



Integrasi Algoritma Firefly dalam Optimasi Hyperparameter CatBoost untuk Prediksi Risiko Penyakit Paru-Paru

Integration of the Firefly Algorithm for CatBoost Hyperparameter Optimization in Predicting Lung Disease Risk

Felix John Pardamean Hutabarat^{1*}, Paskah Abadi Simanullang², Revidamurty Daulay³, Adidtya Perdana⁴

Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan

Email: hutabaratfelix8.4233250008@mhs.unimed.ac.id^{1*}, paskahsimanullang24@gmail.com²,

revidamurti.4231250007@mhs.unimed.ac.id³, adidtya@unimed.ac.id⁴

Article Info

Article history :

Received : 09-12-2025

Revised : 11-12-2025

Accepted : 13-12-2025

Published : 15-12-2025

Abstract

This study presents an integrated approach to improving lung disease risk prediction by optimizing CatBoost hyperparameters using the Firefly Algorithm. Utilizing a dataset of 30,000 samples containing demographic, behavioral, and clinical attributes, the research applies the CRISP-DM methodology to ensure systematic data processing and model development. The Firefly Algorithm is employed to explore the hyperparameter search space and identify the best configuration through 5-fold cross-validated F1-score, resulting in a significantly enhanced CatBoost model that achieves 94.33% accuracy, 100% precision, 88.15% recall, a 93.70% F1-score, and a 0.9926 AUC-ROC. The findings demonstrate that Firefly effectively improves CatBoost's performance and stability, producing a reliable predictive model capable of supporting early diagnosis and clinical decision-making for lung disease risk.

Keywords : CatBoost, Firefly Algorithm, Lung Disease Prediction

Abstrak

Penelitian ini menyajikan suatu pendekatan terintegrasi untuk meningkatkan prediksi risiko penyakit paru-paru melalui optimasi hyperparameter CatBoost menggunakan Algoritma Firefly. Dengan memanfaatkan dataset yang terdiri atas 30.000 sampel yang mencakup atribut demografis, perilaku, dan klinis, penelitian ini menerapkan metodologi CRISP-DM guna memastikan proses pengolahan data dan pengembangan model yang sistematis. Algoritma Firefly digunakan untuk mengeksplorasi ruang pencarian hyperparameter dan menentukan konfigurasi terbaik berdasarkan nilai F1-score melalui validasi silang 5-fold, sehingga menghasilkan model CatBoost yang mengalami peningkatan kinerja secara signifikan dengan capaian akurasi sebesar 94,33%, presisi 100%, recall 88,15%, F1-score 93,70%, serta AUC-ROC sebesar 0,9926. Hasil penelitian menunjukkan bahwa Algoritma Firefly mampu meningkatkan kinerja dan stabilitas CatBoost, sehingga menghasilkan model prediktif yang andal untuk mendukung deteksi dini dan pengambilan keputusan klinis terkait risiko penyakit paru-paru.

Kata Kunci : CatBoost, Algoritma Firefly, Prediksi Penyakit Paru-Paru

PENDAHULUAN

Penyakit paru-paru merupakan salah satu masalah kesehatan yang berdampak besar terhadap angka kesakitan dan kematian di berbagai negara. Berbagai jenis penyakit paru-paru seperti kanker paru, TBC, pneumonia, serta PPOK masih menjadi beban kesehatan yang serius, terutama di negara berkembang. World Health Organization (WHO) melaporkan bahwa penyakit paru-paru termasuk penyebab kematian terbesar di dunia dan jumlah kasusnya terus meningkat setiap tahun (Irmansyah,



2025). Kondisi ini menunjukkan bahwa deteksi dini penyakit paru-paru sangat diperlukan untuk mengurangi risiko komplikasi dan meningkatkan peluang keberhasilan pengobatan.

Perkembangan teknologi kecerdasan buatan memberikan kontribusi besar dalam membantu proses diagnosis penyakit berbasis data medis. Berbagai penelitian telah memanfaatkan algoritma machine learning untuk mengidentifikasi pola klinis yang berkaitan dengan penyakit paru-paru. Studi sebelumnya menunjukkan bahwa algoritma seperti Naive Bayes dan Random Forest mampu memberikan hasil klasifikasi yang baik dalam mendeteksi kanker paru-paru dengan akurasi mencapai lebih dari 93% (Triwardani et al., 2025). Hal ini membuktikan bahwa pendekatan berbasis machine learning efektif dalam memprediksi risiko penyakit paru-paru dengan memanfaatkan data gejala klinis dan informasi demografis.

Selain itu, akurasi prediksi model machine learning sangat dipengaruhi oleh pemilihan dan konfigurasi hyperparameter. Penelitian terkait optimasi hyperparameter menunjukkan bahwa teknik seperti Random Search, Grid Search, maupun Tree Parzen Estimator mampu meningkatkan performa model secara signifikan. Misalnya, pada penelitian mengenai prediksi keberlangsungan hidup pasien gagal jantung, optimasi hyperparameter pada XGBoost terbukti meningkatkan nilai AUC dari 0,904 menjadi 0,94 (Mubarok et al., 2022). Temuan tersebut menguatkan bahwa proses optimasi hyperparameter merupakan langkah penting dalam menghasilkan model prediksi yang lebih akurat dan stabil.


Tidak hanya terbatas pada model berbasis pohon keputusan, penelitian lain juga menunjukkan bahwa algoritma Jaringan Syaraf Tiruan (JST) dengan metode Backpropagation mampu memberikan akurasi prediksi lebih dari 85% dalam klasifikasi penyakit paru-paru (Irmansyah, 2025). Kinerja JST sangat bergantung pada parameter pelatihan seperti learning rate dan jumlah neuron tersembunyi, yang kembali menegaskan pentingnya proses optimasi dalam pengembangan model prediksi.

Berdasarkan studi-studi sebelumnya, terlihat jelas bahwa pemanfaatan machine learning dan proses optimasi hyperparameter memiliki peran penting dalam meningkatkan kualitas sistem prediksi penyakit. Namun, masih terdapat ruang pengembangan, khususnya dalam penggunaan algoritma optimasi metaheuristik seperti Firefly Algorithm yang memiliki kemampuan eksplorasi dan eksploitasi lebih baik pada ruang pencarian hyperparameter.

Oleh karena itu, penelitian ini mengusulkan integrasi Algoritma Firefly untuk optimasi hyperparameter pada model CatBoost guna meningkatkan akurasi prediksi risiko penyakit paru-paru (Nurcahyo & Sasongko, 2023). Dengan pendekatan ini, diharapkan model dapat bekerja lebih optimal dalam menangani data klinis yang kompleks serta memberikan hasil prediksi yang lebih akurat dan dapat diandalkan.

METODE PENELITIAN

Penelitian ini menerapkan kerangka kerja standar industri untuk penambangan data atau *Cross-Industry Standard Process for Data Mining* (CRISP-DM). Metode ini dipilih karena strukturnya yang sistematis dan fleksibel dalam menangani proyek berbasis data, mulai dari pemahaman masalah bisnis hingga evaluasi model.



Gambar 1. CRISP-DM *Workflow Diagram*

Business Understanding

Tahap pertama berfokus pada pemahaman urgensi klinis dari penyakit paru-paru dan bagaimana teknologi dapat memberikan solusi. Penyakit paru-paru merupakan salah satu penyebab kematian tertinggi secara global, di mana deteksi dini sering kali terhambat oleh kompleksitas gejala dan keterbatasan metode diagnostik konvensional. Oleh karena itu, tujuan utama penelitian ini adalah membangun model prediktif yang mampu mengidentifikasi risiko penyakit paru-paru dengan akurasi tinggi, guna membantu tenaga medis dalam pengambilan keputusan klinis yang lebih cepat dan tepat.

Dari sisi teknis, tantangan utama yang dihadapi adalah optimalisasi kinerja algoritma *machine learning*. Penggunaan algoritma CatBoost dipilih karena keunggulannya dalam menangani data kategorikal, namun performanya sangat bergantung pada pengaturan *hyperparameter* yang tepat. Masalah optimasi ini dirumuskan sebagai pencarian kombinasi parameter terbaik untuk meminimalkan *error* prediksi, yang akan diselesaikan dengan mengintegrasikan Algoritma Firefly. Solusi ini diharapkan dapat mengatasi masalah *overfitting* dan meningkatkan generalisasi model dibandingkan dengan penggunaan parameter *default*.

Data Understanding

Data yang digunakan dalam penelitian ini terdiri dari 30.000 sampel, masing-masing merepresentasikan individu dengan sejumlah atribut kesehatan seperti usia, riwayat merokok, aktivitas olahraga, dan status risiko penyakit paru-paru sebagai target. Data dalam penelitian ini bersumber dari repositori data publik Kaggle, yang memuat rekam medis pasien dengan berbagai atribut klinis. Variabel dalam dataset mencakup fitur demografis seperti usia dan jenis kelamin, serta fitur gejala klinis seperti sesak napas, batuk kronis, kebiasaan merokok, dan riwayat penyakit lainnya, dengan satu variabel target yang melabeli tingkat risiko penyakit paru-paru (Rendah/Tinggi atau Positif/Negatif).

Analisis data eksploratif (EDA) dilakukan untuk memahami karakteristik distribusi data dan hubungan antar variabel. Pada tahap ini, dilakukan pemeriksaan statistik deskriptif untuk melihat



tendensi sentral dan penyebaran data, serta visualisasi menggunakan histogram dan *heatmap* korelasi untuk mengidentifikasi fitur yang paling berpengaruh terhadap variabel target. Selain itu, analisis ini juga bertujuan untuk mendeteksi adanya ketidakseimbangan kelas (*class imbalance*) pada label target, yang merupakan masalah umum pada data medis dan memerlukan penanganan khusus pada tahap persiapan data agar model tidak bias.

Data Preparation

Tahap persiapan data meliputi penanganan missing values dengan mengisi nilai kosong pada fitur kategorikal menggunakan label khusus, serta pada fitur numerik dengan nilai median. Seluruh fitur kategorikal dikonversi ke tipe data kategorikal agar dapat diproses secara optimal oleh algoritma CatBoost. Selain itu, target dikonversi ke format numerik biner (1 untuk risiko, 0 untuk tidak berisiko) agar sesuai dengan kebutuhan klasifikasi.

Data kemudian dibagi menjadi data latih dan data uji dengan proporsi 80:20, menggunakan stratified split untuk menjaga proporsi kelas target pada kedua subset. Selanjutnya, pada data latih dilakukan proses validasi silang menggunakan k-fold cross-validation dengan k=5. Artinya, data latih dibagi menjadi 5 bagian, di mana pada setiap iterasi satu bagian digunakan sebagai data validasi dan empat bagian lainnya sebagai data pelatihan, sehingga seluruh data dapat digunakan secara bergantian untuk validasi dan pelatihan.

Modeling

Pada tahap ini, model prediksi dibangun menggunakan algoritma CatBoostClassifier yang dikenal efektif untuk data kategorikal dan mampu menangani imbalance kelas. Untuk mengoptimalkan performa model, dilakukan tuning hyperparameter menggunakan algoritma Firefly, sebuah metode metaheuristik yang meniru perilaku kunang-kunang dalam mencari solusi optimal. Proses optimasi dilakukan secara iteratif, di mana setiap solusi (kombinasi hyperparameter) dievaluasi menggunakan rata-rata skor AUC dari 5-fold cross-validation pada data latih.

Selama proses optimasi, sejumlah parameter penting seperti learning rate, depth, l2_leaf_reg, dan jumlah iterasi dieksplorasi dalam rentang nilai yang telah ditentukan. Setiap iterasi Firefly menghasilkan solusi baru yang dievaluasi dan dibandingkan berdasarkan performa validasi silang. Model dengan kombinasi hyperparameter terbaik kemudian dilatih ulang pada seluruh data latih untuk menghasilkan model akhir yang siap dievaluasi pada data uji.

Evaluation

Evaluasi model dilakukan dengan membandingkan performa model baseline (sebelum optimasi) dan model hasil optimasi Firefly pada data uji. Metrik yang digunakan meliputi AUC, akurasi, precision, recall, dan F1-score, yang dihitung berdasarkan prediksi pada data uji. Selain itu, dilakukan analisis lebih lanjut seperti pembuatan confusion matrix, ROC curve, precision-recall curve, serta analisis sensitivitas parameter untuk memahami pengaruh masing-masing hyperparameter terhadap performa model.

Proses evaluasi juga mencakup optimasi threshold klasifikasi menggunakan metode Youden's J statistic untuk mendapatkan trade-off terbaik antara sensitivitas dan spesifisitas. Selain evaluasi kuantitatif, dilakukan interpretasi model menggunakan SHAP (*SHapley Additive exPlanations*) untuk mengetahui kontribusi masing-masing fitur terhadap prediksi. Seluruh hasil



evaluasi divisualisasikan secara komprehensif agar dapat memberikan gambaran menyeluruh mengenai performa dan interpretabilitas model yang dihasilkan.

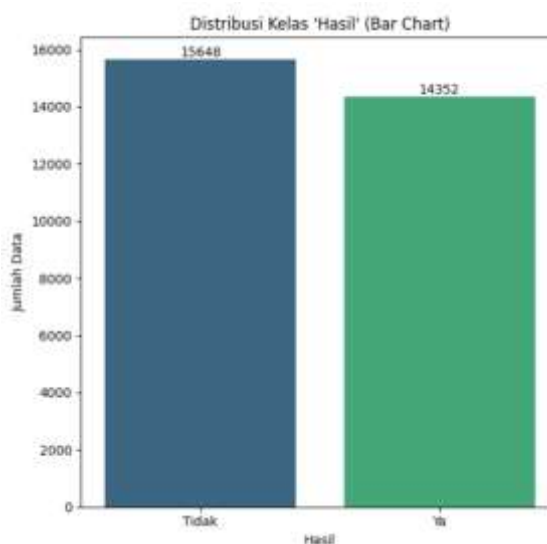
HASIL DAN PEMBAHASAN

Gambaran Umum Hasil

Bab ini menyajikan hasil implementasi dan evaluasi model CatBoost yang dioptimasi menggunakan Algoritma Firefly untuk prediksi risiko penyakit paru-paru. Seluruh proses analisis mengikuti alur CRISP-DM, mulai dari pemahaman data, persiapan data, pemodelan, hingga evaluasi. Fokus utama pembahasan adalah bagaimana integrasi Firefly dalam penentuan hyperparameter CatBoost berpengaruh terhadap peningkatan kinerja model, serta sejauh mana model mampu membedakan individu yang berisiko dan tidak berisiko terhadap penyakit paru-paru berdasarkan faktor demografis, perilaku, dan klinis.

Hasil Tahap Pemahaman Data (Data Understanding)

Pada tahap pemahaman data, diperoleh bahwa dataset yang digunakan terdiri atas 30.000 observasi dengan 10 variabel, yang mencakup sembilan fitur prediktor dan satu variabel target. Variabel target adalah Hasil, yang memuat dua kategori, yaitu “Ya” untuk responden yang diklasifikasikan berisiko atau memiliki penyakit paru-paru, dan “Tidak” untuk responden yang tidak berisiko. Distribusi kelas menunjukkan bahwa terdapat 15.648 data dengan label “Tidak” dan 14.352 data dengan label “Ya”, sehingga proporsi kelas masing-masing sekitar 52,16% dan 47,84%. Komposisi ini relatif seimbang sehingga mengurangi risiko model terlalu bias terhadap salah satu kelas dan menjadikan metrik seperti akurasi dan F1-score tetap informatif.




Gambar 2. Diagram batang distribusi kelas “Ya” dan “Tidak” pada variabel Hasil

Fitur-fitur prediktor yang digunakan meliputi Usia, Jenis_Kelamin, Merokok, Bekerja, Rumah_Tangga, Aktivitas_Begadang, Aktivitas_Olahraga, Asuransi, dan Penyakit_Bawaan. Seluruh fitur ini direkam dalam bentuk kategorikal, misalnya Usia diklasifikasikan sebagai Muda atau Tua, Merokok dibedakan menjadi Tidak, Pasif, dan Aktif, sementara variabel perilaku lain seperti aktivitas begadang dan olahraga menggambarkan kebiasaan hidup responden. Secara substantif, kombinasi variabel ini cukup representatif untuk menangkap faktor-faktor risiko yang



umum dikaitkan dengan penyakit paru-paru, mulai dari kebiasaan merokok, gaya hidup, hingga keberadaan penyakit bawaan.



Gambar 3. Diagram batang yang menggambarkan distribusi beberapa fitur

Hasil eksplorasi awal ini menegaskan bahwa data yang digunakan tidak hanya memadai dari sisi jumlah, tetapi juga relevan dari sisi substansi. Adanya variasi kategori pada faktor perilaku dan klinis memberikan ruang bagi model pembelajaran mesin untuk mempelajari pola risiko secara lebih kaya, sementara keseimbangan distribusi target memastikan bahwa model tidak “dimanjakan” oleh kelas mayoritas.

Hasil Tahap Persiapan Data (Data Preparation)

Tahap persiapan data diarahkan untuk memastikan bahwa dataset berada dalam bentuk yang siap diproses oleh algoritma CatBoost. Langkah pertama yang dilakukan adalah penghapusan kolom “No” yang hanya berperan sebagai penomoran dan tidak mengandung informasi prediktif. Dengan demikian, hanya fitur yang memiliki makna substantif yang dipertahankan dalam proses pemodelan. Selanjutnya, dilakukan pengecekan terhadap keberadaan nilai hilang melalui ringkasan struktur data dan statistik deskriptif. Berdasarkan hasil pemeriksaan, tidak ditemukan nilai hilang yang signifikan pada fitur yang digunakan, sehingga tidak diperlukan prosedur imputasi tambahan.

Proses berikutnya adalah pengolahan variabel kategorikal. Karena seluruh fitur prediktor berbentuk kategori, penyesuaian dilakukan agar sesuai dengan format input CatBoost, yang secara native mampu menangani fitur kategorikal. Sementara itu, variabel target Hasil dikonversi ke bentuk biner, “Tidak” menjadi 0 dan “Ya” menjadi 1, untuk mempermudah perhitungan metrik evaluasi dan analisis lebih lanjut. Hasil akhir tahap ini dapat diringkas dalam sebuah tabel yang memuat nama fitur, tipe data, dan contoh kategori setelah transformasi.

Setelah data dibersihkan dan ditransformasikan, dilakukan pembagian dataset menjadi data latih dan data uji dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian. Pembagian ini



menggunakan skema stratified sampling terhadap variabel target Hasil, sehingga proporsi kelas “Ya” dan “Tidak” pada data latih dan data uji tetap sebanding dengan distribusi awal. Hal ini penting untuk memastikan bahwa model dievaluasi pada data uji yang tetap mencerminkan kondisi populasi data sebenarnya.

Hasil Optimasi Hyperparameter CatBoost dengan Algoritma Firefly

Pada tahap pemodelan, fokus utama adalah integrasi Algoritma Firefly untuk mengoptimasi hyperparameter model CatBoostClassifier. Algoritma Firefly digunakan sebagai metaheuristik yang mengeksplorasi ruang solusi hyperparameter dengan mendasarkan diri pada prinsip ketertarikan antar firefly yang lebih terang (memiliki nilai fitness lebih baik). Dalam konteks ini, setiap firefly merepresentasikan satu kombinasi hyperparameter CatBoost yang diuji menggunakan metrik F1-score pada data latih atau validasi.

Ruang pencarian hyperparameter yang digunakan mencakup empat parameter utama, yaitu jumlah iterasi (iterations), laju pembelajaran (learning_rate), kedalaman pohon (depth), dan koefisien regularisasi L2 pada daun (l2_leaf_reg). Algoritma Firefly dijalankan dengan jumlah firefly sebanyak 10 dan maksimum 20 generasi, dengan fungsi objektif berupa F1-score. Selama proses optimasi, setiap generasi menghasilkan pembaruan posisi firefly berdasarkan tingkat ketertarikan dan komponen eksplorasi acak, hingga diperoleh kombinasi hyperparameter dengan kinerja terbaik.

```
Firefly Algorithm Optimization Complete.  
Best F1-score found: 0.9418  
Best hyperparameters:  
  iterations: 250  
  learning_rate: 0.1630  
  depth: 7  
  l2_leaf_reg: 4.3774
```

Gambar 4. Nilai konvergensi Firefly yang menampilkan perubahan nilai F1-score terbaik

Hasil akhir optimasi menunjukkan bahwa Algoritma Firefly berhasil menemukan kombinasi hyperparameter terbaik dengan F1-score validasi sebesar 0,9418. Kombinasi hyperparameter tersebut antara lain adalah iterations = 250, learning_rate = 0,1630, depth = 7, dan l2_leaf_reg = 4,3174. Kombinasi ini cukup masuk akal dari sisi teori, karena kedalaman pohon yang moderat (depth 7) memungkinkan model menangkap interaksi antar fitur tanpa terlalu kompleks, sedangkan nilai learning rate yang relatif tinggi namun tetap dikontrol oleh regularisasi L2 membantu mempercepat proses pembelajaran tanpa mengorbankan stabilitas.

Hasil Evaluasi Model CatBoost Teroptimasi

Setelah hyperparameter optimal diperoleh, model CatBoost dilatih ulang menggunakan kombinasi hyperparameter hasil Firefly pada data latih, kemudian dievaluasi pada data uji. Evaluasi dilakukan dengan menggunakan metrik akurasi, precision, recall, F1-score, dan AUC-ROC. Hasil evaluasi menunjukkan bahwa model mencapai akurasi sebesar 0,9433 (94,33%), precision sebesar 1,0000 (100,00%), recall sebesar 0,8815 (88,15%), F1-score sebesar 0,9370 (93,70%), dan AUC-ROC sebesar 0,9926 (99,26%) pada data uji. Nilai akurasi yang tinggi menunjukkan bahwa sebagian besar prediksi model telah sesuai dengan label aktual. Precision yang mencapai 100% mengindikasikan bahwa seluruh responden yang diprediksi berisiko oleh model memang benar-benar berasal dari kelas “Ya”, sehingga pada pengujian ini tidak terdapat false positive. Namun,




nilai recall yang berada pada kisaran 88% menunjukkan masih adanya sejumlah responden berisiko yang belum terdeteksi (false negative). F1-score yang tinggi mengonfirmasi bahwa terdapat keseimbangan yang baik antara kemampuan model untuk menghindari kesalahan prediksi positif palsu dan kemampuan untuk menangkap kasus berisiko. Sementara itu, nilai AUC-ROC yang mendekati 1 menunjukkan bahwa model memiliki kemampuan diskriminatif yang sangat baik dalam membedakan antara kelas “Ya” dan “Tidak” pada berbagai nilai ambang keputusan.

Model Performance on Test Set:

Accuracy: 0.9433
Precision: 1.0000
Recall: 0.8815
F1-Score: 0.9370
AUC-ROC: 0.9926


Gambar 5. Performa Model

Untuk memberikan gambaran lebih rinci mengenai pola kesalahan dan keberhasilan model, digunakan confusion matrix pada data uji. Confusion matrix memungkinkan identifikasi jumlah prediksi benar dan salah untuk masing-masing kelas. Pada penelitian ini, pola confusion matrix konsisten dengan nilai metrik yang diperoleh. Prediksi untuk kelas berisiko (“Ya”) tidak menghasilkan false positive, sejalan dengan precision 100%, sementara sebagian kecil kasus “Ya” diklasifikasikan sebagai “Tidak”, yang berkontribusi terhadap nilai recall yang belum mencapai 100%. Di sisi lain, jumlah prediksi benar untuk kelas “Tidak” juga tinggi, yang berarti model tidak cenderung menggeneralisasi secara berlebihan dengan memprediksi terlalu banyak kasus sebagai berisiko.



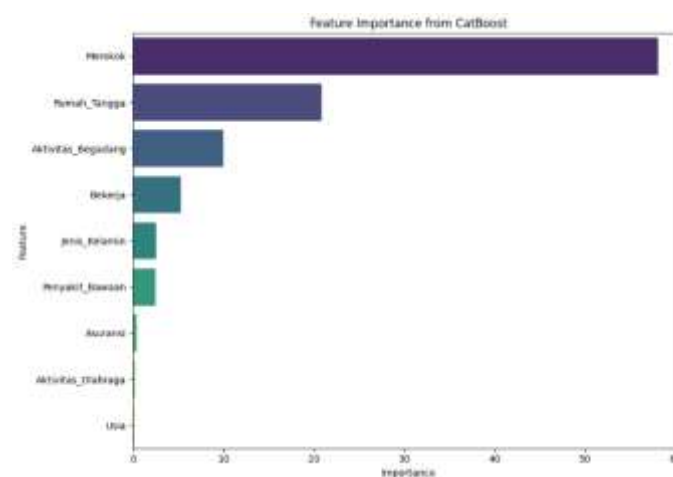
Gambar 6. Confusion Matrix

Selain confusion matrix, kurva ROC (Receiver Operating Characteristic) digunakan untuk mengevaluasi performa model pada berbagai nilai threshold. Kurva ROC model menunjukkan posisi yang jauh di atas garis diagonal, dengan area di bawah kurva (AUC) sebesar 0,9926, yang mengindikasikan bahwa model hampir selalu memberikan skor probabilitas lebih tinggi kepada responden berisiko dibandingkan responden tidak berisiko. Dalam praktik, hal ini berarti model memiliki kemampuan pemeringkatan risiko yang sangat baik; ketika threshold diubah, trade-off antara True Positive Rate dan False Positive Rate tetap berada pada tingkat yang menguntungkan.



Gambar 7. *ROC Curve*

Tahap berikutnya adalah interpretasi feature importance yang dihasilkan oleh CatBoost. Feature importance memberikan informasi mengenai seberapa besar kontribusi relatif setiap fitur terhadap keputusan model. Secara umum, hasil feature importance menunjukkan bahwa fitur-fitur yang berkaitan dengan perilaku dan kondisi kesehatan, seperti kebiasaan merokok, pola aktivitas begadang, aktivitas olahraga, dan keberadaan penyakit bawaan, cenderung memiliki kontribusi yang lebih besar dibandingkan sebagian variabel demografis atau sosial lainnya. Hal ini konsisten dengan pengetahuan domain, di mana pola hidup dan komorbiditas dikenal sebagai faktor penting yang memengaruhi risiko gangguan paru-paru.



Gambar 8. *Feature Importance from CatBoost*

Meskipun demikian, keberadaan faktor demografis seperti usia dan jenis kelamin tetap memberikan tambahan informasi yang membantu model membedakan pola risiko di antara kelompok responden yang berbeda.

KESIMPULAN

Penelitian ini menunjukkan bahwa integrasi Algoritma Firefly sebagai optimasi hyperparameter pada model CatBoost mampu meningkatkan performa prediksi risiko penyakit paru-paru secara signifikan. Proses optimasi menghasilkan kombinasi parameter yang lebih stabil



dan efektif dibandingkan pendekatan default, tercermin dari capaian akurasi sebesar 94,33%, F1-score 93,70%, serta AUC-ROC 99,26% pada data uji. Nilai precision yang mencapai 100% memperlihatkan bahwa model sangat andal dalam mengidentifikasi responden berisiko tanpa menghasilkan prediksi positif palsu, meskipun recall yang berada pada kisaran 88% mengindikasikan bahwa beberapa kasus berisiko masih belum terdeteksi sepenuhnya. Secara keseluruhan, model yang dihasilkan mampu memetakan pola risiko dengan baik dan menunjukkan kinerja yang konsisten berdasarkan struktur data yang digunakan.

Temuan ini menegaskan bahwa pendekatan metaheuristik seperti Firefly dapat menjadi solusi yang efektif dalam mengoptimalkan algoritma pembelajaran mesin, khususnya pada skenario medis yang membutuhkan ketelitian tinggi dan kemampuan generalisasi yang kuat. Di samping performa kuantitatif yang unggul, analisis feature importance juga memperlihatkan bahwa faktor perilaku dan komorbiditas memegang peranan penting dalam prediksi risiko penyakit paru-paru, sejalan dengan pemahaman klinis yang ada. Ke depannya, penelitian dapat diperluas dengan memperbesar variasi dataset, menguji metode optimasi metaheuristik lainnya, atau menggabungkan fitur klinis berbasis citra untuk menghasilkan model prediksi yang lebih komprehensif dan adaptif terhadap kondisi dunia nyata.

DAFTAR PUSTAKA

- Irmansyah, D. (2025). *Jurnal JISILKOM (Jurnal Inovasi Sistem Informasi & Ilmu Komputer) Prediksi Penyakit Paru-Paru Menggunakan Jaringan Syaraf Tiruan Dengan Metode Backpropagation*. 3(1).
- Mubarok, M. R., Muliadi, & Herteno, R. (2022). *HYPER-PARAMETER TUNING PADA XGBOOST UNTUK PREDIKSI KEBERLANGSUNGAN HIDUP PASIEN GAGAL*. 09(02), 391–401.
- Nurchahyo, J. A., & Sasongko, T. B. (2023). Indonesian Journal of Computer Science. *Indonesian Journal of Computer Science*, 12(1), 1351–1365.
- Triwardani, A. A., Daniati, E., Wardani, A. S., Studi, P., & Informasi, S. (2025). *STUDI KOMPARATIF ALGORITMA MACHINE LEARNING DALAM KLASIFIKASI DAN PREDIKSI KANKER PARU-*. 6(2), 214–222.