

PREDIKSI BEBAN PANAS DAN DINGIN BANGUNAN MENGGUNAKAN METODE SUPPORT VECTOR REGRESSION

Albertus Dimas Wardoyo¹⁾, Imam Cholissodin, S.Si.,M.Kom²⁾, Dian Eka Ratnawati, S.Si.,M.Kom³⁾

Program Studi Teknik Informatika
Fakultas Ilmu Komputer

Universitas Brawijaya, Malang 65145, Indonesia

email : wardoyo.bert[at]gmail.com¹⁾, imam.cs[at]ub.ac.id²⁾, dian_ilkom[at]ub.ac.id³⁾

Abstrak

Saat ini energi tidak hanya dikonsumsi oleh makhluk hidup, tetapi juga “dikonsumsi” oleh seluruh elemen di dunia ini. Beberapa elemen trinitas konsumen energi seperti sarana transportasi, pusat industri, maupun berbagai bentuk bangunan juga tidak luput dari kegiatan untuk mengkonsumsi energi. Dengan dilakukannya peramalan beban panas dan dingin bangunan, akan sangat membantu para insinyur dalam membuat bangunan yang ramah-lingkungan. Banyak metode peramalan yang telah digunakan untuk memprediksi data yang bersifat non linier seperti *Support Vector Regression* (SVR) yang terbukti dapat memberikan hasil peramalan yang baik pada beberapa kasus peramalan, seperti pada peramalan kurs nilai tukar rupiah terhadap dollar Amerika. Penelitian mengenai penggunaan metode SVR untuk peramalan pernah digunakan pada peramalan tinggi muka air dan terbukti metode tersebut menghasilkan nilai *error* yang kecil. Sesuai dengan hasil pengujian penelitian ini yang dilakukan menggunakan data desain bangunan hasil program Ecotect dengan menggunakan metode SVR menghasilkan MAPE yang bernilai 0,34492.

Kata Kunci : Beban panas dan dingin bangunan, SVR, MAPE.

Abstract

Nowadays, energy isn't only consumed by living beings, but also "consumed" by all elements in this world. Some elements of the trinity of energy consumers such as transport, industrial centers, as well as various forms of buildings are also not spared from the activities to consume energy. By doing heating and cooling load forecasting will greatly assists engineers in creating eco-friendly building. Many forecasting methods have been used to predict the data that is non-linear as Support Vector Regression (SVR) which is proven to provide better forecasting results in some forecasting cases, as in forecasting the exchange rate of the rupiah against the US dollar. Previous works about using SVR methods in forecasting water level proved that SVR method produce a small error value. The test results in this study using building design data obtained from Ecotect using SVR methods can generate MAPE 0,34492.

Keywords : Heating and Cooling Loads, SVR, MAPE

1. PENDAHULUAN

Energi tidak hanya dikonsumsi oleh makhluk hidup, tetapi juga “dikonsumsi” oleh seluruh elemen di dunia ini. Beberapa elemen seperti sarana transportasi, pusat industri, maupun berbagai bentuk bangunan juga tidak luput dari kegiatan untuk mengkonsumsi energi. Selain dapat dikatakan sebagai trinitas dalam sektor perekonomian suatu Negara, mereka juga termasuk dalam trinitas konsumen energi yang tinggi yang tentunya tidak menutup kemungkinan untuk terus dilakukannya konservasi energi (Al-Homoud, 2000). Dikarenakan bangunan (gedung, perumahan, pabrik, dst.) adalah konsumen utama dan terbesar dari ketersediaan energi global, maka perlu adanya suatu rancangan untuk dapat membuat bangunan yang hemat energi.

Dalam penelitian ini penulis menentukan objek penelitian pada satuan hitungan yakni beban pemanasan (HL/ *Heating Load*) dan beban pendinginan (CL/ *Cooling Load*), yang merupakan ukuran energi yang harus dibubuhkan atau ditiadakan dengan sebuah sistem untuk memberikan kenyamanan dalam sebuah ruang (Chou & Bui, 2014). Untuk memperkirakan kapasitas pemanasan dan pendinginan yang diperlukan, para desainer bangunan (termasuk arsitek) membutuhkan informasi berupa karakteristik bangunan dan ruangan yang dikondisikan (tingkat aktivitas dan hunian), iklim sekitar, dan kegunaan bangunan (dalam kasus ini, bangunan tempat tinggal memiliki persyaratan yang berbeda bila dibandingkan dengan bangunan industri).

Menurut penelitian yang dilakukan oleh Athanasios Tsanas dan Angeliki Xifara perhitungan beban pemanasan (HL) dan beban pendinginan (CL) diperlukan untuk menetapkan detail spesifikasi alat pemanas dan pendingin yang dibutuhkan untuk mempertahankan kenyamanan kondisi udara dalam ruangan. Dalam pelaksanaannya terdapat beberapa alat simulasi energi bangunan yang dipakai dalam memperkirakan konsumsi energi bangunan. Karena sangat boros waktu dan membutuhkan keahlian khusus dalam menggunakannya, banyak pakar mengandalkan beberapa teknik *machine learning* (pembelajaran mesin) seperti *polynomial regression*, *support vector machine*, *artificial neural network*, dan *decision trees* (Tsanas & Xifara, 2012).

Metode *Support Vector Machine* (SVM) adalah metode kecerdasan buatan yang diperkenalkan oleh Vapnik pada akhir tahun 1960. Keunggulan dari metode ini adalah mampu mengoptimasi sistem pengenalan pola dengan keahlian generalisasi yang baik. Selain itu, SVM juga berguna untuk meramalkan suatu nilai tertentu (Santosa, 2007). Metode ini juga dapat digunakan untuk menyelesaikan masalah regresi dan data nonlinier

dengan jumlah data masukan yang besar. Metode tersebut adalah *Support Vector Regression* (SVR) dengan hasil keluaran berupa data berkesinambungan.

Dalam penelitian sebelumnya yang berhasil menerapkan metode SVR, adalah penelitian yang dilakukan oleh Chou & Bui yang berjudul “*Modeling Heating and Cooling Loads by Artificial Intelligence for Energy-Efficient Building Design*”. Metode *Ensemble* (SVR + ANN) dan *Support Vector Regression* dapat digunakan dalam memprediksi CL (*Cooling Loads*) dan HL (*Heating Loads*) secara substansial. Penggunaan metode *Ensemble* untuk memprediksi CL menghasilkan nilai MAPE dibawah 4% dan merata 25,2% lebih baik daripada metode RF (Random Forest). Untuk memprediksi HL, metode SVR meningkatkan nilai RMSE sebanyak 65,9%, MAE 53,8%, dan MAPE sebanyak 48,1% bila dibandingkan dengan metode RF (Chou & Bui, 2014).

Penelitian terakhir yang juga menggunakan SVR tetapi dalam kasus yang berbeda, yakni tentang memprediksi kurs nilai tukar mata uang Rupiah terhadap Dollar Amerika dengan jumlah data *training* 344 data menghasilkan nilai akurasi 100% baik menggunakan kernel linear dan kernel polynomial dan nilai MAPE sebesar 0.3757% pada kernel linier dan 0.4477% pada kernel polynomial. Ketika diuji dengan 147 data *testing* menghasilkan nilai akurasi sebesar 99,99% bagi kedua jenis kernel yang digunakan dan nilai MAPE sebesar 0.6131% pada kernel linier dan 0.6135% pada kernel polynomial (Amanda, et al., 2014). Didasari beberapa informasi diatas, penulis berupaya mengusulkan sebuah sistem “Prediksi Beban Panas dan Dingin Bangunan menggunakan metode *Support Vector Regression*”.

2. DASAR TEORI

2.1 Beban Pendinginan dan Beban Pemanasan

Beban pendinginan merupakan jumlah energi panas yang harus dihilangkan atau dipindahkan dalam satuan waktu tertentu untuk menjaga suhu dalam rentang yang dapat diterima. Beban pemanasan merupakan jumlah energi dingin yang harus dihilangkan atau dipindahkan dalam satuan waktu tertentu untuk menjaga suhu dalam rentang yang dapat diterima. Terdapat dua parameter yang biasa dikontrol adalah *dry bulb temperature* dan *relative humidity* (Ridwan, 2010). *Dry-bulb temperature* adalah kata lain dari temperatur udara dan dapat diukur menggunakan termometer. *Wet-bulb temperature* adalah kandungan air dalam udara yang diukur menggunakan termometer yang dilapisi kain basah. Beban pendinginan bangunan didapat dari (Ridwan, 2010):

- Konduksi panas dari luar melalui atap, dinding, dan jendela.

- Radiasi sinar matahari melalui jendela.
- Konduksi panas melalui sambungan dinding, *ceiling* (langit-langit), dan lantai.
- Panas internal oleh manusia, lampu, kompor, serta alat penghasil panas lainnya.
- Udara panas dan lembab yang masuk melalui pintu, jendela, dan *ventilator* (kipas angin).

Semua beban tersebut rata-rata memberikan kontribusi *sensible* dan *latent heat*, kecuali lampu, konduksi panas dan radiasi sinar matahari yang tidak memberikan kontribusi *latent heat*. Salah satu aspek yang cukup sulit dalam perkiraan beban pendinginan adalah perkiraan waktu maksimum beban pendinginan terjadi. Tabiatnya, beban pendinginan tersebut naik turun dalam rentang jam, hari bahkan bulan dalam satu tahun. Sebagai contoh, panas yang didapatkan dari atap akan maksimal ketika tengah hari, sementara panas yang didapatkan dari dinding sebelah timur akan mencapai maksimal pada pagi hari.

2.2 Support Vector Regression

Support Vector Regression (SVR) adalah sebuah model nonlinier yang digunakan untuk menyelesaikan permasalahan regresi. Dalam kasus regresi *output* berupa bilangan riil atau kontinyu. SVR merupakan metode yang dapat mengatasi *overfitting*, sehingga akan menghasilkan performansi yang bagus (Smola & Scholkopf, 2004). SVR bertujuan untuk memetakan *vector* masukan ke dalam dimensi fitur yang lebih tinggi sehingga dapat menerima regresi linear (Abe, 2005) (Amanda, et al., 2014). Berikut merupakan langkah – langkah metode sekuensial SVR:

1. Inisialisasi $\alpha_i = 0, \alpha_i^* = 0$. Kemudian dilakukan perhitungan matriks *hessian* yang ditunjukkan pada Persamaan 1.

$$[R]_{ij} = K(x_i, x_j) + \lambda^2 \quad (1)$$

2. Untuk masing-masing data training $i, j = 1, \dots, l$, lakukan

2.1 Hitung nilai *error* menggunakan Persamaan 2.

$$E_i = y_i - \sum_{j=1}^l (\alpha_j^* - \alpha_j) R_{ij} \quad (2)$$

2.2 Hitung $\delta\alpha_i$ dan $\delta\alpha_i^*$ menggunakan Persamaan 3 dan Persamaan 4.

$$\delta\alpha_i^* = \min\{\max[\gamma(E_i - \varepsilon), -\alpha_i^*], C - \alpha_i^*\} \quad (3)$$

$$\delta\alpha_i = \min\{\max[\gamma(-E_i - \varepsilon), -\alpha_i], C - \alpha_i\} \quad (4)$$

2.3 Update nilai α_i dan α_i^* dengan Persamaan 5 dan 6.

$$\alpha_i^*(\text{baru}) = \delta\alpha_i^* + \alpha_i^*(\text{lama}) \quad (5)$$

$$\alpha_i(\text{baru}) = \delta\alpha_i + \alpha_i(\text{lama}) \quad (6)$$

3. Jika proses telah mencapai pada iterasi yang telah ditentukan, maka algoritma selesai. Jika tidak maka ulangi langkah kedua.

4. Lakukan pengujian fungsi regresi seperti yang telah dijelaskan pada Persamaan 7.

$$f(x) = \sum_{i=1}^l (\alpha_i^* - \alpha_i) (K(x_i, x) + \lambda^2) \quad (7)$$

5. Selesai.

Keterangan :

R_{ij} = merupakan matriks *kernel*.

E_i = merupakan nilai *error* ke- i .

y_i = merupakan nilai aktual data latih.

γ = merupakan *learning rate*.

$\delta\alpha_i^*$ = merupakan variabel *slack*.

$\delta\alpha_i$ = merupakan variabel *slack*.

α_i, α_i^* = merupakan suatu nilai *Lagrange Multiplier*

C = merupakan nilai kompleksitas.

ε = merupakan nilai deviasi

λ = variabel set untuk data *training*

x_i = merupakan data ke- i

x_j = merupakan data ke- j

2.3 Metode Kernel

Metode kernel adalah sebuah metode yang bisa digunakan untuk membangun sebuah fitur-fitur untuk permasalahan nonlinier yakni memetakan *input space* dan *feature space* (Zhang, 2001). Metode kernel yang digunakan dalam penelitian ini adalah:

- *Radial Basis Function* (RBF) kernel.

Perhitungan kernel RBF akan dijabarkan pada Persamaan 8.

$$K(x_i, x_j) = e^{-\|x_i - x_j\|^2 / 2\sigma^2} \quad (8)$$

Dimana σ merupakan varian gaussian kernel.

2.4 Normalisasi Data dan Denormalisasi Data

Proses *preprocessing* data yang dilakukan pada Peramalan Beban Panas dan Beban Dingin Bangunan berupa normalisasi data. Hal ini bertujuan untuk standarisasi semua data yang digunakan dalam perhitungan sehingga data berada pada jarak tertentu. Proses normalisasi yang digunakan pada penelitian ini adalah *Min-Max normalization*. Perhitungan *Min-Max normalization* ditunjukkan pada Persamaan 17 (Patro & Sahu, 2015):

$$Y = (A - B) * \frac{x - \text{Min}}{\text{Max} - \text{Min}} + B \quad (9)$$

Keterangan:

Y = Hasil normalisasi data yang nilainya berkisar antara 0 dan 1

x = Nilai data yang akan dinormalisasi
 Max = Nilai maksimum dari dataset yang digunakan
 Min = Nilai minimum dari dataset yang digunakan

Sedangkan untuk proses denormalisasi data adalah proses untuk mengembalikan nilai data menjadi nilai riil (seperti keadaan sebelum dinormalisasi) yaitu dengan mencari nilai x . Proses pencarian nilai x dapat dijabarkan melalui Persamaan 10:

$$X = \frac{Y-B}{A-B} * (Max - Min) + Min \quad ..(10)$$

2.5 Nilai Evaluasi

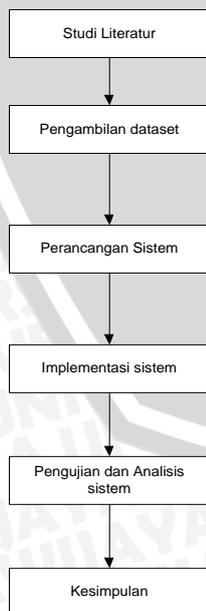
Nilai evaluasi yang digunakan adalah *Mean Absolute Percentage Error* (MAPE) karena MAPE merupakan ukuran statistik dari prediksi akurasi dan biasanya disajikan dalam bentuk persentase (Chou & Bui, 2014). Jika sistem peramalan yang dibuat menghasilkan nilai MAPE yang semakin kecil (dibawah 5%), maka sistem tersebut memiliki akurasi performansi yang baik (Furi, et al., 2015). Penjabaran rumus MAPE akan dijelaskan pada Persamaan 11 (Alwee, et al., 2013).

$$MAPE = \left(\frac{1}{n}\right) * \sum_{i=1}^n \left(\frac{|p_i - y_i|}{y_i}\right) * 100 \quad ..(11)$$

Dengan keterangan p_i adalah nilai terprediksi, y_i adalah nilai aktual, dan n adalah banyaknya *sample*.

3. METODOLOGI PENELITIAN

Tahapan penelitian ini ditunjukkan pada Gambar 1. Diagram Alir Metode Penelitian seperti berikut ini :



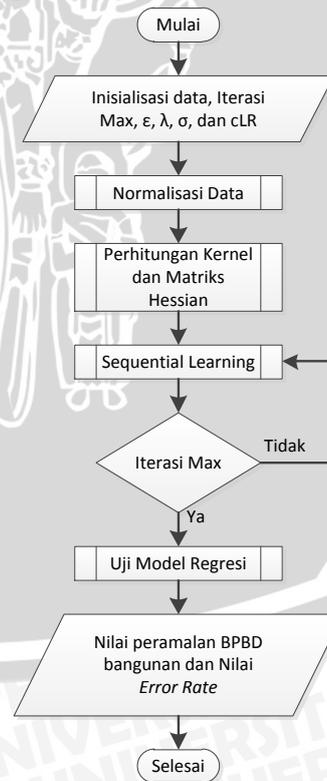
Gambar 1 Diagram Alir Tahapan Penelitian

3.1 Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data yang didapatkan melalui desain bangunan menggunakan program Ecotect. Data tersebut berisi 130 jenis bangunan dengan orientasi (tata letak menurut arah mata angin), luas permukaan, luas dinding, dan jenis material yang berbeda.

4. PERANCANGAN SISTEM

Peramalan Beban Panas dan Dingin Bangunan dilaksanakan dengan membentuk model regresi, yang kemudian diuji untuk mendapatkan nilai *error rate*. Langkah awal adalah inialisasi parameter metode SVR yang digunakan sebagai metode regresi pada penelitian ini, setelah itu melakukan normalisasi data yang digunakan. Setelah proses normalisasi, lalu melakukan proses perhitungan kernel dan perhitungan matriks *Hessian*. Selanjutnya melakukan proses *Sequential Learning* hingga sesuai dengan iterasi maksimal yang diinisialisasikan pada tahap awal. Setelah iterasi maksimum tercapai, nilai *Lagrange Multiplier* akan digunakan sebagai proses pengujian model regresi yang nantinya akan menghasilkan nilai peramalan beban panas dan dingin bangunan. Tahapan perancangan dapat dilihat dalam Diagram alir pada Gambar 2.



Gambar 2 Diagram Alir Proses Peramalan Beban Panas dan Dingin Bngunan



Langkah 1:

Inisialisasi data yang akan diolah, Iterasi maksimum, dan parameter SVR.

Langkah 2:

Normalisasi data menggunakan *min-max normalization*.

Langkah 3:

Proses perhitungan kernel dan perhitungan matriks *Hessian*.

Langkah 4:

Proses *Sequential Learning*.

Langkah 5:

Ulangi langkah 4 hingga Iterasi maksimum.

Langkah 6:

Setelah mencapai Iterasi maksimum, nilai *Lagrange Multiplier* digunakan sebagai nilai uji model regresi.

Langkah 7:

Lakukan perhitungan *error rate* setelah mendapatkan hasil peramalan BPBD (Beban Panas Beban Dingin).

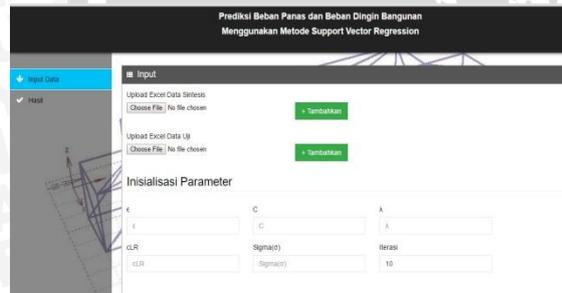
y	f(x)	E	E/(y-f)
0.0	0.8317	-4.0683	0.9768
0.1	0.8808	-4.0792	0.192
0.1552	0.1731	0.0179	0.1053
0.7069	0.7441	0.0322	0.0526
0.4852	0.485	-0.0312	0.0642
TOTAL			0.5
MAPE			0.3333

Gambar 4 Halaman *Error Rate*

5. IMPLEMENTASI

5.1 Halaman Insialisasi Data

Halaman inisialisasi Data digunakan untuk memasukkan data, nilai masukan parameter Algoritma SVR, dan batas – batas parameter yang digunakan. Halaman inisialisasi data dapat dilihat pada Gambar 3.



Gambar 3 Halaman Inisialisasi Data

5.2 Halaman *Error Rate*

Halaman *Error Rate* digunakan untuk menampilkan proses perhitungan dan hasil peramalan serta proses perhitungan dan hasil *error rate* . Halaman *error rate* dapat dilihat pada Gambar 4.

6. PENGUJIAN DAN ANALISIS

a. Pengujian Nilai Parameter cLR

Untuk pengujian pada nilai range parameter yang digunakan adalah 0.0001, 0.0003, 0.001, 0.003, 0.01, 0.03, 0.1, 0.3, dan 1.



Gambar 5 Grafik Hasil Pengujian nilai cLR

Berdasarkan grafik hasil pengujian pada Gambar 5 rerata *error rate* paling kecil didapatkan pada nilai 0.3. Parameter cLR merupakan konstanta laju pembelajaran. Jika nilai parameter ini semakin kecil, maka nilai *error rate* yang diberikan semakin kecil namun proses laju pembelajaran melambat. Jika nilai parameter ini semakin besar, maka nilai *error rate* yang diberikan semakin besar namun proses laju pembelajaran semakin cepat (Vijayakumar & Wu, 1999).

b. Pengujian Nilai Parameter λ

Untuk pengujian pada nilai range parameter yang digunakan 0.001, 0.005, 0.01, 0.05, 0.1, 0.5, 1, 5, dan 10. Berdasarkan grafik hasil pengujian pada Gambar 6 didapatkan nilai paling optimal untuk peramalan pada rentang 0.001-1. Semakin besar nilai lambda maka semakin baik nilai peramalan yang dihasilkan berdasarkan nilai *error rate* yang dihasilkan (Vijayakumar & Wu, 1999).



Gambar 6 Grafik Uji batas nilai lambda

c. Pengujian Nilai Parameter C

Untuk pengujian pada nilai range parameter yang digunakan 0.05, 0.1, 0.5, 1, 5, 10, 50, 100, dan 500. Berdasarkan grafik hasil pengujian pada Gambar 68 didapatkan nilai paling optimal untuk peramalan pada rentang 5-500. Parameter ini merupakan konstanta batas toleransi peramalan, semakin besar nilai C maka model peramalan tidak memberikan toleransi kesalahan dalam meramal. Hal ini berlaku pula sebaliknya (Furi, et al., 2015).



d. Pengujian Jumlah Iterasi

Untuk pengujian ini digunakan beberapa varian jumlah iterasi yakni 10, 50, 100, 500, 1000, 5000, 10000, 50000, dan 100000. Berdasarkan grafik hasil pengujian pada Gambar 69 didapatkan jumlah iterasi paling optimal untuk peramalan pada 100000.

7. PENUTUP

7.1 KESIMPULAN

Berikut adalah kesimpulan yang dapat diambil dari hasil yang telah didapatkan dari perancangan, implementasi dan pengujian yang telah dilakukan

1. Sebelum mengimplementasikan metode SVR untuk memprediksi beban pemanasan dan beban pendinginan bangunan, hal yang pertama dilakukan adalah menentukan susunan data yang nantinya akan dibagi menjadi 2 kelompok data yakni data latih dan data uji. Selanjutnya masing-masing kelompok data tersebut dinormalisasi menggunakan metode *min-max normalization*. Kemudian dilakukan perhitungan *kernel* dan matriks *hessian* untuk mendapatkan nilai parameter *gamma*. Selanjutnya dilakukan proses perhitungan *sequential learning* untuk mendapatkan nilai peramalan beban panas dan dingin bangunan. Terakhir, untuk mengetahui nilai evaluasi sistem prediksi beban panas dan dingin bangunan digunakanlah persamaan MAPE.
2. Dalam mengukur *error rate* dari sistem ini digunakan nilai evaluasi hasil rerata nilai kesalahan pada tiap pengujian. Berdasarkan pengujian yang telah dilakukan, nilai *error rate* terkecil didapatkan sebesar 0,34492. Nilai tersebut didapatkan menggunakan nilai parameter $cLR = 3 * 10^{-1}$, $C = 500$, $\lambda = 1$, $\epsilon = 1 * 10^{-3}$, $\sigma = 2$, Iterasi maksimal = 100000, jumlah data latih = 100 data bangunan, dan jumlah data uji = 30 data bangunan. Nilai MAPE yang dihasilkan sistem prediksi ini tergolong bagus dikarenakan besar nilainya 0,34492.

7.2 SARAN

1. Dapat ditambahkan metode selain SVR dan/atau metode optimasi untuk sistem prediksi beban panas dan dingin bangunan. Metode lain diperlukan mengingat penelitian ini masih dapat dikembangkan lebih jauh lagi.



Sedangkan metode optimasi diperlukan mengingat nilai-nilai pada parameter SVR ini rentan terjebak nilai *local optimum*, maka dengan adanya optimasi diharapkan kekurangan ini dapat ditutupi.

2. Menggunakan *set* lokasi wilayah/kota di Indonesia dalam menghitung beban panas dan dingin bangunan dalam menggunakan *dataset* yang sama dengan penelitian ini.

DAFTAR PUSTAKA

- Abe, S., 2005. *Support Vector Machine for Pattern Classification*. London: Springer-Verlag.
- Al-Homoud, M. S., 2000. *Computer-aided Building Energy Analysis Techniques*, s.l.: Elsevier.
- Alwee, R., Shamsuddin, S. M. H. & Sallehuddin, R., 2013. Hybrid Support Vector Regression and Autoregressive Integrated Moving Average Models Improved by Particle Swarm Optimization for Property Crime Rates Forecasting with Economic Indicators. Volume 2013.
- Amanda, R., Yasin, H. & Prahutama, A., 2014. *Analisis Support Vector Regression (SVR) dalam Memprediksi Kurs Rpih Terhadap Dollar Amerika Serikat*, Semarang: Perpustakaan UNDIP.
- American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997. *Ashrae Handbook Fundamentals*. I.S.ed penyunt. Atlanta: Amer Society of Heating.
- Chou, J.-S. & Bui, D.-K., 2014. *Modeling Heating and Cooling Loads by Artificial Intelligence for Energy-efficient Building Design*, s.l.: Elsevier.
- Faihah, R. T., 2010. *Makalah Data Mining Support Vector Machine (SVM)*, s.l.: Universitas Trunojoyo.
- Furi, R. P., J. & Saepudin, D., 2015. *Prediksi Financial Time Series Menggunakan Independent Component Analysis dan Support Vector Regression Studi Kasus : IHS dan JII*, Bandung: s.n.
- Kim, S. E. & Seo, I. W., 2015. *Artificial Neural Network Ensemble Modeling with Conjunctive Data Clustering for Water Quality Prediction in Rivers*, s.l.: Elsevier.
- Patro, S. K. & Sahu, K. K., 2015. *Normalization: A Preprocessing Stage*, s.l.: arxiv.
- Ridwan, M. K., 2010. Perhitungan Beban Pendinginan. Dalam: *Handout Fisika Bangunan*. Yogyakarta: Jurusan Fisika, FT-UGM, pp. 64-76.
- Santosa, B., 2007. *Data Mining Teknik Pemanfaatan data untuk keperluan bisnis*. Yogyakarta: Graha Ilmu.
- Smola, A. J. & Scholkopf, B., 2004. A Tutorial on Support Vector Regression. *Statistic and Computing*, Issue 14, pp. 199-222.
- Soebroto, A. A. et al., 2015. *Prediksi Tinggi Muka Air (TVM) untuk Deteksi Dini Bencana Banjir menggunakan SVR-TVIWPSO*, Malang: Jurnal Teknologi Informasi dan Teknik Komputer.
- Tonde, C. & Elgammal, A., 2014. *Simultaneous Twin Kernel Learning using Polynomial Transformation for Structured Prediction*, New Jersey: IEEE.
- Tsanas, A. & Xifara, A., 2012. *Accurate Quantitative Estimation of Energy Performance of Residential Building using Statistical Machine Learning Tools*, s.l.: Elsevier.
- Vijayakumar, S. & Wu, S., 1999. Sequential Support Vector Classifiers and Regression. pp. 610-619.
- Zhang, T., 2001. An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods.