

PEMODELAN PREDIKTIF KONSUMSI ENERGI BANGUNAN GEDUNG KOMERSIAL DENGAN ALGORITMA *SUPPORT VECTOR MACHINE*

Indriyanti ¹⁾; Agus Subekti ²⁾

¹⁾ Program Studi Ilmu Komputer
STMIK Nusa Mandiri Jakarta
<http://www.nusamandiri.ac.id>
indriyanti.18120700@gmail.com

²⁾ Pusat Penelitian Elektronika dan Telekomunikasi
Lembaga Ilmu Pengetahuan Indonesia
<http://www.lipi.go.id>
agus.subekti@lipi.go.id



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

Abstract— *Increasing building energy consumption prompted researchers to build a prediction model by applying the machine learning method, but the most accurate model is still unknown. Predictive models for energy consumption of commercial buildings are important for energy conservation. By using the right model, we can make building designs more efficient in energy use. In this paper, we propose a predictive model based on machine learning methods to get the best model for predicting total energy consumption. The algorithm used is SMOreg and LibSVM from the Support Vector Machine class, then to evaluate the model based on the Mean Absolute Error and Root Mean Square Error values. Using available public datasets, we developed a model based on the supporting vector engine for regression. The test results of both algorithms are known that the SMOreg algorithm has better accuracy because it has MAE and RMSE values of 4.70 and 10.15, while for the LibSVM model has MAE and RMSE values of 9.37 and 14.45. We propose a method based on the SMOreg algorithm because of its better performance.*

Keywords: *Support Vector Machine, SMOreg, LibSVM*

Intisari—Konsumsi energi bangunan yang semakin meningkat mendorong para peneliti untuk membangun sebuah model prediksi dengan menerapkan metode *machine learning*, namun masih belum diketahui model yang paling akurat. Model prediktif untuk konsumsi energi bangunan komersial penting untuk konservasi energi. Dengan menggunakan model yang tepat, kita dapat membuat desain bangunan yang lebih

efisien dalam penggunaan energi. Dalam tulisan ini, kami mengusulkan model prediktif berdasarkan metode pembelajaran mesin untuk mendapatkan model terbaik dalam memprediksi total konsumsi energi. Algoritma yang digunakan yaitu *SMOreg* dan *LibSVM* dari kelas *Support Vector Machine*, kemudian untuk evaluasi model berdasarkan nilai *Mean Absolute Error* dan *Root Mean Square Error*. Dengan menggunakan dataset publik yang tersedia, kami mengembangkan model berdasarkan pada mesin vektor pendukung untuk regresi. Hasil pengujian kedua algoritma tersebut diketahui bahwa algoritma *SMOreg* memiliki akurasi lebih baik karena memiliki nilai *MAE* dan *RMSE* sebesar 4,70 dan 10,15, sedangkan untuk model *LibSVM* memiliki nilai *MAE* dan *RMSE* sebesar 9,37 dan 14,45. Kami mengusulkan metode berdasarkan algoritma *SMOreg* karena kinerjanya lebih baik.

Kata kunci: *Support Vector Machine, SMOreg, LibSVM*

PENDAHULUAN

Pertumbuhan populasi yang semakin pesat menyebabkan konsumsi energi bangunan semakin meningkat. Data energi bangunan yang tersedia untuk publik saat ini semakin banyak, sehingga kesempatan menerapkan metode *machine learning* untuk memprediksi kinerja energi bangunan juga semakin banyak. Saat ini para peneliti telah mengembangkan berbagai metodologi statistik untuk membangun pemodelan energi untuk meramalkan total penggunaan energi atau terpilah oleh penggunaan energi akhir. Ada beberapa metode yang dapat digunakan untuk memprediksi

penggunaan energi antara lain metode berbasis regresi, ANN, SVM dan masih banyak lagi. Misalnya, penggunaan metode SVM dan ANN untuk peramalan penggunaan energi listrik bangunan. Metode tersebut telah banyak digunakan untuk mengatasi kompleksitas sistem bangunan yang dipengaruhi oleh banyak parameter bangunan (Ahmad et al., 2014). Berbagai metode yang telah digunakan untuk memprediksi penggunaan energi masih belum menunjukkan hasil yang akurat, karena dari beberapa metode memiliki akurasi yang kurang baik.

Metode *Support Vector Machine* merupakan salah satu metode yang dapat digunakan untuk memprediksi suatu kasus. SVM banyak di implementasikan pada beberapa algoritma lain di WEKA misalnya SMOREg dan LibSVM. SMOREg merupakan algoritma di dalam WEKA yang mengimplementasikan metode SVM untuk kasus regresi, algoritma tersebut dipilih dengan mengatur RegOptimizer. Selain itu, LibSVM juga merupakan implementasi dari SVM dengan berbagai jenis kernel dan parameter yang berbeda untuk setiap kernelnya (<http://weka.sourceforge.net/doc.dev/weka/classifiers/functions/SMOREg.html>, n.d). Setiap metode pasti mempunyai kelebihan dan kekurangan masing-masing, untuk mendapatkan metode atau model prediksi terbaik maka diperlukan beberapa pertimbangan salah satunya berdasarkan tingkat akurasi suatu model dalam memprediksi. Tingkat akurasi suatu model dapat dilihat atau dievaluasi menggunakan nilai MAE (*Mean Absolute Error*) dan RMSE (Colanus, Drajana, & Selection, 2017).

Salah satu data energi bangunan yang tersedia untuk publik saat ini adalah CBECS (*Commercial Buildings Energy Consumption Survey*). CBECS adalah data survey tentang konsumsi energi bangunan di Amerika Serikat yang dikumpulkan oleh Badan Informasi Energi (*US-EIA-Energy Information Administration*) (Michaels, 2016). Energi yang merupakan salah satu aspek bangunan di Amerika diatur dalam peraturan perundangan, ada kriteria minimum yang diisyaratkan oleh peraturan energi dan itu harus dipenuhi oleh setiap bangunan. Karena itu, data konsumsi energi seluruh bangunan komersial yang ada di Amerika dikumpulkan dalam CBECS ini sebagai tolok ukur kondisi efisiensi bangunan. Data di dalam CBECS ini selalu diperbarui secara berkala setiap empat atau lima tahun sekali. Versi terbaru saat ini adalah CBECS 2012 yang memiliki sekitar 50% peningkatan ukuran sampel dan daftar variabel survei yang lebih detail. Dataset CBECS mikrodta telah banyak digunakan untuk penelitian, salah satunya untuk pemodelan

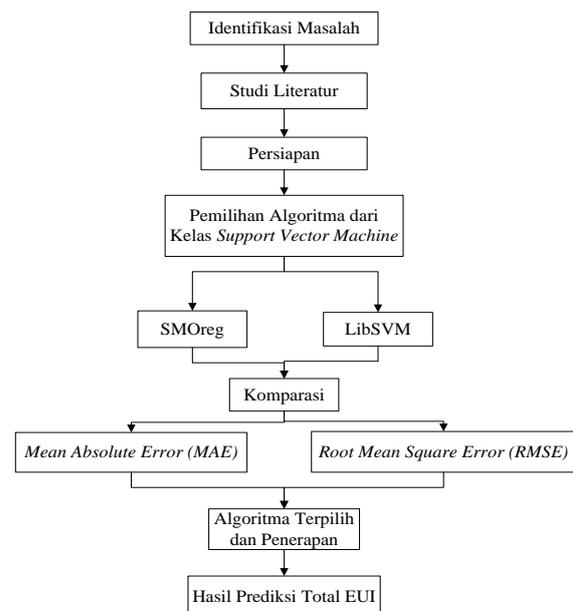
prediktif untuk memprediksi total EUI dengan menggunakan algoritma statistik dan machine learning. Hasil penelitian menunjukkan bahwa algoritma machine learning lebih baik daripada regresi linear (Deng, Fannon, & Eckelman, 2018).

Penelitian ini bertujuan untuk mendapatkan model terbaik untuk memprediksi konsumsi energi bangunan pada gedung komersial berdasarkan nilai MAE dan RMSE suatu model prediksi.

BAHAN DAN METODE

Pada penelitian ini dilakukan prediksi terhadap total konsumsi energi bangunan dari pengujian dataset CBECS mikrodta tahun 2012 yang diambil dari repository EIA (*Energy Information Administration*) yang dapat diakses melalui halaman *website EIA yaitu https://www.eia.gov/consumption/commercial/*. Dataset tersebut berisi survei data penggunaan energi di beberapa bangunan komersial Amerika Serikat. Atribut yang digunakan pada penelitian ini sebanyak 77 atribut dan 1016 data.

Penelitian ini dilakukan dengan beberapa tahapan, antara lain: identifikasi masalah, studi literatur, persiapan, pemilihan algoritma, komparasi, penerapan algoritma terpilih dan menampilkan hasil prediksi total EUI. Sedangkan untuk teknik pengumpulan datanya, peneliti melakukan studi literatur terhadap penelitian sebelumnya dengan tema yang sama yaitu prediktif modeling untuk memprediksi konsumsi energi bangunan.



Sumber: (Indriyanti & Subekti, 2018)

Gambar 1. Kerangka Pemikiran Penelitian

Berikut penjelasan mengenai tahapan-tahapan penelitian yang dilakukan:

1. Identifikasi Masalah

Pada tahap ini peneliti melakukan identifikasi terhadap permasalahan yang ada yaitu algoritma yang digunakan untuk memprediksi konsumsi energi bangunan masih memiliki kekurangan khususnya untuk memprediksi total penggunaan energi (total EUI) pada dataset CBECS mikrodata tahun 2012.

2. Studi Literatur

Tahap kedua yaitu studi literatur untuk menentukan algoritma yang akan dipakai pada penelitian ini. Studi literatur dilakukan dengan mencari referensi dari berbagai sumber yang terkait dengan penelitian ini. Referensi yang dicari antara lain yang berkaitan dengan CBECS mikrodata, algoritma *Support Vector Machine*, nilai *Mean Absolute Error* dan nilai *Root Mean Square Error*.

3. Persiapan

Persiapan yang dilakukan pada penelitian ini yaitu mencari dataset CBECS mikrodata. Setelah dataset didapatkan, tahap selanjutnya yaitu melakukan *preprocessing* dataset. Menentukan berapa jumlah atribut dan data yang akan digunakan sesuai dengan kebutuhan penelitian dan menghilangkan *missing value* pada dataset.

4. Pemilihan Algoritma

Berdasarkan referensi yang telah didapatkan pada tahap studi literatur, maka pada tahap ini dilakukan pemilihan algoritma terbaik dari beberapa sumber yang berkaitan dengan penelitian ini. Beberapa penelitian yang telah dilakukan menunjukkan bahwa metode *Support Vector Machine* memiliki akurasi terbaik untuk memprediksi konsumsi energi. Algoritma yang dipilih untuk penelitian ini adalah *SMOreg* dan *LibSVM* yang merupakan kelas dari metode *Support Vector Machine* pada *tools WEKA*.

5. Komparasi

Pada tahap ini dilakukan komparasi atau perbandingan antara dua algoritma yang telah dipilih yaitu algoritma *SMOreg* dan algoritma *LibSVM*. Kedua algoritma tersebut dievaluasi tingkat akurasinya berdasarkan nilai *Mean Absolute Error* dan nilai *Root Mean Square Error*. Dari evaluasi akurasi tersebut nantinya akan didapatkan algoritma terbaik.

6. Algoritma Terpilih dan Penerapan

Algoritma terbaik yang dihasilkan pada tahap komparasi kemudian digunakan untuk memprediksi total EUI dari dataset CBECS mikrodata tahun 2012.

7. Hasil Prediksi Total EUI

Tahap penerapan algoritma pada dataset CBECS mikrodata tahun 2012 akan menghasilkan data prediksi untuk Total EUI yang nantinya akan ditampilkan dalam bentuk grafik.

HASIL DAN PEMBAHASAN

Dataset

Data konsumsi energi bangunan CBECS mikrodata yang digunakan dalam penelitian ini didapatkan dari www.eia.gov. Penelitian ini hanya menggunakan 77 atribut dan 1016 data bangunan yang akan digunakan untuk mencari model prediksi terbaik dan untuk memprediksikan total konsumsi energi bangunan di Amerika Serikat. Total EUI untuk setiap bangunan sebagai variabel respon utama berdasarkan penggunaan energi tahunan yang dilaporkan dari berbagai bahan bakar dan listrik. Tabel 1 berikut adalah data atribut yang digunakan dalam penelitian ini:

Tabel 1. Atribut CBECS mikrodata 2012

| No | Variabel | Keterangan |
|----|----------|--|
| 1 | CENDIV | Wilayah |
| 2 | SQFT | Luas |
| 3 | WLCNS | Bahan konstruksi dinding |
| 4 | RFCNS | Bahan konstruksi atap |
| 5 | RFCOOL | Bahan atap dingin |
| 6 | RFTILT | Kemiringan atap |
| 7 | BLDSHP | Bentuk bangunan |
| 8 | GLSSPC | Persentase kaca eksterior |
| 9 | EQGLSS | Semua sisi menggunakan kaca |
| 10 | NFLOOR | Jumlah lantai |
| 11 | FLCEILHT | Tinggi lantai ke langit-langit |
| 12 | ATTIC | Loteng |
| 13 | YRCON | Tahun konstruksi |
| 14 | RENRF | Penggantian atap |
| 15 | RENWLL | Penggantian dinding eksterior |
| 16 | RENWIN | Penggantian jendela |
| 17 | RENHVC | Upgrade peralatan HVAC |
| 18 | RENLGT | Peningkatan pencahayaan |
| 19 | RENELC | Upgrade listrik |
| 20 | RENINS | Upgrade isolasi |
| 21 | ONEACT | Satu aktivitas dalam membangun |
| 22 | FACIL | Di kompleks bangunan |
| 23 | OWNTYPE | Pemilik gedung |
| 24 | NOCC | Jumlah bisnis |
| 25 | OWNOCC | Ditempati pemilik atau disewakan kepada penyewa (s) |
| 26 | OWNOPR | Pemilik bertanggung jawab untuk operasi dan pemeliharaan sistem energi |
| 27 | OCCUPYP | Persentase hunian |

| No | Variabel | Keterangan |
|----|----------|---|
| 28 | OPEN24 | Buka 24 jam sehari |
| 29 | OPNWE | Buka pada akhir pekan |
| 30 | WKHRS | Total jam buka per minggu |
| 31 | NWKER | Jumlah Karyawan |
| 32 | FKUSED | Bahan bakar minyak / solar / minyak tanah yang digunakan |
| 33 | PRUSED | Botol gas / LPG / propana yang digunakan |
| 34 | STUSED | Uap distrik digunakan |
| 35 | ELHT1 | Listrik digunakan untuk pemanasan utama |
| 36 | NGHT1 | Gas alam digunakan untuk pemanasan utama |
| 37 | HEATP | Persentase panas |
| 38 | MAINHT | Peralatan pemanas utama |
| 39 | HTVCAV | Ventilasi pemanas: Penanganan udara sentral dengan CAV |
| 40 | HTVVAV | Ventilasi pemanas: Penanganan udara sentral dengan VAV |
| 41 | ELCOOL | Listrik yang digunakan untuk pendinginan |
| 42 | NGCOOL | Gas alam digunakan untuk pendinginan |
| 43 | COOLP | Persentase dingin |
| 44 | MAINCL | Peralatan pendingin utama |
| 45 | CLVCAV | Ventilasi pendingin: Unit penanganan udara sentral dengan CAV |
| 46 | CLVVAV | Ventilasi pendingin: Unit penanganan udara sentral dengan VAV |
| 47 | EMCS | Membangun sistem otomasi |
| 48 | RDHTNF | Pemanasan berkurang selama 24 jam |
| 49 | RDCLNF | Pendinginan berkurang selama 24 jam |
| 50 | ECN | Siklus Economizer |
| 51 | MAINT | Perawatan HVAC reguler |
| 52 | ENRGYPLN | Rencana manajemen energi |
| 53 | PCTERMN | Jumlah komputer |
| 54 | LAPTPN | Jumlah laptop |
| 55 | PRNTRN | Jumlah printer |
| 56 | COPIERN | Jumlah mesin fotokopi |
| 57 | LTOHRP | Persentase menyala saat terbuka |
| 58 | LTNHRP | Persentase menyala dari jam |
| 59 | FLUOR | Lampu neon |
| 60 | CFLR | Lampu neon kompak |
| 61 | BULB | Lampu pijar |
| 62 | HALO | Lampu halogen |
| 63 | HID | Bola lampu intensitas tinggi (HID) |
| 64 | LED | Light-emitting diode (LED) bulbs |

| No | Variabel | Keterangan |
|----|----------|-------------------------------------|
| 65 | SCHED | Penjadwalan cahaya |
| 66 | OCSN | Sensor okupansi |
| 67 | WINTYP | Jenis kaca jendela |
| 68 | TINT | Kaca jendela berwarna |
| 69 | REFL | Kaca jendela reflektif |
| 70 | AWN | Overhang eksternal atau tenda |
| 71 | SKYLT | Skylight atau atrium |
| 72 | DAYLTP | Persen siang hari |
| 73 | HDD65 | Hari gelar pemanas (basis 65) |
| 74 | CDD65 | Hari derajat pendinginan (basis 65) |
| 75 | HVACEUI | Penggunaan HVAC |
| 76 | LTNEUI | Penggunaan pencahayaan |
| 77 | PLEUI | Beban listrik yang digunakan |

Sumber: (Indriyanti & Subekti, 2018)

Hasil Eksperimen Algoritma SMOreg

Tabel 2. Hasil eksperimen dengan algoritma SMOreg

| Model | MAE | RMSE |
|--|-------|-------|
| <i>SMOreg</i> | 4,70 | 10,15 |
| <i>SMOreg + Random Subset</i> | 4,94 | 10,32 |
| <i>SMOreg + Principal Component</i> | 9,39 | 14,36 |
| <i>SMOreg + Normalize</i> | 4,71 | 10,15 |
| <i>SMOreg exp 2.0</i> | 12,60 | 17,86 |
| <i>SMOreg NormalizedPolykernel exp 2.0</i> | 8,08 | 13,14 |
| Model | MAE | RMSE |
| <i>SMOreg NormalizedPolykernel exp 1.5</i> | 7,69 | 12,84 |
| <i>SMOreg RBFkernel</i> | 5,64 | 11,10 |
| <i>SMOreg RBFkernel gamma 0.02</i> | 6,44 | 11,71 |

Sumber: (Indriyanti & Subekti, 2018)

Tabel 2 hasil eksperimen dengan algoritma *SMOreg* di atas menunjukkan bahwa nilai *Mean Absolute Error* dan *Root Mean Square Error* terkecil dimiliki oleh model *SMOreg* dengan parameter standar yang disediakan pada tools WEKA yaitu dengan kernel *polykernel*. Nilai MAE yang dihasilkan sebesar 4,70 dan nilai RMSE sebesar 10,15. Semakin kecil nilai MAE dan RMSE nya, semakin baik pula akurasi. Akurasi terburuk ditunjukkan oleh model *SMOreg* dengan kernel *polykernel* dan nilai *exponent 2*, karena memiliki nilai MAE sebesar 12,60 dan nilai RMSE sebesar 17,86.

LibSVM

Tabel 3. Hasil eksperimen dengan algoritma LibSVM

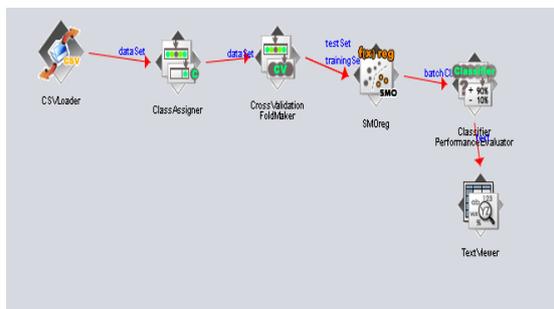
| Model | MAE | RMSE |
|--|-------|-------|
| <i>LibSvm nu-SVR radial basic function</i> | 58,51 | 77,26 |
| <i>LibSvm nu-SVR radial basic function + normalize</i> | 56,59 | 75,31 |
| <i>LibSvm nu-SVR radial basic function + Principal Component</i> | 51,82 | 69,69 |
| <i>LibSVM epsilon SVR + principal component</i> | 49,69 | 49,69 |
| <i>LibSVM epsilon SVR + normalize</i> | 55,80 | 75,93 |
| <i>LibSVM epsilon SVR + random subset</i> | 58,30 | 78,34 |
| <i>LibSVM epsilon SVR + principal component, polinomial (kerneltype)</i> | 54,33 | 73,81 |
| <i>LibSVM epsilon SVR + principal component, linear (kerneltype)</i> | 9,37 | 14,45 |
| <i>LibSVM epsilon SVR + principal component, sigmoid (kerneltype)</i> | 40,86 | 56,67 |

Sumber: (Indriyanti & Subekti, 2018)

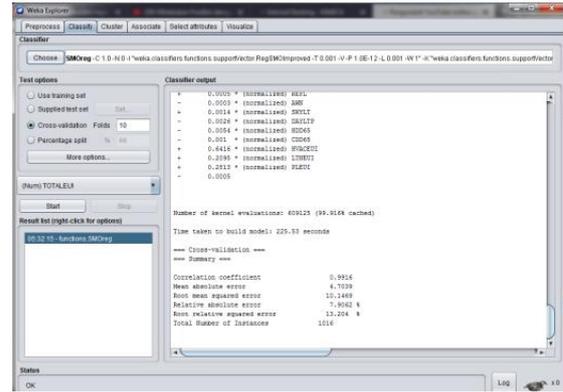
Tabel 3 diatas hasil eksperimen dengan algoritma *SMOreg* di atas menunjukkan bahwa nilai *Mean Absolute Error* dan *Root Mean Square Error* terkecil dimiliki oleh model *LibSVM* dengan tipe algoritma SVM yang berbeda yaitu *epsilon SVR* dan menggunakan tipe kernel *linear* yang dipadukan dengan metode *principal component* pada tahap *preprocessing* data. Nilai MAE yang dihasilkan sebesar 9,37 dan nilai RMSE sebesar 14,45. Semakin kecil nilai MAE dan RMSE nya, semakin baik pula akurasi nya, ditunjukkan oleh model *LibSVM* dengan tipe algoritma SVM yang berbeda yaitu *nu-SVR* dan menggunakan tipe kernel *radial basic function*, karena memiliki nilai MAE sebesar 58,51 dan nilai RMSE sebesar 77,26.

Model SMOreg yang diusulkan

Hasil evaluasi yang telah dilakukan di atas menunjukkan bahwa algoritma *SMOreg* memiliki tingkat error lebih kecil dibandingkan dengan *LibSVM*. Berikut desain dan model *SMOreg* yang digunakan untuk pengujian dataset:



Sumber: (Indriyanti & Subekti, 2018)
Gambar 3. Desain Model Pengujian SMOreg



Sumber: (Indriyanti & Subekti, 2018)
Gambar 4. Model Pengujian SMOreg

Pembahasan

Tingkat akurasi suatu model prediksi dapat dievaluasi menggunakan nilai Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE) dengan menggunakan software WEKA. Berdasarkan pengujian yang telah dilakukan sebelumnya, didapatkan model prediksi terbaik yaitu algoritma *SMOreg*. Algoritma tersebut selanjutnya digunakan untuk memprediksi total EUI bangunan komersial di Amerika Serikat.

Tabel Hasil Prediksi

Prediksi Total EUI yang dihasilkan dengan model pengujian *SMOreg* dapat dilihat pada tabel 4 berikut ini:

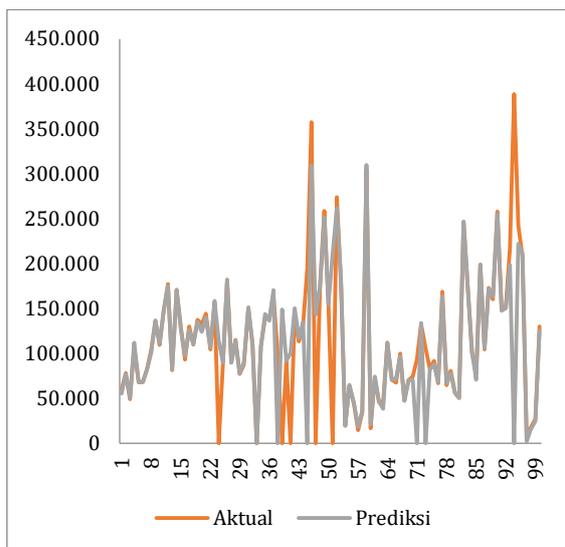
Tabel 4. Sampel Hasil Prediksi Total EUI

| Data | Aktual | Prediksi |
|------|---------|----------|
| 1 | 59.814 | 55.547 |
| 2 | 78.132 | 77.305 |
| 3 | 49.212 | 50.295 |
| 4 | 106.853 | 112.073 |
| 5 | 68.014 | 67.805 |
| 6 | 68.378 | 68.407 |
| 7 | 82.923 | 82.146 |
| 8 | 104.224 | 100.918 |
| 9 | 136.099 | 136.956 |
| 10 | 109.634 | 111.223 |
| 11 | 147.339 | 148.971 |
| 12 | 177.337 | 175.276 |
| 13 | 81.446 | 82.676 |
| 14 | 170.984 | 170.275 |
| 15 | 130.069 | 126.997 |
| 16 | 93.333 | 97.588 |
| 17 | 130.266 | 126.131 |
| 18 | 109.777 | 110.658 |

| Data | Aktual | Prediksi | Data | Aktual | Prediksi |
|------|---------|----------|------|---------|----------|
| 19 | 137.685 | 135.404 | 62 | 45.752 | 46.247 |
| 20 | 132.686 | 124.241 | 63 | 45.851 | 38.541 |
| 21 | 144.441 | 139.914 | 64 | 111.852 | 112.178 |
| 22 | 104.608 | 106.819 | 65 | 70.755 | 70.548 |
| 23 | 155.935 | 158.402 | 66 | 67.706 | 71.968 |
| 24 | 115.3 | 113.724 | 67 | 100.007 | 96.792 |
| 25 | 88.644 | 90.338 | 68 | 47.872 | 47.482 |
| 26 | 181.568 | 182.432 | 69 | 70.265 | 70.612 |
| 27 | 90.311 | 89.471 | 70 | 74.238 | 70.897 |
| 28 | 115.192 | 114.487 | 71 | 93.615 | 92.87 |
| 29 | 77.346 | 77.934 | 72 | 132.621 | 133.892 |
| 30 | 87.658 | 90.339 | 73 | 105.492 | 102.77 |
| 31 | 149.547 | 151.401 | 74 | 83.122 | 82.053 |
| 32 | 110.151 | 110.064 | 75 | 91.912 | 87.749 |
| 33 | 115.17 | 114.5 | 76 | 66.937 | 68.207 |
| 34 | 108.751 | 107.183 | 77 | 169.013 | 163.779 |
| 35 | 139.441 | 143.945 | 78 | 64.717 | 66.998 |
| 36 | 138.258 | 136.522 | 79 | 80.914 | 77.803 |
| 37 | 164.865 | 170.799 | 80 | 56.672 | 56.227 |
| 38 | 99.163 | 105.42 | 81 | 50.454 | 50.396 |
| 39 | 158.41 | 149.112 | 82 | 246.533 | 246.569 |
| 40 | 91.615 | 91.804 | 83 | 173.892 | 173.635 |
| 41 | 99.13 | 100.805 | 84 | 101.008 | 102.816 |
| 42 | 142.411 | 150.505 | 85 | 77.398 | 70.795 |
| 43 | 113.379 | 117.503 | 86 | 199.074 | 198.602 |
| 44 | 132.045 | 134.834 | 87 | 104.519 | 106.045 |
| 45 | 194.065 | 197.53 | 88 | 173.039 | 172.287 |
| 46 | 357.662 | 309.249 | 89 | 160.359 | 163.634 |
| 47 | 137.88 | 143.109 | 90 | 257.978 | 255.049 |
| 48 | 176.177 | 175.709 | 91 | 151.968 | 147.604 |
| 49 | 258.645 | 251.591 | 92 | 150.598 | 150.341 |
| 50 | 153.786 | 154.996 | 93 | 217.586 | 198.563 |
| 51 | 207.99 | 211.518 | 94 | 388.821 | 381.57 |
| 52 | 273.998 | 261.834 | 95 | 242.904 | 221.987 |
| 53 | 175.868 | 182.046 | 96 | 207.824 | 211.416 |
| 54 | 19.808 | 19.618 | 97 | 5.177 | 2.191 |
| 55 | 63.672 | 65.043 | 98 | 17.745 | 15.837 |
| 56 | 44.075 | 45.355 | 99 | 26.977 | 24.501 |
| 57 | 14.512 | 18.161 | 100 | 130.189 | 125.356 |
| 58 | 34.057 | 36.299 | | | |
| 59 | 304.467 | 310.025 | | | |
| 60 | 16.628 | 21.447 | | | |
| 61 | 73.687 | 74.417 | | | |

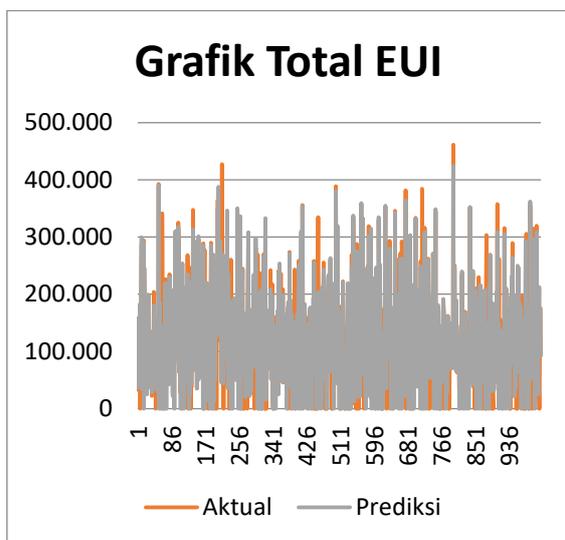
Sumber: (Indriyanti & Subekti, 2018)

Grafik Hasil Prediksi



Sumber: (Indriyanti & Subekti, 2018)
 Gambar 5. Grafik Hasil Prediksi 1016 Data

Gambar 5 merupakan grafik hasil prediksi total EUI dengan menggunakan seluruh data yang ada di dataset CBECS mikordata 2012.



Sumber: (Indriyanti & Subekti, 2018)
 Gambar 6. Grafik Hasil Prediksi 100 Data

Pada grafik gambar 6 dapat disimpulkan bahwa semakin tinggi total penggunaan energi bangunan, maka semakin tinggi pula prediksi total penggunaan energi bangunan dengan algoritma SMOreg. Prediksi berbanding lurus dengan nilai *error* hasil prediksi.

KESIMPULAN

Penelitian ini mengkomparasikan beberapa model untuk memprediksi total penggunaan energi bangunan (Total EUI).

Algoritma dasar yang digunakan adalah *Support Vector Machine (SVM)*, sedangkan algoritma yang digunakan untuk model prediksi yaitu algoritma SMOreg dan LibSVM yang merupakan kelas dari SVM pada *software WEKA*.

Hasil evaluasi dan validasi yang dilakukan dengan mencari *nilai Mean Absolute Error* dan *Root Mean Square Error* menunjukkan bahwa algoritma SMOreg memiliki akurasi lebih baik daripada LibSVM. Nilai MAE dan RMSE yang dihasilkan oleh algoritma SMOreg sebesar 4,70 dan 10,15. Hal itu yang menjadi bukti bahwa algoritma SMOreg dapat digunakan untuk memprediksi total penggunaan energi bangunan komersial di Amerika Serikat. Hasil prediksi total EUI dapat disajikan dalam bentuk grafik agar memudahkan para penyedia energi bangunan untuk melakukan evaluasi.

Berikut saran dari penulis untuk penelitian selanjutnya: menerapkan algoritma SMOreg pada dataset konsumsi energi yang ada di Indonesia untuk memprediksi total penggunaan energi; membandingkan algoritma terpilih dengan algoritma lain seperti *Random Forest*, *Linear Regression* dan dapat juga ditingkatkan akurasinya dengan *feature selection*.

REFERENSI

Ahmad, A. S., Hassan, M. Y., Abdullah, M. P., Rahman, H. A., Hussin, F., Abdullah, H., & Saidur, R. (2014). A review on applications of ANN and SVM for building electrical energy consumption forecasting. *Renewable and Sustainable Energy Reviews*, 33, 102-109. <https://doi.org/10.1016/j.rser.2014.01.069>

Colanus, I., Drajana, R., & Selection, F. (2017). METODE SUPPORT VECTOR MACHINE DAN FORWARD SELECTION PREDIKSI PEMBAYARAN PEMBELIAN BAHAN BAKU, 9, 116-123.

Deng, H., Fannon, D., & Eckelman, M. J. (2018). Predictive modeling for US commercial building energy use: A comparison of existing statistical and machine learning algorithms using CBECS microdata. *Energy and Buildings*, 163, 34-43. <https://doi.org/10.1016/J.ENBUILD.2017.12.031>

Indriyanti, I., & Subekti, A. (2018). *Laporan Akhir Penelitian "Pemodelan Prediktif Konsumsi Energi Bangunan Gedung Komersial Dengan Algoritma Support Vector Machine."* Jakarta.

Michaels, J. (2016). *2012 Commercial Buildings Energy Consumption Survey: Energy Usage Summary*. Washington, DC. Retrieved from <https://www.eia.gov/consumption/commercial/>