



**ESTIMASI KONSUMSI ENERGI PADA BANGUNAN
PERUMAHAN DI DAERAH TROPIS BERBASIS
*MACHINE LEARNING***

Skripsi

**Diajukan Sebagai Salah Satu Syarat untuk Memperoleh Gelar Sarjana
Pendidikan Program Studi Pendidikan Teknik Informatika dan Komputer**

Oleh

Dwi Okte Cahyaningrum

NIM. 5302414070

PENDIDIKAN TEKNIK INFORMATIKA DAN KOMPUTER

JURUSAN TEKNIK ELEKTRO

FAKULTAS TEKNIK

UNIVERSITAS NEGERI SEMARANG

2019

PERSETUJUAN PEMBIMBING

Nama : Dwi Okte Cahyaningrum

NIM : 5302414070

Program Studi : S-1 Pendidikan Teknik Informatika dan Komputer

Judul Skripsi : **Estimasi Konsumsi Energi pada Bangunan Perumahan di Daerah Tropis Berbasis *Machine Learning***

Skripsi ini telah disetujui pembimbing untuk diajukan kepanitia sidang ujian skripsi Program Studi S-1 Pendidikan Teknik Informaika dan Komputer, Jurusan Teknik Elektro, Fakultas Teknik, Universitas Negeri Semarang.

Semarang, 11 Maret 2019

Pembimbing



Dr. Ir. Subiyanto, S.T., M.T.
NIP. 197411232005011001

PENGESAHAN

Skripsi dengan judul “Estimasi Konsumsi Energi pada Bangunan Perumahan di Daerah Tropis Berbasis *Machine Learning*” telah dipertahankan di depan panitia sidang ujian skripsi Fakultas Teknik UNNES pada tanggal 26 bulan Maret tahun 2019.

Oleh

Nama : Dwi Okte Cahyaningrum
NIM : 5302414070
Program Studi : S-1 Pendidikan Teknik Informatika dan Komputer

Panitia :

Ketua

Sekretaris

Dr.-Ing. Dhidik Prastiyanto, S.T., M.T
NIP. 197805312005011002

Ir. Ulfah Mediaty Arief, M.T., IPM
NIP. 196605051998022001

Penguji 1

Penguji 2

Penguji 3 / Pembimbing

Drs. H. Said Sunardiyo, M.T.
NIP. 196505121991031003

Drs. Ir. Henry Ananta, M.Pd., IPM
NIP. 195907051986011002

Dr. Ir. Subiyanto, S.T., M.T
NIP. 197411232005011001

Mengetahui:

Dekan Fakultas Teknik UNNES



Dr. Nur Qudus, M.T
NIP. 19911301994031001

PERNYATAAN KEASLIAN

Yang bertandatangan dibawah ini :

Nama Mahasiswa : Dwi Okte Cahyaningrum

NIM : 5302414070

Program Studi : Pendidikan Teknik Informatika dan Komputer

Fakultas : Teknik

Dengan ini menyatakan bahwa skripsi dengan judul **“Estimasi Konsumsi Energi pada Bangunan Perumahan di Daerah Tropis Berbasis *Machine Learning*”** merupakan hasil karya sendiri dan belum pernah diajukan untuk memperoleh keserjanaan di suatu perguruan tinggi manapun, dan sepanjang pengetahuan saya dalam skripsi ini tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, terkecuali yang secara tertulis diacu / disitasi dalam naskah ini dan disebutkan dalam daftar pustaka.

Semarang, 14 Maret 2019

Yang membuat pernyataan,



Dwi Okte Cahyaningrum
NIM. 5302414070

MOTTO DAN PERSEMBAHAN

- Motto :**
- Make imposible to possible
 - Bersikaplah baik kepada sesama baik itu dalam perilaku maupun ucapan, maka orang disekitarmu akan bersikap demikian.
 - Lakukan yang terbaik walaupun harus berjuang dengan keras tanpa henti.

- Persembahan :**
- Allah Subhanahu Wa Ta'ala yang senantiasa selalu menunjukkan dan memudahkan jalan selama pembuatan skripsi ini.
 - Kedua orang tua, Keluarga, dan Saudara yang menjadi penyemangat dan senantia selalu memberikan dukungan.
 - Dosen Pembimbing, Dr. Ir.Subiyanto, S.T., M.T. yang telah memberikan arahan dan bimbingan sehingga saya dapat menyelesaikan skripsi ini.
 - Teman – teman seperjuangan di Unnes Electrical Student Research Group (UEESRG) yang telah membantu, berdiskusi, mendengarkan keluh kesah serta saling memberi penguatan dalam penyelesaian penyusunan skripsi.
 - Teman – teman jurusan Teknik elektro 2014
 - Serta pihak – pihak lain yang tidak dapat penulis sebutkan satu per satu, semoga Allah SWT senantiasa membalas kebaikan anda sekalian.

RINGKASAN

Dwi Okte Cahyaningrum. 2019. **Estimasi Konsumsi Energi pada Bangunan Perumahan di Daerah Tropis Berbasis *Machine Learning***. Skripsi Jurusan Teknik Elektro Fakultas Teknik Universitas Negeri Semarang. Dr. Ir. Subiyanto, S.T., M.T.

Teknologi *smart energy* memiliki peran penting dalam sistem *smart home*, terutama untuk mengelola konsumsi energi. Penggunaan energi dapat estimasi pada fase awal desain. Penelitian ini menyajikan model komputasi untuk memperkirakan konsumsi energi pada bangunan tempat tinggal menggunakan algoritma *Machine Learning*. Estimasi energi dilakukan dengan menggunakan beberapa model AI seperti ELM (*Extreme Learning Machine*), ANN (*Artificial Neural Network*), dan GLR (*General Linear Regression*). Model-model tersebut telah diuji untuk mendapatkan estimasi kinerja konsumsi energi bangunan perumahan secara akurat. Estimasi ini melibatkan konsumsi energi pendingin (*cooling*) dalam dua desain bangunan perumahan yang berbeda dalam cuaca tropis. Bangunan yang diuji adalah fase desain konsumsi energi yang berfokus pada beban *cooling*. Simulasi desain bangunan dengan memperhatikan suhu dan zona bangunan menggunakan perangkat lunak EnergyPlus (E+) untuk mendapatkan dataset konsumsi energi selama satu tahun.

Hasil komputasi dari semua model algoritma *machine learning* diamati dan dianalisis performa dan akurasi. Perbandingan evaluasi model dilakukan, dari hasil yang diperoleh menunjukkan perbandingan tingkat akurasi untuk memperkirakan konsumsi energi *cooling* pada desain bangunan perumahan.

Kata Kunci : Estimasi, Konsumsi Energi , Bangunan perumahan, cuaca Tropis, *Machine Learning*

PRAKATA

Puji syukur penulis panjatkan kehadiran ALLAH SWT atas segala nikmat, rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi dengan judul **“Estimasi Konsumsi Energi pada Bangunan Perumahan di Daerah Tropis Berbasis *Machine Learning*”**.

Skripsi ini disusun dalam rangka menyelesaikan Studi Srata 1 yang merupakan salah satu syarat untuk memperoleh gelar Sarjana Pendidikan Teknik Informatika dan Komputer pada Jurusan Teknik Elektro Fakultas Teknik Universitas Negeri Semarang. Penulis menyadari sepenuhnya dalam proses menyelesaikan skripsi ini tidak lepas dari bantuan orang lain. Oleh karena itu, ijinilah penulis mengucapkan terimakasih kepada :

1. Dr. Ir. Subiyanto, S.T., M.T, Dosen Pembimbing yang telah memberikan bimbingan, arahan dan motivasi kepada penulis dalam penyusunan naskah skripsi.
2. Drs. H.Said Sunardiyo, M.T. dan Drs.Ir.Henry Ananta, M.Pd.,IPM. yang merupakan dosen penguji sidang skripsi yang telah memberikan arahan dan saran kepada penulis agar skripsi menjadi baik.
3. Segenap Jajaran dan Dosen Jurusan Teknik Elektro Universitas Negeri Semarang yang telah memberikan banyak ilmu pengetahuan selama masa perkuliahan.
4. Dr. Nur Qudus, M.T. Dekan Fakultas Teknik Universitas Negeri Semarang.
5. Prof. Dr. Fathur Rokhman, M.Hum, Rektor Universitas Negeri Semarang.
6. Kedua Orang tua dan saudara yang selalu memberikan doa, semangat dan motivasi.

Penulis menyadari bahwa kesempurnaan hanya milik Allah SWT. Oleh karena itu, kritik dan saran yang membangun demimemperbaiki skripsi ini sangat diharapkan. Akhir kata, dengan tangan terbuka dan tanpamengurangi makna serta isi skripsi, semoga skripsi ini dapat bermanfaat bagi yang membaca.

Semarang, 14 Maret 2019

Dwi Okte Cahyaningrum
NIM. 5302414070

DAFTAR ISI

HALAMAN JUDUL	i
PERSETUJUAN PEMBIMBING	ii
PENGESAHAN.....	iii
PERNYATAAN KEASLIAN.....	iv
MOTTO DAN PERSEMBAHAN.....	v
RINGKASAN	vi
PRAKATA.....	vii
DAFTAR ISI.....	viii
DAFTAR TABEL	xi
DAFTAR GAMBAR.....	xii
DAFTAR LAMPIRAN	xiv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Identifikasi Masalah	5
1.3 Rumusan Masalah	5
1.4 Batasan Masalah.....	6
1.5 Tujuan Penerlitian	7
1.6 Manfaat Penelitian.....	7
1.7 Penegasan Istilah	8
BAB II KAJIAN PUSTAKA DAN TEORI	9
2.1. Kajian Pustaka.....	9
2.2. <i>Energy Performance of Building</i>	13
2.3. Beban Konsumsi Energi Pada Bangunan.....	14
2.4. Sketchup 2017.....	16
2.5. EnergyPlus	16
2.5.1 Menjalankan Simulasi Pada EnergyPlus.....	18
2.5.2 Hasil Simulasi	19
2.5.3 HVAC Template	20

2.6.OpenStudio.....	21
2.7. <i>Machine Learning</i>	21
2.7.1 Asitektur Jaringan Tiruan	22
2.7.2 Fungsi Aktivasi	24
2.7.3 Normalisasi Data.....	25
2.7.4 Denormalisasi Data	25
2.7.5 <i>Extreme Learning Machine</i> (ELM).....	26
2.7.5.1 <i>Single Layer Feedforward Neural Network</i>	26
2.7.6 <i>Artificial Neural Network</i> (ANN)	30
2.7.7 Analisis Regresi	31
2.7.8 MATLAB R2014a.....	32
BAB III METODE PENELITIAN	34
3.1. Waktu dan Tempat Penelitian	34
3.2. Alat dan Bahan Penelitian	34
3.3. Desain Penelitian.....	35
3.4. Objek Penelitian	39
3.5. Teknik Pengumpulan data	39
3.6. Desain dan Implementasi	40
3.6.1 Rencana Denah Bangunan Perumahan.....	40
3.6.2 Permodelan di EnergyPlus.....	42
3.6.3 Simulasi EnergyPlus.....	43
3.6.4 Model AI <i>machine learning</i> Estimasi	45
3.6.5 <i>Data pre-processing</i>	46
3.6.6 Prosedur <i>Extreme Learning Machine</i>	47
3.6.7 Prosedur <i>Artificial Neural Network</i>	50
3.6.8 Prosedur <i>General Linear Regression</i>	51
3.6.9 Prosedur Evaluasi Akurasi Model.....	52
BAB IV HASIL DAN PEMBAHASAN	54
4.1 Performa Estimasi Konsumsi Energi Menggunakan ELM.....	54
4.2 Performa Estimasi Konsumsi Energi Menggunakan ANN.....	57
4.3 Performa Estimasi Konsumsi Energi Menggunakan GLR	60

4.4 Keseluruhan Performa <i>Machine Learning</i>	63
4.4.1 Estimasi Konsumsi Energi <i>Cooling</i> Pada Bangunan Tipe A.....	63
4.4.2 Estimasi Konsumsi Energi <i>Cooling</i> Pada Bangunan Tipe B	65
BAB V KESIMPULAN DAN SARAN	68
5.1 Kesimpulan	68
5.2 Saran.....	69
DAFTAR PUSTAKA	70
LAMPIRAN	75

DAFTAR TABEL

Tabel 3.1 Alat dan Bahan Penelitian	34
Tabel 3.2 Deskripsi luas bangunan	40
Tabel 3.3 Deskripsi Material	42
Tabel 3.4 Deskripsi lokasi bangunan	42
Tabel 3.5 Parameter ELM	49
Tabel 3.6 Parameter ANN	51
Tabel 3.7 Paramater GLR	52
Tabel 4.1 Performa Komputasi ELM Bangunan A.....	54
Tabel 4.2 Performa Komputasi ELM Bangunan B	56
Tabel 4.3 Performa Komputasi ANN Bangunan A	57
Tabel 4.4 Performa Komputasi ANN Bangunan B	59
Tabel 4.5 Performa Komputasi GLR Bangunan A	60
Tabel 4.6 Performa Komputasi GLR Bangunan B	62
Tabel 4.7 Perbandingan Performa model <i>Machine Learning</i> untuk Estimasi komsumsi energi pada bangunan A	64
Tabel 4.8 Perbandingan Performa model <i>Machine Learning</i> untuk Estimasi komsumsi energi pada bangunan B	66

DAFTAR GAMBAR

Gambar 2.1 Definisi Genetik Area Suatu Bangunan	14
Gambar 2.2 Penggunaan energi dalam bangunan standar(ISO 2013)	15
Gambar 2.3 Layar Kerja Sketchup 2017pro	16
Gambar 2.4 Sistem EnergyPlus.....	17
Gambar 2.5 Internal elemen pada EnergyPlus	18
Gambar 2.6 Layar <i>EP_Launch</i>	19
Gambar 2.7 Status Selesai Simulasi	20
Gambar 2.8 <i>Single Layer Network</i>	23
Gambar 2.9 <i>Multi Layer Network</i>	23
Gambar 2.10 Struktur ELM	27
Gambar 2.11 Struktur ANN	30
Gambar 3.1 Skema Penelitian	38
Gambar 3.2 Deskripsi Denah bangunan.....	40
Gambar 3.3 Deskripsi Zona bangunan	41
Gambar 3.4 Model 3D Desain Bangunan	41
Gambar 3.5 Diagram Alir simulasi energi pada bangunan	43
Gambar 3.6. <i>Input weather data</i>	44
Gambar 3.7. <i>Text editor.idf</i>	45
Gambar 3.8 Diagram Alir <i>machine learning</i> untuk prosedur estimasi konsumsi energi.....	46
Gambar 3.9 Diagram alir <i>Extreme Learning Machine</i>	47
Gambar 3.10 Proses Komputasi AAN menggunakan nntool.....	50
Gambar 4.1 Hasil proses <i>training</i> ELM bangunan A	55
Gambar 4.2 Hasil proses <i>testing</i> ELM bangunan A.....	55
Gambar 4.3 Hasil proses <i>training</i> ELM bangunan B.....	56
Gambar 4.4 Hasil proses <i>testing</i> ELM bangunan B.....	57
Gambar 4.5 Hasil proses <i>training</i> ANN bangunan A	58
Gambar 4.6 Hasil proses <i>testing</i> ANN bangunan A	58

Gambar 4.7 Hasil proses <i>training</i> ANN bangunan B	59
Gambar 4.8 Hasil proses <i>testing</i> ANN bangunan B.....	60
Gambar 4.9 Hasil proses <i>training</i> GLR bangunan A.....	61
Gambar 4.10 Hasil proses <i>testing</i> GLR bangunan A	61
Gambar 4.11 Hasil proses <i>training</i> GLR bangunan B	62
Gambar 4.12 Hasil proses <i>testing</i> GLR bangunan B	63
Gambar 4.13 Hasil proses <i>training</i> konsumsi energi <i>cooling</i> pada bangunan Tipe A	64
Gambar 4.14 Hasil proses <i>testing</i> konsumsi energi <i>cooling</i> pada bangunan Tipe A	65
Gambar 4.15 Hasil proses <i>training</i> konsumsi energi <i>cooling</i> pada bangunan Tipe B.....	66
Gambar 4.16 Hasil proses <i>testing</i> konsumsi energi <i>cooling</i> pada bangunan Tipe B	67

DAFTAR LAMPIRAN

Lampiran 1. Usulan Judul Skripsi dan Dosen Pembimbing	76
Lampiran 2. Usulan Topik Skripsi	77
Lampiran 3. Usulan Dosen Pembimbing	78
Lampiran 4. Penetapan Dosen Pembimbing	79
Lampiran 5. Laporan Selesai Bimbingan Proposal Skripsi	80
Lampiran 6. Berita Acara Seminar Proposal Skripsi	81
Lampiran 7. <i>Code ELM</i>	82
Lampiran 8. <i>Code ANN</i>	87
Lampiran 9. <i>Code GLR</i>	91
Lampiran 10. <i>Weather data From EnergyPlus</i>	93
Lampiran 11. Pembagian <i>Weather Zone ASHRAE</i>	94
Lampiran 12. Contoh Data Bangunan Tipe A	95
Lampiran 13. Contoh Data Bangunan Tipe B	97

BAB I

PENDAHULUAN

1.1 Latar Belakang

Terdapat tiga sektor ekonomi utama yang memiliki penggunaan energi listrik yang tinggi yaitu sektor industri, sektor transportasi dan sektor bangunan, yang mana pengolahan konservasi energi merupakan hal yang penting (Al-Homoud, 2001). Namun energi yang tersedia tidak cukup untuk memenuhi semua kebutuhan semua sektor dalam menunjang setiap kehidupan manusia (Diamantoulakis *et al.*, 2015). Hal ini mendasari adanya sistem *smart energy* dimasa depan untuk perencanaan, kontrol dan manajemen energi yang optimal (Lund Henrick *et al.*, 2017). *Smart Grid* merupakan sistem tenaga listrik generasi masa depan yang mampu mengelola permintaan listrik secara berkelanjutan, dapat diandalkan dan ekonomis dengan menggunakan teknologi informasi dan komunikasi digital yang canggih (Bose, 2017). Salah satu visualisasi teknologi sistem *smart grid* yaitu pada penyaluran energi rumah yang nantinya akan mendukung pada sistem *Smart home* (Fan *et al.*, 2017).

Smart home merupakan suatu implementasi teknologi otomatis rumah yang melingkupi teknologi rumah yang didalamnya dapat mengelola energi secara efisien pada penyaluran penggunaan energi yang dipergunakan (Zhuang & Liang, 2015). Hal yang harus diperhatikan dalam membuat sebuah model energi pada *Smart home* yaitu penyimpanan daya, penjadwalan penggunaan alat dan *thermal* pada rumah (Mehdi & Roshchin, 2015). Dimana perekaman data dapat terperinci dengan adanya *smart meter* (Fayaz & Kim, 2018).

Kinerja energi bangunan atau *Energy Performance of Building* (EPB) baru-baru ini menjadi masalah besar karena meningkatnya kekhawatiran emisi gas rumah kaca, emisi CO₂ dan dampak buruk yang tak henti-hentinya terhadap lingkungan (Park *et al.*, 2016). Pada (ISO, 2013) menjelaskan bahwa total penggunaan energi pada bangunan pada bagian HVAC meliputi ruang pendingin, ruang pemanas, air panas domestik dan gerakan udara.

Penggunaan energi menurut (IEA,2018) pada sektor bangunan merupakan penyumbang pemakaian energi terbesar ke-3 setelah sektor industri dan transportasi dari penggunaan total energi. Menemukan cara baru untuk mengurangi konsumsi energi di gedung tanpa mengorbankan kenyamanan dan kualitas udara dalam ruangan adalah tantangan penelitian yang terus – menerus diteliti (Vakiloroaya *et al.*, 2014). Untuk mendapatkan pengurangan dan perbaikan energi yang signifikan dalam bangunan baru dalam mencapai efisiensi energi (Naji *et al.*, 2016).

Salah satu cara yang terbukti untuk mencapai efisiensi energi yang dipergunakan dengan keluaran berupa total beban pada HVAC adalah merancang sistem atau desain yang menggunakan konfigurasi baru dari komponen sistem yang ada (Ascione, 2017). Setiap bidang penggunaan HVAC memiliki persyaratan desain khusus yang berbeda dan masing-masing memberikan peluang untuk penghematan energi (Vakiloroaya *et al.*, 2014).

Dalam praktiknya, mengidentifikasi parameter yang secara substansial memengaruhi konsumsi energi dapat membantu mengoptimalkan desain bangunan (Chou & Bui, 2014). Parameter yang berpengaruh, misalnya, kekompakan relatif bangunan (International & Conference, 2003), iklim (Wan *et al.*, 2011), pemilihan

material bangunan, luas permukaan, luas dinding, luas atap, dan orientasi struktur bangunan (Wan *et al.*, 2011), Meramalkan atau memperkirakan konsumsi energi pada tahap desain atau analisis opsi *retrofit* adalah penting untuk upaya pengurangan energi dan emisi (Fumo, 2014).

Ada beberapa pendekatan yang disampaikan Zhao et al, terdapat dua metode untuk memperkirakan permintaan energi pada bangunan yaitu dengan permodelan secara fisik dan permodelan menggunakan kecerdasan buatan. Metode permodelan fisik didasarkan pada metode teknik fisik dengan menggunakan karakteristik termodinamika dan perpindahan panas untuk menentukan keseimbangan energi bangunan (Zhao & Magoulès, 2012). Beberapa perangkat lunak simulasi bangunan fisik telah dikembangkan seperti EnergyPlus (EnergyPlus, 2018a), TRNSYS (TRNSYS, 2018), Beopt (BEopt, 2018) dll.

Model kecerdasan buatan atau *Artificial Intelligence* (AI) baru-baru ini terbukti menjadi pendekatan alternatif yang layak untuk memprediksi *Energy Performance of Building* (EPB) (Fumo, 2014). *Artificial Intelligence* (AI) digunakan untuk mengembangkan model yang mensimulasikan proses inferensi manusia (Chou & Bui, 2014). Dengan demikian, AI dapat menyimpulkan fakta-fakta baru dari informasi yang diperoleh sebelumnya dan dapat secara adaptif berubah sebagai respons terhadap perubahan dalam data historis (Tsanas & Xifara, 2012). Banyak penelitian telah mengeksplorasi penggunaan model AI untuk memprediksi berbagai kepentingan dalam konteks kinerja energi bangunan (Wei *et al.*, 2018a), (Ekici & Aksoy, 2009).

Berdasarkan beberapa literatur yang sudah ada mempergunakan beberapa metode algoritma *Machine Learning* seperti *General Linear Regression* (GLR) (Fumo & Biswas, 2015), SVM (*Support Vector Machine*) (Chou & Bui, 2014; Lu *et al.*, 2017) dan ANN BP (*back propagation*) (Sacchetti *et al.*, 2017; Ahmad *et al.*, 2014) dapat dipergunakan untuk pelatihan dalam jaringan saraf akan tetapi masih memiliki kelemahan tertentu. ANN khususnya tipe *Back Propagation* memiliki kelemahan dalam waktu pembelajaran yang lama, kemudian pada penelitian yang dilakukan oleh (Huang *et al.*, 2006) memperkenalkan *Exreme Learning Machine* (ELM) sebagai algoritma *Single Layer Feed Forward Neural Network* (SLFN). Algoritma tersebut mampu memecahkan masalah gradien baris pada propagasi pada BPNN dan mempecepat waktu pelatihan yang diperlukan sehingga proses pembelajaran jauh lebih cepat.

Berdasarkan studi penelitian yang telah dilakukan, beberapa model kecerdasan buatan telah dikembangkan untuk memperkirakan penggunaan energi pada bangunan perumahan. Dari teknik di atas, menunjukkan ELM memiliki kinerja yang lebih baik untuk memperkirakan / Estimasi konsumsi energi. Namun, aplikasi teknologi AI untuk memperkirakan konsumsi energi pada berbagai jenis bangunan di negara-negara tropis seperti di kawasan Asia Tenggara belum diselidiki lebih lanjut. Oleh karena itu, penelitian ini akan menyelidiki teknik AI *machine learning* untuk estimasi konsumsi energi *cooling* untuk dua jenis bangunan tempat tinggal di wilayah cuaca tropis. Dataset yang digunakan dari simulasi penggunaan energi satu tahun menggunakan perangkat lunak Energyplus (E+). Kemudian semua teknik akan disimulasikan menggunakan MATLAB. Hasil

kinerja model AI akan dibandingkan secara akurat dan efisien dalam estimasi energi dengan data EnergyPlus yang dihitung.

1.2 Identifikasi Masalah

Berdasarkan latar belakang yang telah dijelaskan, maka dapat diidentifikasi masalah dalam penelitian ini yaitu faktor yang membebani konsumsi energi adalah HVAC. Beban HVAC diperlukan untuk mengetahui performa konsumsi energi yang membebani energi pada suatu bangunan rumah dalam simulasi konsumsi energi. Hal ini dipengaruhi pada faktor geometris bangunan, dan cuaca. Model *artificial intelligence* dapat dipergunakan untuk memperkirakan perhitungan dari setiap faktor yang ada pada konsumsi energi pendingin bangunan. Beberapa AI telah diterapkan dalam memperkirakan konsumsi energi pada bangunan yang memiliki tingkat akurasi, proses pembelajaran dan waktu yang berbeda dalam memperoleh hasil komputasi prakiraan konsumsi energi.

1.3 Rumusan Masalah

Dari identifikasi masalah yang telah dijelaskan bahwa beberapa Model *artificial intelligence* seperti *Extreme Learning Machine* (ELM), *Artificial Neural Network* (ANN) dan *General Linear Regression* (GLR) telah diterapkan dalam memprakirakan konsumsi energi bangunan. Akan tetapi, beberapa model algoritma tersebut belum banyak dikembangkan serta dinvestigasi lebih lanjut performa dan tingkat akurasi untuk memperkirakan konsumsi energi cooling pada bangunan perumahan di wilayah tropis. Oleh karena itu dalam penelitian ini akan menerapkan

serta menginvestigasi lebih lanjut performa beberapa model AI untuk memperkirakan konsumsi energi *cooling* pada bangunan perumahan.

1.4 Batasan Masalah

Ruang lingkup pembahasan dalam penelitian ini dibatasi sebagai berikut :

1. Contoh desain bangunan tipe perumahan berasal dari Indonesia yang mana memiliki keluaran parameter berupa *Energy Cooling Consumption* .
2. Pada pengaturan masukkan *dataset weather* menggunakan salah satu data negara tropis yaitu malaysia.
3. Simulasi yang dilakukan yaitu penerapan faktor geometris bangunan, dan iklim atau cuaca tropis yang mempengaruhi beban HVAC (*cooling load*) pada konsumsi energi pada desain bangunan.
4. Pengaturan sistem HVAC terbatas pada *template* di *software* EnergyPlus yang telah disediakan.
5. Analisa data untuk prediksi kinerja energi pada desain bangunan berdasarkan korelasi geometris bangunan, dan iklim atau cuaca tropis. Dataset *weather* yang dipergunakan pada bangunan yang mana HVAC dilihat melalui hasil akurasi perhitungan pada *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) dan R^2 .
6. Fokus Skripsi ini pada penerapan beberapa model algoritma *machine learning* untuk mengetahui tingkat akurasi dalam memperkirakan konsumsi energi pendingin yang pada data bangunan perumahan.
7. Sistem implementasi dan pengolahan data untuk memperkirakan konsumsi energi pendingin menggunakan *software* Matlab R2014a.

8. Hasil setiap penggunaan model algoritma akan di bandingkan performa dan tingkat akurasi.
9. Analisis berdasarkan hasil implementasi yang ditampilkan oleh grafik hasil simulasi.

1.5 Tujuan Penelitian

Berdasarkan rumusan masalah tersebut, maka tujuan dari penelitian ini adalah untuk menerapkan Algoritma *artificial intelligence Extreme Learning Machine* (ELM), *Artificial Neural Network* (ANN) dan *General Linear Regression* (GLR) serta menginvestigasi performa dan tingkat akurasi dalam memperkirakan konsumsi energi *cooling* pada bangunan perumahan di wilayah Tropis. Penelitian ini menerapkan proses simulasi estimasi konsumsi energi dengan pemberian beban *cooling* dengan musim negara tropis menggunakan simulasi EnergyPlus kemudian *dataset* dianalisa menggunakan beberapa model AI untuk memperoleh performa dan akurasi dari hasil Estimasi konsumsi energi pada bangunan dengan *output* berupa *cooling load* (Wh).

1.6 Manfaat Penelitian

Berdasarkan tujuan penelitian yang telah diuraikan, manfaat yang diharapkan dalam penelitian ini adalah :

1. Hasil penelitian ini dapat memberikan pengetahuan mengenai model AI yang sesuai dan akurat untuk memperkirakan penggunaan energi *cooling* pada bangunan *perumahan* kepada masyarakat secara umum.

2. Memberikan gambaran simulasi penggunaan energi pada desain bangunan dengan masukan faktor geometris bangunan dan iklim.
3. Menjadi pemodelan simulasi energi penggunaan energi *cooling* pada bangunan perumahan.
4. Menjadi referensi pada penelitian selanjutnya yang berkaitan dengan Estimasi penggunaan energi *cooling* pada bangunan perumahan.

1.7 Penegasan Istilah

Untuk menghindari penafsiran yang berbeda tentang penelitian ini, diberikan beberapa penjelasan istilah sebagai berikut:

1. HVAC

Heating Ventilation and Air Condition merupakan beban konsumsi energi yang dipasang pada suatu bangunan, yang berupa *heating* dan *cooling*.

2. AI

artificial intelligence atau kecerdasan buatan model yang mensimulasikan proses inferensi manusia

3. RMSE

Root Mean Square Error digunakan untuk mengevaluasi peramalan kinerja model

4. MAE

Mean Absolute Error digunakan untuk mengevaluasi peramalan kinerja model dalam bentuk persen.

BAB II

KAJIAN PUSTAKA DAN LANDASAN TEORI

2.1 Kajian Pustaka

Penelitian terdahulu yang berkaitan dengan prediksi /prakiraan kinerja energi listrik pada suatu bangunan, antara lain :

1. Penelitian dilakukan oleh Shabunko *et al.*, 2016 yang berjudul “ *EnergyPlus Models for the Benchmarking of residential building in Brunei Darussalam* ” melakukan penelitian mengenai kinerja energi pada bangunan menggunakan EnergyPlus untuk simulasi kinerja energi pada 3 tipe bangunan *perumahan* dimana pada simulasi tersebut diberikan pula beban HVAC berupa pendingin ruangan dengan VAV *system* VRF dengan hasil model kinerja EnergyPlus menghasilkan *Energy Use Intensity* (EUI) per tahun untuk setiap bangunan dengan nilai 64.2 – 47.8 kWh/m² .
2. Penelitian dilakukan oleh Tsanas and Xifara 2012 yang berjudul “*Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools*”. Pada Penelitian ini melakukan prediksi kinerja energi menggunakan Estimasi kuantitatif akurasi simulasi menggunakan Ecotect dengan waktu penggunaan 15 -20 jam pada hari kerja dan 10-20 jam pada akhir pekan untuk kinerja energi sample bangunan tempat tinggal berdasarkan area bangunan yang disesuaikan dengan lingkungan di turki menggunakan *Machine Learning Tools*, mempergunakan model klasifikasi dengan mempergunakan metode *Iteratively reweighted least*

squares dan *Random Forest* pada keluaran prediksi berupa *Heating load* dan *Cooling load*. Kesimpulan dari penelitian ini bahwa faktor *Glazing area* merupakan faktor terpenting pada EPB. Dan menggunakan metode *Random forest* untuk melihat variabel yang berpengaruh terbukti baik. Simulasi yang dilakukan pada Ecotect untuk HL dan CL dianggap mencerminkan nilai sebenarnya ada di kenyataan.

3. Penelitian dilakukan oleh Chou & Bui, 2014, yang berjudul “*Modeling heating and cooling loads by artificial intelligence for energy-efficient building design*”. Pada penelitian memiliki tujuan untuk mendapatkan metode terbaik dan penggabungan metode untuk mengisi kesenjangan yang dialami pada proses perhitungan data hasil simulasi prediksi kinerja energi beban *Heating* dan *Cooling* berasal dari data kinerja energi pada desain bangunan yang dilakukan oleh Tsanas dan Xifani pada tahun 2012. Penelitian ini mempergunakan model tunggal yaitu : ANN , SVR, CART , CHAID dan GLR. Pada kesimpulannya model gabungan SVR + GA merupakan model yang terbaik pada *cooling load* dengan hasil RMSE = 1.566, MAE = 0.973 dan MAPE = 3.45% tetapi, pada heating load hanya model tunggal SVR yang memperlihatkan performa terbaik. Pada model tunggal yang memiliki performa terbaik pertama SVR dan kedua ANN akan tetapi model SVR sangat sulit diimplementasikan dalam pencarian parameter yang diperlukan dibandingkan dengan pengimplementasian ANN.
4. Penelitian dilakukan oleh Deb *et al.*, 2016 yang berjudul “*Forecasting diurnal cooling energy load for institutional buildings using Artificial Neural*

Networks” pada penelitian ini peneliti melakukan teknik peramalan atau prakiraan mengenai konsumsi energi dengan beban pendingin pada bangunan institusional yang mempergunakan teknik analisis data ANN. Penggunaan energi pada beban pendingin dipergunakan/ dinyalakan pada pukul 07:00 – 21:00 dengan hasil data diambil setiap interval 30 menit, dimana beban pendingin menggunakan pengaturan VAV *system*. Data yang telah didapat dibuat menjadi 5 kelas dan 20 kelas yang masing – masing melakukan prakiraan penggunaan energi pada 20 hari kedepan dengan hasil algoritma AAN *feedforward* dengan pelatihan teknik *bayesian regularization* paling efektif dan cepat dalam komputasi prakiraan dengan nomor kelas sebagai masukkan dengan pembagian 5 kelas memiliki variabilitas tinggi.

5. Penelitian dilakukan oleh (Naji *et al.*, 2016), yang berjudul “*Estimating building energy consumption using extreme learning machine method*” memiliki tujuan untuk mengambil korelasi antara material utama parameter pembangun rumah dan distrik beban pemanas dan pendingin dengan melakukan 180 simulasi pada contoh bangunan yang bertipe perumahan untuk menghasilkan model *predictive* ELM. Mempergunakan 5 bagian tembok yaitu *Gypsum board*, *OSB*, *acoustic gypsum*, *OSB* dan *cement-bonded particle board* pada model bangunan dengan cuaca yang disesuaikan dengan berada di turki dengan iklim subtropis yang telah tersedia pada EnergyPlus. Hasil simulasi kemudian dianalisis menggunakan model algoritma ELM, ANN dan GP. ELM yang mengimplemenasikan algoritma pembelajaran untuk SLFN (*Single layer feed- forward neural network*) memiliki kelebihan dalam waktu

dalam proses pembelajaran dibandingkan dengan *algoritma network-learning feedforward* tradisional yaitu *back propagation*. ELM mampu mencapai kesalahan terkecil pada proses pelatihan dan nilai dari bobot.


6. Penelitian dilakukan oleh Nilashi *et al.*, 2017, yang berjudul “*A soft Computing Method for the Predicion of Energy Performance of Residential Building*”. Tujuan penelitian ini yaitu memprediksi kinerja energi dari data kinerja energi pada desain bangunan yang berasal dari data kinerja energi pada desain bangunan yang dilakukan oleh Tsanas dan Xifani pada tahun 2012 menggunakan model *clustering* dengan teknik *Extreme Machine* yang digabungkan dengan PCA- ANFIS. Berdasarkan keluaran berupa *Heating Load* dan *Cooling load* dengan menggunakan metode EM-PCA-ANFIS yang dikerjakan dalam penelitian kemudian dibandingkan dengan beberapa metode lainnya yaitu SVR, ANFIS, NN, CART, ML, PCA-ANFIS dan EMARS. Kesimpulan dari penelitian ini yaitu Hasil perhitungan EM-PCA-ANFIS memperoleh hasil RMSE dan MAPE HL = 0.26 & 1.39%, CL 0.81 dan 2.45%, akan tetapi model salah satu metode *single Support Vector Regression* memperoleh hasil yang baik pada RMSE dan MAPE dibandingkan dengan metode *single* lainnya yaitu HL 0.80 & 1.93% dan CL 1.32 2.82%.
7. Penelitian dilakukan oleh (Kumar *et al.*, 2018), yang berjudul “*Intra ELM variants ensemble based model to predict energy performance in residential buildings* ”. Penelitian ini menerapkan teknik algoritma analisa data untuk memperkirakan performa penggunaan energi pada bangunan perumahan yang diberikan beban HVAC berupa *Heating* dan *Cooling*. Algoritma yang

dipergunakan yaitu *Extreme Learning Machine (ELM)*, *Online Extreme Learning Machine (OELM)* dan *Bidirectional Extreme Learning Machine (B-ELM)*. Dataset yang diperoleh bagi menjadi 4 kelas yang mana penggunaan setiap algoritma mempergunakan aktivasi fungsi signoid, hardlim dan RBF. Hasil dari penelitian ini yaitu performa secara keseluruhan algoritma ELM tunggal lebih baik dibandingkan dengan beberapa algoritma lainnya seperti ANN,SVR,CART, ANN-SVR, RF, OSELM dan B-ELM dengan hasil estimasi *cooling load* : RMSE 0.1348, MAE : 0.646 dan Heating RMSE 0.1389,MAE : 0.3215 dimana waktu yang diperlukan dalam proses perhitungan *cooling load* yaitu 0.16 s dan *heating load* 0.1652s.

2.2 Energy Performance of Building

Kinerja energi pada bangunan merupakan hal yang rumit diprediksi dikarena tergantung pada beberapa variabel yang terkait dengan karakteristik bangunan, peralatan atau sistem, cuaca, penghuni, dan pengaruh sosiologis yang diberikan pada bangunan (Fumo, 2014). Pemasangan material yang berbeda dapat mengubah perilaku termal bangunan (Schiavon *et al.*, 2010).

Pemberian parameter energi bangunan secara preskriptif merupakan persyaratan minimum tentang sifat termal dari komponen bangunan. Untuk menjelaskan geometri bangunan dengan cara yang sederhana, beberapa standar bangunan yang berhubungan dengan energi menggunakan indikator numerik sederhana yang berfokus pada kekompakan geometris bangunan (International and Conference 2003).



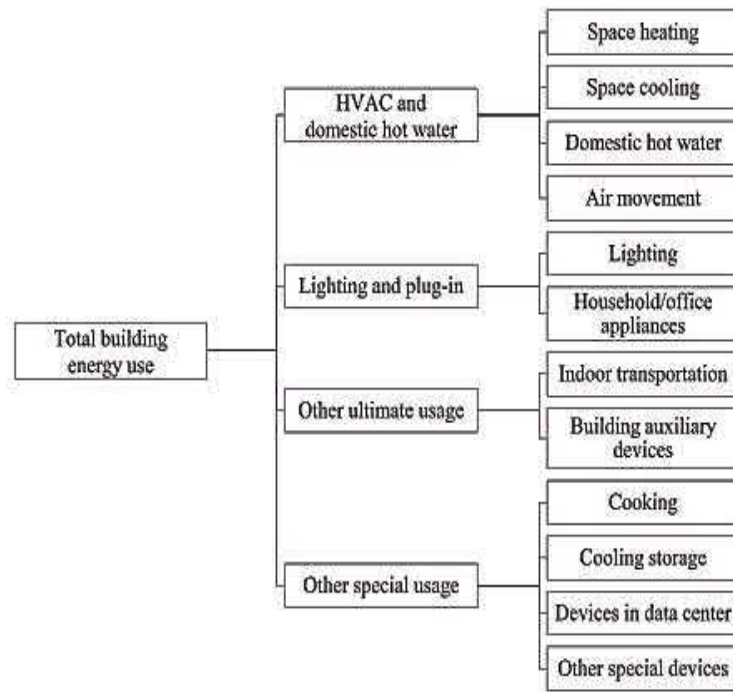
Gambar 2.1 Defenisi Genetik Area Suatu Bangunan

Luas permukaan dihitung sebagai total luas dinding, luas atap dan luas lantai. Gambar. 2.1 menunjukkan rincian luas dinding, luas atap, luas lantai dan tinggi bangunan keseluruhan (Chou & Bui, 2014).

2.3 Beban Konsumsi Energi Pada Bangunan

Manajemen dan optimalisasi dalam membangun konsumsi energi membutuhkan pemahaman penuh tentang kinerja bangunan, yang pertama-tama harus mengidentifikasi sumber daya energi dan penggunaan akhir utama sebuah bangunan. Sumber daya energi dalam sebuah bangunan biasanya mengacu pada listrik, gas alam, dan pasokan pemanas distrik (Wei *et al.*, 2018a).

Penggunaan akhir utama yang terkait termasuk sistem pemanas, ventilasi dan AC (HVAC), air panas domestik, pencahayaan, plug-load, lift, peralatan dapur, peralatan dan peralatan tambahan. Perhatikan bahwa sumber energi dan banyaknya penggunaan energi pada bangunan akan berpengaruh pada penggunaan akhir, jadwal operasi HVAC dan kondisi *indoor/outdoor* adalah dua faktor penting yang perlu dipertimbangkan dalam analisis kinerja bangunan (ISO 12655).

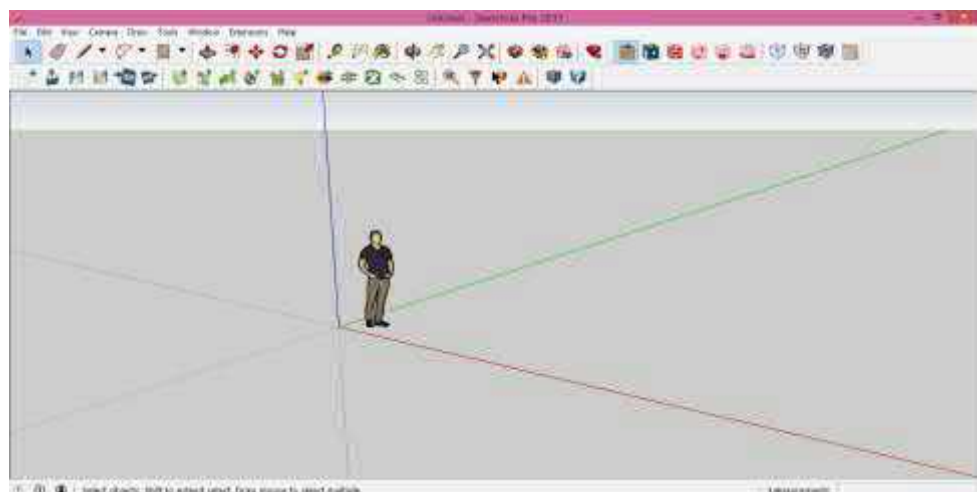


Gambar 2.2 Penggunaan energi dalam bangunan standar (ISO 2013).

Teknologi HVAC secara nyata terus berkembang yang disesuaikan dengan kebutuhan bangunan seperti pemilihan komponen – komponen pembangun HVAC (Standard Heating & AirConditioning, 2019) yang diperuntukan untuk menyempurnakan penggunaan energi secara efisien (ThermalFlow, 2013). Maka untuk itu diperlukan suatu metode mengenai prediksi kinerja maupun konsumsi energi berdasarkan data yang ada, (Fumo, 2014) (Wei *et al.*, 2018a).

2.4 SketchUp 2017

Perangkat lunak SketchUp merupakan salah satu perangkat lunak yang dipergunakan dalam membuat suatu permodelan 3D yang mudah dipergunakan dengan tidak mengesampingkan fungsionalitas (Naji et al., 2016). Para pengguna SketchUp adalah arsitek, perancang, pembangunana, pembuat dan insinyur yang membentuk dunia fisik secara visual. Pada permodelan 3D dimulai dengan membuat suatu garis dan bentuk, dan bantuan *tools* yang tersedia dorong dan tarik permukaan untuk mengubah dalam bentuk 3D (Sketchup, 2018).



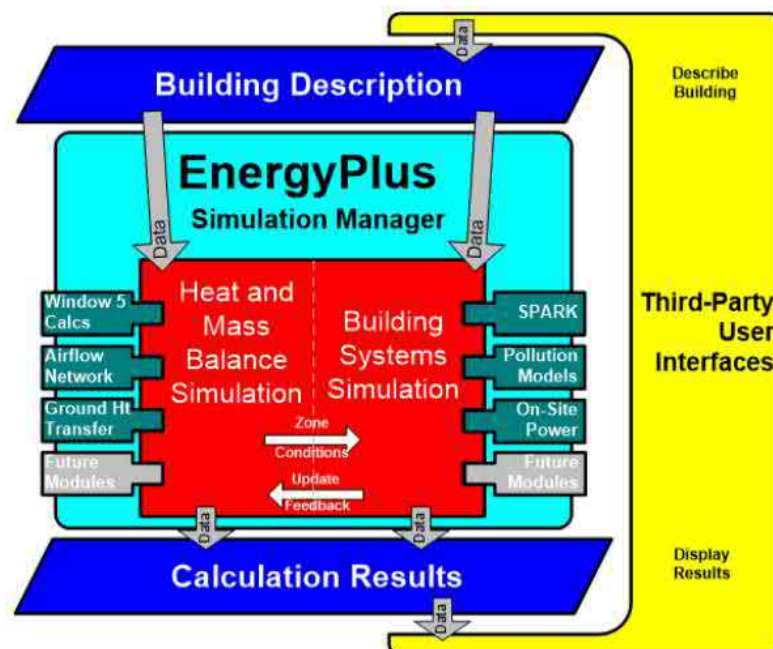
Gambar 2.3. Layar Kerja Sketchup 2017 pro

2.5 EnergyPlus V9-0-1

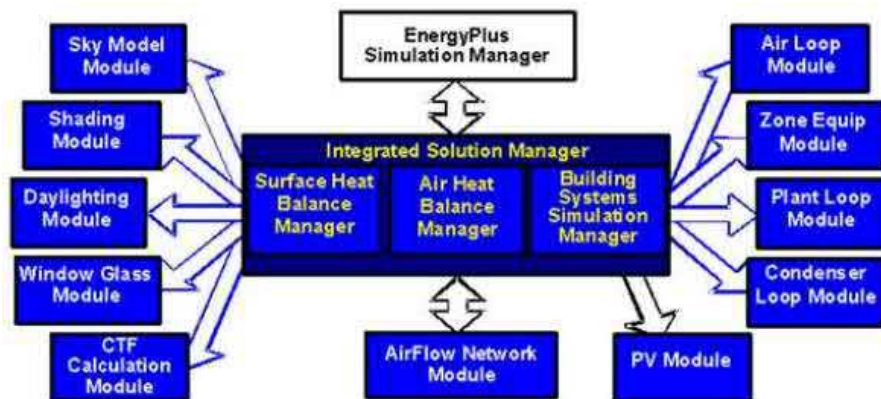
EnergyPlus merupakan perangkat lunak yang memiliki program BLAST (*Building Loads Analysis and Thermodynamics*) dan DOE-2 yang dikembangkan sejak 1970 sebagai perangkat lunak simulasi eneri dan beban (EnergyPlus, 2010). Perangkat lunak ini ditujuka untuk insinyur desain dalam mengukur peralatan HVAC yang sesuai serta megoptimalkan kinerja energi. EnergyPlus akan menghitung beban pemanasan dan pendinginan yang diperlukan untuk

mempertahanan *set point* kontrol termal, kondisi di seluruh sistem HVAC sekunder dan beban kumpanan (EnergyPlus, 2010). Beberapa penggunaan *software* EnergyPlus sebagai berikut :

1. Integrasi sistem sekunder terpaduan simulasi yang digabungkan secara erat.
2. ASCII *texts* berdasarkan masukan, cuaca dan dokumen keluaran yang mencakup kondisi lingkungan setiap jam atau sub –jam, dan standar laporan.
3. Konduksi pemindahan panas melalui elemen bangunan seperti dinding, atap, lantai ,dll
4. Model kenyamanan termal berdasarkan aktivitas, kelembaban dll



Gambar 2.4 Sistem EnergyPlus



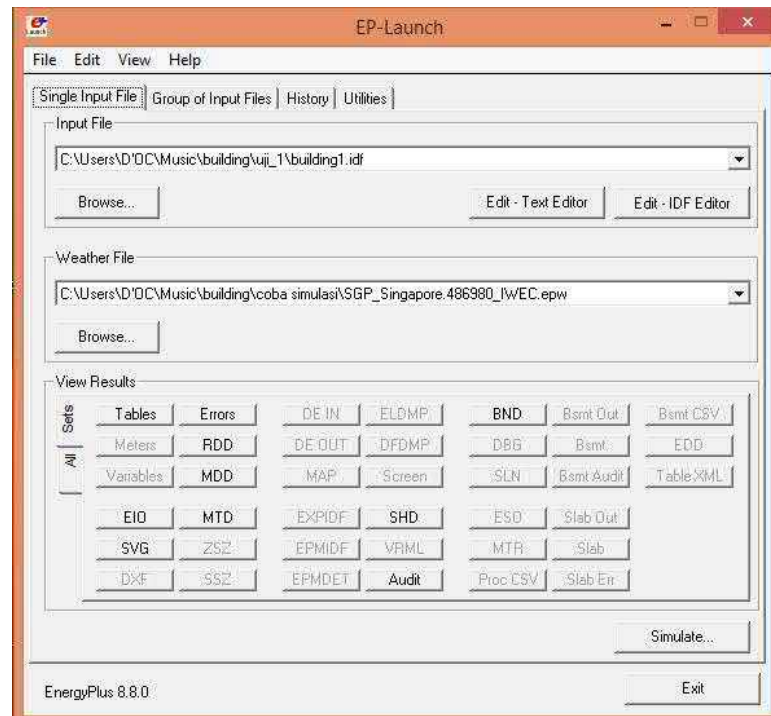
Gambar 2.5 Internal Elemen Pada *EnergyPlus*

2.5.1 Menjalankan Simulasi pada *EnergyPlus*

Perangkat lunak *EnergyPlus* terdiri dari sebuah dokumen eksekusi yang diperlukan sebagai masukan dokumen yang menggambarkan zona dari desain bangunan yang dimodelkan untuk simulasi. Pada program perangkat lunak ini menghasilkan keluaran yang berdasarkan beberapa faktor keadaan yang telah dimasukkan. Untuk menjalankan program simulasi yaitu dengan membuka *EP-Launch* kemudian memasukkan dokumen input file dengan format *.idf* dan dapat melakukan *editing* menggunakan *IDF Editor* (*Input Data File Editor*).

EP-Launch merupakan jendela yang dipergunakan untuk simulasi yang ada telah diinstal di windows yang dapat dipergunakan untuk memilih dokumen dan menjalankannya di *EnergyPlus*. Pada simulasi *EP-Launch* memerlukan dokumen masukan yang berformat *file.idf* dan memerlukan dokumen *Weather data* (parameter standar temperatur, *humidity*, tekanan udara, *wind speed* dan arah, dll) (EnergyPlus, 2018b) yang berformat *file.epw*

yang dapat diperoleh di *website EnergyPlus Weather* kemudian dilakukan proses simulasi dengan menekan tombol “simulasi” pada EP_Launch.



Gambar 2.6. Layar *EP-Launch*

2.5.2 Hasil Simulasi

Setelah simulasi berjalan dengan baik, akan muncul status *box* hasil *running* simulasi. Status *box* akan memberikan informasi singkat tentang sistem. Kemudian untuk menampilkan hasil (*output file*) secara detail dapat dipilih pada tampilan *EP_Launch*. *Output* file dapat dilihat dalam beberapa jenis data seperti *SpreadSheet*, *HTML*, *Texts Editor* dan menampilkan gambar serta laporan *error* yang terjadi dalam proses simulasi.



Gambar 2.7. Status Selesai Simulasi

2.5.3 HVAC Template

HVAC *Template* merupakan suatu cara pengguna untuk mespesifikasikan sistem HVAC yang akan dipergunakan, dengan cara melakukan proses *running* simulasi menggunakan *template* yang tersedia. Untuk melakukan perubahan dapat membuka *file.idf editor*. Dengan *template* yang tersedia sangat memudahkan pengguna E+ untuk meminimalkan kesalahan *input file*.

Berikut ini adalah beberapa kombinasi dari HVAC *template* yang tersedia (EnergyPlus, 2010) :

a. *Simple IdealLoad System for Sizing and Load Oriented*

HVACTemplate : The Thermostat

HVACTemplate :Zone: IdealLoadAirSystem

b. *Packaged Terminal Air Conditioner*

c. *Direct expansion cooling, pakaged and Split system*

HVACTemplate :Thermostat

HVACTemplate :zone: Unitary

HVACTemplate :system: Unitary

d. *VRF system water-cooled Chiller, Tower*

HVACTemplate : The Thermostat

HVACTemplate :Zone : VRF

HVACTemplate :system: VRF

HVACTemplate :ChilledWaterLoop

HVACTemplate :Chiller

HVACTemplate :Tower

e. *Fan coil system with boiler and chiller*

2.6 OpenStudio

OpenStudio merupakan perangkat lunak yang dapat dipergunakan oleh *operating system* windows, Mac dan Linux. Perangkat lunak ini mendukung permodelan energi pada seluruh bangunan menggunakan EnergyPlus. OpenStudio SkecthUp Plug-in adalah ekstensi untuk permodelan SketchUp 3D yang memungkinkan pengguna membuat suatu model geometri dengan cepat untuk dianalisis penggunaan energi menggunakan EnergyPlus (OpenStudio, 2018).

2.7 Machine Learning

Machine Learning atau pembelajaran mesin pada prosesnya mementingkan generalisasi sebagai pencarian melalui kemungkinan hipotesis. Teknik mesin pembelajaran dibedakan dua yaitu Regresi dan Klasifikasi (Ian H. Witten, Eibe, Frank, 2011).

(Dasgupta & Nath, 2016) menjelaskan bahwa Algoritma pembelajaran yang diawasi melalui data pelatihan dan menghasilkan aturan umum (fungsi), yang dapat

digunakan untuk memetakan input baru. Pembelajaran yang diawasi pada pelatihan terdiri dari vektor input x dan output target yang terbagi menjadi 2 cara yaitu:

1. Regresi : Output target merupakan bilangan real atau seluruh vektor bilangan real.
2. Klasifikasi : Output target adalah memberikan label kelas pada setiap kasus yang ada dengan melihat tingkat alternatif yang ada.


Beberapa *machine learning* berbasis jaringan tiruan sering dipergunakan dalam berbagai hal salah satunya sebagai fungsi peramalan atau prakiraan. Jaringan tiruan seperti *Artificial Neural Network* (ANN) sudah sering dipergunakan tetapi pada tipe ANN ditemukan beberapa kelemahan seperti penggunaan waktu yang relatif lama, untuk itu mulai dikembangkannya beberapa model jaringan tiruan untuk mengatasi masalah tersebut (Sacchetti *et al.*, 2017; Ahmad *et al.*, 2014).

2.7.1 Arsitektur Jaringan Tiruan

Beberapa arsitektur jaringan yang sering dipakai dalam jaringan tiruan antara lain (Siang, 2005) :

a. Jaringan layar tunggal (*Single Layer Network*)

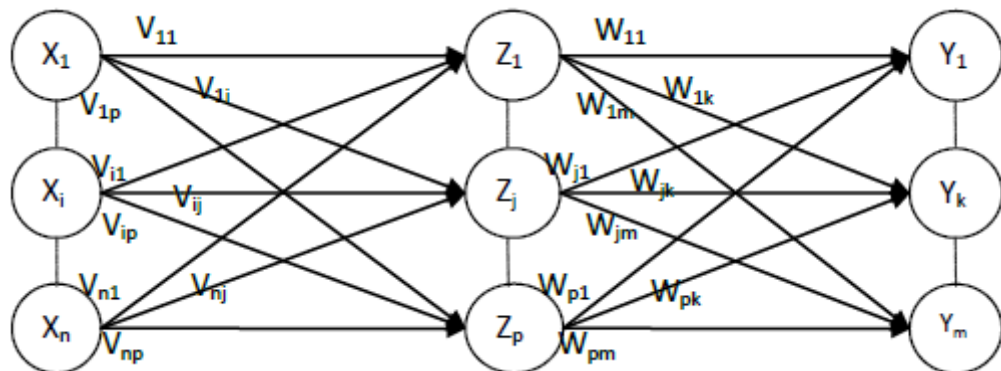
Pada jaringan ini, sekumpulan jaringan *input* yang dihubungkan langsung dengan sekumpulan jaringan *output* dengan bobot yang berbeda – beda yang ditunjukkan pada gambar 2.8. Besaran wji menyatakan bobot hubungan antara unit ke- i dalam input dengan unit ke- j dalam output. Bobot bersifat independen selama proses pelatihan bobot akan dimodifikasi (berganti) untuk meningkatkan keakuratan hasil.



Gambar 2.8. *Single Layer Network*

b. Jaringan layar jamak (*Multilayer Network*)

Jaringan layar jamak merupakan perluasan dari layar tunggal. Dalam jaringan ini, selain terdapat unit masukan (*input*) dan keluaran (*output*) terdapat unit lainnya yaitu unit tersembunyi (*hidden unit*). Sama seperti pada unit input dan output, unit – unit tidak saling berhubungan langsung.



Gambar 2.9. *Multilayer Network*

Gambar 2.9 adalah jaringan dengan n merupakan unit *input* (x_1, x_i, \dots, x_n), *hidden layer* yang terdiri dari p buah unit (z_1, z_j, \dots, z_p) dan m merupakan unit *output* (Y_1, Y_k, \dots, Y_m).

c. Jaringan *Reccurent*

Model jaringan *recurrent* mirip dengan jaringan *single layer* ataupun *multilayer network*. Hanya saja, terdapat jaringan *output* yang memberika sinyal pada unit input.

2.7.2 Fungsi Aktivasi

Dalam komputasi pda jaringan saraf tiruan, fungsi aktivasi dipakai untuk menentukan keluaran (*output*) dari suatu jaringan (*neuron*). Argumen fungsi aktivasi merupakan *net* masukan (kombinasi linier masukan dan bobot). Beberapa fungsi aktivasi yang sering dipergunakan sebagai berikut :

a. Fungsi *threshold* (ambang batas)

$$f(x) = \begin{cases} 1 & \text{jika } x \geq a \\ 0 & \text{jika } x < a \end{cases} \quad (1)$$

Untuk beberapa kasus, fungsi ambang batas dibuat tidak berharga dengan 0 atau 1, tapi sering dipergunakan jika -1 atau 1.

$$f(x) = \begin{cases} 1 & \text{jika } x \geq a \\ -1 & \text{jika } x < a \end{cases} \quad (2)$$

b. Fungsi Sigmoid

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

Fungsi sigmoid sering dipergunakan karena nilai dari fungsinya terletak dengan range yang kecil yaitu antara 0 dan 1, sehingga mudah untuk diturunkan.

c. Fungsi Identitas

$$f(x) = x \quad (4)$$

Fungsi Identitas sering dipakau apabila kita menginginkan keluaran jaringan berupa bilangan sembarang rill.

2.7.3 Normalisasi Data

Data pra-pemrosesan digunakan untuk korelasi statistik, Spearman menjelaskan koefisien korelasi untuk diketahui tentang kekuatan asosiasi antara fitur dan nilai terhadap variabel yang diperkirakan, di rubah kedalam bentuk range yag lebih kecil yaitu [0 1] atau [1 -1] (H.Lutkepohl, n.d.). Jika X_n merupakan nilai masukkan setelah dinormalisasi, x adalah nilai data asli, $\min(x)$ adalah nilai minimum pada dataset, dan $\max(x)$ adalah nilai maksimum dari *dataset*.

Maka pada persamaan (5) digunakan untuk mengubah data menjadi interval [0 1] sebagai berikut (Siang, 2005) :

$$X_n = \frac{0.8 * (X - \min(x))}{(\max(x) - \min(x))} + 0.1 \quad (5)$$

2.7.4 Denormalisasi Data

(Siang, 2005) Menjelaskan bahwa denormalisasi dimaksudkan agar hasil peramalan atau estimasi dengan jaringan syaraf dapat dibaca secara mudah dalam nilai yang sama dengan nilai asalnya. Pada persamaan (6) menunjukkan rumus yang digunakan untuk denormalisasi data dalam interval [0 1] .

$$X_d = \frac{(X_n - 0.1)(\max(x) - \min(x))}{0.8} + \min(x) \quad (6)$$

Dengan X_d merupakan nilai data setelah dinormalisasi, X_n adalah data output normalisasi atau sebelum denormalisasi, $\min(x)$ adalah data minimum pada dataset sebelum normalisasi, dan $\max(x)$ adalah data maksimum pada data set sebelum normalisasi.


2.7.5 *Extreme Learning Machine (ELM)*

Extreme Learning Machine merupakan jenis jaringan saraf baru yang tidak memiliki tahap berulang dalam proses pembelajaran (Eirola *et al.*, 2016). *Extreme Learning Machine* (ELM) adalah mesin algoritma pembelajaran untuk arsitektur SLFN (*single layer feed-forward neural network*) (Devises *et al.*, 2015; Naji *et al.*, 2016). Dibandingkan dengan jaringan saraf tradisional seperti *Backpropagation*, ELM mampu menghilangkan pada kebutuhan tuning parameter dalam tahap pelatihan sehingga mampu mengurangi waktu pelatihan secara signifikan (Devises *et al.*, 2015). ELM mampu menemukan kesalahan pelatihan dan bobot terkecil.

2.7.5.1 *Single Layer Feed Forward Neural Network*

Extreme Learning Machine (ELM) adalah alat algoritma pembelajaran untuk arsitektur SLFN (*single layer feed-forward neural network*) (Devises *et al.*, 2015; Naji *et al.*, 2016). Dibandingkan dengan jaringan saraf tradisional seperti *Backpropagation*, ELM mampu menghilangkan kebutuhan tuning parameter dalam tahap pelatihan sehingga mampu mengurangi waktu pelatihan

secara signifikan, menemukan kesalahan pelatihan dan bobot terkecil (Deviates *et al.*, 2015).



Gambar 2.10. Struktur ELM (Huang *et al.*, 2010)

Extreme Learning Machine (ELM) adalah model modifikasi dari *Single Layer Feed Forward Network* (SLFN), dapat diperoleh dengan *back-propagation* dari *multilayer perceptron*. Mesin pembelajaran ekstrem ELM adalah alat algoritma pembelajaran untuk SLFN (Naji *et al.*, 2016; Deviates *et al.*, 2015). *Extreme Learning Machine* (ELM) memiliki fungsi jaringan saraf tipe SLFN dengan fungsi *buffer* lapisan tersembunyi tunggal.

Extreme Learning Machine (ELM) memiliki fungsi jaringan *neural network* dengan tipe SLFN fungsi penyangga *layer* tersembunyi tunggal, Pada gambar 2.10 menunjukkan struktur tunggal ELM, dengan simpul tersembunyi L dapat direpresentasikan sebagai deskripsi matematis SLFN dengan keluaran ke- i . Dari SLFN dengan i -output $G(a_i b_i, x)$ dalam persamaan (1) (Å *et al.*, 2006):

$$f_L(x) = \sum_{i=1}^L \beta_i G(a_i b_i, x), \quad x \in R^n, a_i, \in R^n \quad (7)$$

Dimana a_i dan b_i merupakan parameter dari simpul tersembunyi. β_i merupakan bobot penghubung dari simpul tersembunyi dengan simpul keluaran. $G(a_i b_i, x)$ adalah nilai keluaran dari i simpul tersembunyi dengan respon dari masukan x .

Simpul aditif tersembunyi memiliki fungsi aktivasi $g(x): R \rightarrow R$: seperti fungsi bias radial (RBF), fungsi sigmoid (Sig) dan fungsi sinusoid (Sin) dan hardlimit (Hlimit), $G(a_i b_i, x)$. Dengan persamaan (2) : (Å *et al.*, 2006):

$$G(a_i, b_i, x) = g(a_i x + b_i), \quad b_i \in R \quad (8)$$

Dimana a_i menunjukkan vektor bobot yang menghubungkan simpul masukan ke dalam simpul tersembunyi yang merupakan bias dari simpul tersembunyi. $a_i \cdot x$ juga merupakan hasil dari vektor a_i di R^n . $G(a_i b_i, x)$.

Untuk sampel N yang berbeda $(x_i, t_i) \in R^n \times R^m$, x_i adalah $n \times 1$ dengan vektor input dan t_i , $m \times 1$ adalah target vektor target. Jika jaringan SLFN dengan *Hidden layer* L dapat mendekati sampel N dengan kesalahan nol implikasinya adalah pada β_i , a_i , dan b_i , dengan persamaan rumus (3) (Å *et al.*, 2006):

$$f_L(x_i) = \sum_{i=1}^L \beta_i G(a_i b_i, x), \quad j = 1, \dots \dots N \quad (9)$$

Persamaan 4 ditulis secara singkat dari persamaan 5 dan 6 sebagai berikut :

$$H\beta = T$$

(10)

dimana, H adalah matriks lapisan keluaran tersembunyi dari SLFN dengan kolom H menjadi i simpul keluaran tersembunyi sehubungan dengan $x_1 \dots x_N$.

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_i b_i, x_1) & G(a_i b_i, x_1) \\ G(a_i b_i, x_N) & G(a_i b_i, x_N) \end{bmatrix}_{N \times L}$$

(11)

Dengan $\tilde{a} = a_1 \dots a_L, \tilde{b} = b_1 \dots b_L, \tilde{x} = x_1 \dots x_L$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad \text{and} \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_L^T \end{bmatrix}_{N \times m}$$

(12)

Setelah dihitung, matriks H dapat menggunakan metode kuadrat minimum norma minimum untuk menjadi sistem linier dan bobot keluaran diperkirakan dengan persamaan (7) (Å et al., 2006):


$$\beta = H^+ T$$

(13)

Dimana H^+ merupakan *Moore-Penrose generalized inverse* dari keluaran hidden layer matrix H dapat digunakan dihitung : *orthogonal projection method, orthogonalization, iterative method, dan singular value decomposition*. Metode proyeksi ortogonal dapat digunakan dalam dua kasus ketika dimana $H^T H$ adalah non-singular and $H^+ = (H^T H)^{-1} H^T$, atau saat HH^T merupakan non-singular and $H^+ = H^T (HH^T)^{-1}$. ELM merupakan pembelajaran sekaligus.

2.7.6 Artificial Neural Network (ANN)

ANN merupakan algoritma yang menirukan prinsip kerja otak manusia untuk melakukan kegiatan belajar (*Learning*) dan prediksi / estimasi. Pada proses pembelajaran ANN melalui pembelajaran yang disesuaikan secara berulan dari bobot. Ciri Khas dari ANN yaitu mampu mempertimbangkan akumulasi informasi yang diperoleh selama proses pelatihan dan dapat menanggapi keadaanbaru dengan cara yang tepat serta memberikan pengalaman (*feed*) yang diperoleh selama proses pelatihan.



Gambar 2.11. Struktur ANN

ANN memiliki struktur yang mirip dengan syaraf manusia yang memiliki 3 lapisan utama yaitu 1.lapisan masukan, 2. Lapisan keluaran, dan 3. Jaringan *multilayer feed forward network* merupakan algoritma pembelajaran arsitektur pada gambar 2.11 jaringan syaraf tiruan yang paling umum yang telah dipelajari secara luas dan dipergunakan dalam banyak disiplin ilmu. Algoritma perhitungan proses pelatihan yang berbeda, seperti *Levenburg Marquardt (LM)*, *Bayesian regularization*, *scaled conjugate gradient* dan lainnya telah digunakan untuk

pelatihan jaringan (Chau, 2006) Notasi untuk lapisan vektor pada *multilayer feed forward network* :

a. Vektor masukan

$$D \in R^n \text{ dan } D = (X_1, X_2, \dots, X_n)^T; \quad (14)$$

b. Vektor *Hidden layer*

$$Z = (Z_1, Z_2, \dots, Z_n)^T; \quad (15)$$

c. Vektor Keluaran

$$Y \in R^m \text{ dan } Y = (Y_1, Y_2, \dots, Y_n)^T; \quad (16)$$

Diasumsikan bahwa berat dan ambang batas antara lapisan masukan dan lapisan tersembunyi masing-masing adalah w_{ij} dan y_j , dan berat dan ambang antara lapisan tersembunyi dan lapisan keluaran masing-masing adalah w_{jk} dan y_k . Output dari setiap *neuron* di lapisan tersembunyi dan lapisan output adalah sebagai berikut:

$$Z_j = f \left(\sum_{i=1}^n w_{ij} \cdot x_i \right) \quad (17)$$

$$Y_k = f \left(\sum_{j=1}^q w_{kj} \cdot Z_j \right) \quad (18)$$

Dimana f merupakan transfer fungsi, yang dipergunakan untuk memetakan jumlah masukan neuron ke output-nya dan menggunakan pilihan yang sesuai sebagai instrumen dalam nn linier ke dalam desain jaringan. Salah satu fungsi yang paling sering dipergunakan adalah fungsi Signoid.

2.7.7 Analisis Regresi

Statistik Regresi adalah model prediksi yang sering digunakan atau model prediksi berdasarkan data-driven (Wei *et al.*, 2018b). Sebagai contoh , Fumo dan

Biswas (Fumo & Biswas, 2015) menggunakan analisis Linier dan MLR dengan analisis regresi kuadratik untuk dilakukan pada konsumsi energi data per jam dan harian dari rumah penelitian dengan regresi linier ganda menggunakan suhu luar ruangan dan radiasi matahari peningkatan koefisien determinasi tetapi memiliki masalah dengan hasil RMSE yang memburuk. Regresi statistik sering digunakan: *General Linear Regression (GLR)*, *Multiple Linear Regression (MLR)* (Chou & Bui, 2014), Autoregressive Integrated Moving Average (ARIMA), etc (Amasyali & El-gohary, 2018).

General Linear Regression (GLR) adalah versi yang lebih fleksibel dari *Linear Regression (LR)*. Dengan hubungan antara X (variabel prediktor) dan Y (variabel respons keluaran) menggunakan fungsi penghubung untuk distribusi. Rumus model relasional (X-Y) dalam persamaan (13) :

$$g(E(y)) = X \times \beta + O, y \sim F \quad (19)$$

dimana $g(\cdot)$ adalah fungsi penghubung yang dipilih, O adalah variabel komplemen, F adalah fungsi distribusi y , X prediktor, y adalah variabel respons keluaran dan β adalah koefisien regresi.

2.7.8 MATLAB R2014a

MATLAB (Attaway, 2009) merupakan paket perangkat lunak yang memiliki banyak *tools* untuk memecahkan masalah dalam hal *signal and image processing*, desain kendali, pengujian dan pengukuran, permodelan, dan analisis. MATLAB juga memiliki program dengan bahasa pemrograman yang tinggi untuk mengembangkan algoritma, visualisasi data, dan komputasi numerik (Young & Mohlenkamp, 2017).

Program MATLAB ini dapat digunakan untuk menyelesaikan masalah komputasi dengan lebih cepat dibandingkan dengan bahasa pemrograman tradisional. Menulis suatu program dalam MATLAB pada dasarnya merupakan sekelompok perintah yang dieksekusi secara berurutan. Beberapa peneliti (Nilashi *et al.*, 2017; Naji *et al.*, 2016; Chou & Bui, 2014), menggunakan MATLAB dalam penelitian untuk menguji atau mengevaluasi kinerja suatu sistem dengan algoritma yang dipergunakan seperti menggunakan uji korelasi koefisien, koefisien determinasi, RMSE, MAE dan R^2 .

BAB V

PENUTUP

Bab ini berisikan tentang beberapa simpulan yang dihasilkan berdasarkan penelitian yang telah dilaksanakan. Selain itu, dalam bab ini juga dimasukkan beberapa saran yang dapat digunakan apabila penelitian ini akan dikembangkan kembali.

5.1 Kesimpulan

Berbagai model algoritma *Machine Learning* seperti ELM, ANN, serta GLR telah diimplementasikan dan diuji dalam memperkirakan konsumsi energi pendingin setiap jam di bangunan perumahan. Dalam hal ini, simulasi dilakukan dengan dua jenis bangunan perumahan yang berbeda. Setiap model dilatih dan diuji pada *dataset* konsumsi energi dengan beban pendinginan (*cooling load*) di cuaca tropis menggunakan Energyplus. Perbandingan teknik *Machine Learning* ELM, ANN dan GLR dilakukan untuk menilai akurasi estimasi. Akurasi diukur dalam hal RMSE, MAE, dan R^2 . Model algoritma ELM memperoleh hasil estimasi akurasi yang stabil dalam dua tipe bangunan perumahan dalam dataset uji dengan hasil tipe A Pelatihan RMSE 0.0143, MAE 0.0263, R^2 0.9943 dan Pengujian Tipe A RMSE 0.0503, MAE 0,0802, R^2 0,9405 dan untuk tipe B Pelatihan RMSE 0,0226, MAE 0,039, R^2 0,9864 dan pengujian RMSE 0,0632, MAE 0,0996, R^2 0,8990. Dalam hal akurasi, komputasi model ELM memiliki penggunaan waktu yang relatif cepat dalam proses pelatihan data. Model ELM itu sendiri memiliki penyesuaian dan proses yang mudah dengan SLFN dibandingkan dengan ANN. ELM jauh lebih

cepat dalam kecepatan belajar dibandingkan dengan algoritma pembelajaran jaringan umpan maju tradisional seperti algoritma ANN dengan menggunakan *BackPropagation*. Selain itu, tidak seperti algoritma pembelajaran tradisional, algoritma ELM mampu mencapai kesalahan pelatihan terkecil.

5.2 Saran

Penelitian tentang estimasi konsumsi energi *cooling* berdasarkan lingkungan daerah cuaca tropis, masih perlu ditindak lanjuti agar diperoleh efektivitas dan hasil yang lebih baik. Dari penelitian ini diperoleh beberapa saran yang dapat dipergunakan untuk penelitian selanjutnya sebagai berikut :

1. Konsumsi energi pendingin dapat diperkirakan menggunakan data variabel iklim aktual yang disesuaikan. Ini dilakukan untuk mendapatkan simulasi data yang lebih akurat. Kita bisa menggunakan rekaman data aktual pada bangunan untuk menguji ulang model algoritma *machine learning*.
2. Memperhatikan pemilihan komponen pembangun HVAC untuk memperoleh sistem yang sesuai dengan hasil konsumsi energi beban HVAC secara efisien dan optimal.
3. Untuk mendapatkan estimasi konsumsi energi yang akurat dapat mempergunakan *Artificial Intelligence (AI) Machine Learning* lainnya atau menggabungkan dengan pendekatan teknik optimasi.

DAFTAR PUSTAKA

- Ã, G.H., Zhu, Q. & Siew, C. 2006. Extreme learning machine : Theory and applications. 70: 489–501.
- Ahmad, A.S., Hassan, M. aY, 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. Tersedia di <http://dx.doi.org/10.1016/j.rser.2014.01.069>.
- Al-Homoud, M.S. 2001. Computer-aided building energy analysis techniques. 36: 421–433.
- Amasyali, K. & El-gohary, N.M. 2018. A review of data-driven building energy consumption prediction studies. *Renewable and Sustainable Energy Reviews*, 81(April 2017): 1192–1205. Tersedia di <http://dx.doi.org/10.1016/j.rser.2017.04.095>.
- Ascione, F. 2017. Energy conservation and renewable technologies for buildings to face the impact of the climate change and minimize the use of cooling. *Solar Energy*. Tersedia di <http://dx.doi.org/10.1016/j.solener.2017.01.022>.
- BEopt 2018. *BEopt*. Tersedia di <https://beopt.nrel.gov/home>.
- BMKG 2018. *No Title*. Tersedia di <https://www.bmkg.go.id/iklim/prakiraan-musim.bmkg>.
- Bose, B.K. 2017. Artificial Intelligence Techniques in Smart Grid and Renewable Energy Systems — Some Example Applications. 105(11): 2262–2273.
- Chau, K.W. 2006. Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River. 363–367.
- Chou, J. & Bui, D. 2014. Modeling heating and cooling loads by artificial intelligence for energy-efficient building design. *Energy & Buildings*, 82: 437–446. Tersedia di <http://dx.doi.org/10.1016/j.enbuild.2014.07.036>.
- Citra Grand Semarang 2018. *Cluster Yellowleaf*. Tersedia di http://www.citragrand-semarang.com/portfolio_category/cluster-yellowleaf/.
- Dasgupta, A. & Nath, A. 2016. Classification of Machine Learning Algorithms. 3(03): 6–11.
- Deb, C., Siew, L., Yang, J. & Santamouris, M. 2016. Forecasting diurnal cooling energy load for institutional buildings using Artificial Neural Networks. *Energy & Buildings*, 121: 284–297. Tersedia di <http://dx.doi.org/10.1016/j.enbuild.2015.12.050>.

- Devices, N., Wang, Y., Yu, H., Member, S., Ni, L., Huang, G., Member, S. & Yan, M. 2015. An Energy-efficient Nonvolatile In-memory Computing Architecture for Extreme Learning Machine by Domain-wall. (c).
- Diamantoulakis, P.D., Kapinas, V.M. & Karagiannidis, G.K. 2015. Big Data Analytics for Dynamic Energy Management in Smart Grids ☆. *Big Data Research*, 1: 6–13. Tersedia di <http://dx.doi.org/10.1016/j.bdr.2015.03.003>.
- Eirola, E., Miche, Y., Björk, K., Nian, R. & Akusok, A. 2016. *Neurocomputing*. 174: 220–231.
- Ekici, B.B. & Aksoy, U.T. 2009. Advances in Engineering Software Prediction of building energy consumption by using artificial neural networks. *Advances in Engineering Software*, 40(5): 356–362. Tersedia di <http://dx.doi.org/10.1016/j.advengsoft.2008.05.003>.
- EnergyPlus 2010. Getting Started with EnergyPlus Basic Concepts Manual - Essential Information You Need about Running EnergyPlus. Tersedia di <https://energyplus.net/>.
- EnergyPlus 2018a. *EnergyPlus*. Tersedia di <https://energyplus.net/> [Accessed 27 Agustus 2018].
- EnergyPlus 2018b. *Weather Data for Simulation*. Tersedia di <https://energyplus.net/weather/simulation>.
- Fan, X., Qiu, B., Liu, Y., Zhu, H. & Han, B. 2017. Energy Visualization for Smart Home. *Energy Procedia*, 105: 2545–2548. Tersedia di <http://dx.doi.org/10.1016/j.egypro.2017.03.732>.
- Fayaz, M. & Kim, D. 2018. A Prediction Methodology of Energy Consumption Based on Deep Extreme Learning Machine and Comparative Analysis in Residential Buildings.
- Fumo, N. 2014. A review on the basics of building energy estimation. *Renewable and Sustainable Energy Reviews*, 31: 53–60. Tersedia di <http://dx.doi.org/10.1016/j.rser.2013.11.040>.
- Fumo, N. & Biswas, M.A.R. 2015. Regression analysis for prediction of residential energy consumption. *Renewable and Sustainable Energy Reviews*, 47: 332–343. Tersedia di <http://dx.doi.org/10.1016/j.rser.2015.03.035>.
- H.Lutkepohl n.d. *New Introduction to Multiple Time Series Analysis*.
- Huang, G., Ding, X. & Zhou, H. 2010. Neurocomputing Optimization method based extreme learning machine for classification \$. *Neurocomputing*, 74(1–3): 155–163. Tersedia di <http://dx.doi.org/10.1016/j.neucom.2010.02.019>.

- Huang, G., Zhu, Q. & Siew, C. 2006. Extreme Learning Machine : A New Learning Scheme of Feedforward Neural Networks. 70: 25–29.
- International, E. & Conference, I. 2003. BUILDING MORPHOLOGY , TRANSPARENCE , AND ENERGY PERFORMANCE Werner Pessenlehner and Ardeshir Mahdavi Department of Building Physics and Human Ecology Vienna University of Technology Vienna , 1040 - Austria. 1025–1032.
- Kumar, S., Pal, S.K. & Singh, R.P. 2018. in residential buildings Intra ELM Variants Ensemble Based Model to Predict Energy Performance in Residential Buildings. *Sustainable Energy, Grids and Networks*. Tersedia di <https://doi.org/10.1016/j.segan.2018.07.001>.
- Liaison, S., Jakob, F.E., Dunn, W.A., Brager, G.S., Brown, K.A., Clark, D.R., Deringer, J.J., Hogeling, J.J., Int-hout, D., Jones, B.W., Knapp, J.N., Kwok, A.G., Levin, H., Melikov, A.K., Simmonds, P., Sipes, J.M., Sterling, E.M. & Sun, B.P. 2004. ASHRAE STANDARD Thermal Environmental Conditions for Human Occupancy. 2004.
- Lu, Y., Fournier, J. & Lacarrière, B. 2017. ScienceDirect The 15th International Symposium on District Heating and Cooling Behavioural Intervention Strategies Using Support Vector Regression Assessing the feasibility of using the heat demand-outdoor a a , long-term district heat Meng for. *Energy Procedia*, 142: 2734–2739. Tersedia di <https://doi.org/10.1016/j.egypro.2017.12.218>.
- Lund, H., Connolly, D., Mathiesen, B.V., Connolly, D., Vad, B., Energy, S. & Systems, S.E. 2017. Smart Energy and Smart Energy Systems.
- Mehdi, G. & Roshchin, M. 2015. Electricity consumption constraints for smart-home automation : An overview of models and applications. *Energy Procedia*, 83: 60–68. Tersedia di <http://dx.doi.org/10.1016/j.egypro.2015.12.196>.
- Naji, S., Keivani, A., Shamshirband, S., Alengaram, U.J., Zamin, M. & Lee, M. 2016. *Estimating building energy consumption using extreme learning machine method*.
- Nilashi, M., Dalvi, M., Ibrahim, O., Fard, K.B., Mardani, A. & Zakuan, N. 2017. A Soft Computing Method for the Prediction of Energy Performance of Residential Buildings. *Measurement*. Tersedia di <http://dx.doi.org/10.1016/j.measurement.2017.05.048>.
- OpenStudio 2018. *No Title*. Tersedia di <https://www.openstudio.net/>.
- Park, J.S., Joo, S., Han, K., Woo, K. & Jeong, J. 2016. Estimating thermal performance and energy saving potential of residential buildings using utility bills. *Energy & Buildings*, 110: 23–30. Tersedia di

<http://dx.doi.org/10.1016/j.enbuild.2015.10.038>.

Sacchetti, A., Politecnico, D. & Corre, O. Le 2017. Heating household and Cooling energy On the use The artificial neural networks to model consumptions consumptions Assessing the feasibility of using , the P . Stefanizzi district temperature function for a heat demand. *Energy Procedia*, 126: 250–257. Tersedia di <https://doi.org/10.1016/j.egypro.2017.08.149>.

Schiavon, S., Lee, K.H., Bauman, F. & Webster, T. 2010. Influence of raised floor on zone design cooling load in commercial buildings. *Energy & Buildings*, 42(8): 1182–1191. Tersedia di <http://dx.doi.org/10.1016/j.enbuild.2010.02.009>.

Shabunko, V., Lim, C.M. & Mathew, S. 2016. EnergyPlus models for the benchmarking of residential buildings in Brunei Darussalam. *Energy & Buildings*. Tersedia di <http://dx.doi.org/10.1016/j.enbuild.2016.03.039>.

Siang, J.J. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya menggunakan matlab*. Yogyakarta: Andi.

Singh, R. & Balasundaram, S. n.d. Application of Extreme Learning Machine Method for Time Series Analysis. 2(4): 256–262.

Sketchup 2018. *No Title*. Tersedia di <https://www.sketchup.com/>.

Smith, K.M. 2018. Forecasting energy consumption of multi- family residential buildings using support vector regression : Investigating *Applied Energy*, 123(June 2014): 168–178. Tersedia di <http://dx.doi.org/10.1016/j.apenergy.2014.02.057>.

Standard Heating & AirConditioning 2019. HVAC diagram. Tersedia di <https://www.standardheating.com/hvac-maintenance/hvac-diagram/>.

ThermalFlow 2013. *Ultra-Efficient Indoor Comfort Systems*. Tersedia di <http://www.thermalflow.net/index.htm>.

TRNSYS 2018. *trnsys*. Tersedia di <http://www.trnsys.com/>.

Tsanas, A. & Xifara, A. 2012. Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools. *Energy & Buildings*, 49: 560–567. Tersedia di <http://dx.doi.org/10.1016/j.enbuild.2012.03.003>.

Vakiloroaya, V., Samali, B., Fakhar, A. & Pishghadam, K. 2014. A review of different strategies for HVAC energy saving. *ENERGY CONVERSION AND MANAGEMENT*, 77: 738–754. Tersedia di <http://dx.doi.org/10.1016/j.enconman.2013.10.023>.

- Wan, K.K.W., Li, D.H.W., Liu, D. & Lam, J.C. 2011. Future trends of building heating and cooling loads and energy consumption in different climates. *Building and Environment*, 46(1): 223–234. Tersedia di <http://dx.doi.org/10.1016/j.buildenv.2010.07.016>.
- Wei, Y., Zhang, X., Shi, Y., Xia, L., Pan, S., Wu, J. & Han, M. 2018a. A review of data-driven approaches for prediction and classification of building energy consumption. *Renewable and Sustainable Energy Reviews*, 82(September 2017): 1027–1047. Tersedia di <http://dx.doi.org/10.1016/j.rser.2017.09.108>.
- Wei, Y., Zhang, X., Shi, Y., Xia, L., Pan, S., Wu, J., Han, M. & Zhao, X. 2018b. A review of data-driven approaches for prediction and classification of building energy consumption. *Renewable and Sustainable Energy Reviews*, 82(October 2017): 1027–1047. Tersedia di <http://dx.doi.org/10.1016/j.rser.2017.09.108>.
- Young, T. & Mohlenkamp, M.J. 2017. *Introduction to Numerical Methods and Matlab Programming for Engineers*.
- Zhao, H. & Magoulès, F. 2012. A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16(6): 3586–3592. Tersedia di <http://dx.doi.org/10.1016/j.rser.2012.02.049>.
- Zhuang, P. & Liang, H. 2015. Energy Storage Management in Smart Homes Based on Resident Activity of Daily Life Recognition. 641–646.