total pemakaian energi tahun lalu dibagi 12 bulan didapatkan rata-rata per bulan. Namun, teknik tersebut ternyata tidak memiliki akurasi yang tinggi terutama jika di dalam periode tersebut terdapat anomali data. Karena data yang anomali tersebut tetap dihitung (dianggap) sebagai data normal. Juga dalam penyiapan data historis perusahaan terkendala dalam jumlah data yang dicatat sehingga data yang dapat digunakan sebagai acuan relatif terbatas.

## **1.2 Identifikasi Masalah**

Dalam penelitian ini ditemukan beberapa identifikasi masalah yang terjadi, yaitu :

- a. Perencanaan energi dilakukan menggunakan data historis, hanya saja masih diambil dari nilai rata-rata sehingga belum optimal untuk dijadikan tolak ukur
- b. Pembuatan target energi masih menggunakan data historis dengan asumsi proporsional.
- c. Perencanaan energi dilakukan secara top-down yaitu dengan hanya menghitung berdasarkan kapasitas mesin saja

## **1.3 Rumusan Masalah**

Dari identifikasi masalah tersebut dapat dirumuskan masalah yang akan dibahas sebagai berikut :

- a. Bagaimanakah metode SVM dapat memprediksi pola konsumsi energi ?
- b. Berapa besar tingkat akurasi metode SVM dalam memprediksi pola konsumsi energi

listrik ?

#### 1.4 Tujuan Penelitian

Dalam penelitian ini memiliki beberapa tujuan antara lain:

- Mengetahui pola konsumsi energi untuk menentukan tolak ukur keberhasilan perencanaan energi yang dapat mendukung program efisiensi energi.
- Mengetahui tingkat akurasi prediksi pola konsumsi energi

## 2. METODOLOGI PENELITIAN

### 2.1 Perhitungan Algoritma


Langkah awal suatu algoritma SVM adalah pendefinisian persamaan suatu hyperplane pemisah yang dituliskan dengan :

$$W \cdot X + b = 0 \quad (1)$$

$W$  adalah suatu bobot vektor, yaitu  $W = \{W_1, W_2, \dots, W_n\}$ ;  $n$  adalah jumlah atribut dan  $b$  merupakan suatu skalar yang disebut dengan bias. Jika berdasarkan pada atribut  $A_1, A_2$  dengan permisalan tupel pelatihan  $X = (x_1, x_2)$ ,  $x_1$  dan  $x_2$  merupakan nilai dari atribut  $A_1$  dan  $A_2$ , dan jika  $b$  dianggap sebagai suatu bobot tambahan  $W_0$ , maka persamaan suatu *hyperplane* pemisah dapat ditulis ulang sebagai berikut:

$$W_0 + W_1x_1 + W_2x_2 = 0 \quad (2)$$

Setelah persamaan dapat didefinisikan, nilai  $x_1$  dan  $x_2$  dapat dimasukkan ke dalam persamaan untuk mencari bobot  $W_1, W_2$ , dan  $W_0$  atau  $b$



**Gambar 1.** Pemisahan Dua Kelas Data Dengan Margin Maksimum

Pada Gambar 1, SVM menemukan *hyperplane* pemisah maksimum, yaitu *hyperplane* yang mempunyai jarak maksimum antara tupel pelatihan terdekat. *Support vector* ditunjukkan dengan batasan tebal pada titik tupel. Dengan demikian, setiap titik yang terletak di atas *hyperplane* pemisah memenuhi rumus:

$$W_0 + W_1x_1 + W_2x_2 > 0 \quad (3)$$

Sedangkan, titik yang terletak di bawah *hyperplane* pemisah memenuhi rumus:

$$W_0 + W_1x_1 + W_2x_2 < 0 \quad (4)$$

Melihat dua kondisi di atas, maka didapatkan dua persamaan *hyperplane* yaitu:

$$H_1 : W_0 + W_1x_1 + W_2x_2 \geq 1 \text{ untuk } y_1 = +1 \quad (5)$$

$$H_2 : W_0 + W_1x_1 + W_2x_2 \leq -1 \text{ untuk } y_1 = -1 \quad (6)$$

Perumusan model SVM menggunakan trik matematika yaitu formula Lagrangian. Berdasarkan *Lagrangian formulation, Maximum Margin Hyperplane (MMH)* dapat ditulis ulang sebagai suatu batas keputusan (*decision boundary*) yaitu:

$$d(X^T) = \sum_i^l = \mathbf{1} y_i a_i X_i X^T + b_0 \quad (7)$$

$y_i$  adalah label kelas dari *support vector*  $X_i$ .  $X^T$  merupakan suatu tupel test.  $a_i$  dan  $b_0$  adalah parameter numerik yang ditentukan secara otomatis oleh optimalisasi algoritma SVM dan  $l$  adalah jumlah *vector support*.

Adanya *hyperplane* yang maksimum mampu memberikan akurasi yang lebih baik pada data yang dapat dipisahkan secara linier, namun hal tersebut tidak berlaku bagi data yang tidak dapat dipisahkan secara linier. Model pembelajaran SVM memperkenalkan istilah penalti untuk klasifikasi kesalahan dalam fungsi objektif dengan menggunakan parameter biaya. Dengan adanya parameter biaya terhadap kesalahan, maka fungsi optimasi SVM menjadi :


$$\min \frac{1}{2} |W|^2 + C \sum_{i=1}^m \xi_i \quad (8)$$

$\xi_i \geq 0, 1 \leq m \leq l$  merupakan variabel *slack* untuk memungkinkan kesalahan beberapa klasifikasi dan  $C$  yang disebut sebagai parameter biaya untuk mengontrol keseimbangan antara margin dan kesalahan klasifikasi. Dengan demikian pembatas pada dua kelas diberi suatu tambahan berupa variable *slack*  $\xi_i$  sehingga margin pembatas menjadi :

$$x_i W + b \geq +1 - \xi_i \text{ untuk } y_i = +1 \quad (9)$$

$$x_i W + b \leq -1 - \xi_i \text{ untuk } y_i = -1 \quad (10)$$

Gambar di bawah ini menggambarkan bagaimana suatu kernel dalam SVM dapat mengubah persamaan non linier menjadi persamaan linier yaitu dengan merubah dimensi setiap titik ke dalam dimensi yang lebih tinggi sehingga *hyperplane* dapat dibuat dengan tepat.



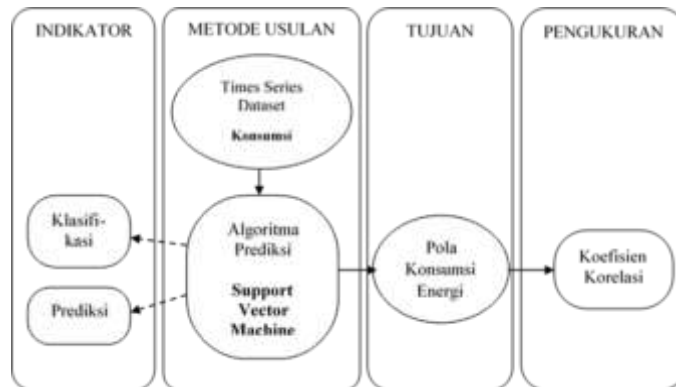
**Gambar 2.** Problem yang Tidak Linier Menjadi Linier Dalam Ruang Baru

Gambar 2. memperlihatkan adanya permasalahan klasifikasi tidak dapat diselesaikan secara linier pada sampel data X. Pengubahan dari problem data non linier ke linier membutuhkan hitungan yang kompleks. Maka diperlukan trik matematika lain yang dapat mempermudah perhitungan, dalam hal ini suatu penggunaan kernel mulai diterapkan. Terdapat 3 persamaan pada kernel SVM yang dapat digunakan yaitu:

- a. *Polynomial Kernel*
- b. Kernel Berbasis *Gaussian Radial (RBF)*
- c. *Sigmoid Kernel*

## 2.2. Kerangka Pemikiran

Kerangka pemikiran yang mencakup metode yang diusulkan dapat digambarkan menjadi diagram seperti di bawah ini :



**Gambar 3.** Diagram Kerangka Pemikiran Penelitian

Langkah-langkah yang digunakan dalam penelitian ini yaitu dimulai dengan mengumpulkan data konsumsi energi listrik yang didapat dari survey maupun interview dengan operator pencatatan energi. Kemudian data tersebut diklasifikasi menjadi data harian dan bulanan. Lalu data tersebut akan dimasukkan ke perhitungan menggunakan metode *Support Vector Machine (SVM)* untuk mengenali pola konsumsi energi listrik yang sudah terjadi (data historis) dan yang akan datang. Data konsumsi energi dibagi menjadi 2, yaitu data latih dan data uji. Data latih digunakan untuk melatih SVM dalam mengenali pola yang sudah terjadi sebelumnya. Sedangkan data uji digunakan untuk menguji pola yang terjadi setelah proses latihan.

Teknik pengukuran yang dilakukan menggunakan metode koefisien korelasi yang didapat dari perbandingan pola hasil penerapan metode SVM dengan data latih dan data aktual. Terdapat 2 jenis pengukuran yang dilakukan, yaitu :

a. Korelasi pola terhadap data latih

Teknik ini mengukur korelasi antara data training aktual dibanding data training hasil perhitungan dengan pola baru yang terbentuk hasil latihan.

b. Korelasi pola terhadap data uji

Teknik ini mengukur korelasi antara data uji aktual dibanding data uji hasil perhitungan dengan pola baru yang terbentuk hasil latihan.

Tujuannya adalah dengan menerapkan Metode SVM ini diperoleh pola konsumsi energi untuk memprediksi konsumsi energi di periode yang akan datang dengan akurat dilihat dari koefisien korelasi yang bernilai tinggi sehingga jika diterapkan dalam perencanaan energi maka hasilnya akan lebih optimal. Proses yang dijadikan contoh yaitu konsumsi energi listrik.

### 3. ANALISA DAN PEMBAHASAN

#### 3.1 Tahapan Pelaksanaan

##### 3.1.1 Penyiapan Data

Langkah pertama dalam penelitian ini adalah mempersiapkan data untuk dimasukkan ke dalam algoritma pemodelan, dalam hal ini adalah *Support Vector Machine*. Dalam tahap penyiapan ini data dibedakan menjadi 2, yaitu data latih dan data tes. Pengelompokan ini dimaksudkan agar model yang diperoleh nantinya memiliki kemampuan generalisasi yang baik dalam melakukan klasifikasi data. Bisa terjadi sebuah model klasifikasi dapat melakukan klasifikasi data dengan sangat baik pada data latih, tetapi sangat buruk dalam melakukan klasifikasi data yang baru atau setelah diuji dengan data tes. Hal ini dinamakan *overfitting*.

### 3.1.2 Dataset Latih (*Training Dataset*)

Dataset latih sesuai dengan namanya adalah sekumpulan data yang digunakan untuk melatih algoritma pemodelan agar dapat belajar mengenali pola yang ada. Model ini merupakan representasi pengetahuan yang akan digunakan untuk memprediksi kelas data yang baru

### 3.1.3 Dataset Tes (*Testing Dataset*)

Dataset tes adalah sekumpulan data yang digunakan untuk mengukur sejauh mana model yang telah terbentuk setelah dilakukan *training* berhasil melakukan klasifikasi dengan benar.

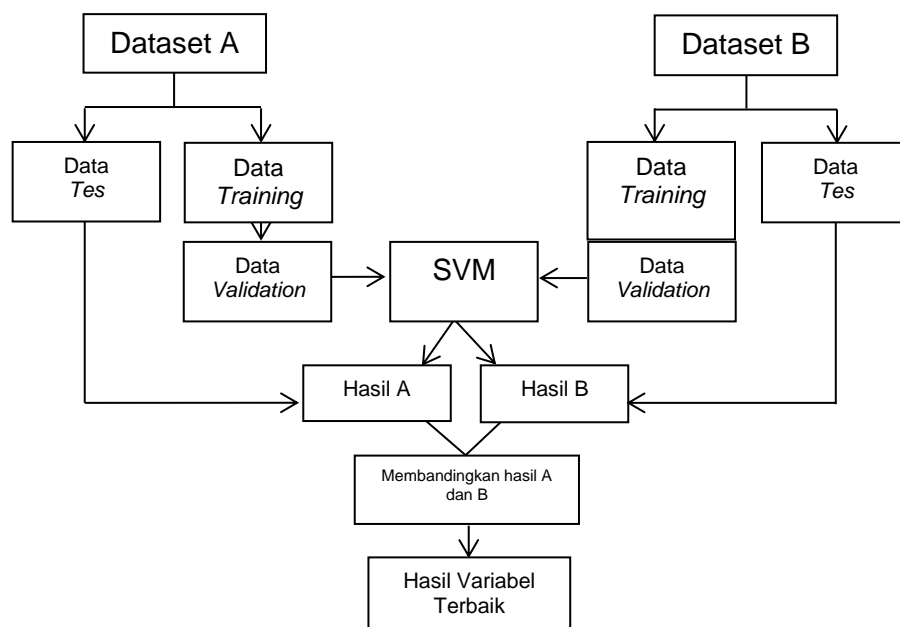
## 3.2 Teknik Pemodelan

### 3.2.1 Model Algoritma

Sebelum diolah, dataset dibagi menjadi 2, yaitu : data *training* dan data *test*. Pada tahap awal program akan memasukkan data *training* ke dalam *routine* untuk memvalidasi terhadap pola yang terbaik dari beberapa pola yang muncul. Pola terbaik tersebut yang akan dipilih dan digunakan untuk melakukan klasifikasi dan prediksi. Setelah ditemukan pola yang terbaik, program akan memasukkan data *test* ke dalam pola tersebut dan akan memberikan beberapa hasil (*output*). Kemudian program akan membandingkan hasil-hasil tersebut dan akan ditentukan hasil yang terbaik. Hasil terbaik ini ditentukan dari nilai *Root Mean Square Error (RMSE)* yang paling rendah dan nilai koefisien korelasi yang tinggi.

Pada saat proses *training*, data yang dimasukkan mempunyai anomali, maka SVM tidak akan terlalu memperhitungkannya agar pola yang terjadi setelah keseluruhan data dimasukkan tidak akan terganggu. Hal ini yang membedakan algoritma SVM dengan algoritma pengenalan pola yang lain seperti *Neural Network*. Pola yang tahan terhadap anomali data inilah yang akan mampu memprediksi data baru yang lebih akurat.

Model algoritma yang digunakan pada penelitian ini dapat digambarkan sebagai berikut :



**Gambar 4.** Metode Algoritma yang Dilakukan

## 4. IMPLEMENTASI

### 4.1 Performa Metode Pada Saat *Training*

Fase pertama algoritma pengenalan pola adalah melakukan *training*. Hal ini dilakukan agar program dapat “belajar” mengenali pola yang sudah pernah terjadi dimana pola tersebut diharapkan

akan berulang di waktu mendatang. Data yang digunakan adalah 75% dari total semua data yang digunakan dalam penelitian. Performa *training* perlu diukur untuk membuktikan keberhasilan proses “belajar” dari algoritma yang digunakan.

Dengan menggunakan metode korelasi akan didapatkan nilai koefisien korelasi dimana semakin besar nilainya maka semakin mirip pola yang didapatkan. Data yang digunakan adalah data konsumsi listrik bulanan dan harian dari gardu listrik. Koefisien korelasi adalah hasil perbandingan antara angka data *training* awal dibanding dengan angka data *training* setelah dimasukkan ke fungsi dari pola hasil *training* pada kurun waktu yang sama. Nilai *Gamma* ( $\gamma$ ) dan *Sigma* ( $\sigma$ ) adalah parameter dari fungsi basis yang digunakan dalam SVM.

#### 4.1.1 Metode SVM

Data *training* periode bulanan setelah dimasukkan ke metode SVM menggunakan bantuan aplikasi MATLAB maka didapatkan tabel sebagai berikut :

**Tabel 1.** Koefisien Korelasi Fase *Training* SVM Dataset Bulanan

Periode	Nilai $\gamma$	Nilai $\sigma$	Koefisien Korelasi ( $r$ )
BULANAN	1	1	99.85%
	1	0.5	99.99%
	1	0.2	99.99%
	1	0.1	100.00%

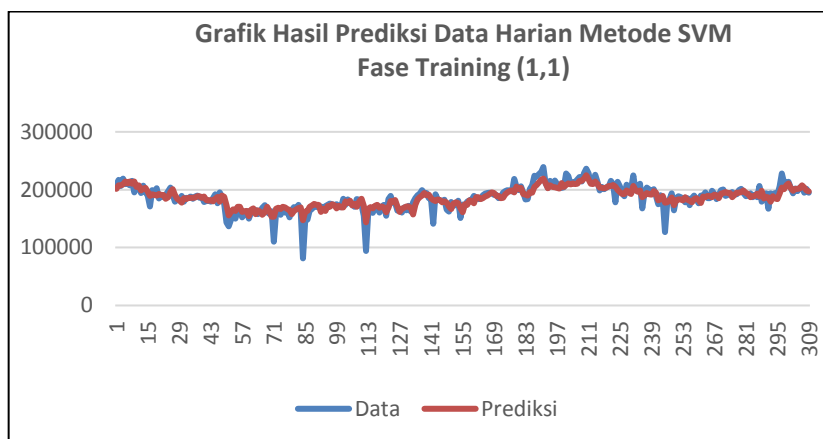
Pada fase *training* metode dapat mengenali pola dengan baik untuk periode data bulanan, terlihat dari nilai koefisien korelasi ( $r$ ) yang tinggi yaitu mencapai 99.85% pada nilai *Gamma* ( $\gamma$ ) = 1 dan *Sigma* ( $\sigma$ ) = 1. Hal ini menunjukkan metode SVM dapat membuat fungsi dengan baik untuk mengenali pola konsumsi energi listrik yang ada.

Sebagai perbandingan dilakukan *training* dengan periode waktu harian. Perbandingan ini dilakukan untuk melihat pengaruh terhadap hasil jika jumlah dataset berbeda. Data *training* periode harian setelah dimasukkan ke metode SVM menggunakan bantuan aplikasi MATLAB maka didapatkan tabel sebagai berikut :

**Tabel 2.** Koefisien Korelasi Fase *Training* SVM Dataset Harian

Periode	Nilai $\gamma$	Nilai $\sigma$	Koefisien Korelasi ( $r$ )
HARIAN	1	1	88.02%
	1	0.5	91.54%
	1	0.2	96.54%
	1	0.1	99.17%

Apabila data disajikan ke dalam Microsoft Excel maka akan didapat grafik seperti di bawah ini :



**Gambar 5.** Grafik Hasil Prediksi Fase *Training SVM* (1,1) Dataset Harian

Pada fase *training* metode *SVM* dapat mengenali pola dengan baik untuk periode data harian, terlihat dari nilai koefisien korelasi ( $r$ ) yang tinggi yaitu mencapai 88.02% pada nilai  $\text{Gamma } (\gamma) = 1$  dan  $\text{Sigma } (\sigma) = 1$ . Hal ini menunjukkan metode *SVM* dapat membuat fungsi dengan baik untuk mengenali pola konsumsi energi listrik yang ada.

#### 4.2 Performa Metode Pada Saat *Test*

Fase selanjutnya algoritma pengenalan pola adalah melakukan *test*. Hal ini dilakukan agar program dapat memprediksi pola yang baru berdasarkan pola yang sudah pernah terjadi hasil fase *training*, dimana pola tersebut diharapkan akan berulang di waktu mendatang. Data yang digunakan adalah 25% dari total semua data yang digunakan dalam penelitian. Performa *testing* perlu diukur untuk membuktikan keberhasilan pola baru yang muncul dari hasil *training* yang dilakukan.

Dengan menggunakan metode korelasi akan didapatkan nilai koefisien korelasi dimana semakin besar nilainya maka semakin mirip pola yang didapatkan. Data yang digunakan adalah data konsumsi listrik bulanan dan harian. Koefisien korelasi adalah hasil perbandingan antara angka data *testing* aktual dibanding dengan prediksi angka data *testing* setelah dimasukkan ke fungsi dari pola yang baru hasil *training*.

##### 4.2.1 Metode *SVM*

Data *testing* periode bulanan setelah dimasukkan ke metode *SVM* menggunakan bantuan aplikasi MATLAB maka didapatkan tabel sebagai berikut :

**Tabel 3.** Koefisien Korelasi Fase *Testing SVM* Dataset Bulanan

Periode	Nilai $\gamma$	Nilai $\sigma$	Koefisien Korelasi ( $r$ )
BULANAN	1	1	-25,71%
	1	0.5	-30,14%
	1	0.2	-34,19%
	1	0.1	-37,75%

Pada fase *testing* metode *SVM*, fungsi hasil *training* tidak dapat memprediksi untuk periode data bulanan dengan tepat, terlihat dari nilai koefisien korelasi ( $r$ ) yang bernilai *minus* (-) yaitu -25.71% pada nilai  $\text{Gamma } (\gamma) = 1$  dan  $\text{Sigma } (\sigma) = 1$ . Hal ini menunjukkan pola yang diprediksi bertolak belakang atau berlawanan dengan nilai aktualnya.

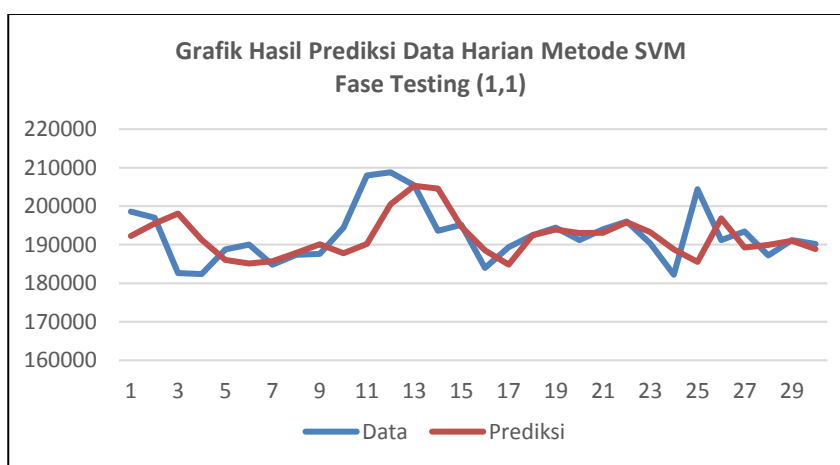
Apabila data *testing* periode harian setelah dimasukkan ke metode *SVM* menggunakan bantuan aplikasi MATLAB maka didapatkan tabel sebagai berikut :



**Tabel 4.** Koefisien Korelasi Fase *Testing SVM* Dataset Harian

Periode	Nilai $\gamma$	Nilai $\sigma$	Koefisien Korelasi ( $r$ )
HARIAN	1	1	37.83%
	1	0.5	28.83%
	1	0.2	8.57%
	1	0.1	4.10%

Apabila data disajikan ke dalam Microsoft Excel maka akan didapat grafik seperti di bawah ini



**Gambar 6.** Grafik Hasil Prediksi Fase *Testing SVM* (1,1) Dataset Harian

Pada fase *testing* metode *SVM*, fungsi hasil *training* sudah dapat memprediksi mendekati pola data aktual untuk periode data harian, terlihat dari nilai koefisien korelasi ( $r$ ) yang bernilai yaitu 37.83% pada nilai *Gamma* ( $\gamma$ ) = 1 dan *Sigma* ( $\sigma$ ) = 1. Hal ini menunjukkan fungsi hasil *training* dapat memprediksi pola yang mendekati pola data aktualnya.

## 5. KESIMPULAN

Dari hasil uji dan analisa di atas maka dapat ditarik beberapa kesimpulan, yaitu :

- Data konsumsi energi memiliki kemungkinan *error* yang dapat mempengaruhi fungsi hasil pengenalan pola metode *SVM*
- Jumlah data mempengaruhi seberapa tepat fungsi dapat “belajar” mengenali pola konsumsi energi
- Besarnya koefisien korelasi pada saat *training* tidak menjadi tolak ukur keberhasilan fungsi untuk memrediksi pola konsumsi energi
- Untuk pengenalan dan prediksi pola konsumsi energi, metode *SVM* lebih tepat digunakan dengan nilai koefisien korelasi pada saat diuji dengan data harian sebesar 37.83%.

## REFERENCES

- Vapnik, Vladimir N., *The Nature Of Statistical Learning Theory Second Edition*, Springer-Verlag New York, Inc, ISBN 0-387-98780-0, pdf version, 2000
- Charles H., Eccleston, Frederic March, Timothy Cohen, *Inside Energy : Developing and Managing an ISO 50001 Energy Management System*, CRC Press, 2012



- [www.esdm.go.id](http://www.esdm.go.id), *Peraturan Pemerintah Republik Indonesia Nomor 70 Tahun 2009 Tentang Konservasi Energi*, website address : [www.esdm.go.id/batubara/doc.../996-peraturan-pemerintah-no70-tahun-2009.html](http://www.esdm.go.id/batubara/doc.../996-peraturan-pemerintah-no70-tahun-2009.html), pdf link version, 2009
- [www.esdm.go.id](http://www.esdm.go.id), *Kajian Indonesia Energy Outlook 2012*, website address : [www.esdm.go.id/batubara/doc.../1443-kajian-indonesia-energy-outlook.html](http://www.esdm.go.id/batubara/doc.../1443-kajian-indonesia-energy-outlook.html), pdf link version, 2012
- [www.esdm.go.id](http://www.esdm.go.id), *Peraturan Pemerintah Republik Indonesia Nomor 70 Tahun 2014 Tentang Kebijakan Energi Nasional*, website address : [prokum.esdm.go.id/pp/2014/PP%20Nomor%2079%202014.pdf](http://prokum.esdm.go.id/pp/2014/PP%20Nomor%2079%202014.pdf), pdf link version, 2014
- Department of Energy (DOE) / Energy Information Administration (EIA), *The International Energy Outlook 2013*, website address : [www.eia.gov/forecasts/ieo/pdf/0484\(2013\)](http://www.eia.gov/forecasts/ieo/pdf/0484(2013)), pdf link version, July 2013
- J. Susukh; S. Premrudeepreechacharn; Tirapong. Kasirawat, *Power Quality Problem Classification Using Support Vector Machine*, Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology. ECTI-CON 2009, 6th International Conference, Volume: 01 Pages: 58 - 61, DOI: 10.1109/ECTICON.2009.5136965, **IEEE Conference Publications, 2009**
- K. Shu; L. Jing; L. Mei; Z. Xin, *Prediction Based On Support Vector Machine For Travel Choice Of High-Speed Railway passenger in China*, International Conference Management Science and Engineering (ICMSE), Pages: 28 - 33, DOI: 10.1109/ICMSE.2011.6069938, **IEEE Conference Publications, 2011**
- D. Xinhui; W. Liang; S. Jiancheng; Z. Yan, *Application of Neural Network and Support Vector Machines to Power System Short-term Load Forecasting*, Computational Aspects of Social Networks (CASoN), International Conference Pages: 729 - 732, DOI: 10.1109/CASoN.2010.167 Cited by: Papers (1), **IEEE Conference Publications, 2010**
- S. Tuntisak; S. Premrudeepreechacharn, *Harmonic Detection in Distribution Systems Using Wavelet Transform and Support Vector Machine*, Power Tech, , IEEE Lausanne Pages: 1540 - 1545, DOI: 10.1109/PCT.2007.4538544 Cited by: Papers (2), Papers (1), IEEE Conference Publications, 2007
- A. Khashman; N. I. Nwulu, *Intelligent Prediction of Crude Oil Price Using Support Vector Machines*, Applied Machine Intelligence and Informatics (SAMI), IEEE 9th International Symposium Pages: 165 - 169, DOI: 10.1109/SAMI.2011.5738868 Cited by: Papers (5), IEEE Conference Publications, 2011
- H. Liu; C. Xu; X. Wang; T. Wang, *Identification of Oil/Gas and Water Zones in Geological Logging With Support-Vector Machine*, Cognitive Informatics & Cognitive Computing (ICCI\*CC), IEEE 11th International Conference Pages: 279 - 282, DOI: 10.1109/ICCI-CC.2012.6311161, IEEE Conference Publications, 2012
- Y. Zhang; X. Ma; Y. Zhang; J., *Support Vector Machine of The Coal Mine Machinery Equipment Fault Diagnosis*, Information and Automation (ICIA), IEEE International Conference Pages: 1141 - 1146, DOI: 10.1109/ICInfA.2013.6720467, IEEE Conference Publications, 2013