

**ANALISIS PERFORMA MODEL LIGHTGBM DALAM PREDIKSI  
INTENSITAS HUJAN WILAYAH STASIUN METEOROLOGI KELAS 1  
KUALANAMU**

***PERFORMANCE ANALYSIS OF LIGHTGBM MODEL IN  
PREDICTING RAIN INTENSITY IN THE KUALANAMU CLASS 1  
METEOROLOGICAL STATION AREA***

**Didik Kurniawan<sup>1\*</sup>, Farhan Oktaviansyah Hidayat<sup>1</sup>, Agung Hari Saputra<sup>1</sup>**

<sup>1</sup>Program Studi Meteorologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Indonesia

\*Corresponding author's email: [farhanoktaviansyah@gmail.com](mailto:farhanoktaviansyah@gmail.com)

**ABSTRACT**

*The intensity of rain or rainfall that occurs is influenced by various weather parameters and it plays a big role for the community. Therefore, information related to rain intensity is very important, there is a need for the availability of information related to this. This study aims to analyze the performance of Machine Learning using the Light Gradient Boosting Machine model in predicting the intensity of rainfall in the Kualanamu Meteorological Station area during the 2018-2022 time span. Historical data collection is done through synoptic data collection that has been issued by Kualanamu class 1 Meteorological Station. Several matrix evaluations are used in the form of Accuracy, AUC (Area Under the Curve), Recall, Precision, and F1 Score. The matrix evaluation is able to produce detailed evaluation calculations and is able to measure how well the model works. Then the average value of the matrix evaluation is 0.7251 for accuracy, 0.8122 for AUC, 0.7251 for Recall, 0.7236 for Precision and 0.7231 for F1 Score. Based on the results obtained, the Light Gradient Boosting Machine model is able to provide good rain intensity prediction results but there is a need for further analysis in the model development stage, focusing on reducing the error rate and increasing prediction accuracy so as to make a significant contribution to the planning and decision-making process related to weather conditions.*

**Keywords:** *Light Gradient Boosting Machine, Rainfall Intensity, Weather Analysis, Machine Learning*

**ABSTRAK**

*Intensitas hujan ataupun curah hujan yang terjadi dipengaruhi oleh berbagai parameter cuaca dan hal tersebut sangatlah berperan besar untuk masyarakat. Oleh karena itu informasi terkait intensitas hujan sangatlah penting, perlu adanya ketersediaan informasi terkait hal tersebut. Kajian ini bertujuan untuk menganalisis performa Machine Learning dengan menggunakan model Light Gradient Boosting Machine dalam memprediksi intensitas curah hujan wilayah Stasiun Meteorologi Kualanamu selama rentang waktu 2018-2022. Pengumpulan data historis dilakukan melalui pengambilan data sinoptik yang sudah dikeluarkan oleh Stasiun Meteorologi kelas 1 Kualanamu. Digunakan beberapa evaluasi matriks yang berupa Accuracy, AUC (Area Under the Curve), Recall, Precision, dan F1 Score. Evaluasi matriks tersebut mampu menghasilkan perhitungan evaluasi yang detail dan mampu mengukur seberapa baik model bekerja. Kemudian didapatkan nilai rata-rata dari evaluasi matriks sebesar 0.7251 untuk akurasi, 0.8122 untuk AUC, 0.7251 untuk Recall, 0.7236 untuk Precision dan sebesar 0.7231 untuk F1 Score. Berdasarkan hasil yang telah didapat, bahwa model Light Gradient Boosting Machine mampu memberikan hasil prediksi intensitas hujan yang baik namun perlu adanya analisis lebih lanjut dalam tahap pengembangan model, dengan fokus pada pengurangan tingkat kesalahan dan peningkatan akurasi prediksi sehingga memberikan kontribusi yang signifikan dalam proses perencanaan dan pengambilan keputusan terkait kondisi cuaca.*

**Kata kunci:** *Light Gradient Boosting Machine, Intensitas Hujan, Machine Learning*

## PENDAHULUAN

Cuaca merupakan salah satu parameter yang dipertimbangkan oleh beberapa sektor untuk melakukan suatu kegiatan, salah satunya yaitu sektor pertanian yang sangat bergantung kepada keadaan cuaca [1]. Cuaca yang merupakan kombinasi dari beberapa komponen penyusun berupa tekanan, suhu, jumlah volume air yang terkandung pada awan, kecepatan angin dan arah mata angin, tekanan udara, kelembaban udara, dan lain-lain dapat menghasilkan berbagai jenis cuaca salah satunya yaitu hujan. Hujan yang terjadi di bumi memiliki intensitas yang berbeda-beda, intensitas hujan sendiri dapat dilihat sebagai jumlah curah hujan dalam satu satuan waktu [2].

Data intensitas hujan merupakan suatu produk yang diperoleh berdasarkan jumlah curah hujan yang terjadi. Data curah hujan yang didapat akan digolongkan menjadi beberapa kategori yang mengklasifikasikan intensitas curah hujan [3]. Intensitas hujan ataupun curah hujan yang terjadi dipengaruhi oleh berbagai parameter cuaca. Karena pentingnya informasi mengenai intensitas hujan, perlu ketersediaan informasi yang bisa menjelaskan fenomena variasi intensitas dari hujan yang terjadi yang kemudian data dari prediksi tersebut bisa digunakan untuk melakukan suatu Langkah preventif [4]. Prediksi tersebut harus dilakukan dengan model yang mampu menghasilkan hasil yang akurat, solusi dari permasalahan tersebut adalah menggunakan model Machine Learning (AI) [5].

Salah satu cara untuk bisa dilakukan analisis adalah dengan menggunakan data historis dari beberapa tahun kebelakang yang dikomputasi oleh machine learning [6]. Dengan adanya data historis mengenai keadaan cuaca yang terjadi di masa lampau, data tersebut dapat dipakai untuk menentukan cuaca yang akan terjadi di waktu yang akan datang [7]. Penelitian terkait prediksi curah hujan sudah banyak dilakukan menggunakan berbagai model salah satunya yaitu model Machine learning [8].

Di dalam perkembangan keilmuan modern, dikembangkan suatu model yang dinamakan Machine Learning, model ini diciptakan oleh para ilmuwan dengan algoritma berpikir seperti manusia yang mampu belajar dari lingkungan-nya [9]. Kemampuan algoritma Machine Learning untuk belajar dari data data yang diberikan memungkinkan untuk model ini mampu mempelajari data tersebut dan menghasilkan sebuah prediksi yang akurat yang dapat digunakan untuk kegiatan analisis maupun forecasting [10].

Model *Light Gradient Boosting Machine (LightGBM)* merupakan salah satu algoritma dari model *decision tree*, *LightGBM* memiliki high-performance dengan efisiensi pelatihan yang cepat memiliki tingkat akurasi tinggi serta memiliki kapasitas memori yang besar. *LightGBM* merupakan salah satu model yang menggunakan metode ensemble, yaitu ketika model melakukan agrerasi terhadap prediksi dari beberapa decisiontree. Model *LightGBM* memiliki beberapa algoritma seperti ID3, C,45, C,50, algoritma tersebut umum digunakan dalam klasifikasi dan *extraction rule*. Klasifikasi tersebut bekerja dengan mencari pola dari sekumpulan data atau fungsi yang dapat memisahkan data kelas yang satu dengan yang lain [12].

Stasiun kelas 1 Kualanamu sendiri merupakan stasiun pengamatan meteorologi yang berlokasi pada bandara udara Kualanamu. Bandara udadara kualanamu merupakan salah satu dari yang terbesar di Indonesia. Di setiap stasiun penerbangan, pengaruh dari intensitas hujan merupakan hal yang signifikan dalam keselamatan penerbangan [25]. Untuk itu perlu adanya informasi terbaru untuk menunjang kegiatan penerbangan di Bandara tersebut. Dengan adanya prediksi intensitas hujan, pihak bandara mampu memberikan antisipasi yang lebih matang terhadap perkembangan kondisi cuaca yang lalu, sekarang, dan yang akan datang. Penelitian serupa juga pernah dilakukan sebelumnya oleh beberapa peneliti, diantaranya yaitu prediksi curah Hujan di Kota Medan menggunakan Model Backpropagation Neural Network [13]. Dengan adanya penelitian tersebut, penelitian ini akan menggunakan pendekatan yang berbeda, dengan menggunakan salah satu model dari *Decision Tree* yaitu *LightGBM*. [14].

## METODE PENELITIAN

### 1. Lokasi Penelitian

Data pada penelitian ini didapatkan dari hasil pengamatan Stasiun Meteorologi Kualanamu Kelas 1, Deli Serdang Sumatera Utara. Stasiun Meteorologi Kuala Namu memiliki koordinat geografis  $03^{\circ}38'25''$  LU dan  $098^{\circ}52'43''$  BT dan memiliki ketinggian 7 meter diatas permukaan laut. Stasiun ini berlokasi pada Bandara Udara Internasional Kualanamu, stasiun kualanamu menyediakan data-data pengamatan cuaca yang diperlukan oleh bandara dan juga tersedia untuk public [24].

### 2. Teknik Pengolahan Data

Data yang digunakan dalam penelitian ini menggunakan data historis yang didapat dari pengamatan Stasiun Meteorologi Kelas 1 Kualanamu. Data diunduh melalui laman penyedia data observasi synop yang bernama ogimet. Data yang digunakan memiliki rentang waktu dari tahun 2018 sampai 2022 yang berisi data *diurnal* yang diakumulasikan menjadi satu hari. Digunakan 12 parameter seperti pada table 1 yang akan menentukan intensitas hujan yang terjadi seperti yang ditunjukkan pada table 2.

Tabel 1 Variabel Datasetset Cuaca yang Digunakan

No	Parameter Cuaca	Deskripsi
1	Tmax	Suhu Maksimum
2	Tmin	Suhu Minimum
3	Tavg	Suhu Rata Rata
4	Vis	Visibilitas
5	Td	Titik Embun
6	Rh	Kelembapan Relatif
7	WindDir	Arah Angin
8	WindSpd	Kecepatan Angin
9	Pres	Tekanan
10	TotCLOct	Jumlah Awan
11	LowCLOc	Awan Rendah
12	SunD1	Lama Penyinaran

Tabel 2 Target Prediksi

No	Kategori Target	Deskripsi
1	0	Tidak Hujan
2	1	Hujan
3	2	Hujan Lebat

Data yang telah diunduh kemudian akan melalui beberapa tahap pengolahan sebelum di simulasikan dengan model. Data akan diolah atas beberapa tahap pemrosesan untuk mendapatkan data yang sesuai, beberapa tahapannya yaitu *filtering* data, *Collecting Data* dan *Feature Engineering*.

Pada tahap *filtering* data, data diolah untuk menghilangkan dan memilih parameter data yang diperlukan saja dan menghilangkan data yang rusak atau hilang serta yang tidak dapat dijelaskan. Selanjutnya data yang sudah di *Filter* setiap tahun-nya kemudian digabungkan dalam satu file. Yang terakhir data diolah untuk mendapatkan rata-rata data harian selama 5 tahun. Kemudian digunakan Teknik *fitur engineering* untuk kemudian dibagi menjadi 2 set yaitu set pelatihan dan pengujian, set pelatihan bertujuan melatih model dan set pengujian untuk menguji model. Pada penelitian ini menggunakan *train\_size* = 0.9 yaitu rasio pelatihan dan pengujian 90:10. Kemudian dijalankan agar terlihat apakah model sudah berjalan dengan baik [14].

Sebelum data dimasukkan ke dalam model, perlu dilakukan konfigurasi model untuk mengatur *hyperparameter* yang akan digunakan. *Hyperparameter* tersebut akan dimodifikasi apabila hasil prediksi yang dihasilkan kurang baik berdasarkan nilai errornya terhadap data

target prediksi curah hujan pada table 1. Nilai hyperparameter yang digunakan ditunjukkan pada Tabel 3.

Tabel 3 Keterangan Hyperparameter yang digunakan oleh model

Deskripsi	Nilai
<i>Original data shape</i>	<i>(1826, 13)</i>
<i>Transformed data shape</i>	<i>(2769, 13)</i>
<i>Transformed train set shape</i>	<i>(2586, 13)</i>
<i>Transformed test set shape</i>	<i>(183, 13)</i>
<i>Numeric features</i>	<i>11</i>
<i>Categorical features</i>	<i>1</i>
<i>Rows with missing values</i>	<i>1.9%</i>
<i>Preprocess</i>	<i>True</i>
<i>Imputation type</i>	<i>Simple</i>
<i>Numeric imputation</i>	<i>mean</i>
<i>Categorical imputation</i>	<i>mode</i>
<i>Maximum one-hot encoding</i>	<i>25</i>
<i>Encoding method</i>	<i>None</i>
<i>Fix imbalance</i>	<i>True</i>
<i>Fix imbalance method</i>	<i>SMOTE</i>
<i>Normalize</i>	<i>True</i>
<i>Normalize method</i>	<i>zscore</i>
<i>Fold Generator</i>	<i>StratifiedKfold</i>
<i>Fold Number</i>	<i>10</i>

### 3. Teknik Analisis data

Data dievaluasi untuk mengetahui apakah model tersebut sudah baik atau belum. Data dievaluasi menggunakan beberapa tahap evaluasi matriks atau *confusion matrix*, biner klasifikasi diantaranya *Accuracy*, *AUC (Area Under the Curve)*, *Recall*, *Precision*, dan *F1 Score*. *Confusion matrix* mampu menghasilkan perhitungan evaluasi yang detail dan mampu mengukur seberapa baik model bekerja. Berikut ditampilkan rumus dari *Light Gradient Boosting Machine* [15].

Tabel 4 Confusion Matrix

Confusion matrix		Actual Class	
		Positive	Negative
Predicted class	Positive	(TP)	(FP)
	Negative	(FN)	(TN)

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \times 100\% \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

$$F1 \text{ score} = 2 \times \frac{(PRECISION \times RECALL)}{PRECISION+RECALL} \quad (4)$$

Keterangan:

- TP : True Positif (Data Positif yang diidentifikasi Positif)
- FP : False Positif (Data Negatif yang diidentifikasi Positif)
- FN : False Negatif (Data Positif yang diidentifikasi Negatif)
- TN : True Negatif (Data Negatif yang diidentifikasi Negatif)

#### 4. Alur Kerja

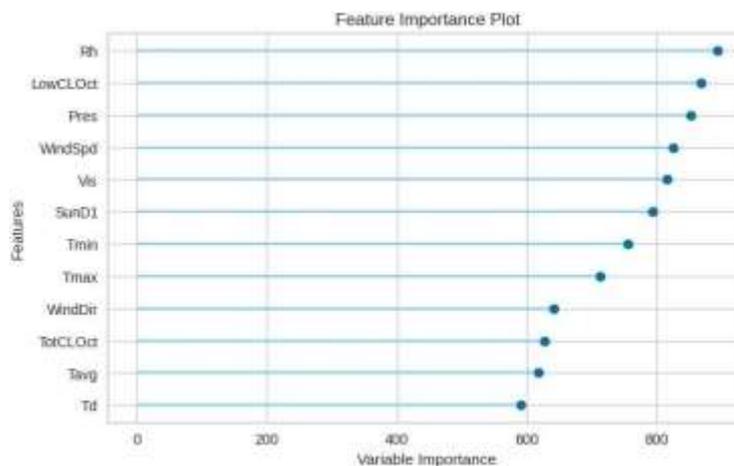


Gambar 1 Alur Kerja dari proses komputasi oleh model

Alur kerja pada gambar Proses pengolahan data dimulai dengan membuat dataset penelitian berupa 12 parameter yang diteliti seperti yang ditunjukkan pada tabel 1 dengan rentang waktu 5 tahun dari 2018 hingga 2022. Dataset yang telah terkumpul akan di- interpolasikan untuk mengisi data kosong dan membuat target berupa angka biner yang mewakili intensitas curah hujan. Pada proses tersebut melibatkan sebuah prosedur imputasi untuk mengisi nilai-nilai yang hilang dalam dataset. Kedua proses SimpelImputer tersebut merupakan proses untuk memanipulasi data agar terbentuk suatu dataset yang utuh, lengkap dan compatible. Skala standar digunakan untuk menormalkan/standarisasi fitur dengan menghilangkan mean dan scaling ke unit variance [23]. Dataset yang telah melalui berbagai tahap proses kemudian akan di-*input* ke dalam Pycaret pada model *Decision Tree* menggunakan algoritma *LightGBM*. Hasil dari prediksi LightGBM akan gunakan untuk melakukan evaluasi dan analisis terhadap akurasi model dalam memprediksi intensitas curah hujan.

## HASIL DAN PEMBAHASAN

### 1. Important Features



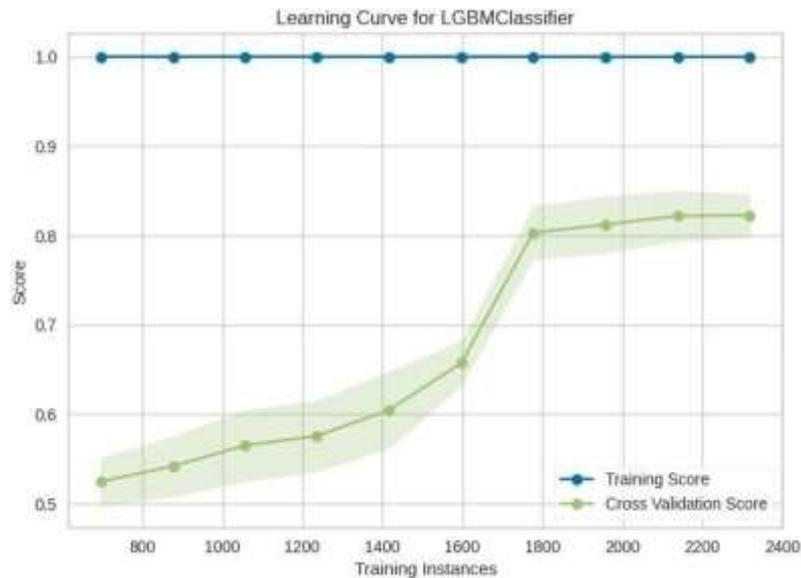
Gambar 2 Feature Important menunjukan parameter yang memiliki pengaruh paling besar terhadap hasil target

Gambar 2 merupakan grafik yang menunjukkan seberapa berpengaruhnya suatu parameter terhadap skor kepentingan variabel, digunakan dalam *machine learning* dan analisis data untuk menunjukkan sejauh mana berbagai variabel input berperan terhadap model prediktif, dengan adanya grafik tersebut, mampu memberi kegunaan dalam pengembangan model, mendalami pemahaman terhadap data, serta membuat keputusan terkait pengumpulan dan pengolahan data. Dalam grafik ini, fitur-fitur disusun di sepanjang sumbu y, sedangkan skor kepentingannya disajikan di sepanjang sumbu x. Berdasarkan hasil yang didapat, fitur yang paling berpengaruh dalam model ini adalah "LowCLOct" diikuti oleh "Tmax" yang

menunjukkan suhu maksimum.

Fitur lainnya mencakup "SunD1", yang terkait dengan durasi sinar matahari, "WindSpd" untuk kecepatan angin, "Vis" untuk visibilitas, dan "Tmin" untuk suhu minimum. Variabel seperti "TotCLOct", "Tavg", "Rh", "Pres", dan "WindDir" berada di tengah skala kepentingan, menandakan pengaruh sedang terhadap prediksi model, dan "Td" yang mewakili suhu titik embun memiliki tingkat kepentingan paling rendah di antara fitur-fitur yang terdaftar.

## 2. Learning curves



Gambar 3 Learning curve menunjukkan perkembangan model seiring waktu

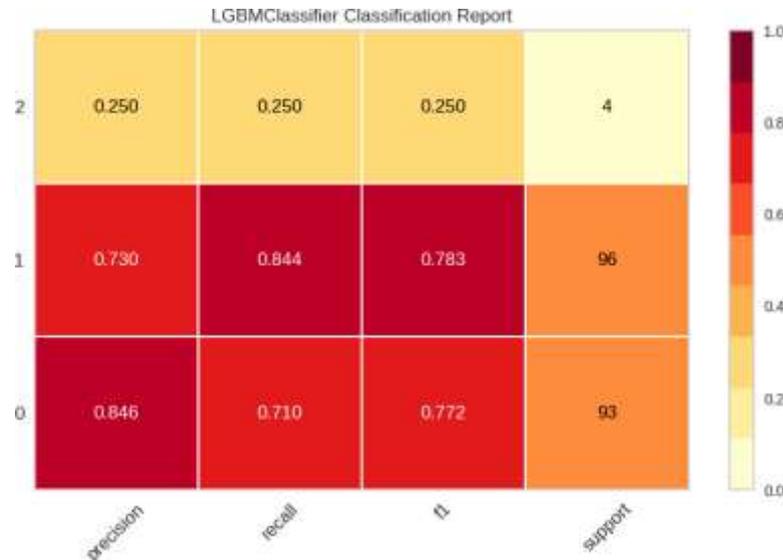
Gambar 3 merupakan grafik yang memperlihatkan kurva pembelajaran untuk model klasifikasi *Light Gradient Boosting Machine*. Grafik ini merupakan alat visual yang digunakan untuk memahami bagaimana performa suatu model belajar terhadap data seiring waktu, terutama dalam konteks proses pelatihan dengan jumlah sampel data yang bervariasi [16]. Dapat dilihat Pada sumbu vertikal atau sumbu y, terdapat parameter yang disebut "Skor" yang menunjukkan nilai performa dari sebuah model untuk dapat memprediksi atau mengklasifikasikan data. Skor ini bisa mencakup berbagai metrik, seperti akurasi atau nilai lain yang menggambarkan performa model. Pada sumbu horizontal atau sumbu x, terdapat parameter "Instansi Pelatihan" yang mencerminkan jumlah sampel data yang digunakan untuk melatih model pada titik waktu tertentu.

Dalam grafik tersebut, terdapat dua kurva yang dihasilkan oleh model yaitu *training score* dan *Cross Validation Score*. Pada *training score* ditunjukkan garis performa dari seberapa baik model dapat mempelajari dan mengingat data pelatihan. *training score* yang tinggi dan stabil di sekitar nilai 1 menandakan bahwa model mampu menyesuaikan diri dengan data pelatihan. Garis *Cross Validation Score* menunjukkan performa dari model pada data yang belum pernah dilihat sebelumnya. Skor validasi silang meningkat dari yang sebelumnya memiliki nilai rendah hingga memiliki kisaran skor  $> 0.8$ , peningkatan ini seiring dengan bertambahnya jumlah sampel pelatihan. Skor ini memberikan gambaran lebih baik tentang kemampuan model dalam menggeneralisasi ke data baru.

Area berbayang di sekitar garis skor validasi silang. Area tersebut dinamakan "interval kepercayaan" yang mengindikasikan variasi yang mungkin bisa terjadi dalam performa model ketika diuji pada set data yang berbeda. Peningkatan lebar interval kepercayaan dengan bertambahnya jumlah sampel pelatihan dapat menunjukkan peningkatan variabilitas dalam estimasi kinerja model. Berdasarkan analisis yang didapat menunjukkan bahwa terdapat kemungkinan bahwa model mengalami *overfitting*, yaitu keadaan keadaannya Dimana model terlalu

"menghafal" data pelatihan dan kurang mampu menggeneralisasi ke data yang belum pernah dilihat sebelumnya [17].

### 3. Class Report

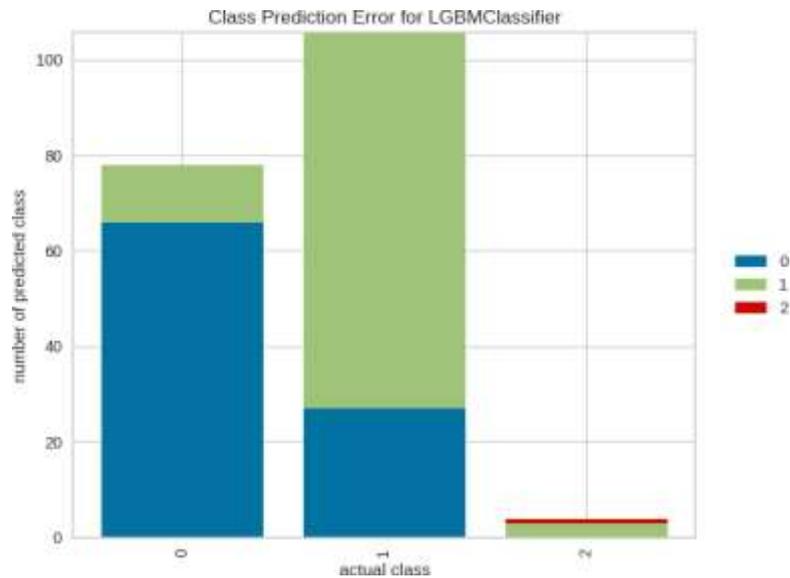


Gambar 4.0 Light Gradient Boosting Machine Classifier Report menunjukkan laporan klasifikasi untuk model Light Gradient Boosting Machine Classifier dalam format heat map

Gambar 3 menunjukkan laporan klasifikasi untuk model *Light Gradient Boosting Machine Classifier* dalam format *heat map*. Laporan ini memberikan informasi mendalam mengenai performa model untuk tiga kelas yang ditandai sebagai 0, 1, dan 2 pada sisi vertikal. Sementara itu, empat metrik evaluasi model, yaitu *Precision*, *Recall*, *F1-score* (disingkat sebagai *f1*), dan *Support*, ditampilkan pada sisi horizontal [18]. *Precision* (Presisi) mengukur seberapa akurat model dalam memprediksi kasus positif. Kelas 0 memiliki nilai *precision* tertinggi, yaitu 0.846. Ini menunjukkan bahwa ketika model memprediksi kelas 0, prediksinya benar sekitar 84.6% dari waktu. *Recall* (Recall) mengukur sejauh mana model dapat mengidentifikasi semua kasus positif dengan benar. Kelas 2 memiliki nilai *recall* tertinggi, yaitu 0.250. Ini menunjukkan bahwa model cenderung baik dalam mengidentifikasi kasus-kasus kelas 2, meskipun masih ada ruang untuk peningkatan.

*F1-score* merupakan nilai yang didapat dari rata-rata harmonik *precision* dan *recall*, memberikan gambaran seimbang antara kedua metrik tersebut. Kelas 1 memiliki skor tertinggi dengan nilai sebesar 0.783, hal tersebut menunjukkan bahwa terdapat keseimbangan yang baik antara *precision* dan *recall* untuk kelas tersebut. *Support* menggambarkan jumlah contoh aktual dari kelas yang bersangkutan dalam dataset. Sebagai contoh, terdapat 4 contoh dari kelas 2, yang merupakan jumlah paling sedikit dibandingkan dengan kelas lainnya. Kemudian warna pada *heat map* menunjukkan performa model dengan rentang dari kuning muda (nilai rendah) hingga merah tua (nilai tinggi). Warna yang lebih tua menunjukkan kinerja yang lebih baik dalam metrik tertentu.

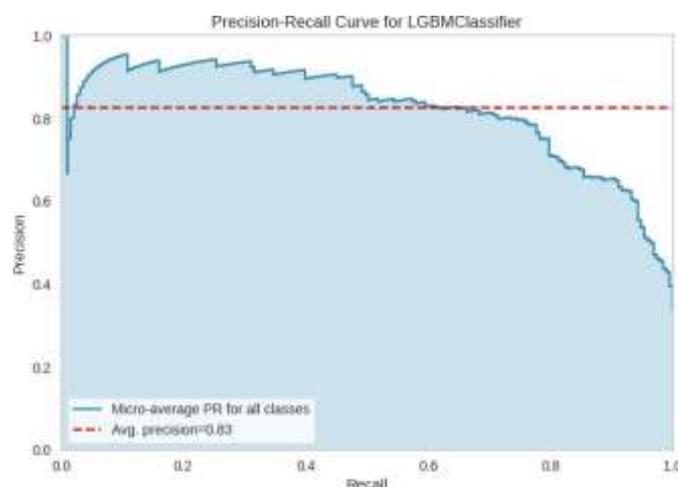
#### 4. Class Prediction Error



Gambar 5 Class Prediction Error untuk Light Gradient Boosting Machine

Diperlihatkan grafik diagram batang pada gambar 5 yang merupakan suatu rincian dari kesalahan prediksi kelas untuk model *Light Gradient Boosting Machine Classifier*. Diagram ini memberikan gambaran tentang sejauh mana setiap kelas pada model yang memiliki kinerja kurang akurat [19]. Pada sumbu x, bisa dilihat terdapat *actual class* yang mencerminkan kelas asli dari data. Pada sumbu y, terdapat *number of predicted class*, yaitu seberapa sering kesalahan prediksi terjadi untuk masing-masing kelas. Untuk *actual class 0*, bagian biru pada mewakili prediksi yang benar (TN), sedangkan bagian hijau mewakili bagian di mana model salah memprediksi kelas 1 (FP). Untuk *actual class 1* bagian hijau mewakili prediksi yang benar (TP). Pada *actual class 2* tidak terdapat warna biru atau merah yang berarti tidak ada bagian di mana kelas 1 diprediksi secara salah sebagai kelas 0 atau kelas 2 (tidak ada FN untuk kelas 1).

#### 5. Precision Recall Curve

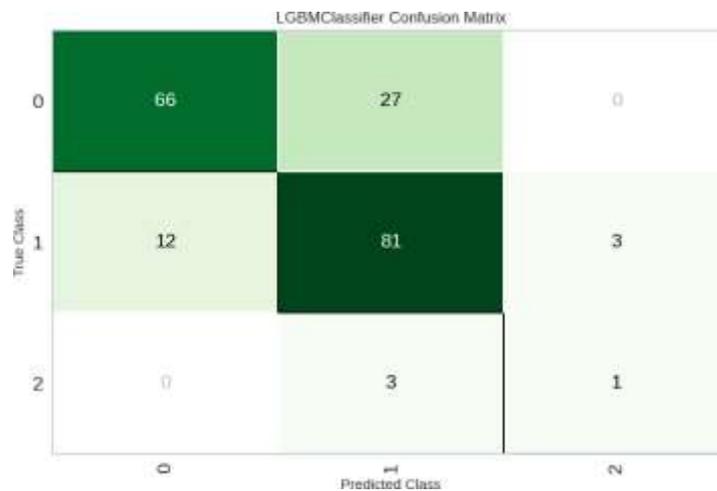


Gambar 6 Precision Recall Curve

Gambar 6 memperlihatkan kurva korelasi antara *precision* dan *recall* untuk model *Light Gradient Boosting Machine Classifier*. Kurva ini adalah alat evaluasi yang digunakan untuk menganalisis performa model klasifikasi dalam lingkungan *machine learning*. Khususnya, kurva ini berguna dalam situasi di mana kelas positif memiliki jumlah yang lebih sedikit atau memiliki

signifikansi yang lebih besar dibandingkan dengan kelas *negative*. Pada kurva ini, ditunjukkan bahwa sumbu y mewakili nilai *precision*, yang mengukur seberapa akurat model memprediksi hasil positif. Sementara itu, sumbu x mewakili nilai *recall*, yang mengukur kemampuan model untuk mengidentifikasi dengan benar proporsi hasil positif yang sebenarnya. Grafik tersebut ditampilkan suatu garis biru solid yang mewakili nilai dari *micro-average Precision-Recall* (PR) untuk semua kelas. *Mikro-average* dihitung sebagai rata-rata *precision* dan *recall* dengan mempertimbangkan frekuensi setiap kelas sebagai bobot. Adanya beberapa titik pemotongan pada kurva, yang bukan merupakan kejadian umum dalam kurva *Precision-Recall*, mungkin mengindikasikan adanya perhitungan pada dataset dengan distribusi kelas yang tidak seimbang atau pada model yang membuat keputusan dengan *threshold* yang sangat spesifik. Garis putus merah menunjukkan nilai *precision* rata-rata ( $Avg. precision = 0.83$ ) untuk model tersebut. Nilai ini mencerminkan bahwa secara keseluruhan, model memiliki kemungkinan sekitar 83% untuk memprediksi kelas positif dengan benar.

## 6. Confusion matrix

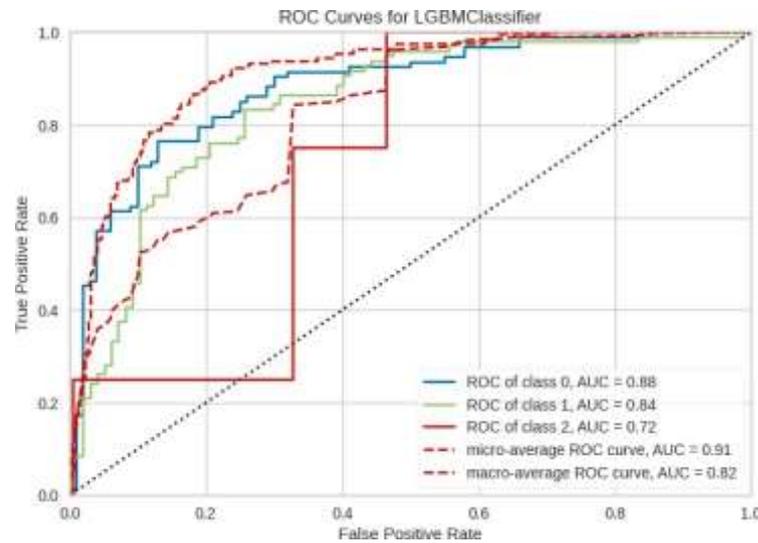


Gambar 7 Confusion matrix

Pada gambar 7 disajikan matriks untuk mengevaluasi kinerja model *Light Gradient Boosting Machine Classifier* dengan menggunakan klasifikasi pada dataset dengan nilai sebenarnya yang sudah diketahui. Pembagian Matriks terbagi menjadi empat kuadran, dengan *True Class* berada di sumbu y, dan *Predicted Class* di sumbu x. setiap kelas akan dianalisis kualitas prediksinya. Analisis Kelas 0 berhasil terprediksi sebanyak 66 kali dengan benar. Terdapat 27 kesalahan di mana model memprediksi instansi dari kelas lain sebagai kelas 0. Sebanyak 0 instansi yang sebenarnya berasal dari kelas 0 namun diprediksi sebagai kelas 2. Analisis Kelas 1 berhasil terprediksi dengan benar sebanyak 81 kali. Terdapat 1 kesalahan di mana instansi dari kelas 0 dan 3 instansi dari kelas 2 diprediksi sebagai kelas 1. Analisis Kelas 2 menunjukkan performa yang baik dengan 1 prediksi yang benar, 0 kesalahan di mana instansi dari kelas 0 dan

3 instansi dari kelas 1 diprediksi sebagai kelas 2. Warna yang ditunjukkan pada Matriks merupakan suatu penanda dari jumlah intensitas keberhasilan model dalam melakukan prediksi. Warna yang lebih gelap menandakan jumlah yang lebih besar, khususnya terlihat pada kelas 2 dengan 1 prediksi yang benar, menjadi hasil terbaik dibandingkan dengan kelas lainnya. Matriks ini memberikan gambaran yang mendalam tentang jenis kesalahan yang dibuat oleh model, seperti kecenderungan salah dalam memprediksi kelas 0 sebagai kelas 2.

## 7. Kurva ROC



Gambar 8.0 Kurva ROC

Visual yang ditampilkan merupakan kurva *Receiver Operating Characteristic* (ROC) untuk model *Light Gradient Boosting Machine Classifier* yang memiliki tiga kelas. Kurva ROC, biasanya digunakan untuk mengevaluasi model klasifikasi biner [20], telah diperluas dalam konteks ini untuk menangani klasifikasi *multiclass*. Setiap kelas memiliki kurva ROC sendiri, ditunjukkan dengan garis biru, hijau, dan merah. Dimana ketiga warna tersebut mewakili kelas 0, 1 dan 2 [21][22]. Untuk setiap kelas diperoleh hasil untuk setiap kelasnya yang menggambarkan keakuratan dari masing-masing kelas dimana nilai kelas 0 sebesar 0.88, kelas 1 menghasilkan nilai sebesar 0.84, dan kelas 2 tingkat keakuratan yang lebih rendah dibandingkan dengan kelas lain sebesar 0.72. Selain kurva dari *actual class* terdapat kurva lain yaitu kurva *micro-average* dan kurva *macro-average*. Kurva *micro-average* merepresentasikan rata-rata dari *True Positive Rate* (*Recall*) dan *False Positive Rate* (*FPR*) dari semua kelas. Kurva ini diwakili oleh garis hitam putus-putus dan memiliki AUC sebesar 0.91. Sedangkan kurva *Macro-average* yang diwakili oleh garis merah putus-putus memberikan rata-rata AUC dari semua kelas tanpa mempertimbangkan distribusi kelas, dengan nilai AUC sebesar 0.82. Nilai AUC yang dihasilkan memiliki Tingkat performa tersendiri. Dimana jika nilai AUC mendekati 1 menandakan performa yang baik, sedangkan nilai mendekati 0.5 menunjukkan performa setara dengan kebetulan. Hasil evaluasi AUC menunjukkan bahwa kelas 0 memiliki performa terbaik, diikuti oleh kelas 2, dan kelas 1 yang memiliki performa paling rendah.

## 8. Model Performance

Pada table 5 hasil *confusion matrix* dari Model *Light Gradient Boosting Machine Classifier* ditampilkan. Dari hasil yang dihasilkan, kita bisa melihat bahwa model ini memiliki akurasi rata-rata sekitar 0.7251, yang berarti model ini secara akurat memprediksi kelas yang benar sekitar 72.51%. Rata-rata AUC sebesar 0.8122, menunjukkan kemampuan yang baik dalam membedakan antara kelas. Nilai F1 0.7231 menunjukkan keseimbangan yang baik antara *presisi* dan *recall*.

Tabel 5 Tabel Performa Model

Parameter Evaluasi	Mean	Max
Akurasi	0.7251	0.763
AUC	0.8122	0.8343
Recall	0.7251	0.7630
Prec.	0.7236	0.7584
F1	0.7231	0.7580

## KESIMPULAN

Model LightGBM digunakan dalam melakukan prediksi intensitas curah hujan dengan memanfaatkan data pengamatan stasiun dari tahun 2018 sampai tahun 2022. Hasil menunjukkan bahwa, performa model dengan nilai akurasi sebesar 0.7251, nilai *auc* sebesar 0.8122 nilai *recall* sebesar 0.7251, nilai *precision* sebesar 0.7236 dan nilai *F1 Score* sebesar 0.7231. dengan hasil tersebut, menunjukkan bahwa performa model sudah baik, namun penggunaan model *LightGBM* untuk melakukan prediksi dengan dataset intensitas curah hujan diperlukan peningkatan, salah satu langkah yang dapat membantu meningkatkan kemampuan model adalah dengan menambahkan lebih banyak data pelatihan, peningkatan melalui fitur tambahan, teknik pemrosesan data yang lebih canggih, atau penerapan algoritma pembelajaran mesin alternatif. Memeriksa keseimbangan distribusi kelas target juga penting untuk memastikan bahwa performa model tidak terganggu oleh ketidakseimbangan dataset.

## DAFTAR PUSTAKA

- [1] Saragih, Immanuel. (2020). Identifikasi Pola Diurnal Curah Hujan di Sumatera Utara (Studi Kasus Tahun 2019).
- [2] Ali, Zakia Intan, Indah Manfaati Nur, and Fatkhurrokhman Fauzi. "Artificial Neural Network Untuk Memprediksi Curah Hujan di Kota Padang Dengan Model Backpropagation dan Adaline." (2020): 1-7.
- [3] Laserio, Soni Darma. "Analisis Data Parameter Hujan Menggunakan Fitur Guide pada Matlab Berdasarkan Hasil Pengukuran Instrumen Optical Rain Gauge di Loka Pengamatan Atmosfer Kototabang Lapan." *PILLAR OF PHYSICS* 3.1 (2014).
- [4] Harlina, Sitti, and Usman Usman. "Analisa Prediktif Curah Hujan Data Time Series Berbasis Model Neural Network." *Inspiration: Jurnal Teknologi Informasi dan Komunikasi* 10.2 (2020): 163- 176.
- [5] Dwiratna, N. P. S., G. Nawawi, and C. Asdak. "Analisis Curah Hujan dan Aplikasinya dalam Penetapan Jadwal dan Pola Tanam Pertanian Lahan Kering di Kabupaten Bandung." *Bionatura* 15.1 (2013).
- [6] Pertiwi, Dwika Ananda Agustina, Tanzilal Mustaqim, and Much Aziz Muslim. "Prediksi Rating Aplikasi Playstore Menggunakan Xgboost." *Proceedings of SNIK* (2020): 108-112.
- [7] Harun, Rofiq, Kartika Chandra Pelangi, and Yuliyanti Lasena. "Penerapan Data Mining untuk Menentukan Potensi Hujan Harian dengan Menggunakan Algoritma K Nearest Neighbor (KNN)." *Jurnal Manajemen Informatika dan Sistem Informasi* 3.1 (2020): 8-15. Book
- [8] Intan, Indo, et al. "Performance Analysis of Weather Forecasting using Machine Learning Algorithms (Analisis Performansi Prakiraan Cuaca Menggunakan Algoritma Machine Learning)." *Pekommas* 6.2 (2021): 1-8.
- [9] XGBoost Simply Explained (With an Example in Python) (springboard.com)
- [10] Id, Ibnu Daqiqil. *Machine Learning: Teori, Studi Kasus dan Implementasi Menggunakan Python*. Vol. 1. Unri Press, 2021.
- [11] Chen, Tianqi, et al. "Xgboost: extreme gradient boosting." *R package version 0.4-2 1.4* (2015): 1-4.
- [12] Fauzi, A., & M.S, A. (2020). Klasifikasi Kabupaten Kota Provinsi Jawa Barat Berdasarkan Pendapatan Dari Sektor Pertanian Dengan Algoritma Decision Tree. *Faktor Exacta*, 13(1), 1–8. <https://doi.org/10.30998/faktorexacta.v13i1.5542>
- [13] Andrian, Yudhi, and Erlinda Ningsih. "Prediksi Curah Hujan Di Kota Medan Menggunakan Model Backpropagation Neural Network." 2014.
- [14] Cici Oktaviani, Afdal. "Prediksi Curah Hujan Bulanan Menggunakan Jaringan Syaraf Tiruandengan beberapa Fungsi Pelatihan Backpropagation." *Jurnal fisika Unand*, 2014: 228-237.

- [15] Sihombing, Cristianto, et al. "Prediksi Curah Hujan di Wilayah DKI Jakarta dengan Model NeuralProphet." *Jurnal Aplikasi Meteorologi* 1.2 (2022).
- [16] Darmawan, Alan Chandra. "Pengembangan Aplikasi Berbasis Web dengan Python Flask untuk Klasifikasi Data Menggunakan Model Decision Tree C4. 5." (2023).
- [17] Rahim, Abdul Mizwar A., Inggrid Yanuar Risca Pratiwi, and Muhammad Ainul Fikri. "Klasifikasi Penyakit Jantung Menggunakan Model Synthetic Minority Over-sampling Technique Dan Random Forest Clasifier." *Indonesian Journal of Computer Science* 12.5 (2023).
- [18] Kurniawardhani, Arrie. "Estimasi Kalori pada makanan melalui Citra Makanan menggunakan Model SSD (Single Shot Detector) pada Mobile Device." (2020).
- [19] Setiawan, Ismail, Renata Fina Antika Cahyani, and Irfan Sadida. "Exploring Complex Decision Trees: Unveiling Data Patterns And Optimal Predictive Power." *Journal of Innovation And Future Technology (IFTECH)* 5.2 (2023): 112-123.
- [20] Purwanto, Agung, and Handoyo Widi Nugroho. "Analisa Perbandingan Kinerja Algoritma C4. 5 Dan Algoritma K-Nearest Neighbors Untuk Klasifikasi Penerima Beasiswa." *Jurnal Teknoinfo* 17.1 (2023): 236-243.
- [21] Kurdanti, Weni, Tri Mei Khasana, and Lastmi Wayansari. "Lingkar lengan atas, indeks massa tubuh, dan tinggi fundus ibu hamil sebagai prediktor berat badan lahir." *Jurnal Gizi Klinik Indonesia* 16.4 (2020): 168-175.
- [22] Andini, Rizki, Susetyowati Susetyowati, and Dian Caturini Sulistyoningrum. "Studi komparasi beberapa model skrining penilaian status gizi pada pasien dewasa rawat inap rumah sakit." *Jurnal Gizi Klinik Indonesia* 14.2 (2017): 64-71.
- [23] Aldi, F., Hadi, F., Rahmi, N. A., & Defit, S. (2023). StandardScaler's Potential in Enhancing Breast Cancer Accuracy Using Machine Learning. *Journal of Applied Engineering and Technological Science (JAETS)*, 5(1), 401-413.
- [24] [Sistem Informasi Meteorologi Penerbangan \(bmkgo.id\)](http://bmkgo.id)
- [25] Yonas, Banu Wijaya, Immanuel Jhonson A. Saragih, And Nanda Rinaldy. "Prediksi Curah Hujan Menggunakan Metode Regression Analysis Di Bandara Betoambari Baubau."