

PERBANDINGAN PERAMALAN BEBAN LISTRIK JANGKA PENDEK MENGGUNAKAN *SUPPORT VECTOR MACHINE* DAN JARINGAN SYARAF TIRUAN PERAMBATAN BALIK

I Nyoman Setiawan, Widyadi Setiawan

Jurusan Teknik Elektro, Universitas Udayana

Kampus Bukit Jimbaran, Bali, 80361

E-Mail : setiawan@unud.ac.id

Abstrak

Penelitian ini membahas pemakaian Jaringan Syaraf Tiruan (JST) Perambatan Balik dan *Support Vector Machine* (SVM) untuk peramalan kebutuhan beban listrik. Variabel yang dipakai dalam JST dan SVM adalah data beban listrik wilayah Bali. Hasil peramalan memiliki persentase kesalahan rata-rata absolut 5,71% untuk metode JST dan 3,53% untuk metode SVM. Metode JST mempunyai rata-rata eror minimal 0,35% dan maksimal 17,34%. Metode SVM mempunyai rata-rata eror minimal 0,16% dan maksimal 10,53%. Metode SVM memiliki keakuratan lebih baik dibandingkan dengan metode JST.

Kata Kunci : jaringan syaraf tiruan, perambatan balik, *support vector machine*, peramalan beban

1. PENDAHULUAN

Perhitungan besarnya permintaan listrik pada suatu waktu tertentu tidak dapat dilakukan secara pasti. Sehingga peramalan besarnya kebutuhan listrik sangat diperlukan. Bila besarnya permintaan listrik tidak dapat diramalkan maka akan sangat berpengaruh pada kesiapan unit pembangkit untuk menyediakan pasokan listrik pada jaringan distribusi. Ketimpangan daya listrik antara permintaan dan yang disediakan dapat mengakibatkan kerugian. Peramalan beban jangka pendek bertujuan untuk meramalkan beban listrik pada jangka waktu menit, jam, hari atau minggu. Peramalan beban jangka pendek memainkan peran yang penting dalam *real-time control* dan fungsi-fungsi keamanan dari suatu sistem manajemen energi [1]. Sebuah peramalan beban listrik jangka pendek yang tepat, dapat menghasilkan penghematan biaya operasional bagi produsen dan pengoptimalan penyediaan tenaga listrik kepada konsumen [2]. Peramalan beban listrik jangka pendek untuk jangka waktu 1-24 jam ke depan adalah penting untuk operasi sehari-hari dari utilitas daya. Peramalan beban ini digunakan untuk *unit commitment*, *energy transfer scheduling* dan *load dispatch* [3].

Banyak metode telah dikembangkan untuk peramalan beban listrik jangka pendek. Metode tersebut antara lain metode parametrik, nonparametrik, dan berbasis kecerdasan buatan. Metode parametrik merumuskan model matematika atau statistik untuk beban dengan memeriksa kuantitatif hubungan antara beban dan faktor yang mempengaruhi. Beberapa contoh model yang digunakan adalah fungsi polynomial, model ARMA, deret Fourier, dan regresi linier berganda [4]. Metode nonparametrik memungkinkan ramalan akan dihitung langsung dari data historis. Sebagai contoh, menggunakan regresi nonparametrik, sebuah ramalan beban dapat dihitung sebagai rata-rata lokal beban

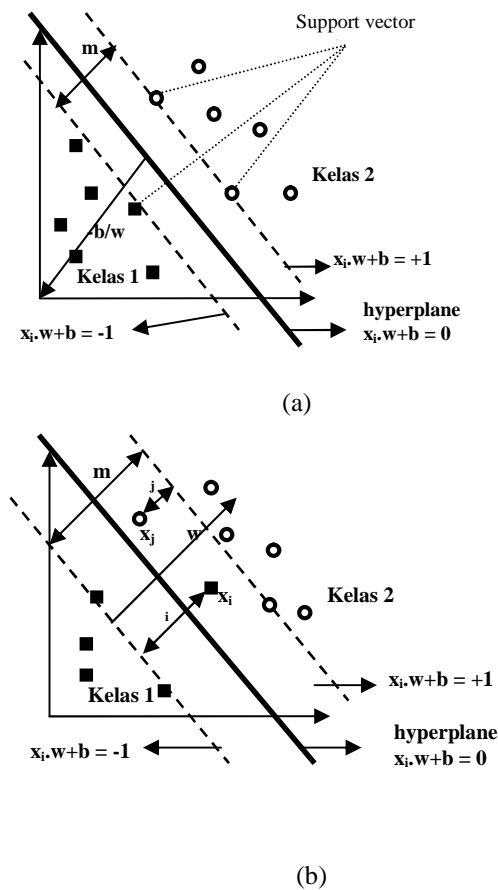
masa lalu diamati dengan ukuran lingkungan lokal dan bobot tertentu pada beban yang didefinisikan oleh *multivariate product kernel* [5]. Beberapa metode berbasis kecerdasan buatan seperti *Fuzzy Inference System*, *Fuzzy Linear Regression* dan *Artificial Neural Network* telah banyak diaplikasikan pada peramalan beban listrik dan hasilnya memuaskan [6]. Saat ini, *Support Vector Machine* (SVM) adalah metode berbasis kecerdasan buatan yang sangat populer digunakan untuk peramalan beban listrik jangka pendek dan akurasi peramalan sangat bagus dibandingkan metode lainnya. *Support Vector Machine* (SVM) merupakan metode yang memiliki keunggulan dalam optimasi sistem pengenalan pola dengan kemampuan generalisasi yang menakjubkan. SVM juga dapat digunakan untuk peramalan suatu nilai, seperti yang diperkenalkan oleh Vapnik pada akhir tahun 1960-an. Tidak seperti metode konvensional lainnya, SVM yang dikembangkan berdasarkan prinsip *Structural Risk Minimization* berusaha menemukan *hyperplane* pemisah antar kelas yang terbaik dengan memaksimalkan jarak margin *hyperplane* sehingga berperan pada minimisasi error. Lebih dari itu, generalisasi error pada SVM tidak berkaitan dengan dimensionalitas input masalah dan merepresentasikan solusi sebaik mungkin. Hal ini menjelaskan mengapa SVM memiliki kinerja yang baik bahkan untuk persoalan-persoalan dengan jumlah input yang besar [7].

Pada penelitian ini diusulkan metode SVM untuk peramalan beban listrik jangka pendek serta sebagai metode pembandingnya menggunakan jaringan syaraf tiruan perambatan balik.. Metode SVM yang akan dipakai dalam penelitian ini adalah metode SVM untuk regresi yang dikenal sebagai *Support Vector Regression* (SVR) digunakan untuk peramalan beban listrik jangka pendek [8].

2. KAJIAN PUSTAKA

2.1 Support Vector Machine (SVM)

Support Vector Machine (SVM) bekerja berdasarkan prinsip *Structural Risk Minimization*, yang meminimalkan batas atas dari dimensi VC atau *Vapnik-Chervonenkis*. SVM dapat melakukan klasifikasi data yang terpisah secara linier dan nonlinier. Data terpisah secara linier merupakan data yang dapat dipisahkan secara linier. Misalkan $\{x_1, \dots, x_n\}$ adalah dataset dan $y_i \in \{+1, -1\}$ adalah label kelas dari data x_i . Pada gambar 1 dapat dilihat berbagai alternatif bidang pemisah yang dapat memisahkan semua data set sesuai dengan kelasnya. Namun, bidang pemisah terbaik tidak hanya dapat memisahkan data tetapi juga memiliki margin paling besar. Data yang berada pada bidang pembatas ini disebut *support vector*.



Gambar 1. Hard dan Soft margin hyperplane

$$\begin{aligned}
 x_i.w + b &\geq +1 \text{ untuk } y_i = +1 \\
 x_i.w + b &\leq -1 \text{ untuk } y_i = -1
 \end{aligned}
 \tag{1}$$

w adalah bidang normal dan b adalah posisi bidang relatif terhadap pusat koordinat. Nilai margin (jarak) antara bidang pembatas (berdasarkan rumus jarak garis ke titik pusat) adalah $\frac{1-b-(-1-b)}{w} = \frac{2}{|w|}$

Nilai margin ini dimaksimalkan dengan tetap memenuhi (1).

Selain itu, karena memaksimalkan sama dengan meminimumkan dan jika kedua bidang pembatas pada (1) direpresentasikan dalam pertidaksamaan berikut :

$$y_i(x_i.w + b) - 1 \geq 0 \quad \forall_i \tag{2}$$

maka pencarian bidang pemisah terbaik dengan nilai margin terbesar dapat dirumuskan menjadi masalah optimasi konstrain, yaitu $\min \frac{1}{2}|w|^2$

Persoalan ini akan lebih mudah diselesaikan jika diubah ke dalam formula *lagrangian* yang menggunakan *lagrange multiplier*. Dengan demikian permasalahan optimasi konstrain dapat diubah menjadi:

$$\begin{aligned}
 \min Lp(w, b, r) &= \frac{1}{2}|w|^2 - \\
 &\sum_{i=1}^l r_i y_i (x_i.w + b) + \sum_{i=1}^l r_i
 \end{aligned}
 \tag{3}$$

Karena $w = \sum_i r_i y_i x_i, \sum_i r_i y_i = 0$ disubstitusi ke persamaan (3), dan menjadi :

$$L_D = \sum_i r_i - \frac{1}{2} \sum_{i,j} r_i r_j y_i y_j x_i \cdot x_j \tag{4}$$

Untuk mengklasifikasi data yang terpisah secara tidak linier dapat dilakukan dengan menggunakan teknik *softmargin hyperplane*, dengan formula pencarian bidang pemisah terbaik:

$$\min \frac{1}{2}|w|^2 + C \left(\sum_{i=1}^l \xi_i \right)$$

Dimana $y_i(x_i.w + b) \geq 1 - \xi_i$ dan $\xi_i \geq 0$. C adalah parameter yang menentukan besar penalti akibat kesalahan dalam klasifikasi data dan nilainya ditentukan oleh pengguna. Bentuk persoalan (4) memenuhi prinsip SRM, dimana meminimumkan $\frac{1}{2}|w|^2$ ekuivalen dengan meminimumkan dimensi VC

dan meminimumkan $C(\sum_i \xi_i)^k$ berarti meminimumkan error pada data pelatihan.

Selanjutnya, bentuk *primal problem* sebelumnya berubah menjadi:

$$\begin{aligned}
 Lp(w, x, b) &= \frac{1}{2}|w|^2 + \\
 C \sum_{i=1}^n \xi_i - \sum_{i=1}^n r_i \{y_i(x_i.w + b) - 1 + \xi_i\} - \sum_{i=1}^n \xi_i
 \end{aligned}
 \tag{5}$$

dengan ξ_i adalah *Lagrange multiplier*. Sedangkan bentuk dual problemnya adalah sebagai berikut:

$$L_D = \sum_i r_i - \frac{1}{2} \sum_{i,j} r_i r_j y_i y_j x_i \cdot x_j,$$

dimana $0 \leq r_i \leq C$ dan $\sum_i r_i y_i = 0$, maka

solusinya diberikan oleh $w = \sum_{i=1}^{ns} r_i y_i x_i$ dengan ns

adalah jumlah *support vector*.

Metode lain untuk mengklasifikasikan data yang tidak dapat dipisahkan secara linier adalah dengan mentransformasikan data ke dalam dimensi ruang fitur (*feature space*) sehingga dapat dipisahkan secara linier pada *feature space*. Dengan menggunakan transformasi $\Phi: R^d \rightarrow R^q, d < q$, selanjutnya proses pembelajaran SVM dalam menemukan support vector hanya tergantung dari dot product dari data yang sudah ditransformasikan. Untuk $(\Phi(x_i), \Phi(x_j))$, terdapat fungsi kernel K sedemikian hingga $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$. Dengan demikian fungsi hasil pembelajaran dapat dituliskan :

$$f(x) = \sum_{i=1}^{ns} r_i y_i \Phi(x_i) \cdot \Phi(x) + b = \sum_{i=1}^{ns} r_i y_i K(x_i, x) + b \quad (6)$$

2.2 Jaringan Syaraf Tiruan (JST)

Jaringan Syaraf Tiruan (JST) adalah model sistem komputasi yang bekerja seperti sistem syaraf biologis pada saat berhubungan dengan 'dunia luar', nama jaringan syaraf tiruan merupakan terjemahan dari "*Artificial Neural Network*". Terjemahan yang diambil bukan jaringan syaraf buatan seperti dalam menterjemahkan *Artificial Intelligent* (AI). Penggunaan kata buatan dapat memberikan konotasi, bahwa manusia berusaha membuat jaringan syaraf aslinya. Padahal maksud dari JST adalah membuat model sistem komputasi yang dapat menirukan cara kerja jaringan syaraf biologis. Model JST yang digunakan dalam penelitian ini adalah arsitektur *feedforward* (umpan maju). Sedangkan konsep belajar yaitu algoritma belajar *backpropagation* momentum dengan teknik perbaikan menggunakan gradient dengan momentum dan *adaptive learning* (*traindx*) yang merupakan perkembangan dari algoritma belajar *backpropagation* standar. Jaringan Syaraf Tiruan *Backpropagation* pertama kali diperkenalkan oleh Rumelhart, Hinton dan William pada tahun 1986, kemudian Rumelhart dan Mc Clelland mengembangkannya pada tahun 1988.

Pola kegiatan beban listrik pada hari kerja yaitu hari Senin sampai hari Jumat dan hari akhir pekan, pada setiap minggunya tidak akan banyak berubah. Pola kegiatan konsumen akan berulang pada setiap minggunya. Pengulangan ini juga akan terjadi pada pola kurva beban dari minggu ke minggu, dimana hari yang sama pada suatu minggu mempunyai pola kurva beban yang mirip. Berdasarkan pengalaman menunjukkan bahwa beban listrik pada suatu hari dipengaruhi oleh beban pada hari-hari sebelumnya. Misalnya untuk meramalkan kebutuhan beban pada hari senin digunakan data beban hari minggu (1 hari

sebelumnya), setelah didapat hasilnya. Peramalan dilakukan lagi dengan data sabtu dan minggu (2 hari sebelumnya). 3 hari sebelumnya sampai 7 hari (1 minggu) sebelumnya. Disini akan terlihat pengaruh banyaknya data yang digunakan untuk peramalan.

2.3 Kriteria Keakuratan Peramalan

Seorang perencana tentu menginginkan hasil perkiraan ramalan yang tepat atau paling tidak dapat memberikan gambaran yang paling mendekati sehingga rencana yang dibuatnya merupakan rencana yang realistis. Ketepatan atau ketelitian inilah yang menjadi kriteria performance suatu metode peramalan. Ketepatan atau ketelitian tersebut dapat dinyatakan sebagai kesalahan dalam peramalan. Kesalahan yang kecil memberikan arti ketelitian peramalan yang tinggi, dengan kata lain keakuratan hasil peramalan tinggi, begitu pula sebaliknya. Besar kesalahan suatu peramalan dapat dihitung dengan beberapa cara, antara lain adalah :

1. *Mean Square Error* (MSE)

$$MSE = \frac{\sum_{t=1}^N (X_t - F_t)^2}{N}$$

2. *Mean Absolute Percentage Error* (MAPE) :

$$MAPE = \frac{\sum_{t=1}^N \frac{|X_t - F_t|}{X_t} \times 100\%}{N}$$

Dimana:

X_t = data aktual periode t

F_t = nilai ramalan periode t

N = banyaknya periode

3. METODE PENELITIAN

Pembuatan dan implementasi fungsi metode SVM dan Perambatan Balik, pelatihan dan pengujian dengan menggunakan tools *Matlab*. Pengujian perangkat lunak dengan pengambilan dan pembelajaran beberapa data beban uji. Pengujian ini dilakukan dua tahap yaitu, pengujian perangkat lunak untuk proses pelatihan (training) dan pengujian untuk proses pengujian (testing/validasi). Dimana setengah dari data yang ada digunakan untuk pengujian proses pelatihan dan setengah lainnya digunakan untuk proses pengujian. Data yang digunakan adalah beban listrik harian PLN Bali. Pengumpulan data beban harian dilakukan selama periode 3- 30 April 2011. Selanjutnya dilakukan pengujian metode JST dibandingkan dengan SVM dengan memakai beban real selama kurun waktu 7 hari yaitu dari 24 - 30 April 2011 memakai struktur optimal JST.

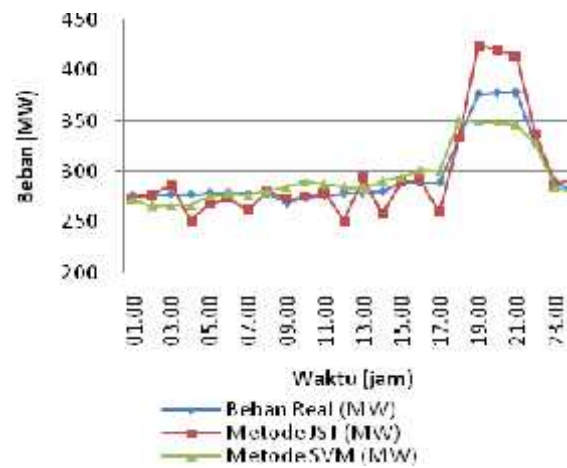
4. HASIL DAN PEMBAHASAN

Penelitian ini meramalkan beban listrik jangka pendek (maksimal satu minggu ke depan). Skenario pengujian meramalkan beban pada suatu hari dengan memakai masukan satu hari, dua hari sampai

maksimal 7 hari sebelumnya. Data yang dipakai adalah beban daya nyata (MW) yang digunakan pelanggan selama 28 hari (April 2011), berupa data beban tiap jam selama satu hari yang berasal dari total pembangkit-pembangkit di Bali. Pemakaian data dibagi menjadi dua, 14 hari pertama dipakai pelatihan (3 – 16 April 2011) dan 14 hari berikutnya dipakai untuk pengujian (17-30 April 2011). Struktur Neuron pada Jaringan Syaraf Tiruan (JST) memiliki lapisan input, lapisan tersembunyi dan lapisan output. Jumlah neuron pada lapisan input adalah $24 \times n$, dimana n bernilai 1, 2 sampai 7, yang melambangkan jumlah hari yang dipakai untuk masukan ke JST. Jumlah neuron lapisan tersembunyi akan divariasikan mulai 5, 10, 20, sampai 140 neuron untuk mendapatkan neuron optimal pada lapisan ini. Jumlah neuron pada lapisan output selalu tetap 24, melambangkan 24 data beban pada hari yang akan diramalkan. Hasil pelatihan dan pengujian JST perambatan balik didapatkan hasil optimal untuk jumlah neuron input 7×24 , jumlah neuron lapisan tersembunyi 110 dan jumlah neuron output 24. MAPE untuk pelatihan 0,0034 % dan pengujian 5,7131 %. Hasil peramalan beban listrik hari Minggu 24 April 2011 terlihat pada Tabel 1 dan Gambar 2.

Tabel 1: Peramalan Minggu 24 April 2011

Waktu (Jam)	Beban Real (MW)	Metode JST (MW)	Metode SVM (MW)	Error JST (%)	Error SVM (%)
01.00	276,1	274,32	272,64	0,64	1,25
02.00	277,6	276,58	265,82	0,37	4,24
03.00	277,7	286,73	266,45	3,25	4,05
04.00	277,5	251,38	266,92	9,41	3,81
05.00	278,6	267,98	275,32	3,81	1,18
06.00	278,5	273,82	278,66	1,68	0,06
07.00	278,1	262,20	277,08	5,72	0,37
08.00	278,4	280,40	280,82	0,72	0,87
09.00	269,2	273,82	284,51	1,72	5,69
10.00	273,5	275,15	290,63	0,60	6,26
11.00	276,3	279,17	287,4	1,04	4,02
12.00	278,5	251,48	284,79	9,70	2,26
13.00	278,8	293,73	282,66	5,73	1,75
14.00	280,6	258,63	291,08	7,83	3,73
15.00	288,8	290,71	294,74	0,66	2,06
16.00	288,9	291,21	301,36	0,80	4,31
17.00	289,1	259,54	299,99	10,23	3,77
18.00	333,0	333,8	351,17	0,24	5,46
19.00	376,8	423,89	348,72	12,50	7,56
20.00	378,1	420,49	348,79	11,21	7,75
21.00	377,8	413,81	346,17	9,53	8,37
22.00	328,3	337,94	327,68	2,94	0,19
23.00	290,7	286,82	284,37	1,34	2,18
24.00	278,6	294,18	278,85	5,59	0,09
Error Minimal				0,24	0,06
Error Maksimal				12,50	8,37
MAPE				4,47	3,39



Gambar 2. Perbandingan hasil peramalan beban listrik pada hari Minggu 24 April 2011

Hasil perbandingan MAPE peramalan JST dan SVM terlihat pada Tabel 2. MAPE peramalan metode SVM selalu lebih kecil dari JST. Hasil tersebut menunjukkan metode SVM lebih akurat dari JST.

Tabel 2: Perbandingan MAPE Metode JST dan SVM

Waktu	MAPE	
	Metode JST	Metode SVM
Minggu, 24 April 2011	4,47	3,39
Senin, 25 April 2011	4,35	3,05
Selasa, 26 April 2011	8,33	3,79
Rabu, 27 April 2011	5,54	4,88
Kamis, 28 April 2011	4,98	2,98
Jumat, 29 April 2011	5,68	3,60
Sabtu, 30 April 2011	6,63	2,99
MAPE Pengujian	5,71	3,53

4. SIMPULAN

Semakin banyak jumlah neuron pada lapisan tersembunyi dan jumlah pemakaian input akan menghasilkan peningkatan unjuk kerja. Peningkatan unjuk kerja terbaik didapatkan pada kombinasi struktur JST dengan jumlah neuron input 7×24 , 110 neuron pada lapisan tersembunyi dan 24 neuron pada lapisan output. Hasil peramalan memiliki persentase kesalahan rata-rata absolut 5,71% untuk metode JST dan 3,53% untuk metode SVM. Metode JST mempunyai rata-rata eror minimal 0,35% dan maksimal 17,34%. Metode SVM mempunyai rata-rata eror minimal 0,16% dan maksimal 10,53%. Metode SVM memiliki keakuratan lebih baik dibandingkan dengan metode JST.

5. DAFTAR PUSTAKA

- [1] Dipti, S., 1998. “ *Evolving Artificial Neural Networks for Short Term Load Forecasting*”. Neurocomputing, Volume 23, Issues 1-3, 7 December 1998, Pages 265-276
- [2] Nahi K., René Wamkeue, Maarouf Saad, Semaan Georges.2006. “*An Efficient Approach for Short Term Load Forecasting using Artificial Neural Networks*”. International Journal of Electrical Power & Energy Systems, Volume 28, Issue 8. Pages 525-530.
- [3] El-Sharkawi, M., Niebur, D., 1996. “*Short-Term Load Forecasting with Artificial Neural Networks: The International Activities*”, IEEE power engineering society: tutorial course on artificial neural networks with applications to power systems, pp. 90–103
- [4] Ran Qiwen, Shan Yongzheng, Wang Qi and et al. 2003. “*Wavelet-neural networks-PARIMA method for power system short term load forecasting*”, Proceedings of the CSEE, 23(3):38-42
- [5] Kang Chongqing, Xia Qing, Zhang Boming. 2004. *Review of Power System Load Forecasting and Development*. Automation of Electric Power Systems, 28(7): 1-11.
- [6] Kyung-Bin Song, Young-Sik Baek, Dug Hun Hong, and Gilsoo Jang.2005. “*Short-Term Load Forecasting for the Holidays Using Fuzzy Linear Regression Method*”, IEEE Transactions on Power System, Vol.20, No.1, February.
- [7] X.M. Li, D. Gong, L. Li, and C.Y. 2005. “*Next day load forecasting using SVM*”, Proc. ISNN '05, Lecture Notes in Computer Science, Springer, Berlin, pp. 634-639.
- [8] Gunn, S., 1998, *Support Vector Machines for Classification and Regression*, Tech.Rep., Dep.of Electronics and Computer Science, University of Southampton.
- [9] Janes A. Freeman and David M Skapura,1992, *Neural Network Algorithms, Application and Programming Techniques*, Addison-Wesley Publishing Company, California.
- [10] I Nyoman Setiawan dan Widyadi Setiawan, 2012, *Perbandingan Peramalan Beban Listrik Jangka Pendek Menggunakan Support Vector Machine dan Jaringan Syaraf Tiruan Perambatan Balik (Studi Kasus di Pulau Bali)*, Laporan Akhir Penelitian Bidang Ilmu Teknik Elektro, Jurusan Teknik Elektro Universitas Udayana.