

Prediksi Beban Listrik PT. PLN (Persero) Area Semarang Menggunakan Metode Support Vector Regression

Andika Putra Pratama ^{*1)}, Sukmawati Nur Endah ^{*2)}

*Departemen Ilmu Komputer/Informatika, Fakultas Sains dan Matematika, Universitas Diponegoro
¹⁾dika.blogger@gmail.com, ²⁾ sukawati020578@gmail.com

Abstrak

Tren kenaikan konsumsi listrik dan tidak stabilnya beban listrik puncak bulanan membuat PT. PLN (Persero) sebagai penyedia layanan listrik perlu melakukan perencanaan produksi yang matang agar dapat melakukan penjadwalan perawatan sistem tenaga listrik serta penyediaan cadangan bahan bakar untuk menjaga keberlangsungan produksi listrik. Perencanaan produksi listrik untuk keperluan penjadwalan perawatan sistem dan penyediaan cadangan bahan bakar dilakukan dengan melakukan prediksi beban listrik jangka menengah. Penelitian ini menyajikan hasil prediksi beban listrik menggunakan metode Support Vector Regression dengan menggunakan fitur prediktor yang terdiri dari beban listrik, daya tersambung, jumlah pelanggan listrik, dan PDRB-ADHB. Data yang digunakan berasal dari PT. PLN (Persero) Area Semarang sejumlah 75 data (Juni 2011 - Desember 2017) dan data dari BPS Kota Semarang sejumlah 7 data (2010 – 2016). Hasil penelitian menunjukkan nilai error menggunakan MAPE yang diperoleh sebesar 4,03 % untuk nilai parameter terbaik $C = 10^8$, $\varepsilon = 10^6$, dan fungsi Kernel Linear, dengan fitur prediktor terbaik adalah daya tersambung dan jumlah pelanggan listrik. Data prediksi bulan Oktober – Desember 2017 didapatkan hasil nilai error MAPE sebesar 3,0384 %.

Kata kunci : *Prediksi, Beban Listrik, Support Vector Regression.*

Abstract

The trend of the increased electricity consumption and the unstable of monthly peak load make PT. PLN (Persero) as the electricity service provider needs to conduct a production planning in order to perform the electricity power system maintenance scheduling as well as fuel reserve provision to keep the sustainability of electricity production. The electricity production plan for the purpose of system maintenance scheduling and fuel reserve provision was conducted by mid-term load forecasting. This research presented the result of load forecasting using Support Vector Regression method using predictor feature consisted of load, connected power, the number of electricity subscribers, and PDRB-ADHB. The data used were 75 data (Juni 2011 - Desember 2017) from PT. PLN (Persero) Semarang Area and 7 data (2010 – 2016) from BPS Semarang. The result of the research showed the obtained of error value using MAPE was 4,03 % for the best parameter value $C = 10^8$, $\varepsilon = 10^6$, and Kernel Linear function, with the best predictor feature was connected power, and the number of electricity subscribers. The prediction data of October – December 2017, the result of MAPE error value was 3,0384 %.

Keywords : *Prediction, Electricity Load, Support Vector Regression*

1 PENDAHULUAN

Listrik telah digunakan untuk menunjang berbagai kegiatan pada segala bidang. Penggunaan listrik meningkat seiring dengan meningkatnya ragam dan jumlah aktifitas manusia serta mesin yang membutuhkan tenaga listrik. Statistik Ketenagalistrikan Indonesia tahun 2015 menyatakan adanya tren kenaikan konsumsi listrik di Indonesia dengan rata-rata kenaikan konsumsi sebesar 5,27% per tahun pada rentang tahun 2011-2015 [1]. Selain itu, beban listrik puncak bulanan tidak selalu stabil [2]. Kedua hal ini memaksa perusahaan penyedia layanan listrik untuk dapat membuat perencanaan produksi listrik, termasuk di dalamnya penjadwalan untuk perawatan sistem dan penyediaan cadangan bahan bakar agar dapat memproduksi jumlah listrik sesuai kebutuhan.

Secara umum, perencanaan produksi listrik diawali dengan melakukan prediksi beban listrik dalam jangka waktu tertentu. Menurut Djiteng, terdapat tiga jenis prediksi beban listrik, antara lain: jangka panjang, jangka menengah, dan jangka pendek [3]. Tiap jenis prediksi beban listrik memiliki kegunaan masing-masing. Prediksi beban listrik jangka panjang diperuntukkan untuk perencanaan ekspansi kapasitas produksi listrik. Prediksi beban listrik jangka menengah diperuntukkan untuk perencanaan penjadwalan perawatan sistem dan penyediaan cadangan bahan bakar untuk produksi listrik, sedangkan prediksi beban listrik jangka pendek digunakan untuk perencanaan operasi dari sistem tenaga yang dibutuhkan terutama ketika terjadi beban puncak harian [4]. Berdasarkan penjelasan tersebut, maka perlu dilakukan kegiatan prediksi beban listrik jangka menengah dengan melakukan prediksi beban listrik sebagai penunjang proses perencanaan

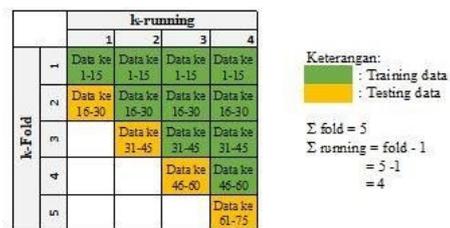
penjadwalan perawatan sistem dan penyediaan cadangan bahan bakar agar proses produksi listrik berjalan dengan lancar.

Berdasarkan penjabaran di atas, penelitian ini mengusulkan pembuatan sebuah model prediksi beban listrik jangka menengah menggunakan metode Support Vector Regression dengan parameter uji fungsi kernel, nilai C, dan nilai epsilon untuk menemukan hyperplane terbaik, serta menggunakan data time series beban listrik, jumlah pelanggan, daya tersambung, dan Produk Domestik Regional Bruto Atas Dasar Harga Berlaku (PDRB-ADHB) sebagai fitur prediktor.

2 DASAR TEORI

Dasar teori ini memaparkan tentang referensi yang digunakan, antara lain tentang prediksi beban listrik, data preprocessing, k-fold Cross Validation, Fungsi kernel, Support Vector Regression.

2.1 PREDIKSI BEBAN LISTRIK



Menurut Djiteng, prediksi beban listrik terdapat tiga jenis prediksi beban listrik, antara lain: jangka panjang, jangka menengah, dan jangka pendek [3]. Tiap jenis prediksi beban listrik memiliki kegunaan masing-masing. Prediksi beban listrik jangka panjang diperuntukkan untuk perencanaan ekspansi kapasitas produksi listrik, prediksi beban listrik jangka menengah diperuntukkan untuk perencanaan penjadwalan perawatan sistem dan

penyediaan cadangan bahan bakar untuk produksi listrik, sedangkan prediksi beban listrik jangka pendek digunakan untuk perencanaan operasi dari sistem tenaga yang dibutuhkan terutama ketika terjadi beban puncak harian [4].

2.2 DATA PREPROCESSING

Data preprocessing adalah tahapan dimana dilakukan rekayasa sebagai sebuah bentuk kompromi terhadap data mentah agar layak diolah [5].

2.3 K-FOLD CROSS VALIDATION

K-fold Cross Validation (k-fold CV) merupakan metode statistik yang digunakan untuk melakukan evaluasi dan perbandingan algoritma dalam proses training atau testing melalui pembagian data ke dalam dua segmen [6]. k-fold bekerja membagi dataset menjadi k buah himpunan bagian (subset) secara acak dengan ukuran yang sama pada tiap subset-nya.

Dalam kasus cross validation pada data time series, testing data berperan sebagai data baru yang sifatnya memiliki keterkaitan yang erat (dependen) terhadap data sebelumnya. Maka apabila data observasi dalam rentang waktu setelah data testing juga diikuti dalam proses training, akan terjadi bias pada hasil training yang dilakukan [7]. Ilustrasi k-fold Cross Validation data untuk data time series dapat dilihat pada Gambar 1.

2.4 FUNGSI KERNEL

Fungsi kernel adalah sebuah fungsi yang mampu memetakan data x dalam input space ke dalam feature space dengan dimensi yang lebih tinggi melalui ϕ , seperti berikut.

$$\phi: x \rightarrow \phi(x)$$

dimana:

$\phi: x$: input space

$\phi(x)$: feature space

Fungsi kernel mengubah data input menjadi sebuah matriks kernel yang akan digunakan dalam melakukan training, testing, dan prediksi.

2.5 SUPPORT VECTOR REGRESSION

Gambar 1 Ilustrasi k-fold Cross Validation untuk Data Time Series

Support Vector Regression (SVR) merupakan pengembangan SVM untuk kasus regresi. Tujuan dari SVR adalah untuk menemukan sebuah fungsi F sebagai suatu hyperplane (garis pemisah) berupa fungsi regresi yang mana sesuai dengan semua input data dengan sebuah error dan membuat setipis mungkin [8]. Abe (2005) menyatakan bahwa tujuan dari SVR ini adalah untuk memetakan vector input ke dalam dimensi yang lebih tinggi [9]. Fungsi pada persamaan (1) adalah garis regresi sebagai optimal hyperplane:

$$F = w\phi(x_i) + b \tag{1}$$

dimana:

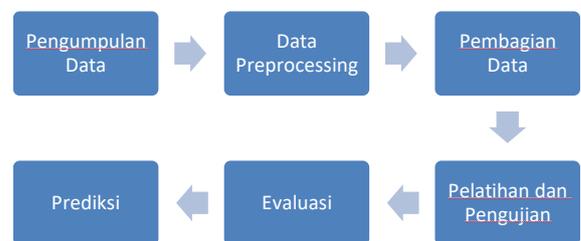
F : hyperplane

w : bobot fitur

$\phi(x_i)$: nilai fitur ke-i

b : bias

Proses pencarian nilai w dan b sebagai nilai akhir yang digunakan untuk memprediksi dapat dilihat pada flowchart pada Gambar 3.



Gambar 2 Metode Penelitian

3 METODE PENELITIAN

Metode yang dilakukan dalam penelitian ini dapat dilihat pada blok proses di Gambar 2.

Masing-masing blok proses akan di jelaskan sebagai berikut.

1). Pengumpulan Data

Data yang digunakan antara lain data yang berasal dari PT PLN (Persero) Area Semarang sejumlah 75 data dengan fitur beban listrik, daya tersambung, dan jumlah pelanggan sebanyak 75 data. Data lain yang digunakan adalah data dari BPS Kota Semarang sebanyak 7 data. Contoh dari masing-masing data dapat dilihat pada Tabel 1 dan Tabel 2.

Tabel 1 Contoh data dari PT PLN (Persero) Area Semarang

| Tahun | Bulan | BELST | DATER | PELGN |
|-------|-----------|-------------|---------------|-----------|
| 2011 | Juni | 316.120.393 | 1.754.982.265 | 1.097.647 |
| 2011 | Juli | 307.852.681 | 1.769.572.865 | 1.101.173 |
| 2011 | Agustus | 318.824.726 | 1.781.711.165 | 1.106.020 |
| 2011 | September | 293.214.451 | 1.792.557.415 | 1.112.580 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 2017 | April | 309.540.671 | 1.923.286.088 | 795.352 |
| 2017 | Mei | 319.744.164 | 1.930.464.988 | 798.363 |
| 2017 | Juni | 284.584.805 | 1.937.696.488 | 801.250 |
| 2017 | Juli | 309.502.970 | 1.945.061.438 | 804.578 |
| 2017 | Agustus | 322.378.025 | 1.957.741.988 | 808.685 |

Tabel 2 Contoh data dari BPS Kota Semarang

| Tahun | PDRBT |
|-------|-------------|
| 2010 | 80.824.100 |
| 2011 | 91.034.099 |
| 2012 | 99.755.672 |
| 2013 | 108.807.145 |
| 2014 | 122.109.871 |
| 2015 | 134.206.716 |
| 2016 | 145.993.676 |

2). Data Preprocessing

Dalam penelitian ini dilakukan dua aktifitas *data preprocessing*, yakni *feature selection* yaitu pemilihan fitur yang akan digunakan dan *data cleaning* dengan melakukan pengisian *missing value* dan *data*

normalization. Pengisian *missing value* dilakukan untuk fitur PDRB-ADHB. Dengan asumsi pencatatan PDRB dilakukan pada akhir tahun (Bulan Desember) maka dilakukan pengisian *missing value* untuk bulan selain Desember. Perhitungan yang digunakan seperti yang tercantum dalam persamaan (2).

$$PDRB[m,n] = PDRB[m-1,12] + n/12 * (PDRB[m,12] - PDRB[(m-1),12]) \quad (2)$$

dimana:

PDRB = Nilai PDRB-ADHB

[m,n] = tahun ke-m, bulan ke-n

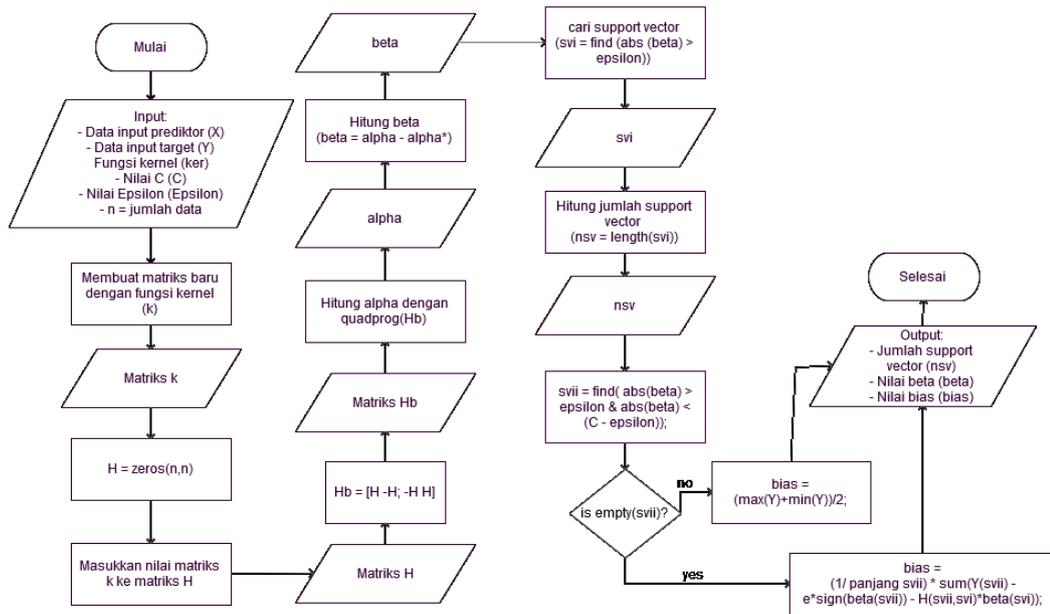
3). Pembagian Data

Pembagian data yang terdiri data latih dan data uji yang digunakan dalam penelitian ini menggunakan *k-fold cross validation*.

4). Pelatihan dan Pengujian

Proses pelatihan dan pengujian yang dilakukan menggunakan metode SVR. Flowchart proses pelatihan dapat dilihat Gambar 3. Adapun langkah-langkah yang dilakukan pada proses *training* metode SVR ini antara lain:

- a) Membuat matriks kernel dengan fungsi kernel dengan input data *training* lalu menyimpannya.
- b) Membuat matriks Hb dengan isi [H -H; -H H] dengan matriks H merupakan matriks yang sama dengan matriks k.
- c) Mencari nilai alpha dengan *quadratic programming* menggunakan Hb sebagai matriks input.
- d) Mencari nilai beta dengan rumus: $\beta = \alpha(1:n) - \alpha(n+1:2*n)$.



Gambar 3 Flowchart Proses Training SVR

- e) Mencari *support vector* dari beta yang memenuhi syarat nilai absolut beta > epsilon.
- f) Menghitung jumlah *support vector*.
- g) Menentukan *support vector* yang juga memenuhi syarat $\beta < (C - \epsilon)$.
- h) Menghitung nilai bias dengan ketentuan jika ada *support vector* yang memenuhi syarat pada langkah g. Maka: $\text{bias} = (1 / \text{length}(\text{svii})) * \sum(Y(\text{svii}) - e * \text{sign}(\beta(\text{svii})) - H(\text{svii}, \text{svi}) * \beta(\text{svi}))$. Jika tidak ada *support vector* yang memenuhi syarat pada langkah g, maka: $\text{bias} = (\max(Y) - \min(Y)) / 2$.

- c) Mencari nilai Y hasil pengujian dengan rumus $Y_{\text{test}} = H * \beta - \text{bias}$.

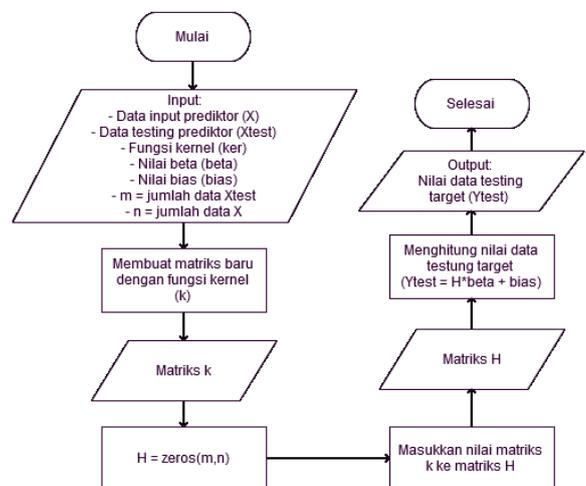
5). Evaluasi

Evaluasi dalam penelitian ini menggunakan *Mean Absolute Percent Error* (MAPE). MAPE merupakan salah satu teknik perhitungan error dengan mencari rata-rata dari jumlah selisih dari nilai prediksi dan nilai observasi. MAPE merupakan metode evaluasi yang paling sering digunakan untuk peramalan lintas bidang [10].

Hasil akhir akan diperoleh jumlah *support vector*, beta, dan bias. Proses pengujian dilakukan dengan mengikuti langkah pada *flowchart* pada Gambar 4.

Langkah-langkah yang dilakukan pada proses pengujian metode SVR ini antara lain:

- a) Membuat matriks kernel dengan fungsi kernel dengan input data uji lalu menyimpannya.
- b) Membuat matriks H dengan isi matriks kernel.



Gambar 4 Flowchart Proses Testing SVR

Rumus MAPE dapat dilihat pada persamaan (3).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (3)$$

dimana:

MAPE = Mean Absolute Percent Error

N = jumlah data

\hat{y}_i = nilai prediksi

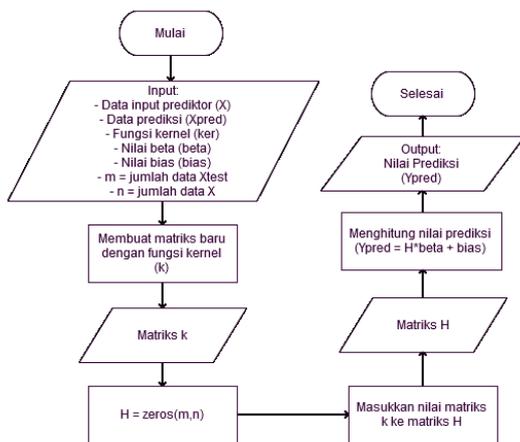
y_i = nilai observasi

6). Prediksi

Untuk melakukan prediksi dapat dilakukan dengan mengikuti langkah pada *flowchart* pada Gambar 5.

Langkah-langkah yang dilakukan pada proses prediksi sama dengan proses pengujian. Yang membedakan hanya data input yang pada pengujian adalah data uji, untuk prediksi adalah nilai input prediksi. Berikut langkah-langkah dalam prediksi:

- Membuat matriks kernel dengan fungsi kernel dengan input data input prediksi lalu menyimpannya.
- Membuat matriks H dengan isi matriks kernel.
- Mencari nilai Y hasil prediksi dengan rumus: $Y_{pred} = H * \text{beta} - \text{bias}$.



Gambar 5 Flowchart Proses Prediksi SVR

4 PEMBAHASAN

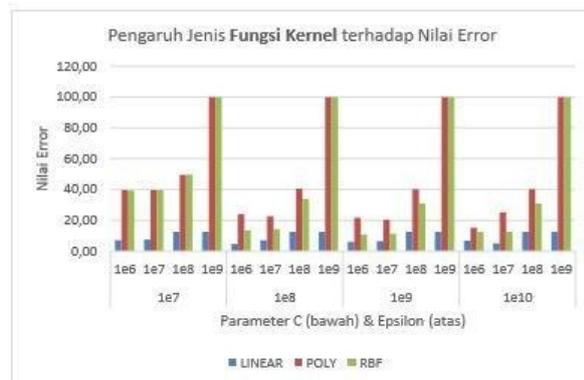
Pada bab ini akan dipaparkan mengenai skenario yang dilakukan serta hasil dan analisis skenario yang dilakukan.

4.1 SKENARIO, HASIL, DAN ANALISIS

Penelitian ini dibagi menjadi empat skenario. Pada bagian ini akan dijelaskan skenario yang dilakukan beserta hasil dan analisa masing-masing skenario.

4.1.1 SKENARIO 1

Skenario 1 dilakukan untuk mengetahui pengaruh jenis fungsi kernel terhadap nilai error menggunakan metode Support Vector Regression (SVR). Data input yang digunakan adalah seluruh fitur prediktor data dari PT. PLN (Persero) Area Semarang dan BPS Kota Semarang. Fungsi Kernel yang digunakan antara lain Kernel Linear, Kernel Polynomia, dan Kernel RBF; Nilai C yang diujikan: 10^7 , 10^8 , 10^9 , 10^{10} ; Nilai epsilon yang diujikan 10^6 , 10^7 , 10^8 , 10^9 . Hasil percobaan dapat dilihat pada grafik pada Gambar 6. Pada grafik dapat dilihat bahwa ketiga nilai kernel memiliki kesamaan dimana nilai error akan naik dan memiliki nilai sama pada nilai epsilon 10^8 dan 10^9 untuk tiap fungsi kernel.



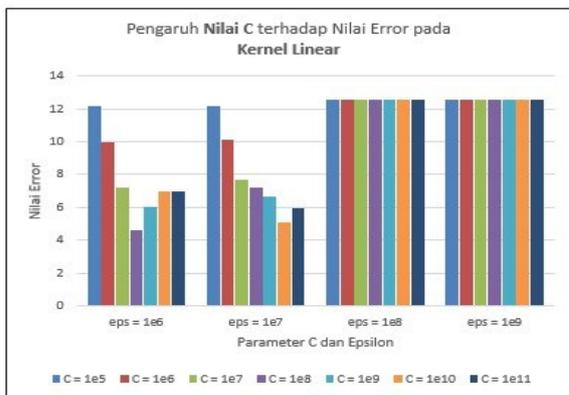
Gambar 6 Grafik Pengaruh Fungsi Kernel Terhadap Nilai Error

Hal ini disebabkan karena nilai epsilon berpengaruh pada jumlah *support vector* yang ditemukan. Semakin besar nilai epsilon, semakin sedikit jumlah *support vector* yang ditemukan, begitu pula sebaliknya. Meski demikian, dampak nilai epsilon ini memiliki imbas yang berbeda pada masing- masing fungsi kernel. Pada penelitian menunjukkan hasil bahwa fungsi Kernel Linear tidak terlalu terpengaruh oleh nilai epsilon yang besar jika dibandingkan dengan Kernel Polynomial dan Kernel RBF.

Hasil kesimpulan skenario 1, Kernel Linear memiliki performa terbaik jika dibandingkan dengan Kernel Polynomial dan Kernel RBF pada studi kasus penelitian ini.

4.1.2 SKENARIO 2

Skenario 2 untuk mengetahui pengaruh nilai C terhadap nilai error. Data input yang digunakan adalah seluruh fitur prediktor data dari PT. PLN (Persero) Area Semarang dan BPS Kota Semarang. Sedangkan untuk fungsi kernel yang digunakan adalah fungsi Kernel Linear; Nilai C yang diujikan ditambah dua nilai menjadi : 10^5 , 10^6 , 10^7 , 10^8 , 10^9 , 10^{10} untuk memperluas pengamatan; Nilai epsilon yang diujikan masih sama seperti pada skenario 1 yaitu 10^6 , 10^7 , 10^8 , 10^9 . Hasil percobaan dapat dilihat pada grafik pada Gambar 7.



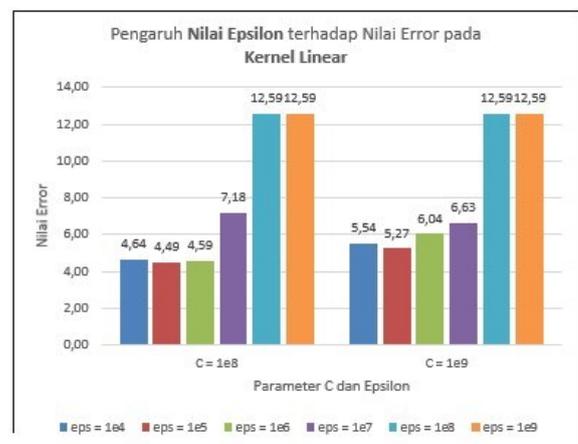
Gambar 7 Grafik Pengaruh Nilai C Terhadap Nilai Error

Berdasarkan pengamatan yang dilakukan pada nilai error, diperoleh hasil bahwa nilai C optimal diperoleh pada nilai C yang mendekati nilai input target. Dengan melihat nilai error yang sama pada nilai epsilon 10^8 dan 10^9 , dapat diketahui pula bahwa nilai epsilon juga mempengaruhi nilai C dalam menghasilkan nilai error karena nilai epsilon yang terlalu tinggi memberikan nilai error yang sama.

Berdasarkan hasil percobaan yang dilakukan, nilai C yang digunakan dalam skenario 3 adalah nilai C 10^8 dan 10^9 dengan pertimbangan kedua nilai C tersebut merupakan nilai C optimal yang dapat digunakan dari segi nilai error.

4.1.3 SKENARIO 3

Skenario 3 untuk mengetahui pengaruh nilai epsilon terhadap nilai error. Fungsi kernel dan dua nilai C dari model dengan nilai error terendah yang didapatkan pada skenario 1 dan skenario 2 digunakan dalam skenario 3 sehingga jumlah kombinasi semakin kecil. Fungsi kernel yang digunakan adalah Kernel Linear dan nilai C yang digunakan adalah 10^8 dan 10^9 . Hasil percobaan dapat dilihat pada grafik pada Gambar 8.

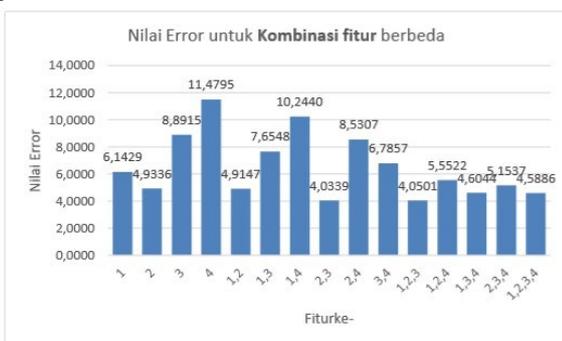


Gambar 8 Grafik Pengaruh Nilai Epsilon Terhadap Nilai Error

Grafik pada Gambar 8. menunjukkan kecenderungan semakin tinggi nilai epsilon, semakin tidak akurat suatu model. Semakin besar nilai epsilon, semakin sedikit jumlah *support vector* yang ditemukan. Dengan semakin sedikitnya jumlah *support vector* yang ditemukan, semakin tinggi nilai error yang di dapat, begitu pula sebaliknya. Pada percobaan yang dilakukan nilai error untuk nilai epsilon 10^8 dan 10^9 memiliki nilai yang sama. Dengan demikian nilai epsilon memiliki pengaruh terhadap nilai error yang didapat. Gambar 8. di atas menunjukkan bahwa nilai error terendah diperoleh pada nilai epsilon 10^5 baik untuk nilai C 10^8 maupun 10^9 dengan nilai error terendah diperoleh pada saat nilai C 10^8 . Dari hasil skenario 3 dapat disimpulkan bahwa nilai error akan mencapai titik optimal pada nilai C 10^8 dan epsilon 10^5 .

4.1.4 SKENARIO 4

Pada tiga skenario sebelumnya telah didapat tiga parameter terbaik berupa fungsi Kernel Linear, nilai C 108, dan nilai epsilon 105. Pada skenario 4 akan dilakukan percobaan untuk menentukan kombinasi fitur terbaik dengan menggunakan parameter terbaik yang telah didapatkan pada tiga skenario sebelumnya. Pengujian kombinasi fitur yang dilakukan membentuk 15 buah kombinasi dengan hasil seperti pada grafik pada Gambar 9.



Gambar 9 Grafik Perolehan Nilai Error untuk Kombinasi Fitur Berbeda

Grafik pada Gambar 9 menunjukkan nilai error untuk masing-masing kombinasi fitur. Pada grafik dapat dilihat bahwa kombinasi fitur terbaik dimiliki oleh kombinasi fitur 2 dan 3 (daya tersambung dan jumlah pelanggan).

Dari seluruh skenario yang telah dilakukan dapat disimpulkan bahwa kombinasi Kernel Linear, nilai C 108, nilai epsilon 105, dengan kombinasi fitur daya tersambung (DATER), dan jumlah pelanggan (PELGN) lebih sesuai digunakan untuk melakukan prediksi, dibuktikan dengan nilai error yang rendah.

4.2 PREDIKSI

Berdasarkan kombinasi parameter yang diperoleh dilakukan prediksi terhadap beban listrik Bulan Oktober - Desember 2017. Hasil prediksi menghasilkan nilai error untuk data prediksi Bulan Oktober – Desember 2017 sebesar 3,0384 %.

5 KESIMPULAN DAN SARAN

Kesimpulan yang dapat diambil dari penelitian mengenai Prediksi Beban Listrik PT. PLN (Persero) Menggunakan Metode *Support Vector Regression* adalah: 1) Pengaruh fungsi kernel sangat besar terhadap tingkat error. Pemilihan fungsi kernel sangat bergantung pada jenis permasalahan yang dihadapi. Penelitian ini mendapatkan hasil bahwa Kernel Linear merupakan fungsi kernel yang paling sesuai untuk studi kasus prediksi beban listrik. 2) Hasil penelitian menunjukkan bahwa secara umum nilai C memiliki pola kurva yaitu: semakin besar nilai C, maka nilai error semakin rendah sampai pada nilai C optimal, lalu akan berangsur-angsur naik untuk nilai C yang lebih besar dari nilai optimal. Nilai parameter C optimal diperoleh pada nilai dengan kisaran nilai input target pada data. 3)

Nilai Epsilon berpengaruh besar terhadap nilai error. Nilai epsilon yang menjadi tolak ukur toleransi berdampak pada jumlah support vector yang ditemukan. Semakin kecil nilai epsilon, semakin banyak support vector yang ditemukan, dan begitu pula sebaliknya. Nilai epsilon yang terlalu besar akan menghasilkan jumlah support vector yang sangat sedikit bahkan berjumlah nol. Jumlah support vector akan sangat berpengaruh dalam penentuan bobot (w) yang berpengaruh langsung terhadap hasil prediksi. 4) Kombinasi parameter terbaik untuk memprediksi beban listrik yang diperoleh dari penelitian ini adalah fungsi Kernel Linear, $C = 10^8$, $\epsilon = 10^6$, sedangkan untuk fitur terbaik yang diperoleh adalah daya tersambung dan jumlah pelanggan.

Beberapa saran yang dapat diberikan untuk penelitian selanjutnya adalah untuk memperakurat hasil prediksi, jumlah data yang digunakan dapat ditingkatkan karena data dalam penelitian ini terdiri dari 75 data. Selanjutnya, variasi fitur yang digunakan dalam penelitian ini antara lain beban listrik, daya tersambung, jumlah pelanggan, dan PDRB-ADHB. Penelitian ini dapat dikembangkan dengan mengganti atau menambah jumlah fitur terutama fitur-fitur lain terkait kelistrikan

DAFTAR PUSTAKA

- [1] "Statistik Ketenagalistrikan 2015 Kementerian Energi dan Sumber Daya Mineral, Jakarta, 2015.
- [2] Z. Hu, Y. Bao, R. Chiong dan T. Xiaong, "Mid-term Interval Load Forecasting using Multi-Output Support vector Regression with A Memetic Algorithm for Feature Selection," *Energy*, vol. 84, pp. 1-13, 2015.
- [3] M. Djiteng, *Operasi Sistem Tenaga Listrik*, Yogyakarta: Graha Ilmu, 2006.
- [4] P. Bunnoon, . K. Chalermyanont dan C. Limsakul, "Mid Term Load Forecasting of the Country Using Statistical Methodology: Case study in Thailand," *International Conference on Signal Processing Systems*, pp. 924-928, 2009.
- [5] C. C. Aggarwal, *Data Mining The Textbook*, Springer, 2015.
- [6] P. Refaeilzadeh, L. Tang dan H. Liu, "Cross Validation," Springer, 2009.
- [7] S. Arlot dan A. Celisse, "A Survey of Cross Validation Procedures for Model Selection," pp. 40-97, 2010.
- [8] B. Scholkopf dan A. J. Smola, *Learning with Kernel*, Cambridge: The MIT Press, 2001.
- [9] S. Abe, *Support Vector Machines for Pattern Classification*, 2005.
- [10] R. J. Hyndman dan A. B. Koehler, "Another Look at Measures of Forecast Accuracy," *International Journal of Forecasting*, vol. 22, pp. 678-688, 2006.
- [11] R. Achanta, "Long Term Electric Load Forecasting using Neural Networks and Support Vector Machines," *International Journal of Computer Science and Technology*, vol. III, no. 1, pp. 266-269, 2012.
- [12] R. Kohavi, "A Study of Cross Validation and Bootstrap for Accuracy Estimation and Model Selection," *International Joint Conference on Artificial Intelligence*, 1995.
- [13] S. Gunn, *Support Vector Machines for Classification and Regression*, Image Speech and Intelligent Systems Group, 1998.
- [14] B. Santosa, *Data Mining Terapan dengan MATLAB*, 1st penyunt., Yogyakarta: Graha Ilmu, 2007.