

# EFISIENSI ENERGI PADA BANGUNAN MENGUNAKAN MULTIVARIATE RANDOM FOREST

Triando Hamonangan Saragih<sup>1</sup>, Mohammad Reza Faisal<sup>2</sup>, Muhammad Haekal<sup>3</sup>

<sup>123</sup>Ilmu Komputer FMIPA ULM

Jalan A. Yani KM 36 Banjarbaru Kalimantan Selatan

Email: triando.saragih@ulm.ac.id

## Abstract

*Energy is needed by humans. Energy utilization is often carried out in daily activities, such as helping with work, household activities to lighting both at home and on the road. Recently, there has been a lot of research on concerns about the waste of energy and its lasting adverse impact on the environment. Previous research conducted by Tsanas and Xifara in 2012 has carried out energy efficiency in buildings using Statistical Machine Learning. Their research focuses on calculating outcomes one by one, not directly on all outcomes. In this study using the Multivariate Random Forest method. Multivariate Random Forest has similarities compared to Random Forest, while the Multivariate Random Forest method is more used if more than one output is produced. Based on the tests that have been carried out, it can be concluded that the best parameter that gives maximum results is the number of trees as many as 200 with a data division of 60% training data and 40% testing data with RMSE results of 2.602036 and MSE result of 6.770589. Based on the tests that have been carried out, it proves that the more the number of trees does not prove that it can provide maximum results.*

**Keywords:** Energy, Efficiency, Prediction, Multivariate Random Forest

## Abstrak

*Energi sangat dibutuhkan oleh manusia. Pemanfaatan energi sering dilakukan dalam kegiatan sehari-hari, seperti membantu pekerjaan, kegiatan rumah tangga hingga penerangan baik dalam rumah maupun di jalan. Akhir-akhir ini banyak penelitian tentang kekhawatiran mengenai pemborosan energi dan dampak buruknya yang abadi terhadap lingkungan. Penelitian sebelumnya yang dilakukan oleh Tsanas dan Xifara pada tahun 2012 telah melakukan efisiensi energi pada bangunan menggunakan Statistical Machine Learning. Penelitian mereka berfokus pada perhitungan luaran secara satu persatu, tidak secara langsung semua luaran. Pada penelitian ini menggunakan metode Multivariate Random Forest. Multivariate Random Forest memiliki kesamaan dibandingkan dengan Random Forest, sedangkan metode Multivariate Random Forest lebih digunakan jika luaran yang dihasilkan lebih dari satu. Berdasarkan pengujian yang sudah dilakukan, dapat disimpulkan bahwa parameter terbaik yang memberikan hasil maksimal yaitu pada jumlah pohon sebanyak 200 dengan pembagian data sebanyak 60% data latih dan 40% data uji dengan hasil RMSE sebesar 2.602036 dan MSE sebesar 6.770589. Berdasarkan pengujian yang sudah dilakukan membuktikan semakin banyak jumlah pohon tidak membuktikan bisa memberikan hasil yang maksimal.*

**Kata kunci:** Energi, Efisiensi, Prediksi, Multivariate Random Forest

## 1. PENDAHULUAN

Energi sangat dibutuhkan oleh manusia. Pemanfaatan energi sering dilakukan dalam kegiatan sehari-hari, seperti membantu pekerjaan, kegiatan rumah tangga hingga penerangan baik dalam rumah maupun di jalan. Akhir-akhir ini banyak penelitian tentang kekhawatiran mengenai pemborosan energi dan dampak buruknya yang abadi terhadap lingkungan[1]. Di Eropa, sudah mulai diberlakukan hukum yang mengatur bahwa bangunan-bangunan disana harus terikat secara hukum untuk mengetahui persyaratan mengenai efisiensi energi[2]. Laporan menunjukkan bahwa konsumsi energi bangunan terus meningkat selama dekade terakhir di seluruh dunia[3], [4], dan pemanas, ventilasi, dan pendingin udara, yang memiliki peran katalitik dalam mengatur iklim dalam ruangan [5], menyumbang sebagian besar penggunaan energi dalam bangunan [6]. Oleh karena itu, salah satu cara untuk mengurangi permintaan pasokan energi tambahan yang terus meningkat adalah dengan memiliki desain bangunan yang lebih hemat energi dengan sifat konservasi energi yang lebih baik.

Dalam hal desain bangunan yang efisien, perhitungan beban pemanas (*Heating Load*) dan beban pendinginan (*Cooling Load*) diperlukan untuk menentukan spesifikasi peralatan pemanas dan pendingin yang dibutuhkan untuk menjaga kondisi udara dalam ruangan yang nyaman. Untuk memperkirakan kapasitas pendinginan dan pemanasan yang diperlukan, arsitek dan perancang bangunan memerlukan informasi tentang karakteristik bangunan dan ruang yang dikondisikan (misalnya tingkat hunian dan aktivitas), iklim, dan tujuan penggunaan (bangunan tempat tinggal memiliki persyaratan umumnya berbeda dibandingkan dengan bangunan industri).

Menggunakan perangkat lunak simulasi energi bangunan khusus yang canggih dapat memberikan solusi yang andal untuk memperkirakan dampak alternatif desain bangunan; namun, proses ini bisa sangat memakan waktu dan membutuhkan keahlian pengguna dalam program tertentu. Selain itu, keakuratan hasil perkiraan dapat bervariasi di berbagai paket perangkat lunak simulasi bangunan [7]. Oleh karena itu, dalam praktiknya, banyak peneliti mengandalkan alat pembelajaran mesin untuk mempelajari pengaruh berbagai parameter bangunan (misalnya kepadatan) pada beberapa variabel yang diinginkan (misalnya energi) karena ini lebih mudah dan lebih cepat jika database rentang variabel yang diperlukan tersedia. [1], [8], [9]. Menggunakan konsep statistik dan pembelajaran mesin memiliki keuntungan yang berbeda bahwa keahlian yang disaring dari disiplin lain dibawa ke domain efisiensi energi pada bangunan, dan dengan menggunakan teknik ini sangat cepat untuk mendapatkan jawaban dengan memvariasikan beberapa parameter desain bangunan setelah model telah dilatih secara memadai. Terlebih lagi, analisis statistik dapat meningkatkan pemahaman kita dengan menawarkan ekspresi kuantitatif dari faktor-faktor yang mempengaruhi kuantitas (atau kuantitas) minat yang mungkin ingin difokuskan oleh perancang atau arsitek bangunan. Oleh karena itu, integrasi pembelajaran mesin di efisiensi energi pada bangunan telah memicu minat yang sangat besar akhir-akhir ini.

Penelitian sebelumnya yang dilakukan oleh Tsanas dan Xifara pada tahun 2012 telah melakukan efisiensi energi pada bangunan menggunakan *Statistical Machine Learning*. Pada penelitian ini, Tsanas dan Xifara menggunakan metode *Statistical Machine Learning* untuk melakukan prediksi. Pada penelitian ini, mereka menggunakan delapan masukan dan dua luaran. Hasil dari penelitian mereka yaitu menghasilkan error MAE sebesar rata-rata 2.14 untuk metode *Iteratively Reweighted Least Square* (IRLS) untuk nilai Y1 dan 2.21 untuk Y2. Mereka juga menggunakan *Random Forest* (RF) dengan hasil error 0.51 untuk Y1 dan 1.42 untuk Y2. Mereka kemudian menggunakan perhitungan MSE dengan hasil metode IRLS yaitu error 9.87 untuk Y1 dan 11.46 untuk Y2 serta metode RF yaitu error 1.03 untuk Y1 dan 6.59 untuk Y2. Terakhir, mereka menggunakan MRE untuk perhitungan nilai error dengan hasil 10.09 pada Y1 dan 9.41 pada Y2 untuk metode IRLS serta 2.18 pada Y1 dan 4.62 untuk Y2 pada metode RF[10].

Berdasarkan penelitian sebelumnya, Tsanas dan Xifara melakukan perhitungan berdasarkan masing-masing masukan kemudian dilakukan perhitungan untuk menghasilkan keluaran satu persatu. Pada penelitian ini, mereka menggunakan dua keluaran, sehingga perhitungan satu persatu menghasilkan hasil subjektif yang tinggi. Hasil subjektif yang tinggi bisa menghasilkan bias yang mempengaruhi hasil error tersebut. Salah satu metode yang bisa menangani permasalahan ini yaitu *Multivariate Random Forest*[11]–[13].

*Multivariate Random Forest* merupakan sebuah pengembangan metode *Random Forest* dengan tujuan untuk melakukan perhitungan yang bisa menghasilkan luaran lebih dari satu. Beberapa penelitian sebelumnya sudah dilakukan seperti yang dilakukan oleh Sa'adah, Indahwati dan Susetyo berjudul *Multivariate Random Forest to Identify the Importance Variable of 8 National Education Standards toward National Examination of Student High School in Indonesia*. Pada penelitian ini, mereka menggunakan 8 kriteria masukan dan 3 luaran. Hasil dari penelitian RMSEP sebesar 8.545 dan lebih baik dibanding menggunakan *Random Forest* yang sebesar 8.568[13].

Penelitian lainnya dilakukan oleh Browne, dkk yang berjudul *Multivariate random forest prediction of poverty and malnutrition prevalence*. Pada penelitian ini, mereka menggunakan data dari sebelas negara dengan mengambil indikator dari *Advancing Research on Nutrition and Agriculture* (ARENA). Hasil dari penelitian ini mereka menyimpulkan bahwa metode *Multivariate Random Forest* bisa digunakan untuk melakukan prediksi yang datanya bersifat sekuensial[12].

Berdasarkan penelitian sebelumnya yang sudah dijelaskan, peneliti ingin menggunakan metode *Multivariate Random Forest* untuk melakukan efisiensi energi. Penelitian ini bisa memberikan hasil yang lebih baik dibandingkan penelitian yang sudah dilakukan sebelumnya dan mengurangi bias yang terjadi agar bisa menghasilkan hasil yang lebih akurat.

## 2. METODOLOGI PENELITIAN

### 2.1. Data Efisiensi Energi

Berdasarkan penelitian sebelumnya yang dilakukan Tsanas dan Xifara, Mereka mengambil kubus dasar ( $3,5 \times 3,5 \times 3,5$ ) dan menghasilkan 12 bentuk

bangunan dimana setiap bentuk bangunan terdiri dari 18 elemen (kubus dasar). Semua bangunan tersebut memiliki volume yang sama yaitu 771,75 m<sup>3</sup>, namun luas permukaan dan dimensinya berbeda. Bahan yang digunakan untuk masing-masing dari 18 elemen adalah sama untuk semua bentuk bangunan. Pemilihan dilakukan oleh bahan terbaru dan paling umum di industri konstruksi bangunan dan dengan nilai U terendah. Secara khusus, kami menggunakan karakteristik bangunan berikut (nilai-U terkait muncul dalam tanda kurung): dinding (1.780), lantai (0.860), atap (0.500), jendela (2.260). Simulasi mengasumsikan bahwa bangunan berada di Athena, Yunani, perumahan dengan tujuh orang, dan aktivitas menetap (70W). Kondisi desain internal ditetapkan sebagai berikut: pakaian: 0,6 clo, kelembaban: 60%, kecepatan udara: 0,30 m/s, tingkat pencahayaan: 300 Lux. Penguatan internal diatur ke sensibel (5) dan laten (2 W/m<sup>2</sup>), sedangkan laju infiltrasi diatur ke 0,5 untuk laju pergantian udara dengan sensitivitas angin 0,25 pengubah udara per jam. Untuk sifat termal, kami menggunakan mode campuran dengan efisiensi 95%, rentang termostat 19-24°C, dengan operasi 15-20 jam pada hari kerja dan 10-20 jam pada akhir pekan.

Pada penelitian menggunakan tiga jenis area kaca, yang dinyatakan sebagai persentase luas lantai: 10%, 25%, dan 40%. Selanjutnya, lima skenario distribusi yang berbeda untuk setiap area kaca disimulasikan: (1) seragam: dengan 25% kaca di setiap sisi, (2) utara: 55% di sisi utara dan 15% di masing-masing sisi lainnya, (3) timur: 55% di sisi timur dan 15% di setiap sisi lainnya, (4) selatan: 55% di sisi selatan dan 15% di setiap sisi lainnya, dan (5) barat: 55% di sisi barat dan 15% pada masing-masing sisi lainnya. Selain itu, pada penelitian memperoleh sampel tanpa area kaca. Akhirnya, semua bentuk diputar untuk menghadapi empat titik mata angin.

Jadi, dengan mempertimbangkan dua belas bentuk bangunan dan tiga variasi area kaca dengan masing-masing lima distribusi area kaca, untuk empat orientasi, pada penelitian memperoleh  $12 \times 3 \times 5 \times 4 = 720$  sampel bangunan. Selain itu, penelitian ini mempertimbangkan dua belas bentuk bangunan untuk empat orientasi tanpa kaca. Oleh karena itu, secara total, pada penelitian ini mempelajari  $12 \times 3 \times 5 \times 4 + 12 \times 4 = 768$  bangunan. Masing-masing dari 768 bangunan simulasi dapat dicirikan oleh delapan parameter bangunan (agar sesuai dengan notasi matematika standar dan memudahkan analisis dalam pekerjaan ini, selanjutnya parameter bangunan ini akan disebut variabel input dan akan direpresentasikan dengan X) yang kami tertarik untuk mengeksplorasi lebih jauh. Juga, untuk masing-masing dari 768 bangunan, pada penelitian ini mencatat HL dan CL menjadi parameter yang disebut variabel keluaran dan akan direpresentasikan dengan y. Tabel 1 merangkum variabel masukan dan variabel luaran dalam penelitian ini, memperkenalkan representasi matematis untuk setiap variabel, dan menunjukkan jumlah nilai yang mungkin.

Pada Tabel 1 akan dijelaskan variabel data apa saja yang digunakan beserta luarannya[10].

Tabel 1. Representasi Matematika pada Data Masukkan dan Luaran

Representasi	Variabel Masukkan atau	Jumlah dari
--------------	------------------------	-------------

---

Matematika	Luaran	banyaknya kemungkinan
X1	Kepadatan relatif	2
X2	Luas permukaan	12
X3	Area dinding	7
X4	Luas atap	4
X5	Tinggi keseluruhan	2
X6	Orientasi	4
X7	Area kaca	4
X8	Distribusi area kaca	6
Y1	Beban pendinginan (CL)	586
Y2	Beban Pemanasan (HL)	636

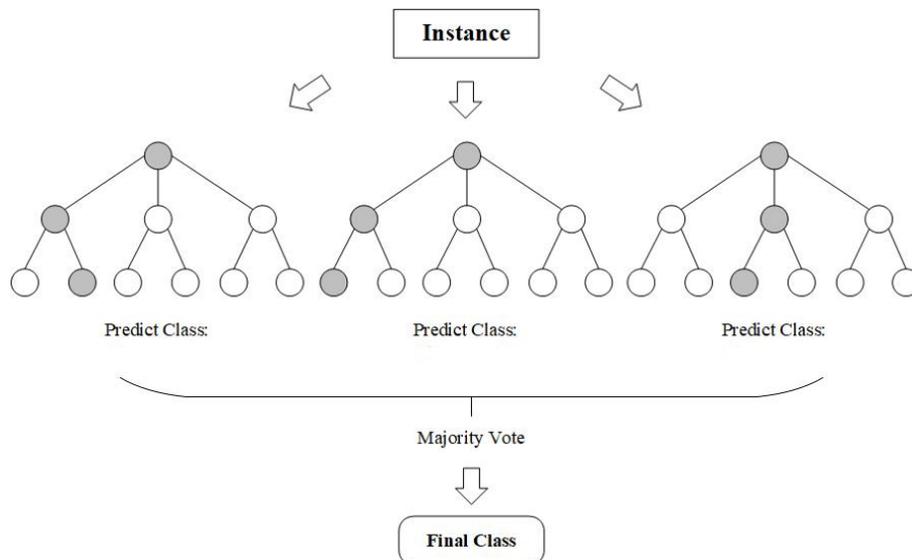
---

Berdasarkan Tabel 1, kami juga ikut menggunakan delapan data masukan serta dua data luaran. Data masukan diproses bersamaan kemudian menghasilkan dua prediksi menggunakan metode yang kami gunakan.

## 2.2. Multivariate Random Forest

*Multivariate Random Forest* pada dasarnya memiliki kesamaan dengan *Random Forest*. Perbedaan dari kedua metode ini terletak pada jumlah hasil keputusan, dimana *Random Forest* hanya memberikan satu hasil saja, sedangkan *Multivariate Random Forest* bisa memberikan lebih dari satu hasil[11].

Umumnya, *Random Forest* memiliki ratusan atau bahkan ribuan Pohon Keputusan, yang memprediksi kelas secara individual. tujuan dari *Random Forest* adalah untuk membentuk satu keputusan yang mewakili dari banyak pohon keputusan. Suara mayoritas dari seluruh pohon dapat didefinisikan sebagai hasil dari kelas prediksi. Struktur *Random Forest* dapat dilihat pada Gambar 1[14].



Gambar 1. Arsitektur Random Forest

Pada Gambar 1 menjelaskan bagaimana arsitektur *Random Forest*. *Multivariate Random Forest* memiliki kesamaan pada proses, cuman berbeda pada saat memberikan hasil luaran.

Untuk membentuk model *Multivariate Random Forest*, ada dua metode yang dapat digunakan, yaitu bagging dan random subspace. Berikut ini adalah langkah-langkah pengembangan model *Multivariate Random Forest*[15]:

- lakukan *resampling* secara acak dengan ukuran yang sama dengan data pelatihan menggunakan metode *bootstrap*
- Pilih atribut  $K$  dari total  $M$  atribut dimana  $K < M$  menggunakan metode *random subspace*, biasanya nilai  $K$  sama dengan akar kuadrat dari  $M$
- Bentuk pohon keputusan menggunakan sampel *bootstrap* dan atribut yang telah dipilih sebelumnya
- Ulangi langkah 1 hingga 3 untuk membentuk pohon hingga angka yang diinginkan. Jumlah pohon di *Multivariate Random Forest* ditentukan berdasarkan *out-of-bag error rate* (OOB)

### 2.3. Indeks Penilaian

Hasil klasifikasi dari penelitian ini perlu dievaluasi untuk mengukur tingkat keberhasilan sistem yang telah direncanakan sebelumnya. Umumnya *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE) Digunakan untuk mengukur kinerja klasifikasi. Dalam penelitian ini, nilai akurasi juga digunakan untuk menghitung kinerja prediksi sistem.

Untuk menghitung nilai selisih antara kuadrat nilai estimasi rata-rata dan nilai sebenarnya, digunakan *Mean Square Error* (MSE). Sedangkan pengukuran nilai selisih (sampel atau populasi) dari hasil prediksi dan nilai observasi menggunakan *Root Mean Square Error* (RMSE). Rumus MSE dan RMSE ditunjukkan pada (1) dan (2).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{n}} \quad (2)$$

Pada (1) dan (2),  $y$  merupakan nilai aktual,  $\hat{y}$  merupakan nilai prediksi, dan  $n$  merupakan jumlah data uji.

### 3. HASIL DAN PEMBAHASAN

Pada pengujian penelitian ini, kami melakukan dengan melakukan beberapa pengujian parameter. Parameter yang kami uji yaitu dari jumlah pohon yang dibentuk oleh *Multivariate Random Forest* dan kombinasi pembagian data latih dan data uji.

Jumlah pohon yang dibentuk kami batasi dari 100 hingga 500 pohon. Tujuan dari pembatasan ini agar bisa melihat seberapa baik hasil yang bisa diberikan dan mengetahui titik parameter mana yang bisa memberikan hasil maksimal.

Untuk pembagian data latih dan data uji, kami membatasi ke kombinasi 80% data latih 20% data uji, 70% data latih 30% data uji, dan 60% data latih 40% data uji. Kami tidak menggunakan kombinasi 90% data latih 10% data uji karena untuk mengurangi hasil yang kurang akurat dikarenakan data uji yang terlalu sedikit. Data yang kami bagi ke dalam data latih dan data uji dilakukan secara acak untuk meningkatkan objektifitas hasil pengujian yang dilakukan.

Pengujian setiap parameter dilakukan sebanyak 10 kali. Kami mengambil rata-rata tiap parameter kemudian membandingkannya agar didapat hasil terbaik. Berikut ini hasil pengujian parameter pertama dengan jumlah pohon sebanyak 100.

Tabel 2. Hasil Pengujian Menggunakan Jumlah Pohon Sebanyak 100

Pembagian Data	RMSE	MSE
60:40	2.83923	8.061229
70:30	3.232597	10.44969
80:20	2.984136	8.905069

Berdasarkan Tabel 2, dapat kita lihat bahwa pengujian terbaik pada jumlah pohon sebanyak 100 terdapat pada pembagian data 60:40 dengan rata-rata RMSE sebesar 2.83923 dan MSE sebesar 8.061229. Pada pengujian ini bisa kita lihat selisih pembagian data pada 70:30 terlihat sangat signifikan dibandingkan kelompok pembagian data yang lain.

Pengujian kedua yaitu menggunakan parameter jumlah pohon sebanyak 200. Hasil pengujian ini bisa dilihat pada Tabel 3.

Tabel 3. Hasil Pengujian Menggunakan Jumlah Pohon Sebanyak 200

Pembagian Data	RMSE	MSE
60:40	2.602036	6.770589
70:30	2.830261	8.010378
80:20	2.821516	7.96095

Berdasarkan hasil Tabel 3, dapat kita lihat bahwa hasil pengujian menggunakan jumlah pohon sebanyak 200 mengalami peningkatan hasil yang signifikan. Hasil terbaik dihasilkan pada pembagian data 60:40 dengan RMSE sebesar 2.602036 dan MSE sebesar 6.770589.

Pengujian ketiga yaitu menggunakan parameter jumlah pohon sebanyak 300. Hasil pengujian ini bisa dilihat pada Tabel 4.

Tabel 4. Hasil Pengujian Menggunakan Jumlah Pohon Sebanyak 300

Pembagian Data	RMSE	MSE
60:40	2.931006	8.590796
70:30	2.708732	7.337232
80:20	2.98848	8.93101

Berdasarkan hasil Tabel 4, dapat kita lihat bahwa hasil pengujian menggunakan jumlah pohon sebanyak 300 mengalami penurunan hasil dibandingkan pengujian sebelumnya. Hasil terbaik dihasilkan pada pembagian data 70:30 dengan RMSE sebesar 2.708732 dan MSE sebesar 7.337232.

Pengujian keempat yaitu menggunakan parameter jumlah pohon sebanyak 400. Hasil pengujian ini bisa dilihat pada Tabel 5.

Tabel 5. Hasil Pengujian Menggunakan Jumlah Pohon Sebanyak 400

Pembagian Data	RMSE	MSE
60:40	2.85198	8.13379
70:30	2.726301	7.432719
80:20	2.927317	8.569186

Berdasarkan hasil Tabel 5, dapat kita lihat bahwa hasil pengujian menggunakan jumlah pohon sebanyak 400 mengalami penurunan hasil dibandingkan pengujian sebelumnya. Hasil terbaik dihasilkan pada pembagian data 70:30 dengan RMSE sebesar 2.726301 dan MSE sebesar 7.432719.

Pengujian terakhir yaitu menggunakan parameter jumlah pohon sebanyak 500. Hasil pengujian ini bisa dilihat pada Tabel 6.

Tabel 6. Hasil Pengujian Menggunakan Jumlah Pohon Sebanyak 500

Pembagian Data	RMSE	MSE
60:40	2.916417	8.505489
70:30	2.789702	7.782436
80:20	2.805858	7.872842

Berdasarkan hasil Tabel 6, dapat kita lihat bahwa hasil pengujian menggunakan jumlah pohon sebanyak 500 mengalami penurunan hasil dibandingkan pengujian sebelumnya. Hasil terbaik dihasilkan pada pembagian data 70:30 dengan RMSE sebesar 2.789702 dan MSE sebesar 7.782436.

Berdasarkan kelima pengujian tersebut, dapat kita lihat bahwa parameter terbaik yang memberikan hasil maksimal yaitu pada jumlah pohon sebanyak 200 dengan pembagian data sebanyak 60% data latih dan 40% data uji dengan hasil RMSE sebesar 2.602036 dan MSE sebesar 6.770589. Berdasarkan pengamatan hasil ini, bisa kita lihat setelah jumlah pohon lebih dari 200 mengalami penurunan hasil dan mulai begeser jumlah pembagian data yang memberikan hasil terbaik.

#### 4. SIMPULAN

Berdasarkan pengujian yang sudah dilakukan, dapat disimpulkan bahwa parameter terbaik yang memberikan hasil maksimal yaitu pada jumlah pohon sebanyak 200 dengan pembagian data sebanyak 60% data latih dan 40% data uji dengan hasil RMSE sebesar 2.602036 dan MSE sebesar 6.770589. Semakin banyak jumlah pohon yang dibentuk belum tentu memberikan hasil yang lebih baik dan menemui titik maksimal di jumlah pohon sebanyak 200.

Berdasarkan hasil penelitian yang sudah dilakukan, kami menyarankan untuk penelitian selanjutnya dilakukan optimasi pada pembentukan pohon. Beberapa metode optimasi yang bisa dilakukan yaitu Algoritma Genetika [16], [17], *Simulated Annealing* [18], [19] atau metode *Bayesian Network*[20] untuk melakukan prediksi.

#### DAFTAR PUSTAKA

- [1] Z. Yu, F. Haghghat, B. C. M. Fung, and H. Yoshino, "A decision tree method for building energy demand modeling," *Energy Build.*, vol. 42, no. 10, pp. 1637–1646, 2010, doi: 10.1016/j.enbuild.2010.04.006.
- [2] T. H. E. E. Parliament, T. H. E. Council, O. F. The, and E. Union, "Directive 2002/65/EC of the European Parliament and of the Council," *Fundam. Texts Eur. Priv. Law*, pp. 65–71, 2020, doi: 10.5040/9781782258674.0021.
- [3] W. G. Cai, Y. Wu, Y. Zhong, and H. Ren, "China building energy consumption: Situation, challenges and corresponding measures," *Energy Policy*, vol. 37, no. 6, pp. 2054–2059, Jun. 2009, doi: 10.1016/j.enpol.2008.11.037.
- [4] L. Pérez-Lombard, J. Ortiz, and C. Pout, "A review on buildings energy consumption information," *Energy Build.*, vol. 40, no. 3, pp. 394–398, Jan. 2008, doi: 10.1016/j.enbuild.2007.03.007.
- [5] G. Platt, J. Li, R. Li, G. Poulton, G. James, and J. Wall, "Adaptive HVAC zone modeling for sustainable buildings," *Energy Build.*, vol. 42, no. 4, pp. 412–421, Apr. 2010, doi: 10.1016/j.enbuild.2009.10.009.

- [6] R. Yao, B. Li, and K. Steemers, "Energy policy and standard for built environment in China," *Renew. Energy*, vol. 30, no. 13, pp. 1973–1988, Oct. 2005, doi: 10.1016/j.renene.2005.01.013.
- [7] A. Yezioro, B. Dong, and F. Leite, "An applied artificial intelligence approach towards assessing building performance simulation tools," *Energy Build.*, vol. 40, no. 4, pp. 612–620, Jan. 2008, doi: 10.1016/j.enbuild.2007.04.014.
- [8] T. Catalina, J. Virgone, and E. Blanco, "Development and validation of regression models to predict monthly heating demand for residential buildings," *Energy Build.*, vol. 40, no. 10, pp. 1825–1832, Jan. 2008, doi: 10.1016/j.enbuild.2008.04.001.
- [9] B. Dong, C. Cao, and S. E. Lee, "Applying support vector machines to predict building energy consumption in tropical region," *Energy Build.*, vol. 37, no. 5, pp. 545–553, May 2005, doi: 10.1016/j.enbuild.2004.09.009.
- [10] A. Tsanas and A. Xifara, "Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools," *Energy Build.*, vol. 49, pp. 560–567, 2012, doi: 10.1016/j.enbuild.2012.03.003.
- [11] M. Sega and Y. Xiao, "Multivariate random forests," *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, vol. 1, no. 1, pp. 80–87, 2011, doi: 10.1002/widm.12.
- [12] C. Browne *et al.*, "Multivariate random forest prediction of poverty and malnutrition prevalence," *PLoS One*, vol. 16, no. 9 September, pp. 1–23, 2021, doi: 10.1371/journal.pone.0255519.
- [13] A. A. Sa'adah, Indahwati, and B. Susetyo, "Multivariate Random Forest to Identify the Importance Variable of 8 National Education Standards toward National Examination of Student High School in Indonesia," *Int. J. Sci. Basic Appl. Res.*, vol. 48, no. 6, pp. 174–183, 2019.
- [14] T. H. Saragih, V. N. Wijayaningrum, and M. Haekal, "Jatropha Curcas Disease Identification using Random Forest," *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 7, no. 1, p. 9, Apr. 2021, doi: 10.26555/jiteki.v7i1.20141.
- [15] X. Zhou, P. Lu, Z. Zheng, D. Tolliver, and A. Keramati, "Accident Prediction Accuracy Assessment for Highway-Rail Grade Crossings Using Random Forest Algorithm Compared with Decision Tree," *Reliab. Eng. Syst. Saf.*, vol. 200, p. 106931, 2020, doi: 10.1016/j.ress.2020.106931.
- [16] T. H. Saragih, W. F. Mahmudy, and Y. P. Anggodo, "Genetic algorithm for optimizing FIS Tsukamoto for dental disease identification," *2017 Int. Conf. Adv. Comput. Sci. Inf. Syst. ICACSIS 2017*, vol. 2018-Janua, pp. 345–349, 2018, doi: 10.1109/ICACSIS.2017.8355057.
- [17] P. Guo, W. Cheng, and Y. Wang, "Hybrid evolutionary algorithm with extreme machine learning fitness function evaluation for two-stage capacitated facility location problems," *Expert Syst. Appl.*, vol. 71, pp. 57–68, 2017, doi: 10.1016/j.eswa.2016.11.025.
- [18] L. M. R. Rere, M. I. Fanany, and A. M. Arymurthy, "Simulated Annealing Algorithm for Deep Learning," *Procedia Comput. Sci.*, vol. 72, pp. 137–144, 2015, doi: 10.1016/j.procs.2015.12.114.

- [19] T. H. Saragih, W. F. Mahmudy, A. L. Abadi, and Y. P. Anggodo, "Application of extreme learning machine and modified simulated annealing for jatropa curcas disease identification," *Int. J. Adv. Soft Comput. its Appl.*, vol. 10, no. 2, pp. 108–119, 2018.
- [20] S. Monti and G. F. Cooper, "A Multivariate Discretization Method for Learning Bayesian Networks from Mixed Data," pp. 404–413, 2013, [Online]. Available: <http://arxiv.org/abs/1301.7403>.