

IMPLEMENTASI SHAP PADA CATBOOST UNTUK MENINGKATKAN AKURASI PREDIKSI TEMPERATUR UDARA DI KOTA PEKANBARU

Enggar Mumpuni¹, Harison²

enggar.mumpuni5569@student.unri.ac.id¹, harison@lecturer.unri.ac.id²

Universitas Riau

ABSTRAK

Temperatur udara merupakan parameter cuaca yang berpengaruh pada berbagai aspek kehidupan dan ekosistem. Penelitian ini bertujuan untuk meningkatkan akurasi prediksi temperatur udara menggunakan klasifikasi Categorical Boosting (CatBoost) dengan menggunakan implementasi Shapley Additive Explanation (SHAP). Data yang digunakan diperoleh dari Stasiun Cuaca Otomatis di Jurusan Teknik Elektro, Fakultas Teknik Universitas Riau pada bulan Oktober 2023. Hasil analisis menunjukkan bahwa implementasi Shapley Additive Explanation pada klasifikasi Categorical Boosting dapat meningkatkan akurasi prediksi. Sebelum penerapan Shapley Additive Explanation, akurasi prediksi temperatur udara mencapai 92.2%. Namun, setelah mengidentifikasi kontribusi variabel yang signifikan dengan menggunakan Shapley Additive Explanation, terjadi peningkatan akurasi prediksi sebesar 1.47%. Sehingga akurasi prediksi temperatur udara setelah dioptimalkan menjadi 93.67%. Shapley Additive Explanation memiliki dampak positif dalam meningkatkan akurasi prediksi temperatur udara. Implikasinya adalah peningkatan keandalan dalam memprediksi kondisi cuaca yang memiliki manfaat luas dalam berbagai bidang, seperti perencanaan kegiatan harian, pengelolaan lingkungan, dan pemahaman lebih mendalam tentang perubahan iklim.

Kata Kunci: Prediksi, Akurasi, Temperatur Udara, Catboost, SHAP.

ABSTRACT

Air temperature is a weather parameter that influences various aspects of life and ecosystems. This study aims to improve the accuracy of air temperature prediction using Categorical Boosting (CatBoost) classification with the implementation of Shapley Additive Explanation (SHAP). The data used were obtained from the Automatic Weather Station at the Department of Electrical Engineering, Faculty of Engineering, University of Riau in October 2023. The analysis results show that the implementation of Shapley Additive Explanation in Categorical Boosting classification can improve prediction accuracy. Before applying Shapley Additive Explanation, the accuracy of air temperature prediction reached 92.2%. However, after identifying the significant variable contributions using Shapley Additive Explanation, there was an increase in prediction accuracy by 1.47%. Thus, the optimized accuracy of air temperature prediction became 93.67%. Shapley Additive Explanation has a positive impact on improving the accuracy of air temperature prediction. The implication is an increase in reliability in predicting weather conditions, which has broad benefits in various fields such as daily activity planning, environmental management, and a deeper understanding of climate change.

Keywords: prediction, accuracy, air temperature, CatBoost, SHAP.

PENDAHULUAN

Temperatur udara merupakan elemen penting yang mampu memberikan dampak besar pada ekosistem makhluk hidup di Bumi. Badan Meteorologi, Klimatologi, dan Geofisika, (2023) menekankan bahwa suhu udara memegang peran utama dalam pembentukan kondisi cuaca dan diperlukan pemantauan yang akurat untuk merencanakan aktivitas sehari-hari. Perubahan suhu udara memiliki dampak yang lebih luas terhadap pola iklim, keberlanjutan ekosistem dan keseimbangan ekologi. Apabila suhu tinggi yang

disertai dengan kelembapan yang rendah dapat menciptakan kondisi terik yang berdampak luas pada lingkungan. Data yang dikumpulkan dari 91 stasiun oleh Badan Meteorologi, Klimatologi, dan Geofisika mengenai suhu normal di Indonesia pada tahun 1991- 2020 menunjukkan tren peningkatan, dengan suhu rata-rata mencapai 26.8°C dan meningkat menjadi 27.0°C pada tahun 2022. Suhu meningkat sebesar 0.3°C setiap tahunnya, termasuk suhu minimum, rata-rata dan maksimum. Oleh karena itu, diperlukan akurasi prediksi untuk mengevaluasi sejauh mana hasil prediksi pada suatu model dapat diandalkan.

Teknologi prediksi cuaca semakin hari semakin berkembang dan salah satu pendekatan terdepan yang mampu membantu memprediksi cuaca yaitu melalui pendekatan CatBoost. Algoritma CatBoost dikenal karena kemampuannya dalam menangani data kategorik dan mampu mengatasi noisy data serta mampu memberikan potensi untuk meningkatkan akurasi prediksi yang lebih efisien. CatBoost mencerminkan kemajuan teknologi dan berpotensi membawa manfaat signifikan dalam pemahaman dan pengelolaan lingkungan sehari-hari (Emanuele La Malfa et al., 2022). Meskipun peningkatan akurasi prediksi merupakan langkah yang positif, namun hal tersebut tidak cukup. Oleh karena itu, diperlukan pemahaman mendalam terhadap faktor-faktor yang berkontribusi terhadap hasil prediksi. Inilah alasan mengapa penerapan Shapley Additive Explanation (SHAP) menjadi sangat penting, dikarenakan memungkinkan analisis terhadap variabel yang paling berkontribusi dengan melibatkan perhitungan feature importance. Selain itu, SHAP juga memberikan informasi mengenai kontribusi variabel terhadap prediksi akhir.

Penelitian menggunakan metode SHAP maupun CatBoost telah banyak dilakukan. Bahndari et al., (2020) melakukan penelitian menggunakan SHAP untuk mengurangi fitur guna meningkatkan kinerja. Hasil penelitian menunjukkan bahwa penggunaan SHAP mampu menjaga akurasi prediksi dan dapat mengurangi waktu training. Penelitian lainnya juga dilakukan oleh Luo et al., (2021) untuk mengestimasi biomassa di atas permukaan tanah dengan menggabungkan metode seleksi fitur. Didapati bahwa CatBoost mampu meningkatkan akurasi estimasi penelitian dengan baik.

Berdasarkan beberapa penelitian terdahulu tersebut, maka akan dilakukan penelitian berupa penggabungan metode CatBoost dengan SHAP dalam klasifikasi temperatur udara dengan lokasi penelitian di Kota Pekanbaru. Pada penelitian ini diharapkan akan dicapai hasil berupa peningkatan akurasi prediksi pada temperatur cuaca.

TINJAUAN PUSTAKA

Penelitian ini memiliki beberapa tinjauan pustaka yang digunakan adalah sebagai berikut.

1. Temperatur Udara

Badan Meteorologi, Klimatologi, dan Geofisika, (2023) menjelaskan bahwa temperatur udara merupakan salah satu unsur utama dalam perkiraan cuaca yang dapat mengukur derajat panas atau dingin berdasarkan skala tertentu. Suhu dapat diukur menggunakan alat yang disebut termometer dan satuan yang digunakan yaitu derajat celsius. Temperatur udara dipengaruhi oleh berbagai faktor yaitu sinar matahari dan cuaca. Data suhu udara menunjukkan bahwa di Indonesia rata-rata suhu adalah 27°C pertahun. Pengukuran dilakukan secara terus menerus selama 24 jam setiap hari, hal tersebut dilakukan untuk menghitung suhu rata-rata harian, mingguan, dan tahunan (Purwantara, 2018). Badan Meteorologi, Klimatologi, dan Geofisika, (2023) mencatat bahwa suhu meningkat sebesar 0.3°C setiap tahunnya, termasuk suhu minimum, rata-rata dan maksimum. Suhu udara di kota Pekanbaru pada bulan oktober 2023 suhu normal berkisar

antara 23°C hingga 34°C. Kelembapan udara berada dalam kisaran 50 hingga 98 %. Sehingga suhu tidak normal berada dibawah 23°C dan diatas 34°C (Heru, 2023).

2. Klasifikasi

Klasifikasi merupakan suatu pendekatan untuk mengelompokkan objek atau konsep kedalam kategori tertentu berdasarkan sifatnya. Hal ini melibatkan penerapan model dan algoritma untuk mengidentifikasi dan menetapkan label atau kelas pada objek berdasarkan informasi yang ada (Gorunescu, 2016).

3. Categorical Boosting (CatBoost)

CatBoost merupakan implementasi peningkatan gradien yang menggunakan pohon keputusan biner sebagai prediktor dasar (Prokhorenkova et al., 2018). Menurut Liu et al., (2020) CatBoost merupakan esemble dari pohon keputusan simetris, dimana struktur simetrisnya memberikan parameter yang lebih sedikit, pelatihan dan pengujian yang lebih cepat serta akurasi yang lebih tinggi. CatBoost menggantikan metode estimasi gradien dari algoritma boosting gradien tradisional dengan ordered boosting, sehingga mengurangi bias estimasi gradien dan meningkatkan kemampuan generalisasi. Persamaan matematis CatBoost dijelaskan pada persamaan berikut.

$$h^{t+1} = \arg \min_h \frac{1}{n} \left(\frac{\partial Ly}{\partial F^t} - h \right)^2$$

4. SHapley Additive exPlanation (SHAP)

Shapley Additive Explanations (SHAP) merupakan metode yang digunakan untuk menjelaskan prediksi individu dengan menggunakan pendekatan game teori sehingga menghasilkan model machine learning yang dapat memperbaiki setiap fitur secara optimal. SHAP mampu menganalisis hasil output pada model berdasarkan jumlah dampak pada setiap fitur dan menghitung nilai yang mempresentasikan kontribusi setiap fitur terhadap hasil model. Penerapan metode ini sangat berguna untuk memahami bagaimana variabel dapat mempengaruhi prediksi model secara bersama- sama. Penjelasan nilai SHAP dijelaskan sebagai berikut (Deepak Gupta et al., 2023):

$$g(z) = \phi_0 + \sum_{j=1}^M \phi_j z_j$$

Dengan $g(z)$ merupakan nilai prediksi yang dihasilkan pada model, ϕ_0 merupakan nilai konstanta, dan M merupakan jumlah fitur atau elemen dalam vektor z

5. Evaluasi

Metode evaluasi merupakan hal yang penting dilakukan untuk mengevaluasi dengan melihat kinerja metode sehingga dapat diketahui seberapa baik metode yang digunakan dalam mengklasifikasi data. Salah satu cara yang dapat digunakan untuk mengukur kinaerja metode pada klasifikasi yaitu Confusion Matrix. Confusion matrix diperoleh dengan menghitung data hasil prediksi dan data kelas sebenarnya (Gorunescu, 2016). Pada perhitungan Confusion matrix terdapat empat kondisi kasus dengan TP sebagai true Positive, TN sebagai True Negative, FP sebagai False Positive, dan FN sebagai False Negative seperti pada Tabel 1 berikut.

Tabel 1. *Confusion Matrix*

<i>Confusin Matrix</i>	<i>Predicted Class</i>	
<i>Actual</i>	<i>True Positive (TP)</i>	<i>False Positive (FN)</i>
<i>Class</i>	<i>False Negative (FN)</i>	<i>True Negative (TN)</i>

Confusion matrix yang digunakan pada penelitian ini yakni accuracy, precision, recall, dan F1-score dengan persamaan sebagai berikut.

a. Accuracy

Accuracy (akurasi) merupakan suatu ukuran yang digunakan untuk mengevaluasi sejauh mana model klasifikasi mampu memprediksi dengan benar. Akurasi dihitung dengan membagi jumlah prediksi yang benar oleh model dengan total jumlah prediksi yang dilakukan. Persamaan akurasi sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

b. Precision

Precision (presisi) merupakan ukuran evaluasi dalam klasifikasi yang menilai akurasi model dalam memprediksi kasus positif. Presisi memberikan proporsi dari prediksi positif yang benar dari keseluruhan prediksi positif yang dibuat model. Persamaan sebagai berikut:

$$Precision = \frac{TP}{TP + FP}$$

c. Recall

Recall merupakan metrik evaluasi dalam klasifikasi yang mampu menilai model untuk mengidentifikasi kasus positif yang sebenarnya. recall dihitung sebagai rasio antara True Positive dengan jumlah keseluruhan kasus positif yaitu pada True Positive dan False Negative. Persamaan recall sebagai berikut:

$$Recall = \frac{TP}{TP + FN}$$

d. F-1 Score

F-1 score merupakan suatu ukuran evaluasi yang digunakan untuk mengevaluasi performa model pada klasifikasi biner berdasarkan kelas positif. F1-score menggabungkan nilai presisi dan recall dan sering diterapkan saat situasi ketidakseimbangan antara kelas positif dan negatif pada dataset. Persamaan F-1 score sebagai berikut:

$$F1 - Score = 2 \times \frac{Recall \times Precision}{Recall + Precision}$$

METODE PENELITIAN

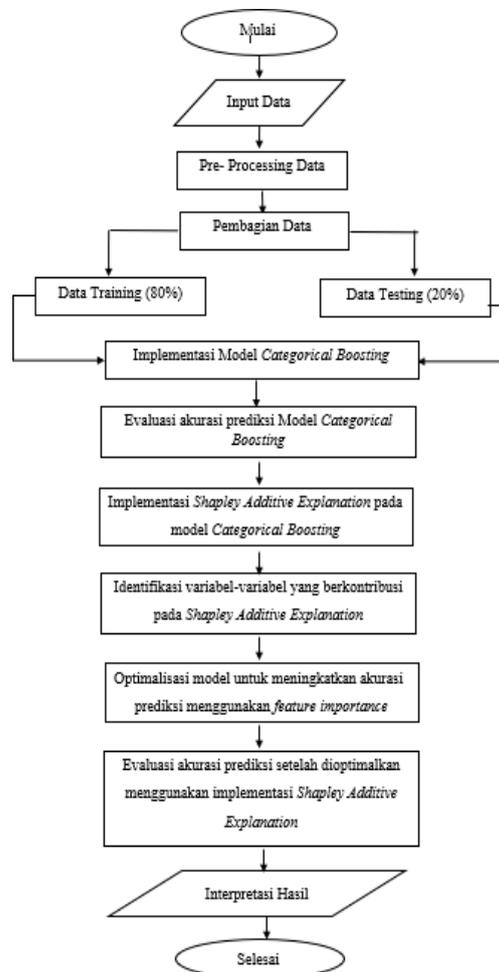
Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Stasiun Cuaca Otomatis di Jurusan Teknik Elektro, Fakultas Teknik Universitas Riau yang dikelola oleh Dr. Iswadi Hasyim Rosma, ST, MT, PhD, berupa data temperatur udara di Kota Pekanbaru yang diukur setiap lima menit pada bulan Oktober 2023 sebanyak 7629 data dengan variabel penelitian sebagaimana terlampir pada Tabel 2 berikut.

Tabel 2. Variabel Penelitian

Variabel	Nama Variabel
Y	<i>Outdoor Temperature</i>

Variabel	Nama Variabel
X ₁	<i>Feels Like</i>
X ₂	<i>Dew Point</i>
X ₃	<i>Wind Speed</i>
X ₄	<i>Wind Gust</i>
X ₅	<i>Max Daily Gust</i>
X ₆	<i>Wind Direction</i>
X ₇	<i>Weekly Rain</i>
X ₈	<i>Monthly Rain</i>
X ₉	<i>Humadity</i>
X ₁₀	<i>Ultra-Violet Radiation Index</i>
X ₁₁	<i>Solar Radiation</i>
X ₁₂	<i>Wind Chill</i>

Langkah-langkah yang dilakukan pada penelitian dijabarkan dalam diagram alir penelitian pada Gambar 1 berikut.



Gambar 1. Diagram Alir Penelitian

HASIL DAN PEMBAHASAN

Analisis Deskriptif

Analisis statistik deskriptif digunakan untuk melihat gambaran secara umum dan ukuran penyebaran serta pemusatan dari data mengenai data yang akan digunakan pada

penelitian ini. Pada tahap ini, analisis deskriptif dilakukan untuk menghitung jumlah frekuensi kategori penelitian yang dapat dilihat pada penjelasan berikut.

Tabel 3. Jumlah frekuensi kategori penelitian

Kelas	Jumlah	Per	(%)
0	6290	0.82449	82.40%
1	1339	0.17551	17.60%

Pada tabel 3 terlihat bahwa terdapat dua kelas atau kategori. Dua kelas tersebut yaitu 0 yang artinya kategori normal dan 1 kategori tidak normal. Jumlah frekuensi kategori pada baris pertama yaitu kelas 0 yang memiliki jumlah sebesar 6290, persentase yang dihasilkan yaitu 0.824486 atau 82.4%. Sedangkan dibaris kedua yaitu pada kelas 1 jumlah frekuensi yaitu sebesar 1339, persentase yang dihasilkan yaitu 0.175514 atau 17.6%. Secara umum, pada tabel 3 memberikan gambaran tentang perbandingan kategori yang dihasilkan, terlihat bahwa kelas 0 memiliki frekuensi lebih tinggi dibanding dengan kelas 1. Langkah selanjutnya yang digunakan untuk memahami data penelitian adalah analisis deskriptif yang dapat dilihat pada Tabel 4 berikut.

Tabel 4. Analisis deskriptif

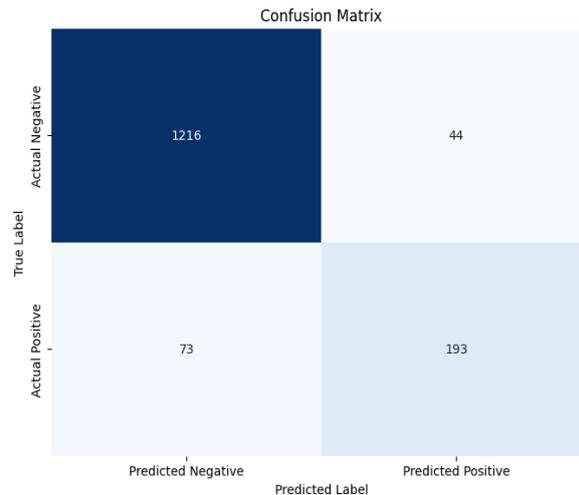
Variabel	Jumlah	Mean	Std	25%	50%	75%	Max	Min
X ₁	7629	33.3	8.47	26	31	41.8	56.8	23
X ₂	7629	26	1.68	25	26	27.3	31.1	22
X ₃	7629	0.38	0.68	0	0	0.5	6.2	0
X ₄	7629	0.74	1.12	0	0	1.1	8.9	0
X ₅	7629	5.38	3.6	3.3	5.5	6.7	14.5	0
X ₇	7629	10.8	14.2	0	5.3	18.3	56.1	0
X ₈	7629	63.3	70.3	0.3	27	150	173	0
X ₉	7629	90.6	10.8	82	98	99	99	59
X ₁₀	7629	1.11	1.74	0	0	2	10	0
X ₁₁	7629	95.5	144	0	0	168	648	0
X ₁₂	7629	27.8	3.59	25	27	31	36.8	23

Secara keseluruhan, hasil perhitungan statistika deskriptif dapat disimpulkan sebagai berikut:

1. Nilai rata-rata dari masing masing variabel adalah: X₁ = 33.3, X₂=25.9, X₃= 0.38, X₄= 0.74, X₅= 5.38, X₇= 10.84, X₈= 63.33, X₉= 90.6, X₁₀= 1.106, X₁₁=95.5 dan X₁₂= 27.81
2. Standar deviasi dari masing-masing variabel menunjukkan seberapa jauh data tersebar dari nilai rata-rata. Apabila semakin besar nilai standar deviasi, maka semakin besar pula variasi data dan begitu sebaliknya.
3. Nilai minimum dan nilai maksimum menunjukkan rentang nilai dari masing-masing variabel.
4. Kuartil dibagi menjadi 3 bagian yaitu kuartil 25%(Q1), kuartil 50% (Q2), dan kuartil 75% (Q3). Kuartil-kuartil ini memberikan gambaran distribusi data dan membantu mengidentifikasi sebaran nilai pada dataset.

Pelatihan Model Menggunakan *Categorical Boosting*

Dalam proses pelatihan model CatBoost, digunakan *RandommizedSearchCV* untuk mencari parameter secara acak dengan jumlah *cross-validation* sebanyak 5. Model analisis pada metode CatBoost divalidasi menggunakan *confusion matrix* dengan hasil pada Gambar 2 berikut.

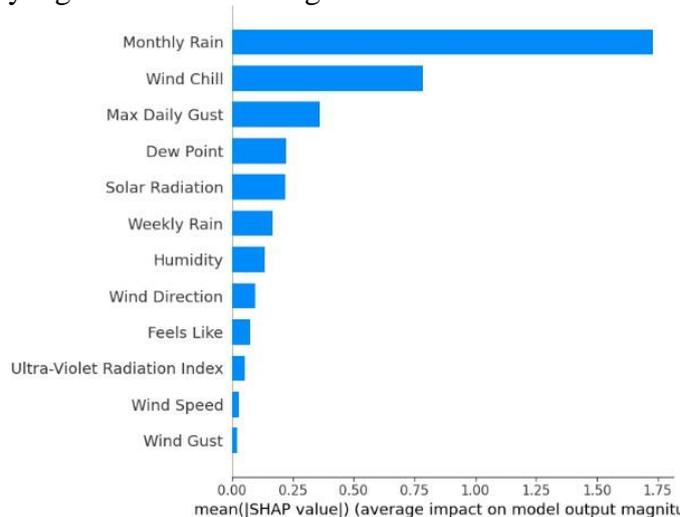


Gambar 2. *Confusion Matrix* Sebelum dioptimalkan

Dari hasil perhitungan, dapat dilihat bahwa nilai akurasi dari perhitungan confusion matrix dalam memprediksi akurasi temperatur udara yaitu sebesar 92.2%, dengan nilai presisi sebesar 81.4%, nilai *recall* sebesar 72.7% dan nilai *F-1 Score* sebesar 76.7%. Melalui hasil perhitungan tersebut dapat disimpulkan bahwa akurasi prediksi temperatur udara dengan model *categorical boosting* sudah sangat baik.

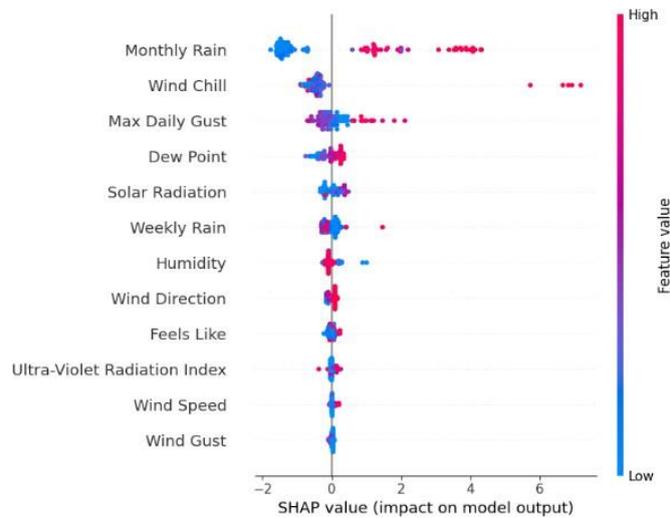
Implementasi *SHapley Additive exPlanation* pada Model *Categorical Boosting*

Implementasi *Shapley Additive Explanation* digunakan untuk mengetahui variabel yang berkontribusi dengan metode *Categorical Boosting*. Langkah yang dilakukan menentukan variabel yang berkontribusi dengan melihat Gambar 3.



Gambar 3. Visualisasi SHAP dengan *Boxplot*

Dari hasil output pada Gambar 3, dapat disimpulkan bahwa variabel *Monthly Rain*, *Wind Chill*, dan *Max Daily Gust* memiliki kontribusi yang signifikan terhadap metode *categorical boosting*. Ini menunjukkan bahwa perubahan dalam variabel *Monthly Rain* secara signifikan mempengaruhi prediksi yang dihasilkan oleh model dan memiliki korelasi yang kuat dengan target atau variabel lainnya. Sedangkan terdapat dua variabel yaitu *Wind Gust* dan *Daily Rain* yang tidak memberikan kontribusi terhadap prediksi model, hal ini ditunjukkan dengan nilai SHAP yang mendekati atau sama dengan 0.



Gambar 5. Visualisasi SHAP dengan *Beeswarm*

Dari hasil visualisasi SHAP pada Gambar 5 plot sumbu x merupakan nilai SHAP dimana semakin besar nilainya maka semakin besar peluang temperatur udara tersebut mencirikan keadaan normal. Sumbu y merupakan urutan variabel penting. Pada gambar 4.6, warna biru dan merah digunakan untuk membedakan dampak positif dan negatif dari fitur terhadap prediksi model. Gradasi warna biru menuju merah pada nilai variabel menunjukkan nilai yang bergerak dari rendah ke tinggi. Sehingga dapat disimpulkan tiga teratas yang menjadi variabel penting atau berkontribusi yaitu *Monthly Rain*, *Wind Chill*, dan *Max Daily*.

Feature Importance pada Penerapan SHAP

Feature Importance variabel penelitian ditampilkan pada Tabel 5 berikut.

Tabel 5. *Feature Importance*

Variabel	Nilai Feature Importance
<i>Monthly Rain</i>	1.72860035
<i>Wind Chill</i>	0.785917817
<i>Max Daily Gust</i>	0.359999185
<i>Dew Point</i>	0.221991671
<i>Solar Radiation</i>	0.220441479
<i>Weekly Rain:</i>	0.167378907
<i>Humidity</i>	0.136692855
<i>Wind Direction</i>	0.096383932
<i>Feels Like</i>	0.074725849
<i>Ultra-Violet Radiation Index</i>	0.053143419
<i>Wind Speed</i>	0.028089076
<i>Wind Gust</i>	0.023065903

Pada tabel 4.6 didapatkan hasil feature importance pada penerapan SHAP, sehingga hasil dari nilai feature importance pada masing-masing variabel sebesar:

1. *Monthly Rain* memiliki nilai *feature importance* pada penerapan SHAP sebesar 1.72860035, maka *Monthly Rain* memiliki kontribusi tertinggi dalam pengambilan keputusan model yang menunjukkan bahwa variabel ini memiliki pengaruh paling signifikan terhadap hasil prediksi.

2. *Wind Chill* memiliki nilai *feature importance* pada penerapan SHAP sebesar 0.785917817, maka *Wind Chill* memiliki nilai *feature importance* yang cukup tinggi, menunjukkan bahwa variabel ini memiliki kontribusi yang kuat terhadap prediksi.
3. *Max Daily Gust* nilai *feature importance* pada penerapan SHAP sebesar 0.359999185, maka *Max Daily Gust* juga memberikan kontribusi yang signifikan terhadap model.
4. *Dew Point* nilai *feature importance* pada penerapan SHAP sebesar 0.221991671, maka *Dew Point* memiliki pengaruh yang cukup signifikan terhadap hasil prediksi.
5. *Solar Radiation* nilai *feature importance* pada penerapan SHAP sebesar 0.220441479, maka *Solar Radiation* memberikan kontribusi yang sebanding dengan Dew Point terhadap model.
6. *Weekly Rain* nilai *feature importance* pada penerapan SHAP sebesar 0.167378907, maka *Weekly Rain* memiliki nilai *Feature Importance* yang menengah, menunjukkan pengaruh yang cukup terhadap keputusan model.
7. *Humidity* nilai *feature importance* pada penerapan SHAP sebesar 0.136692855, maka *Humidity* memiliki pengaruh yang cukup signifikan terhadap prediksi.
8. *Wind Direction* nilai *feature importance* pada penerapan SHAP sebesar 0.096383932, maka *Wind Direction* memberikan kontribusi yang lebih rendah dibandingkan dengan beberapa variabel lainnya, tetapi tetap memberikan pengaruh terhadap model.
9. *Feels Like* nilai *feature importance* pada penerapan SHAP sebesar 0.074725849, maka *Feels Like* memiliki kontribusi yang cukup rendah, tetapi masih memberikan kontribusi terhadap hasil prediksi.
10. *Ultra-Violet Radiation Index* nilai *feature importance* pada penerapan SHAP sebesar 0.053143419, maka Variabel ini memberikan kontribusi yang relatif rendah terhadap keputusan model.
11. *Wind Speed* nilai *feature importance* pada penerapan SHAP sebesar 0.028089076, maka *Wind Speed* memberikan kontribusi yang lebih rendah dibandingkan dengan sebagian besar variabel lainnya.
12. *Wind Gust* nilai *feature importance* pada penerapan SHAP sebesar 0.023065903, maka *Wind Gust* memiliki nilai *Feature Importance* yang paling rendah di antara variabel-variabel lainnya.

Optimalisasi Model Berdasarkan Analisis *Feature Importance*



Gambar 6. *Confusion matrix* setelah dioptimalkan

Dari hasil perhitungan yang telah dioptimalkan pada Gambar 6, dapat dilihat bahwa nilai akurasi dari perhitungan *confusion matrix* setelah dilakukan peningkatan akurasi yaitu sebesar 3.67%, dengan nilai presisi sebesar 85.54%, nilai *recall* sebesar 75.12% dan nilai *F-1 Score* sebesar 79.99%.

Evaluasi Hasil Penelitian

Adapun hasil dari penelitian metode *Categorical Boosting* (CatBoost) dengan implementasi *Shapley Additive Explanation* (SHAP) berupa evaluasi perbandingan performa model sebelum dan sesudah dioptimalkan menggunakan *confusion matrix* dijabarkan pada Tabel 6 berikut.

Tabel 6. Evaluasi hasil penelitian

Keterangan	Sebelum dioptimalkan	Setelah dioptimalkan
Akurasi	92.20%	93.67%
Presisi	81.40%	85.54%
Recall	72.50%	75.12%
F-1 Score	76.70%	79.99%

KESIMPULAN

Berdasarkan implementasi Shapley Additive Explanation menggunakan Categorical Boosting untuk meningkatkan akurasi prediksi, dapat disimpulkan bahwa sebelum dilakukan optimalisasi dengan implementasi SHAP dan feature importance, akurasi prediksi sebesar 92.2% dengan nilai presisi 81.4%, recall 72.7%, dan F-1 Score 76.7%. Setelah dilakukan optimalisasi, terjadi peningkatan signifikan dalam kinerja model, di mana akurasi meningkat menjadi 93.67%, dengan nilai presisi 85.54%, recall 75.12%, dan F-1 Score 79.99%. Hal ini menunjukkan bahwa optimalisasi model dengan menggunakan SHAP dan feature importance berhasil meningkatkan kinerja model dalam memprediksi temperatur udara, dengan peningkatan akurasi sebesar 1.47%. Oleh karena itu, penggunaan metode tersebut memberikan kontribusi yang signifikan dalam meningkatkan kualitas akurasi prediksi temperatur udara.

DAFTAR PUSTAKA

Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). 2023. "Informasi parameter iklim". Diakses pada tanggal : 2 Januari 2024. Source: <https://www.bmkg.go.id/iklim/?p=ekstrem-perubahan-iklim>.

- Bhandari, Shilpa et al. 2020. "feature selection improves tree-based classification for wireless intrusion detection." SNTA 2020 - Proceedings of the 3rd International Workshop on Systems and Network Telemetry and Analytics: 19–26.
- Deepak Gupta (Ph.D.), M. Shamim Hossain, Utku Kose, ed. 2023. "Explainable machine learning for multimedia based healthcare applications". Germany: Springer.
- Emanuele La Malfa, Gabriele La Malfa, Giorgio Jansen, Giovanni Giuffrida, Giuseppe Nicosia, Panos M. Pardalos, Renato Umeton, Varun Ojha, ed. 2022. "Machine learning optimization and data science :7th international". Switzerland: Springer International Publishing.
- Gorunescu, Florin. 2016. " Revista brasileira de linguística aplicada data mining concepts, models and techniques".
- Liu, Weirong et al. 2020. "A semi-supervised tri-catboost method for driving style recognition." Symmetry 12(3): 1–18.
- Luo, Mi et al. 2021. "Combination of feature selection and catboost for prediction: the first application to the estimation of aboveground biomass." Forests 12(2): 1–22.
- Prokhorenkova, Liudmila et al. 2018. "Catboost: unbiased boosting with categorical features." Advances in Neural Information Processing Systems 2018-Decem(Section 4): 6638–48.
- Purwantara, Suhadi. 2018. "Studi temperatur udara terkini di wilayah di jawa tengah dan diy." Geomedia: Majalah Ilmiah dan Informasi Kegeografian 13(1): 41–52.