

Peningkatan Performa Model Gradient Boosting dalam Klasifikasi Stroke Melalui Optimasi Grid Search

Susi Handayani¹, Fajrizal², Taslim³, Dafwen Toresa⁴, Syahril⁵

^{1,2,3,4}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Lancang Kuning

⁵Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muhammdiyah Riau

susi@unilak.ac.id, fajrizal@unilak.ac.id, taslim@unilak.ac.id*, dafwen@unilak.ac.id, syahril@umri.ac.id

Abstract

This study investigates the effect of hyperparameter optimization with grid search on the XGBoost and LightGBM models in stroke classification. The research results show that parameter optimization significantly improves the performance of both models, especially in accuracy, precision, F1 Score, and ROC-AUC Score. In the XGBoost model, improvements are mainly seen in accuracy and precision, while LightGBM shows even improvements in all evaluation metrics. These findings underscore the importance of hyperparameter optimization in building effective classification models to predict stroke risk more accurately and reliably. These findings may contribute to further understanding of the factors that influence stroke and support more appropriate and effective treatment in clinical practice..

Keywords: hyperparameter, optimization, grid search, stroke, classification.

Abstrak

Studi ini menyelidiki pengaruh optimasi hyperparameter dengan grid search pada model XGBoost dan LightGBM dalam klasifikasi stroke. Hasil penelitian menunjukkan bahwa optimasi parameter secara signifikan meningkatkan performa kedua model, terutama dalam akurasi, precision, F1 Score, dan ROC-AUC Score. Pada model XGBoost, peningkatan terutama terlihat akurasi dan precision, sementara LightGBM menunjukkan peningkatan merata di semua metrik evaluasi. Temuan ini menggarisbawahi pentingnya optimasi hyperparameter dalam membangun model klasifikasi yang efektif untuk memprediksi risiko stroke dengan lebih akurat dan dapat diandalkan. Penemuan ini dapat berkontribusi dalam pemahaman lebih lanjut tentang faktor-faktor yang mempengaruhi stroke serta mendukung penanganan yang lebih tepat dan efektif dalam praktik klinis

Kata kunci: hyperparameter, optimasi, grid search, stroke, klasifikasi.

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International.

1. Pendahuluan

Stroke adalah suatu sindrom defisit neurologis akut dan fokal yang didefinisikan secara klinis akibat cedera vaskular (infark, perdarahan) pada sistem saraf pusat. Stroke merupakan penyebab kematian dan kecacatan nomor dua di dunia. Stroke bukanlah suatu penyakit tunggal namun dapat disebabkan oleh berbagai faktor risiko, proses dan mekanisme penyakit [1]. Stroke menjadi penyebab kematian nomor dua dan penyebab kematian serta kecacatan nomor tiga di dunia [2].

Diagnosis yang tepat waktu serta perawatan yang tepat sangat penting dalam mengurangi dampak penyakit ini. Salah satunya dengan melakukan Klasifikasi penderita stroke sebagai langkah awal dalam memahami pola, faktor risiko, dan karakteristik individu yang lebih rentan terhadap penyakit ini dan pengobatan dini dapat memanfaatkan diagnosis yang cepat dan berbiaya rendah untuk meminimalkan kelanjutan penyakit.

Banyak model yang diusulkan oleh para ahli terkait klasifikasi data penderita stroke. Govindarajan mengevaluasi berbagai algoritma pembelajaran mesin untuk klasifikasi stroke. Mereka menemukan bahwa jaringan saraf tiruan yang dilatih dengan algoritma *Stochastic Gradient Descent* menunjukkan kinerja

terbaik. Hasil ini menunjukkan bahwa jaringan saraf tiruan dapat menjadi alat yang efektif untuk klasifikasi stroke [3].

Kandukuri pada penelitiannya menggunakan K-Nearest Neighborhood (KNN) untuk klasifikasi penyakit stroke jantung dengan metode pembobotan parameter untuk meningkatkan akurasi. Penerapan KNN dengan metode pembobotan parameter menunjukkan potensi untuk meningkatkan akurasi klasifikasi dan membantu dokter dalam mendiagnosis penyakit stroke jantung dengan lebih tepat [4]. Santos mengusulkan pendekatan pembelajaran mesin untuk prediksi stroke serebral berdasarkan Sistem Imun Artifisial dan Pohon Keputusan yang diinduksi melalui Pemrograman Genetik. Tulisan ini menyajikan pendekatan baru dan menjanjikan untuk prediksi stroke serebral menggunakan teknik ML. Pendekatan penulis sangat cocok untuk kumpulan data yang tidak seimbang [5].

Dalam ranah Machine Learning, klasifikasi menjadi tugas penting untuk mengelompokkan data ke dalam kategori tertentu. Pembelajaran *ensemble* dan *deep learning* merupakan dua pendekatan terdepan yang mendominasi ranah pembelajaran mesin saat ini [6]. Algoritma ensemble, seperti peningkatan gradien

(gradient boosting), telah mendapatkan popularitas pesat dalam beberapa tahun terakhir [7]. Hal ini didorong oleh kemampuannya untuk meningkatkan akurasi dan kecepatan model klasifikasi. Algoritma peningkatan gradien membangun model prediksi akhir dengan menggabungkan beberapa model yang lebih kecil (disebut weak learners) secara berulang. Model-model ini dilatih secara berurutan, di mana setiap model baru berusaha memperbaiki kesalahan prediksi model sebelumnya. Algoritma ini diperkaya dengan beberapa algoritma yaitu XGBoost, LightGBM, dan CatBoost yang berfokus pada kecepatan dan akurasi. XGBoost adalah teknik ansambel terukur yang telah terbukti menjadi pemecah tantangan pembelajaran mesin yang andal dan efisien. LightGBM adalah model akurat yang berfokus pada penyediaan kinerja pelatihan yang sangat cepat menggunakan pengambilan sampel selektif dari instans gradien tinggi. CatBoost memodifikasi komputasi gradien untuk menghindari pergeseran prediksi guna meningkatkan akurasi model [8].

Optimasi parameter adalah salah satu alat terpenting dalam proses pembelajaran mesin. Proses ini melibatkan pemilihan solusi terbaik dari sekumpulan kandidat solusi, dengan tujuan untuk mencapai keseimbangan optimal antara akurasi dan generalisasi model [9]. Salah satu perkembangan terkemuka dalam ilmu komputer pada saat ini adalah integrasi antara optimasi dan machine learning. Penerapan formula dan teknik optimasi dalam pengembangan algoritma untuk mengekstrak informasi relevan dari dataset yang besar telah terbukti sangat bermanfaat [10]. Hal ini membuka peluang baru untuk berbagai aplikasi, seperti analisis data, pengenalan pola, dan prediksi. Contohnya, dalam bidang medis, integrasi ini dapat digunakan untuk mengembangkan algoritma yang lebih akurat untuk mendiagnosis penyakit, memprediksi risiko kesehatan, dan personalisasi perawatan pasien.

XGBoost dan LightGBM merupakan algoritma machine learning yang sangat kuat dan efisien untuk tugas klasifikasi dan regresi. Meskipun kedua algoritma ini memiliki parameter default yang sudah terdefinisi, optimasi parameter perlu dipertimbangkan untuk meningkatkan performa model dan menghindari overfitting atau underfitting. Optimasi parameter adalah salah satu alat terpenting dalam proses pembelajaran mesin. Proses ini melibatkan pemilihan solusi terbaik dari sekumpulan kandidat solusi, dengan tujuan untuk mencapai keseimbangan optimal antara akurasi dan generalisasi model [9].

Penelitian ini mengusulkan optimasi algoritma gradient menggunakan metode grid search untuk menemukan parameter terbaik. Parameter yang dioptimasi meliputi jumlah fitur pada setiap pemisahan, jumlah pohon dalam forest, kedalaman maksimum pohon, dan jumlah minimum sampel untuk pemisahan pada leaf node [11]. Selanjutnya, penelitian ini menerapkan pemilihan parameter pada model XGBoost dan LightGBM untuk

mengoptimalkan nilai max_depth , $n_estimators$, dan learning rate.

2. Metode Penelitian

Studi klasifikasi pasien stroke terus berkembang, dengan berbagai metode dan pendekatan baru yang bermunculan. Al Hak mengusulkan sebuah algoritma segmentasi tingkat fuzzy yang dioptimalkan sebagai langkah awal dalam mendeteksi lesi stroke iskemik. Setelah proses segmentasi, fitur multitekstur diekstraksi dari gambar untuk membentuk kumpulan fitur yang akan digunakan dalam proses klasifikasi. Dalam penelitiannya Al Hak mengusulkan penggunaan pengklasifikasi Gaussian Naïve Bayes yang efisien dalam membedakan kelas lesi stroke normal dan abnormal. Hasil eksperimen menunjukkan bahwa metodologi yang diusulkan memiliki kinerja yang sangat baik. Akurasi yang dicapai mencapai 99,32%, sensitivitas mencapai 96,87%, dan ukuran F1 mencapai 98,82%. Hasil ini menunjukkan bahwa algoritma segmentasi dan klasifikasi yang dikembangkan dalam penelitian tersebut mengatasi tantangan dalam deteksi otomatis lesi stroke dengan sangat baik dan memiliki potensi aplikasi di bidang medis [12]. Sailasya dalam penelitiannya menggunakan berbagai faktor fisiologis dan menerapkan algoritma pembelajaran mesin, termasuk Regresi Logistik, Klasifikasi *Decision tree*, Klasifikasi *Random Forest*, *k-Nearest Neighbors*, *Support Vector Machine*, dan Klasifikasi *Naïve Bayes* untuk melatih lima model yang berbeda guna mencapai prediksi yang akurat. Hasil penelitian menunjukkan bahwa algoritma *Naïve Bayes* menjadi yang terbaik dalam tugas ini, menghasilkan tingkat akurasi sekitar 82% [13]. Dev berhasil meningkatkan akurasi prediksi stroke dengan menggunakan algoritma neural network dan memilih empat atribut yang paling relevan. Model ini menunjukkan kinerja terbaik, baik dalam hal akurasi maupun tingkat kesalahan, dibandingkan dengan model yang menggunakan semua fitur masukan atau algoritma lain. Selain itu, penelitian ini juga menggarisbawahi pentingnya pemilihan fitur, analisis komponen utama, dan penyeimbangan data dalam meningkatkan kinerja prediksi stroke. Hasil evaluasi perbandingan prediksi stroke dengan melibatkan semua fitur menggunakan *Decision Tree*, *Random Forest*, *Neural Network*, *Convolutional Neural Network* dan *Support Vector Machine* dapat dilihat pada tabel 1 berikut stroke [14].

Tabel 1. Evaluasi klasifikasi stroke menggunakan DT, RF, NN, CNN dan SVM

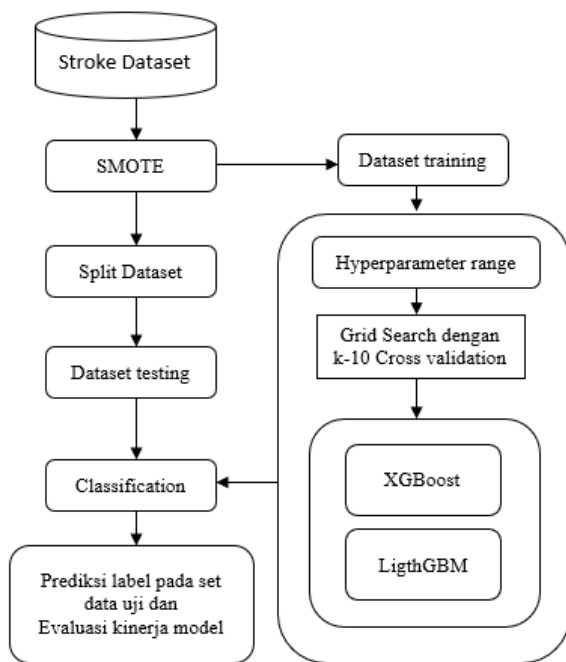
	DT	RF	NN	CNN	SVM
Precision	0.75	0.74	0.8	0.74	0.67
Recall	0.74	0.73	0.74	0.72	0.68
F1-score	0.74	0.73	0.77	0.73	0.68
Accuracy	0.74	0.74	0.77	0.74	0.68
Miss rate	0.17	0.18	0.16	0.17	0.23

Prediksi stroke yang akurat merupakan hal krusial dalam upaya pencegahan dan penanganan penyakit ini. Penelitian sebelumnya, seperti yang diulas dalam artikel [14], telah berhasil mengidentifikasi sejumlah faktor kunci yang berkontribusi terhadap stroke. Namun, penelitian lebih lanjut diperlukan untuk mengembangkan model prediktif dengan akurasi yang lebih tinggi.

Model Gradient Boosting, yang dikenal dengan kemampuannya dalam menangani data kompleks dan menghasilkan prediksi yang akurat, menawarkan potensi besar untuk meningkatkan akurasi prediksi stroke. Gradient Boosting memiliki banyak hyperparameter yang perlu disetel dengan tepat untuk mencapai performa optimal. Oleh karena itu, penelitian ini akan mengkaji efektivitas penggunaan model Gradient Boosting yang dioptimalkan melalui teknik Grid Search untuk meningkatkan akurasi prediksi stroke.

Sumber data yang digunakan adalah stroke prediction dataset. Berdasarkan kriteria masukan yaitu usia, jenis kelamin, riwayat hipertensi, riwayat penyakit jantung, status pernikahan, tipe pekerjaan, tipe tempat tinggal, rata-rata tingkat glukosa, indeks massa tubuh (BMI), dan status merokok., kumpulan data ini digunakan untuk memperkirakan kemungkinan seorang pasien akan mengalami stroke. Dataset ini terdiri atas dua kelas yaitu 1 untuk stroke dan 0 untuk tidak stroke dengan jumlah data 5110.

Dalam penelitian ini akan dilakukan beberapa langkah-langkah atau tahapan penelitian seperti yang digambarkan pada gambar 1.



Gambar 1. Rancangan Alur Penelitian

3. Hasil dan Pembahasan

3.1. Pembersihan Data

Pada tahap pembersihan data dan ekstraksi fitur dilakukan langkah-langkah untuk memastikan kebersihan dan kualitas data yang akan digunakan dalam pengembangan model klasifikasi.


3.2. Optimasi

Optimasi dimaksudkan agar model dapat menghasilkan hasil yang lebih baik. Optimasi *grid search 10-fold cross validation* dilakukan pada pemilihan parameter *max_depth*, *n_estimators* dan *learning rate*. Proses optimasi hyperparameter akan mencoba setiap kombinasi nilai dari hyperparameter yang ditentukan pada parameter grid. Untuk setiap kombinasi, model akan dilatih dengan data pelatihan dan kemudian dievaluasi dengan data validasi. Performa model pada setiap kombinasi akan diukur dengan metrik yang sesuai, seperti akurasi, precision, recall, F1 Score, atau AUC Score. Kombinasi nilai hyperparameter yang menghasilkan performa terbaik akan dipilih sebagai hyperparameter final untuk model.

3.3. Over-sampling Minoritas Sintetis (SMOTE)

Klasifikasi data yang tidak seimbang merupakan masalah umum di berbagai aplikasi. Hal ini terjadi karena kelas minoritas (kategori yang jarang) memiliki jumlah data yang jauh lebih sedikit dibandingkan kelas mayoritas. Biasanya, kelas minoritas menjadi fokus utama karena memiliki nilai informasi yang lebih tinggi. Teknik Over-sampling Minoritas Sintetis (SMOTE) adalah salah satu solusi yang populer untuk menangani ketidakseimbangan data. Teknik ini membuat data sintesis baru untuk kelas minoritas, sehingga jumlahnya menjadi lebih seimbang dengan kelas mayoritas. Hal ini bertujuan untuk meningkatkan performa model klasifikasi dalam memprediksi kelas minoritas [15].


Dataset yang digunakan dalam penelitian ini juga mengalami data yang tidak seimbang. Data yang digunakan terdiri atas dua kelas yaitu 1 untuk stroke dengan jumlah data 249 dan class 0 dengan jumlah data 4861. Setelah SMOTE untuk tidak stroke dengan jumlah data 5110. Jumlah data setelah SMOTE adalah 4861 untuk kelas 1 dan kelas 0. Gambar 2 berikut memperlihatkan grafik kelas sebelum SMOTE dan sesudah SMOTE.



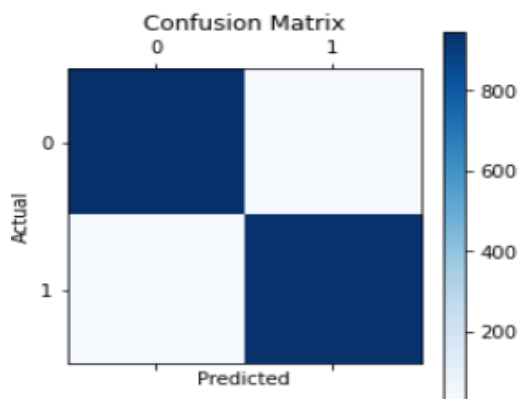
Gambar 2. Grafik kelas sebelum dan sesudah SMOTE

3.4. Klasifikasi dengan XGBoost tanpa optimasi hyperparameter

Model klasifikasi XGBoost tanpa optimasi hyperparameter memberikan hasil dengan tingkat akurasi sebesar 96.86%, model mampu secara konsisten melakukan prediksi dengan tepat dalam mengklasifikasikan data. *Precision* sebesar 0.97 menunjukkan bahwa model memiliki kemampuan yang tinggi dalam mengidentifikasi *true positive* dan meminimalkan *false positive*, sehingga prediksi positifnya dapat diandalkan. Nilai *recall* sebesar 0.97 menunjukkan bahwa model dapat dengan efisien mengenali sebagian besar data positif yang sebenarnya. F1-Score yang mencapai 0.97 mengindikasikan keseimbangan yang baik antara presisi dan recall, menunjukkan performa keseluruhan model yang sangat baik. Skor ROC-AUC yang tinggi, yaitu 0.97, menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antara kelas positif dan negatif (Gambar 3). Matriks konfusi (Gambar 4) memberikan gambaran visual tentang kinerja model, menyoroti jumlah prediksi yang benar dan salah. Dengan 947 true negative, 937 true positive, 28 false positive, dan 33 false negative, model ini telah memberikan hasil yang konsisten. Dengan demikian, dapat disimpulkan bahwa model klasifikasi ini memiliki performa yang sangat baik dalam melakukan prediksi pada data yang diberikan.




Gambar 3. Kurva ROC XGBoost tanpa optimasi



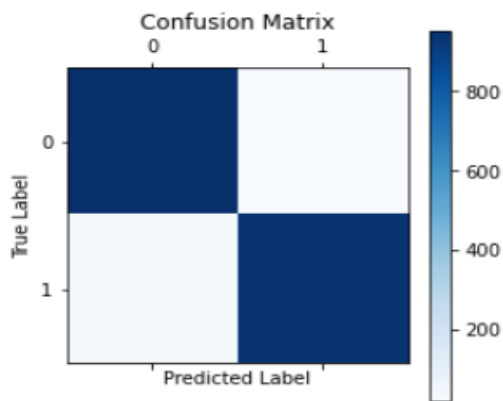
Gambar 4. Matrik Konfusi XGBoost tanpa optimasi

3.5. Klasifikasi XGBoost dengan optimasi hyperparameter

Optimasi dimaksudkan agar model dapat menghasilkan hasil yang lebih baik. Optimasi *grid search 10-fold cross validation* dilakukan pada pemilihan parameter *max_depth*, *n_estimators* dan *learning rate*. Dalam penelitian ini, model klasifikasi yang dikembangkan menunjukkan hasil evaluasi yang memuaskan. Nilai akurasi menunjukkan adanya peningkatan akurasi dibandingkan dengan XGBoost sebelum optimasi hyperparameter. Akurasi model sebesar 97.17% menunjukkan tingkat ketepatan dalam memprediksi kelas-kelas data. Hasil *precision* sebesar 0.98 menunjukkan tingkat keakuratan prediksi data positif, sementara *recall* sebesar 0.96 menunjukkan kemampuan model dalam menangkap data aktual yang positif. F1 Score sebesar 0.97, yang merupakan nilai gabungan dari *precision* dan *recall*, memberikan gambaran keseluruhan performa model. Selain itu, ROC-AUC Score yang mencapai 0.97 (Gambar 5) mengindikasikan performa model yang sangat baik dalam klasifikasi biner. Confusion Matrix digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan hasil prediksi model dengan label yang sebenarnya [16]. Tabel ini mengandung nilai True positif, False positif, True negatif dan False negatif [17]. Hasil penelitian klasifikasi XGBoost dengan optimasi hyperparameter diperoleh 954 true positive, 21 false positive, 34 false negative, dan 936 true negative (Gambar 6). Dari hasil evaluasi tersebut, dapat disimpulkan bahwa model memiliki performa yang sangat baik dalam melakukan prediksi dengan tingkat akurasi dan kehandalan yang tinggi.

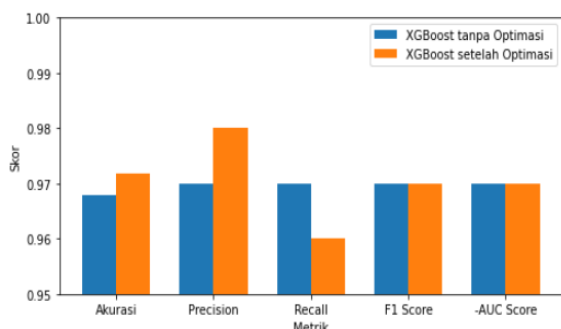


Gambar 5. Kurva ROC XGBoost dengan optimasi hyperparameter



Gambar 6. Grafik matrik konfusi XGBoost dengan optimasi hyperparameter

Dari hasil perbandingan antara XGBoost tanpa optimasi *hyperparameter* dan setelah dilakukan optimasi, terlihat bahwa performa model XGBoost mengalami peningkatan yang signifikan setelah dilakukan optimasi. Pada akurasi terjadi peningkatan sebesar 0.37%, *precision* meningkat 1%, nilai *recall* terjadi penurunan sebesar 1%, sementara nilai F1 Score dan AUC tidak mengalami perubahan. Grafik perbandingan antara XGBoost tanpa optimasi *hyperparameter* dan setelah dilakukan optimasi terlihat pada gambar 7 berikut.



Gambar 7. Grafik perbandingan hasil XGBoost tanpa optimasi dengan XGBoost yang di optimasi


3.6. Klasifikasi dengan LightGBM tanpa optimasi hyperparameter

Model LightGBM yang telah dilatih menunjukkan metrik evaluasi yang sangat baik. Dengan akurasi sebesar 95.32%, model ini mampu dengan tepat mengklasifikasikan data sebanyak 95.32%. Precision, recall, dan F1-Score semua mencapai 0.95, menunjukkan keseimbangan yang optimal antara kemampuan model dalam mengidentifikasi kelas positif dan negatif. Selain itu, ROC-AUC Score sebesar 0.95 menggambarkan kemampuan model dalam membedakan antara true positive rate dan false positive rate.


Dari confusion matrix, terlihat bahwa terdapat 931 true positives dan 923 true negatives, dengan hanya 44 false positives dan 47 false negatives. Hal ini menunjukkan bahwa model memiliki kecenderungan untuk membuat

lebih sedikit kesalahan, baik dalam mengklasifikasikan kelas positif maupun kelas negatif.

Performa yang luar biasa ini membuat model LightGBM menjadi alat yang andal dan efektif untuk tugas klasifikasi, serta dapat memberikan hasil yang konsisten dan dapat diandalkan. Dengan kemampuannya yang solid dalam menangani data, model ini siap digunakan dalam berbagai aplikasi dan skenario bisnis. Kurva ROC-AUC dan grafik konfusi LightGBM tanpa optimasi dapat dilihat pada gambar 8 dan 9 berikut.



Gambar 8. Kurva ROC-AUC LightGBM tanpa optimasi hyperparameter




Gambar 9. Grafik matrik konfusi LightGBM tanpa optimasi hyperparameter


3.7. Klasifikasi dengan LightGBM dengan optimasi hyperparameter

Penelitian ini menghasilkan model klasifikasi dengan performa yang sangat baik. Model ini mencapai akurasi 96.61%, menunjukkan kemampuannya dalam mengklasifikasikan data dengan tepat. Precision 0.97 menunjukkan model mampu mengidentifikasi data positif dengan benar, dan recall 0.96 menunjukkan model mampu menangkap hampir semua data positif yang ada. F1 Score 0.97, gabungan precision dan recall, memberikan gambaran menyeluruh tentang performa model. ROC-AUC Score 0.97 menunjukkan model memiliki performa klasifikasi biner yang sangat baik. Confusion Matrix menunjukkan 944 true positive, 31 false positive, 35 false negative, dan 935 true negative, memperkuat kesimpulan bahwa model ini memiliki akurasi dan keandalan prediksi yang tinggi. Kurva

ROC-AUC dan grafik kufusi LightGBM dengan optimasi dapat dilihat pada gambar 10 dan 11 berikut

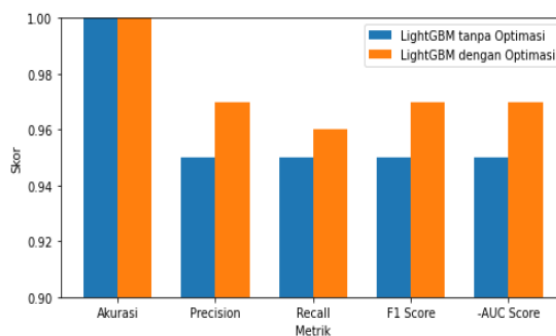


Gambar 10. Kurva ROC-AUC LighGBM dengan optimasi hyperparameter



Gambar 11. Grafik matrik kufusi LightGBM dengan optimasi hyperparameter

Dalam perbandingan antara model LightGBM tanpa optimasi dan dengan optimasi, terdapat peningkatan performa yang signifikan. Secara khusus, model LightGBM dengan optimasi mengalami peningkatan akurasi sebesar 1.29%, dari 95.32% menjadi 96.61%. Selain itu, terjadi peningkatan sebesar 2.11% dalam precision (dari 0.95 menjadi 0.97), peningkatan 0.01% dalam recall (dari 0.95 menjadi 0.96), peningkatan 2.11% dalam F1 Score (dari 0.95 menjadi 0.97), dan peningkatan 2.11% dalam ROC-AUC Score (dari 0.95 menjadi 0.97). Hal ini menunjukkan bahwa optimasi pada model LightGBM memberikan peningkatan yang signifikan dalam performa model tersebut. Gambar 12 memperlihatkan grafik perbandingan sebelum dan sesudah optimasi hyperparameter LightGBM.



Gambar 12. Grafik perbandingan hasil LightGBM tanpa optimasi dengan LightGBM yang di optimasi

4. Kesimpulan

Penelitian terkait klasifikasi stroke menggunakan algoritma machine learning seperti XGBoost dan LightGBM menunjukkan bahwa optimasi hyperparameter memiliki dampak signifikan terhadap performa model. Hasil penelitian menunjukkan bahwa optimasi parameter yang cermat dapat meningkatkan akurasi, precision, F1 Score, dan ROC-AUC Score model klasifikasi stroke.

Optimasi hyperparameter pada model XGBoost menghasilkan peningkatan yang paling menonjol pada akurasi dan precision. Meskipun recall mengalami sedikit penurunan, peningkatan pada akurasi dan precision menunjukkan bahwa model lebih handal dalam mengklasifikasikan instance positif dengan benar. Hal ini menunjukkan bahwa dengan penyetelan parameter yang tepat, model XGBoost dapat menjadi lebih efektif dalam memprediksi risiko stroke.

Di sisi lain, model LightGBM menunjukkan peningkatan yang lebih merata di semua metrik evaluasi yang diukur setelah optimasi hyperparameter. Hal ini menunjukkan bahwa optimasi parameter pada LightGBM menghasilkan peningkatan menyeluruh dalam kemampuan model untuk mengklasifikasikan data stroke dengan akurat. Peningkatan di semua aspek (akurasi, precision, F1 Score, ROC-AUC Score) menunjukkan bahwa model LightGBM yang dioptimalkan lebih unggul dalam melakukan prediksi risiko stroke.

Temuan ini mendukung pentingnya optimasi hyperparameter dalam membangun model klasifikasi stroke yang andal. Optimasi parameter tidak hanya meningkatkan performa model, tetapi juga dapat membantu dalam memahami faktor-faktor yang mempengaruhi risiko stroke, sehingga diagnosis dan penanganan dapat dilakukan dengan lebih efektif dan tepat waktu.

Daftar Rujukan

- [1] S. J. X. Murphy and D. J. Werring, "Stroke: causes and clinical features," *Medicine (Baltimore)*, vol. 48, no. 9, pp. 561–566, 2020, doi: <https://doi.org/10.1016/j.mpmed.2020.06.002>.
- [2] V. L. Feigin *et al.*, "World Stroke Organization (WSO): Global Stroke Fact Sheet 2022," vol. 17, no. X, 2022, doi: [10.1177/17474930211065917](https://doi.org/10.1177/17474930211065917).
- [3] P. Govindarajan, R. K. Soundarapandian, A. H. Gandomi, R. Patan, P. Jayaraman, and R. Manikandan, "Classification of stroke disease using machine learning algorithms," *Neural Comput. Appl.*, vol. 32, no. 3, pp. 817–828, 2020, doi: [10.1007/s00521-019-04041-y](https://doi.org/10.1007/s00521-019-04041-y).
- [4] K. Kandukuri and A. Sandhya, "Heart Stroke Detection Using KNN Algorithm," *ECS Trans.*, vol. 107, no. 1, p. 18385, Apr. 2022, doi: [10.1149/10701.18385ecst](https://doi.org/10.1149/10701.18385ecst).
- [5] L. I. Santos *et al.*, "Decision tree and artificial immune systems for stroke prediction in imbalanced data," *Expert Syst. Appl.*, vol. 191, p. 116221, 2022, doi: <https://doi.org/10.1016/j.eswa.2021.116221>.
- [6] A. Mohammed and R. Kora, "A comprehensive review on ensemble deep learning: Opportunities and challenges," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 35, no. 2, pp. 757–774, 2023, doi: <https://doi.org/10.1016/j.jksuci.2023.01.014>.
- [7] Y. Zhang and A. Haghani, "A gradient boosting method to improve travel time prediction," *Transp. Res. Part C Emerg. Technol.*, vol. 58, pp. 308–324, 2015, doi: <https://doi.org/10.1016/j.trc.2015.02.019>.
- [8] C. Bentéjac, A. Csörgő, and G. Martínez-Muñoz, "A comparative analysis of gradient boosting algorithms," *Artif. Intell. Rev.*, vol. 54, no. 3, pp. 1937–1967, 2021, doi: [10.1007/s10462-020-09896-5](https://doi.org/10.1007/s10462-020-09896-5).
- [9] M. M. El-Halwagi, Ed., "Overview of optimization," in *Process Integration*, vol. 7, in *Process Systems Engineering*, vol. 7, Academic Press, 2006, pp. 285–314. doi: [https://doi.org/10.1016/S1874-5970\(06\)80012-3](https://doi.org/10.1016/S1874-5970(06)80012-3).
- [10] A. Alridha, F. A. Wahbi, and M. K. Kadhim, "Training analysis of optimization models in machine learning," *Int. J. Nonlinear Anal. Appl.*, vol. 12, no. 2, pp. 1453–1461, 2021, doi: [10.22075/ijnaa.2021.5261](https://doi.org/10.22075/ijnaa.2021.5261).
- [11] B. H. Shekar and G. Dagnev, "Grid Search-Based Hyperparameter Tuning and Classification of Microarray Cancer Data," in *2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP)*, 2019, pp. 1–8. doi: [10.1109/ICACCP.2019.8882943](https://doi.org/10.1109/ICACCP.2019.8882943).
- [12] A. H. H. F. Miko Trenggono Hidayatullah, Masduki Asbari, Muhammad Iqbal Ibrahim, "Diabetes Prediction Using Binary Grey.pdf," *Int. J. Comput.* 21(4), 489-494. <https://doi.org/10.47839/ijc.21.4.2785>, 2022.
- [13] G. Sailasya and G. L. A. Kumari, "Analyzing the Performance.pdf," 2021.
- [14] S. Dev, H. Wang, C. S. Nwosu, N. Jain, B. Veeravalli, and D. John, "A predictive analytics approach for stroke prediction using machine learning and neural networks," *Healthc. Anal.*, vol. 2, p. 100032, 2022, doi: <https://doi.org/10.1016/j.health.2022.100032>.
- [15] D. Elreedy and A. F. Atiya, "A Comprehensive Analysis of Synthetic Minority Oversampling Technique (SMOTE) for handling class imbalance," *Inf. Sci. (Ny)*, vol. 505, pp. 32–64, 2019, doi: <https://doi.org/10.1016/j.ins.2019.07.070>.
- [16] R. Firdaus, H. Habibie, and Y. Rizki, "Implementasi Algoritma Random Forest Untuk Klasifikasi Pencemaran Udara di Wilayah Jakarta Berdasarkan Jakarta Open Data," vol. 14, no. 2, pp. 520–525, 2021.
- [17] H. Mukhtar, F. Alfanico, H. Fu'adah Amran, F. Handayani, and R. Medikawati Taufiq, "Deep Learning Untuk Klasifikasi Kematangan Buah Mangrove Berdasarkan Warna," 2023. doi: [10.37859/jf.v13i3.6292](https://doi.org/10.37859/jf.v13i3.6292).