
Perbandingan Metode *LightGBM* dan *XGBoost* dalam Menangani Data dengan Kelas Tidak Seimbang

Putri Septiana Rizky⁽¹⁾, Ristu Haiban Hirzi⁽²⁾, Umam Hidayaturrohman⁽³⁾

¹²³Universitas Hamzanwadi Selong

Jl. TGKH. Muhammad Zainuddin Abdul Madjid Pancor, Selong, Lombok Timur, Telp./Fax.
(0376) 22954 NTB 83612

e-mail: putriseptianarizky@gmail.com, ristuastalavista@gmail.com dan
hidayaturrohman4@gmail.com

ABSTRAK

Masalah ketidakseimbangan kelas telah menjadi salah satu tantangan dalam kinerja banyak algoritma klasifikasi. Kelas tidak seimbang merupakan suatu kondisi dimana terdapat dataset yang jumlah kelasnya terdapat perbedaan yang signifikan terhadap masing-masing jumlah kelas. Dalam kumpulan data yang terdiri dari dua kelas, ukuran sampel kategori mayoritas (lebih besar) mendominasi sampel kategori minoritas (lebih kecil) dengan rasio sebesar 1:100, 1:1.000 atau 1:10.000. Dampak ketidakseimbangan ini menyebabkan klasifikasi menjadi buruk dan tidak optimal. Sebagian besar algoritma klasifikasi standar cenderung mengklasifikasikan kelas mayoritas dengan tingkat akurasi tinggi dan kelas minoritas dengan tingkat akurasi rendah, sehingga mengakibatkan terjadinya bias. Dalam banyak aplikasi, lebih penting untuk mengidentifikasi kelas minoritas dari pada kelas mayoritas. Pada penelitian ini diusulkan pendekatan berbasis *ensemble* dengan pengklasifikasi yang digunakan adalah *LightGBM* dan *XGBoost*, kedua metode ini merupakan metode gradien efisien yang beberapa tahun terakhir telah disarankan berdasarkan pohon keputusan sehingga mampu menangani masalah data dengan skala besar. Data yang digunakan diperoleh dari *UCI Repository* dengan 5 data, 3 diantaranya memiliki tingkat ketidakseimbangan tinggi dan sisanya dengan tingkat ketidakseimbangan rendah. Jumlah kelas yang digunakan pada penelitian adalah dua kelas. Hasil penelitian menunjukkan bahwa kinerja metode *XGBoost* dalam akurasi dan sensitivitas lebih baik dibandingkan *LightGBM* di hampir seluruh data. Sedangkan kemampuan dalam menebak kelas minoritas (spesifisitas), metode *LightGBM* lebih baik dibandingkan *XGBoost* dengan nilai keseluruhan rata-rata sebesar 80,41% : 74,64%.

Kata kunci : *LightGBM, XGBoost, Ensemble, Klasifikasi, Kelas Tidak Seimbang*

ABSTRACT

Class imbalance problem had become one of the challenges in the performance of many classification algorithms. Imbalanced class is a condition where there is a dataset in which the number of classes has a significant difference to each number of classes. In a data set consisting of two classes, the sample size of the majority category (larger) dominates the sample of the minority category (smaller) with a ratio of 1:100, 1:1.000 or 1:10.000. The impact of this imbalance causes the classification to be poor and not optimal. Most of the standard classification algorithms tend to classify the majority class with high accuracy and minority class with low accuracy, resulting in bias. In many applications, it is more important to identify the minority class than the majority class-based approach is proposed ensemble with the classifiers used are LightGBM and XGBoost. The data used is obtained from the UCI Repository with 5 data, 3 of which have a high level of imbalance and the rest with a low level of imbalance. The number of classes used in the study were two classes. The results showed that the performance of the XGBoost in accuracy and sensitivity was better than LightGBM in almost all data. While the ability to guess the minority class (specificity), the LightGBM is better than XGBoost with an average overall score of 80.41% :74.64%.

Keywords : *LightGBM, XGBoost, Ensemble, Classification, Imbalanced Class*

1. PENDAHULUAN

Masalah ketidakseimbangan kelas telah menjadi salah satu tantangan dalam kinerja banyak algoritma klasifikasi (Prasetio dan Pratiwi, 2015). *Imbalanced class* (kelas tidak seimbang) merupakan suatu kondisi dimana terdapat dataset yang jumlah kelasnya tidak sama atau terdapat perbedaan yang signifikan terhadap masing-masing jumlah kelas (Astuti dan Lenti, 2021). Sehingga akan memberikan dampak yang tidak baik terhadap klasifikasi (Siringoringo, 2018). Karena suatu algoritma klasifikasi mengumpamakan distribusi kelas pada *dataset* yang relatif seimbang (Pristyanto, 2019). Dalam kumpulan data yang terdiri dari dua kelas, ukuran sampel kategori mayoritas (lebih besar) mendominasi sampel kategori minoritas (lebih kecil) dengan rasio sebesar 1:100, 1:1.000 atau 1:10.000 (Elrahman dan Abraham, 2013).

Dampak ketidakseimbangan ini menyebabkan dampak buruk pada proses *machine learning* seperti klasifikasi maupun klusterisasi, pada akhirnya hasil yang diperoleh buruk dan tidak optimal (Siringoringo, 2018). Sebagian besar algoritma klasifikasi tunggal cenderung mengklasifikasikan kelas mayoritas dengan tingkat akurasi tinggi dan kelas minoritas dengan tingkat akurasi rendah, sehingga mengakibatkan terjadinya bias (Galar dkk, 2011). Dalam banyak aplikasi, lebih penting untuk mengidentifikasi kelas minoritas dari pada kelas mayoritas (Sulistiyowati dan Jajuli, 2020). Misalnya pada masalah medis (Kothan, 2015), masalah klasifikasi teks (Wu dkk, 2014), memprediksi cacat *software* (Saifudin dan Wahono, 2015) dan lain sebagainya.

Terdapat tiga pendekatan untuk menangani kumpulan data dengan kelas tidak seimbang, yaitu level algoritma, level data dan menggabungkan atau memasangkan metode (*Ensemble*) (Yap dkk, 2014). Pada penelitian ini akan berfokus pada penanganan kelas tidak seimbang menggunakan pendekatan *Ensemble learning*. Kelebihan Teknik *Ensemble learning* dibandingkan dengan *Single classifier* adalah mampu menghasilkan banyak pohon keputusan sehingga dalam melakukan prediksi lebih stabil dan efisien daripada *single classifier* (Lessmann dkk, 2015). *Ensemble* adalah algoritma yang menggabungkan beberapa metode klasifikasi tunggal yang bertujuan untuk menghasilkan model klasifikasi yang lebih akurat dan telah berhasil digunakan dalam menangani masalah *machine learning*, seperti pemilihan fitur, estimasi kepercayaan, fitur yang hilang dan kelas data (Zhang dan Ma, 2012). Prinsip kerja metode *Ensemble* menurut Sartono (2015) adalah

menghasilkan banyak pohon klasifikasi dari *dataset* yang digunakan kemudian melakukan pendugaan berdasarkan hasil penggabungan dari masing-masing pohon klasifikasi. Metode ini dirancang dengan tujuan meningkatkan akurasi dari *single classifier* dengan cara melatih beberapa pengklasifikasian yang berbeda (Hakim, 2018). Selanjutnya dari hasil prediksi setiap klasifikasi tersebut digabungkan menjadi prediksi akhir melalui proses yang dinamakan *voting*. Adapun metode berbasis *Ensemble* yang digunakan adalah *LightGBM* dan *XGBoost*, dimana kedua metode ini merupakan metode gradien efisien yang beberapa tahun terakhir telah disarankan berdasarkan pohon keputusan (Al Daoud, 2019:6).

XGBoost merupakan salah satu metode yang berbasis *Gradient Tree Boosting* canggih yang dapat bekerja secara efisien dalam menangani masalah skala besar dengan sumber daya komputasi yang sangat terbatas (Chen dan Guestrin, 2016). Sejak metode ini diperkenalkan, *XGBoost* mampu memenangkan berbagai kompetisi *machine learning* dan menjadi solusi yang kuat, efisien dan berguna untuk memecahkan berbagai masalah klasifikasi. *XGBoost* dikembangkan dengan optimasi 10 kali lebih cepat dibanding metode *Gradient Boosting* lainnya (Chen dan Guestrin, 2016). *XGBoost* memiliki keunggulan dalam kinerja dan kompleksitas waktu serta memori yang terjangkau, telah digunakan pada berbagai bidang penelitian sejak diusulkan mulai dari bidang medis, risiko kredit dan metagenomik (Wang dkk, 2020). Metode *XGBoost* dilaporkan memiliki kemampuan dalam menangani ketidakseimbangan data, hal ini ditunjukkan melalui eksperimen yang telah dilakukan oleh Zhao dkk (2018), menunjukkan bahwa *XGBoost* mampu mengungguli metode lain pada dataset tidak seimbang. Selain itu, *XGBoost* mampu mengerjakan berbagai fungsi seperti klasifikasi, regresi dan rangking (Handayani dkk, 2017).

Metode *LightGBM* dikembangkan oleh *Microsoft* yang memberikan kemampuan yang efisien dari algoritma *Gradient Boosting* (Ke dkk, 2017). *LightGBM* merupakan salah satu metode dalam *Gradient Boosting Decision Tree* (GBDT) baru yang mampu menangani *big data* dan sejumlah fitur besar (Tang dkk, 2020). *LightGBM* merupakan metode yang populer dan secara konsisten mampu untuk memecahkan berbagai masalah klasifikasi. *LightGBM* mempercepat waktu proses 20 kali lebih cepat dari fase pelatihan GBDT konvensional dengan akurasi yang sama (Ke dkk, 2017). Sehingga memberikan hasil model yang lebih efektif. Algoritma *LightGBM* telah banyak diaplikasikan

dalam berbagai klasifikasi dan studi regresi dan mencapai hasil deteksi yang sangat baik yang menunjukkan bahwa *LightGBM* adalah algoritma pengklasifikasi yang efektif (Rufo dkk, 2021).

Untuk mencari metode terbaik dalam menangani masalah ketidakseimbangan kelas, maka pada penelitian ini akan dilakukan pengukuran kinerja pendekatan *Ensemble* dengan pengklasifikasi *LightGBM* dan *XGBoost* dalam menangani permasalahan ketidakseimbangan kelas pada data.

2. METODE PENELITIAN

2.1 LightGBM

LightGBM algoritma yang dirancang oleh *Microsoft Research Asia* menggunakan kerangka *Gradient Boosting Decision Tree* (GBDT) (Ke dkk, 2017). Tujuannya untuk meningkatkan efisiensi komputasi, sehingga masalah prediksi dengan *big data* dapat diselesaikan dengan efisien (Liang dkk, 2020). *LightGBM* memiliki beberapa keunggulan dibandingkan metode GBDT lainnya, yaitu kecepatan pelatihan lebih cepat, efisiensi lebih tinggi, penggunaan memori lebih rendah, tingkat akurasi lebih baik, kemampuan dalam menangani data dengan skala yang besar dan dukungan pembelajaran paralel dan GPU (Rufo dkk, 2021). *LightGBM* adalah kerangka *Gradient Boosting* yang cepat, terdistribusi dan berkinerja tinggi berdasarkan algoritma pohon keputusan yang dapat digunakan untuk peringkat, klasifikasi, regresi dan banyak tugas pembelajaran mesin lainnya (Rufo dkk, 2021).

Diasumsikan bahwa himpunan data mentah dengan contoh $N = \{1, 2, \dots, n\}$ dan model *LightGBM* yang memiliki $T = \{1, 2, \dots, t\}$ pohon dihasilkan. Setelah iterasi t kali, prediksi akhir sama dengan jumlah yang pertama $(1 - t)$ th dan t th. Proses iterasi digambarkan sebagai berikut (Zhang dkk, 2020):

$$y_i^{(t)} = y_i^{(t-1)} + f_i(x_i) \tag{1}$$

Dimana $y_i^{(t)}$ adalah nilai prediksi contoh i th pada iterasi t th. $y_i^{(t-1)}$ menunjukkan model pohon yang dihasilkan sebelumnya dan $f_i(x_i)$ menunjukkan model baru yang dibangun.


Oleh karena itu, menurut persamaan (1), setiap prediksi baru dihasilkan oleh residu dan prediksi sebelumnya. Proses pelatihan lengkap digambarkan pada persamaan (2), sedangkan istilah regularisasi dapat dihitung menggunakan persamaan (3) yang digunakan untuk mengurangi kompleksitas model dan dapat digunakan untuk meningkatkan kegunaan pada *dataset* lainnya.

$$\begin{cases} y_i^{(0)} = 0 \\ y_i^{(t)} = f_1(x_i) = y_i^{(0)} + f_1(x_i) \\ y_i^{(2)} = f_1(x_i) + f_2(x_i) = y_i^{(1)} + f_2(x_i) \end{cases} \tag{2}$$

$$\begin{aligned} \mathcal{L}^{(t)} &= \sum_{i=1}^n l(y_i, y_i^{(t-1)} + f_t(x_i)) + \sum_{t=1}^T \Omega(f_t) \\ \Omega(f) &= \gamma T + \frac{1}{2} \lambda \|\omega\|^2 \end{aligned} \tag{3}$$

Dimana y_i adalah nilai aktual, $y_i^{(t)}$ adalah nilai prediksi. $\sum l$ mewakili jumlah kerugian antara masing-masing kelompok y_i dan $y_i^{(t)}$. dan $\Omega(f_i)$ adalah istilah regularisasi. T adalah jumlah daun, ω adalah bobot daun, λ dan γ adalah koefisien, dengan nilai *default* ditetapkan untuk $\gamma = 0$ dan $\lambda = 1$.

LightGBM memiliki karakteristik yang membedakannya dengan algoritma *tree boosting* lainnya adalah dengan membelah pohon secara memanjang (*leaf-wise tree growth*) dengan yang paling cocok, sedangkan algoritma *tree boosting* lainnya membagi pohon secara mendalam atau sejajar (*level-wise tree growth*) yang ditunjukkan pada gambar 2. Oleh karena itu, ketika tumbuh pada daun yang sama di *LightGBM*, algoritma *leaf-wise* dapat mengurangi lebih banyak kerugian dari pada algoritma *level wise* dan juga menghasilkan akurasi yang jauh lebih baik yang tidak dipenuhi oleh algoritma *boosting* lainnya (Rufo dkk, 2021). Namun, algoritma *leaf-wise* cenderung lebih rentan terhadap *overfitting*.



Gambar 1. Konstruksi *level-wise* dan *leaf-wise*

2.2 XGBoost

XGBoost adalah singkatan dari *Extreme Gradient Boosting*, metode ini pertama kali diperkenalkan oleh Friedman (2001), kemudian

Chen dan Guestrin (2016) mengusulkan metode *XGBoost* sebagai proyek *open-source* yang menerapkan system *machine learning* yang efisien, cepat dan terukur. *XGBoost* merupakan salah satu Teknik *machine learning* untuk mengatasi permasalahan klasifikasi dan regresi berdasarkan Teknik GBDT (Cherif dan Kortebi, 2019). Meskipun *XGBoost* terkenal sebagai model yang kokoh, beberapa studi menyatakan kelemahan metode ini. *XGBoost* merupakan model yang memiliki banyak parameter. Penentuan nilai setiap parameter tergolong sulit sehingga menghabiskan waktu yang tidak sedikit (Siringoringo dkk, 2021:98).

Berbeda dengan GBDT, *XGBoost* memperkenalkan istilah regularisasi dalam fungsi objektif untuk mencegah *overfitting*. Fungsi objektif didefinisikan sebagai berikut:

$$O = \sum_{i=1}^n L(y_i, F(x_i)) + \sum_{k=1}^t R(f_k) + C \quad (4)$$

Dimana $L(y_i, F(x_i))$ adalah fungsi kerugian (*loss function*), $R(f_k)$ menunjukkan istilah regularisasi pada iterasi waktu k dan C adalah istilah konstan yang dapat dihilangkan secara selektif. Istilah regularisasi $R(f_k)$ dinyatakan sebagai:

$$R(f_k) = \alpha H + \frac{1}{2} \eta \sum_{j=1}^H w_j^2 \quad (5)$$

Dimana α mewakili kompleksitas daun, H menunjukkan jumlah daun, η menunjukkan parameter penalti dan w_j^2 adalah hasil *output* dari setiap simpul daun. Secara khusus daun menunjukkan kategori yang diprediksi mengikuti aturan klasifikasi dan simpul daun menunjukkan simpul pohon yang tidak dapat dibagi. Selain itu, alih-alih menggunakan turunan orde pertama di GBDT, serangkaian objektif *taylor* orde kedua diadopsi dalam *XGBoost*. Misalkan kesalahan kuadrat rata-rata digunakan sebagai fungsi kerugian, maka fungsi objektif dapat diturunkan sebagai berikut:

$$O = \sum_{i=1}^n \left[p_i w_{q(x_i)} + \frac{1}{2} (q_i w_{q(x_i)}^2) \right] + \alpha H + \frac{1}{2} \eta \sum_{j=1}^H w_j^2 \quad (6)$$

$q(x_i)$ menunjukkan fungsi yang menetapkan titik data ke daun yang sesuai, p_i dan q_i menunjukkan

turunan pertama dan kedua dari fungsi kerugian masing-masing.

Nilai kerugian akhir dihitung berdasarkan jumlah semua nilai kerugian. Karena sampel sesuai dengan node dalam pohon keputusan, nilai kerugian akhir dapat ditentukan dengan menjumlahkan nilai kerugian node daun. Oleh karena itu, fungsi objektif juga dinyatakan sebagai berikut:

$$O = \sum_{j=1}^T \left[P_j w_j + \frac{1}{2} (Q_j + \eta) w_j^2 \right] + \alpha H \quad (7)$$

Dimana $P_j = \sum_{i \in I_j} p_i$, $Q_j = \sum_{i \in I_j} q_i$, dan I_j menunjukkan semua sampel dalam simpul daun j .

Untuk menyimpulkan, optimalisasi fungsi objektif diubah sebagai kasus memilih minimum fungsi kuadrat. Selain itu, karena pengenalan istilah regularisasi, *XGBoost* memiliki kemampuan yang lebih baik untuk melawan masalah *overfitting*.

3. HASIL DAN PEMBAHASAN

3.1 Analisis Deskriptif

Pada penelitian ini menggunakan 5 data yang memiliki karakteristik berbeda antara satu data dengan data yang lainnya. Data diperoleh dari situs *UCI Repository*, kriteria data yang digunakan adalah ketidakseimbangan data, tipe data multivariat dan termasuk data klasifikasi.

Tabel 1. Informasi data

No	Nama Data	Jumlah Data	Jumlah Variabel	Perbandingan kelas
1	<i>Abalone</i>	4.177	9	94:6
2	<i>Car</i>	1.728	7	95:5
3	<i>HTRU-2</i>	17.627	9	91:9
4	<i>Winequality-white</i>	4.659	12	83:17
5	<i>Winequality-red</i>	1521	12	86:14

Berdasarkan tabel 6, dapat dilihat bahwa perbandingan kelas data *Abalone*, *Car* dan *HTRU-2* diatas 90:10 yang menandakan tingkat ketidakseimbangan tinggi, sedangkan tingkat ketidakseimbangan rendah terdapat pada data *winequality-red* dan *winequality-white*. Setiap data yang digunakan pada penelitian ini memiliki karakteristik yang berbeda, yaitu jumlah data, variabel dan perbandingan kelas. Tujuan dari penggunaan kelima data tersebut untuk melihat

kinerja dari *LightGBM* dan *XGBoost* dalam menangani berbagai karakteristik yang berbeda.

3.2 Evaluasi hasil kinerja metode *LightGBM* dan *XGBoost* dalam menangani data dengan kelas tidak seimbang

a Klasifikasi *LightGBM*

Proses klasifikasi pada penelitian ini menggunakan *software R Studio* versi 4.0.2 dengan bantuan *package lightgbm, data.Tabel, caret, dplyr* dan *ROSE*. Algoritma *LightGBM* membutuhkan data dengan tipe matriks, maka peneliti menggunakan fungsi *sparse.model.matrix()*. Keuntungan dari matriks ini adalah dapat mengirimkan variabel dan label serta dapat mengidentifikasi kolom nama yang merupakan label. Serta membagi data menjadi dua bagian yaitu data pelatihan (*training*) sebanyak 75% dan data uji (*testing*) sebanyak 25%.

1) Model *LightGBM*

Pada model *LightGBM* digunakan fungsi *training* yang telah diubah ke bentuk matriks, maka dimasukkan data *train_matrix*. Kemudian menyesuaikan serangkaian model *LightGBM* untuk setiap parameter yang digunakan seperti *max_bin = 5, num_leaves = 35, learning_rate = 0,001, objective = "binary", metric = 'binary_logloss'* dan *nrounds = 1000*.

2) Prediksi *LightGBM*

Hasil pengujian model dianalisis dengan melakukan pencocokan kelas prediksi dengan kelas sebenarnya yang dapat memberikan informasi berupa akurasi, sensitivitas dan spesifisitas dengan menggunakan *confusion matrix*.

Tabel 2. Confusion matrix prediksi *LightGBM*

Nama Data	Akurasi	Sensitivitas	Spesifisitas
<i>Abalone</i>	81.51%	82.14%	71.90%
<i>HTRU-2</i>	94.62%	95.10%	89.76%
<i>Car</i>	95.63%	96.15%	86.36%
<i>Winequality-red</i>	73.46%	71.71%	84.54%
<i>Winequality-white</i>	75.51%	76.62%	69.50%

Berdasarkan tabel 2, dapat dilihat bahwa hasil prediksi diperoleh 2 data dengan nilai akurasi, sensitivitas dan spesifisitas kurang baik yaitu data *Winequality-red* dan *Winequality-white* karena nilai akurasi kurang dari 80% yaitu 73.46% dan 75.51%, nilai sensitivitas kurang dari 80% yaitu 71.71% dan

76.62% serta nilai spesifisitas dari data *Winequality-white* kurang dari 70% yaitu 69.50%. Metode *lightGBM* bekerja dengan optimal pada data *HTRU-2* dan *Car* karena dari kedua data tersebut memiliki nilai akurasi, sensitivitas dan spesifisitas tertinggi dengan nilai diatas 80%.

Untuk melihat seberapa baik atau optimal metode *LightGBM* digunakan untuk melakukan klasifikasi data dengan kelas tidak seimbang, peneliti menggunakan pengukuran nilai AUC (*Area Under the Curve*). Berikut ditampilkan nilai AUC dari setiap *dataset* yang digunakan.

Tabel 3. Nilai AUC metode *LightGBM*

Nama Data	AUC
<i>Abalone</i>	77%
<i>HTRU-2</i>	92,4%
<i>Car</i>	91,3%
<i>Winequality-Red</i>	78,1%
<i>Winequality-White</i>	73,1%

Tabel 3 Menunjukkan nilai AUC yang diperoleh menggunakan metode *LightGBM*. Semakin tinggi nilai AUC yang diperoleh maka kinerja suatu metode dalam melakukan klasifikasi semakin baik. Berdasarkan hasil di atas, kinerja *LightGBM* sangat baik dalam melakukan klasifikasi pada data *HTRU-2* dan *Car* dengan nilai AUC masing-masing sebesar 92.4% dan 91.3%.

b Klasifikasi *XGBoost*

Proses klasifikasi *XGBoost* membutuhkan bantuan *package xgboost, caret, tidyverse* dan *ROSE*. Algoritma *LightGBM* membutuhkan data dengan tipe matriks, maka peneliti menggunakan fungsi *model.matrix()* untuk membuat *dataset* kelas *trained* dan *tested*. Keuntungan dari matriks ini adalah dapat mengirimkan variabel dan label serta dapat mengidentifikasi kolom nama yang merupakan label. Serta membagi data menjadi dua bagian yaitu data pelatihan (*training*) sebanyak 75% dan data uji (*testing*) sebanyak 25%.

1) Model *XGBoost*

Pembuatan model *XGBoost* digunakan data *training* yang telah diubah ke dalam bentuk matriks, maka perlu dimasukkan data *trained*. Parameter yang digunakan pada penelitian ini adalah *nrounds* dan *nthreads*. Parameter *nrounds* memberitahu berapa kali *XGBoost* diulangi, pada penelitian ini menggunakan *nrounds = 1000* dan menggunakan *nthreads = 5*.

2) Prediksi *XGBoost*

Hasil dari pengujian model dianalisis dengan melakukan suatu pencocokan kelas prediksi dengan kelas sebenarnya yang dapat memberikan suatu informasi penting berupa nilai akurasi, sensitivitas dan spesifisitas dengan menggunakan *confusion matrix RStudio*.

Tabel 4. *Confusion matrix* model *XGBoost*

Nama Data	Akurasi	Sensitivitas	Spesifisitas
<i>Abalone</i>	92.54%	94.84%	52.63%
<i>HTRU-2</i>	98%	98.86%	88.49%
<i>Car</i>	97.22%	97.80%	86.36%
<i>Winequality-red</i>	90.03%	91.04%	82.61%
<i>Winequality-white</i>	85.06%	89.78%	63.11%

Nilai akurasi, sensitivitas dan spesifisitas yang diperoleh secara keseluruhan dapat dikatakan baik. Akan tetapi, terdapat 2 data yang memiliki nilai spesifisitas kurang dari 70% yaitu data *Abalone* dan *Winequality-white* dengan nilai spesifisitas masing-masing sebesar 52.63% dan 63.11%. Sedangkan 3 data lainnya yaitu *HTRU-2*, *Car* dan *Winequality-red* memiliki nilai *confusion matrix* baik.

Untuk melihat seberapa optimal metode *XGBoost* digunakan untuk melakukan klasifikasi data dengan kelas tidak seimbang, peneliti menggunakan pengukuran nilai AUC.

Tabel 5. Nilai AUC Metode *XGBoost*

Nama Data	AUC
<i>Abalone</i>	72,2%
<i>HTRU-2</i>	93,7%
<i>Car</i>	92.1%
<i>Winequality-red</i>	86.8%
<i>Winequality-hite</i>	76.4%

Berdasarkan tabel 5 metode *XGBoost* paling optimal/sangat baik digunakan dalam melakukan klasifikasi pada data *HTRU-2*, *Car* dan *Winequality-red* dengan masing-masing nilai AUC sebesar 93.7%, 92.1% dan 76.4%. Sedangkan pada data *Abalone* dan *Winequality-white*, metode *XGBoost* cukup baik digunakan dalam melakukan klasifikasi.

c. Perbandingan Kinerja Klasifikasi Metode *LightGBM* dan *XGBoost*

Setelah diperoleh hasil klasifikasi menggunakan metode *LightGBM* dan *XGBoost*, maka perbandingan nilai akurasi, sensitivitas, spesifisitas dan AUC ditunjukkan pada masing-masing tabel di bawah.

Tabel 6. Perbandingan akurasi metode *LightGBM* dan *XGBoost*

Nama Data	<i>LightGBM</i>	<i>XGBoost</i>
<i>Abalone</i>	81.51%	92.54%
<i>HTRU-2</i>	94.62%	98%
<i>Car</i>	95.63%	97.22%
<i>Winequality-red</i>	73.46%	90.03%
<i>Winequality-white</i>	75.51%	85.06%
Nilai Keseluruhan	84.15	92.57%

Berdasarkan Tabel 6, dapat dilihat bahwa metode *XGBoost* memiliki nilai akurasi lebih tinggi dibandingkan metode *LightGBM*. Nilai akurasi tertinggi untuk *lightGBM* dan pada data *Car* sebesar 95.63% dan untuk *XGBoost* pada data *HTRU-2* sebesar 98%. Selain itu, nilai akurasi terendah menggunakan *LightGBM* terdapat pada data *Winequality-red* dengan akurasi sebesar 73.46%, sedangkan menggunakan *XGBoost* terdapat pada data *Winequality-white* dengan akurasi sebesar 85.06%.

Tabel 7. Perbandingan sensitivitas metode *LightGBM* dan *XGBoost*

Nama Data	<i>LightGBM</i>	<i>XGBoost</i>
<i>Abalone</i>	82.14%	94.84%
<i>HTRU-2</i>	95.10%	98.86%
<i>Car</i>	96.15%	97.80%
<i>Winequality-red</i>	71.71%	91.04%
<i>Winequality-white</i>	76.62%	89.78%
Nilai Keseluruhan	84.34%	94.46%

Kinerja suatu metode dikatakan baik tidak hanya dilihat pada nilai akurasi melainkan mempertimbangkan nilai sensitivitas (ketepatan prediksi kelas positif/mayoritas). Tabel 7 menunjukkan nilai sensitivitas untuk setiap data menggunakan metode *LightGBM* dan *XGBoost*, dimana nilai sensitivitas *XGBoost* sedikit lebih tinggi dibandingkan *LightGBM* pada setiap data yang digunakan. Diperoleh nilai sensitivitas tertinggi terdapat pada data *HTRU-2* menggunakan *XGBoost* dengan nilai sebesar 98.86%. Kemudian untuk nilai sensitivitas terendah terdapat pada data *Winequality-red* menggunakan *LightGBM* dengan nilai sensitivitas sebesar 71.71%.

Tabel8. Perbandingan spesifisitas metode *LightGBM* dan *XGBoost*

Nama Data	<i>LightGBM</i>	<i>XGBoost</i>
<i>Abalone</i>	71.90%	52.63%
<i>HTRU-2</i>	89.76%	88.49%
<i>Car</i>	86.36%	86.36%
<i>Winequality-red</i>	84.54%	82.61%

<i>Winequality-white</i>	69.50%	63.11%
Nilai Keseluruhan	80.41%	74.64%

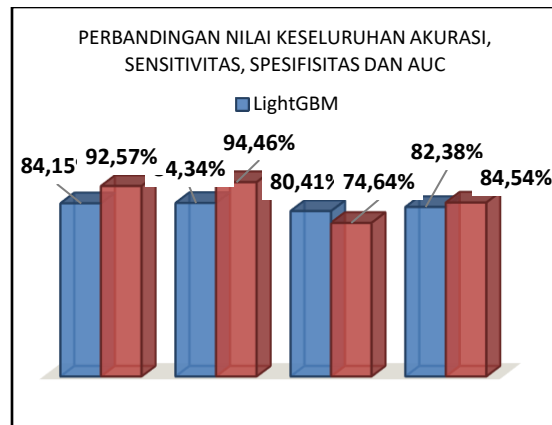
Tabel 8 menunjukkan nilai spesifisitas yang menggambarkan kemampuan metode dalam memprediksi kelas negatif (minoritas). Berdasarkan tabel di atas, terlihat bahwa nilai spesifisitas yang dihasilkan kedua metode dapat dikatakan baik untuk keseluruhan data. Akan tetapi, pada data *Abalone* dan *Winequality-white* nilai spesifisitas rendah, baik menggunakan metode *LightGBM* ataupun *XGBoost*. Nilai spesifisitas terendah terdapat pada data *Abalone* dengan menggunakan metode *XGBoost* sebesar 52.63%. Sedangkan nilai spesifisitas tertinggi terdapat pada data *HTRU-2* menggunakan metode *LightGBM* sebesar 89.76%.

Pada tabel 9 menunjukkan perbandingan nilai AUC dari metode *LightGBM* dan *XGBoost* yang digunakan untuk mengukur seberapa baik/optimal kedua metode tersebut digunakan pada setiap *dataset* yang disajikan. Nilai AUC yang tertinggi diperoleh menggunakan metode *XGBoost* pada data *HTRU-2* sebesar 93.7%, artinya *XGBoost* bekerja dengan optimal dalam melakukan klasifikasi pada data *HTRU-2*. Jika dilihat secara keseluruhan, nilai AUC *XGBoost* sedikit lebih tinggi dibandingkan *LightGBM* pada setiap *dataset* yang digunakan. Maka dengan itu, dapat dikatakan bahwa kinerja dari *XGBoost* lebih optimal dibandingkan *LightGBM*. Akan tetapi, metode *LightGBM* lebih baik/optimal digunakan untuk melakukan klasifikasi pada data *Abalone* dengan nilai AUC sebesar 77%.

Tabel 9. Perbandingan Nilai AUC metode *LightGBM* dan *XGBoost*

Nama Data	<i>LightGBM</i>	<i>XGBoost</i>
<i>Abalone</i>	77%	73.7%
<i>HTRU-2</i>	92.4%	93.7%
<i>Car</i>	91.3%	92.1%
<i>Wine Quality-Red</i>	78.1%	86.8%
<i>Wine Quality-White</i>	73.1%	76.4
Nilai Keseluruhan	82.38%	84.54%

Berikut gambar 2 mengenai tingkat kestabilan *LightGBM* dan *XGBoost* dilihat dari nilai akurasi, sensitivitas, spesifisitas dan AUC.



Gambar 2. Perbandingan Rata-rata keseluruhan nilai dari metode *LightGBM* dan *XGBoost*

Pada gambar 2 menunjukkan hasil perbandingan metode *LightGBM* dan *XGBoost* dengan 5 data dengan kelas tidak seimbang. Secara keseluruhan metode *XGBoost* lebih stabil dari pada metode *LightGBM*. Akan tetapi, nilai keseluruhan rata-rata spesifisitas *LightGBM* lebih tinggi dibandingkan *XGBoost* yaitu 80,41% dan 74,64%. Artinya metode *LightGBM* lebih baik digunakan dalam melakukan prediksi terhadap kelas negatif/minoritas dan tanpa harus mengabaikan kelas mayoritas dan hasil akurasi.

4. KESIMPULAN DAN SARAN

4.1 Kesimpulan

Berdasarkan penjelasan diatas, dapat ditarik kesimpulan dari hasil dan pembahasan yang telah penulis uraikan di atas, diantaranya sebagai berikut:

1. Pengklasifikasian data dengan kelas tidak seimbang menggunakan *LightGBM* dan *XGBoost* memerlukan beberapa parameter pengukuran yang telah ditentukan setelah melakukan beberapa kali percobaan, sehingga diperoleh hasil prediksi klasifikasi yang bagus. Parameter yang digunakan dalam melakukan analisis klasifikasi menggunakan *LightGBM*, yaitu *max_bin* = 5, *num_leaves* = 35, *learning_rate* = 0,001 dan *nrounds* =1000. Sedangkan untuk metode *XGBoost* menggunakan parameter *nrounds* = 1000 dan *nthreads* = 5. Selain itu, membagi data sampel menjadi dua, yaitu *training* 75% dan *testing* 25%.
2. Evaluasi hasil kinerja *LightGBM* dan *XGBoost* dengan menggunakan parameter yang telah ditentukan tersebut menghasilkan nilai akurasi dan sensitivitas terbaik pada data *HTRU-2* menggunakan metode *XGBoost* dengan nilai masing-masing sebesar 98% dan 98,86%.

Sedangkan, untuk nilai spesifisitas terbaik pada data *HTRU-2* menggunakan *LightGBM* dengan nilai sebesar 89,76%. Jika dilihat dari nilai keseluruhan rata-rata, kemampuan metode *LightGBM* lebih baik dalam melakukan prediksi terhadap kelas minoritas dibandingkan metode *XGBoost* dengan nilai 80,41% : 74,64%.

4.2 Saran

Penelitian ini masih dapat dikembangkan dengan membandingkan beberapa metode *Ensemble* lainnya, juga dapat menggunakan data yang lebih spesifik pada saat membandingkan metode serta menggunakan pengukuran kebaikan model yang lainnya. Contohnya perbandingan metode pada jumlah data, jumlah variabel, adanya *outlier* dan lain-lain.

DAFTAR PUSTAKA

- Abd Elrahman, S. M., & Abraham, A. (2013). *A review of class imbalance problem*. Journal of Network and Innovative Computing, 1(2013), 332-340.
- Chen, T., & Guestrin, C. (2016). *Xgboost: A scalable tree boosting system*. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining (pp. 785-794).
- Cherif, I. L., & Kortebi, A. (2019). *On using extreme gradient boosting (XGBoost) machine learning algorithm for home network traffic classification*. In 2019 Wireless Days (WD) (pp. 1-6). IEEE.
- Galar, M., Fernandez, A., Barrenechea, E., Bustince, H., & Herrera, F. (2011). *A review on ensembles for the class imbalance problem: bagging-, boosting-, and hybrid-based approaches*. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 42(4), 463-484.
- Hakim, L. (2018). *Metode Ensemble Berbasis Bagging untuk Penanganan Pemodelan Klasifikasi pada Data dengan Kelas Tidak Seimbang*. (Doctoral dissertation). Bogor: Sekolah Pascasarjana. Institut Pertanian Bogor.
- Handayani, A., Jamal, A., & Septiandri, A. A. (2017). *Evaluasi Tiga Jenis Algoritme Berbasis Pembelajaran Mesin untuk Klasifikasi Jenis Tumor Payudara*. Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI), 6(4), 394-403.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., ... & Liu, T. Y. (2017). *Lightgbm: A highly efficient gradient boosting decision tree*. Advances in neural information processing systems, 30, 3146-3154.
- Lessmann, S., Baesens, B., Seow, H. V., & Thomas, L. C. (2015). *Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research*. European Journal of Operational Research, 247(1), 124-136.
- Liang, W., Luo, S., Zhao, G., & Wu, H. (2020). *Predicting hard rock pillar stability using GBDT, XGBoost, and LightGBM algorithms*. Mathematics, 8(5), 765.
- Pristyanto, Y., Setiawan, NA, & Ardiyanto, I. (2017). *Resampling hybrid untuk menangani kelas yang tidak seimbang pada klasifikasi kinerja siswa di kelas*. Pada tahun 2017 1st International Conference on Informatics and Computational Sciences (ICICoS) (hlm. 207-212). IEEE.
- Rufo, D. D., Debelee, T. G., Ibenthal, A., & Negera, W. G. (2021). *Diagnosis of diabetes mellitus using gradient boosting machine (LightGBM)*. Diagnostics, 11(9), 1714.
- Saifudin, A., & Wahono, R. S. (2015). *Penerapan teknik ensemble untuk menangani ketidakseimbangan kelas pada prediksi cacat software*. IlmuKomputer. com Journal of Software Engineering, 1(1), 28-37.
- Sartono, B. (2015). *Tinjauan terhadap Keunggulan Pohon Klasifikasi Ensemble untuk Memperbaiki Kemampuan Prediksi Pohon Klasifikasi Tunggal*. Journal Biostatistics| Departemen Statistika FMIPA Universitas Padjadjaran, 9(2), 33-38.
- Siringoringo, R. (2018). *Klasifikasi data tidak seimbang menggunakan algoritma SMOTE dan k-nearest neighbor*. Journal Information System Development (ISD), 3(1).
- Siringoringo, R., Perangin-angin, R., & Jamaluddin, J. (2021). *Model Hibrid Genetic-Xgboost dan Principal Component Analysis Pada Segmentasi Dan Peramalan Pasar*. METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi, 5(2), 97-103.

- Sulistiyowati, N., & Jajuli, M. (2020). *Integrasi Naive Bayes Dengan Teknik Sampling SMOTE Untuk Menangani Data Tidak Seimbang*. NUANSA INFORMATIKA, 14 (1), 34-37.
- Tang, M., Zhao, Q., Ding, S. X., Wu, H., Li, L., Long, W., & Huang, B. (2020). *An improved lightGBM algorithm for online fault detection of wind turbine gearboxes*. Energies, 13(4), 807.
- Wang, C., Deng, C., & Wang, S. (2020). *Imbalance-XGBoost: Leveraging weighted and focal losses for binary label-imbalanced classification with XGBoost*. Pattern Recognition Letters, 136, 190-197.
- Wu, Q., Ye, Y., Zhang, H., Ng, M. K., & Ho, S. S. (2014). *ForesTexter: An efficient random forest algorithm for imbalanced text categorization*. Knowledge-Based Systems, 67, 105-116.
- Yap, B. W., Rani, K. A., Rahman, H. A. A., Fong, S., Khairudin, Z., & Abdullah, N. N. (2014). *An application of oversampling, undersampling, bagging and boosting in handling imbalanced datasets*. In Proceedings of the first international conference on advanced data and information engineering (DaEng-2013) (pp. 13-22). Springer, Singapore.
- Zhang, C., & Ma, Y. (Eds.). (2012). *Ensemble machine learning: methods and applications*. Springer Science & Business Media.
- Zhang, Y., Zhu, C., & Wang, Q. (2020). *LightGBM-based model for metro passenger volume forecasting*. IET Intelligent Transport Systems, 14(13), 1815-1823.
- Zhao, Z., Peng, H., Lan, C., Zheng, Y., Fang, L., & Li, J. (2018). *Imbalance learning for the prediction of N6-Methylation sites in mRNAs*. BMC genomics, 19(1), 1-10.