



PENERAPAN ALGORITMA DECISION TREE UNTUK KLASIFIKASI KONSUMSI ENERGI LISRIK RUMAH TANGGA DENGAN PENGGUNAAN RAPID MINER

Ubeitul Maltuf^{a*}, Zaehol Fatah^b

^a Fakultas & Sistem Informasi, ubeitulmaltuf@gmail.com, Universitas Ibrahimy Situbondo, Jawa Timur

^b Fakultas & Sistem Informasi, zaeholfatah@gmail.com, Universitas Ibrahimy Situbondo, Jawa Timur

*Korespondensi

ABSTRACT

The research aims to explore and understand energy consumption patterns in households. By using the Decision Tree algorithm, to classify the level of electrical energy consumption. And data on household electrical energy consumption can be obtained from various sources, such as Household electricity meter. Survey or questionnaire filled out by homeowners regarding the use of electrical appliances. Based on the image above, the application of the Decision Tree algorithm in analyzing risk factors for The classification of household electrical energy consumption produces an accuracy value of 100.00%. From the displayed confusion matrix, we can see the distribution of predicted and actual values for various classes. For example, in the class "true 110 25," there are 17052 correct predictions. The evaluation results also show the precision and recall values for each class. The highest precision was achieved in the "true 2205" class with 100% recall, while the precision was found in the "true 122.5" class of 100.00%.

Keywords: *Algorithm Classification Decision Tree Energy Consumption RapidMiner*

Abstrak

Penelitian ini bertujuan untuk mengeksplorasi dan memahami pola konsumsi energi pada rumah tangga. Dengan menggunakan algoritma Decision Tree, untuk mengklasifikasikan tingkat konsumsi energi listrik. Dan data konsumsi energi listrik rumah tangga dapat diperoleh dari berbagai sumber, seperti meteran listrik rumah tangga. Survei atau kuesioner yang diisi oleh pemilik rumah mengenai penggunaan peralatan listrik. Berdasarkan gambar di atas, penerapan algoritma Decision Tree dalam menganalisis faktor risiko klasifikasi konsumsi energi listrik rumah tangga menghasilkan nilai akurasi sebesar 100,00%. Dari matriks konfusi yang ditampilkan, kita dapat melihat distribusi nilai prediksi dan aktual untuk berbagai kelas. Misalnya, pada kelas "true 110 25," terdapat 17052 prediksi yang benar. Hasil evaluasi juga menunjukkan nilai presisi dan recall untuk setiap kelas. Presisi tertinggi dicapai pada kelas "true 2205" dengan recall 100%, sedangkan presisi terdapat pada kelas "true 122,5" sebesar 100,00%.

Kata Kunci: Algoritma, DecisionTree, Klasifikasi, Konsumsi Energi, RapidMiner.

1. PENDAHULUAN

Konsumsi energi listrik pada rumah tangga merupakan aspek penting dalam pengelolaan sumber daya energi berkelanjutan. Di banyak negara, peningkatan permintaan energi rumah tangga merupakan tantangan besar yang perlu dihadapi, terutama dalam konteks keberlanjutan dan efisiensi energi. Oleh karena itu, pemahaman yang mendalam tentang pola konsumsi energi diperlukan untuk mengembangkan strategi penghematan energi yang efektif. Salah satu metode yang dapat digunakan untuk menganalisis dan memprediksi konsumsi energi adalah algoritma Decision Tree. Decision Tree merupakan teknik machine learning yang mampu memodelkan hubungan kompleks antara variabel input dan output dengan cara yang mudah dipahami. Metode ini secara otomatis membagi data ke dalam kategori berdasarkan fitur yang relevan, sehingga dapat digunakan untuk klasifikasi atau regresi. Keunggulan utama Decision Tree adalah

kemampuannya untuk memberikan interpretasi yang jelas dan visualisasi yang intuitif, menjadikannya pilihan yang menarik untuk analisis data energi Loh, 2011 [1]. Dalam konteks ini, RapidMiner sebagai alat analisis data yang canggih menawarkan berbagai fitur untuk mengimplementasikan algoritma Decision Tree secara efisien. RapidMiner memungkinkan pengguna untuk melakukan praproses data, membangun model, dan mengevaluasi kinerjanya dalam satu platform. Terpadu. Melalui penelitian ini, kami bertujuan untuk menerapkan algoritma Decision Tree di RapidMiner untuk mengklasifikasikan tingkat konsumsi listrik rumah tangga ke dalam kategori rendah, sedang, dan tinggi, serta untuk mengeksplorasi faktor-faktor yang memengaruhi pola konsumsi tersebut. Dengan demikian, diharapkan penelitian ini dapat memberikan kontribusi bagi pemahaman tentang manajemen energi listrik di rumah tangga, serta menjadi dasar untuk mengembangkan kebijakan yang lebih baik untuk penghematan energi

2. METODOLOGI PENELITIAN

2.1 Jenis penelitian

Penelitian terapan bertujuan untuk memecahkan masalah praktis dengan menerapkan teori dan metode yang ada pada situasi nyata. Dalam konteks ini, penelitian difokuskan pada penerapan algoritma Decision Tree untuk klasifikasi konsumsi energi listrik rumah tangga yang merupakan isu penting dalam manajemen energi yang efisien. Pendekatan kuantitatif digunakan untuk mengumpulkan dan menganalisis data numerik. Data diperoleh melalui survei yang melibatkan pertanyaan terstruktur terkait penggunaan energi, sehingga analisis dapat dilakukan secara statistik untuk menemukan pola dan hubungan antar variabel. Desain penelitian ini bersifat eksploratif, dimana penelitian bertujuan untuk mengeksplorasi dan memahami pola konsumsi energi dalam rumah tangga. Dengan menggunakan algoritma Decision Tree, penelitian ini berupaya mengidentifikasi faktor-faktor signifikan yang memengaruhi tingkat konsumsi energi. Penelitian ini juga dapat dianggap sebagai studi kasus, karena analisis dilakukan pada sejumlah rumah tangga tertentu. Hal ini memungkinkan peneliti untuk mendapatkan wawasan mendalam tentang pola konsumsi energi dalam konteks lokal dan memberikan rekomendasi yang tepat untuk manajemen Makonin,

2.2 Metode pengumpulan data

Data konsumsi listrik rumah tangga dapat diperoleh dari berbagai sumber, seperti: Meteran listrik rumah tangga. Survei atau kuesioner yang diisi oleh pemilik rumah mengenai penggunaan peralatan listrik. Data dari penyedia listrik. Pengumpulan Data Primer Buatlah kuesioner yang memuat pertanyaan mengenai jenis peralatan listrik yang digunakan (misalnya lampu, AC, kulkas, dan lain-lain) Lamanya penggunaan peralatan listrik per hari. Jumlah anggota keluarga. Kebiasaan penggunaan listrik (misalnya waktu puncak penggunaan) Observasi Langsung Lakukan observasi langsung pada rumah-rumah terpilih untuk memperoleh data akurat mengenai penggunaan listrik Hakiki, M. H. (2024). [7]

2.3 Pengumpulan Data Sekunder

Menggunakan data dari sumber sekunder seperti Statistik dari lembaga pemerintah yang terkait dengan konsumsi energi Laporan tahunan dari perusahaan listrik Penelitian sebelumnya yang relevan dengan topik Pengolahan dan Pembersihan Data Setelah data terkumpul, lakukan pembersihan data untuk menghilangkan duplikat, kesalahan, atau data yang tidak relevan. Ubah data menjadi format yang sesuai untuk analisis, seperti mengubah variabel kategorikal menjadi numerik jika perlu Pemisahan Dataset Membagi dataset menjadi dua bagian data latih dan data pengujian untuk menguji keakuratan model yang dibangun Implementasi di RapidMiner mengimpor dataset ke RapidMiner Menggunakan operator Decision Tree untuk membangun model klasifikasi. Mengevaluasi model menggunakan data uji dan menghitung metrik seperti akurasi, presisi, recall, dan F1-score. Terdapat fitur ikhtisar data (Implementasi Algoritma Decision Tree untuk Klasifikasi Konsumsi Listrik Rumah Tangga Menggunakan Rapid Miner Ini adalah data gambar Tentang Implementasi Algoritma Decision Tree untuk. Klasifikasi Konsumsi Listrik Rumah Tangga Menggunakan Rapid Miner Yang diambil dari dataset U.S. Energy Information Administration [8]

0.64	784.00	343.00	220.50	3.50	4
0.64	784.00	343.00	220.50	3.50	5
0.62	808.50	367.50	220.50	3.50	2
0.62	808.50	367.50	220.50	3.50	3
0.62	808.50	367.50	220.50	3.50	4
0.62	808.50	367.50	220.50	3.50	5
0.98	514.50	294.00	110.25	7.00	2
0.98	514.50	294.00	110.25	7.00	3
0.98	514.50	294.00	110.25	7.00	4
0.98	514.50	294.00	110.25	7.00	5
0.90	563.50	318.50	122.50	7.00	2
0.90	563.50	318.50	122.50	7.00	3
0.90	563.50	318.50	122.50	7.00	4
0.90	563.50	318.50	122.50	7.00	5
0.86	588.00	294.00	147.00	7.00	2
0.86	588.00	294.00	147.00	7.00	3
0.86	588.00	294.00	147.00	7.00	4
0.86	588.00	294.00	147.00	7.00	5
0.82	612.50	318.50	147.00	7.00	2
0.82	612.50	318.50	147.00	7.00	3
0.82	612.50	318.50	147.00	7.00	4
0.82	612.50	318.50	147.00	7.00	5
0.79	637.00	343.00	147.00	7.00	2
0.79	637.00	343.00	147.00	7.00	3
0.79	637.00	343.00	147.00	7.00	4
0.79	637.00	343.00	147.00	7.00	5
0.76	661.50	416.50	122.50	7.00	2
0.76	661.50	416.50	122.50	7.00	3
0.76	661.50	416.50	122.50	7.00	4
0.76	661.50	416.50	122.50	7.00	5
0.74	686.00	245.00	220.50	3.50	2
0.74	686.00	245.00	220.50	3.50	3
0.74	686.00	245.00	220.50	3.50	4
0.74	686.00	245.00	220.50	3.50	5
0.71	710.50	269.50	220.50	3.50	2
0.71	710.50	269.50	220.50	3.50	3
0.71	710.50	269.50	220.50	3.50	4
0.71	710.50	269.50	220.50	3.50	5
0.69	735.00	294.00	220.50	3.50	2
0.69	735.00	294.00	220.50	3.50	3
0.69	735.00	294.00	220.50	3.50	4
0.69	735.00	294.00	220.50	3.50	5
0.66	759.50	318.50	220.50	3.50	2
0.66	759.50	318.50	220.50	3.50	3
0.66	759.50	318.50	220.50	3.50	4
0.66	759.50	318.50	220.50	3.50	5

Figure 1. Household Electrical Energy Consumption Classification Dataset

2.4 Data Mining

Data mining merupakan proses menemukan korelasi, pola, dan tren yang signifikan dengan cara menganalisis sejumlah besar data yang tersimpan dalam repositori, menggunakan teknik pengenalan pola serta metode statistik dan matematika. Data mining bertujuan untuk mengungkap pola dan informasi yang menarik dari sejumlah besar data. Istilah data mining sering dikaitkan dengan istilah lain seperti knowledge discovery atau pattern recognition. Istilah knowledge discovery dinilai tepat karena tujuan utama dari data mining adalah mengungkap pengetahuan yang tersembunyi dalam data. Sementara itu, istilah pattern recognition cocok digunakan karena proses ini berfokus pada penemuan pola yang tersimpan dalam kumpulan data yang besar. (Teknologi et al. 2021).[2]

2.5 Klasifikasi

Klasifikasi merupakan proses penilaian data untuk menempatkannya ke dalam salah satu kelas yang tersedia. Dalam proses ini, dibuat suatu model berdasarkan data latih yang kemudian digunakan untuk mengklasifikasikan data baru. Klasifikasi dapat diartikan sebagai suatu proses pembelajaran atau pelatihan terhadap suatu fungsi target yang memetakan setiap himpunan atribut (fitur) ke dalam salah satu kelas yang sudah ada. Tujuan dari suatu sistem klasifikasi adalah untuk mengklasifikasikan semua data secara akurat, namun kinerjanya tidak selalu 100% sempurna. Oleh karena itu, diperlukan pengukuran untuk mengevaluasi kinerja sistem klasifikasi, yang biasanya dilakukan dengan menggunakan matriks konfusi (Arrohman dan Fatah 2024 [3]).

2.6 Algoritma Decision Tree

Algoritma ini juga digunakan dalam random forest untuk melatih subset data pelatihan yang berbeda dan mencapai hasil yang lebih akurat. Selain untuk memudahkan pengambilan keputusan dan memberi gambaran yang jelas mengenai alasan keputusan tersebut dibuat, decision tree juga sangat berguna untuk

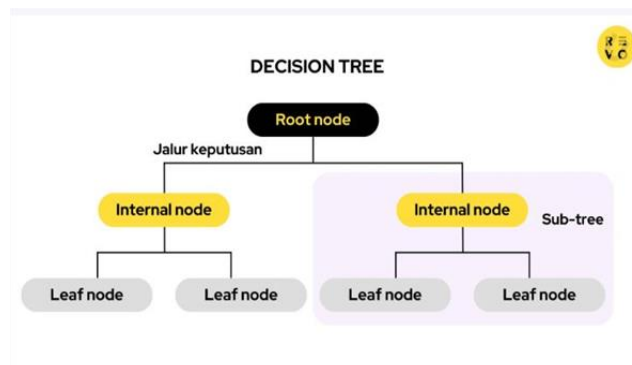
data mining. Kelebihan Decision Tree Karena strukturnya sederhana, decision tree merupakan salah satu metode tercepat untuk mengidentifikasi variabel signifikan dan hubungan antara dua variabel.

a. kelebihan decision tree

Bersifat fleksibel karena bisa digunakan untuk tugas klasifikasi dan regresi, serta cocok untuk menangani berbagai jenis data seperti data diskrit, data kontinu, dan data kategorikal. Mudah dipahami, khususnya untuk orang tanpa latar belakang analitis, karena decision tree mengikuti proses yang sama seperti yang dilakukan manusia saat membuat keputusan di dunia nyata. Sifat hierarki decision tree mempermudah analyst melihat atribut mana yang paling penting. Membantu analyst memikirkan semua kemungkinan solusi untuk menyelesaikan suatu masalah. Decision tree hanya membutuhkan sedikit data cleaning untuk memperbaiki kesalahan atau ketidakkonsistenan dibandingkan algoritma lain.

b. Kekurangan Decision Tree

Decision tree memiliki banyak lapisan sehingga terkesan kompleks dan rentan overfitting, yaitu algoritma tidak memberikan prediksi akurat untuk data pelatihan yang baru. Tidak didukung sepenuhnya oleh Scikit-learn, library machine learning populer berbasis Python. Tidak ideal untuk dataset besar karena decision tree membutuhkan waktu yang lama untuk dilatih dan lebih mahal, serta kompleksitas bisa meningkat. Contoh Decision Tree Tanpa disadari, decision tree sering digunakan pada kehidupan sehari-hari baik untuk pengambilan keputusan sederhana maupun kompleks. Gambar dibawah ini memberikan ilustrasi mengenai algoritma Decision Tree sesuai definisi tersebut.



Gambar 2. Skema Algoritma Decision Tree

2.7 Faktor Risiko Kualitas Data

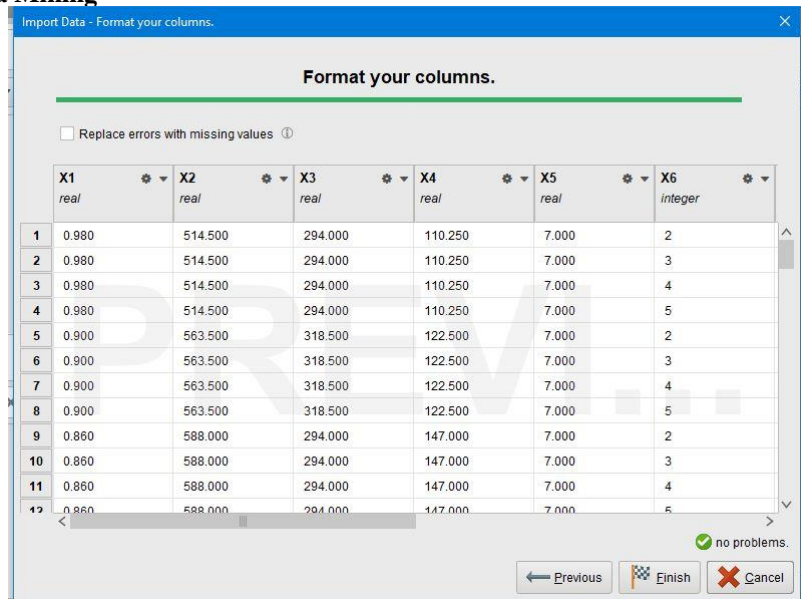
Keterangan: Data yang tidak lengkap, tidak akurat, atau tidak konsisten dapat menyebabkan model yang buruk. Data yang hilang atau outlier dapat memengaruhi hasil klasifikasi. Mitigasi: Lakukan pembersihan dan pemrosesan data sebelum analisis. Overfitting Model Pohon Keputusan yang terlalu rumit dapat mempelajari terlalu banyak dari data pelatihan, dan karenanya tidak dapat digeneralisasi dengan baik ke data pengujian. Gunakan teknik pemangkasan untuk menyederhanakan model dan mengurangi kompleksitas pohon. Memilih fitur yang tidak relevan atau kurang informatif dapat mengurangi kinerja model. Terlalu banyak fitur juga dapat menimbulkan gangguan. Lakukan analisis fitur dan pilih fitur yang relevan sebelum membangun model. Jika data tidak mewakili populasi yang lebih besar, model yang dihasilkan akan bias dan tidak akurat. Gunakan teknik pengambilan sampel yang tepat dan pastikan keterwakilan data. Konsumsi listrik dapat dipengaruhi oleh banyak faktor eksternal seperti cuaca, hari dalam seminggu, dan acara khusus, yang mungkin tidak terwakili dalam data. Kumpulkan data tambahan yang mencakup variabel eksternal Pola penggunaan listrik dapat berubah seiring waktu, yang dapat membuat model kurang relevan jika tidak diperbarui. Lakukan pemodelan secara berkala dengan data terbaru untuk memastikan keakuratan. Kesalahan dalam penggunaan RapidMiner atau konfigurasi model dapat mengakibatkan hasil yang salah. Memastikan pemahaman yang baik tentang alat dan teknik yang digunakan, dan memvalidasi hasilnya. Quinlan, J. R. (1996) [9]

3. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan dengan menggunakan salah satu model klasifikasi yaitu Random Forest. Model ini diimplementasikan menggunakan software RapidMiner versi 10.3 untuk mempermudah proses analisis data. Dataset yang digunakan dalam penelitian ini diperoleh dari situs Kaggle. Data ini berisi atribut-atribut yang relevan untuk mengklasifikasi individu berdasarkan risiko untuk Klasifikasi Konsumsi Energi Listrik Rumah Tangga Menggunakan Rapid Miner dengan kategori individu yang mengalami obesitas atau tidak,

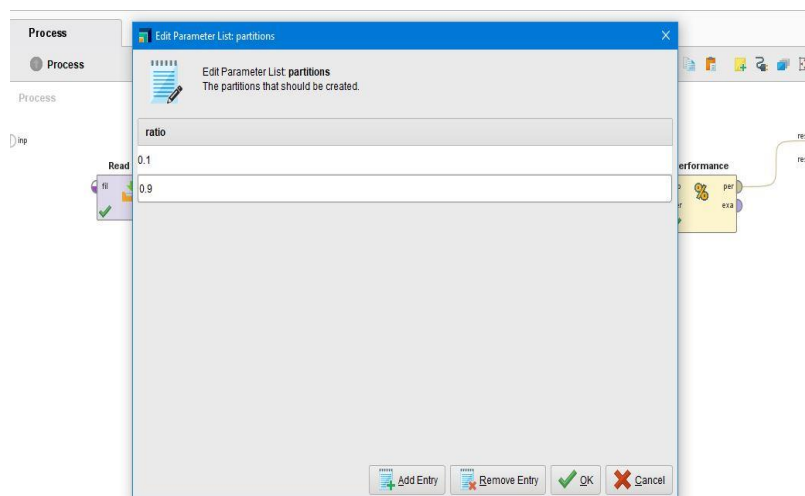
yang dapat dijadikan sebagai parameter utama. Proses penggunaan visualisasi pada RapidMiner dilakukan melalui langkah-langkah sebagai berikut Hakiki, M. H. (2024) [6]

3.1 Model Data Mining



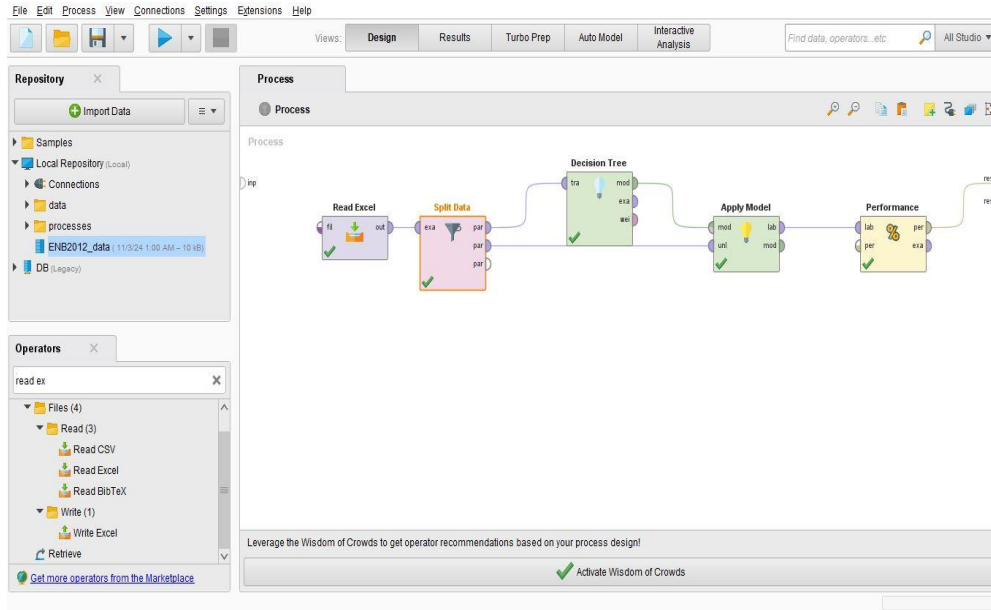
Gambar 3. Operator Pemanggil Data

Operator Read Excel digunakan untuk memuat dataset yang disimpan dalam format Excel. Di bagian ini, kita juga menentukan atribut yang akan digunakan sebagai label dalam dataset yang digunakan.



Gambar 4. Split Data

Fungsi split data untuk memisahkan dataset menjadi data latih dan data uji. Oktafiani, Hermawan, dan Avianto 2023. [4] Langkah ini sangat penting untuk menghindari overfitting dan mengevaluasi kemampuan model dalam mengidentifikasi faktor risiko klasifikasi konsumsi energi listrik rumah tangga. Operator Split Data dapat digunakan untuk membagi dataset, misalnya 100% untuk data latih dan 10% untuk data uji, untuk memastikan bahwa model Decision Tree dapat digeneralisasi dengan baik ke data baru, bukan hanya data yang digunakan untuk pelatihan.



Gambar 5. Model Pohon Keputusan

Implementation of data mining with the Decision Tree algorithm using the RapidMiner application version 10.3 is carried out through several steps as shown in the image above. The next stage is to connect all the operators that have been prepared. The Apply Model operator is an important component used to apply a trained model to a new dataset, allowing predictions or classifications to be made on unknown data based on a model built from the training data. After training a Decision Tree model using the training data, the Apply Model operator can be used to apply the model on test data to predict risk for classification of household electrical energy consumption. The Performance Operator is used to evaluate the performance of models that have been trained and implemented. It is an important tool for assessing the effectiveness of models in predicting or classifying risk factors for classification of household electrical energy consumption, by providing various metrics such as accuracy, precision, and recall to assess the quality of predictions produced by the model after being applied to test data Al-Giffary and Martanto 2024. [5]

The screenshot shows the 'PerformanceVector (Performance)' window with a 'Table View' selected. The window displays a confusion matrix and accuracy metrics. The accuracy is 100.00%. The confusion matrix is as follows:

	true 110.25	true 122.5	true 147	true 220.5	class precision
pred. 110.25	17052	0	0	0	100.00%
pred. 122.5	0	42115.500	0	0	100.00%
pred. 147	0	0	55198.500	0	100.00%
pred. 220.5	0	0	0	106109.500	100.00%
class recall	100.00%	100.00%	100.00%	100.00%	

Gambar 6. Hasil Akurasi

Based on the image above, the Application of the Decision Tree Algorithm in analyzing risk factors for the classification of household electrical energy consumption produces an accuracy value of 100.00%. From the displayed confusion matrix, we can see the distribution of predicted and actual values for various classes. For example, in the class "true 110 25," there are 17052 correct predictions. The evaluation results also show the precision and recall values for each class. The highest precision was achieved in the "true 2205" class with 100% recall, while the precision was found in the "true 122.5" class of 100.00%. Performance evaluation using these various metrics provides an idea of how well the Decision Model is at

predicting household electrical energy consumption classification risk factors among the analyzed individuals. By considering these results, this model shows good ability in classifying data, although there are several classes that require improvement in terms of precision and recall which are quite accurate and have high accuracy in risk analysis for classification of household electrical energy consumption. Géron, A. (2019) [10]

4. KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan bahwa beberapa variabel memiliki pengaruh yang lebih besar terhadap risiko klasifikasi konsumsi energi listrik rumah tangga dan adanya riwayat klasifikasi konsumsi energi listrik rumah tangga dalam keluarga muncul sebagai faktor yang meningkatkan risiko klasifikasi konsumsi energi listrik rumah tangga. Berdasarkan analisis menggunakan algoritma Decision Tree, dapat disimpulkan bahwa model ini efektif dan efisien dalam mengidentifikasi faktor-faktor utama yang mempengaruhi risiko Klasifikasi Konsumsi Energi Listrik Rumah Tangga. Hasil ini memberikan wawasan yang berharga bagi para pembuat kebijakan dan praktisi Konsumsi Energi Listrik Rumah Tangga untuk merancang program agar lebih baik lagi. Meskipun hasil penelitian ini memberikan bukti yang kuat mengenai efektivitas Decision Tree dalam menganalisis faktor-faktor risiko klasifikasi konsumsi energi listrik rumah tangga, penelitian ini masih memiliki beberapa keterbatasan. Salah satunya adalah keterbatasan ukuran dataset yang digunakan, yang dapat mempengaruhi generalisasi hasil. Oleh karena itu, disarankan untuk melakukan penelitian lanjutan dengan menggunakan dataset yang lebih besar dan lebih bervariasi, serta melibatkan variabel-variabel lain yang dapat berkontribusi terhadap klasifikasi konsumsi energi listrik rumah tangga, seperti faktor psikologis dan sosial ekonomi rumah tangga. Secara keseluruhan, penelitian ini menegaskan bahwa algoritma Decision Tree merupakan alat yang berguna dan andal untuk menganalisis data kesehatan, terutama dalam mengidentifikasi faktor risiko klasifikasi konsumsi energi listrik rumah tangga. Temuan ini dapat digunakan sebagai dasar upaya pencegahan klasifikasi konsumsi energi listrik rumah tangga agar lebih aman.

Ucapan Terima Kasih

Dalam pembuatan “Penerapan Algoritma Decision Tree Untuk Klasifikasi Konsumsi Energi Listrik Rumah Tangga Dengan Penggunaan Rapid Miner” ini tidak lepas dari bimbingan dan bantuan dari berbagai pihak. Saya ucapkan banyak-banyak terima kasih kepada: a. dosen pembimbing yang telah meluangkan waktunya untuk memberikan arahan, bimbingan dan serta wawasan yang menjadikan salah satu kunci keberhasilan penelitian ini. b. Kepada orang tua yang telah membiayai serta memberikan arahan dalam penyelesaian penelitian ini c. Pihak kampus yang telah memberikan fasilitas yang sangat memadai sehingga penelitian ini bisa selesai tepat waktu.

DAFTAR PUSTAKA

- [1] Loh, W. Y. (2011). "Classification and Regression Trees." Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 1(1), 14-23.
- [2] Teknologi, Jurnal et al. 2021. “Analisis Data Mining Untuk Clustering Kasus): 100–108.
- [3] Arrohman, Supri, and Zaehol Fatah. 2024. “Gudang Jurnal Multidisiplin Ilmu Prediksi Diabetes Menggunakan Algoritma Klasifikasi K-Nearest Neighbors (K-NN) Pada Perempuan Indian Pima.” 2: 220–26.
- [4] Oktafiani, Rian, Arief Hermawan, and Donny Avianto. 2023. “Pengaruh Komposisi Split Data Terhadap Performa Klasifikasi Penyakit Kanker Payudara Menggunakan Algoritma Machine Learning.” Jurnal Sains dan Informatika 9(April): 19–28.
- [5] Al-Giffary, Farhan Rizky, and Martanto Martanto. 2024. “Klasifikasi Kelulusan Siswa Tahun 2024 Menggunakan Metode Decision Tree (Studi Kasus Sma Islam Alazhar 5 Cirebon).” Jurnal Manajemen Informatika Jayakarta 4(2): 195.
- [6] Hakiki, M. H. (2024). *Prediksi Konsumsi Energi Listrik Menggunakan Pendekatan Non-Intrusive Load Monitoring*. ITS Repository. [ITS Repository ps://repository.its.ac.id/111071/](https://repository.its.ac.id/111071/).
- [7] Hakiki, M. H. (2024). *Prediksi Konsumsi Energi Listrik Menggunakan Pendekatan Non-Intrusive Load Monitoring*. ITS Repository. [ITS Repository ps://repository.its.ac.id/111071/](https://repository.its.ac.id/111071/).
- [8] U.S. Energy Information Administration. (n.d.). *Annual Energy Review*. Retrieved from <https://www.eia.gov/>

- [9] Quinlan, J. R. (1996). Improved Use of Continuous Attributes in C4.5. *Journal of Artificial Intelligence Research*, 4, 77-90.
- [10] Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media.