

PREDIKSI BEBAN PANAS DAN BEBAN DINGIN BANGUNAN MENGUNAKAN METODE *SUPPORT VECTOR REGRESSION*

SKRIPSI

Untuk memenuhi sebagian persyaratan
memperoleh gelar Sarjana Komputer

Disusun oleh:

Albertus Dimas Wardoyo

NIM: 0910683009



**PROGRAM STUDI TEKNIK INFORMATIKA
JURUSAN TEKNIK INFORMATIKA
FAKULTAS ILMU KOMPUTER
UNIVERSITAS BRAWIJAYA
MALANG
2016**

PENGESAHAN

PREDIKSI BEBAN PANAS DAN BEBAN DINGIN BANGUNAN MENGGUNAKAN
METODE *SUPPORT VECTOR REGRESSION*

SKRIPSI

Diajukan untuk memenuhi sebagian persyaratan
memperoleh gelar Sarjana Komputer

Disusun Oleh :
Albertus Dimas Wardoyo
NIM: 0910683009

Skripsi ini telah diuji dan dinyatakan lulus pada
26 Agustus 2016

Telah diperiksa dan disetujui oleh:

Dosen Pembimbing I

Dosen Pembimbing II

Imam Cholissodin, S.Si., M.Kom
NIK. 201201 850719 1 001

Dian Eka Ratnawati, S.Si., M.Kom
NIP. 19730619 200212 2 001

Mengetahui
Ketua Jurusan Teknik Informatika

Tri Astoto Kurniawan, S.T., M.T., Ph.D
NIP. 19710518 200312 1 001

PERNYATAAN ORISINALITAS


Saya menyatakan dengan sebenar-benarnya bahwa sepanjang pengetahuan saya, di dalam naskah skripsi ini tidak terdapat karya ilmiah yang pernah diajukan oleh orang lain untuk memperoleh gelar akademik di suatu perguruan tinggi, dan tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang secara tertulis disitasi dalam naskah ini dan disebutkan dalam daftar pustaka.

Apabila ternyata didalam naskah skripsi ini dapat dibuktikan terdapat unsur-unsur plagiasi, saya bersedia skripsi ini digugurkan dan gelar akademik yang telah saya peroleh (sarjana) dibatalkan, serta diproses sesuai dengan peraturan perundang-undangan yang berlaku (UU No. 20 Tahun 2003, Pasal 25 ayat 2 dan Pasal 70).

Malang, 26 Agustus 2016

Albertus Dimas Wardoyo

NIM: 0910683009



KATA PENGANTAR

Puji syukur penulis panjatkan kehadiran Tuhan Yang Maha Esa karena hanya dengan berkat-Nya, penulis dapat menyelesaikan proposal skripsi dengan judul *“Prediksi Beban Pemanasan dan Beban Pendinginan Bangunan menggunakan metode SVR”*. Penulisan skripsi ini disusun untuk memenuhi syarat menjadi Sarjana Komputer.

Dalam pelaksanaan dan penulisan skripsi ini penulis mendapatkan banyak bantuan dari berbagai pihak baik secara moril dan materiil. Dalam kesempatan ini penulis ingin mengucapkan terimakasih sebesar - besarnya kepada:

1. Bapak Imam Cholissodin, S.Si., M.Kom, selaku pembimbing utama dan Ibu Dian Eka Ratnawati, S.Si., M.Kom, selaku pembimbing pendamping yang telah meluangkan waktu memberikan pengarahan dan bimbingan kepada penulis.
2. Bapak Arief Andy Soebroto, S.T, M.Kom, selaku dosen penasihat akademik penulis.
3. Bapak Ir. Heru Nurwarsito, M.Kom, selaku Wakil Ketua I Bidang Akademik Fakultas Ilmu Komputer.
4. Bapak Issa Arwani, S.Kom, M.Sc, selaku Sekretaris Jurusan periode 2010-2015 yang telah memberikan contoh kepada penulis untuk selalu siap dan semangat dalam melayani.
5. Bapak Agus Wahyu Widodo, S.T, M.Cs, selaku Ketua Program Studi Teknik Informatika yang selalu memberikan dukungan kepada penulis baik berupa doa maupun hal yang bersifat administratif.
6. Staff Pendidikan BKPK Fakultas Ilmu Komputer Bapak Prasetyo Iskandar, S.T dan Ibu Wiwin Lukitohadi, S.H, S.Psi, CHRM. yang selalu memberikan dorongan semangat kepada penulis melalui pertemuan rutin tiap minggu.
7. Segenap dosen Fakultas Ilmu Komputer Universitas Brawijaya atas segenap ilmu pengetahuan dan perhatian yang diberikan.
8. Segenap staff dan pegawai Program Teknologi Informasi dan Ilmu Komputer Universitas Brawijaya atas segala bantuan yang bersifat administratif.
9. Keluarga terkasih Ignatius Daman Wardoyo yang telah menjadi panutan dan inspirasi semangat bagi penulis, Petra Sri Rahayu yang selalu memberikan dukungan dan doa tiada henti, Grace Dinda Sri Wardhani yang selalu memberikan semangat bagi penulis.
10. Bapak I Made Sutatha dan Ibu Yuni Yuhniarti yang telah memberikan pandangan dunia kerja dan telah memberikan kesempatan bagi penulis untuk tinggal di Rumah Tirtasani selama masa perkuliahan penulis.
11. Seluruh teman-teman TPL-B dan TPL Legend UB '09 terkasih atas dukungan dan kebersamaannya dari awal perkuliahan sampai akhir

diantaranya Anom Harya Wicaksana yang merupakan ketua angkatan, I Putu Arie Bayu Antara, Aggy Kubelaborbir, Andreas Bagus, Zahrul Ahmad Aris, Heri Kurniawan, M. Rizki Gus Sofwan, Rizki Kurnia Aziz M., Antarangga Bhawika Manggala, Ilham Ubaidillah, Raviqul Haidir, Tony Dwiatmoko, Septa Hendra P.U., Albiyan Dwi B., dan semua teman-teman TPL Legend 09 yang tidak bisa penulis sebutkan satu-persatu.


12. Teman-teman Fakultas Ilmu Komputer angkatan 2009 terkasih yang selalu memberikan semangat, dorongan, dan bantuan pikiran.
13. Teman-teman, saudara, serta kakak tingkat yang tergabung dalam KMK (Keluarga Mahasiswa Katholik) Fakultas Teknik Universitas Brawijaya yang telah memberikan kesempatan bagi penulis untuk menimba pengalaman selama masa perkuliahan.
14. Serta semua pihak yang telah membantu dan memberikan pengalaman berharga bagi penulis selama penulis menjalani masa perkuliahan.

Akhirnya atas segala bantuan semua pihak semoga mendapat balasan yang setimpal dari Tuhan YME. Penulis sadar bahwa skripsi ini masih jauh dari kesempurnaan, untuk itu dengan segala kerendahan hati penulis mengharapkan saran dan kritik yang membangun demi kesempurnaan penulisan selanjutnya.

Malang, 26 Agustus 2016

Penulis

wardoyo.bert@gmail.com



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 mengonsumsi 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



DAFTAR ISI


PENGESAHAN	ii
PERNYATAAN ORISINALITAS	iii
KATA PENGANTAR.....	iv
ABSTRAK.....	vi
ABSTRACT	vii
DAFTAR ISI	viii
DAFTAR TABEL.....	x
DAFTAR GAMBAR.....	xii
DAFTAR KODE PROGRAM	xiii
DAFTAR LAMPIRAN	xiv
BAB 1 PENDAHULUAN.....	1
1.1 Latar belakang.....	1
1.2 Rumusan masalah	2
1.3 Tujuan	2
1.4 Manfaat.....	2
1.5 Batasan masalah	3
1.6 Sistematika pembahasan.....	3
BAB 2 LANDASAN KEPUSTAKAAN	5
2.1 Kajian Pustaka	5
2.2 Beban Pemanasan dan Beban Pendinginan Bangunan	7
2.2.1 Pengertian	7
2.2.2 Contoh Perhitungan	8
2.3 Normalisasi dan Denormalisasi.....	18
2.4 <i>Support Vector Regression</i> (SVR)	18
2.5 Kriteria Evaluasi	20
BAB 3 METODOLOGI PENELITIAN	22
3.1 Studi Literatur	23
3.2 Pengambilan <i>dataset</i>	23
3.3 Perancangan sistem.....	23
3.4 Implementasi	23

3.5 Pengujian Sistem.....	23
3.6 Pengambilan Kesimpulan.....	24
BAB 4 PERANCANGAN.....	25
4.1 Formulasi Permasalahan.....	25
4.2 Perancangan Antarmuka Pengguna	25
4.3 Algoritma <i>Support Vector Regression</i>	27
4.4 Perancangan Skenario Pengujian	37
4.4.1 Pengujian jumlah iterasi pelatihan SVR	37
4.4.2 Pengujian nilai batas parameter <i>cLR</i> SVR	38
4.4.3 Pengujian nilai batas parameter λ (<i>lambda</i>)	38
4.4.4 Pengujian nilai batas parameter <i>C</i>	39
BAB 5 IMPLEMENTASI	40
5.1 Implementasi <i>source code</i>	40
5.1.1 Proses Normalisasi Data.....	40
5.1.2 Proses Perhitungan <i>Kernel RBF</i>	41
5.1.3 Proses Perhitungan Matriks <i>Hessian</i>	41
5.1.4 Proses <i>Sequential Learning</i>	42
5.1.5 Proses Perhitungan Fungsi Peramalan dan <i>Error Rate</i>	43
5.2 Implementasi Antarmuka Pengguna	44
BAB 6 PENGUJIAN DAN ANALISIS.....	46
6.1 Hasil dan Analisis Pengujian Jumlah Iterasi Pelatihan	46
6.2 Hasil dan Analisis Pengujian Nilai Batas Parameter λ (<i>lambda</i>).....	47
6.3 Hasil dan Analisis Pengujian Nilai Batas Parameter <i>cLR</i>	48
6.4 Hasil dan Analisis Pengujian Nilai Batas Parameter <i>C</i>	49
BAB 7 PENUTUP	51
7.1 Kesimpulan.....	51
7.2 Saran	51
DAFTAR PUSTAKA.....	52
LAMPIRAN A DATA BANGUNAN	54

DAFTAR TABEL

Tabel 2.1 Perbandingan Metode Penelitian	5
Tabel 2.2 Nilai <i>dry-bulb</i> dan <i>wet-bulb temperature</i>	10
Tabel 2.3 Nilai CLTD Tembok.....	11
Tabel 2.4 Nilai CLTD <i>Sunlit Walls</i> (40° Lintang Utara, 21 Juli).....	12
Tabel 2.5 Nilai CLTD <i>Flat Roofs</i> (40° Lintang Utara, 21 Juli).....	12
Tabel 2.6 Nilai CLTD untuk Jendela	13
Tabel 2.7 Nilai SCL untuk jendela yang terkena sinar matahari maksimal (40° Lintang Utara, 21 Juli)	14
Tabel 2.8 Level Aktivitas	15
Tabel 2.9 Nilai CLF manusia.....	15
Tabel 2.10 Contoh alat rumah tangga yang dapat memberikan panas.....	16
Tabel 2.11 Estimasi Hembusan Angin, Pergantian Udara per jam	17
Tabel 2.12 Ringkasan hasil perhitungan	18
Tabel 4.1 Dataset	25
Tabel 4.2 Inisialisasi Parameter SVR	28
Tabel 4.3 Data Latih	28
Tabel 4.4 Data Uji	28
Tabel 4.5 Hasil Normalisasi Data Latih.....	29
Tabel 4.6 Hasil Normalisasi Data Uji	29
Tabel 4.7 Matriks <i>Kernel</i> Data Latih	31
Tabel 4.8 Matriks <i>Kernel</i> Data Uji.....	32
Tabel 4.9 Matriks <i>Hessian</i> Data Latih.....	32
Tabel 4.10 Matriks <i>Hessian</i> Data Uji	32
Tabel 4.11 Inisialisasi Nilai <i>Lagrange Multiplier</i>	33
Tabel 4.12 Hasil Iterasi ke-1	35
Tabel 4.13 Hasil Iterasi ke-10	35
Tabel 4.14 Hasil Denormalisasi Nilai Peramalan.....	37
Tabel 4.15 Rancangan pengujian jumlah iterasi pelatihan SVR.....	38
Tabel 4.16 Rancangan pengujian nilai batas parameter <i>cLR</i> SVR.....	38
Tabel 4.17 Rancangan pengujian nilai batas parameter λ (<i>lambda</i>).....	38

Tabel 4.18 Rancangan pengujian nilai batas parameter C	39
Tabel 6.1 Hasil pengujian jumlah iterasi pelatihan	46
Tabel 6.2 Hasil pengujian batas nilai parameter λ (<i>lambda</i>)	47
Tabel 6.3 Hasil pengujian nilai parameter cLR	49
Tabel 6.4 Hasil pengujian nilai parameter C	50




DAFTAR GAMBAR

Gambar 2.1 Denah Ruangan 101	9
Gambar 3.1. Diagram Alir Metode Penelitian.....	22
Gambar 4.1 Rancangan Antarmuka Data Masukan.....	26
Gambar 4.2 Rancangan Antarmuka Data Keluaran	26
Gambar 4.3 Diagram Alir Algoritma <i>Support Vector Regression</i>	28
Gambar 4.4 Diagram Alir Proses Perhitungan Normalisasi	29
Gambar 4.5 Diagram Alir Perhitungan <i>Kernel</i> dan Matriks <i>Hessian</i>	31
Gambar 4.6 Diagram Alir Perhitungan <i>Seqrntial Learning</i>	34
Gambar 4.7 Diagram Alir Perhitungan Nilai Peramalan	35
Gambar 4.8 Diagram Alir Denormalisasi Nilai Peramalan	36
Gambar 5.1 Antarmuka Utama <i>Input</i> Data dan Parameter.....	45
Gambar 5.2 Tampilan Hasil Perhitungan dan <i>Error Rate</i>	45
Gambar 6.1 Grafik Rerata <i>Error Rate</i> Pengujian Jumlah Iterasi.....	47
Gambar 6.2 Grafik Rerata <i>Error Rate</i> Pengujian Nilai λ	48
Gambar 6.3 Grafik Rerata <i>Error Rate</i> Pengujian Nilai <i>cLR</i>	49
Gambar 6.4 Grafik Rerata <i>Error Rate</i> Pengujian Nilai <i>C</i>	50


DAFTAR KODE PROGRAM

Kode Program 5.1 Normalisasi Data	40
Kode Program 5.2 Perhitungan <i>kernel RBF</i>	41
Kode Program 5.3 Perhitungan matriks <i>Hessian</i>	42
Kode Program 5.4 <i>Sequential Learning</i>	43
Kode Program 5.5 Perhitungan <i>Error Rate</i>	44



DAFTAR LAMPIRAN

Lampiran 1 Data Bangunan.....	54
-------------------------------	----



BAB 1 PENDAHULUAN

1.1 Latar belakang

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 dikenalkan oleh Vapnik pada 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 rerata 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 berikutnya 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 penelitian terkait SVR, penulis berupaya mengimplementasikan SVR pada sistem peramalan dengan judul "Prediksi Beban Panas dan Beban Dingin Bangunan menggunakan metode *Support Vector Regression*".

1.2 Rumusan masalah

Adapun sekelumit permasalahan yang dapat dirumuskan dari latar belakang sebagai berikut:

1. Bagaimana menerapkan algoritma *Support Vector Regression* (SVR) untuk memprediksi beban panas dan dingin dari beberapa desain bangunan?
2. Berapakah nilai evaluasi hasil implementasi algoritma *Support Vector Regression* (SVR) untuk memprediksi beban panas dan dingin dari beberapa desain bangunan?

1.3 Tujuan

Tujuan dari diadakannya penelitian ini adalah sebagai berikut:

1. Menerapkan algoritma *Support Vector Regression* (SVR) untuk memprediksi beban panas dan dingin dari beberapa desain bangunan.
2. Mengetahui nilai evaluasi dari hasil implementasi algoritma *Support Vector Regression* (SVR) untuk memprediksi beban panas dan dingin dari beberapa desain bangunan.

1.4 Manfaat

Adapun manfaat baik yang diharapkan dari penulisan skripsi ini antara lain sebagai berikut:

1. Mendapatkan wawasan tentang penerapan metode *Support Vector Regression* dalam memprediksi beban panas dan beban dingin suatu bangunan.
2. Memudahkan para insinyur dalam merancang model bangunan yang ramah lingkungan (rendah penggunaan emisi gas buang).
3. Membantu para insinyur dalam menganalisis beban pemanasan dan beban pendinginan bangunan dengan bantuan kecerdasan buatan.

1.5 Batasan masalah

Dalam penelitian ini penulis membatasi ruang lingkup penelitian sebagai berikut:

1. Data yang digunakan merupakan 130 desain bangunan hasil simulasi dari program Ecotect.
2. Detail desain yang digunakan menggunakan referensi penelitian yang dilakukan oleh Tsanas dan Xifara tahun 2012.
3. Volume tiap bangunan sama, yakni $771,75\text{m}^3$.
4. Menggunakan metode *Support Vector Regression* (SVR) untuk keseluruhan sistem dan metode *Gaussian RBF* untuk *kernel*.
5. Pengujian hanya berpusat pada pengujian metode, tidak menguji perangkat keras (*hardware*).
6. Nilai evaluasi dihitung menggunakan rumus MAPE (*Mean Absolute Percentage Error*).

1.6 Sistematika pembahasan

Pendokumentasian hasil penelitian berupa skripsi ini menganut sistematika penulisan sebagai berikut:

BAB I PENDAHULUAN

Bab ini memuat latar belakang dibuatnya sistem prediksi beban panas dan dingin bangunan menggunakan metode *support vector regression*, rumusan masalah yang ingin diselesaikan, batasan masalah agar penelitian terfokus pada masalah yang dikemukakan, tujuan penelitian, manfaat baik bagi pihak yang terkait, dan sistematika pembahasan laporan dari hasil penelitian ini.

BAB II LANDASAN KEPUSTAKAAN

Bab ini menjabarkan tentang kajian pustaka dan dasar teori yang mendasari penulisan sistem prediksi beban panas dan dingin bangunan.

BAB III METODE PENELITIAN

Bab ini membahas metode yang digunakan dalam implementasi *Support Vector Regression* pada sistem prediksi beban panas dan beban dingin bangunan.

BAB IV PERANCANGAN

Bab ini membahas tentang perancangan sistem prediksi beban panas dan beban dingin bangunan meliputi deskripsi aplikasi, perancangan antarmuka, dan perancangan pengujian.

BAB V IMPLEMENTASI

Bab ini membahas tentang implementasi dari perancangan sistem prediksi beban panas dan beban dingin bangunan. Implementasi yang dimaksud adalah bahasa pemrograman dan algoritma yang digunakan dalam penelitian ini.

BAB VI PENGUJIAN dan ANALISIS

Bab ini berisi proses, hasil pengujian, serta analisis hasil pengujian aplikasi prediksi beban panas dan beban dingin bangunan.

BAB VII PENUTUP

Bab ini berisi kesimpulan yang diperoleh dari pembuatan dan pengujian sistem prediksi beban panas dan dingin bangunan serta saran untuk pengembangan penelitian lebih lanjut.



BAB 2 LANDASAN KEPUSTAKAAN

Bab ini berisi beberapa kajian pustaka dan dasar teori yang digunakan dalam penelitian. Kajian pustaka berisi tentang beberapa penelitian yang memiliki tema yang mirip dengan penelitian ini. Dasar Teori yang akan dibahas meliputi pengertian dan contoh perhitungan beban pemanasan dan beban pendinginan bangunan, metode SVR (*Support Vector Regression*), Proses normalisasi, dan kriteria evaluasi.

2.1 Kajian Pustaka

Kajian pustaka berisi tentang penelitian-penelitian terdahulu yang memiliki kemiripan tema dan/atau metode dengan penelitian yang penulis lakukan. Ringkasan penelitian-penelitian yang dimaksud terangkum dalam Tabel 2.1 berikut ini:

Tabel 2.1 Perbandingan Metode Penelitian

No	Judul	Objek dan Input	Metode (Proses)	Hasil
1	<i>Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools</i>	Objek: Beban pemanasan dan Beban pendinginan bangunan.	<i>Random Forest, Iterative Reweighted Least Squares</i>	metode RF dinilai lebih akurat untuk memprediksi beban pendinginan dan beban pemanasan dibandingkan dengan metode IRLS.
2	<i>Modeling heating and cooling loads by artificial intelligence forenergy-efficient building design</i>	Objek: Pemakaian energi yang paling efisien berdasarkan desain bangunan.	<i>Artificial Neural Network, Support Vector Regression, Classification and Regression Tree, Chi-squared Automatic Interaction Detector, Genereal Linear Regression, Ensemble (SVR+JST)</i>	Metode <i>ensemble</i> bisa dijadikan standar prediksi untuk beban pendinginan (CL) sedangkan SVR dapat dijadikan standar untuk memprediksi

No	Judul	Objek dan Input	Metode (Proses)	Hasil
				beban pemanasan (HL).
3	Prediksi tinggi muka air (tma) untuk deteksi dini bencana banjir menggunakan svr-tviwps	Objek: Tinggi Muka Air	<i>Support Vector Regression, Time Variant Inertia Weight Particle Swarm Optimization</i>	Prediksi yang dilakukan dengan metode SVR-TVIWPSO memberikan hasil yang lebih akurat dibandingkan metode SVR biasa.
4	Analisis <i>support vector regression</i> (svr) dalam memprediksi kurs rupiah terhadap dollar amerika serikat	Objek: Nilai tukar Rupiah terhadap Dollar Amerika.	<i>Support Vector Regression</i>	Prediksi kurs jual Rupiah menggunakan fungsi <i>kernel</i> linear dan <i>polynomial</i> dalam metode SVR memberikan hasil yang tidak jauh berbeda .
5	<i>Artificial neural network ensemble modeling with conjunctive data clustering for water quality prediction in rivers</i>	Objek: Kualitas Air Sungai.	<i>Artificial Neural Network</i>	metode <i>conjunctive clustering</i> digunakan untuk membangun pelatihan data dapat menambah kinerja dari JST.

Sumber : (Tsanas & Xifara, 2012), (Chou & Bui, 2014) , (Soebroto, et al., 2015), (Amanda, et al., 2014), (Kim & Seo, 2015)

Penelitian pertama oleh Tsanas & Xifara bertemakan evaluasi energi bangunan. Menggunakan metode *Iterative Reweighted Least Squares* (IRLS) yang dibandingkan dengan metode *Random Forest* (RF), menghasilkan penilaian bahwa metode RF lebih akurat dibandingkan dengan IRLS (Tsanas & Xifara, 2012).

Terinspirasi dengan penelitian pertama, Chou & Bui melakukan penelitian dengan metode *Artificial Neural Network* (ANN), *Support Vector Regression* (SVR), *Classification and Regression Tree* (CART), *Chi-squared Automatic Interaction Detector* (CHAID), *General Linear Regression* (GLR), dan pendekatan *Ensemble* (gabungan SVR dan ANN). Hasilnya, pendekatan *ensemble* lebih cocok untuk memprediksi CL sedangkan SVR lebih cocok untuk memprediksi HL (Chou & Bui, 2014).

Penelitian ketiga tentang deteksi dini banjir dengan menganalisis data curah hujan dan serta ketinggian muka air pada permukaan sungai kota Surabaya. Metode yang digunakan adalah *Support Vector Regression* (SVR) yang dioptimasi parameternya dengan metode *Time Variant Inertia Weight Particle Swarm Optimization* (TVIWPSO). Hasil yang didapat SVR yang dioptimalisasi menggunakan TVIWPSO lebih akurat dalam memprediksi bencana banjir dibanding SVR (Soebroto, et al., 2015).

Penelitian keempat tentang peramalan kurs tukar Rupiah terhadap Dollar Amerika. Metode yang digunakan yakni *Support Vector Regression* (SVR). Hasilnya, akurasi yang diberikan terbilang bagus (Amanda, et al., 2014).

Penelitian kelima dilakukan oleh Kim dan Seo tentang prediksi kualitas air sungai. Metode yang digunakan adalah *Artificial Neural Network* (ANN) *ensemble modeling*. Hasil yang diberikan dengan metode *ANN ensemble modeling*, galat dari ketidakseimbangan kumpulan data dapat dikurangi dan kinerja dari ANN dapat ditingkatkan.

2.2 Beban Pemanasan dan Beban Pendinginan Bangunan

2.2.1 Pengertian

Beban pendinginan merupakan jumlah energi panas 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). *Relative humidity* (kelembapan relatif) adalah rasio tekanan parsial uap air dalam campuran tekanan uap jenuh air pada temperatur yang sama. *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 :

- 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.

Untuk perhitungan panas melalui dinding (*shaded wall*) menggunakan persamaan (Ridwan, 2010):

$$Q = U \times A \times \Delta T \quad (2.1)$$

Dengan U adalah (*overall heat transfer coefficient*), A adalah luas dinding dikurangi luas jendela, sedangkan ΔT adalah nilai *dry-bulb* dikurangi *wet-bulb*.

Untuk perhitungan panas melalui *sunlit* (dinding yang terkena sinar matahari) menggunakan persamaan (Ridwan, 2010):

$$Q = U \times A \times CLTD \quad (2.2)$$

Dengan CLTD (*cooling load temperature different*) digunakan untuk menghitung adanya heat transfer dari bagian luar yakni dinding, atap, dan jendela. CLTD merupakan fungsi dari kemampuan bahan dalam menyimpan panas dan merupakan pengganti ΔT dalam perhitungan konduksi.

Untuk menghitung sinar radiasi matahari yang melalui kaca menggunakan persamaan (Ridwan, 2010):


$$Q = A \times SC \times SCL \quad (2.3)$$

Dengan Q = radiasi panas yang masuk ke dalam ruangan, A = total luas kaca dalam satuan m^2 , SC = *shading coefficient*, SCL = *solar cooling load factor* dalam satuan W/m^2 . Nilai SCL didasarkan atas beberapa variabel yakni arah jendela, waktu dalam sehari, serta bulan dan garis lintang.

2.2.2 Contoh Perhitungan

Sebagai contoh perhitungan beban pemanasan dan beban pendinginan bangunan, penulis menggunakan contoh bangunan 101 dalam buku ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers,

1997). Berikut beberapa poin yang menjelaskan keadaan ruang yang akan dihitung :



Gambar 2.1 Denah Ruang 101

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997)

- Ruang yang dihitung adalah ruangan no 101.
- Arah jendela menghadap ke barat sehingga mendapatkan radiasi maksimal ketika sore hari dengan asumsi jam 4 sore.
- Lokasi berada di St.Louis Missouri memiliki luas lantai 13,7 x 18,3 m dan tinggi bangunan 3,7 m.
- Kondisi ruangan yang diinginkan adalah 25,6°C *dry-bulb* dan 50% *relative humidity*.
- Dinding yang menghadap ke barat seluas (3,7 m x 13,7m) bermaterial setebal 203,2 mm *light concrete* dengan lapisan aluminium di bagian luar setebal 88.9 mm dan 12,7 mm lapisan gipsum di bagian dalam.
- Delapan buah jendela *double pane* (6,4 mm) dipasang di bagian dinding aluminium, masing-masing jendela seluas 1.2 m x 1.5 m.
- Atap datar memiliki luas 13,7 x 18.3 m terbuat dari *concrete* 100 mm dengan lapisan isolasi dan *stell decking* setebal 90 mm.
- Ruang ditinggali dari jam 8 pagi hingga jam 5 sore oleh 18 orang yang bekerja ringan.
- Lampu *flourescent* sebesar 21.5 W/m².
- Komputer dan alat-alat yang lain sebesar 5.4 W/m² ditambah satu *coffee maker*.

- Untuk memudahkan perhitungan diasumsikan bahwa ruang 101 kecuali dinding sebelah barat dikelilingi dengan ruangan yang suhunya sama dengan ruangan 101.
- Catatan : sistem HVAC biasanya akan sangat *oversized* jika perhitungan didasarkan pada suhu paling ekstrem (pada kasus musim panas, adalah paling panas) oleh karena itu *outdoor desain temperature* didasarkan pada frekuensi paling sering.

Tabel 2.2 Nilai *dry-bulb* dan *wet-bulb temperature*

	0,40%		1,00%		2%	
	DB	WB	DB	WB	DB	WB
St. Louis,	95° F	76° F	93° F	75° F	90° F	74° F
Missouri	[36° C]	[25° C]	[34° C]	[24° C]	[32° C]	[23° C]

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997)

- Tabel 2.2 menunjukkan 3 kolom *dry-bulb* dan *wet-bulb temperature*. Angka 0.4% menunjukkan bahwa temperatur di St Louis melebihi 35°C hanya 0.4% dalam satu tahun. Demikian juga dengan kolom kedua, angka 1% artinya temperatur yang melebihi 34°C hanya 1% atau sekitar 87.6 jam dalam satu tahun, ketika *dry-bulb* 34°C maka *wet-bulb temperature* yang paling sering terjadi adalah 24°C.
- Dalam kasus ini akan menggunakan angka 35°C untuk *dry-bulb* dan 25°C untuk *wet-bulb*.

A. Panas yang melalui dinding (shaded wall)

- Menggunakan persamaan (2.1), yakni $Q = U \times A \times \Delta T$.
- Perhitungan nilai U (*overall heat transfer coefficient*) dan data-datanya didapatkan dari ASHRAE (Ridwan, 2010).
- Dinding bangunan tersebut merupakan seri dari beberapa bahan sebagai berikut:

Aluminium	$R = 0.11 \text{ m}^2 \text{ }^\circ\text{K/W}$
200 mm <i>concrete</i> ringan	$R = 0.35 \text{ m}^2 \text{ }^\circ\text{K/W}$
90 mm <i>fiberglass</i>	$R = 2.29 \text{ m}^2 \text{ }^\circ\text{K/W}$
12.7mm <i>gypsum</i>	$R = 0.08 \text{ m}^2 \text{ }^\circ\text{K/W}$

- Sebagai asumsi udara di luar ruangan bergerak dengan kecepatan 12 km/jam di waktu *summer* maka nilai $R = 0,044$ dan di bagian dalam $R = 0,12$. Berikut perhitungannya (Ridwan, 2010):

$$U = \frac{1}{R_{\text{outdoor-airfilm}} + R_{\text{siding}} + R_{\text{concrete}} + R_{\text{siding}} + R_{\text{gypsum}} + R_{\text{indoor-airfilm}}}$$

$$= \frac{1}{0,044 + 0,11 + 0,35 + 2,29 + 0,08 + 0,12} = \frac{1}{2,994} = 0,33 \text{ W/m}^2 \text{ } ^\circ\text{K}$$

- Maka perhitungan U atap adalah sebagai berikut (Ridwan, 2010):

$$U = \frac{1}{0,044 + 0,06 + 2,29 + 0,54 + 0 + 0,16}$$

$$= \frac{1}{3,09} = 0,323 \text{ W/m}^2 \text{ } ^\circ\text{K}$$

- Maka panas konduksi yang melalui dinding sebelah barat dengan asumsi sehabian tidak terkena matahari adalah total area dinding adalah luas dinding dikurangi luas jendela: $[3.7 \times 13.7 \text{m}] - [8 \times (1.2 \times 1.5) = 14.4 \text{ m}^2] = 36.3 \text{ m}^2$, maka $Q = U \times A \times \Delta T$, $Q = 0.33 \times 36.3 \times (35 - 25.6) = 113 \text{ W}$.

B. Perhitungan konduksi permukaan sunlit

- Sebagian besar dari permukaan bangunan biasanya terpapar sinar matahari. Radiasi sinar matahari sama dengan cahaya lampu yang berjalan tegak lurus dan dapat direfleksikan dari permukaan yang cerah (putih) serta dapat menembus kaca (*transparent surface*).
- Saat cahaya matahari mengenai permukaan dinding, sebagian energinya masuk dan memanasi permukaan dinding. Besarnya energi cahaya akan mencapai maksimum pada sudut datang 90 derajat.
- Dinding dan atap mampu untuk menyimpan energi, oleh karena itu mampu membuat penundaan transfer energi dari luar ke dalam.
- Sebuah faktor yakni CLTD digunakan untuk menghitung adanya perpindahan panas dari bagian luar yaitu dinding, atap dan jendela (*exterior wall*). CLTD adalah fungsi dari kemampuan bahan dalam menyimpan panas, serta pengganti ΔT di perhitungan konduksi yang menggunakan persamaan (2.2) $Q = U \times A \times CLTD$.
- Pada Tabel 2.3 ditunjukkan nilai CLTD tembok yang menghadap barat. *Cell* berwarna hijau adalah yang digunakan dalam perhitungan:

Tabel 2.3 Nilai CLTD Tembok

	Hour																							
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
CLTD [$^{\circ}\text{F}$]	35	30	25	21	17	14	11	8	7	6	6	7	8	10	12	16	22	30	37	44	48	48	45	41
CLTD [$^{\circ}\text{C}$]	19	17	14	12	9	8	6	4	4	3	3	4	4	6	7	9	12	17	21	24	27	27	25	23

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997)

- Perlu diperhatikan nilai CLTD pada Tabel 2.3 adalah nilai yang telah sesuai dengan asumsi yang diberikan sebelumnya yakni suhu ruangan 25.6°C suhu maksimum *outdoor* 35°C dan maksimum perbedaan temperatur harian 11.7°C, tanggal 21 Juli, 40 lintang utara dan permukaan dinding warna gelap.
- Dinding yang digunakan diklasifikasikan dalam dinding tipe 9, pada jam 4 sore (jam ke 17 dalam Tabel 2.4 yang ditandai warna hijau), CLTD untuk dinding yang menghadap ke barat adalah 12°C, ini artinya meskipun perbedaan suhu udara kering aktual berkisar 9.4°C, tetapi matahari yang memanasi dinding seolah-olah menambah perbedaan temperatur menjadi 12°C.
- Perlu diperhatikan bahwa nilai CLTD naik di siang hari dan turun di sore hari, karena panas yang tersimpan akhirnya tertransfer ke dalam ruangan.

Tabel 2.4 Nilai CLTD Sunlit Walls (40° Lintang Utara, 21 Juli)

	Wall Type 9																							
	Hour																							
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
N	9	8	7	6	5	4	3	2	2	2	3	4	6	6	7	8	9	11	12	12	13	13	12	11
NE	10	8	7	6	5	4	3	3	3	6	9	11	13	14	14	15	15	16	16	15	14	14	13	11
E	11	9	8	7	6	4	3	3	4	7	11	14	18	20	21	21	21	20	19	18	17	16	14	13
SE	11	9	8	7	6	4	3	3	3	5	7	11	14	17	19	20	21	20	19	19	18	16	14	13
S	12	10	8	7	6	4	3	3	2	2	2	3	6	8	11	14	16	18	19	19	18	17	15	13
SW	17	14	12	10	8	7	5	4	3	3	3	3	4	6	8	11	14	18	22	24	25	24	22	20
W	19	17	14	12	9	8	6	4	4	3	3	4	4	6	7	9	12	17	21	24	27	27	25	23
NW	16	14	12	9	8	6	5	4	3	3	3	3	4	5	6	8	10	12	16	19	21	21	20	18

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997), Chapter 28, Tabel 32

Tabel 2.5 Nilai CLTD Flat Roofs (40° Lintang Utara, 21 Juli)

Roof Type	Hour																							
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	0	-1	-2	-3	-3	-3	0	7	16	25	33	41	46	49	49	46	41	33	24	14	8	5	3	1
2	1	0	-1	-2	-3	-3	-2	2	9	18	27	34	41	46	48	47	44	39	31	22	14	8	5	3
3	7	4	3	1	0	-1	0	3	7	13	19	26	32	37	40	41	41	37	33	27	21	17	13	9
4	9	6	4	2	1	-1	-2	-2	0	4	9	16	23	30	36	41	43	43	41	37	31	25	19	13
5	12	9	7	4	3	2	1	1	3	7	12	17	23	28	33	37	38	38	36	33	28	23	19	15

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997), Chapter 28, Table 32

- Dengan menggunakan CLTD (menggantikan ΔT) maka dilakukan perhitungan konduksi melalui dinding sebelah barat dan atap. Tabel 2.5 yang ditandai warna hijau menunjukkan nilai CLTD atap tipe 2 pada jam 5 sore.
- Untuk dinding yang menghadap ke barat: $Q = 0.33 \times 36.3 \times 12 = 144$ W.
- Sedangkan untuk atap: $Q = 0.323 \times 250.7 \times 44 = 3,563$ W.

C. Penentuan *U-factor* pada jendela

- Penentuan *U-factor* pada kaca jendela juga sama dengan cara penentuan pada jendela dan atap. Jendela kaca dalam kasus ini adalah 6.4 mm dan udara bebas diantaranya. Di asumsikan jendela tetap *fix*, tidak bisa buka tutup dengan *frame* aluminium dan *thermal break* maka *U-factor* adalah 3.56 W/m²K.
- Maka besar konduksi untuk 8 buah jendela adalah $Q = 3.56 \times 14.4 \times 7 = 359 \text{ W}$.
- Nilai CLTD = 7 (sesuai tanda hijau pada Tabel 2.6), juga didapat dari daftar ASHRAE berikut:

Tabel 2.6 Nilai CLTD untuk Jendela

Hour																							
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	0	-1	-1	-1	-1	-1	0	1	2	4	5	7	7	8	8	7	6	4	3	2	2	2	1

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997), *Chapter 28, Table 34*

D. Radiasi matahari melalui kaca

- Panas terbesar yang masuk melalui kaca adalah melalui radiasi langsung jika dibandingkan melalui konduksi.
- Kaca yang *double* atau *triple* sangat efektif dalam menghambat panas konduksi tetapi tidak banyak berpengaruh dalam menahan radiasi.
- Untuk membatasi jumlah sinar matahari yang masuk maka akan lebih efektif menggunakan lapisan penyerap panas, *reflective glass*, atau *internal* dan *external shading*.
- SCL digunakan untuk menghitung rerata radiasi matahari yang masuk ke dalam ruangan, memanaskan ruangan dan melepaskan panasnya dalam bentuk *sensible heat*.
- SCL didasarkan atas beberapa variabel yaitu : arah jendela, waktu dalam sehari, bulan dan garis lintang. Empat variabel ini menentukan posisi jendela dalam hubungannya dengan sudut datang sinar matahari.
- Dua variabel yang lain yaitu interior partisi dinding dan tipe dari lantai menentukan kapasitas dan ruang untuk menyimpan panas. Dua hal ini akan menentukan *time lag* antara radiasi matahari memanasi ruangan dan perabotan dan waktu dimana panas dilepaskan oleh benda-benda tadi ke dalam ruangan.
- Yang terakhir yaitu *shading* menentukan besarnya sinar matahari yang masuk melalui kaca jendela.
- Dalam contoh perhitungan ini, nilai SCL untuk jendela bisa dilihat dalam Tabel 2.7 yang ditandai warna hijau.

**Tabel 2.7 Nilai SCL untuk jendela yang terkena sinar matahari maksimal (40°
Lintang Utara, 21 Juli)**

	Space Type A																							
	Hour																							
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
N	0	0	0	0	3	79	85	88	101	110	120	126	126	123	113	98	98	113	38	19	9	3	3	0
NE	0	0	0	0	6	268	406	422	353	236	173	151	139	126	117	101	82	57	22	9	6	3	0	0
E	0	0	0	0	6	293	495	583	576	485	334	211	167	142	123	104	82	57	22	9	6	3	0	0
SE	0	0	0	0	3	148	299	413	473	473	413	306	198	154	129	107	85	57	22	9	6	3	0	0
S	0	0	0	0	0	28	54	79	129	202	268	306	302	265	198	132	98	63	25	13	6	3	0	0
SW	0	0	0	0	0	28	54	76	95	110	123	202	318	419	476	479	419	293	110	54	25	13	6	3
W	3	0	0	0	0	28	54	76	95	110	120	126	205	359	498	589	605	491	180	85	41	19	9	6
NW	3	0	0	0	0	28	54	76	95	110	120	126	126	158	265	381	450	410	145	69	35	16	9	3

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997), Chapter 28, Table 36

- SC (*shading coefficient*) adalah angka yang digunakan untuk memberikan porsi seberapa banyak sinar matahari masuk melewati jendela luar dan kemudian masuk ke dalam ruangan.
- *Shading coefficient* jendela didapatkan dengan membandingkan reflektifitas kaca bersangkutan dengan standar jendela. Semakin kecil nilainya semakin banyak sinar matahari yang dipantulkan keluar.
- Bangunan dalam contoh perhitungan ini menggunakan jendela dua panel setebal 6.4 mm dipasang di panel alumunium dan *fixed*. Nilai SC-nya adalah 0.74.
- Maka besar radiasi solar melalui jendela dihitung menggunakan persamaan (2.3) adalah $Q = 14.4 \times 0.74 \times 605 = 6447 \text{ W}$.

Shading device

- Menggunakan *internal shading*, seperti *venetian blinds*, *curtain* atau *drape* dapat mengurangi sinar matahari yang masuk.
- Efektivitasnya tergantung pada kemampuannya untuk memantulkan kembali sinar yang masuk ke dalam ruangan.
- Dapat pula menggunakan *shading external* seperti *overhang*, *vertical fins*, atau *awning* untuk mengurangi panas yang masuk ke jendela.

E. Panas Internal

- Beban panas internal yang utama adalah manusia, lampu, alat masak, motor dll.
- Tabel 2.8 berisi tentang beberapa panas yang dibangkitkan oleh beberapa peralatan dan manusia.

Tabel 2.8 Level Aktifitas

Level of Activity	Sensible Heat Gain		Latent Heat Gain	
Moderately active work (office)	250 Btu/h	[75W]	200 Btu/h	[55W]
Standing, light work, or walking (store)	250 Btu/h	[75W]	200 Btu/h	[55W]
light bench work (factory)	275 Btu/h	[80W]	475 Btu/h	[140W]
heavy work (factory)	580 Btu/h	[170W]	870 Btu/h	[255W]
athletics (gymnasium)	710 Btu/h	[210W]	1090 Btu/h	[315W]

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997)

- Dalam perhitungan ini dikenalkan konsep CLF (*Cooling load Factor*), dimana konsepnya sama dengan CLTD untuk konduksi dan SCL untuk radiasi sinar yaitu untuk menghitung kapasitas dari ruangan dalam menyimpan panas.
- Panas *sensible* yang oleh manusia diserap dan disimpan oleh semua benda dalam ruangan. Ada waktu jeda antara benda-benda itu mendapatkan panas dan akhirnya melepaskan panas tersebut kembali sehingga mempengaruhi panas di ruangan.
- Dalam menghitung panas dari manusia, nilai dari CLF tergantung pada konstruksi dinding bagian dalam, tipe dari lantai, jumlah jam ruangan dipakai oleh manusia, dan jumlah jam sejak manusia masuk ke ruangan tersebut.

Tabel 2.9 Nilai CLF manusia

Total Hour	Hours after people enter space											
	1	2	3	4	5	6	7	8	9	10	11	12
2	0,65	0,7	0,16	0,11	0,08	0,06	0,05	0	0	0	0	0,01
4	0,65	0,8	0,81	0,85	0,24	0,17	0,13	0,1	0,1	0,1	0	0,03
6	0,65	0,8	0,81	0,85	0,89	0,91	0,29	0,2	0,2	0,1	0,1	0,07
8	0,65	0,8	0,81	0,85	0,89	0,91	0,93	1	0,3	0,2	0,2	0,13
10	0,65	0,8	0,81	0,85	0,89	0,91	0,93	1	1	1	0,3	0,24

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997)

- Dari tabel 2.9 dapat dilihat bahwa satu jam setelah orang masuk ke ruangan, ada 35% ($1 - 0.65$) dari panas *sensible* diserap oleh dinding lantai dan perabotan, dan 65 % adalah nilai aktual beban pendinginan dari manusia.
- Dengan melihat tabel ke arah kanan, dengan semakin lama orang ada dalam ruangan ternyata dinding, lantai dan perabotan tidak lagi menyerap banyak panas dan semua benda itu melepaskan panas yang didapatkan sebelumnya.

- Contohnya jika orang masuk pada jam 08 pagi dan bertahan total 8 jam, sampai dengan pukul 14 (6 jam setelah masuk), maka 91% dari panas yang dibangkitkan manusia merupakan beban pendinginan oleh ruangan hanya 9 persen yang diserap oleh permukaan (dinding lantai atap) dan perabotan.
- Catatan : Jika suhu ruangan tidak diatur pada suhu sama dalam waktu 24 jam, maka nilai CLF = 1. Rata-rata AC dimatikan di malam hari dan dinaikkan *setting* suhunya untuk mengurangi energi, oleh karena itu CLF = 1.
- Jadi nilai beban dari manusia : *Sensible heat* : 18 (orang) x 75 W x 1 = 1350 W *Latent heat* : 18 x 55 W x 1 = 990 W.

F. Panas dari lampu

- Panas lampu merupakan hal yang sangat signifikan, sebagai contoh, sebuah lampu 120 watt membangkitkan 120W, yang rata-rata sama dengan panas yang dibangkitkan oleh rata-rata seorang pekerja kantor.
- Ketika menghitung panas *flouroscent lights*, maka 20% ditambahkan untuk memperhitungkan panas dari *ballast*. Maka persamaan adalah :

$$Q = \text{watts} \times \text{ballast factor} \times \text{CLF} \quad (2.4)$$
- Perhitungan panas dari lampu = Jumlah penerangan : 21.5 W/m²
- Luas lantai : 13.7 x 18.3 = 250.7 m².
- Total energi untuk penerangan = 21.5 W/m² x 250.7 m² = 5400 W
- Nilai *Ballast factor* 1.2 (lampu *flourescent*) CLF = 1.0 karena *temperature set point* pada malam hari dinaikkan, sehingga besar nilai $Q = 5400 \times 1.2 \times 1.0 = 6480 \text{ W}$.

G. Panas dari peralatan

- ASHRAE juga memberikan beberapa pedoman panas yang dibangkitkan dari beberapa peralatan rumah tangga seperti yang tertera pada Tabel 2.10.

Tabel 2.10 Contoh alat rumah tangga yang dapat memberikan panas

Equipment	Sensible Heat Gain		Latent Heat Gain	
Coffee maker	3580 Btu/h	[1050W]	1540 Btu/h	[450W]
printer (letter quality)	1000 Btu/h	[292W]		
typewriter	230 Btu/h	[67W]		

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997)

- *Coffee maker* memberikan kontribusi panas sebesar 1050 W (*sensible*) dan 450 W (*latent*).
- Juga komputer sebanyak 5.4W/m² dengan Luas lantai 250.7 m² maka menghasilkan panas : 1354 W.

H. Beban panas karena infiltrasi

- Infiltrasi selalu terjadi dalam bangunan, maka infiltrasi AC selalu memberikan kontribusi pada beban panas *sensible* dan *latent* karena udara luar biasanya lebih panas dan lebih lembab dari pada ruangan dalam.
- Beberapa metode yang biasa digunakan untuk menghitung adalah:

A. Air Change Method

- Metode ini paling mudah tetapi pada saat yang sama juga paling tidak akurat.
- Dengan menggunakan metode ini jumlah udara infiltrasi dihitung dengan persamaan :
Infiltrasi = (volume ruang x air change rate) : 60

B. Crack Method

- Metode ini lebih kompleks dan berdasar pada rata-rata kuantitas udara masuk melalui *crack* di sekitar jendela dan pintu ketika kecepatan udara konstan.

C. Effective leakage-area method, juga mempertimbangkan kecepatan angin, *shielding*, dan *stack effect*, dan membutuhkan perhitungan yang detail.

- Dengan menggunakan metode ACH, nilai infiltrasi adalah :
Infiltrasi = $(927.6 \times 0.3) / 3600 = 0.077 \text{ m}^3/\text{s}$ Daftar ACH untuk infiltrasi bisa dilihat di Tabel 2.11.

Tabel 2.11 Estimasi Hembusan Angin, Pergantian Udara per jam

Neutral Pressure, poor construction	1
Neutral Pressure, average construction	0,6
Neutral Pressure, tight construction	0,3
Pressurized, poor construction	0,5
Pressurized, average construction	0,3
Pressurized, tight construction	0

Sumber : (American Society of Heating, Refrigerating and Air-Conditioning Engineers, 1997)

- Perhitungan *sensible heat* untuk infiltrasi : $Q_S = 1,210 \times \text{airflow} \times \Delta T$
 $Q_S = 1,210 \times 0.077 \times (35 - 25.6) = 876 \text{ W}$
- Perhitungan *latent heat* adalah sebagai berikut : $Q_L = 3,010 \times \text{airflow} \times \Delta W$ [$Q_L = 3,010 \times 0.077 \times (15 - 10) = 1,159 \text{ W}$]
- Dengan 1210 adalah *specific heat*, 3,010 adalah *latent heat factor*, ΔW adalah perbedaan antara *outdoor* dan *indoor design humidity ration*. Catatan : angka 1210 dan 3010 adalah tidak konstan tergantung pada kondisi tertentu yaitu kondisi 21°C udara kering pada permukaan laut.
- Densitas udara = 1.2 kg/m³, panas spesifik = 1,004 J/kg°K, *Latent heat of water vapor* = 2,503 kJ/kg, maka $1.2 \times 1,004 = 1,210$, Sementara $0.7 (1.2 \times 2.503 \times 1000 \text{ J/kJ}) / 1.000 \text{ g/kg} = 3010$.

Pada Tabel 2.12 ditunjukkan ringkasan hasil perhitungan beban panas pada bangunan 101:

Tabel 2.12 Ringkasan hasil perhitungan

Beban Panas	<i>Sensible</i>	<i>Latent</i>
Konduksi melalui atap	3563	
Konduksi melalui dinding luar	144	
Konduksi melalui jendela	359	
Radiasi Solar melewati kaca	6447	
Beban orang	1350	990
Lampu	6480	
Alat-alat listrik	2404	450
Infiltrasi	876	1159
Total	21623	2599

2.3 Normalisasi dan Denormalisasi

Normalisasi dilakukan untuk mendapatkan data dengan ukuran yang lebih kecil antara 0-1 yang mewakili data asli tanpa kehilangan karakteristik data itu sendiri. Adapun persamaan Normalisasi yakni:

$$Y = (A - B) * \frac{x - \text{Min}}{\text{Max} - \text{Min}} + B \quad (2.5)$$

Dengan keterangan x adalah nilai data, Min adalah nilai data minimum, Max adalah nilai data maksimum, A dan B adalah batas nilai diantara ukuran data yang ditentukan yakni A = 0,9 sedangkan B = 0,1. Jenis normalisasi diatas adalah normalisasi Min-Max yang fungsinya adalah menyediakan transformasi linear pada kisaran asli dari data (Patro & Sahu, 2015).

Denormalisasi dilakukan dengan tujuan mendapatkan data yang asli melalui cara mengembalikan ukuran data yang telah dinormalisasikan sebelumnya. Adapun persamaan denormalisasi sebagai berikut :

$$X = \frac{Y - B}{A - B} * (\text{Max} - \text{Min}) + \text{Min} \quad (2.6)$$

Dengan y adalah hasil dari normalisasi, Min adalah nilai data minimum, Max adalah nilai data Maksimum.

2.4 Support Vector Regression (SVR)

SVR merupakan penerapan *support vector machine* (SVM) untuk kasus 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 disitasi dalam Amanda, et.al., 2014, p.2). Sebuah fungsi regresi *linear* dapat dimisalkan seperti persamaan (2.7).

$$f(x) = \omega\varphi(x) + b \quad (2.7)$$

Dengan keterangan ω dan b adalah koefisien sedangkan $\varphi(x)$ adalah fungsi pemetaan nilai x pada dimensi fitur yang lebih tinggi.

Ada sebuah algoritma sekuensial hasil ciptaan Vijayakumar dan Wu yang dapat menghasilkan solusi optimal dengan iterasi lebih cepat jika dibandingkan metode konvensional. Berikut penjelasan mengenai tahapan algoritma sekuensial:

1. Inisialisasi parameter dan jumlah iterasi

Parameter yang biasanya digunakan dalam metode SVR adalah λ (*lambda*, variabel skalar), γ (*gamma*, *learning rate*), C (*balanceable parameter*), dan ε (*epsilon*, *insensitive parameter*).

2. Menghitung matriks *Hessian*

Sebelum menghitung matriks *Hessian*, inisialisasi $\alpha_i = \alpha_i^* = 0$. Lalu, hitung matriks *Hessian* dengan menggunakan persamaan (2.8).

$$[R]_{ij} = K(x_i, x_j) + \lambda^2 \quad \text{Untuk } i, j = 1, \dots, l \quad (2.8)$$

Dengan keterangan l adalah banyaknya data, λ adalah variabel skalar, dan $K(x_i, x_j)$ adalah fungsi *kernel*. Fungsi *kernel* adalah untuk memetakan data ke ruang dimensi yang lebih tinggi dengan harapan dalam ruang yang lebih tinggi, dimensi data dapat lebih terstruktur (Tonde, 2014 disitasi dalam Soebroto, A. A. et.al., 2015, p.3). Fungsi *kernel* yang digunakan adalah *kernel Gaussian* hasil implementasi *kernel Radial Basis Function* (Furi, et al., 2015) sebagaimana terumuskan dalam persamaan (2.9).

$$K(x_i, x_j) = e^{-\|x_i - x_j\|^2 / 2\sigma^2} \quad (2.9)$$

Dengan keterangan x_i dan x_j adalah nilai data, σ adalah nilai awal yang didefinisikan. Selanjutnya hasil dari matriks *Hessian*, terlebih dari data latih, adalah nilai parameter *gamma* (γ) yang akan digunakan pada langkah selanjutnya yaitu penghitungan perubahan nilai *Lagrange Multiplier*. Nilai parameter *gamma* (γ) dihitung dengan persamaan 2.10.

$$\gamma = \frac{cLR}{\max(\text{matriks } Hessian)} \quad (2.10)$$

3. Langkah *sequential learning*

Langkah ini adalah langkah menghitung nilai error E_i , perubahan nilai *lagrange multiplier* (α_i^* dan α_i), dan mendapatkan nilai *lagrange multiplier* baru dari data latih. Sebelum memulai langkah ini, inisialisasikan dulu nilai *lagrange multiplier* (α_i^* dan α_i) yakni 0. Lalu, mulai dari data ke- $i, j = 1$ hingga ke- l lakukan langkah-langkah berikut:

a. Menghitung nilai galat E_i

Nilai galat dapat dihitung dengan persamaan (2.11).

$$E_i = y_i - \sum_{j=1}^l (\alpha_j^* - \alpha_j) R_{ij} \quad (2.11)$$

Dengan keterangan E_i merupakan nilai galat ke- i , y_i merupakan nilai aktual ke- i , $\alpha_j^* - \alpha_j$ merupakan nilai *Lagrange Multiplier* yang baru, l adalah banyaknya data latih.

b. Menghitung perubahan nilai *Lagrange Multiplier*

Perubahan nilai *Lagrange Multiplier* dapat dihitung dengan persamaan (2.12) untuk nilai $\delta\alpha_i^*$ dan persamaan (2.13) untuk nilai $\delta\alpha_i$.

$$\delta\alpha_i^* = \min\{\max(\gamma(E_i - \varepsilon), -\alpha_i^*), C - \alpha_i^*\} \quad (2.12)$$

$$\delta\alpha_i = \min\{\max(\gamma(-E_i - \varepsilon), -\alpha_i), C - \alpha_i\} \quad (2.13)$$

Dengan keterangan $\delta\alpha_i^*$ dan $\delta\alpha_i$ adalah perubahan nilai dari α_i^* dan α_i , γ adalah *learning rate*, ε adalah nilai *insensitive parameter*, dan C adalah nilai kompleksitas.

c. Menghitung nilai *Lagrange multiplier* yang baru

Nilai *Lagrange Multiplier* (α_i^* dan α_i) yang baru didapatkan dari hasil penjumlahan nilai *Lagrange Multiplier* yang lama dengan nilai perubahannya ($\delta\alpha_i^*$ atau $\delta\alpha_i$). Nilai *Lagrange Multiplier* yang baru dapat dihitung dengan persamaan (2.14) dan (2.15).

$$\alpha_i^*(\text{baru}) = \delta\alpha_i^* + \alpha_i^*(\text{lama}) \quad (2.14)$$

$$\alpha_i(\text{baru}) = \delta\alpha_i + \alpha_i(\text{lama}) \quad (2.15)$$

4. Langkah perulangan (iterasi)

Langkah perulangan (mengulangi langkah no. 3) dilakukan hingga mencapai batas iterasi maksimal yang telah dinisialisasikan sebelumnya, atau hingga memenuhi syarat $\max(|\delta\alpha_i|) < \varepsilon$ dan $\max(|\delta\alpha_i^*|) < \varepsilon$.

5. Menghitung nilai peramalan

Nilai peramalan dihitung menggunakan persamaan regresi (2.16).

$$f(x) = \sum_{i=1}^n (\alpha_j^* - \alpha_j) (K(x_i, x_j) + \lambda^2) \quad (2.16)$$

Dengan keterangan $K(x_i, x_j)$ adalah fungsi *kernel*, α_j^* dan α_j adalah nilai *Lagrange Multiplier* yang baru, λ adalah variabel skalar, dan $f(x)$ adalah nilai peramalan.

2.5 Kriteria Evaluasi

Evaluasi dilakukan untuk mengukur dan menguji model peramalan yang dibuat agar mampu memberikan hasil peramalan dengan nilai kesalahan paling kecil. Perhitungan pada tahap ini menggunakan MAPE. MAPE (*Mean Absolute Percentage Error*) merupakan ukuran statistik dari prediksi akurasi dan biasanya disajikan dalam bentuk persentase (Chou & Bui, 2014). Berikut persamaan (2.17) yang dapat digunakan untuk menghitung MAPE (Alwee, et al., 2013):


$$MAPE = \left(\frac{1}{n}\right) * \sum_{i=1}^n \left(\frac{|p_i - y_i|}{y_i}\right) * 100 \quad (2.17)$$

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



BAB 3 METODOLOGI PENELITIAN

Pada bab ini akan dibahas metode yang digunakan dan langkah yang dilakukan dalam penelitian prediksi beban pemanasan dan pendinginan bangunan menggunakan metode *Support Vector Regression* (SVR). Penelitian ini dilakukan dengan mengikuti tahapan seperti yang digambarkan pada diagram alir sebagai berikut:



Gambar 3.1. Diagram Alir Metode Penelitian

Penjelasan dari langkah – langkah pada Gambar 3.1 adalah sebagai berikut:

1. Mempelajari berbagai literatur yang megandung ilmu tentang beban pemanasan dan beban pendinginan bangunan, metode *Support Vector Regression*.
2. Mempelajari *dataset* yang akan digunakan sebagai *data training* dan data uji.
3. Melakukan perancangan sistem dari hasil analisis data agar dapat diterapkan menggunakan metode *Support Vector Regression*.
4. Proses membangun perangkat lunak berdasarkan hasil analisis kebutuhan dan perancangan sistem.
5. Proses pengujian dan analisis sistem pada metode untuk memastikan metode dapat berjalan sesuai tujuan penelitian.
6. Pengambilan kesimpulan berdasarkan hasil yang didapat dari hasil analisis sistem.

3.1 Studi Literatur

Dibutuhkan studi literatur yang berisi dasar teori untuk menunjang penulisan laporan skripsi. Media seperti jurnal, buku, bahkan penelitian sebelumnya dapat menjadi sumber yang dapat digunakan untuk studi literatur. Berikut beberapa hal yang dapat digunakan untuk menopang penelitian ini:

1. Jurnal internasional sebagai studi kasus untuk menunjang kelayakan publikasi.
2. Pemahaman tentang *energy performance buildings*.
3. Perhitungan beban pemanasan dan beban pendinginan bangunan.
4. Metode *Support Vector Regression* (SVR).
5. Pemrograman menggunakan bahasa *PHP*.
6. Proses pengujian sistem.

3.2 Pengambilan *dataset*

Pada tahapan ini, *dataset* yang digunakan berupa *data dummy* yang ada pada penelitian sebelumnya yang berjudul "*Accurate Quantitative Estimation of Energy Performance of Residential Buildings using Statistical Machine Learning Tools*" (Tsanas & Xifara, 2012). Akan tetapi dibatasi dengan 3 parameter *input*, yakni *relative compactness*, *surface area*, *wall area*.

3.3 Perancangan sistem

Perancangan merupakan tahapan yang dilakukan sebelum menuliskan *source code* ke dalam bahasa pemrograman yang digunakan. Pada tahap perancangan penulis melakukan perhitungan manual untuk *sample data*, merancang antarmuka pengguna, dan membuat diagram alir langkah penyelesaian masalah.

3.4 Implementasi

Implementasi diterapkan sesuai perancangan yang telah disusun dalam tahap perancangan. Implementasi perangkat lunak dengan menggunakan bahasa pemrograman *PHP* dan alat pendukung lainnya. Berikut implementasi aplikasi yang dimaksud:

- Membuat antarmuka pengguna.
- Mengimplementasi algoritma / perhitungan SVR (*Support Vector Regression*).
- Implementasi akan menghasilkan nilai *Mean Absolute Percentage Error*.

3.5 Pengujian Sistem


Pengujian dalam penelitian ini dimaksudkan untuk menguji agar aplikasi yang telah dibuat mampu bekerja sesuai dengan yang diharapkan. Pengujian yang dilakukan melalui langkah – langkah sebagai berikut:

1. Pengujian untuk mengetahui apakah perangkat lunak yang dibuat dapat bekerja dengan baik tanpa galat.

2. Pengujian terhadap jumlah kesesuaian hasil keluaran aplikasi perangkat lunak dibandingkan dengan hasil pada dataset, bertujuan untuk menghitung tingkat akurasi.
3. Menghitung kesesuaian data hasil keluaran perangkat lunak untuk dibanding dataset guna mencari tingkat akurasinya.

3.6 Pengambilan Kesimpulan

Pengambilan kesimpulan dan saran untuk pengembangan penelitian selanjutnya dilakukan setelah perancangan, implementasi dan pengujian pada sistem selesai dilaksanakan. Kesimpulan diambil dari hasil pengujian sistem dan analisis. Saran diambil dengan tujuan memperbaiki dan menyempurnakan penelitian selanjutnya yang lebih baik.



BAB 4 PERANCANGAN

Pada bab ini akan dibahas mengenai perancangan aplikasi sebagai langkah implementasi metode yang digunakan. Selain itu, juga terdapat rancangan-rancangan *flowchart* yang merupakan implementasi dari algoritma yang telah ditetapkan.

4.1 Formulasi Permasalahan

Permasalahan yang akan diselesaikan dalam penelitian ini adalah peramalan beban panas dan dingin bangunan dengan data masukan dari pengguna. Data tersebut diolah menggunakan algoritma *Support Vector Regression*, kemudian hasilnya berupa data beban panas dan dingin yang diramalkan dan rerata galat. Dua hasil tersebut akan digunakan untuk mendapatkan nilai evaluasi menggunakan persamaan *Mean Absolute Percentage Error*(MAPE).

Sampel data yang digunakan berjumlah 130 data bangunan sebagaimana ditunjukkan pada Tabel 4.1 berikut: (data yang lengkap terdapat dalam Lampiran)

Tabel 4.1 Dataset

RC	SA	WA	HL	CL
0,9	750	400	35	40
0,65	560	300	7	11
0,76	600	315	8	13
0,85	700	375	28	33
0,8	650	350	14	25
0,91	779	336	22	16
0,69	523	304	32	31
0,64	618	383	22	32
0,91	522	335	26	42
0,78	757	312	13	13
0,71	783	337	31	38
0,97	766	259	13	39
0,7	757	318	12	31

Dengan RC adalah nilai *Relative Compactness*, SA adalah *Surface Area*, WA adalah *Wall Area*, HL adalah *Heating Load*, dan CL adalah *Cooling Load*.

4.2 Perancangan Antarmuka Pengguna

Antarmuka sistem yang dibuat terdiri dari 2 halaman yakni halaman masukan dan halaman hasil perhitungan. Halaman masukan mengizinkan pengguna mengunggah data bangunan dan memasukkan nilai-nilai parameter SVR akan digunakan. Pada Gambar 4.1 ditunjukkan rancangan antarmuka data masukan sistem ini.

**PREDIKSI BEBAN PANAS DAN DINGIN BANGUNAN
MENGUNAKAN METODE SUPPORT VECTOR REGRESSION (SVR)**

Upload Excel

1 Choose File

Nama File

2 +Tambahkan

Inisialisasi Parameter

ϵ

3

C

3

λ

3

cLR

3

Gamma (Y)

3

Jumlah Iterasi

3

Gambar 4.1 Rancangan Antarmuka Data Masukan

Keterangan:

1. Tombol pengunggah *file* dataset.
2. Tombol penambah setelah *file* dataset diunggah.
3. *Field* untuk memasukkan parameter SVR.

Halaman hasil perhitungan memiliki 2 menu yakni menu hasil dan menu perhitungan. Menu hasil menampilkan tabel *error rate* dan tabel denormalisasi, sedangkan menu perhitungan menampilkan tabel hasil perhitungan *sequential learning*. Gambar 4.2 menunjukkan rancangan antarmuka halaman hasil:

**PREDIKSI BEBAN PANAS DAN DINGIN BANGUNAN
MENGUNAKAN METODE SUPPORT VECTOR REGRESSION (SVR)**

1

Perhitungan

3

Hasil

Hasil

2

Error Rate

4

Denormalisasi

5


Gambar 4.2 Rancangan Antarmuka Data Keluaran

Keterangan:

1. Tombol untuk melihat halaman hasil yang berfokus pada tabel perhitungan *sequential learning*.
2. Tabel hasil perhitungan *sequential learning*.
3. Tombol melihat halaman hasil yang berfokus pada tabel *error rate* dan denormalisasi.
4. Tabel hasil perhitungan *error rate*.
5. Tabel hasil perhitungan denormalisasi.

4.3 Algoritma Support Vector Regression

Algoritma *Support Vector Regression* (SVR) adalah proses penyelesaian kasus menggunakan metode SVR. Kasus yang akan diselesaikan adalah prediksi beban panas dan beban dingin bangunan. Proses prediksi dimulai dengan membentuk model regresi, yang kemudian diuji untuk mendapatkan nilai *error*. Nilai galat atau *error* ini merupakan petunjuk tingkat akurasi dari model regresi yang telah terbentuk. Parameter yang digunakan dalam penelitian ini yaitu kompleksitas (C), epsilon (ϵ), *constant learning rate* (cLR), lambda (λ), dan sigma (σ) untuk *Kernel Gaussian RBF*. Gambar 4.3 menunjukkan diagram alir peramalan beban panas dan dingin bangunan secara garis besar:



Gambar 4.3 Diagram Alir Algoritma *Support Vector Regression*

1. Proses Inisialisasi Parameter

Dari diagram alir pada Gambar 4.3 disebutkan bahwa langkah pertama adalah inisialisasi parameter dan data. Nilai parameter tersebut ditentukan secara eksplisit. Sedangkan inisialisasi data adalah proses memasukkan nilai data yang akan diolah. Pada Tabel 4.2 ditunjukkan inisialisasi parameter yang digunakan dalam perhitungan manual.

Tabel 4.2 Inisialisasi Parameter SVR

ϵ	C	λ	cLR	Gamma (γ)	Sigma(σ)
0,001	10	0,1	0,32	0,316831683	2,0

2. Proses Pemilihan Fitur

Pada penelitian ini digunakan 10 data sekuensial dari urutan yang ada dalam dataset. Sepuluh data tersebut dibagi menjadi 2 kelompok data, data latih dan data uji. Pada Tabel 4.3 dan Tabel 4.4 ditunjukkan 2 kelompok data yang dimaksud.

Tabel 4.3 Data Latih


No	relative compactness	surface area	wall area	heating load	cooling load
1	0.9	750	400	35	40
2	0.65	560	300	7	11
3	0.76	600	315	8	13
4	0.85	700	375	28	33
5	0.8	650	350	14	25

Tabel 4.4 Data Uji

No	relative compactness	surface area	wall area	heating load	cooling load
1	0.91	779	336	22	16
2	0.69	523	304	32	31
3	0.64	618	383	22	32
4	0.91	522	335	26	42
5	0.78	757	312	13	13

3. Normalisasi Data

Data latih dan data uji yang telah didapat selanjutnya dinormalisasikan menggunakan metode *Min-Max*. Pada Gambar 4.4 ditunjukkan diagram alir proses normalisasi.



Gambar 4.4 Diagram Alir Proses Perhitungan Normalisasi

Dalam proses normalisasi, langkah pertama adalah mencari nilai minimum dan maksimum data. Berikut adalah contoh perhitungannya menggunakan persamaan (2.5):

$$x_1 = 0.8 * \left(\frac{x_1 - Min}{Max - Min} \right) + 0.1 = 0.8 * \left(\frac{40 - 11}{40 - 11} \right) + 0.1 = 0.9$$

Pada Tabel 4.5 dan Tabel 4.6 ditunjukkan hasil lengkap hasil normalisasi.

Tabel 4.5 Hasil Normalisasi Data Latih


No	relative compactness	surface area	wall area	heating load	cooling load
1	0.9	0.9	0.9	0.9	0.9
2	0.1	0.1	0.1	0.1	0.1
3	0.452	0.268421053	0.22	0.128571429	0.155172414
4	0.74	0.689473684	0.7	0.7	0.706896552
5	0.58	0.478947368	0.5	0.3	0.486206897


Tabel 4.6 Hasil Normalisasi Data Uji

No	relative compactness	surface area	wall area	heating load	cooling load
1	0.9	0.9	0.424050633	0.478947368	0.182758621
2	0.248148148	0.10311284	0.1	0.9	0.596551724
3	0.1	0.398832685	0.9	0.478947368	0.624137931
4	0.9	0.1	0.413924051	0.647368421	0.9
5	0.514814815	0.83151751	0.181012658	0.1	0.1

4. Proses Perhitungan *Kernel* dan Matriks *Hessian*

Setelah mendapatkan nilai hasil normalisasi, maka dilakukan perhitungan *Kernel* dan Matriks *Hessian*. *Kernel* yang digunakan adalah *kernel* RBF. Pada Gambar 4.5 ditunjukkan diagram alir kedua proses perhitungan tersebut:





Gambar 4.5 Diagram Alir Perhitungan *Kernel* dan Matriks *Hessian*

Sebelum melakukan perhitungan *kernel*, perlu dilakukan perhitungan jarak data tiap elemen pada matriks tabel hasil normalisasi *min-max*. Berikut perhitungan manual jarak data latih ke -1 dan data latih ke -2 yang pertama kali dilakukan sebelum menghitung matriks *Hessian* menggunakan persamaan (2.9):

$$\|x_1 - x_2\|^2 = (0,9 - 0,1)^2 + (0,9 - 0,1)^2 + (0,9 - 0,1)^2 = 1,92$$

Setelah mendapatkan nilai jarak data, selanjutnya dilakukan perhitungan nilai *kernel* menggunakan persamaan (2.9):

$$K(x_i, x_j) = e^{-\|x_i - x_j\|^2 / 2\sigma^2} = e^{-(1,92) / 2(2)^2} = 0,021493601$$

Tabel 4.7 merupakan hasil perhitungan jarak data latih, sedangkan Tabel 4.8 merupakan hasil perhitungan jarak data uji:

Tabel 4.7 Matriks *Kernel* Data Latih

k	x1	x2	x3	x4	x5
x1	1	0.021493601	0.119553425	0.802645077	0.415044043
x2	0.021493601	1	0.716527034	0.107082207	0.343694459
x3	0.119553425	0.716527034	1	0.374839016	0.757137307
x4	0.802645077	0.107082207	0.374839016	1	0.802645077
x5	0.415044043	0.343694459	0.757137307	0.802645077	1

Tabel 4.8 Matriks Kernel Data Uji

k	x1	x2	x3	x4	x5
x1	1	0.021493601	0.875222807	0.724214149	0.500403172
x2	0.078123449	0.999941863	0.716527034	0.802645077	0.954226744
x3	0.021493601	0.585197524	0.119553425	0.724214149	0.926003407
x4	1	1	0.88651709	0.97409437	0.415044043
x5	0.410571264	0.040328083	0.847733671	0.107082207	0.343694459

Setelah mendapatkan nilai *kernel*, selanjutnya dilakukan perhitungan Matriks *Hessian* menggunakan persamaan (2.8) seperti berikut:

$$[R]_{ij} = K(x_i, x_j) + \lambda^2 = 0,021493601 + (0,1)^2 = 0,031493601$$

Pada Tabel 4.9 dan Tabel 4.10 ditunjukkan hasil perhitungan matriks *Hessian* data latih dan data uji:

Tabel 4.9 Matriks Hessian Data Latih

k	x1	x2	x3	x4	x5
x1	1.01	0.031493601	0.129553425	0.812645077	0.425044043
x2	0.031493601	1.01	0.726527034	0.117082207	0.353694459
x3	0.129553425	0.726527034	1.01	0.384839016	0.767137307
x4	0.812645077	0.117082207	0.384839016	1.01	0.812645077
x5	0.425044043	0.353694459	0.767137307	0.812645077	1.01

Tabel 4.10 Matriks Hessian Data Uji

k	x1	x2	x3	x4	x5
x1	1.01	0.031493601	0.885222807	0.734214149	0.510403172
x2	0.088123449	1.009941863	0.726527034	0.812645077	0.964226744
x3	0.031493601	0.595197524	0.129553425	0.734214149	0.936003407
x4	1.01	1.01	0.89651709	0.98409437	0.425044043
x5	0.420571264	0.050328083	0.857733671	0.117082207	0.353694459

Setelah mendapatkan nilai matriks *Hessian*, selanjutnya dilakukan perhitungan besar nilai parameter gamma (γ) untuk data latih menggunakan persamaan (2.10).

$$\gamma = \frac{cLR}{\max(\text{matriks Hessian})} = \frac{0,32}{1,01} = 0,316832$$


5. Proses perhitungan *Sequential Learning*


Tahapan ini dimulai dengan menginisialisasi nilai *Lagrange Multiplier* (α_i^* dan α_i) sebesar 0. Nilai tersebut diinisialisasi sebanyak jumlah data latih, seperti yang ditunjukkan Tabel 4.11.

Tabel 4.11 Inisialisasi Nilai *Lagrange Multiplier*

α_i^*	α_i
0	0
0	0
0	0
0	0
0	0

Setelah inisialisasi selesai dilakukan, maka dilakukan proses perhitungan secara berulang sesuai dengan jumlah iterasi yang diinisialisasikan di awal atau mencapai hingga menggapai batas $\max(|\delta\alpha_i|) < \varepsilon$ dan $\max(|\delta\alpha_i^*|) < \varepsilon$. Proses perhitungan berulang ini ditunjukkan pada Gambar 4.6.





Gambar 4.6 Diagram Alir Perhitungan Sequerntial Learning

Perhitungan ini secara berurutan menggunakan persamaan (2.11), (2.12), (2.13), (2.14), dan (2.15). Berikut contoh menghitung nilai galat E_i , $\delta\alpha_i^*$, dan $\delta\alpha_i$ dan mencari nilai α_i^* dan α_i yang baru menggunakan data latih pertama:

$$\begin{aligned}
 E_1 &= y_1 - \sum_{j=1}^l (\alpha_1^* - \alpha_1) R_{15} \\
 &= 0,9 - ((0 - 0)5 + (0 - 0)4,825306868 + (0 - 0)4,938042899 + \\
 &\quad (0 - 0)4,98906806 + (0 - 0)4,966592255) \\
 &= 0,900 \\
 \delta\alpha_1^* &= \min\{\max[\gamma(E_1 - \epsilon), -\alpha_1^*], C - \alpha_1^*\} \\
 &= \min\{\max[0,31683168(0,900 - 0,001), -0], 10 - 0\} \\
 &= \min\{\max[0,31683168(0,899)] 10\} \\
 &= 0,284831683 \\
 \delta\alpha_1 &= \min\{\max[\gamma(-E_1 - \epsilon), -\alpha_1], C - \alpha_1\} \\
 &= \min\{\max[0,31683168((-0,900) - 0,001), -0], 10 - 0\} \\
 &= \min\{\max[0,31683168(-0,901)] 10\} \\
 &= 0
 \end{aligned}$$

Lalu, dilakukan perhitungan untuk mencari nilai α_i^* dan α_i yang baru. Berikut perhitungan pada data latih ke -1:

$$\begin{aligned}
 \alpha_1^* &= \alpha_1^* + \delta\alpha_1^* = 0 + 0,284831683 = 0,284831683 \\
 \alpha_1 &= \alpha_1 + \delta\alpha_1 = 0 + 0 = 0
 \end{aligned}$$

Pada Tabel 4.12 dan Tabel 4.13 ditunjukkan secara lengkap hasil perhitungan manual pada proses *sequential learning* pada iterasi pertama dan iterasi ke-10:

Tabel 4.12 Hasil Iterasi ke-1


Yi	Ei	y _{ai} *	y _{ai}	α _i *	α _i
0,9	0,900	0,284831683	0	0,284832	0
0,1	0,100	0,031366337	0	0,031366	0
0,155172414	0,155	0,048846705	0	0,048847	0
0,706896552	0,707	0,223650393	0	0,223650	0
0,486206897	0,486	0,153728918	0	0,153729	0

Tabel 4.13 Hasil Iterasi ke-10

Yi	Ei	y _{ai} *	y _{ai}	α _i *	α _i
0,9	0,026	0,00793193	-0,008565594	0,595697	-0,202853016
0,1	0,002	0,000332424	-0,000966087	0,053404	-0,040660642
0,155172414	-0,034	0	0,010424004	0,000000	0,114866864
0,706896552	-0,058	-0,018600863	0,0179672	0,127862	0,122765247
0,486206897	0,023	0,006867914	-0,007501577	0,149690	-0,007823529

6. Proses Perhitungan Nilai Peramalan dan Nilai MAPE

Setelah mendapatkan nilai *Lagrange Multiplier* (α_i^* dan α_i) yang baru, maka dilakukanlah proses perhitungan nilai peramalan menggunakan persamaan (2.16). Pada Gambar 4.7 ditunjukkan diagram alir proses perhitungan nilai peramalan:

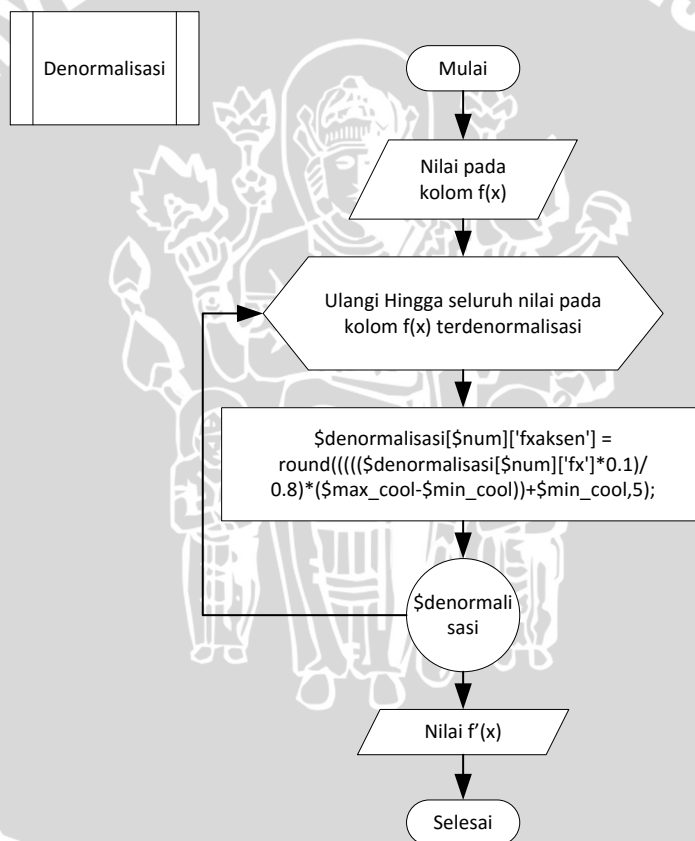


Gambar 4.7 Diagram Alir Perhitungan Nilai Peramalan

Sebagai contoh perhitungan manual nilai peramalan, peneliti menggunakan nilai *Lagrange Multiplier* (α_i^* dan α_i) baru dalam indeks pertama Tabel 4.13. Berikut contoh perhitungan manual nilai peramalan:

$$\begin{aligned} f(x) &= \sum_{i=1}^l (\alpha_i^* - \alpha_i) (K(x_i, x) + \lambda^2) = \sum_{i=1}^l (\alpha_i^* - \alpha_i) R_{ij} \\ &= (0,595697 - (-0,202853016))(1,01) \\ &\quad + (0,053404 - (-0,040660642))(0,031493601) \\ &\quad + (0 - 0,114866864)(0,129553426) \\ &\quad + (0,127862 - 0,122765247)(0,812645076) \\ &\quad + (0,149690 - (-0,007823529))(0,425044042) \\ &= 0,8657 \end{aligned}$$

Lalu, dilakukan proses denormalisasi setelah selesai menghitung nilai peramalan seperti pada Gambar 4.8.



Gambar 4.8 Diagram Alir Denormalisasi Nilai Peramalan

Nilai denormalisasi diperoleh dengan menggunakan persamaan (2.6), berikut contoh perhitungan manual denormalisasi:

$$\begin{aligned} X &= \frac{Y - B}{A - B} * (Max - Min) + Min \\ &= \frac{0,8657 - 0,1}{0,9 - 0,1} * (40 - 11) + 11 \end{aligned}$$

$$= 38,75693615$$

Hasil denormalisasi ($f'(x)$) secara lengkap dapat dilihat pada Tabel 4.14 berikut:

Tabel 4.14 Hasil Denormalisasi Nilai Peramalan

$f(x)$	$f'(x)$
0,8657	38,75693615
0,0930	10,74659324
0,1786	13,84838729
0,7489	34,5224865
0,4478	23,60779284

4.4 Perancangan Skenario Pengujian

Perancangan ini dilakukan sebagai langkah untuk menguji hasil prediksi beban panas dan beban dingin bangunan dengan algoritma SVR. Skenario pengujian yang akan dilaksanakan diantaranya:

1. Pengujian jumlah iterasi SVR.
2. Pengujian nilai batas parameter cLR SVR.
3. Pengujian nilai batas parameter λ (*lambda*) SVR.
4. Pengujian nilai batas parameter C (*Complexity*) SVR.

Pengujian ini dilakukan sebagai langkah untuk mengetahui jumlah iterasi dan besar nilai parameter sesuai dengan dataset yang digunakan. Data latih dan data uji yang dilakukan dalam pengujian ini diambil dari dataset yang sama. Data latih dan data uji tersebut diambil dengan cara bergantian dengan jarak 13 interval baris dalam dataset yang digunakan. Contohnya untuk percobaan pertama, data latih yang digunakan adalah 10 urutan pertama data bangunan dalam dataset dan data uji yang digunakan adalah 3 urutan data bangunan setelah 10 data urutan pertama.

Lalu untuk percobaan kedua, data latih yang digunakan adalah 10 data berurutan setelah 3 urutan data yang digunakan dalam percobaan pertama menjadi data uji. Sedangkan data uji yang digunakan adalah 3 data berurutan setelah 10 urutan data yang sebelumnya digunakan sebagai data latih. Demikian seterusnya hingga percobaan ke-10. Skenario pengujian yang akan dilaksanakan diantaranya:

4.4.1 Pengujian jumlah iterasi pelatihan SVR

Pengujian ini dilakukan untuk mencari jumlah iterasi SVR yang memberikan nilai *Lagrange Multiplier* (α_i^* dan α_i) terbaik sehingga dapat memberikan hasil peramalan yang lebih baik. Pengujian ini menggunakan nilai parameter yang sama dan 10 variasi susunan data. Tabel 4.15 menunjukkan rancangan pengujian yang menggunakan sembilan varian jumlah iterasi dimana masing-masing varian diuji 10 kali.

Tabel 4.15 Rancangan pengujian jumlah iterasi pelatihan SVR

Jumlah Iterasi	Error Rate										Rerata Error Rate
	Percobaan ke-										
	1	2	3	4	5	6	7	8	9	10	
10											
50											
100											
500											
1000											
5000											
10000											
50000											
100000											

4.4.2 Pengujian nilai batas parameter cLR SVR

Pengujian ini dilakukan untuk mencari nilai terbaik cLR sehingga dapat memberikan hasil peramalan yang lebih baik. Pengujian ini menggunakan 10 variasi susunan data. Tabel 4.16 menunjukkan rancangan pengujian dengan sembilan varian nilai batas cLR dimana masing-masing varian nilai diuji 10 kali.

Tabel 4.16 Rancangan pengujian nilai batas parameter cLR SVR

Nilai cLR	Error Rate										Rerata Error Rate
	Percobaan ke-										
	1	2	3	4	5	6	7	8	9	10	
0,0001											
0,0003											
0,001											
0,003											
0,01											
0,03											
0,1											
0,3											
1											

4.4.3 Pengujian nilai batas parameter λ ($lambda$)

Pengujian ini dilakukan untuk mencari nilai terbaik λ sehingga dapat memberikan hasil peramalan yang lebih baik. Pengujian ini menggunakan 10 variasi susunan data. Tabel 4.17 menunjukkan sembilan varian nilai batas λ dimana masing-masing varian nilai diuji 10 kali.

Tabel 4.17 Rancangan pengujian nilai batas parameter λ ($lambda$)

Nilai λ	Error Rate										Rerata Error Rate
	Percobaan ke-										
	1	2	3	4	5	6	7	8	9	10	
0,001											
0,005											
0,01											
0,05											
0,1											
0,5											
1											
5											
10											

4.4.4 Pengujian nilai batas parameter C

Pengujian ini dilakukan untuk mencari jarak nilai terbaik C sehingga dapat memberikan hasil peramalan yang lebih baik. Pengujian ini menggunakan 10 variasi susunan data. Tabel 4.18 menunjukkan sembilan varian nilai dimana masing-masing varian nilai diuji 10 kali.

Tabel 4.18 Rancangan pengujian nilai batas parameter C

Nilai C	Error Rate										Rerata Error Rate
	Percobaan ke-										
	1	2	3	4	5	6	7	8	9	10	
0,05											
0,1											
0,5											
1											
5											
10											
50											
100											
500											



BAB 5 IMPLEMENTASI

Pada bab ini akan dibahas implementasi sistem yang telah dirancang pada bab 4, Perancangan. Bagian yang menjadi pokok bahasan pada bab ini adalah implementasi *source code* dan implementasi antarmuka pengguna.

5.1 Implementasi *source code*

Aplikasi sistem prediksi beban pemanasan dan beban pendinginan bangunan menggunakan metode *support vector regression* diimplementasikan dengan bahasa *PHP*.

5.1.1 Proses Normalisasi Data

Normalisasi dilakukan untuk menyederhanakan nilai data agar berada pada jarak 0 hingga 1. Metode normalisasi yang penulis gunakan adalah metode *minmax normalization*, proses perhitungan dalam *source code* disajikan pada Kode Program 5.1 berikut:

```

1 public function get_normalisasi($sintesis)
2 {
3     $min_rel = $this->mp->get_min_rel();
4     $max_rel = $this->mp->get_max_rel();
5
6     $min_sur = $this->mp->get_min_sur();
7     $max_sur = $this->mp->get_max_sur();
8
9     $min_wall = $this->mp->get_min_wall();
10    $max_wall = $this->mp->get_max_wall();
11
12    $min_heat = $this->mp->get_min_heat();
13    $max_heat = $this->mp->get_max_heat();
14
15    $min_cool = $this->mp->get_min_cool();
16    $max_cool = $this->mp->get_max_cool();
17
18    $n=1;
19    foreach ($sintesis as $key => $value) {
20        $normalisasi[$n]['rel'] = 0.8* (($value->rel-
21 $min_rel)/ ($max_rel-$min_rel))+0.1;
22        $normalisasi[$n]['sur'] = 0.8* (($value->sur-
23 $min_sur)/ ($max_sur-$min_sur))+0.1;
24        $normalisasi[$n]['wall'] = 0.8* (($value-
25 >wall-$min_wall)/ ($max_wall-$min_wall))+0.1;
26        $normalisasi[$n]['heat'] = 0.8* (($value-
27 >heat-$min_heat)/ ($max_heat-$min_heat))+0.1;
28        $normalisasi[$n]['cool'] = 0.8* (($value-
29 >cool-$min_cool)/ ($max_cool-$min_cool))+0.1;
30        $n++;
31    }
32    return $normalisasi;
33 }

```

Kode Program 5.1 Normalisasi Data

Penjelasan Kode Program 5.1 sebagai berikut :

1. Rel, sur, wall, heat, dan cool adalah singkatan dari nama variabel yang digunakan yakni *Relative compactness*, *Surface area*, *Wall area*, *Heating load*, dan *Cooling load*.
2. Baris 3-16 adalah proses mendapatkan nilai minimal dan maksimal pada tiap variabel.
3. Baris 18-31 adalah proses perhitungan normalisasi tiap variable menggunakan persamaan (2.5).
4. Baris 32 berfungsi mengembalikan nilai normalisasi tiap variabel.

5.1.2 Proses Perhitungan *Kernel RBF*

Fungsi *kernel* digunakan untuk memetakan data masukan ke dimensi yang lebih tinggi. Fungsi *kernel* yang digunakan adalah *kernel RBF*. Proses perhitungan dalam *source code* disajikan pada Kode Program 5.2 berikut:

```

1 public function get_kernel($normalisasi,$d,$sigma)
2 {
3     foreach ($normalisasi as $i => $value) {
4         foreach ($normalisasi as $j => $nilai) {
5             $data = -
6             $d['x'.'. $i']['x'.'. $j]/2*($sigma*$sigma);
7             $kernel['x'.'. $i']['x'.'. $j] = exp($data);
8         }
9     }
10    return $kernel;
11 }

```

Kode Program 5.2 Perhitungan *kernel RBF*

Penjelasan Kode Program 5.2 sebagai berikut :

1. Baris 1 adalah inisialisasi matriks *kernel* sesuai dari matriks data hasil normalisasi.
2. Baris 3-7 adalah proses perhitungan *kernel* yang dijalankan berulang sampai semua index terisi oleh nilai hasil perhitungan *kernel*.
3. Baris 5-6 berfungsi untuk menghitung jarak data.
4. Baris 7 berfungsi untuk menghitung *kernel RBF*.
5. Baris 10 berfungsi untuk mengembalikan nilai *kernel* yang didapat.

5.1.3 Proses Perhitungan Matriks *Hessian*

Nilai yang diperlukan pada perhitungan matriks *Hessian* berasal dari nilai *kernel*. Proses perhitungan dalam *source code* disajikan pada Kode Program 5.3 berikut:

```

1 public function get_r($normalisasi,$kernel,$lambda)
2 {
3     foreach ($normalisasi as $i => $value) {
4         foreach ($normalisasi as $j => $nilai) {
5             $r['x'.'. $i']['x'.'. $j] =
6             $kernel['x'.'. $i']['x'.'. $j]+($lambda*$lambda);
7         }
8     }

```

9	return \$r;
10	}

Kode Program 5.3 Perhitungan matriks *Hessian*

Penjelasan Kode Program 5.3 sebagai berikut :

1. Baris 1 adalah inisialisasi matriks *hessian* sesuai dengan nilai pada matriks *kernel* dan inisialisasi nilai λ .
2. Baris 3-7 adalah proses perhitungan matriks *hessian* yang dijalankan berulang sampai semua index terisi oleh nilai hasil perhitungan matriks *hessian*.

5.1.4 Proses *Sequential Learning*

Fungsi *Sequential Learning* digunakan untuk mencari nilai *Lagrange Multiplier* (α_i dan α_i^*). Dalam prosesnya, perhitungan dilakukan berulang sebanyak jumlah iterasi yang diinisialisasikan di awal. Proses perhitungan dalam *source code* disajikan pada Kode Program 5.4 berikut:

1	public function
2	get_iterasi(\$normalisasi,\$r,\$clr,\$e,\$c,\$ulang)
3	{
4	foreach (\$r as \$key => \$value) {
5	foreach (\$value as \$kunci => \$nilai) {
6	\$array_r[]=\$nilai;
7	}
8	}
9	
10	\$gamma = \$clr/max(\$array_r);
11	
12	\$alpha = 1;
13	foreach (\$r as \$key => \$value) {
14	\$iterasi[0][\$alpha]['alphaaksen'] = 0;
15	\$iterasi[0][\$alpha]['alpha'] = 0;
16	\$alpha++;
17	}
18	
19	for (\$i=1; \$i <= \$ulang; \$i++) {
20	\$num = 1;
21	foreach (\$r as \$key => \$value) {
22	\$iterasi[\$i][\$num]['yi'] =
23	\$normalisasi[\$num]['cool'];
24	\$pengurang = 0;
25	\$index=1;
26	foreach (\$r['x'].\$num as \$kunci =>
27	\$nilai) {
28	\$pengurang += (\$iterasi[\$i-
29	1][\$index]['alphaaksen']-\$iterasi[\$i-
30	1][\$index]['alpha'])*\$nilai;
31	\$index++;
32	}
33	
34	\$iterasi[\$i][\$num]['ei'] =
35	\$iterasi[\$i][\$num]['yi'] - \$pengurang;
36	\$iterasi[\$i][\$num]['yaiaksen'] =
37	min(max(\$gamma*(\$iterasi[\$i][\$num]['ei']-\$e),-
38	\$iterasi[\$i-1][\$num]['alphaaksen']),\$c-\$iterasi[\$i-
39	1][\$num]['alphaaksen']);

```

40         $iterasi[$i][$num]['yai'] =
41 min(max($gamma*(-$iterasi[$i][$num]['ei']-$e),-
42 $iterasi[$i-1][$num]['alpha']),$c-$iterasi[$i-
43 1][$num]['alpha']);
44         $iterasi[$i][$num]['alphaaksen'] =
45 $iterasi[$i-
46 1][$num]['alphaaksen']+$iterasi[$i][$num]['yaiaksen'];
47         $iterasi[$i][$num]['alpha'] =
48 $iterasi[$i-1][$num]['alpha']+$iterasi[$i][$num]['yai'];
49
50         $num++;
51     }
52 }
53 return $iterasi;
54 }

```

Kode Program 5.4 Sequential Learning

Penjelasan Kode Program 5.4 sebagai berikut:

1. Baris 2 adalah inisialisasi nilai jumlah iterasi, parameter CLR, parameter *epsilon*, parameter C, normalisasi nilai data yang akan diramalkan (Yi).
2. Baris 4-6 berfungsi menginisialisasi variabel key yang diisi oleh *array* dari kolom matriks *hessian*.
3. Baris 10 berfungsi menjalankan persamaan (2.10) untuk mencari nilai parameter *gamma*.
4. Baris 12-16 berfungsi menginisialisasi nilai α_i^* dan α_i yang akan digunakan.
5. Baris 19-50 berfungsi untuk menjalankan proses perhitungan *sequential learning* sebanyak jumlah iterasi yang diinisialisasikan.
6. Baris 19-27 berfungsi untuk menggunakan nilai normalisasi pada kolom "coolong load" pada matriks *hessian* sebagai nilai data yang akan diramalkan (Yi).
7. Baris 28-31 berfungsi menampilkan nilai α_i^* dan α_i^* yang baru setelah dihitung dalam baris 44-48.
8. Baris 34-35 menjalankan persamaan (2.11) yang berfungsi untuk mencari nilai E_i .
9. Baris 36-39 menjalankan persamaan (2.12) yang berfungsi untuk mencari nilai $\delta\alpha_i^*$.
10. Baris 40-43 menjalankan persamaan (2.13) yang berfungsi untuk mencari nilai $\delta\alpha_i$.
11. Baris 44-46 menjalankan persamaan (2.14) yang berfungsi untuk mencari nilai α_i^* yang baru.
12. Baris 47-48 menjalankan persamaan (2.15) yang berfungsi untuk mencari nilai α_i yang baru.

5.1.5 Proses Perhitungan Fungsi Peramalan dan Error Rate

Proses perhitungan fungsi peramalan ($f(x)$) membutuhkan nilai α_i dan α_i^* pada hasil iterasi terakhir dari proses perhitungan *sequential*

learning. Proses perhitungan dalam *source code* disajikan pada Kode Program 5.5 berikut:

```

1 public function
2 get_error_rate($normalisasi,$r,$iterasi,$ulang)
3 {
4     $num=1;
5     foreach ($r as $key => $value) {
6         $error_rate[$num]['yi'] =
7         round($normalisasi[$num]['cool'],5);
8         $fx=0;
9         $index=1;
10        foreach ($r['x'.$num] as $kunci => $nilai) {
11            $fx +=
12            ($iterasi[$ulang][$index]['alphaaksen']-
13            $iterasi[$ulang][$index]['alpha'])*$nilai;
14            $index++;
15        }
16        $error_rate[$num]['fx'] = round($fx,5);
17        $error_rate[$num]['ei'] = round($fx-
18        $error_rate[$num]['yi'],5);
19        $error_rate[$num]['ei/yi'] =
20        round(abs($error_rate[$num]['ei']/$error_rate[$num]['yi']
21        ),5);
22        $num++;
23    }
24    return $error_rate;
25 }

```

Kode Program 5.5 Perhitungan Error Rate

Penjelasan Kode Program 5.5 sebagai berikut:

1. Baris 2 adalah inisialisasi nilai variabel normalisasi, matriks *hessian*, dan jumlah iterasi.
2. Baris 4-24 adalah proses perhitungan *Error Rate*.
3. Baris 4-7 berfungsi menginisialisasi variabel key yang berisi nilai normalisasi pada kolom “coolong load” pada matriks *hessian* sebagai nilai data yang akan diramalkan (Y_i), kemudian dibulatkan menjadi 5 angka dibelakang koma.
4. Baris 8-14 berfungsi melakukan perhitungan nilai peramalan $f(x)$.
5. Baris 16 berfungsi untuk membulatkan nilai peramalan $f(x)$ menjadi 5 angka dibelakang koma.
6. Baris 17-18 berfungsi untuk menghitung nilai E_i dan kemudian membulatkan menjadi 5 angka di belakang koma.
7. Baris 19-21 berfungsi untuk menghitung nilai E_i/Y_i dan kemudian membulatkan menjadi 5 angka di belakang koma.

5.2 Implementasi Antarmuka Pengguna

Antarmuka dari aplikasi sistem prediksi beban panas dan dingin bangunan terdiri dari beberapa menu. Menu utama berisikan data masukan seperti tombol mengunggah data latih dan data uji spesifikasi bangunan dan beberapa *input* parameter SVR seperti pada Gambar 5.1 berikut:

Prediksi Beban Panas dan Beban Dingin Bangunan
Menggunakan Metode Support Vector Regression

Input Data

Upload Excel Data Sintesis
Choose File No file chosen + Tambahkan

Upload Excel Data Uji
Choose File No file chosen + Tambahkan

Inisialisasi Parameter

ϵ C λ

cLR Sigma(σ) Iterasi

cLR Sigma(σ) 10

Gambar 5.1 Antarmuka Utama *Input Data* dan Parameter

Beberapa parameter yang digunakan seperti *epsilon*(ϵ), *C*, *lambda*(λ), *cLR*, *sigma*(σ), *gamma*(γ), dan jumlah iterasi dapat diinisialisasikan di awal sebelum melakukan proses perhitungan.

Prediksi Beban Panas dan Beban Dingin Bangunan
Menggunakan Metode Support Vector Regression

Hasil

Perhitungan Hasil

Error Rate

y_i	$f(x)$	E_i	$ E_i / y_i $
0.9	0.8317	-0.0683	0.0759
0.1	0.0808	-0.0192	0.192
0.1552	0.1731	0.0179	0.1153
0.7069	0.7441	0.0372	0.0526
0.4862	0.455	-0.0312	0.0642
TOTAL			0.5
MAPE			8.33333

Gambar 5.2 Tampilan Hasil Perhitungan dan *Error Rate*

Pada Gambar 5.2 terlihat hasil perhitungan *Error Rate* yang merupakan hasil perhitungan setelah iterasi berjalan sesuai dengan nilai yang dimasukkan dalam kolom jumlah iterasi pada menu utama. Untuk melihat perhitungan saat iterasi berjalan dapat dilakukan dengan menekan tombol perhitungan di atas tombol hasil.

BAB 6 PENGUJIAN DAN ANALISIS

Pada bab ini akan dibahas tahapan pengujian dan analisis sistem prediksi beban pemanasan dan beban pendinginan bangunan menggunakan metode *support vector regression*. Proses pengujian yang dilakukan terdiri dari pengujian Jumlah Iterasi SVR, pengujian nilai batas parameter *cLR*. Selanjutnya hasil dari pengujian akan dianalisa dengan harapan menghasilkan kesimpulan yang kuat.

6.1 Hasil dan Analisis Pengujian Jumlah Iterasi Pelatihan

Jumlah iterasi SVR untuk pelatihan yang diuji adalah 50, 100, 500, 1000, 5000, 10000, 50000, 100000, 500000 sesuai dengan perancangan pada Bab 4. Berikut penulis sajikan informasi detail tentang parameter lain yang digunakan dalam proses pengujian jumlah iterasi SVR:


- Nilai ε : 0.001
- Nilai *cLR* : 0.32
- Nilai *C* : 10
- Nilai λ : 0.1
- Nilai σ : 2
- Jumlah data Latih : 100 data bangunan
- Jumlah data Uji : 30 data bangunan

Hasil pengujian jumlah iterasi pelatihan secara lengkap ditunjukkan pada Tabel 6.1 berikut:

Tabel 6.1 Hasil pengujian jumlah iterasi pelatihan

Jumlah Iterasi	Error Rate										Rerata Error Rate
	Percobaan ke-										
	1	2	3	4	5	6	7	8	9	10	
10	8,32170	6,77950	23,31483	8,05600	52,95383	27,72267	21,87933	37,84650	5,00350	10,09500	20,19729
50	5,24483	0,37850	4,61817	0,68550	5,36750	3,64467	0,49400	8,00200	0,58167	1,75883	3,07757
100	4,01233	0,33100	1,76617	0,30783	0,66183	0,73417	0,28533	1,63033	0,33933	0,85933	1,09277
500	0,66050	0,33100	0,13317	0,30867	0,43533	0,33117	0,24450	0,42667	0,32417	0,39133	0,35865
1000	0,36350	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34848
5000	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
10000	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
50000	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
100000	0,35033	0,33100	0,29983	0,30867	0,43533	0,33117	0,24900	0,42667	0,32583	0,39133	0,34492

Jumlah iterasi pelatihan SVR berpengaruh pada tingkat akurasi SVR yang dihasilkan. Tabel 6.1 menunjukkan rata-rata *error rate* terkecil didapatkan pada 100000 iterasi SVR dengan nilai 0.34492. Grafik pada Gambar 6.1 menunjukkan rerata *error rate* yang cenderung menurun, dan apabila dicermati detail pada setiap percobaan pada Tabel 6.1 nilai *error rate* yang didapat cenderung menurun sampai pada jumlah iterasi maksimal tertentu kemudian menjadi konstan.



Gambar 6.1 Grafik Rerata *Error Rate* Pengujian Jumlah Iterasi

6.2 Hasil dan Analisis Pengujian Nilai Batas Parameter λ (*lambda*)

Nilai jarak (*Nilai*) parameter λ (*lambda*) adalah 0. Berikut penulis sajikan informasi detail tentang parameter lain yang digunakan dalam proses pengujian jumlah iterasi SVR:

- Nilai cLR : 0.32
- Nilai ε : 0.001
- Nilai C : 10
- Nilai σ : 2
- Iterasi SVR : 5000
- Jumlah data Latih : 10 data bangunan
- Jumlah data Uji : 3 data bangunan


Hasil pengujian ditunjukkan pada Tabel 6.2 berikut:

Tabel 6.2 Hasil pengujian batas nilai parameter λ (*lambda*)

Nilai λ	Error Rate										Rerata Error Rate
	Percobaan ke-										
	1	2	3	4	5	6	7	8	9	10	
0,001	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
0,005	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
0,01	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
0,05	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
0,1	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
0,5	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
1	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
5	1,61900	0,33100	383238,24283	393963,43150	0,43717	451217,33200	316537,93800	543804,47300	0,32933	498341,82533	258710,59592
10	3,64400	1662420,04100	1507497,49283	1551068,59050	5,50017	1777568,70083	1250227,64633	2143995,38217	0,65933	1966595,79367	1185938,34508

Parameter ini berpengaruh terhadap penskalaan pemetaan *kernel* dalam SVR. Semakin tinggi nilai parameter ini maka semakin baik nilai evaluasi yang

diberikan pada kasus regresi, namun beresiko memiliki waktu komputasi yang lama. Hal itu disebabkan karena konvergensi yang melambat seiring dengan proses *learning* yang kurang stabil (Vijayakumar & Wu, 1999). Tabel 6.2 menunjukkan rata-rata *error rate* terkecil didapatkan pada rentang nilai λ 0,001-1 dengan nilai 0,34717. Pada Gambar 6.2 ditunjukkan terjadi peningkatan tajam ketika nilai $\lambda = 5$.



Gambar 6.2 Grafik Rerata *Error Rate* Pengujian Nilai λ

6.3 Hasil dan Analisis Pengujian Nilai Batas Parameter *cLR*

Nilai parameter *cLR* (laju pembelajaran) yang diuji sesuai dengan perancangan yang telah dibuat pada Bab 4. Rincian parameter lainnya yang digunakan pada proses pengujian ini adalah sebagai berikut:


- Nilai λ : 0.1
- Nilai ε : 0.001
- Nilai C : 10
- Nilai σ : 2
- Iterasi SVR : 5000
- Jumlah data Latih : 10 data bangunan
- Jumlah data Uji : 3 data bangunan

Pengujian *cLR* (laju pembelajaran) dilakukan sebanyak 10 kali untuk setiap nilai yang diujikan. Hasil pengujiannya ditunjukkan pada Tabel 6.3 berikut:

Tabel 6.3 Hasil pengujian nilai parameter cLR

Nilai cLR	Error Rate										Rerata Error Rate
	Percobaan ke-										
	1	2	3	4	5	6	7	8	9	10	
0,0001	22,31750	39,01000	56,17183	38,21450	72,94183	41,39683	53,67700	57,63783	27,57383	21,43783	43,03790
0,0003	13,45900	22,73367	47,09133	20,33767	80,17000	39,36650	42,27300	51,68317	16,35417	20,64500	35,41135
0,001	6,72183	3,71183	13,60317	5,28333	38,93200	16,96850	12,71317	30,23117	3,45700	6,13817	13,77602
0,003	5,36350	0,45350	4,99433	0,83983	6,88650	4,31933	0,68100	9,26633	0,69883	1,95383	3,54570
0,01	2,97517	0,33100	0,67883	0,31033	0,39233	0,37600	0,25983	0,58600	0,30850	0,55000	0,67680
0,03	0,73217	0,33100	0,13417	0,30867	0,43533	0,33117	0,24550	0,42667	0,32417	0,39133	0,36602
0,1	0,35067	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34720
0,3	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
1	9396,74167	7479,05300	8635,06100	8415,99233	10050,71200	9443,72250	5432,52733	10260,86200	0,32583	9119,60333	7823,46010

Parameter cLR yang merupakan konstanta laju pembelajaran akan memberikan nilai *error rate* yang kecil apabila memiliki nilai yang kecil, namun proses *learning* akan melambat. Sedangkan jika parameter cLR memiliki nilai yang besar maka proses *learning* akan semakin cepat namun riskan memberikan hasil *error rate* yang buruk (Vijayakumar & Wu, 1999). Hasil pengujian menunjukkan bahwa pada parameter cLR yang bernilai 0,3 nilai *error rate* terkecil yang bernilai 0,34717. Saat nilai cLR 1×10^{-3} terjadi penurunan tajam pada perolehan rerata *error rate*, hal tersebut ditunjukkan pada Gambar 6.3 berikut:



Gambar 6.3 Grafik Rerata Error Rate Pengujian Nilai cLR

6.4 Hasil dan Analisis Pengujian Nilai Batas Parameter C

Nilai parameter C (Complexity) yang diuji sesuai dengan perancangan yang telah dibuat pada Bab 4. Rincian parameter lainnya yang digunakan pada proses pengujian ini adalah sebagai berikut:

- Nilai cLR : 0.32


- b. Nilai ε : 0.001
- c. Nilai λ : 0.1
- d. Nilai σ : 2
- e. Iterasi SVR : 5000
- f. Jumlah data Latih : 10 data bangunan
- g. Jumlah data Uji : 3 data bangunan

Pengujian C (*Complexity*) dilakukan sebanyak 10 kali untuk setiap nilai yang diujikan. Hasil pengujiannya ditunjukkan pada Tabel 6.4 berikut:

Tabel 6.4 Hasil pengujian nilai parameter C

Nilai C	Error Rate										Rerata Error Rate
	Percobaan ke-										
	1	2	3	4	5	6	7	8	9	10	
0,05	40,12150	51,51700	53,06167	51,02283	41,22300	40,95567	57,93483	45,19667	49,94900	38,15133	46,91335
0,1	31,83250	43,73517	47,45283	42,47150	37,43917	31,76167	51,35650	37,79850	34,97017	20,28417	37,91022
0,5	4,39683	38,31650	15,55317	2,10833	19,40300	10,49450	13,22583	42,07233	2,17600	10,15267	15,78992
1	2,99600	0,33100	5,13433	0,30867	14,67583	6,21483	0,24900	36,28000	0,35183	0,67000	6,72115
5	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
10	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
50	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
100	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717
500	0,35033	0,33100	0,29983	0,30867	0,43533	0,35367	0,24900	0,42667	0,32583	0,39133	0,34717

Parameter ini merupakan konstanta batas toleransi kesalahan peramalan. Jika nilai yang dimiliki semakin besar, maka model peramalan akan tidak memberikan toleransi kesalahan peramalan. Hal tersebut berarti hasil peramalan yang diberikan baik dan hal tersebut berlaku pula sebaliknya (Furi, et al., 2015). Pernyataan ini terbukti pada hasil pengujian dalam Tabel 6.4 dimana nilai C dimulai dari 5 hingga 500 memiliki nilai *error rate* terkecil yakni 0,34717. Gambar 6.4 menunjukkan rerata *error rate* menurun drastis ketika nilai $C = 0,5$ lalu konstan saat nilai parameter $C = 5$ hingga $C = 500$.



Gambar 6.4 Grafik Rerata *Error Rate* Pengujian Nilai C

BAB 7 PENUTUP

Bagian ini memuat kesimpulan dan saran terhadap skripsi. Kesimpulan dan saran disajikan secara terpisah, dengan penjelasan sebagai berikut:

7.1 Kesimpulan

Kesimpulan yang dapat diambil dari proses perancangan, implementasi, dan pengujian adalah:

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 $cLR = 3 * 10^{-1}$, $C = 500$, $\lambda = 1$, $\varepsilon = 1 * 10^{-3}$, $\sigma = 2$, 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

Saran yang dapat digunakan untuk penelitian selanjutnya terkait objek dan metode pada penelitian ini adalah sebagai berikut:

1. Dapat ditambahkan metode selain SVR dan/atau metode optimasi untuk perhitungan beban pemanasan dan beban pendinginan. Metode selain SVR 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 atau kota di Indonesia dalam menghitung beban pemanasan dan beban pendinginan 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. & 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*, Skudai: Hindawi.
- Amanda, R., Yasin, H. & Prahutama, A., 2014. *Analisis Support Vector Regression (SVR) dalam Memprediksi Kurs Rpiah 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 : IHSG 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 Classiers and Regression*. Genoa, Italy, Saitama: RIKEN Brain Science Institute, The Institute for Physical and Chemical Research, pp. 610-619.



LAMPIRAN A DATA BANGUNAN

Lampiran 1 Data Bangunan Hasil Sintesis menggunakan program Ecotect

No.	RC	SA	WA	HL	CL
1	0,9	750	400	35	40
2	0,65	560	300	7	11
3	0,76	600	315	8	13
4	0,85	700	375	28	33
5	0,8	650	350	14	25
6	0,91	779	336	22	16
7	0,69	523	304	32	31
8	0,64	618	383	22	32
9	0,91	522	335	26	42
10	0,78	757	312	13	13
11	0,71	783	337	31	38
12	0,97	766	259	13	39
13	0,7	757	318	12	31
14	0,65	763	289	14	27
15	0,77	673	251	8	45
16	0,86	586	413	42	48
17	0,69	676	325	29	26
18	0,75	755	272	30	22
19	0,65	649	275	18	14
20	0,8	538	340	14	42
21	0,85	797	264	31	14
22	0,78	593	394	22	21
23	0,85	730	413	33	14
24	0,96	675	285	17	35
25	0,77	782	265	12	44
26	0,81	629	375	31	47
27	0,93	613	317	36	40
28	0,78	629	406	34	16
29	0,84	554	402	19	12
30	0,7	663	380	40	20
31	0,65	587	375	13	27
32	0,94	602	253	28	23
33	0,75	538	256	16	12
34	0,95	736	396	34	27
35	0,98	762	401	23	25

No.	RC	SA	WA	HL	CL
66	0,66	608	282	21	43
67	0,62	528	281	16	48
68	0,62	721	393	11	48
69	0,74	800	339	13	37
70	0,86	711	286	26	44
71	0,68	641	380	37	28
72	0,82	579	326	21	25
73	0,95	690	353	36	39
74	0,98	616	317	29	12
75	0,67	678	277	9	25
76	0,72	645	255	27	12
77	0,7	547	392	41	40
78	0,96	793	410	41	12
79	0,65	604	304	8	15
80	0,69	685	411	25	25
81	0,66	737	314	17	36
82	0,9	637	291	42	36
83	0,85	614	332	26	47
84	0,91	645	363	39	12
85	0,79	540	390	17	15
86	0,91	526	257	10	28
87	0,86	518	345	35	18
88	0,84	566	383	18	28
89	0,94	660	275	23	18
90	0,63	532	260	28	28
91	0,68	605	249	27	15
92	0,87	606	405	19	38
93	0,66	807	413	8	30
94	0,62	690	344	40	45
95	0,83	631	397	34	35
96	0,66	767	368	16	25
97	0,86	638	286	28	31
98	0,75	771	325	42	34
99	0,89	765	298	11	27
100	0,82	666	278	26	44

36	0,77	770	247	25	30
37	0,92	596	251	32	26
38	0,76	654	358	37	33
39	0,66	671	299	7	38
40	0,82	675	333	36	26
41	0,62	531	357	26	19
42	0,29	590	272	36	16
43	0,82	559	262	18	29
44	0,8	645	388	27	42
45	0,74	671	361	8	39
46	0,97	663	316	37	16
47	0,96	581	269	13	14
48	0,64	687	356	23	11
49	0,94	643	291	33	25
50	0,84	704	280	32	43
51	0,62	642	339	37	31
52	0,92	610	396	25	41
53	0,94	618	327	20	17
54	0,86	639	315	27	29
55	0,7	728	318	17	32
56	0,92	580	252	30	15
57	0,82	592	316	34	14
58	0,63	680	388	40	40
59	0,91	565	291	26	42
60	0,7	762	281	27	25
61	0,72	700	290	17	31
62	0,98	732	370	27	27
63	0,9	733	265	14	17
64	0,73	620	311	27	28
65	0,85	564	323	35	36

101	0,87	666	362	33	33
102	0,75	528	254	14	46
103	0,87	526	269	27	30
104	0,63	752	248	17	35
105	0,63	788	260	43	15
106	0,76	540	377	37	36
107	0,71	578	250	22	14
108	0,93	657	406	14	18
109	0,67	593	247	43	40
110	0,73	600	383	43	31
111	0,89	664	408	26	26
112	0,86	765	275	31	12
113	0,97	742	272	23	43
114	0,8	783	266	29	11
115	0,69	731	273	26	24
116	0,74	748	296	38	24
117	0,85	799	249	30	21
118	0,71	798	289	20	27
119	0,73	588	337	24	14
120	0,95	780	310	20	19
121	0,71	562	369	32	44
122	0,73	755	267	43	34
123	0,79	766	341	31	44
124	0,77	788	349	16	38
125	0,7	577	250	34	31
126	0,65	734	246	31	24
127	0,81	605	287	8	36
128	0,88	573	297	39	11
129	0,65	800	393	40	26
130	0,92	742	265	11	22

Dengan keterangan:

RC = *Relative Compactness*

SA = *Surface Area* (Luas permukaan bangunan)

WA = *Wall Area* (Luas dinding)

HL = *Heating Load* (beban pemanasan)

CL = *Cooling Load* (beban pendinginan)