

PENENTUAN PARAMETER KINERJA BANGUNAN DENGAN METODE INVERSE MODELING MENGGUNAKAN MACHINE LEARNING

DETERMINING BUILDING PERFORMANCE PARAMETER WITH INVERSE MODELING METHOD USING MACHINE LEARNING

Septian Nur Hiadayat¹, Dr. Eng, Amaliyah R.I.U., S.T., M.Si², Dr. Eng, Indra
Wahyudhin Fathona., S.Si., M.Si.³

^{1,2,3}Prodi S1 Teknik Fisika, Fakultas Teknik Elektro, Universitas Telkom

¹septiannh@student.telkomuniversity.ac.id ²amaliyahriu@telkomuniversity.ac.id

³indrafathonah@telkomuniversity.ac.id

Abstrak

Energy Signature dalam suatu bangunan dapat dilihat dengan cara membandingkan *Energy Usage Intensity* (EUI) dengan *Outdoor Temp*. Metode untuk mengidentifikasi *Energy Signature* adalah *Invers Modeling*. Metode *inverse modeling* sendiri bisa digunakan dengan *Machine Learning*. Metode *invers modeling* dimulai saat mensimulasikan enam (6) bangunan dengan berbagai geometri. Hasil dari simulasi bangunan tersebut adalah parameter bangunan yaitu kondisi *wwr* (*window to wall ratio*), dinding, kaca, ventilasi, kondisi infiltrasi, nilai COP (*Coefficient of Performance*) AC, setpoint temperatur AC, okupansi bangunan, dan iklim. Data hasil penelitian menunjukkan bahwa dari masing-masing bangunan menunjukkan nilai EUI yang berbeda. Pada saat inilah *machine learning* digunakan untuk mencari nilai akurasi dari masing-masing bangunan. Penelitian ini menggunakan *Python* sebagai bahasa pemrograman *machine learning* dan *Artificial neural networks* (ANN) sebagai metode yang digunakan untuk mentraining data hasil simulasi. Setelah di training didapatkan nilai akurasi dari masing-masing bangunan menggunakan satu (1), tiga (3), sampai lima (5) *hidden layer* dengan masing-masing 25 *neuron*.

Kata kunci: energy signature, artificial neural networks (ANN), parameter bangunan.

Abstract

Energy Signature in a building can be seen by comparing Energy Usage Intensity (EUI) with Outdoor Temp. The method for identifying Energy Signature is Inverse Modeling. The inverse modeling method itself can be used with Machine Learning. The inverse modeling method starts when simulating six (6) buildings with various geometries. The results of the building simulation are building parameters namely window to wall ratio, walls, glass, ventilation, infiltration conditions, AC COP (Coefficient of Performance) values, AC temperature setpoints, building occupancy, and climate. The research data shows that each building shows a different EUI value. At this time machine learning is used to find the accuracy value of each building. This study uses Python as a machine learning programming language and Artificial neural networks (ANN) as a method used for training simulation data. After training, the accuracy values of each building are obtained using one (1), three (3), up to five (5) hidden layers with 25 neurons each.

Keywords: Energy Signature, Artificial Neural Networks (ANN), building paramater.

1. Pendahuluan

Kebutuhan daya dan tarif dasar tenaga listrik memiliki peran yang sangat penting dalam suatu industri atau perumahan. Hal ini bisa dilihat dalam kehidupan sehari-hari, hampir setiap bangunan membutuhkan energi listrik seperti pelayanan sosial, rumah tangga, bisnis, industri, perkantoran, mall dan sebagainya. Kebutuhan tersebut dapat di karakteristikkan berdasarkan beban dari suatu bangunan tersebut. Profil beban listrik merupakan informasi yang berisi tentang besarnya energi yang membebani suatu *station* penyedia listrik, data ini biasanya dinyatakan dalam kW atau MW. Data beban listrik biasanya dibuat dalam interval waktu tertentu: setiap 10, 15, atau 30 menit [1]. Dalam penelitian kali ini menggunakan *Python* sebagai bahasa pemrograman *machine learning* dan menggunakan ANN (*Artificial Neural Networks*) sebagai metode yang digunakan untuk mentraining data. Data yang didapat berasal dari tugas akhir Alvin Hizra M yang mensimulasi 6 bangunan yang memiliki geometri yang berbeda-beda dan juga parameter input bangunan yang telah ditentukan sebelumnya. Nantinya data yang didapat akan digunakan sebagai awal mula proses *invers modeling* yang akan menghasilkan *energy signature* [2].

2. Dasar Teori

2.1 EUI (Energy Usage Intensity)

EUI adalah perbandingan antara konsumsi energi dengan satuan luas bangunan gedung dalam periode tertentu (kWh/m² per bulan atau kWh/m² per tahun)” [3]. Konsumsi energi adalah besarnya energi yang digunakan oleh bangunan gedung dalam waktu periode tertentu dan merupakan perkalian antara daya dan waktu operasi (kWh/bulan atau kWh/tahun).

2.2 Energy Signature

Energy Signature bangunan adalah plot konsumsi energi bangunan versus suhu udara ambien rata-rata, yang biasanya diambil dari data harian [4]. Tanda tangan energi secara umum didasarkan pada total energi yang dipasok ke sebuah bangunan, biasanya dipecah berdasarkan jenis bahan bakar, tetapi mereka juga dapat didasarkan pada data sub-meter untuk penggunaan akhir tertentu.

2.3 Inverse Modeling

Inverse Modeling adalah pemodelan berkebalikan dengan pemodelan ke depan atau dapat diartikan dengan membangun/mencari model dari fenomena yang telah terjadi atau yang telah ada. *Invers Modeling* berjalan dengan cara suatu model dihasilkan langsung dari data. Pemodelan jenis ini sering disebut dengan data *fitting* atau pencocokan data karena proses didalamnya dicari parameter model yang dihasilkan respon yang cocok dengan data pengamatan. Diharapkan untuk respon model dan data pengamatan memiliki kesesuaian yang tinggi, dan ini akan menghasilkan model yang optimum [5].

2.4 Machine Learning

Machine Learning adalah metode yang digunakan untuk membuat program yang bisa belajar dari data. Berbeda dengan program komputer biasa yang statis, program *machine learning* adalah program yang dirancang untuk mampu belajar sendiri.

Cara belajar program *machine learning* mengikuti cara belajar manusia, yakni belajar dari contoh-contoh. *Machine learning* akan mempelajari pola dari contoh-contoh yang dianalisa, untuk menentukan jawaban dari pertanyaan-pertanyaan berikutnya.

Machine learning adalah seperti membuat program yang bisa menebak kotak hitam yang memiliki rumus fungsi yang belum diketahui. Kotak hitam itu diberikan sebuah *input* dan akan menghasilkan sebuah *output* tertentu. Dari data-data *input* dan *output* yang diperoleh, maka program akan menebak rumus fungsi yang paling mendekati keakuratan[6].

Machine Learning mempunyai dua tipe yaitu :

Supervised Learning

Supervised Learning adalah metode yang digunakan saat semua data yang dipunya sudah mempunyai label dan algoritmanya belajar memprediksi output dari input. *Supervised Learning* meliputi : Teknik *Regression* dan *Classification*.

Unsupervised Learning


Unsupervised Learning adalah metode yang digunakan saat semua data yang dipunya tidak mempunyai label dan algoritmanya mempelajari struktur yang melakat dari data tersebut. *Unsupervised Learning* meliputi : Teknik *Clustering* dan *Association*.

2.5 ANN (Artificial Neural Networks)

Jaringan Saraf Tiruan (JST) atau *Artificial Neural Network* merupakan suatu pendekatan yang berbeda dari metode AI lainnya. JST merupakan suatu model kecerdasan yang diilhami dari struktur otak manusia dan kemudian diimplementasikan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran berlangsung. Algoritma *Artificial Neural Network* (ANN) merupakan model penalaran yang didasarkan pada otak manusia. ANN terdiri dari sejumlah prosesor sangat sederhana dan saling berhubungan yang disebut neuron. *Neuron* yang terhubung dengan pembobotan (*weight*) melewatisinyal dari neuron satu ke neuron yang lain.[7]

2.6 Metodologi Penelitian

Secara garis besar penelitian ini dilakukan sesuai dengan diagram alir penelitian seperti yang ditunjukkan oleh gambar 1.



Gambar 2.1 Flowchart Skema Metode Penelitian yang Diusulkan.

Sesuai dengan gambar 3.1 Diagram Alir Penelitian diatas, penelitian ini dimulai dengan mencari literatur yang berhubungan dengan tugas akhir penulis, lalu setelah itu menentukan objek uji yang akan di olah, setelah mendapatkan objek uji, penulis mulai merancang sistem yang akan digunakan, mulai dari mensimulasikan bangunan sampai dengan perancangan sistem algoritma untuk *training data*, setelah itu melakukan *training data* dari data yang diolah menggunakan metode ANN, lalu terakhir penulis menganalisis nilai akurasi dari masing-masing bangunan dan masing-masing parameter.

2.7 Tahapan Penelitian

Penelitian ini dilakukan secara bertahap dengan rincian sebagai berikut:

1. Simulasi enam (6) bangunan dengan karakteristik yang berbeda.
2. Hasil simulasi dari enam (6) bangunan selanjutnya akan di training, namun sebelum itu dilakukan proses data cleaning sesuai dengan kebutuhan.
3. Setelah itu melakukan training data menggunakan bahasa pemrograman *python* dengan metode ANN.
4. Analisis error yang didapat dan membuat kesimpulan.


3 Pembahasan

Training data dilakukan guna mengetahui error dari tiap-tiap parameter yang didapat. Dengan menggunakan 5 *hidden layer* dengan masing-masing 25 *neuron*, berikut adalah data grafik perbandingannya.

3.1 Hasil Training Data Bangunan 1

Tabel 3.1 Perbandingan Error Bangunan 1

No	BANGUNAN	NILAI AKURASI							
		Perc	Wall	Kaca	Ven	Fill	COP	Temp	Occ
1	BANGUNAN A	0.6962	0.3192	0.5410	0.7580	0.5805	0.7715	0.7011	0.7676
2	BANGUNAN B	0.8303	0.5149	0.6210	0.7049	0.5506	0.8640	0.6798	0.7657
3	BANGUNAN C	0.8245	0.4002	0.5661	0.7194	0.5236	0.8669	0.6490	0.7695
4	BANGUNAN D	0.2295	0.3086	0.4889	0.3134	0.3404	0.4687	0.3346	0.4860
5	BANGUNAN E	0.7859	0.3587	0.5902	0.7338	0.6056	0.7830	0.6982	0.8004
6	BANGUNAN F	0.7608	0.4233	0.5632	0.6721	0.5506	0.8177	0.6557	0.7223



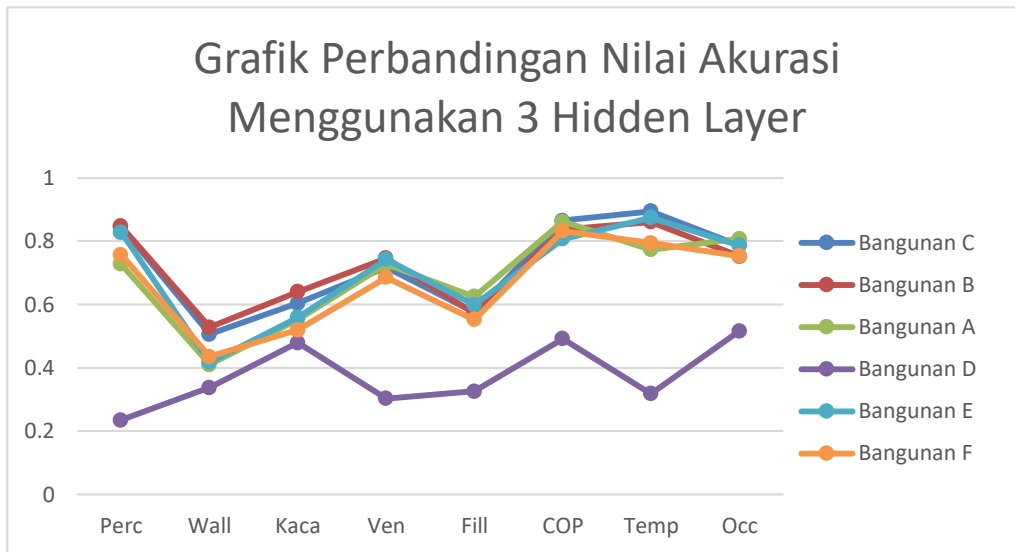
Gambar 3.1 Grafik Perbandingan Error Bangunan 1

Pada gambar 3.1 Grafik Perbandingan Nilai Akurasi Menggunakan 1 *Hidden Layer*, data diolah menggunakan *hidden layer* sebanyak 1 dan berisi 25 *neuron*. Sumbu X merupakan parameter dari bangunan, Perc untuk menyatakan WWR atau *Window to Ratio*, Wall untuk menyatakan jenis dinding yang digunakan, Kaca untuk menyatakan jenis kaca yang digunakan, Ven merupakan pengkondisian dari ventilasi, Fill adalah pengkondisian infiltrasi, COP merupakan *Coefficient Of Performance* (COP), Temp merupakan setpoint temperature yang di gunakan, dan yang terakhir untuk OCC merupakan beban manusia dalam banguna. Terdapat perbedaan nilai akurasi yang didapat dari masing masing bangunan dan masing-masing parameternya, akurasi tertinggi didapatkan oleh bangunan C dengan parameter COP dengan nilai 0.866 atau 86.6% dan yang paling rendah parameter Perc pada bangunan D yaitu sebesar 0.23 atau 23%.

3.2 Hasil Training Data Bangunan 2

Tabel 3.2 Perbandingan Error Bangunan 2

No	BANGUNAN	NILAI AKURASI							
		Perc	Wall	Kaca	Ven	Fill	COP	Temp	Occ
1	BANGUNAN A	0.7281	0.4098	0.5526	0.7271	0.6249	0.8621	0.7734	0.8081
2	BANGUNAN B	0.8476	0.5284	0.6403	0.7464	0.5718	0.8370	0.8611	0.7522
3	BANGUNAN C	0.8447	0.5063	0.6037	0.7175	0.5757	0.8650	0.8949	0.7869
4	BANGUNAN D	0.2343	0.3375	0.4793	0.3028	0.3259	0.4918	0.3182	0.5159
5	BANGUNAN E	0.8284	0.4176	0.5593	0.7425	0.5988	0.8071	0.8746	0.7869
6	BANGUNAN F	0.7570	0.4349	0.5198	0.6856	0.5526	0.8322	0.7946	0.7531




Gambar 3.2 Grafik Perbandingan Error Bangunan 2

Pada gambar 3.2 Grafik Perbandingan Nilai Akurasi Menggunakan 3 *Hidden Layer*, data diolah menggunakan *hidden layer* sebanyak 1 dan berisi 25 *neuron*. Sumbu X merupakan parameter dari bangunan, Perc untuk menyatakan WWR atau *Window to Ratio*, Wall untuk menyatakan jenis dinding yang digunakan, Kaca untuk menyatakan jenis kaca yang digunakan, Ven merupakan pengkondisian dari ventilasi, Fill adalah pengkondisian infiltrasi, COP merupakan *Coefficient Of Perfomance* (COP), Temp merupakan setpoint temperature yang di gunakan, dan yang terakhir untuk OCC merupakan beban manusia dalam banguna. Terdapat perbedaan nilai akurasi yang didapat dari masing masing bangunan dan masing-masing parameternya, akurasi tertinggi didapatkan oleh bangunan C dengan parameter Temp dengan nilai akurasi mencapai 0.89 atau 89%. dan yang paling rendah parameter Perc pada bangunan D yaitu sebesar 0.23 atau 23%.

3.3 Hasil Training Data Bangunan 3

Tabel 3.3 Perbandingan Error Bangunan 3

No	BANGUNAN	NILAI AKURASI							
		Perc	Wall	Kaca	Ven	Fill	COP	Temp	Occ
1	BANGUNAN A	0.7040	0.4484	0.5429	0.7290	0.5931	0.8023	0.7927	0.7657
2	BANGUNAN B	0.8284	0.4976	0.6528	0.7097	0.5439	0.8669	0.9229	0.7743
3	BANGUNAN C	0.8226	0.4802	0.6278	0.6982	0.5699	0.8737	0.9142	0.7705
4	BANGUNAN D	0.2469	0.3462	0.4899	0.3385	0.3279	0.4822	0.3153	0.4918
5	BANGUNAN E	0.7888	0.4571	0.5593	0.7271	0.6365	0.8679	0.8872	0.7821
6	BANGUNAN F	0.7396	0.4069	0.6011	0.6490	0.5564	0.8361	0.8949	0.7261



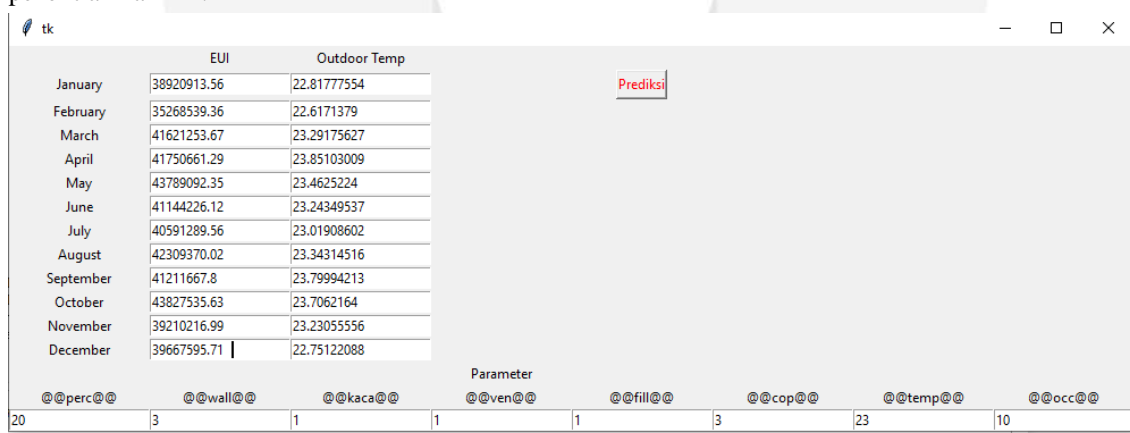
Gambar 3.3 Grafik Perbandingan Error Bangunan 3

Pada gambar 3.3 Grafik Perbandingan Nilai Akurasi Menggunakan 5 *Hidden Layer*, data diolah menggunakan *hidden layer* sebanyak 1 dan berisi 25 *neuron*. Sumbu X merupakan parameter dari bangunan, Perc untuk menyatakan WWR atau *Window to Ratio*, Wall untuk menyatakan jenis dinding yang digunakan, Kaca untuk menyatakan jenis kaca yang digunakan, Ven merupakan pengkondisian dari ventilasi, Fill adalah pengkondisian infiltrasi, COP merupakan *Coefficient Of Perfomance* (COP), Temp merupakan setpoint temperature yang di gunakan, dan yang terakhir untuk OCC merupakan beban manusia dalam banguna. Terdapat perbedaan nilai akurasi yang didapat dari masing masing bangunan dan masing-masing parameternya, akurasi tertinggi didapatkan oleh bangunan B dengan parameter Temp dengan nilai akurasi mencapai 0.92 atau 92%. dan yang paling rendah parameter Perc pada bangunan D yaitu sebesar 0.24 atau 24%.

Dari hasil diatas banyaknya hidden layer tidak terlalu berpengaruh terhadap tingkat akurasi yang didapatkan dari masing-masing bangunan dan masing-masing parameter.

3.4 GUI (*Graphical User Interface*)

Setelah data di training dan didapatkan nilai akurasi nya, langkah selanjutnya adalah pembuatan GUI, menggunakan bahasa pemrograman *python*. Nantinya GUI ini digunakan untuk menentukan parameter – parameter kinerja bangunan yang baru. Berikut adalah tampilan GUI yang penulis buat pada penelitian kali ini :



Gambar 3.4 Grafik Perbandingan Error Bangunan 3

Pada gambar 3.4 GUI Penentuan Parameter Kinerja Bangunan, Cara kerja GUI ini adalah dengan memasukkan nilai EUI dan *Outdoor Temperature* kedalam kotak yang disediakan maka nantinya hasil prediksi untuk masing-masing nilai parameternya akan muncul sesuai dengan pengolahan yang dilakukan oleh *machine learning*..

4 Kesimpulan dan Saran

4.1 Kesimpulan

Berdasarkan pada penelitian yang telah dilakukan dapat disimpulkan sebagai berikut :

1. Secara umum, profil beban listrik suatu bangunan dipengaruhi oleh beberapa faktor, salah satunya adalah parameter-parameter kinerja dari suatu bangunan tersebut.
2. Nilai *error* dari parameter-parameter kinerja bangunan dari ke enam bangunan menunjukkan bahwa baik menggunakan MAE (*Mean Absolute Error*) maupun RMSE (*Root Mean Square Error*) keduanya menunjukkan nilai error yang cukup baik.

4.2 Saran

Dari penelitian yang telah dilakukan ini terdapat beberapa hal yang perlu diperbaiki untuk pengembangan dan penelitian lebih lanjut. Beberapa saran yang penulis anjurkan untuk diperbaiki adalah

1. Proses *training data* alangkah baiknya menggunakan metode yang berbeda agar dapat dilihat perbandingan tingkat keakurasiannya.
2. GUI yang dibuat alangkah baiknya diperbagus atau di buat se maksimal mungkin, agar tampilannya merarik perhatian.

DAFTAR PUSTAKA

- [1] Ilir Keka and M. Hamiti, *Load profile analyses using R language*. IEEE.
- [2] Djunaedy, Ery. Van Den Wymelenberg, Kevin. Targeted Calibration of Energy Models for Existing Building.
- [3] Standar Nasional Indonesia 03-6196-2011, Prosedur Audit Energi Pada Bangunan Gedung, Jakarta: Badan Standardisasi Nasional, 2011.
- [4] R.Hitchin and I. Knight, "Daily energy consumption signatures and control charts for air-conditioned buildings," *Energy Build.*, vol. 112, pp. 101–109, Jan. 2016.
- [5] Ahmad al imbron, "Metode Inverse Modeling." [Online]. Available: <https://gefisi.blogspot.com/2017/04/metode-Inverse-modeling.html>.
- [6] Makers Institute, "Pengenalan terhadap Machine Learning." [Online]. Available: <https://medium.com/@makersinstitute/pengenalan-terhadap-machine-learning-9011fe71d1e4>.
- [7] Kurniawansyah, Arius Satoni. 2018. IMPLEMENTASI METODE *ARTIFICIAL NEURAL NETWORK* DALAM MEMREDIKSI HASII UJIAN KOMPETENSI KEBIDANAN (STUDI KASUS: AKADEMI KEBIDANAN DEHASEN BENGKULU). Jurnal Pseudocode, Volume V Nomor 1.