

# PERAMALAN BEBAN LISTRIK BULANAN SEKTOR INDUSTRI MENGGUNAKAN SUPPORT VECTOR MACHINE DENGAN VARIASI FUNGSI KERNEL

**Luqman Assaffat**

Program Studi Teknik Elektro, Fakultas Teknik  
Universitas Muhammadiyah Semarang  
Jl.Raya Kasipah No. 12 Semarang 50254  
email : assaffat@unimus.ac.id

## ABSTRACT

*Electrical energy consumption in the industrial sector is one of the factors that accounted for the production cost, and efficiency of electrical energy use can reduce the production cost. Energy efficiency in industry can be applied by regulating the use of the electric load, it can be watched from the electrical load Characteristics. The monthly characteristics of the electrical load every can be predicted, so do the efforts to regulate the amount of load and provide electrical energy required. This research present the monthly electricity load forecasting in the industrial sector by SVM with a variety of Kernel functions. There are 3 (three) types of training data given on SVM, they are types months of the year, production data and time series data past the electrical load, with a variable input data between 1 year to 6 years. Variations Kernel functions used in SVM methods are Linear, quadratic, Gaussian RBF, polynomial and Multilayer Perceptron. This research produced the smallest forecasting MAPE of 5.33% with a 6 year input data training scheme with Gaussian RBF kernel function.*

**Keyword: Electric Load, Monthly Forecasting, SVM, Kernel Function**

## PENDAHULUAN

Efisiensi energi listrik pada saat sekarang menjadi topik yang sangat penting bagi berbagai perusahaan dan industri. Banyak permasalahan yang timbul saat ini, di mana perusahaan dan industri mengalami kesulitan di dalam menjalankan produksi dan operasionalnya terkait dengan konsumsi energi listrik (Door dkk, 2013). Sektor industri merupakan pengguna energi listrik terbesar jika dibandingkan dengan sektor yang lain, yaitu sekitar 27% dari konsumsi energi listrik dunia. Sehingga diperlukan peningkatan efisiensi energi pada sektor industri dipandang dari sudut ekonomi dan bisnis (Thollander dan Ottosson, 2010).

Penghematan energi listrik dapat dilakukan dengan pengaturan operasional industri berdasarkan laporan prakiraan beban listrik listrik tersebut (Assaffat, 2015). Keakuratan peramalan beban listrik menjadi kunci dalam perencanaan sistem tenaga listrik. Hal ini digunakan sebagai alat untuk menentukan jadwal perawatan sistem tenaga listrik, pembangunan fasilitas baru, penyediaan energi dan lain-lain (Al-Hamadi, 2005).

Peramalan beban listrik dapat diklasifikasikan berdasarkan waktu, yaitu peramalan beban jangka pendek (*Short Term Load Forecasting*, STLF), peramalan beban jangka menengah (*Medium Term Load Forecasting*, MTLF) dan peramalan beban jangka panjang (*Long Term Load Forecasting*, LTLF) (Hahn, 2009). Peramalan jangka menengah (MTLF) dengan dimensi waktu bulanan dalam satu tahun biasanya digunakan untuk penjadwalan dan penyediaan energi listrik serta pembelian bahan bakar untuk pembangkit listrik. Selain menyediakan informasi beban listrik, peramalan beban bulanan juga terdapat faktor tambahan seperti demografi dan pengaruh ekonomi (Almeshaie dkk, 2011).

Terdapat beberapa pendekatan yang digunakan di dalam peramalan beban listrik, antara lain yaitu metode regresi dan *time series* klasik dan metode kecerdasan buatan. Salah satu metode kecerdasan buatan yang sering digunakan dan terkenal yaitu metode jaringan syaraf tiruan (*Artificial Neural Network*, ANN), sedangkan metode kecerdasan buatan yang relatif baru yaitu metode *Support Vector Machine* (SVM) (Hahn, 2009).


SVM merupakan salah satu algoritma *machine learning* yang paling populer untuk klasifikasi dan regresi (Maali dkk, 2013). Konsep dasar SVM sebenarnya merupakan kombinasi harmonis dari teori-teori komputasi yang telah ada puluhan tahun sebelumnya. Konsep Kernel diperkenalkan tahun 1950, dan demikian juga dengan konsep-konsep pendukung yang lain. Akan tetapi hingga tahun 1992, dan pernah ada upaya merangkaikan komponen-komponen tersebut (Vapnik, 1999). Dalam proses pembelajarannya, SVM memperkenalkan strategi baru dengan menemukan *hyperplane* yang terbaik pada *input space*, lewat strategi yang disebut *Structural Risk Minimization*. Prinsip dasar SVM yaitu sebagai *linear classifier*, dan selanjutnya dikembangkan agar dapat bekerja pada problem non-linear dengan memasukkan konsep *Kernel trick* pada ruang kerja berdimensi tinggi (Cristianini, 2000). Keunggulan metode SVM dibandingkan dengan metode peramalan lainnya, salah satunya yaitu aplikasi SVM digunakan untuk memprediksi konsumsi energi listrik pada suatu gedung mempunyai nilai kesalahan lebih kecil dan lebih handal jika dibandingkan dengan metode jaringan syaraf tiruan (Ahmad dkk, 2014).

**SUPPORT VECTOR MACHINE**

Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada *input space*. *Hyperplane* pemisah terbaik antara kedua class dapat ditemukan dengan mengukur *margin hyperplane* tersebut dan mencari titik maksimalnya. Margin merupakan jarak antara *hyperplane* tersebut dengan data terdekat dari masing-masing class. Subset data training set yang paling dekat ini disebut sebagai *support vector*. Upaya mencari lokasi *hyperplane* optimal ini merupakan inti dari proses pembelajaran pada SVM .

Apabila terdapat  $N$  set data training,  $(x_i, y_i)$  dengan  $i = 1, 2, 3, \dots, N$  dan input  $x = \{x_1, x_2, x_3\} \dots \subseteq \mathfrak{R}$  serta output  $y = \{y_1, y_2, \dots, y_\ell\} \subseteq \mathfrak{R}$  . Metode SVM akan menemukan suatu fungsi  $f(x)$  yang mempunyai deviasi paling besar  $\epsilon$  dari target aktual  $y_i$  untuk semua data training. Di dalam penggunaan SVM, apabila  $\epsilon$  sama dengan 0 akan didapatkan regresi yang sempurna. Jika sebuah fungsi berikut sebagai garis regresi, sebagai berikut :

$$f(x) = w^T \cdot \Phi(x) + b \tag{1}$$



**Gambar 1. Tube  $\epsilon$  SVM non linier**

$\Phi(x)$  menunjukkan suatu titik di dalam *feature space*  $F$  hasil pemetaan  $x$  di dalam *input space*. Koefisien  $w$  dan  $b$  diestimasi dengan cara meminimalkan fungsi resiko (*risk function*). Setelah permasalahan optimasi *quadratic* dengan ketidakpastian *constraint* diselesaikan, maka parameter  $w$  pada persamaan (1) menjadi :

$$w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \Phi(x_i) \tag{2}$$

Parameter  $\alpha_i$  dan  $\alpha_i^*$  merupakan *Langrange multiplier* yang didapat dari penyelesaian optimasi kuadrat. Fungsi regresi SVM untuk *dual space* sebagai berikut :

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \tag{3}$$

$K(x_i, x_j)$  disebut sebagai fungsi Kernel, dan nilai dari fungsi Kernel merupakan perkalian titik (*dot product*) antar kedua vektor  $x_i$  dan  $x_j$  di dalam *feature space*  $\Phi(x_i)$  dan  $\Phi(x_j)$ . Sehingga fungsi Kernel sama dengan :

$$K(x_i, x_j) = \Phi(x_i) \circ \Phi(x_j) \tag{4}$$

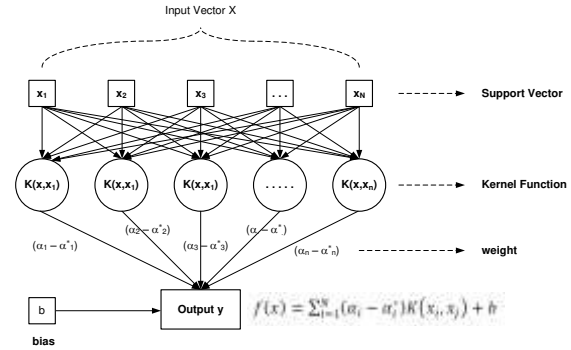
Tabel 1 di bawah menjelaskan fungsi kernel yang sering digunakan pada SMV, yaitu Polinomial, Gaussian dan Sigmoid. Pada penelitian ini, fungsi Kernel yang digunakan adalah Linear, Polinomial, *Quadratic*, *Gaussian Radial Basic Funcion* (RBF) dan Perceptron Multilayer.

**Tabel 1. Kernel yang umum dipakai dalam SVM**

Jenis Kernel	Definisi
Polynomial	$K(\bar{x}_i, \bar{x}_j) = K(\bar{x}_i, \bar{x}_j + 1)^P$
Gaussian	$K(\bar{x}_i, \bar{x}_j) = \exp\left(-\frac{\ (\bar{x}_i, \bar{x}_j)\ ^2}{2\sigma^2}\right)$
Sigmoid	$K(\bar{x}_i, \bar{x}_j) = \tanh(\alpha\bar{x}_i, \bar{x}_j\beta)$

SVM merupakan metode yang dapat melakukan klasifikasi hanya untuk dua kelas (biner), sementara masalah di dunia nyata umumnya mempunyai banyak kelas. Terdapat dua pilihan untuk menetapkan SVM multikelas yaitu dengan menggabungkan beberapa SVM biner atau menggabungkan semua data yang terdiri dari beberapa kelas ke dalam sebuah bentuk permasalahan optimal. Namun pada pendekatan yang kedua permasalahan optimasi yang harus diselesaikan jauh lebih rumit (Prasetyo, 2014).

Salah satu penerapan SVM adalah SVR, yaitu penerapan *support vector machine* (SVM) yang digunakan untuk kasus regresi. Dalam kasus regresi output berupa bilangan riil atau kontinue. SVR merupakan metode yang dapat mengatasi *overfitting*, sehingga akan menghasilkan performansi yang bagus (Smola dan Scholkopf, 2004). Gambar 2 memperlihatkan arsitektur konstruksi algoritma SVR. Pola input (dimana prediksi akan dibuat) dipetakan ke dalam ruang fitur dengan peta  $\Phi$ . Kemudian perkalian titik (*dot product*) dihitung dengan gambar pola pelatihan di bawah peta  $\Phi$ . Akhirnya titik produk ditambahkan dengan menggunakan bobot  $w = (\alpha_i - \alpha_i^*)$ . Kemudian ditambahkan konstanta  $b$  sebagai bias untuk menghasilkan output prediksi akhir. Proses yang dijelaskan di atas sangat mirip dengan regresi dalam jaringan saraf tiruan, dengan perbedaan bahwa dalam kasus SVR bobot pada lapisan input diperoleh dari pola pelatihan (Smola dan Scholkopf, 2004).



**Gambar 2. Arsitektur Konstruksi Algoritma SVR**

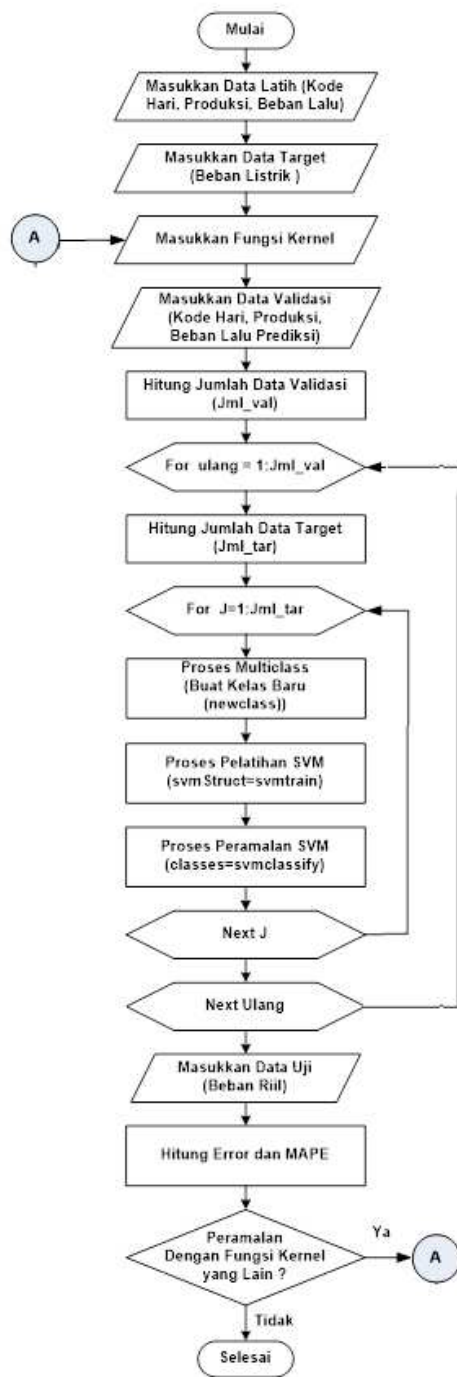
**METODE PENELITIAN**

Objek dalam penelitian ini adalah peramalan beban listrik bulanan pada setor industri, dan sebagai indeks keakuratan metode peramalan menggunakan nilai persentase kesalahan absolut rata-rata (*Mean Absolute Error Percentage, MAPE*). Data penelitian yang dibutuhkan yaitu data historis *time series* beban listrik bulanan dan data produksi dalam format *excell spreadsheet*. Studi kasus diterapkan pada salah satu Industri Farmasi Nasional yang terletak di Kota Semarang.

Metode yang digunakan dalam sistem peramalan bulanan sektor industri pada penelitian ini adalah Support Vector Machine, dengan variasi fungsi kernel. Alur metode SVM dalam peramalan beban listrik bulanan dengan variasi fungsi Kernel diperlihatkan pada gambar 3.

Variabel bebas sebagai parameter peramalan beban listrik bulanan pada sektor industri ini adalah :

1. Beban listrik bulanan (MWh), sebagai data historis penggunaan listrik
2. Kapasitas produksi industri (Ton), sebagai variabel pendukung peramalan
3. Jenis Bulan dalam setahun, sebagai variabel pendukung peramalan



**Gambar 3. Diagram Alir Peramalan Beban Listrik Bulanan Dengan SVM**

Data *times series* beban listrik bulanan (MWh) merupakan data sekunder pencatatan konsumsi energi listrik di bagian utilitas, sedangkan data kapasitas produksi merupakan data yang telah terekam di bagian produksi. Data pelatihan, data validasi dan data testing yang akan digunakan merupakan data *times series* bulanan dari variabel data input vektor  $x$  selama kurun waktu 84 bulan (Januari 2008 – Desember 2014). Tabel

2 berikut ini memperlihatkan skema pelatihan SVM serta validasi keluaran SVM.

**Tabel 2 Skema Data Latih dan Data Validasi SVM**

DATA LATIH SVM	DATA VALIDASI SVM
1 th : Data th 2008 (12 data)	Data th 2009 (12 data)
2 th : Data th 2008-2009 (24 data)	Data th 2010 (12 data)
3 th : Data th 2008-2010 (36 data)	Data th 2011 (12 data)
4 th : Data th 2008-2011 (48 data)	Data th 2012 (12 data)
5 th : Data th 2008-2012 (60 data)	Data th 2013 (12 data)
6 th : Data th 2008-2013 (72 data)	Data th 2014 (12 data)

Ukuran akurasi dari suatu metode peramalan dapat ditentukan dengan nilai kesalahan persentase absolut rata-rata (*Mean Absolute Percentage Error*, MAPE) (Hong, 2009) yaitu :

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - f_i}{y_i} \right| \quad (5)$$

Keterangan :

- $N$  : jumlah data dalam periode peramalan
- $y_i$  : data aktual pada periode ke  $i$
- $f_i$  : data peramalan pada periode ke  $i$

## HASIL DAN PEMBAHASAN

Gambar 4 memperlihatkan grafik kapasitas produksi dari tahun 2008 sampai tahun 2014, sedangkan Gambar 5 memperlihatkan grafik beban listrik dari tahun 2008 sampai 2014.



**Gambar 4 Kapasitas Produksi Bulanan 2008-2014**



**Gambar 5 Beban Listrik Bulanan Tahun 2008-2014**

Hasil pengujian sistem peramalan beban listrik bulanan pada sektor industri dengan skema yang telah ditentukan serta menggunakan variasi fungsi Kernel diperlihatkan pada Tabel 3. Dari tabel 3 jika dibuat rata-rata MAPE setiap fungsi Kernel, didapatkan rata-rata MAPE peramalan beban listrik bulanan terkecil adalah MAPE fungsi Kernel Gaussian RBF sebesar 16,72%, sehingga dapat dikatakan bahwa Kernel Gaussian RBF mempunyai kesalahan peramalan terkecil jika dibandingkan dengan fungsi kernel yang lain.


**Tabel 3 MAPE (%) Hasil Pengujian Sistem Peramalan**

Jml Data	Fungsi Kernel				
	L	Q	G	P	M
1 th	50,1	30,4	29,1	27,7	64,4
2 th	35,2	26,5	20,6	20,2	28,2
3 th	43,2	21,0	19,1	28,3	47,4
4 th	54,0	30,4	18,6	45,7	32,0
5 th	38,9	35,2	7,4	37,9	45,0
6 th	25,0	21,7	5,3	20,0	34,5

L : Linear, Q : Quadratic, G : Gaussian RBF, P : Polynomial, M : Multilayer Perceptron

Bila ditinjau setiap data pengujian, nilai MAPE terkecil didapatkan pada pengujian system peramalan SVM menggunakan fungsi Kernel Gaussian RBF dengan data latih sebanyak 72 data latih atau selama 6 tahun, dengan besarnya MAPE 5,33 %. Sehingga Fungsi Kernel yang sesuai dengan peramalan bulanan untuk sektor industri adalah fungsi Kernel Gaussian RBF. Jika ditinjau dari gambar 5 tentang grafik hasil pengujian peramalan SVM berdasarkan data latih, dengan semakin banyaknya data latih maka MAPE peramalan akan semakin kecil. Hal ini

hanya dapat ditunjukkan oleh fungsi Kernel Gaussian RBF.



**Gambar 6 Grafik hasil Pegujian SVM berdasarkan jumlah data latih**

### KESIMPULAN

Dari penelitian ini dapat disimpulkan bahwa Fungsi Kernel yang sesuai untuk peramalan beban listrik sektor industri menggunakan Support Vektor Machine adalah fungsi Kernel Gaussian RBF, karena mempunyai nilai rata-rata MAPE paling kecil. Nilai MAPE terkecil dari pengujian system adalah 5,33% yang didapatkan saat pengujian menggunakan fungsi kernel Gaussian RBF dengan jumlah data latih paling banyak yaitu 72 data (6 tahun). Semakin banyak jumlah data latih yang diberikan kepada SVM, maka nilai MAPE semakin kecil, sehingga peramalannya semakin akurat.

### DAFTAR PUSTAKA

- Ahmad, A.S., Hassan, M.Y., Abdullah, M.P., Rahman, H.A., Hussin, F., Abdullah, H., Saidur, R., 2014, A Review on Applications of ANN And SVM For Building Electrical Energy Consumption Forecasting, Renewable And Sustainable Energy Reviews 33, 102–109
- Al-Hamadi, H.M., Soliman, S.A., 2005, Long-Term/Mid-Term Electric Load Forecasting Based on Short-Term Correlation and Annual Growth, Electric Power Systems Research 74 (2005) 353–361
- Almehaie, E., Soltan, H., 2011, A Methodology for Electric Power Load

Forecasting, Alexandria Engineering Journal, 50, 137–144

Assaffat, L., 2015, Analisis Akurasi Support Vector Machine Dengan Fungsi Kernel Gaussian RBF Untuk Prakiraan Beban Listrik Harian Sektor Industri, Momentum, Vol. 11 No. 2, 2015

Cristianini N., Taylor J.S., 2000, An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods, Cambridge Press University, 2000

Dörr, M., Wahren, S., Bauernhansl, T., 2013, Methodology for Energy Efficiency on Process Level, Procedia CIRP, 652–657

Hahn, H., Nieberg, S.M., Pickl, S., 2009 , Electric Load Forecasting Methods: Tools for Decision Making, European Journal of Operational Research 199, 902–907

Hong, W.C., 2009, Chaotic particle swarm optimization algorithm in a support vector regression electric load forecasting model, Energy Conversion and Management, 50, 105–117

Maali, Y., Al-Jumaily, A., 2013, Self-Advising Support Vector Machine, Knowledge-Based Systems 52, 214–222.

Smola, A.J., Scholkopf, B., 2004, A Tutorial On Support Vector Regression, Statistic and Computing 14, 199-222

Thollander, P., Ottosson, M., 2010, Energy Managemen Practices in Swedish Energy – Intensive Industries

Vapnik, V.N., 1999, The Nature of Statistical Learning Theory 2nd edition, Springer-Verlag, New York Berlin Heidelber