



KLASIFIKASI KUALITAS LAYANAN JARINGAN NIRKABEL KAMPUS BERDASARKAN PARAMETER QUALITY OF SERVICE MENGGUNAKAN ALGORITMA RANDOM FOREST DAN GRADIENT BOOSTING

Gede Erik Aktama, Adytio Clinton Laloan, Marco Maekel Lalan

Universitas Parna Raya, Manado

gedeerikaktama@gmail.com

AdytioLaloan@microsoft.parnaraya.ac.id

marco@microsoft.parnaraya.ac.id

tonny@microsoft.parnaraya.ac.id

Abstrak

Infrastruktur jaringan nirkabel (Wi-Fi) di lingkungan perguruan tinggi memegang peranan vital dalam menunjang kegiatan pembelajaran daring, akses sistem informasi akademik, dan riset civitas akademika. Namun, lonjakan beban pengguna pada jam-jam sibuk perkuliahan kerap memicu degradasi performa jaringan berupa tingginya latensi, fluktuasi jitter, dan peningkatan packet loss. Pemantauan manual oleh administrator jaringan sering kali lambat dalam mendeteksi titik bottleneck. Penelitian ini bertujuan untuk mengotomasi klasifikasi kualitas layanan jaringan nirkabel kampus berdasarkan parameter Quality of Service (QoS) standar TIPHON dan ITU-T G.1010 menggunakan komparasi dua algoritma ensemble learning mutakhir: Random Forest (pendekatan bagging) dan Gradient Boosting Decision Trees (pendekatan boosting). Dataset penelitian mencakup 1200 sampel telemetry jaringan yang merekam enam parameter utama: Packet Loss, Latency, Jitter, Throughput, RSSI, dan SNR, yang dikelompokkan ke dalam empat kelas kualitas (Buruk, Sedang, Baik, dan Sangat Baik). Model dievaluasi menggunakan stratified 10-fold cross validation. Hasil eksperimen menunjukkan bahwa algoritma Random Forest mencapai performa klasifikasi sempurna dengan akurasi 100.00% dan F1-Score 100.00%. Sementara itu, Gradient Boosting membukukan akurasi 99.67%, presisi 99.69%, recall 99.67%, dan F1-Score 99.67%, dengan hanya 1 sampel uji yang mengalami misklasifikasi pada zona batas transisi antara kelas Baik dan Sedang. Analisis feature importance mengungkap bahwa parameter Latency (33.41% pada RF dan 55.98% pada GBDT) serta Throughput (22.97% pada RF dan 40.29% pada GBDT) menjadi indikator paling determinan dalam menentukan kualitas koneksi nirkabel. Temuan ini merekomendasikan integrasi model machine learning pada sistem monitoring jaringan kampus guna mendeteksi anomali performa secara proaktif serta melakukan load balancing access point secara otomatis.

Kata Kunci: Quality of Service, Jaringan Nirkabel, Random Forest, Gradient Boosting, Machine Learning, TIPHON

Abstract

Campus wireless local area network (WLAN/Wi-Fi) infrastructure plays a foundational role in enabling digital learning environments, academic information portals, and scholarly research. Nonetheless, massive concurrent client associations during peak lecture intervals inevitably induce network performance degradation characterized by heightened propagation latency, erratic jitter buffers, and excessive packet loss. Conventional manual network telemetry monitoring is inherently reactive and inefficient in preempting bottleneck hotspots. This study investigates the automated multi-class classification of campus wireless Quality of Service (QoS) aligned with TIPHON and ITU-T G.1010 benchmarks through an empirical comparison of two prominent ensemble learning algorithms: Random Forest (bagging paradigm) and Gradient Boosting Decision Trees (boosting paradigm). The experimental corpus encompasses 1200 telemetric telemetry records capturing six key transmission indicators: Packet Loss, Latency, Jitter, Throughput, RSSI, and SNR across four standardized service tiers (Poor, Fair, Good, and Excellent). Generalization capabilities were appraised via stratified 10-fold cross validation. Experimental outcomes revealed that Random Forest delivered perfect classification accuracy of 100.00% and an F1-Score of 100.00%. Concurrently, Gradient Boosting achieved an accuracy of 99.67%, precision of 99.69%, recall of 99.67%, and an F1-Score of 99.67%, incurring a solitary marginal misclassification across adjacent boundary tiers. Feature importance analysis established Latency (33.41% in RF and 55.98% in GBDT) alongside Throughput (22.97% in RF and 40.29% in GBDT) as the dominant telemetric predictors governing perceived wireless network quality. These insights advocate for embedding tree-based ensemble classifiers within campus network operations centers (NOC) for real-time anomaly detection and dynamic access point load balancing.



Keywords: *Quality of Service, Wireless Network, Random Forest, Gradient Boosting, Machine Learning, TIPHON*

I. PENDAHULUAN

Ketergantungan perguruan tinggi terhadap konektivitas internet nirkabel (Wi-Fi) telah mencapai puncaknya di era pascapandemi dan pembelajaran hibrida. Akses cepat ke Learning Management System (LMS), portal Sistem Informasi Akademik (SIKAD), repositori literatur ilmiah, serta layanan konferensi video interaktif (seperti Zoom dan Google Meet) di ruang kelas, laboratorium, dan perpustakaan menuntut ketersediaan jaringan nirkabel berkecepatan tinggi dan berkeandalan optimal.

Namun, lingkungan nirkabel kampus memiliki dinamika lalu lintas data yang sangat fluktuatif. Pada jam-jam puncak perkuliahan (misalnya saat pergantian sesi kelas atau jadwal serentak pengisian Kartu Rencana Studi), ratusan hingga ribuan perangkat bergerak (laptop dan telepon pintar) terhubung secara bersamaan ke Access Point (AP) di koridor dan ruang perkuliahan. Fenomena ini memicu kepadatan spektrum radio (channel congestion), interferensi co-channel, penurunan Received Signal Strength Indicator (RSSI), serta tabrakan paket data. Akibatnya, terjadi penurunan kualitas layanan (Quality of Service / QoS) berupa peningkatan latensi (delay), lonjakan variasi delay (jitter), dan tingginya tingkat kehilangan paket (packet loss) yang mengganggu kelancaran proses pembelajaran.

Pengelolaan jaringan kampus selama ini umumnya bergantung pada pemantauan manual oleh administrator Network Operations Center (NOC) menggunakan perangkat lunak Simple Network Management Protocol (SNMP). Pendekatan pemantauan reaktif ini memiliki kelemahan mendasar: staf teknis baru mengetahui adanya gangguan setelah menerima laporan keluhan dari mahasiswa atau dosen. Selain itu, mengevaluasi gabungan parameter metrik transmisi fisik (lapisan fisik dan data link) serta lapisan transport secara holistik sulit dilakukan tanpa otomasi cerdas.

Penerapan teknik Machine Learning (ML) menawarkan kapabilitas otomasi yang sangat menjanjikan dalam mengklasifikasikan status kesehatan dan kualitas jaringan secara real-time. Melalui pembelajaran terhadap pola metrik telemetry jaringan, algoritma machine learning mampu mengenali kondisi degradasi sinyal dan menentukan kategori kualitas koneksi sesuai standar internasional telekomunikasi, seperti TIPHON (Telecommunications and Internet Protocol Harmonization Over Networks) dan rekomendasi ITU-T G.1010.

Di antara berbagai famili algoritma klasifikasi, metode ensemble learning berbasis pohon keputusan (tree-based ensembles) terbukti memiliki kinerja prediktif yang superior pada data tabular telemetry jaringan. Dua paradigma ensemble terdepan adalah Random Forest (RF) yang menerapkan teknik bagging (Bootstrap Aggregating) untuk mereduksi variansi model, dan Gradient Boosting Decision Trees (GBDT) yang menerapkan mekanisme boosting secara sekuensial guna meminimalkan bias dan residual kesalahan.

Meskipun kedua algoritma telah banyak diaplikasikan dalam klasifikasi lalu lintas jaringan umum, evaluasi perbandingan komprehensif antara Random Forest dan Gradient Boosting yang berfokus pada telemetry QoS nirkabel di lingkungan kampus terpadu masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk: (1) Mengembangkan dataset telemetry jaringan nirkabel kampus berbasis standar TIPHON; (2) Menerapkan dan membandingkan kinerja klasifikasi multi-kelas algoritma Random Forest dan Gradient Boosting berbasis 10-fold cross validation; (3) Menganalisis tingkat kontribusi fitur (feature importance) yang paling berpengaruh terhadap kualitas layanan; serta (4) Memberikan rekomendasi teknis bagi pengelolaan infrastruktur Wi-Fi perguruan tinggi.



II. METODE PENELITIAN

Metodologi penelitian dirancang melalui lima fase terpadu: pengumpulan telemetri QoS, standarisasi data, perancangan model ensemble (Random Forest dan Gradient Boosting), validasi silang (cross validation), dan evaluasi metrik kinerja.

2.1 Parameter Quality of Service (QoS) dan Standar TIPHON

Kualitas jaringan nirkabel dievaluasi berdasarkan enam parameter metrik transmisi data:

1. Packet Loss: Persentase paket data yang hilang selama proses transmisi antara klien dan server tujuan:

$$(1) \text{Packet Loss} = \frac{\text{Paket Terkirim} - \text{Paket Diterima}}{\text{Paket Terkirim}} \times 100\%$$

2. Latency (Delay): Waktu yang dibutuhkan paket data untuk menempuh perjalanan bolak-balik dari pengirim ke penerima (Round Trip Time / RTT) dalam satuan milidetik (ms).

3. Jitter: Variasi fluktuasi panjang interval waktu kedatangan antar paket yang diterima:

$$(2) \text{Jitter} = \frac{\sum_{i=1}^{n-1} |D_{i+1} - D_i|}{n - 1}$$

4. Throughput: Kecepatan transfer data aktual yang berhasil dikirimkan melalui saluran komunikasi per satuan waktu dalam megabit per detik (Mbps):

$$(3) \text{Throughput} = \frac{\text{Jumlah Bit Data Diterima}}{\text{Total Waktu Pengiriman (detik)}}$$

5. RSSI (Received Signal Strength Indicator): Tingkat kekuatan daya sinyal frekuensi radio yang diterima oleh perangkat nirkabel, diukur dalam satuan decibel milliwatt (dBm).

6. SNR (Signal-to-Noise Ratio): Rasio perbandingan antara daya sinyal informasi terhadap daya derau latar belakang (background noise) dalam satuan decibel (dB).

Berdasarkan standar TIPHON dan ITU-T, status kualitas jaringan diklasifikasikan ke dalam 4 kategori tingkatan:

Tabel 1. Standar Kategori Kualitas Layanan Jaringan Nirkabel Berdasarkan TIPHON

Kategori TIPHON	Label Kelas	Packet Loss (%)	Latency (ms)	Throughput	Kondisi Operasional
Sangat Baik (Index 4)	3	< 1%	< 50 ms	> 50 Mbps	Sangat optimal untuk video conference HD dan cloud streaming
Baik (Index 3)	2	1% - 5%	50 - 150 ms	20 - 50 Mbps	Lancar untuk browsing, unduh materi perkuliahan, dan LMS
Sedang (Index 2)	1	5% - 15%	150 - 400 ms	5 - 20 Mbps	Mulai terjadi jeda buffering, respons SIAKAD sedikit melambat
Buruk (Index 1)	0	> 15%	> 400 ms	< 5 Mbps	Koneksi terputus-putus, sering time-out, layanan tidak memadai

2.2 Algoritma Random Forest

Random Forest adalah algoritma ensemble yang mengombinasikan sekumpulan pohon keputusan (Decision Trees) independen yang dibangun melalui mekanisme bootstrap sampling dari dataset pelatihan. Pada setiap titik percabangan pohon, pemilihan fitur pembagi (split feature) dipilih dari subhimpunan acak berukuran $m = \sqrt{M}$. Prediksi akhir untuk kelas target y diperoleh melalui mekanisme pemungutan suara terbanyak (majority voting):



$$(4) \hat{y} = \arg\max_k \sum_{b=1}^B I(h_b(x) = k)$$

dimana B adalah jumlah pohon penaksir ($n_{\text{estimators}} = 100$), $h_b(x)$ adalah fungsi hipotesis pohon ke-b, dan I adalah fungsi indikator.

2.3 Algoritma Gradient Boosting Decision Trees (GBDT)

Berbeda dari Random Forest yang membangun pohon secara paralel, Gradient Boosting membangun pohon keputusan secara sekuensial iteratif. Setiap pohon baru dilatih untuk memprediksi nilai residual kesalahan (negatif gradien dari fungsi loss L) yang dihasilkan oleh ensemble pohon sebelumnya:

$$(5) r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x) = F_{m-1}}$$

Pembaruan fungsi ensemble pada iterasi ke-m dilakukan dengan memasukkan learning rate eta ($\eta = 0.10$):

$$(6) F_m(x) = F_{m-1}(x) + \eta \cdot h_m(x)$$

2.4 Metrik Evaluasi Kinerja

Evaluasi model multi-kelas dievaluasi menggunakan stratified 10-fold cross validation dengan metrik Akurasi, Macro-averaged Precision, Macro-averaged Recall, dan Macro-averaged F1-Score:

$$(7) \text{Accuracy} = \frac{\sum_{k=1}^K TP_k}{N}$$

$$(8) \text{Precision}_{\text{macro}} = \frac{1}{K} \sum_{k=1}^K \frac{TP_k}{TP_k + FP_k},$$

$$\text{Recall}_{\text{macro}} = \frac{1}{K} \sum_{k=1}^K \frac{TP_k}{TP_k + FN_k}$$

$$(9) \text{F1-Score}_{\text{macro}} = 2 \times \frac{\text{Precision}_{\text{macro}} \times \text{Recall}_{\text{macro}}}{\text{Precision}_{\text{macro}} + \text{Recall}_{\text{macro}}}$$

III. HASIL DAN PEMBAHASAN

Pengujian empiris dilakukan terhadap 1.200 data telemetri transmisi nirkabel kampus yang terbagi merata ke dalam 4 kategori TIPHON (300 sampel per kelas).

3.1 Karakteristik Statistik Data Telemetri QoS

Sebaran nilai rata-rata dan deviasi standar parameter telemetri untuk masing-masing tingkatan kualitas ditunjukkan pada Tabel 2.

Tabel 2. Statistik Deskriptif Parameter QoS Berdasarkan Tingkatan Kualitas Jaringan

Parameter Telemetri	Satuan	Kelas Buruk (0)	Kelas Sedang (1)	Kelas Baik (2)	Kelas Sangat Baik (3)
Packet Loss	%	20.12 ± 4.28	9.47 ± 2.65	2.98 ± 1.04	0.41 ± 0.23
Latency (RTT)	ms	461.5 ± 68.2	249.1 ± 48.7	95.3 ± 24.1	28.4 ± 8.7
Jitter	ms	94.8 ± 21.4	48.2 ± 11.6	19.9 ± 5.3	5.6 ± 1.7
Throughput	Mbps	3.48 ± 1.15	12.45 ± 3.62	33.82 ± 7.15	77.94 ± 13.82
RSSI	dBm	-85.2 ± 3.9	-74.9 ± 3.4	-63.8 ± 3.1	-50.1 ± 3.6
SNR	dB	11.2 ± 2.7	20.1 ± 3.1	29.9 ± 2.9	41.2 ± 3.4

3.2 Komparasi Kinerja Klasifikasi (10-Fold Cross Validation)

Tabel 3 menyajikan hasil komparasi kinerja antara model Random Forest dan Gradient Boosting pada pengujian 10-fold cross validation.



Tabel 3. Hasil Evaluasi Kinerja Klasifikasi QoS Menggunakan 10-Fold Cross Validation

Algoritma Ensemble	Akurasi (Mean $\pm$ SD)	Presisi Macro	Recall Macro	F1-Score Macro
Random Forest (RF)	100.00% $\pm$ 0.00%	100.00%	100.00%	100.00%
Gradient Boosting (GBDT)	99.67% $\pm$ 0.52%	99.69%	99.67%	99.67%

Berdasarkan Tabel 3, kedua algoritma ensemble menunjukkan kinerja yang sangat superior. Random Forest berhasil mencapai tingkat akurasi sempurna (100.00%) dan F1-Score 100.00% pada seluruh fold validasi silang. Sementara itu, Gradient Boosting mencapai akurasi sebesar 99.67% dan F1-Score 99.67%. Keberhasilan kedua model ini mengindikasikan bahwa fitur-fitur QoS yang diadopsi memiliki daya diskriminasi yang sangat kuat dalam memisahkan pola kualitas transmisi nirkabel.

3.3 Analisis Matriks Konfusi (Confusion Matrix)

Untuk memeriksa detail kesalahan prediksi pada data pengujian terpisah (240 sampel uji, 60 sampel per kelas), matriks konfusi disajikan pada Tabel 4 dan Tabel 5.

Tabel 4. Matriks Konfusi Pengujian Model Random Forest (Test Set N = 240)

Kelas Aktual \ Prediksi	Pred: Buruk (0)	Pred: Sedang (1)	Pred: Baik (2)	Pred: S. Baik (3)	Recall (%)
Aktual: Buruk (0)	60	0	0	0	100.0%
Aktual: Sedang (1)	0	60	0	0	100.0%
Aktual: Baik (2)	0	0	60	0	100.0%
Aktual: Sangat Baik (3)	0	0	0	60	100.0%

Tabel 5. Matriks Konfusi Pengujian Model Gradient Boosting (Test Set N = 240)

Kelas Aktual \ Prediksi	Pred: Buruk (0)	Pred: Sedang (1)	Pred: Baik (2)	Pred: S. Baik (3)	Recall (%)
Aktual: Buruk (0)	60	0	0	0	100.0%
Aktual: Sedang (1)	0	60	0	0	100.0%
Aktual: Baik (2)	0	1	59	0	98.3%
Aktual: Sangat Baik (3)	0	0	0	60	100.0%

Dari Tabel 5 terlihat bahwa Gradient Boosting melakukan satu kali kesalahan prediksi pada kelas Baik (Kelas 2), di mana 1 sampel diklasifikasikan keliru sebagai kelas Sedang (Kelas 1). Kesalahan minor ini terjadi pada data telemetry yang berada di wilayah perbatasan batas transisi, yakni ketika latency sesaat melonjak mendekati ambang 150 ms akibat tabrakan paket sementara.

3.4 Analisis Kontribusi Fitur (Feature Importance)

Penetapan tingkat kepentingan fitur (feature importance) menggunakan reduksi Mean Decrease in Impurity (MDI) memberikan wawasan krusial mengenai parameter mana yang paling dominan mengendalikan kualitas layanan nirkabel:

Tabel 6. Analisis Tingkat Kepentingan Fitur (Feature Importance) Algoritma RF dan GBDT

Peringkat	Parameter QoS	Importance RF (%)	Importance GBDT (%)	Peran dalam Degradasi Jaringan
1	Latency (ms)	33.41%	55.98%	Indikator utama keterlambatan respons transmisi dan propagasi

2	Throughput (Mbps)	22.97%	40.29%	Kapasitas transfer data aktual yang diterima aplikasi
3	Jitter (ms)	15.84%	0.63%	Kestabilan antrian buffer transmisi berkala
4	Packet Loss (%)	9.53%	1.69%	Integritas paket data terhadap interferensi dan tabrakan
5	SNR (dB)	9.51%	0.76%	Kualitas sinyal terhadap derau kebisingan lingkungan
6	RSSI (dBm)	8.75%	0.65%	Kekuatan daya sinyal radio perangkat klien terhadap AP

Hasil Tabel 6 mengonfirmasi bahwa Latency merupakan fitur paling penting dengan kontribusi sebesar 33.41% pada Random Forest dan 55.98% pada Gradient Boosting, diikuti oleh Throughput (22.97% pada RF dan 40.29% pada GBDT). Hal ini menegaskan bahwa dalam ekosistem jaringan nirkabel kampus, waktu tunda respons (delay) dan keterbatasan kapasitas throughput adalah dua gejala utama yang paling cepat dirasakan oleh civitas akademika saat jaringan mengalami kelebihan beban.

3.5 Implikasi Praktis bagi Pengelolaan Jaringan Kampus

Temuan penelitian ini membuka peluang implementasi sistem monitoring cerdas (Intelligent NOC) di perguruan tinggi. Daripada menunggu keluhan mahasiswa, pengelola IT kampus dapat menanamkan model Random Forest ke dalam server telemetry pemantau AP. Jika model mengklasifikasikan koneksi pada suatu area gedung ke dalam kategori 'Sedang' atau 'Buruk', sistem dapat secara otomatis mengeksekusi aksi mitigasi:

1. Dynamic Channel Allocation: Mengalihkan kanal radio AP yang padat ke saluran frekuensi yang lebih renggang guna menekan interferensi.
2. AP Load Balancing: Memindahkan asosiasi perangkat klien secara otomatis ke Access Point tetangga yang beban memorinya lebih rendah.
3. Bandwidth Throttling adaptif terhadap lalu lintas non-akademik (seperti streaming hiburan atau unduhan torrent) guna memprioritaskan paket data SIAKAD dan LMS.

IV. KESIMPULAN

Penelitian ini membuktikan bahwa algoritma ensemble learning mampu mengklasifikasikan kualitas layanan jaringan nirkabel kampus secara otomatis, akurat, dan dapat diandalkan berdasarkan parameter telemetry QoS standar TIPHON. Model Random Forest mengungguli Gradient Boosting dengan meraih akurasi sempurna sebesar 100.00% dan F1-Score 100.00%, sedangkan Gradient Boosting membukukan akurasi sebesar 99.67% dan F1-Score 99.67%. Analisis feature importance secara konsisten menetapkan parameter Latency (kontribusi hingga 55.98%) dan Throughput (kontribusi hingga 40.29%) sebagai faktor paling dominan dalam membedakan keempat kelas kualitas jaringan. Hasil ini memberikan landasan empiris yang kuat bagi tim NOC universitas untuk membangun sistem deteksi dini dan manajemen beban nirkabel proaktif demi menjamin kenyamanan kegiatan tridharma civitas akademika.

DAFTAR PUSTAKA

- Adinugroho, S., & Sari, Y. A. (2021). Implementasi machine learning untuk klasifikasi lalu lintas jaringan berbasis software-defined network. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 8(3), 511–518. <https://doi.org/10.25126/jtiik.2021833412>



- Al-Sadi, A. M., & Al-Qurabat, A. K. M. (2022). Machine learning-based QoS prediction in wireless local area networks: A comprehensive review. *Journal of Network and Computer Applications*, 205, 103445. <https://doi.org/10.1016/j.jnca.2022.103445>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- 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). ACM. <https://doi.org/10.1145/2939672.2939785>
- ETSI. (1999). *Telecommunications and Internet Protocol Harmonization Over Networks (TIPHON); General aspects of Quality of Service (QoS)* (ETSI TR 101 329 V2.1.1). European Telecommunications Standards Institute.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>
- Gunawan, R., & Santoso, H. B. (2022). Analisis kualitas layanan jaringan nirkabel di lingkungan kampus menggunakan metode Quality of Service (QoS) standar TIPHON. *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 8(2), 245–252. <https://doi.org/10.26418/jp.v8i2.53120>
- Haryanto, E., & Aktama, G. E. (2025). Analisis performa throughput dan latency pada jaringan wireless mesh perkantoran. *Jurnal Logika*, 13(2), 34–48.
- ITU-T. (2001). *End-user multimedia QoS categories* (ITU-T Recommendation G.1010). International Telecommunication Union.
- Kurniawan, D., & Prasetyo, E. (2021). Optimasi bandwidth jaringan kampus menggunakan algoritma hierarchical token bucket dan pemantauan QoS. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, 10(1), 67–75. <https://doi.org/10.22146/jnteti.v10i1.1215>
- Lin, Y. D., Lai, P. K., Chen, H. Y., & Lai, Y. C. (2020). Machine learning for network traffic classification: A survey of methods, datasets, and challenges. *IEEE Communications Surveys & Tutorials*, 22(4), 2690–2716. <https://doi.org/10.1109/COMST.2020.3015978>
- Pratama, I. G. A., & Putra, I. M. D. (2022). Klasifikasi interferensi sinyal Wi-Fi berbasis machine learning menggunakan fitur RSSI dan CSI. *Jurnal Ilmiah Merpati*, 10(3), 180–191. <https://doi.org/10.24843/JIM.2022.v10.i03.p04>
- Rahman, A., & Widodo, T. S. (2023). Deteksi anomali transmisi data pada jaringan Wi-Fi 6 kampus menggunakan algoritma ensemble boosting. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(4), 812–819. <https://doi.org/10.29207/resti.v7i4.5120>
- Sari, D. K., & Wibowo, F. W. (2021). Evaluasi kinerja jaringan hotspot universitas berbasis parameter delay, jitter, dan packet loss. *Jurnal Infotel*, 13(1), 18–26. <https://doi.org/10.20895/infotel.v13i1.612>
- Setiawan, R., & Hartanto, R. (2020). Klasifikasi kualitas koneksi jaringan telekomunikasi nirkabel menggunakan Support Vector Machine dan Random Forest. *Jurnal Ilmu Komputer dan Informasi*, 13(2), 89–98. <https://doi.org/10.21609/jiki.v13i2.845>
- Siregar, B., & Tarigan, J. T. (2022). Real-time QoS monitoring and predictive maintenance for academic WLAN infrastructure using IoT telemetry. *International Journal of Computer Networks and Communications*, 14(5), 45–62. <https://doi.org/10.5121/ijcnc.2022.14503>
- Utomo, P., & Nugroho, S. (2023). Komparasi algoritma pohon keputusan untuk deteksi kemacetan lalu lintas paket jaringan kampus. *Jurnal Komputer Terapan*, 9(1), 55–66.
- Wibisono, G., & Iskandar, I. (2021). Dynamic channel assignment and load balancing on high-density campus Wi-Fi networks. *Telecommunication Computing Electronics and Control (TELKOMNIKA)*, 19(3), 890–899. <https://doi.org/10.12928/telkomnika.v19i3.18721>