

Implementasi Metode Support Vector Machine Dengan Algoritma Genetika Pada Prediksi Konsumsi Energi Untuk Gedung Beton Bertulang

Asep Syaputra¹, Buhori Muslim², Nanda S. Prawira³, Edowinsyah⁴

¹³Program Studi Teknik Informatika, Institut Teknologi Pagar Alam, Indonesia

²Program Studi Teknik Informatika, Universitas Putra Indonesia (UNPI) Cianjur, Indonesia

⁴Program Studi Teknik Sipil, Institut Teknologi Pagar Alam, Indonesia

Article Info

Article history:

Received Sep xx, 20xx

Revised May xx, 20xx

Accepted Jun xx, 20xx

Keywords:

Algoritma Genetika
Support Vector Machine
Gedung Beton Bertulang
Konsumsi Energi

ABSTRACT

Informasi tentang konsumsi energi sangat penting dalam mengukur efisiensi energi dan penghematan energi dalam bangunan. Konsumsi energi ini mengacu pada jumlah energi yang dibutuhkan untuk memberi daya pada bangunan pada waktu tertentu. Dalam jangka panjang, penghematan energi dapat membantu mengurangi biaya dan juga memberikan manfaat bagi lingkungan dengan mengurangi emisi gas rumah kaca yang dihasilkan oleh bangunan. Oleh karena itu, memperoleh informasi konsumsi energi yang akurat sangat penting bagi semua pihak yang terlibat dalam perencanaan, pembangunan, dan pengelolaan bangunan. Selama beberapa dekade terakhir, konsumsi energi di bangunan terus meningkat di seluruh dunia, dan sebagian besar konsumsi energi ini berasal dari Pemanasan, Ventilasi, dan Penyejuk Udara (HVAC) di dalam bangunan. Untuk mengatasi masalah ini, penelitian dilakukan dengan membuat model mesin vektor dukungan yang menggunakan algoritma genetika untuk memprediksi konsumsi energi di bangunan secara akurat. Dalam penelitian ini, dua model mesin vektor dukungan diuji, yaitu support vector machine dan support vector machine yang menggunakan algoritma genetika. Hasil pengujian menunjukkan bahwa model support vector machine memberikan nilai RMSE sebesar 2,6. Selanjutnya, algoritma genetika digunakan untuk mengoptimalkan parameter C dan memilih variabel prediktor yang paling relevan, dan hasilnya adalah nilai RMSE sebesar 1,7 dan hanya 3 variabel prediktor yang dipilih. Pada tahap selanjutnya, optimasi parameter dan pemilihan fungsi dilakukan untuk mencapai nilai RMSE terendah yang mungkin, dan hasilnya adalah RMSE sebesar 1,537. Dengan menggabungkan SVM dan Algoritma Genetika, penelitian ini bertujuan untuk meningkatkan kualitas prediksi konsumsi energi untuk gedung beton bertulang. Dalam implementasi ini, SVM digunakan sebagai model prediksi utama, sementara Algoritma Genetika digunakan untuk menemukan parameter optimal SVM atau fitur-fitur yang relevan. Penelitian terbaru dalam domain ini telah menunjukkan bahwa penggabungan SVM dengan Algoritma Genetika dapat menghasilkan prediksi yang lebih akurat dibandingkan dengan metode standar. Pendekatan ini dapat membantu dalam perencanaan energi yang lebih efisien, pengurangan biaya operasional, dan pengoptimalan sumber daya di gedung beton bertulang. Namun, penting untuk memperhatikan bahwa implementasi ini mungkin memerlukan pemrosesan dan penggunaan sumber daya yang signifikan untuk menghasilkan hasil yang baik, tergantung pada ukuran dan kompleksitas dataset yang digunakan.

Copyright © 2023 Universitas Indraprasta PGRI.
All rights reserved.

Corresponding Author:

Asep Syaputra,
Teknik Informatika,
Institut Teknologi Pagar Alam,
JL. Simpang Bacang No.43, Karang Dalo, Dempo Tengah, Kota Pagar Alam, Sumatera Selatan, Indonesia.
Email: asepsyaputra68@itpa.ac.id

1. PENDAHULUAN

Peningkatan konsumsi energi yang terus meningkat menjadi masalah global yang membutuhkan solusi untuk mengurangi konsumsi energi dan emisi gas rumah kaca. Salah satu cara untuk mengurangi konsumsi energi adalah dengan membangun gedung yang lebih efisien secara energi [1]. Berdasarkan data terbaru yang dipublikasikan oleh Badan Standar Nasional Indonesia (SNI) 1726 - 2012 tentang seismik sejak Indonesia termasuk dalam negara rentan gempa berkekuatan besar, ditunjukkan platform atau kondisi gerak ekstrim percepatan di tanah dari banyak tempat di Indonesia jika diklasifikasi bisa kelas desain seismik D, E, atau F, yang dapat sangat mempengaruhi tindakan pekerjaan teknik sipil atau tempat lain struktur bangunan, dan bisa sangat berisiko runtuh dan mengancam jiwa manusia [2].

Untuk merancang struktur bangunan tinggi yang tahan gempa bumi, setidaknya struktur tersebut harus memiliki kekuatan dan perilaku yang baik di bawah beberapa tingkat pembebanan, termasuk beban gempa bumi yang paling penting [3]. Ketika gempa bumi terjadi, gaya yang sesuai dengan kekakuan struktur bekerja, dan struktur merespons hingga runtuh. Pada saat merancang bangunan tahan gempa bumi, diharapkan struktur dapat menahan beban gempa bumi secara memadai sehingga bangunan tidak akan rusak pada gempa bumi skala kecil dan sedang, dan bangunan tidak akan runtuh pada gempa bumi skala besar [4]. Peraturan gempa bumi terbaru adalah SNI 03-1726-2012 Target untuk mengubah peraturan pada tahun 2012 sebelumnya yaitu SNI 03-1726-2002. Adanya Peraturan ini melihat terjadinya fenomena seismik di Indonesia dengan tingkat kerusakannya infrastruktur yang substansial. Zona seismik No dibagi menjadi 6 zona seismik Mana yang lebih detail dari sebelumnya, respons spektral, akselerasi platform masuk daerah dengan risiko gempa rendah dari 0 hingga 0,15 g, zona risiko gempa rata-rata dari 0.15g ke 0.5g dan daerah dengan risiko gempa tinggi lebih besar dari 0,5 g [5].

SNI 03-1726-2012 menetapkan bahwa sistem struktur untuk menahan gaya horisontal, aksial, dan momen yang disebabkan oleh gempa bumi dapat dilakukan melalui sistem rangka yang mampu menahan momen. Sistem rangka ini terdiri dari komponen struktur dan konsumsi energi beton yang diperlukan untuk memberikan daya pada bangunan pada waktu tertentu [5]. Konsumsi energi bangunan menjadi semakin penting karena meningkatnya kekhawatiran tentang penggunaan energi yang tidak efisien dan dampak negatifnya terhadap lingkungan. Oleh karena itu, memprediksi konsumsi energi bangunan menjadi langkah penting dalam penghematan energi yang bermanfaat bagi individu dan masyarakat. Dengan memprediksi konsumsi energi, kita dapat merancang bangunan baru dengan lebih bijaksana dan meningkatkan efisiensi energi untuk menghemat energi dan mengurangi dampak lingkungan [6]. Ada banyak penelitian yang dilakukan untuk memprediksi konsumsi energi pada beton dengan tingkat akurasi yang tinggi menggunakan berbagai metode komputasi dan kumpulan data yang berbeda. Penelitian tersebut telah mengadopsi dua jenis metode perhitungan, yaitu metode variabel individual dan metode gabungan. Dalam mengoptimalkan setiap masalah, komputer dapat digunakan jika variabel yang terlibat dapat diubah menjadi bentuk elektronik. Dengan cara ini, solusi untuk masalah tersebut dapat diperoleh dengan mudah jika data terkait dengan masalah tersebut dapat diolah di komputer. Optimasi dapat dilakukan untuk memecahkan suatu masalah dengan mencari kondisi yang paling menguntungkan [7].

Menurut Asphalt Institute (1993), untuk mencapai kualitas perkerasan yang dibutuhkan, perhatian harus diberikan pada keberadaan agregat, yaitu bahan keras dan kaku yang digunakan sebagai campuran. Persyaratan campuran beton aspal atau ikatan beton aspal (AC - BC) adalah kekuatan, keawetan, kelenturan, kekuatan geser, kekuatan leleh, kemudahan pemrosesan, ketahanan air dan ekonomi. Untuk mengetahui tingkat kegunaan agregat yang digunakan dalam campuran pengaspalan dilakukan uji Marshall [8]. Dalam penelitian di Cina, metode decision tree digunakan untuk memprediksi tingkat konsumsi energi beton. Sementara itu, dalam penelitian lain di Cina, Li, Meng, dan rekan-rekan mereka menggunakan *Support Vector Machine* untuk memprediksi beban pendinginan per jam pada musim panas di sebuah gedung perkantoran. Di Yunani, Ekonomou melakukan penelitian yang menggunakan *Artificial Neural Network* untuk memprediksi konsumsi energi jangka panjang [9].

Support Vector Machine (SVM) merupakan algoritma yang berguna dalam menyelesaikan masalah dengan sampel kecil, non-linear, dan multidimensi. *SVM* bertujuan untuk meminimalkan risiko struktural daripada risiko empiris. *SVM* digunakan untuk memetakan data dalam ruang input dengan cara nonlinier ke dalam ruang fitur multidimensi, dimana optimalisasi klasifikasi model menggunakan *hyperplane linear*. Saat menggunakan *SVM*, terdapat dua masalah yang perlu diatasi, yaitu memilih fitur yang optimal untuk *SVM* dan mengatur parameter terbaik. Pemilihan fitur yang tepat dapat mempengaruhi kecocokan parameter, dan sebaliknya, fitur yang tidak relevan akan mengurangi akurasi classifier [10]. Untuk meningkatkan efisiensi dan akurasi classifier, beberapa fitur harus dihilangkan. Selain itu, pengaturan parameter yang tepat juga sangat penting dalam meningkatkan akurasi pengklasifikasi *SVM*. Parameter kunci dalam *SVM* harus disesuaikan agar akurasi klasifikasi atau regresi yang dihasilkan optimal [11].

Metode *Support Vector Machine (SVM)* telah digunakan dalam banyak bidang, termasuk dalam prediksi konsumsi energi gedung. *SVM* dapat memproses data dengan dimensi tinggi dan dapat menangani masalah regresi dengan baik. Namun, *SVM* memiliki beberapa kekurangan, seperti sensitif terhadap parameter dan memiliki tingkat *error* yang tinggi. Algoritma genetika (GA) adalah teknik optimisasi yang dapat membantu meningkatkan performa *SVM* dengan mengoptimalkan parameter *SVM* [12]. Untuk memperoleh prediksi yang lebih akurat dari *Support Vector Machine*, perlu dilakukan optimasi parameter seperti jumlah unit *hidden layer and learning rate*. Algoritma Genetika digunakan untuk mencari parameter-parameter tersebut secara efisien. Prinsip dasar dari algoritma genetika adalah mencari keturunan yang lebih baik melalui proses seleksi yang mirip dengan seleksi alam, dan tujuan utamanya adalah untuk menemukan nilai optimal dari parameter model *SVM*. Algoritma Genetika sangat sesuai untuk mengoptimalkan parameter manifold dan multi-objektif dalam pengujian Marshall dengan menentukan struktur dan parameter optimal untuk model *SVM* [13].

2. METODE PENELITIAN

Pemilihan fitur digunakan untuk mengidentifikasi subset dari prediktor yang kuat dalam database dan mengurangi jumlah prediktor yang digunakan dalam proses perhitungan [14]. Hal ini mempengaruhi berbagai aspek dari model klasifikasi, termasuk akurasi algoritma klasifikasi yang dilatih, waktu yang diperlukan untuk melatih *classifier*, jumlah contoh yang diperlukan untuk melatih model, dan biaya yang terkait dengan fungsi tersebut. Terkadang tidak semua prediktor sama pentingnya dalam aplikasi tertentu dan efisiensi yang lebih baik dapat dicapai dengan menghapus beberapa prediktor yang tidak relevan atau mengganggu. Oleh karena itu, kami melakukan pemilihan fitur dengan cara menghilangkan data yang tidak berguna seperti noise, outlier, dan redundansi, sambil tetap menjaga integritas data yang relevan dan berguna. Data mining digunakan sebagai proses untuk mengatasi masalah dengan menganalisis data yang ada dalam database. Data mining didefinisikan sebagai proses untuk menemukan pola dalam data. Data mining, yang juga dikenal sebagai *Knowledge Discovery In Database (KDD)*, adalah kegiatan untuk mengumpulkan dan menggunakan data historis untuk menemukan keteraturan, pola, atau hubungan dalam kumpulan data yang besar.

2.1. Support Vector Machine (SVM)

Pada tahun 1992, Vapnik bersama rekannya Bernhard Boser dan Isabelle Guyon memperkenalkan *Support Vector Machine (SVM)*. Algoritma *SVM* dapat meningkatkan dimensi data pelatihan asli dengan menggunakan pemetaan nonlinier, sehingga dapat menemukan *hyperplane* untuk dekomposisi linier. Dalam teknik ini, *SVM* menggunakan support vector dan margin untuk mencari fungsi *classifier* terbaik yang dapat memisahkan dua kelas yang berbeda. *SVM* bertujuan untuk mencari fungsi pemisah terbaik yang dapat membedakan dua jenis objek dan *hyperplane* terbaik adalah yang berada di tengah kumpulan objek dari dua kelas [15]. Teknik ini telah digunakan secara luas dalam klasifikasi dan regresi, dan *SVM* adalah model matematis yang dapat memisahkan dua kelas atau lebih dari data dengan menggunakan *hyperplane* di ruang fitur.

SVM berfungsi dengan mencari *hyperplane* dengan margin terbesar antara kedua kelas, di mana margin dihitung sebagai jarak antara *hyperplane* dan titik-titik data terdekat dari setiap kelas. *SVM* juga dapat digunakan untuk mengatasi masalah *overfitting* dengan menambahkan parameter yang disebut dengan "C", yang mengontrol trade-off antara margin dan kesalahan klasifikasi. Selain itu, *SVM* dapat menangani masalah regresi dengan memperkenalkan fungsi kernel, yang dapat mengubah data ke dalam ruang fitur yang lebih tinggi [16]. Fungsi kernel dapat membantu *SVM* menemukan hubungan yang lebih kompleks antara data.

Beberapa keuntungan dari *SVM* adalah [16]:

- *SVM* dapat menangani data dengan dimensi tinggi
- *SVM* dapat menangani kasus di mana jumlah sampel jauh lebih sedikit dibandingkan dengan jumlah fitur
- *SVM* dapat menghasilkan model yang akurat dan stabil

SVM menemukan *hyperplane* yang paling sesuai dengan memaksimalkan jarak atau margin antara dua set kelas yang berbeda. Dalam *SVM* untuk klasifikasi linier, masalah optimisasi dapat dirumuskan sebagai berikut.

$$\text{min} \frac{1}{2} \|\omega\|^2 \quad (1)$$

Subject to

$$y_i(\omega x_i + b) \geq 1, i=1, \dots, \lambda \quad (2)$$

Langkah-langkah umum untuk melakukan pengklasifikasian menggunakan metode SVM adalah sebagai berikut:

1. Persiapan data Langkah ini meliputi pengumpulan data, preprocessing data, dan pemilihan fitur. Data yang telah dikumpulkan kemudian diproses untuk menghilangkan noise, missing value, atau outlier. Selain itu, fitur-fitur yang tidak penting juga dapat dihapus agar model SVM lebih efisien.
2. Pembagian data menjadi data latih dan data uji Data latih digunakan untuk melatih model SVM, sedangkan data uji digunakan untuk menguji performa model SVM.
3. Pelatihan model SVM Model SVM dilatih dengan menggunakan data latih. Pada saat pelatihan, SVM mencari hiperplane terbaik untuk memisahkan dua kelas atau lebih dari data.
4. Validasi model Model SVM yang telah dilatih kemudian diuji dengan menggunakan data uji. Hasil prediksi SVM kemudian dibandingkan dengan label kelas yang sebenarnya untuk mengukur performa model SVM.
5. Optimisasi parameter Jika performa model SVM masih belum memuaskan, parameter SVM dapat diatur ulang agar model SVM lebih baik. Parameter-parameter yang dapat diatur ulang antara lain C (*penalty parameter*), kernel (fungsi kernel), dan gamma (parameter kernel).
6. Penggunaan model SVM Setelah model SVM telah diuji dan dinyatakan baik, model dapat digunakan untuk memprediksi kelas atau nilai pada data yang belum diketahui.
7. Evaluasi model SVM Setelah digunakan, model SVM dapat dievaluasi kembali untuk memastikan apakah model masih memiliki performa yang baik. Jika model tidak memiliki performa yang baik, maka langkah-langkah sebelumnya dapat diulangi untuk meningkatkan performa model SVM.

2.2. Algoritma Genetika

Algoritma genetika adalah algoritma optimasi yang terinspirasi oleh prinsip-prinsip evolusi dalam alam. Prinsip utama dari algoritma genetika adalah seleksi alamiah dan rekombinasi genetik, dimana individu-individu yang paling cocok atau fit untuk lingkungan akan diwariskan gen-gennya untuk generasi berikutnya. Dalam konteks prediksi konsumsi energi untuk gedung beton bertulang, algoritma genetika digunakan untuk mencari parameter-parameter terbaik dalam model prediksi konsumsi energi dengan metode *Support Vector Machine (SVM)* [17].

Parameter-parameter yang dioptimalkan melalui algoritma genetika adalah parameter C dan gamma pada kernel *RBF (Radial Basis Function)* pada SVM. Parameter C mengontrol tingkat toleransi terhadap kesalahan dalam model, sedangkan parameter gamma mengontrol lebar fungsi kernel. Proses optimasi parameter dimulai dengan membuat populasi awal yang terdiri dari sejumlah kandidat solusi acak. Setiap kandidat solusi diberi skor berdasarkan akurasi dalam memprediksi konsumsi energi pada data training. Kemudian, kandidat solusi dengan skor terbaik akan diturunkan menjadi solusi baru untuk generasi berikutnya melalui rekombinasi dan mutasi genetik. Proses ini berulang-ulang hingga mencapai kondisi terminasi yang ditentukan sebelumnya, seperti jumlah iterasi atau nilai tertentu dari nilai fitness [18].

Dengan menggunakan algoritma genetika pada SVM, model prediksi konsumsi energi untuk gedung beton bertulang dapat menghasilkan akurasi yang lebih baik dibandingkan dengan SVM tanpa algoritma genetika. Selain itu, penggunaan algoritma genetika pada SVM juga dapat mempercepat waktu pelatihan model dan mengurangi overfitting. Namun, perlu diingat bahwa proses optimasi parameter pada algoritma genetika dapat memerlukan waktu yang cukup lama dan membutuhkan sumber daya komputasi yang cukup besar. Oleh karena itu, pemilihan parameter yang tepat sangat penting untuk mengoptimalkan penggunaan algoritma genetika dalam prediksi konsumsi energi untuk gedung beton bertulang.

2.3. Desain Penelitian

Desain penelitian Implementasi *Metode Support Vector Machine* dengan Algoritma Genetika pada Prediksi Konsumsi Energi untuk Gedung Beton Bertulang dapat dirancang dengan langkah-langkah sebagai berikut:



Gambar 1. Desain Penelitian

1. Tujuan Penelitian: Tujuan dari penelitian ini adalah untuk menguji efektivitas implementasi metode Support Vector Machine dengan Algoritma Genetika dalam memprediksi konsumsi energi untuk gedung beton bertulang.
2. Data: Data yang digunakan dalam penelitian ini adalah data konsumsi energi gedung beton bertulang yang dikumpulkan dari beberapa gedung di daerah tertentu. Data ini harus lengkap dengan variabel input seperti luas bangunan, jenis penggunaan gedung, waktu pemakaian, kondisi cuaca, dan variabel output berupa konsumsi energi.
3. Metode: Metode yang digunakan dalam penelitian ini adalah metode Support Vector Machine dengan Algoritma Genetika. Proses pemodelan akan dilakukan dengan cara membagi data menjadi dua bagian, yaitu data training dan data testing. Data training digunakan untuk membangun model prediksi, sedangkan data testing digunakan untuk menguji akurasi model yang dibangun.
4. Proses Optimasi: Proses optimasi dilakukan dengan menggunakan algoritma genetika untuk mencari parameter-parameter terbaik dalam model prediksi konsumsi energi. Parameter-parameter yang dioptimalkan melalui algoritma genetika adalah parameter C dan gamma pada kernel RBF pada SVM. Proses optimasi parameter dilakukan pada data training.
5. Analisis Hasil: Analisis hasil dilakukan dengan membandingkan akurasi model yang dibangun dengan menggunakan metode Support Vector Machine dengan Algoritma Genetika dengan akurasi model yang dibangun tanpa menggunakan algoritma genetika. Akurasi model dievaluasi dengan menggunakan metrik-metrik seperti Mean Squared Error (MSE) atau R-squared.
6. Kesimpulan: Kesimpulan dari penelitian ini adalah menunjukkan efektivitas implementasi metode Support Vector Machine dengan Algoritma Genetika dalam memprediksi konsumsi energi untuk gedung beton bertulang. Hasil penelitian dapat digunakan sebagai panduan untuk meningkatkan efisiensi energi pada gedung beton bertulang dengan mengoptimalkan penggunaan energi.
7. Saran: Saran yang diberikan adalah mengembangkan penelitian ini dengan mempertimbangkan variabel lain yang dapat mempengaruhi konsumsi energi pada gedung beton bertulang, seperti jenis bahan bangunan dan orientasi bangunan. Selain itu, penelitian dapat dilakukan dengan menggunakan data yang lebih luas dan diversifikasi jenis gedung beton bertulang yang digunakan sebagai sampel penelitian.

2.4. Pengumpulan Data

Pengumpulan data dapat dilakukan dengan mengumpulkan informasi dari sumber literatur atau mengambil data dari gedung beton bertulang yang telah dibangun sebelumnya. Data yang dikumpulkan meliputi variabel-variabel yang telah diidentifikasi sebelumnya. Identifikasi variabel yang berpengaruh pada konsumsi energi gedung beton bertulang, seperti luas bangunan, orientasi gedung, material dinding, jumlah jendela, jenis sistem pendingin, dan sebagainya. Data yang dipergunakan dalam penelitian ini merupakan data sekunder yang didapatkan dari *UCI machine learning repository* berkenaan dengan *Energy efficiency*. Terdapat 768 bangunan yang terdiri dari 12 jenis bentuk yang berbeda, di mana beberapa bangunan memiliki area kaca dan beberapa yang lain tidak. Parameter-parameter yang digunakan dalam penelitian ini meliputi faktor perilaku energi bangunan, konstruksi bangunan dan analisis sifat termal bahan fisik, seperti kepadatan relatif, luas wilayah, area dinding, area atap, total tinggi bangunan, orientasi, area kaca dan beban pendinginan.

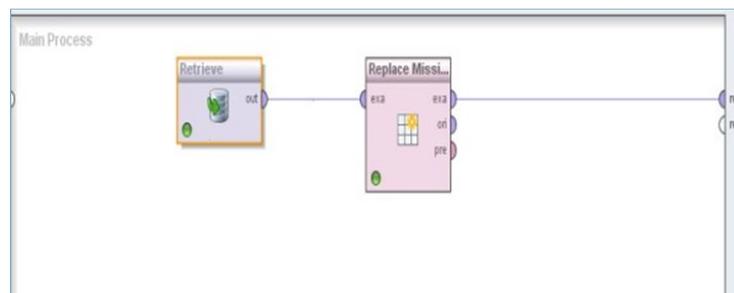
Tabel 1. Data Efisiensi Konsumsi Energi Bangunan

No	Kepadatan Relatif	Luas Wilayah	Area Dinding	Area Atap	Total Tinggi Bangunan	Orientasi	Area Kaca	Beban Pendinginan
1	0,9	514,5	294,1	110,2	7,0	2	0	21,3
2	0,9	514,5	294,1	110,2	7,0	3	0	21,3
3	0,9	514,5	294,1	110,2	7,0	4	0	21,3
4	0,9	514,5	294,1	110,2	7,0	5	0	21,3
5	0,9	514,5	294,1	110,2	7,0	2	0,1	26,47
6	0,9	514,5	294,1	110,2	7,0	3	0,1	26,37
7	0,9	514,5	294,1	110,2	7,0	4	0,1	26,44
8	0,9	514,5	294,1	110,2	7,0	5	0,1	26,29
9	0,9	514,5	294,1	110,2	7,0	2	0,1	25,95
10	0,9	514,5	294,1	110,2	7,0	3	0,1	25,63

2.5. Pengolahan Data

Data yang tidak memiliki nilai dalam setiap dataset akan dihapus dan tidak dipergunakan, sebagai bagian dari usaha untuk memperoleh data yang berkualitas. Beberapa teknik yang dapat digunakan untuk mencapai hal tersebut adalah sebagai berikut:

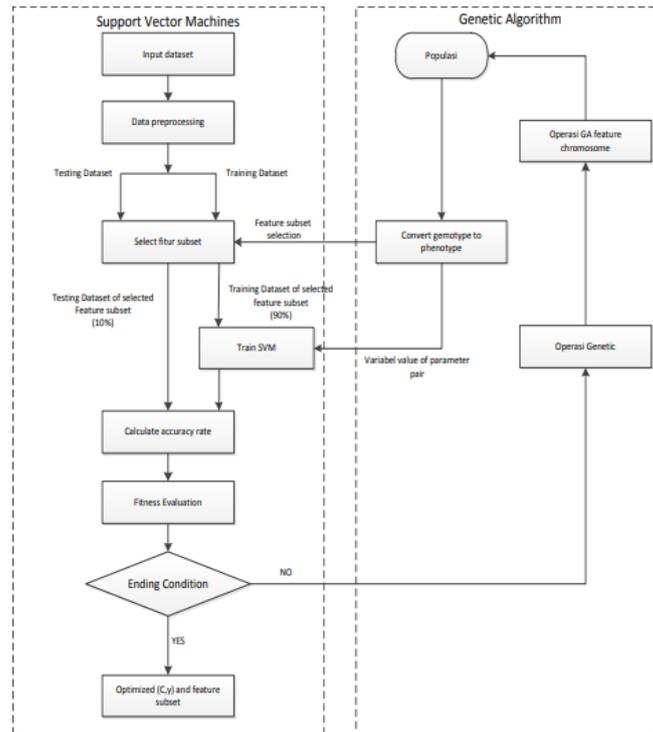
1. Validasi data dapat menunjukkan bahwa kualitas data input tidak memuaskan karena kurang lengkap, terdapat kebisingan atau ketidaksesuaian. Untuk mengatasi masalah tersebut, dapat dilakukan identifikasi, perbaikan, dan penghapusan data yang aneh (*outlier/noise*), data yang tidak konsisten, serta data yang tidak lengkap (*Missing Value*).
2. Integrasi dan transformasi data dilakukan untuk meningkatkan akurasi dan efisiensi algoritma. Data yang digunakan dalam penulisan ini memiliki nilai numerik dan kemudian ditransformasikan ke dalam perangkat lunak *Rapidminer*.
3. Reduksi ukuran data dan diskritisasi dilakukan untuk mendapatkan dataset yang memiliki jumlah atribut dan catatan yang lebih sedikit namun tetap memberikan informasi yang signifikan.



Gambar 2. Skema Pengganti Data yang Hilang

2.6. Model yang Direkomendasikan

Dalam fase pemodelan, terdapat dua jenis data yang diproses yaitu data latihan (90%) dan data uji (10%). Pada tahap ini, akan dijelaskan mengenai teknik algoritma yang diujikan dengan memasukkan data penggunaan energi, kemudian dianalisis dan dibandingkan. Berikut adalah deskripsi dari teknik algoritma yang akan diujikan.



Gambar 3. Model yang Direkomendasikan

2.7. Evaluasi Model

Studi ini terdiri dari tahapan eksperimen dan pengujian model dengan menggunakan kumpulan data efisiensi energi dari UCI Repository pada aplikasi RapidMiner 5. Pada tahap eksperimen, *Software* dan *Hardware* tertentu digunakan sebagai bantuan, yang terperinci dalam Tabel 2.

Tabel 2. Parameter *Software* dan *Hardware*

<i>Software</i>	<i>Hardware</i>
Versi Sistem Operasi:	Prosesor: Intel
Microsoft Windows 7	Pentium Dual Core
Pengolahan Data:	Memory : 4 GB
RapidMiner Versi 5	Hardisk : 500 GB

2.7. Uji Coba dan Validasi

Output yang dihasilkan dari penelitian ini adalah proses validasi pada model yang telah digunakan. Validasi dilakukan untuk mengevaluasi model prediksi yang dianggap optimal dengan menghitung kesalahan prediksi menggunakan nilai *Root Mean Square Error (RMSE)*. Validasi ini dilakukan dengan menghitung nilai *Root Mean Square Error (RMSE)* yang merupakan salah satu metrik evaluasi yang umum digunakan untuk model prediksi. *RMSE* mengukur rata-rata perbedaan antara nilai prediksi dengan nilai observasi yang sebenarnya dalam skala yang sama. Semakin rendah nilai *RMSE*, semakin baik performa model prediksi. Hasil dari proses validasi ini akan memberikan indikasi apakah model yang telah digunakan optimal atau perlu diperbaiki lagi. Jika hasil validasi menunjukkan nilai *RMSE* yang rendah, maka model tersebut dapat digunakan untuk memprediksi data baru dengan tingkat akurasi yang tinggi. Namun, jika nilai *RMSE* tinggi, maka model tersebut perlu diperbaiki atau dimodifikasi untuk meningkatkan performanya.

3. HASIL DAN PEMBAHASAN

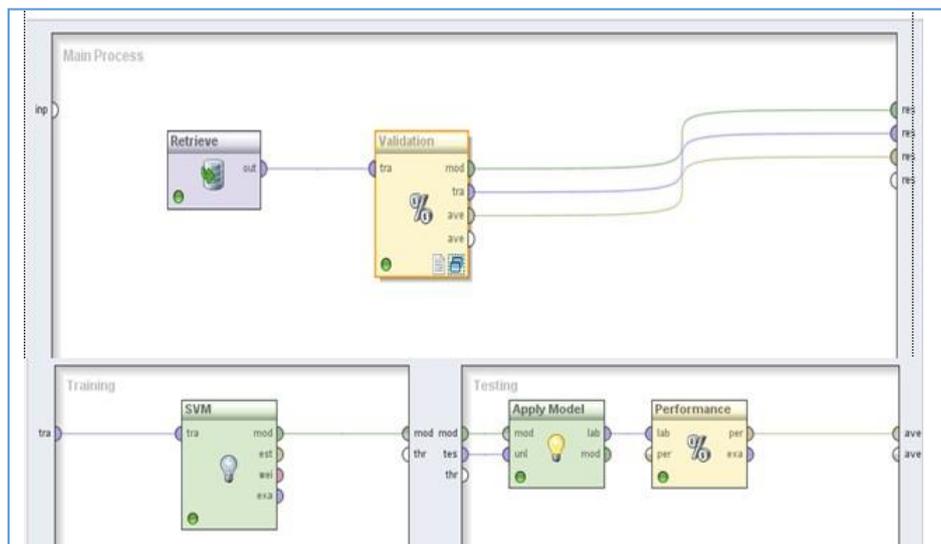
Penelitian ini bertujuan untuk memvalidasi model yang digunakan, dimana validasi tersebut dilakukan dengan tujuan untuk mengevaluasi keakuratan model prediksi yang dianggap optimal, dengan memperhatikan nilai *Root Mean Square Error (RMSE)* sebagai indikator kesalahan prediksi. Dengan melakukan proses validasi tersebut, diharapkan dapat memastikan bahwa model tersebut dapat memberikan hasil prediksi yang akurat. Dalam hal ini, model akan diuji dengan menggunakan teknik validasi yang relevan guna memastikan hasilnya dapat diandalkan dan *valid*. Selain itu, nilai *RMSE* akan dijadikan acuan dalam mengukur tingkat akurasi model prediksi tersebut. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan kontribusi yang signifikan bagi pengembangan dan peningkatan kualitas model prediksi yang lebih baik di masa depan.

3.1. Hasil Uji dan Implementasi Metode

Hasil uji dan implementasi metode merupakan bagian penting dari suatu penelitian, khususnya dalam bidang ilmu komputer dan teknologi informasi. Pada tahap ini, peneliti akan melakukan uji coba dan evaluasi terhadap metode atau teknik yang telah dikembangkan. Tujuannya adalah untuk memastikan bahwa metode tersebut dapat bekerja secara efektif dan efisien, serta memberikan hasil yang akurat dan valid. Hasil uji dan implementasi metode ini sangat penting untuk menentukan apakah metode yang dikembangkan dapat digunakan secara luas atau tidak. Selain itu, hasil uji dan implementasi metode juga dapat memberikan masukan bagi peneliti dalam pengembangan metode yang lebih baik dan efektif di masa depan. Oleh karena itu, hasil uji dan implementasi metode merupakan tahap krusial dalam suatu penelitian dan harus dilakukan dengan teliti dan cermat.

3.1.1 Pendekatan Dengan Metode SVM

Untuk mengevaluasi kinerja algoritma *Support Vector Machine*, dilakukan pengujian dengan menggunakan teknik *K-Fold Cross Validation*. Pengujian ini melibatkan penggunaan data testing yang dipilih secara hati-hati untuk memastikan bahwa data tersebut dapat mewakili keseluruhan data yang tersedia. Hasil dari pengujian ini diolah dengan bantuan aplikasi *RapidMiner*, sehingga memudahkan dalam analisis dan visualisasi dari hasil yang diperoleh. Dengan demikian, penggunaan teknik *K-Fold Cross Validation* dan aplikasi *RapidMiner* dapat membantu dalam memperoleh hasil pengujian yang lebih akurat dan efisien.

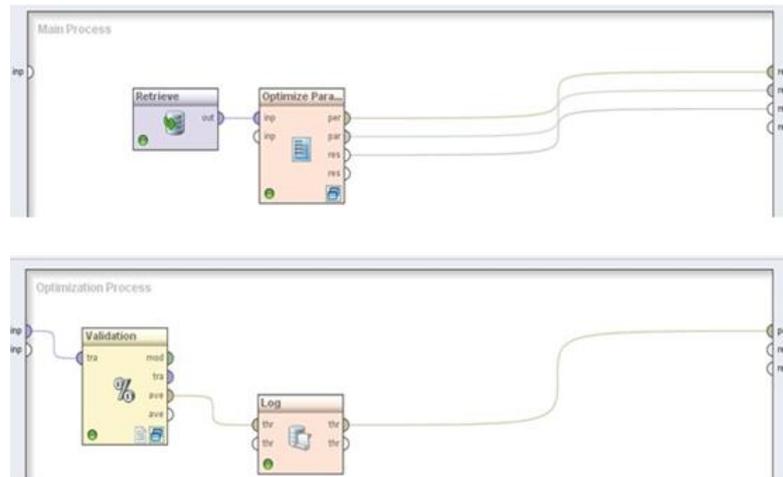


Gambar 4. Evaluasi menggunakan Teknik *K-Fold Cross Validation* Pada Algoritma *Support Vector Machine*

Setelah melalui serangkaian pengujian yang dilakukan dengan menggunakan metode *Support Vector Machine*, diperoleh hasil evaluasi berupa nilai *Root Mean Square Error (RMSE)* sebesar 2.613. Dengan adanya hasil pengujian ini, dapat membantu dalam memperbaiki kualitas dan akurasi dari model prediksi yang digunakan untuk mendukung pengambilan keputusan yang lebih tepat dan akurat.

3.1.2 Optimasi Parameter *Support Vector Machines* dengan Algoritma Genetika

Di bawah ini terdapat ilustrasi hasil pengujian algoritma *Support Vector Machine* berbasis *Genetic Algorithm* untuk melakukan optimasi parameter, yang dilakukan dengan menggunakan teknik *K-Fold Cross Validation* dan aplikasi *RapidMiner*. Teknik *K-Fold Cross Validation* digunakan untuk menguji dan mengevaluasi kinerja model prediksi yang dihasilkan oleh algoritma tersebut, sementara optimasi parameter dilakukan dengan memanfaatkan algoritma genetika. Hasil pengujian ini dapat memberikan informasi yang berguna dalam meningkatkan kualitas dan akurasi model prediksi.

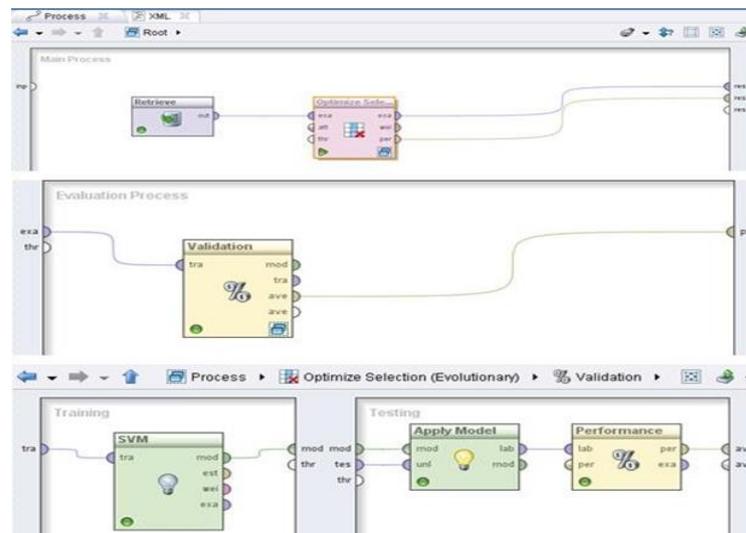


Gambar 5. Pengujian Optimasi Parameter *Support Vector Machine* dengan Pendekatan Algoritma Genetika

Dalam rangka meningkatkan kinerja dan akurasi prediksi dari model mesin *vector* pendukung, dilakukan suatu eksperimen untuk melakukan pemilihan parameter C dan γ dengan menggunakan teknik *Genetic Algorithm*. Pengujian dilakukan dengan tujuan untuk mendapatkan parameter terbaik yang dapat meminimalkan nilai *Root Mean Square Error (RMSE)*. Setelah melalui serangkaian pengujian, didapatkan hasil evaluasi berupa nilai *RMSE* sebesar 1.825.

3.1.3 Metode Seleksi Fitur *Support Vector Machines* Menggunakan Algoritma Genetika

Berikut ini adalah ilustrasi pengujian algoritma *Support Vector Machine* yang didasarkan pada teknik *Genetic Algorithm* untuk melakukan seleksi fitur pada model. Pengujian ini menggunakan teknik *K-Fold Cross Validation* untuk memastikan keakuratan dan keandalan dari model. Untuk melakukan pengujian tersebut, digunakan aplikasi *Rapid Miner* sebagai sarana utama untuk menganalisis data dan memvisualisasikan hasil dari eksperimen.



Gambar 6. Pengujian Seleksi Fitur *Support Vector Machine* menggunakan Metode Algoritma Genetika

Dalam penelitian ini, dilakukan seleksi atribut atau fitur yang akan digunakan dalam model prediksi. Fitur-fitur tersebut dipilih berdasarkan relevansinya dalam mempengaruhi beban pendinginan pada bangunan. Proses seleksi fitur dilakukan dengan mempertimbangkan nilai korelasi antara setiap atribut dan target yang ingin diprediksi. Berdasarkan analisis tersebut, fitur yang terpilih meliputi kepadatan relatif (*relative compactness*), luas wilayah (*surface area*), area dinding (*wall area*), area atap (*roof area*), total tinggi bangunan (*overall height*), orientasi (*orientation*), dan area kaca (*glazing area*). Selain itu, satu atribut juga dijadikan sebagai label yaitu beban pendinginan (*cooling load*) yang menjadi target prediksi dari model yang dikembangkan.

Role	Name	Type	Statistics	Range	Missings
label	coolingload	real	avg = 24.296 +/- 9.648	[11.270 ; 46.230]	0
regular	relativecompactness	real	avg = 0.763 +/- 0.103	[0.620 ; 0.980]	0
regular	surfacearea	numeric	avg = 672.280 +/- 86.520	[514.500 ; 808.500]	0
regular	wallarea	numeric	avg = 317.275 +/- 41.842	[245.000 ; 416.500]	0
regular	roofarea	numeric	avg = 177.502 +/- 44.442	[110.250 ; 220.500]	0
regular	overallheight	numeric	avg = 5.250 +/- 1.759	[3.500 ; 7.000]	0
regular	orientation	integer	avg = 3.430 +/- 1.047	[2.000 ; 5.000]	0
regular	glazingarea	numeric	avg = 0.226 +/- 0.138	[0.000 ; 0.400]	0

Gambar 7. Ekstraksi Fitur Terbaik sebelum Evaluasi

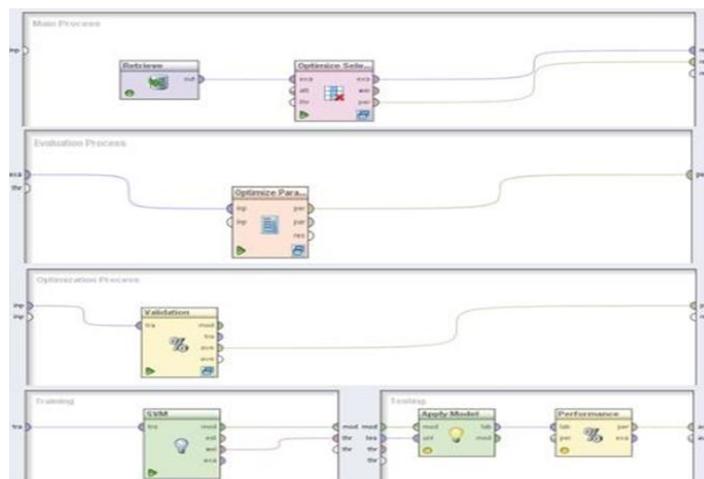
Dari 7 variabel prediktor, dipilih 3 atribut yang memiliki pengaruh terhadap beban pendinginan (*cooling load*) dengan nilai *RMSE* sebesar 1.767, yaitu *wall area*, *overall height*, dan *glazing area*. Hasil seleksi atribut ini menunjukkan bahwa wall area, overall height, dan glazing area merupakan faktor-faktor yang paling signifikan dalam mempengaruhi beban pendinginan (*cooling load*) pada sistem yang sedang diuji. Oleh karena itu, ketiga atribut ini dapat dijadikan fokus dalam pengembangan sistem yang lebih optimal dan efisien. Selain itu, penggunaan teknik seleksi atribut ini juga dapat membantu dalam mempercepat waktu komputasi dan mengurangi kompleksitas model yang digunakan.

Role	Name	Type	Statistics	Range	Missings
label	coolingload	real	avg = 24.588 +/- 9.513	[10.900 ; 48.030]	0
regular	wallarea	numeric	avg = 318.500 +/- 43.626	[245.000 ; 416.500]	0
regular	overallheight	numeric	avg = 5.250 +/- 1.751	[3.500 ; 7.000]	0
regular	glazingarea	numeric	avg = 0.234 +/- 0.133	[0.000 ; 0.400]	0

Gambar 8. Ekstraksi Fitur Optimal setelah Pengujian

3.1.3 Seleksi Fitur dan Optimasi Parameter *Support Vector Machines* dengan Algoritma Genetika

Setelah melakukan seleksi fitur dan parameter, langkah selanjutnya adalah melakukan pengujian dengan menggunakan algoritma genetika untuk memperoleh nilai *RMSE* yang optimal. Dalam pengujian ini, digunakan algoritma *Support Vector Machine* berbasis *Genetic Algorithm* untuk melakukan seleksi fitur dan parameter. Dalam proses pengujian ini, dilakukan iterasi sebanyak beberapa kali dengan variasi parameter dan fitur yang berbeda-beda. Hasil pengujian kemudian dianalisis untuk memilih kombinasi fitur dan parameter yang paling optimal. Dengan menggunakan teknik ini diharapkan dapat ditemukan model prediksi yang lebih akurat dan efisien. Pengujian dilakukan dengan menggunakan aplikasi Rapid Miner seperti yang ditunjukkan dalam gambar berikut:



Gambar 9. Pengujian Optimasi Fitur dan Parameter *Support Vector Machines* dengan Pendekatan Algoritma Genetika

Hasil pengukuran *RMSE* sebesar 1.537 menunjukkan bahwa model prediksi yang telah dikembangkan mampu memberikan estimasi beban pendinginan (*cooling load*) dengan akurasi yang baik. Hal ini menunjukkan bahwa penggunaan teknik seleksi fitur dan parameter dengan algoritma genetika pada *Support Vector Machine* dapat meningkatkan kinerja model prediksi dan menghasilkan nilai *RMSE* yang lebih rendah dibandingkan dengan

model prediksi yang tidak mengalami seleksi fitur dan parameter. Dalam konteks aplikasi praktis, peningkatan kinerja model prediksi ini dapat memberikan manfaat yang signifikan, seperti penghematan biaya dan energi pada sistem pendinginan, serta peningkatan kualitas dan kenyamanan lingkungan di dalam gedung atau bangunan.

3.2. Evaluasi dan Validasi Hasil

Beban pendinginan (*cooling load*) memiliki peranan yang penting dalam memprediksi konsumsi energi pada bangunan. Berdasarkan hasil pengujian, nilai *RMSE* sebesar 2.613 menunjukkan bahwa metode *Support Vector Machine* dapat dijadikan sebagai alat prediksi yang efektif untuk memproyeksikan konsumsi energi pada bangunan. Hal tersebut mengindikasikan bahwa faktor-faktor yang mempengaruhi beban pendinginan dapat menjadi acuan dalam mengestimasi konsumsi energi pada bangunan dengan metode *Support Vector Machine*. Meskipun nilai *RMSE* tersebut masih terbilang tinggi, namun penggunaan metode ini dapat ditingkatkan dengan melakukan penyesuaian pada parameter dan fitur yang digunakan agar menghasilkan prediksi yang lebih akurat.

Tahapan berikutnya melibatkan penggunaan algoritma genetika untuk memaksimalkan nilai C dan γ dalam rangka mengoptimalkan nilai *RMSE* menjadi 1,825. Selain itu, algoritma genetika juga digunakan untuk melakukan seleksi fitur, yang menghasilkan *RMSE* sebesar 1,767. Dalam seleksi fitur, dari 7 variabel prediktor, yakni *relative compactness*, *surface area*, *wall area*, *roof area*, *overall height*, *orientation*, dan *glazing area*, hanya 3 atribut yang terpilih, yaitu *wall area*, *overall height*, dan *glazing area*, yang mempengaruhi *cooling load*. Selanjutnya, dilakukan optimasi parameter dan seleksi fitur untuk mencari nilai *RMSE* yang paling optimal, dan diperoleh nilai sebesar 1,537.



Gambar 10. Grafik Validasi Hasil Optimasi Fitur dan Parameter *Support Vector Machines*

Penelitian ini memiliki implikasi yang signifikan pada prediksi konsumsi energi bangunan beton bertulang. Implikasi ini mencakup beberapa aspek, seperti pengurangan biaya operasional bangunan, peningkatan kenyamanan lingkungan, dan pengurangan dampak negatif pada lingkungan. Selain itu, hasil penelitian ini dapat menjadi acuan bagi pengembangan teknologi energi yang lebih efisien dan berkelanjutan pada bangunan. Implikasi lainnya adalah pentingnya penggunaan metode *support vector machine* dan algoritma genetika untuk meningkatkan akurasi dan efektivitas dalam prediksi konsumsi energi pada bangunan beton bertulang.

Dari implikasi terhadap aspek system berdasarkan hasil evaluasi, terbukti bahwa penerapan Algoritma Genetika pada *Support Vector Machines (SVM)* untuk seleksi fitur dan optimasi parameter dapat menunjukkan atribut yang mempengaruhi hasil prediksi konsumsi energi dengan nilai error paling kecil. Oleh karena itu, metode *SVM* berbasis Algoritma Genetika dapat dianggap sebagai metode yang efektif dalam klasifikasi data. Hasil ini menunjukkan bahwa penerapan Algoritma Genetika pada *SVM* dapat menjadi solusi dalam memprediksi konsumsi energi bangunan beton bertulang dan membantu arsitek bangunan dalam merancang bangunan baru yang hemat energi. Di Indonesia, teknik ini dapat diterapkan oleh Kementerian Pekerjaan Umum.

Penggunaan Algoritma Genetika pada *Support Vector Machine (SVM)* melalui *software RapidMiner* dapat memberikan kontribusi dalam pengambilan keputusan dalam merancang bangunan beton bertulang. Hal ini menekankan pentingnya kemampuan manajerial dari arsitek bangunan untuk merencanakan perancangan bangunan baru secara lebih efektif. Dalam konteks penelitian, penerapan Algoritma Genetika pada *SVM* dapat digunakan untuk mengevaluasi kehandalan metode tersebut. Oleh karena itu, penelitian selanjutnya sebaiknya melibatkan penggunaan lebih dari satu dataset untuk meningkatkan validitas hasil. Penelitian semacam ini dapat diaplikasikan pada unit bisnis lain yang serupa. Selain itu, metode lain seperti *Neural Network*, *Decision Tree*, *C4.5* dan sejenisnya dapat digunakan untuk pengembangan lebih lanjut.

4. PENUTUP

SVM yang didasarkan pada Algoritma Genetika digunakan untuk melakukan seleksi atribut dari 7 variabel prediktor yang tersedia. Dalam hal ini, penggunaan Algoritma Genetika dapat membantu memilih atribut yang paling berpengaruh dalam memprediksi konsumsi energi pada bangunan. Dari hasil eksperimen pada data *set energy efficiency UCI*, terdapat perbedaan signifikan antara nilai rata-rata *RMSE* sebelum dan setelah dilakukan seleksi atribut dan optimasi parameter dengan Algoritma Genetika. Hal ini menunjukkan bahwa penggunaan *SVM* dengan Algoritma Genetika dapat meningkatkan akurasi dalam memprediksi konsumsi energi bangunan beton bertulang dengan nilai *error* terkecil. Peningkatan akurasi dalam memprediksi konsumsi energi bangunan beton bertulang dapat membantu arsitek dan insinyur dalam merancang bangunan yang lebih efisien dan ramah lingkungan. Selain itu, penelitian ini dapat memberikan kontribusi pada pengembangan teknologi dan metode dalam bidang arsitektur dan teknik sipil, khususnya dalam penggunaan teknologi *SVM* dan Algoritma Genetika untuk analisis data pada bangunan dan infrastruktur. Hasil penelitian ini dapat memberikan pemahaman yang lebih baik mengenai bagaimana data dapat digunakan untuk memperbaiki keefektifan dan efisiensi penggunaan energi pada bangunan. Selain itu, penelitian selanjutnya dapat menggunakan metode lain seperti *Neural Network*, *Decision Tree*, *C4.5* dan sejenisnya untuk mengembangkan dan memperluas penggunaan teknologi *SVM* dan Algoritma Genetika dalam analisis data pada bangunan dan infrastruktur.

DAFTAR PUSTAKA

- [1] R. Kumala, R. Ulpa, And A. Rahayu, "Pajak Karbon: Perbaiki Ekonomi Dan Solusi Lindungi Bumi," In Prosiding Seminar Stiami, 2021, Vol. 8, No. 1, Pp. 66–73.
- [2] S. A. Fauzan And A. Sapei, "Evaluasi Struktur Gedung X Di Jakarta Berdasarkan Sni 03-1726-2012 Ketahanan Gempa Untuk Struktur Gedung," *J. Tek. Sipil Dan Lingkung.*, Vol. 3, No. 1, Pp. 11–24, 2018.
- [3] A. Prasetyo And B. Bukhori, "Perbandingan Kebutuhan Tulangan Struktur Beton Bertulang Tahan Gempaterhadap Biaya Konstruksi Berdasarkan Pembebanan Sni 1726: 2012 Serta Sni 1727: 2013 Dengan Pembebanan Sebelumnya," *Log. J. Ilm. Lemlit Unswagati Cirebon*, Vol. 23, No. 1, Pp. 12–25, 2019.
- [4] A. Prihatiningrum, "Karakter Bentuk Hunian Suku Rejang Di Daerah Rawan Gempa (Studi Kasus: Desa Gunung Alam, Kabupaten Lebong)," *Arsitektura*, Vol. 18, No. 1, Pp. 84–93, 2020.
- [5] M. Masril, "Analisis Perilaku Struktur Atas Gedung Asrama Pusdiklat Ipdn Baso, Bangunan Wing 1 Dengan Beban Gempa Berdasarkan Sni 03-1726-2012," *Rang Tek. J.*, Vol. 2, No. 1, 2019.
- [6] A. Savitri, *Revolusi Industri 4.0: Mengubah Tantangan Menjadi Peluang Di Era Disrupsi 4.0*. Penerbit Genesis, 2019.
- [7] A. Syaputra, "Implementasi Metode Random Sampling Pada Animasi Motion Grapich Herbisida Dan Fungsida," *J. Sisfokom (Sistem Inf. Dan Komputer)*, Vol. 11, No. 2, Pp. 142–147, 2022.
- [8] A. I. No, *Teknologi Beton Dan Bahan Bangunan*. Media Sahabat Cendekia, 2019.
- [9] D. Dewi And S. M. Lumbanraja, "Rantai Pasok Industri Baja Untuk Pembangunan Pltn Di Indonesia," *J. Pengemb. Energi Nukl.*, Vol. 19, No. 1, Pp. 51–60, 2017.
- [10] I. C. R. Drajana, "Metode Support Vector Machine Dan Forward Selection Prediksi Pembayaran Pembelian Bahan Baku Kopra," *Ilk. J. Ilm.*, Vol. 9, No. 2, Pp. 116–123, 2017.
- [11] D. P. A. Sb And H. Suparwito, "Analisis Sentimen Bantuan Langsung Tunai Covid-19 Menggunakan Algoritma Support Vector Machine," In Prosiding Seminar Nasional Sanata Dharma Berbagi" Pengembangan, Penerapan Dan Pendidikan'sains Dan Teknologi'pasca Pandemi", 2022, P. 72.
- [12] H. C. Husada And A. S. Paramita, "Analisis Sentimen Pada Maskapai Penerbangan Di Platform Twitter Menggunakan Algoritma Support Vector Machine (Svm)," *Teknika*, Vol. 10, No. 1, Pp. 18–26, 2021.
- [13] M. Huda And M. Kom, *Algoritma Data Mining: Analisis Data Dengan Komputer*. Bisakimia, 2019.
- [14] A. Syaputra, "Analisis Kombinasi Metode Algoritma Mfep Dan Ahp Pada Pemilihan Bibit Unggul Kopi Robusta," *Komputika J. Sist. Komput.*, Vol. 11, No. 2, Pp. 185–192, 2022.
- [15] R. I. Nurachim, "Pemilihan Model Prediksi Indeks Harga Saham Yang Dikembangkan Berdasarkan Algoritma Support Vector Machine (Svm) Atau Multilayer Perceptron (Mlp) Studi Kasus: Saham Pt Telekomunikasi Indonesia Tbk," *J. Teknol. Inform. Dan Komput.*, Vol. 5, No. 1, Pp. 29–35, 2019.
- [16] F. S. Jumeilah, "Penerapan Support Vector Machine (Svm) Untuk Pengkategorian Penelitian," *J. Resti (Rekayasa Sist. Dan Teknol. Informasi)*, Vol. 1, No. 1, Pp. 19–25, 2017.
- [17] B. V. Christioko, S. Asmiatun, And S. Susanto, "Penjadwalan Kegiatan Praktikum Menggunakan Algoritma Genetika (Studi Kasus: Jurusan Teknologi Informasi Universitas Semarang)," *J. Voi (Voice Informatics)*, Vol. 11, No. 1, Pp. 25–34, 2022.
- [18] M. Saukani, E. A. Hakim, And I. Pakaya, "Analisa Perbandingan Aliran Daya Optimal Mempertimbangkan Biaya Pembangkitan Dan Kestabilan Daya Menggunakan Particle Swarm Optimization Dan Algoritma Genetika," In Prosiding Sentra (Seminar Teknologi Dan Rekayasa), 2016, No. 2, Pp. 77–82.