

PREDIKSI LATENCY PADA JARINGAN GPON DAN EPON MENGGUNAKAN HYBRID RANDOM FOREST-XGBOOST BERBASIS PARAMETER QUALITY OF SERVICE

Alvi Kavila Kurniansyah¹, Dian Ade Kurnia², Yudhistira Arie Wijaya³, Dadang Sudrajat⁴, Saeful Anwar⁵.

Program Studi Teknik Informatika¹⁴⁵
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
kurniansyah085@gmail.com

(*) Corresponding Author : kurniansyah085@gmail.com
Published : 30 Juni 2026

Abstract—This study analyzed latency prediction on GPON and EPON networks using a hybrid Random Forest-XGBoost based on Quality of Service parameters, namely jitter, throughput, and packet loss. The objectives of this study were to identify the influence of Quality of Service parameters on latency, build prediction models with Random Forest and XGBoost, and assess performance improvements through hybrid models. This research is an applied research with quantitative and computational approaches. Primary data was obtained from PT Anugerah Cimanuk Raya's operational network through packet capture using Wireshark as many as 10,000 samples. Data are processed through Exploratory Data Analysis, data cleaning, normalization, and supervised regression modeling. Model evaluation was conducted using RMSE, MAE, and R^2 , while the latency quality classification was assessed through accuracy, precision, recall, and F1-Score. The results showed that latency had a strong positive relationship with jitter and packet loss, as well as a very strong negative relationship with throughput. The tuned XGBoost Regressor model provides the best performance with an RMSE of 0.460371, MAE of 0.359267, and R^2 of 0.915101. The Random Forest-XGBoost hybrid stacked model also produced high performance, with an RMSE of 0.466739, MAE of 0.364402, and an R^2 of 0.912736, while the tuned Random Forest obtained an RMSE of 0.484631, MAE of 0.378514, and R^2 of 0.905917. On classification, the model achieved an accuracy of 0.789500 and an F1-Score of 0.799237. These findings suggest that latency predictions on GPON and EPON networks can be accurately constructed from Quality of Service parameters, as well as that hybrid models are feasible to be used as a basis for network quality monitoring.

Keywords: latency; GPON; EPON; Random Forest; XGBoost

Abstrak—Penelitian ini menganalisis prediksi latency pada jaringan GPON dan EPON menggunakan hybrid Random Forest-XGBoost berbasis parameter Quality of Service, yaitu jitter, throughput, dan packet loss. Tujuan penelitian ini adalah mengidentifikasi pengaruh parameter Quality of Service terhadap latency, membangun model prediksi dengan Random Forest dan XGBoost, serta menilai peningkatan kinerja melalui model hybrid. Penelitian ini merupakan penelitian terapan dengan pendekatan kuantitatif dan komputasional. Data primer diperoleh dari jaringan operasional PT Anugerah Cimanuk Raya melalui *packet capturing* menggunakan Wireshark sebanyak 10.000 sampel. Data diolah melalui *Exploratory Data Analysis*, pembersihan data, normalisasi, dan pemodelan regresi terawasi. Evaluasi model dilakukan menggunakan RMSE, MAE, dan R^2 , sedangkan klasifikasi kualitas latency dinilai melalui akurasi, *precision*, *recall*, dan F1-Score. Hasil penelitian menunjukkan bahwa latency memiliki hubungan positif yang kuat dengan jitter dan packet loss, serta hubungan negatif yang sangat kuat dengan throughput. Model XGBoost Regressor tuned memberikan performa terbaik dengan RMSE 0,460371, MAE 0,359267, dan R^2 0,915101. Model hybrid stacked Random Forest-XGBoost juga menghasilkan kinerja yang tinggi, dengan RMSE 0,466739, MAE 0,364402, dan R^2 0,912736, sedangkan Random Forest tuned memperoleh RMSE 0,484631, MAE 0,378514, dan R^2 0,905917. Pada klasifikasi, model mencapai akurasi 0,789500 dan F1-Score 0,799237. Temuan ini menunjukkan bahwa prediksi latency pada jaringan GPON dan EPON dapat dibangun secara akurat dari

parameter Quality of Service, serta bahwa model hybrid layak digunakan sebagai dasar pemantauan kualitas jaringan.

Kata Kunci: latency; GPON; EPON; Random Forest; XGBoost

INTRODUCTION

Perkembangan bidang Informatika dalam beberapa dekade terakhir telah mendorong transformasi yang signifikan pada aspek teknologi, bisnis, pendidikan, dan layanan publik. Kemajuan teknik komputasi, telekomunikasi, dan metode pembelajaran mesin telah memungkinkan *otomasi* dan analitik berskala besar yang berimplikasi langsung pada peningkatan kualitas layanan jaringan serta efisiensi operasional [1]. Integrasi sensor, telemetri jaringan, dan kemampuan pemrosesan *real-time* mendorong munculnya paradigma baru dalam pengelolaan sumber daya jaringan termasuk prakiraan metrik QoS yang krusial bagi penyedia layanan akses optik seperti GPON dan EPON. Dalam konteks praktis, operator ISP membutuhkan alat prediktif yang andal untuk mengantisipasi degradasi layanan sehingga intervensi proaktif dapat meminimalkan dampak terhadap pengguna akhir.

Sejalan dengan tren tersebut, penelitian *informatik* saat ini menekankan penggunaan model hibrida dan *ensemble* (misalnya kombinasi Random Forest dan XGBoost) serta teknik rekayasa fitur dan deret waktu *framing* untuk menangani kompleksitas data jaringan (Nurakhov et al., 2025; Sajid et al., 2024). Pendekatan hybrid telah terbukti efektif pada berbagai pengujian *testbed* dan lingkungan SDN/5G untuk memprediksi metrik kinerja jaringan, seperti *throughput* dan *latency*, serta untuk mendeteksi pola *trafik* besar (*elephant flows*) yang mengakibatkan kemacetan (Wassie et al., 2023b). Kombinasi metode pembelajaran pohon dengan teknik *deep learning* atau pemilihan fitur yang adaptif meningkatkan kemampuan generalisasi pada data nyata yang heterogen, sehingga relevan bagi studi yang menargetkan perbandingan GPON EPON berbasis parameter QoS.

Meski demikian, sejumlah tantangan besar masih menghambat penerapan model prediktif yang handal di lingkungan operasional. Isu integrasi data dari sumber heterogen, manajemen kualitas data yang terus berubah, skalabilitas pemrosesan *real-time*, serta kebutuhan akan interpretabilitas model dan otomatisasi alur kerja merupakan kendala praktis yang sering dilaporkan (Wakili et al., 2024). Dalam studi-studi terkait pula ditemukan masalah teknis seperti ketidaksesuaian format


sampling, kehilangan paket pada capture, serta perbedaan kondisi antara data uji laboratorium dan operasi riil yang mempersulit generalisasi model (C. Shao et al., 2024; Wong et al., 2023). Keterbatasan ini menegaskan pentingnya penelitian yang memanfaatkan data primer dari jaringan operasional serta melaporkan proses pemrosesan dan validasi secara transparan.

Rangkaian penelitian terdahulu pada jaringan akses optik menunjukkan kemajuan penting namun juga celah penelitian yang belum terisi penuh. Berbagai studi menggunakan LSTM, model boosting, dan teknik statistik untuk pemodelan delay pada PON/EPON, menghasilkan perbaikan prediksi pada kondisi tertentu, namun seringkali terbatas pada skenario simulasi atau *testbed* kecil (Hernández et al., 2021; M. Wang et al., 2025). Umpan balik literatur menunjukkan kebutuhan untuk evaluasi lintas-teknologi (GPON vs EPON) dengan dataset dunia nyata, penggunaan metrik evaluasi yang baku (mis. RMSE, MAE), serta eksplorasi model hybrid yang memadukan kekuatan bagging dan boosting untuk mereduksi kesalahan pada ekor distribusi latency (Mohammed et al., 2024; C. Shao et al., 2024). Oleh karena itu, penelitian ini berupaya menutup celah tersebut dengan menyajikan analisis komparatif berbasis data primer operasional.

Penelitian ini bertujuan mengembangkan dan mengevaluasi model prediksi latency pada jaringan GPON dan EPON menggunakan pendekatan hybrid Random Forest-XGBoost berbasis parameter QoS (latency, jitter, throughput, packet loss) dengan sumber data primer dari jaringan ISP di PT Anugerah Cimanuk Raya. Metodologi meliputi pengumpulan data *packet capturing* menggunakan Wireshark, tahap EDA untuk memahami pola QoS, preprocessing yang meliputi penanganan noise dan normalisasi, serta pembangunan dan tuning model RF, XGBoost, dan stacked hybrid. Evaluasi dilakukan menggunakan RMSE dan MAE. Kontribusi penelitian diharapkan berupa bukti empiris perbandingan kinerja prediktif antara GPON dan EPON pada data operasional nyata, rekomendasi pipeline preprocessing dan evaluasi untuk studi prediksi latency di PON, serta panduan penerapan model hybrid yang seimbang antara akurasi dan interpretabilitas untuk kebutuhan operasional ISP.

MATERIALS AND METHODS

Langkah-langkah penelitian yang diambil untuk membangun, melatih, dan mengevaluasi model prediksi latency berbasis hybrid Random Forest-xgboost menggunakan parameter qos pada jaringan GPON dan EPON. Tahapan disusun secara berurutan mulai dari eksplorasi data hingga pra-pemrosesan yang diperlukan untuk memastikan integritas data, keterwakilan fitur, serta kesesuaian untuk pemodelan mesin pembelajaran.



Gambar 1. Alur Penelitian

Roses dimulai dari tahap **pengumpulan data**, yang mencakup pengambilan data dari berbagai sumber seperti data historis, sensor, atau API. Pada tahap ini, kualitas dan kelengkapan data sangat penting karena akan memengaruhi keseluruhan proses analisis dan hasil model.

Selanjutnya, data masuk ke tahap Exploratory Data Analysis (EDA). Pada tahap ini dilakukan eksplorasi awal terhadap data untuk memahami karakteristiknya. Kegiatan yang dilakukan meliputi visualisasi distribusi data, analisis korelasi antar fitur, serta identifikasi pola atau tren yang tersembunyi. EDA juga membantu dalam mendeteksi adanya anomali atau ketidakseimbangan data yang perlu ditangani sebelum proses lebih lanjut.

Tahap berikutnya adalah preprocessing data, yaitu proses pembersihan dan transformasi data agar siap digunakan dalam pemodelan. Aktivitas yang dilakukan antara lain menangani missing values, normalisasi atau scaling data, serta encoding jika terdapat data kategorikal. Tahap ini bertujuan untuk meningkatkan kualitas data sehingga model dapat belajar dengan lebih optimal.

Setelah data siap, dilakukan pembangunan model menggunakan beberapa algoritma seperti Random Forest, xgboost, dan metode hybrid seperti stacking. Pada tahap ini, model dilatih menggunakan data training untuk menemukan pola yang dapat digunakan dalam prediksi.

Pemilihan algoritma yang beragam bertujuan untuk membandingkan performa dan mendapatkan model terbaik.

Kemudian masuk ke tahap prediksi, di mana model yang telah dilatih digunakan untuk memprediksi data baru atau data uji. Hasil prediksi ini selanjutnya akan dianalisis untuk melihat sejauh mana model mampu memberikan output yang akurat. Validasi juga dilakukan untuk memastikan model tidak mengalami overfitting.

Tahap terakhir adalah evaluasi model, yang dilakukan menggunakan metrik seperti MAE (Mean Absolute Error), RMSE (Root Mean Square Error), dan R^2 (Coefficient of Determination). Selain itu, dilakukan analisis visual hasil prediksi, evaluasi error, serta perbandingan antar model untuk menentukan model terbaik. Hasil evaluasi ini menjadi dasar dalam pengambilan keputusan serta pengembangan model lebih lanjut agar performanya semakin optimal.

RESULTS AND DISCUSSION

Pada tahap ini dilakukan proses pemodelan untuk memprediksi nilai latency berdasarkan parameter *Quality of Service* (QoS) yang telah diperoleh dari dataset. Metode yang digunakan dalam penelitian ini meliputi Random Forest Regressor, XGBoost Regressor, dan Hybrid Stacked RF-XGB Regressor. Ketiga model tersebut dievaluasi menggunakan tiga metrik utama, yaitu Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan R-Square (R2 Score). Hasil evaluasi kemudian dirangkum dalam Tabel 1

Tabel 1 Hasil Regresi (RMSE dan MAE)


Model	RMSE (ms)	MAE (ms)	R2 Score
Random Forest Regressor (Tuned)	0.484631	0.378514	0.905917
XGBoost Regressor (Tuned)	0.460371	0.359267	0.915101
Hybrid (Stacked RF-XGB) Regressor	0.466739	0.364402	0.912736

Berdasarkan hasil pengujian yang ditunjukkan pada tabel 1 model XGBoost Regressor (Tuned) memberikan performa terbaik dibandingkan model lainnya. Model ini menghasilkan nilai RMSE sebesar 0,460371 ms, MAE sebesar 0,359267 ms, dan R2 Score sebesar 0,915101. Nilai RMSE dan MAE yang rendah menunjukkan bahwa selisih antara nilai

aktual dan nilai prediksi tergolong kecil, sedangkan nilai R2 yang tinggi menunjukkan bahwa model mampu menjelaskan sebagian besar variasi data latency dengan sangat baik.

Sementara itu, model Random Forest Regressor (Tuned) memperoleh nilai RMSE sebesar 0,484631 ms, MAE sebesar 0,378514 ms, dan R2 Score sebesar 0,905917. Hasil ini menunjukkan bahwa Random Forest juga memberikan performa yang baik, namun masih sedikit berada di bawah XGBoost dalam hal ketepatan prediksi.

Adapun model Hybrid (Stacked RF-XGB) Regressor menghasilkan RMSE sebesar 0,466739 ms, MAE sebesar 0,364402 ms, dan R2 Score sebesar 0,912736. Meskipun performanya cukup kompetitif, model hybrid belum mampu melampaui performa XGBoost Regressor secara keseluruhan. Hal ini mengindikasikan bahwa pada dataset ini, kombinasi model tidak memberikan peningkatan yang signifikan dibandingkan model tunggal terbaik. Untuk visualisasi actual dan prediksi akan ditampilkan pada Gambar 2



Gambar 2 Aktual vs Prediksi

Berdasarkan Gambar 2 grafik Aktual vs Prediksi pada model hybrid menunjukkan bahwa titik-titik prediksi cenderung mengikuti garis diagonal merah yang merepresentasikan kondisi ideal, yaitu kesamaan antara nilai aktual dan nilai prediksi. Penyebaran titik yang cukup rapat di sekitar garis diagonal menandakan bahwa model memiliki kemampuan prediksi yang baik. Namun demikian, masih terlihat beberapa titik yang menyimpang dari garis ideal, terutama pada rentang latency yang lebih tinggi. Hal ini menunjukkan adanya sedikit deviasi prediksi pada data tertentu, meskipun secara umum model masih mampu mempertahankan akurasi yang baik.

Secara keseluruhan, hasil modeling menunjukkan bahwa seluruh model yang diuji mampu melakukan prediksi nilai latency dengan performa yang tinggi. Namun, berdasarkan kombinasi nilai error yang paling rendah dan nilai R2 Score yang paling tinggi, XGBoost

Regressor (Tuned) dipilih sebagai model terbaik dalam penelitian ini.

Hasil Modeling Dan Evaluasi Klasifikasi

Pada tahap ini dilakukan evaluasi terhadap model klasifikasi yang digunakan untuk mengelompokkan kualitas jaringan berdasarkan nilai latency ke dalam kategori tertentu, yaitu kelas Low dan High. Evaluasi model bertujuan untuk mengukur sejauh mana model mampu melakukan klasifikasi secara akurat dan konsisten.

Untuk mengukur performa model, digunakan beberapa metrik evaluasi yang umum dalam klasifikasi, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Metrik-metrik ini dipilih karena mampu memberikan gambaran menyeluruh terhadap performa model, baik dari sisi ketepatan prediksi maupun keseimbangan antar kelas. Sebagai hasil dari proses evaluasi, diperoleh nilai metrik klasifikasi yang disajikan pada Tabel 2

Tabel 2 Nilai Metrik Klasifikasi

No	Metric	Value
0	Accuracy	0.789500
1	Precision	0.770929
2	Recall	0.829703
3	F1-Score	0.799237


Berdasarkan Tabel 2, model klasifikasi yang digunakan menghasilkan nilai Accuracy sebesar 0,789500, yang menunjukkan bahwa sekitar 78,95% data berhasil diklasifikasikan dengan benar. Nilai ini mengindikasikan bahwa model memiliki performa yang cukup baik dalam membedakan antara kelas latency rendah dan tinggi.

Nilai *Precision* sebesar 0,770929 menunjukkan bahwa dari seluruh data yang diprediksi sebagai suatu kelas (misalnya High), sekitar 77,09% di antaranya merupakan prediksi yang benar. Hal ini menunjukkan bahwa model memiliki tingkat ketepatan yang baik dalam meminimalkan kesalahan prediksi positif (false positive).

Selanjutnya, nilai *Recall* sebesar 0,829703 menunjukkan bahwa model mampu mengidentifikasi sekitar 82,97% dari seluruh data yang benar-benar termasuk dalam suatu kelas. Nilai *recall* yang cukup tinggi ini mengindikasikan bahwa model memiliki kemampuan yang baik dalam menangkap data yang relevan (true positive).

Adapun nilai F1-Score sebesar 0,799237 merupakan rata-rata harmonis antara *precision* dan *recall*. Nilai ini menunjukkan bahwa model memiliki keseimbangan yang baik antara ketepatan dan kelengkapan dalam melakukan klasifikasi.

Untuk memberikan pemahaman lebih lanjut mengenai performa model dalam klasifikasi kategori latency, dilakukan evaluasi menggunakan confusion matrix yang ditampilkan pada Gambar 3



Gambar 3 Confusion Matrix Hybrid Model

Pada Gambar 3 confusion matrix menunjukkan performa model hybrid dalam mengklasifikasikan kategori latency ke dalam dua kelas, yaitu Low dan High. Berdasarkan visualisasi tersebut, dapat diketahui bahwa model mampu mengklasifikasikan data dengan cukup baik, yang ditunjukkan oleh dominasi nilai pada diagonal utama matriks. Nilai pada diagonal ini merepresentasikan prediksi yang benar, di mana terdapat 741 data dengan kategori Low latency yang berhasil diklasifikasikan dengan tepat, serta 838 data dengan kategori High latency yang juga diprediksi dengan benar.

Di sisi lain, masih terdapat sejumlah kesalahan klasifikasi yang ditunjukkan oleh nilai di luar diagonal. Sebanyak 249 data yang sebenarnya termasuk dalam kategori Low latency diprediksi sebagai High, sementara 172 data dengan kategori High latency diprediksi sebagai Low. Meskipun demikian, jumlah prediksi yang benar masih lebih dominan dibandingkan dengan kesalahan prediksi, sehingga secara keseluruhan model memiliki kemampuan klasifikasi yang cukup baik.

Distribusi nilai pada confusion matrix ini juga menunjukkan bahwa model cenderung lebih baik dalam mengenali kelas High latency dibandingkan kelas Low latency, yang terlihat dari jumlah prediksi benar pada kelas High yang lebih tinggi. Hal ini mengindikasikan bahwa model memiliki sensitivitas yang baik terhadap kondisi jaringan dengan latency tinggi, yang dalam konteks kualitas layanan jaringan

merupakan kondisi yang penting untuk dideteksi.

CONCLUSION

Bagian ini menyajikan penarikan makna umum dari hasil penelitian yang telah dilakukan. Uraian difokuskan pada jawaban atas tujuan penelitian, hubungan antar variabel yang ditemukan, serta kontribusi ilmiah yang dihasilkan. Penyampaian dilakukan secara ringkas dan langsung pada inti temuan agar mudah dipahami.

Penelitian ini menunjukkan bahwa prediksi latency pada jaringan GPON dan EPON tidak dapat dipahami hanya dari satu parameter QoS. Hasil analisis membuktikan bahwa latency berhubungan positif dengan jitter sebesar 0,82 dan packet loss sebesar 0,84, sedangkan throughput memiliki hubungan negatif yang sangat kuat sebesar -0,94. Temuan ini menegaskan bahwa perubahan pada parameter QoS bergerak bersama dan membentuk pola yang dapat digunakan untuk membaca kondisi latency secara lebih tepat. Dengan demikian, tujuan penelitian untuk memahami pola latency melalui parameter QoS telah tercapai dan memberi dasar ilmiah yang lebih kuat dalam analisis jaringan akses optik.

Penelitian ini juga membuktikan bahwa model pembelajaran mesin dapat digunakan untuk memprediksi latency dengan akurasi tinggi. Model XGBoost Regressor (Tuned) menjadi model terbaik dengan RMSE 0,460371 ms, MAE 0,359267 ms, dan R^2 0,915101. Model hybrid Stacked RF-XGB juga bekerja sangat baik dengan RMSE 0,466739 ms, MAE 0,364402 ms, dan R^2 0,912736, sedangkan Random Forest Regressor (Tuned) memperoleh RMSE 0,484631 ms, MAE 0,378514 ms, dan R^2 0,905917. Hasil klasifikasi juga mendukung temuan ini dengan Accuracy 0,789500, Precision 0,770929, Recall 0,829703, dan F1-Score 0,799237. Data tersebut menunjukkan bahwa model prediktif yang dibangun mampu menangkap pola latency secara konsisten dan layak digunakan sebagai alat analisis awal kondisi jaringan.

Kebaruan penelitian ini terletak pada penggunaan data primer dari jaringan ISP nyata, perbandingan GPON dan EPON dalam satu kerangka analisis, dan pengujian langsung antara model tunggal serta model hybrid. Kontribusi ilmiahnya terlihat pada temuan bahwa model yang lebih rumit tidak selalu menjadi pilihan terbaik, karena XGBoost tunggal justru memberi kinerja paling baik pada data ini. Penelitian ini juga memberi batas yang jelas, yaitu fitur yang digunakan masih terbatas pada jitter, throughput, dan packet loss, data hanya berasal dari satu sumber operasional, dan algoritma yang diuji masih terbatas pada Random Forest, XGBoost, serta hybrid RF-XGBoost. Batasan tersebut penting untuk

diperhatikan karena memengaruhi keluasan generalisasi hasil penelitian.

REFERENCE

- [1] E. Dritsas and M. Trigka, "Machine Learning in ICT: A Survey," *Information*, vol. 16, no. 1, p. 8, 2025, doi: 10.3390/info16010008.
- [2] Y. Nurakhov and et al., "A Machine Learning Approach to Investigating Key Influencing Factors for Network Performance in a Software-Defined 5G Architecture," *Electronics*, vol. 14, no. 19, p. 3817, 2025, doi: 10.3390/electronics14193817.
- [3] M. Sajid and et al., "Enhancing Intrusion Detection: A Hybrid Machine and Deep Learning Approach," *Journal of Cloud Computing*, vol. 13, p. 123, 2024, doi: 10.1186/s13677-024-00685-x.
- [4] G. Wassie and et al., "Traffic Prediction in SDN for Explainable QoS Using Deep Learning and XGBoost," *Scientific Reports*, vol. 13, p. 46471, 2023, doi: 10.1038/s41598-023-46471-8.
- [5] A. Wakili and et al., "Machine-learning for QoS and security enhancement of RPL in IoT networks," *Computer Networks*, vol. 229, p. 109645, 2024, doi: 10.1016/j.comnet.2024.109645.
- [6] E. Wong and et al., "Machine learning enhanced next-generation optical access networks," *Journal of Optical Communications and Networking*, vol. 15, no. 2, pp. A49–A60, 2023, doi: 10.1364/JOCN.493139.
- [7] C. Shao and et al., "Machine learning in short-reach optical systems," *Photonics*, 2024, doi: 10.3390/photonics11070613.
- [8] J. A. Hernández, A. Ebrahimzadeh, M. Maier, and D. Larrabeiti, "Learning EPON delay models from data: A machine-learning approach," *Journal of Optical Communications and Networking*, vol. 13, no. 12, pp. 322–330, 2021, doi: 10.1364/JOCN.13.000322.
- [9] M. Wang and et al., "Experimental evaluation of low-latency features in optical access networks," *Journal of Optical Communications and Networking*, 2025, doi: 10.1364/JOCN.560139.
- [10] A. F. Y. Mohammed and et al., "Dynamic bandwidth slicing in passive optical networks to support federated-learning services," *Sensors*, vol. 24, no. 15, p. 5000, 2024, doi: 10.3390/s24015000.