

Implementasi AI untuk Analisis Penggunaan *Bandwidth*

Mika M. F. Simanullang^{1*}, Dedy Kiswanto², Sirlia Sahid³, Maissy Angelica Pakpahan⁴

^{1*,2,3,4}Universitas Negeri Medan

*Email: simanullangmika6@gmail.com

Abstract

Increasing internet service demands make bandwidth analysis important for understanding network conditions. This study developed a Streamlit-based application integrating K-Means clustering, Isolation Forest, rule-based activity identification, and SNMP monitoring. The Adaptive Bandwidth Prediction Dataset comprised 8,653 records and nine original network attributes, of which throughput, jitter, and actual bandwidth were standardized as clustering features. Three clusters ($k = 3$) were specified for operational interpretation, producing 2,786 Low records (32.20%), 3,173 Medium records (36.67%), and 2,694 High records (31.13%). The model obtained a Silhouette Score of 0.2425, indicating limited separation between clusters. The Medium group had the highest mean throughput (8.12 Mbps), while the High group had the highest mean actual bandwidth (7.65 Mbps), showing that both attributes did not increase consistently across the categories. The dashboard displays clustering outputs, anomaly flags, network-condition indicators, and configurable SNMP monitoring. Its main contribution is the integration of analytical functions into one interface, rather than a new algorithm. Additional tests of alternative k values, external CSV processing, and measurement agreement with physical network devices remain necessary.

Keywords: Bandwidth analysis, k-means, network traffic, anomaly detection, streamlit

Abstrak

Peningkatan kebutuhan layanan internet menuntut analisis *bandwidth* yang mampu menjelaskan karakteristik lalu lintas dan kondisi jaringan. Penelitian ini mengembangkan aplikasi berbasis *Streamlit* yang mengintegrasikan *K-Means Clustering*, *Isolation Forest*, identifikasi aktivitas berbasis aturan, dan monitoring SNMP. *Adaptive Bandwidth Prediction Dataset* terdiri atas 8.653 data dengan sembilan atribut awal; *throughput*, *jitter*, dan *actual bandwidth* digunakan sebagai fitur pengelompokan setelah standarisasi. Jumlah klaster ditetapkan tiga ($k = 3$) untuk kebutuhan interpretasi, menghasilkan kategori Rendah sebanyak 2.786 data (32,20%), Sedang 3.173 data (36,67%), dan Tinggi 2.694 data (31,13%). Evaluasi menghasilkan *Silhouette Score* 0,2425 yang mengindikasikan pemisahan antarklaster masih terbatas. Kategori Sedang memiliki rata-rata *throughput* tertinggi (8,12 Mbps), sedangkan kategori Tinggi mempunyai rata-rata *actual bandwidth* tertinggi (7,65 Mbps), sehingga kedua parameter tersebut tidak menunjukkan kenaikan yang searah pada setiap kategori. *Dashboard* menyajikan hasil pengelompokan, penandaan anomali, indikator kondisi jaringan, dan konfigurasi monitoring SNMP. Kontribusi penelitian terletak pada integrasi beberapa fungsi analisis, bukan pengembangan algoritma baru. Pengujian nilai k alternatif, pemrosesan CSV eksternal, serta kesesuaian pengukuran dengan perangkat jaringan nyata masih diperlukan.

Kata kunci: Analisis *Bandwidth*, K-Means, Lalu Lintas Jaringan, Deteksi Anomali, *Streamlit*.

1. Pendahuluan

Kebutuhan konektivitas internet meningkat seiring penggunaan layanan pendidikan daring, konferensi video, komunikasi, dan distribusi konten digital. Ketika sejumlah perangkat mengakses jaringan secara bersamaan, perubahan beban trafik dapat memengaruhi kualitas layanan. Pengelolaan bandwidth karena itu tidak cukup hanya mengamati kapasitas, tetapi juga perlu mempertimbangkan parameter kinerja jaringan [1], [2].

Throughput menunjukkan laju data yang berhasil dikirimkan, sedangkan *latency*, *jitter*, dan *packet loss* menggambarkan aspek lain dari proses pengiriman paket. Keempat parameter tersebut dapat berubah dengan pola yang berbeda. Sebuah jaringan dapat memiliki nilai bandwidth aktual tinggi, tetapi belum tentu menunjukkan *throughput* tinggi atau kualitas layanan yang konsisten [3], [4].

Pemantauan jaringan secara konvensional umumnya menampilkan penghitung trafik dan grafik penggunaan. Informasi tersebut bermanfaat untuk observasi, tetapi tidak langsung menjelaskan kelompok pola penggunaan atau pengamatan yang menyimpang. Analisis berbasis pembelajaran mesin dapat membantu mengenali struktur trafik melalui pengelompokan data dan deteksi anomali [5]–[9]. Metode tanpa pengawasan relevan ketika label kondisi jaringan tidak tersedia secara lengkap [10].

Fahmi dan Fajri [11] serta Budiati dkk. [12] menunjukkan penerapan K-Means pada data trafik jaringan untuk tujuan analisis yang berbeda. Pada pengembangan sistem, aspek visualisasi dan pencatatan data turut dibahas oleh Silalahi dkk. [13], sementara pengembangan analisis trafik melalui beragam metode dipaparkan pada kajian terkait [14], [15]. Penggunaan SNMP sebagai dasar pengamatan trafik jaringan juga telah diterapkan pada penelitian terdahulu [16].


Berdasarkan kebutuhan tersebut, penelitian ini mengembangkan aplikasi analisis penggunaan bandwidth berbasis *Streamlit* yang menggabungkan K-Means, *Isolation Forest*, analisis aktivitas berbasis aturan, dan modul

SNMP. Fokus kajian diarahkan pada hasil pengelompokan, interpretasi keluaran setiap modul, dan keterbatasan bukti evaluasi yang tersedia. Integrasi fitur tidak diperlakukan sebagai bukti bahwa kinerja sistem lebih unggul daripada penelitian lain tanpa pengujian pembandingan.

2. Metoda Penelitian


Penelitian ini menggunakan pendekatan eksperimental berbasis pengolahan data jaringan dan implementasi perangkat lunak. Tahapan penelitian meliputi penyiapan dataset, pemilihan fitur, standardisasi, pelatihan model, evaluasi pengelompokan, serta integrasi keluaran ke dalam aplikasi. Pengembangan antarmuka menggunakan Python, *Streamlit*, dan pustaka visualisasi *Plotly*.

2.1. Perancangan Sistem



Gambar 1. Alur Kerja Pemrosesan Data Sistem Analisis Bandwidth Berbasis AI

Gambar 1 memperlihatkan urutan pemrosesan data mulai dari pemeriksaan input dan penyiapan fitur, standardisasi, pengelompokan menggunakan *K-Means*, hingga penyajian hasil. Proses identifikasi anomali merupakan komponen terpisah yang melengkapi analisis karakteristik penggunaan bandwidth.



Gambar 2. Alur Kerja Sistem Aplikasi Analisis Bandwidth Berbasis AI

Gambar 2 menunjukkan hubungan antara modul dalam aplikasi. Pengguna dapat memeriksa *dashboard*, memasukkan data jaringan secara manual, mengunggah dataset CSV, atau membuka halaman monitoring SNMP. Setiap modul menyajikan informasi yang sesuai dengan jenis masukan dan aturan pemrosesan masing-masing.

2.2. Dataset dan Prapemrosesan

Data yang digunakan adalah *Adaptive Bandwidth Prediction Dataset* dari Kaggle, sebagaimana dilaporkan pada dokumen penelitian awal. Data terdiri atas 8.653 catatan lalu lintas jaringan dan sembilan atribut, yaitu *receiving_rate*, *packet_delay*, *packet_loss_ratio*, *rtt*, *bandwidth_usage*, *throughput*, *error_rate*, *jitter*, serta *actual_bandwidth*. Dokumen sumber

melaporkan tidak adanya nilai hilang. Tiga atribut, yaitu *throughput*, *jitter*, dan *actual_bandwidth*, dipilih sebagai fitur *K-Means* berdasarkan relevansinya terhadap karakteristik trafik, tanpa mengklaim adanya uji korelasi yang belum disajikan hasilnya.

Menurut statistik deskriptif pada laporan penelitian awal, rata-rata *throughput* adalah 5.209.315 bps, *actual_bandwidth* 4.997.107 bps, dan *jitter* 49,993 ms. Ketiga fitur dinormalisasi menggunakan *StandardScaler* agar perbedaan satuan bps dan milidetik tidak mendominasi perhitungan jarak Euclidean. Jumlah atribut awal harus dibedakan dari jumlah fitur model maupun jumlah kolom DataFrame yang ditampilkan setelah proses aplikasi.

2.3. Implementasi K-Means dan Evaluasi

Algoritma *K-Means* dikonfigurasi dengan tiga kluster ($k = 3$), sesuai kebutuhan interpretasi penggunaan bandwidth menjadi kategori Rendah, Sedang, dan Tinggi. Parameter *n_init* dilaporkan sebesar 10 pada rancangan awal. Sesudah model dilatih, kategori ditetapkan berdasarkan nilai rata-rata *actual_bandwidth* setiap kluster, bukan semata-mata berdasarkan nilai *throughput* atau *jitter*.

Evaluasi menggunakan *Silhouette Score* dengan rentang -1 hingga $+1$. Semakin tinggi nilainya, semakin baik kecenderungan pemisahan dan kekompakan kelompok. Dalam penelitian ini $k = 3$ ditetapkan sebagai pilihan operasional. Belum tersedia dataset dan kode pelatihan yang memungkinkan replikasi pengujian k lain, sehingga naskah ini tidak menyatakan bahwa $k = 3$ merupakan konfigurasi optimal.

2.4. Modul Analisis Tambahan

Isolation Forest digunakan untuk menandai pengamatan yang relatif menyimpang, dengan *contamination* 0,08 pada rancangan penelitian awal. Fitur yang digunakan mencakup *actual_bandwidth*, *throughput*, *jitter*, *rtt*, dan *packet_loss_ratio*. Identifikasi aktivitas seperti *Browsing* atau *Streaming* dilakukan berdasarkan aturan, bukan


model klasifikasi yang telah diverifikasi dengan data aktivitas berlabel. *Network Health Score* merupakan indikator yang dihitung menurut ketentuan aplikasi.

Modul SNMP ditujukan untuk membaca penghitung trafik, termasuk *ifInOctets* dan *ifOutOctets*, pada perangkat yang menyediakan layanan SNMP. Perubahan penghitung antarsampel dapat digunakan untuk menghitung laju trafik berdasarkan interval pengamatan. Apabila modul dioperasikan dalam simulasi, keluaran simulasi tidak diperlakukan sebagai bukti akurasi pengukuran pada perangkat nyata.

3. Hasil Penelitian

3.1. Implementasi Sistem

Sistem berhasil dibangun sebagai aplikasi berbasis *Streamlit* yang menyajikan indikator trafik, hasil pengelompokan, analisis input manual, unggahan CSV, dan konfigurasi monitoring SNMP. Integrasi ini menyediakan satu antarmuka untuk menelusuri beberapa keluaran analisis, meskipun masing-masing modul menggunakan sumber data dan dasar perhitungan berbeda.



Gambar 3. *Dashboard* Utama Sistem Analisis Penggunaan *Bandwidth* Berbasis AI

Gambar 3 memperlihatkan indikator download, upload, *throughput*, *latency*, *jitter*, *packet loss*, dan *Network Health Score*. Perbedaan parameter tersebut perlu dibaca bersama karena kategori penggunaan *bandwidth* tidak otomatis mencerminkan kualitas jaringan secara keseluruhan. *Network Health Score* dan *Network Mood* merupakan penilaian berbasis aturan aplikasi, sehingga validitasnya harus dibedakan dari hasil pengukuran independen.

3.2. Hasil Pelatihan Model *K-Means Clustering*

Pelatihan *K-Means* pada 8.653 catatan menggunakan tiga fitur terstandarisasi menghasilkan tiga kategori penggunaan *bandwidth*. Ringkasan konfigurasi dan nilai evaluasi ditampilkan dalam Tabel 1. Jumlah fitur masukan tidak sama dengan jumlah kluster yang dibentuk, meskipun keduanya bernilai tiga pada penelitian ini.

Tabel 1. Ringkasan Pelatihan Model

Parameter	Nilai
Jumlah data	8.653
Atribut awal	9
Fitur <i>K-Means</i>	3
Jumlah kluster (<i>k</i>)	3
Silhouette Score	0,2425


Sebanyak 2.786 catatan atau 32,20% termasuk kategori Rendah, 3.173 catatan atau 36,67% kategori Sedang, dan 2.694 catatan atau 31,13% kategori Tinggi. Ukuran kelompok relatif seimbang, tetapi keseimbangan ini tidak membuktikan adanya batas pemisahan yang kuat. Tabel 2 memperlihatkan rata-rata fitur setiap kategori berdasarkan hasil penelitian awal.

Tabel 2. Karakteristik Hasil Pengelompokan *Bandwidth*

Parameter	Rendah	Sedang	Tinggi
Jumlah data	2.786	3.173	2.694
<i>Throughput</i> (Mbps)	3,66	8,12	3,39
<i>Jitter</i> (ms)	48,46	51,46	49,85
<i>BW</i> aktual (Mbps)	2,28	5,13	7,65

Rata-rata *actual_bandwidth* meningkat dari 2,28 Mbps pada kategori Rendah menjadi 5,13 Mbps pada Sedang dan 7,65 Mbps pada Tinggi. Namun, *throughput* tidak mengikuti urutan tersebut. Kategori Sedang justru mencatat *throughput* tertinggi sebesar 8,12 Mbps, sekitar 2,40 kali kategori Tinggi yang hanya mencapai 3,39 Mbps. Temuan ini menegaskan bahwa label Rendah, Sedang, dan Tinggi terutama menggambarkan urutan *actual_bandwidth*, bukan peringkat keseluruhan kinerja jaringan.

Rata-rata *jitter* antarklaster berdekatan, yaitu 48,46–51,46 ms, tetapi kedekatan rata-rata tidak membuktikan bahwa *jitter* tidak memengaruhi proses *clustering*. Penilaian kontribusi setiap fitur masih memerlukan distribusi dalam klaster dan nilai centroid terstandarisasi. *Silhouette Score* 0,2425 mengindikasikan pemisahan antarklaster masih terbatas. Karena data tidak memiliki label kelas rujukan dalam evaluasi ini, keberhasilan setiap data memperoleh klaster juga tidak dapat disebut akurasi 100%.



Dataset Training

Baris: 12

Skor Silhouette: 0.2425

Data Awal

	1	2	3	4	5	6	7	8	9	10	11	12
1	451008	75127	15782	10497	1576	72284	3302	40437	53885	1	1	1
2	48938	11398	1089	104293	1576	40437	1117	91175	93385	2	1	1
3	49432	104889	100	104293	1089	11398	1089	11398	41284	3	1	1
4	251490	104889	100	104293	1089	11398	1089	11398	41284	4	1	1
5	163490	104889	100	104293	1089	11398	1089	11398	41284	5	1	1
6	163490	104889	100	104293	1089	11398	1089	11398	41284	6	1	1
7	163490	104889	100	104293	1089	11398	1089	11398	41284	7	1	1
8	163490	104889	100	104293	1089	11398	1089	11398	41284	8	1	1
9	163490	104889	100	104293	1089	11398	1089	11398	41284	9	1	1
10	163490	104889	100	104293	1089	11398	1089	11398	41284	10	1	1
11	163490	104889	100	104293	1089	11398	1089	11398	41284	11	1	1
12	163490	104889	100	104293	1089	11398	1089	11398	41284	12	1	1

Gambar 4. Halaman Dataset Training dan Hasil *Clustering*


Gambar 4 memperlihatkan modul *Dataset Training* yang menampilkan tabel berjumlah 12 kolom, sedangkan dataset sumber dijelaskan memiliki sembilan atribut awal. Kedua angka tersebut merujuk pada struktur data di tahap yang berbeda: sembilan merupakan jumlah atribut pada dataset sumber, sementara 12 merupakan jumlah kolom yang terlihat pada tabel di dashboard. Angka 12 juga tidak menunjukkan jumlah fitur K-Means karena model hanya menggunakan *throughput*, *jitter*, dan *actual bandwidth*.

Selisih tiga kolom tersebut belum dapat diidentifikasi secara pasti tanpa membandingkan daftar nama kolom pada data awal dengan data yang ditampilkan aplikasi. Oleh karena itu, identitas dan fungsi ketiga kolom pembeda perlu dikonfirmasi dari kode pengolahan sebelum dinyatakan sebagai kolom hasil pemrosesan.

3.3. Hasil Analisis Data

Sistem menyediakan analisis melalui input manual dan unggahan dataset CSV. Pada contoh input manual, aplikasi menghasilkan kategori bandwidth Rendah, estimasi aktivitas

Browsing, *Network Health Score* 84/100, *Network Mood* Calm, dan status Stabil. Keberagaman keluaran tersebut menunjukkan bahwa penilaian karakteristik *bandwidth* dan penilaian kondisi jaringan menggunakan aturan yang berbeda.



Analisis Bandwidth dengan Input Manual

Throughput: 10000, Latency: 100, Packet Loss: 100


Hasil Analisis:

Kategori Bandwidth	Estimasi Aktivitas	Health Score	Status
Rendah	Browsing	Calm	84/100

Gambar 5. Halaman Analisis Menggunakan Input Manual

Gambar 5 memperlihatkan bahwa label Rendah dapat muncul bersamaan dengan status Stabil. Kondisi ini tidak kontradiktif karena kategori pengelompokan ditentukan oleh karakteristik fitur model, sedangkan *Health score* dipengaruhi parameter lain menurut aturan aplikasi. Label *Browsing* merupakan estimasi aktivitas, bukan hasil pengamatan langsung aplikasi yang dipakai pengguna. Karena itu, ketepatan kategori aktivitas dan *health score* belum dapat dinyatakan tervalidasi hanya dari satu *screenshot*.

Fitur kedua menerima data berbentuk CSV untuk diproses sebagai kumpulan pengamatan. Keberadaan fitur unggah memperluas bentuk masukan, tetapi kualitas hasil bergantung pada nama kolom, satuan, tipe data, dan penggunaan transformasi fitur yang sama dengan pelatihan.



Analisis Bandwidth dengan Upload Dataset CSV

Dataset yang Diupload:

Throughput	Latency	Packet Loss
10000	100	100
10000	100	100
10000	100	100
10000	100	100
10000	100	100

Hasil Analisis Dataset Baru

Kategori Bandwidth	Estimasi Aktivitas	Health Score	Status
Rendah	Browsing	Calm	84/100


Gambar 6. Halaman Analisis Menggunakan Upload Dataset CSV

Gambar 6 memperlihatkan antarmuka unggah dan tabel hasil yang dapat ditampilkan. Tangkapan layar ini tidak menyediakan catatan uji yang cukup untuk mengukur persentase

berkas berhasil diproses atau ketahanan terhadap masukan tidak valid. Untuk mengukur keandalannya diperlukan pengujian terhadap CSV valid, kolom hilang, tipe data salah, dan perbedaan satuan. Oleh karena itu, hasil yang dilaporkan terbatas pada keberadaan mekanisme dan visualisasi pemrosesan.

3.4. Hasil Monitoring *Real-Time* Menggunakan SNMP


Modul SNMP menyediakan konfigurasi untuk komunikasi dengan perangkat jaringan serta tampilan indikator download, upload, dan perubahan trafik berdasarkan interval pengamatan. Rancangan sistem menyebut penggunaan perangkat MikroTik sebagai salah satu sumber yang dituju dalam pengujian.



Gambar 7. Halaman Konfigurasi Monitoring Real-Time SNMP

Gambar 7 menunjukkan alamat dan parameter koneksi yang dapat diatur sebelum proses monitoring. Keberadaan halaman konfigurasi membuktikan dukungan pengaturan akses SNMP, tetapi tidak dengan sendirinya membuktikan bahwa setiap pengaturan sudah berhasil menghasilkan komunikasi dengan perangkat. Keberhasilan komunikasi seharusnya diperiksa melalui respons perangkat dan catatan pembacaan.

Gambar 8 memperlihatkan indikator dan grafik trafik yang berubah dari waktu ke waktu. Grafik membantu mengenali fluktuasi pengamatan, sedangkan indikator menampilkan nilai pada saat pembacaan. Namun, berkas yang tersedia belum menyertakan pasangan data penghitung mentah SNMP, interval pengambilan sampel, dan pengukuran pembandingan dari perangkat MikroTik.



Gambar 8. Hasil Monitoring Bandwidth Real-Time Menggunakan SNMP

Dengan demikian, gambar tersebut mendukung keberadaan visualisasi monitoring, tetapi belum cukup sebagai dasar untuk mengklaim ketepatan pengukuran pada jaringan nyata.

3.5. Perbandingan dengan Penelitian Terdahulu

Fahmi dan Fajri [11] serta Budiati dkk. [12] menerapkan *K-Means* untuk analisis trafik jaringan, sedangkan penelitian ini menggunakan tiga fitur untuk membuat kategori bandwidth dan mengintegrasikannya dengan modul analisis lain. Miftahuddin dan Ridwan [17] melaporkan peningkatan Silhouette Index dari 0,321 menjadi 0,773 pada pengujian pertama melalui kombinasi SOM dan *K-Means*. Skor penelitian ini sebesar 0,2425 menunjukkan kebutuhan penguatan evaluasi, tetapi angka lintas penelitian tersebut tidak dapat dibandingkan sebagai ukuran keunggulan langsung karena data dan eksperimennya berbeda.

Feng dkk. [9] menggunakan X-iForest dengan pengujian AUC dan tingkat deteksi anomali, sedangkan penelitian ini baru melaporkan penandaan anomali dengan parameter contamination yang telah ditentukan. Alhilali dkk. [16] menguji pengelolaan trafik melalui SNMP, sementara penelitian ini menampilkan modul serupa sebagai bagian dari *dashboard* terintegrasi. Kontribusinya terletak pada penggabungan beberapa fungsi, dengan keterbatasan pada validasi pemisahan kluster, penandaan anomali, dan akurasi monitoring.

4. Kesimpulan

Aplikasi analisis penggunaan *bandwidth* berbasis *Streamlit* berhasil dikembangkan dengan mengintegrasikan *K-Means*, *Isolation Forest*, penilaian kondisi jaringan, dan modul SNMP. Pengelompokan 8.653 data menghasilkan kategori Rendah 32,20%, Sedang 36,67%, dan Tinggi 31,13%. Silhouette Score 0,2425 menunjukkan bahwa pemisahan antarkluster masih terbatas. Kategori Sedang memiliki throughput rata-rata tertinggi, sedangkan kategori Tinggi memiliki *actual_bandwidth* rata-rata tertinggi. Hasil tersebut mendukung penggunaan sistem untuk eksplorasi karakteristik trafik, namun belum membuktikan konfigurasi kluster optimal maupun keandalan semua modul pada lingkungan operasional nyata

5. Saran

Penelitian selanjutnya perlu menguji beberapa nilai *k* dengan metrik yang sama dan melaporkan konfigurasi pelatihan secara lengkap, termasuk kode dan dataset. Pengujian CSV eksternal serta validasi hasil deteksi anomali menggunakan data berlabel juga diperlukan. Pada modul SNMP, pengukuran hendaknya dibandingkan dengan penghitung perangkat fisik menggunakan interval sampel yang terdokumentasi. Identitas kolom hasil pemrosesan yang menyebabkan tampilan berjumlah 12 kolom harus ditelusuri dan dijelaskan dalam dokumentasi data.

6. Daftar Pustaka

- [1] K. Somsuk, S. Khummanee, and P. Songram, "Dynamic Predictive Feedback Mechanism for Intelligent Bandwidth Control in Future SDN Networks," *Network*, vol. 5, no. 4, 2025, doi: 10.3390/network5040054.
- [2] L. O. Sari, H. A. Suri, E. Safrianti, and F. Jalil, "Rancang Bangun Sistem Monitoring Bandwidth Server pada PT. Industri Kreatif Digital," *MALCOM*, vol. 3, no. 2, pp. 168–179, 2023, doi: 10.57152/malcom.v3i2.914.
- [3] A. S. Ningsih, Subardin, and Gunawan, "Analisis Kinerja Jaringan Wireless LAN Menggunakan Metode QoS dan RMA," *AnoaTIK*, vol. 1, no. 1, 2023.
- [4] E. Safrianti, L. O. Sari, and N. A. Sari, "Real-Time Network Device Monitoring System with Simple Network Management Protocol (SNMP) Model," in *Proc. ICRACOS*, pp. 122–127, 2021.
- [5] J. Koumar, K. Hynek, J. Pešek, and T. Čejka, "NetTiSA: Extended IP flow with time-series features for universal bandwidth-constrained high-speed network traffic classification," *Computer Networks*, vol. 240, Art. 110147, 2024, doi: 10.1016/j.comnet.2023.110147.
- [6] J. Koumar, T. Smoleň, K. Jeřábek, and T. Čejka, "Comparative Analysis of Deep Learning Models for Real-World ISP Network Traffic Forecasting," 2025. [Online]. Available: <https://arxiv.org/abs/2503.17410>.
- [7] E. Zadeh et al., "Automated Contextual Anomaly Detection for Network Interface Bandwidth Utilisation: A Case Study in Network Capacity Management," in *Frontiers in Artificial Intelligence and Applications*, pp. 659–666, 2021, doi: 10.3233/FAIA210459.
- [8] K. A. Nugroho, "Deteksi Anomali Trafik Jaringan dan Aktivitas Pengguna Menggunakan Isolation Forest untuk Meningkatkan Keamanan Jaringan," *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 5, no. 5, pp. 1365–1376, 2025, doi: 10.52436/1.jpti.790.
- [9] Y. Feng et al., "An improved X-means and isolation forest based methodology for network traffic anomaly detection," *PLOS ONE*, vol. 17, no. 1, e0263423, 2022, doi: 10.1371/journal.pone.0263423.
- [10] V. Chandola, A. Banerjee, and V. Kumar, "Anomaly Detection: A Survey," *ACM Computing Surveys*, vol. 41, no. 3, Art.

- 15, 2009, doi: 10.1145/1541880.1541882.
- [11] M. Fahmi and A. Fajri, "Analisis Clustering Trafik Jaringan Menggunakan Metode K-Means," *Buletin Poltanesa*, vol. 23, no. 2, 2022, doi: 10.51967/tanesa.v23i2.1736.
- [12] H. Budiati, A. B. M. Wijaya, B. S. V. Zebua, Jatmika, and Y. P. Sumihar, "Implementation of K-Means Clustering Method for Network Traffic Anomaly Detection," *Jurnal Mantik*, vol. 6, no. 3, 2022.
- [13] E. K. Silalahi, D. Kiswanto, F. Suleho, and C. K. Panjaitan, "Pengembangan Sistem Logging Jaringan Berbasis Web Untuk Deteksi Anomali Secara Real-Time," *Jurnal Sistem Komputer dan Kecerdasan Buatan*, vol. 9, no. 3, pp. 399–408, 2026, doi: 10.47970/siskom-kb.v9i3.959.
- [14] A. Thakkar and R. Logiya, "A survey on intrusion detection system: feature selection, model, performance measures, application perspective, challenges, and future research directions," *Artificial Intelligence Review*, vol. 55, no. 1, pp. 453–563, 2022.
- [15] M. Shen et al., "Machine Learning-Powered Encrypted Network Traffic Analysis: A Comprehensive Survey," *IEEE Communications Surveys & Tutorials*, vol. 25, no. 1, pp. 791–824, 2023, doi: 10.1109/COMST.2022.3208196.
- [16] A. H. Alhilali, A. Al Farawn, and A. Y. Mjhool, "Design and implement a real-time network traffic management system using SNMP protocol," *Eastern-European Journal of Enterprise Technologies*, vol. 5, no. 9(125), pp. 35–44, 2023, doi: 10.15587/1729-4061.2023.286528.
- [17] Y. Miftahuddin and A. R. S. Ridwan, "Application of Self-Organizing Map and K-Means to Cluster Bandwidth Usage Patterns in Campus Environment," *JOIN: Jurnal Online Informatika*, vol. 10, no. 1, pp. 66–76, 2025, doi: 10.15575/join.v10i1.1438.