

PENERAPAN DEEP LEARNING DENGAN *ATTENTION MECHANISM* PADA PERAMALAN TRAFIK JARINGAN UNTUK MANAJEMEN QoS ADAPTIF

(Application of Deep Learning with Attention Mechanism on Network Traffic Forecasting for Adaptive QoS Management)

Muhammad Farhan Zul Fahmi^[1], Bambang Krismono Triwijoyo^[2], Neny Sulistianingsih^[3]

^[1,2,3]Program Studi Magister Ilmu Komputer, Universitas Bumigora

Jl. Ismail Marzuki No.22, Cilinaya, Cakranegara, Mataram, Nusa Tenggara Barat, INDONESIA

Email: farhanzulfbusiness@gmail.com, bambang.krismono@universitasbumigora.ac.id,
neny.sulistianingsih@universitasbumigora.ac.id

Abstract

Static Quality of Service (QoS) management in government network infrastructures often fails to dynamically adapt bandwidth allocation to fluctuating and non-linear traffic conditions. This study develops an adaptive QoS management system based on a Hybrid Long Short-Term Memory (LSTM)-Attention model for network traffic forecasting at the Communication and Information Technology Office (Diskominfo) of Lombok Barat Regency, serving approximately 200 Regional Government Organization (OPD) users with 700 Mbps dedicated 1:1 ISP capacity. A dataset of 43,488 data points was collected from the WAN interface of a MikroTik Router via RouterOS API during January–May 2026 at 5-minute intervals. The preprocessing pipeline included Z-Score outlier detection with capping, Min-Max Scaling normalization, and Sliding Window transformation (timestep = 60). The model architecture consists of two stacked LSTM layers (128 and 64 units) and one custom Attention Layer, totaling 122,241 trainable parameters, with a sequential 70/15/15 train-validation-test split. Evaluation on the testing set (May 2026) yielded RMSE of 43.66 Mbps and MAE of 27.96 Mbps for download traffic (RX), and RMSE of 30.72 Mbps and MAE of 19.66 Mbps for upload traffic (TX). MAPE values of 19.64% (RX) and 17.95% (TX) fall in the "Good" category. The model outperformed the ARIMA baseline on three of four evaluation metrics, with RMSE improvement of 16.7% and MAE improvement of 28.8%, while MAPE was marginally higher (+1.00 point) than ARIMA, a nuance attributable to the differing sensitivity of scale-dependent versus percentage-based metrics; an ablation study further confirmed the Attention layer's contribution is asymmetric, consistently improving accuracy on upload (TX) traffic and substantially reducing training variance on both signals (62.5–83.1% lower standard deviation across seeds) at a marginal parameter cost (+3.5%). Integration with MikroTik Queue Tree via RouterOS API successfully executed 603 automated adaptive cycles, achieving 26.7% throughput increase, 37.0% delay reduction, 59.3% packet loss reduction, and 49.6% jitter reduction compared to conventional static QoS management.

Keywords: Deep Learning, Hybrid LSTM-Attention, Adaptive QoS Management, Network Traffic Forecasting, RouterOS API, Queue Tree MikroTik

1. PENDAHULUAN

Infrastruktur jaringan komputer pada instansi pemerintahan menghadapi tantangan pengelolaan *bandwidth* yang semakin kompleks seiring meningkatnya adopsi layanan digital berbasis internet. Dinas Komunikasi dan Informatika (Diskominfo) Kabupaten Lombok Barat sebagai pusat konektivitas data bagi sekitar 200 pengguna dari berbagai Organisasi Perangkat Daerah (OPD) mengoperasikan jaringan dengan kapasitas ISP Pop Net 700 Mbps *dedicated 1:1* melalui Router MikroTik. Kondisi ini menuntut manajemen *bandwidth* yang optimal agar

seluruh layanan pemerintahan berbasis digital dapat berjalan tanpa hambatan [1].

Permasalahan utama yang dihadapi adalah pendekatan manajemen Quality of Service (QoS) yang masih bersifat statis, menetapkan batas *bandwidth* tetap per pengguna tanpa mempertimbangkan kondisi trafik aktual yang berubah secara dinamis. Akibatnya, terjadi dua masalah bersamaan: pemborosan kapasitas *bandwidth* pada periode *off-peak* dan kemacetan (*congestion*) pada jam puncak aktivitas OPD, yang berdampak pada peningkatan *delay*, *packet loss*, dan

jitter yang mengganggu kualitas layanan komunikasi *real-time* [2], [3].

Perkembangan *Deep Learning* dalam beberapa tahun terakhir membuka peluang baru untuk mengatasi keterbatasan tersebut. Model berbasis Long Short-Term Memory (LSTM) terbukti efektif dalam menangkap ketergantungan temporal jangka panjang pada data *time series* jaringan berkat mekanisme *gating* yang canggih [4]. Penambahan *Attention mechanism* pada arsitektur LSTM lebih lanjut meningkatkan kemampuan prediktif dengan memberikan bobot dinamis pada informasi historis yang paling relevan [5], [6].

Beberapa penelitian terdahulu telah mengeksplorasi pemanfaatan *Deep Learning* untuk peramalan trafik jaringan. Zhao & He [7] mengembangkan NTAM-LSTM yang mengintegrasikan *attention mechanism* dengan LSTM dan melaporkan akurasi prediksi lebih tinggi dibanding model tradisional. Zhang dkk. [8] mengusulkan model CSTCN-Transformer yang menggabungkan CBAM, TCN, dan Transformer untuk prediksi trafik jaringan kota dengan peningkatan akurasi signifikan. Jia dkk. [9] mengembangkan model hybrid *Deep Learning* untuk prediksi trafik jaringan 5G. Wassie dkk. [15] mengembangkan model prediksi trafik pada Software-Defined Networking (SDN) yang menekankan aspek *explainability* hasil prediksi namun tanpa eksekusi kebijakan QoS otomatis pada perangkat nyata, sedangkan Bi dkk. [16] mengusulkan model hybrid TCN-LSTM yang terbukti unggul dalam akurasi prediksi trafik skala besar namun tetap berhenti pada tahap evaluasi *offline*. Kelima penelitian tersebut [7]-[9], [15]-[16] secara konsisten menunjukkan pola yang sama: seluruhnya berfokus pada peningkatan akurasi prediksi atau interpretabilitas model, namun tidak satupun menutup siklus dari keluaran prediksi menuju eksekusi kebijakan QoS secara otomatis pada perangkat jaringan fisik yang sedang beroperasi. Celah teknis inilah - putusnya rantai antara prediksi dan aksi nyata pada perangkat - yang menjadi *research gap* utama penelitian ini, dengan infrastruktur MikroTik pada instansi pemerintah daerah Indonesia - khususnya Diskominfo Kabupaten Lombok Barat - berfungsi sebagai konteks studi kasus penerapan, bukan sebagai definisi celah penelitian itu sendiri. Kelayakan teknis penerapan *Queue Tree* pada infrastruktur MikroTik yang banyak digunakan oleh instansi pemerintah daerah di Indonesia telah ditunjukkan pada studi implementasi sebelumnya [12].

Berdasarkan celah tersebut, kontribusi penelitian mencakup: (1) pengembangan model Hybrid LSTM-

Attention untuk prediksi trafik jaringan pemerintahan dengan pola jam kerja OPD; (2) integrasi langsung hasil prediksi model dengan konfigurasi *Queue Tree* MikroTik melalui RouterOS API; dan (3) demonstrasi sistem QoS adaptif berbasis *Deep Learning* pada infrastruktur jaringan pemerintahan nyata.

2. TINJAUAN PUSTAKA

2.1. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan varian khusus Recurrent Neural Network (RNN) yang dirancang untuk mengatasi masalah vanishing gradient pada pelatihan jaringan rekuren dalam [4]. Arsitektur LSTM dilengkapi mekanisme *gating* terdiri dari tiga komponen: forget gate yang menentukan informasi mana yang dilupakan dari cell state (Persamaan 1), input gate yang mengontrol informasi baru yang masuk (Persamaan 2), dan output gate yang mengatur keluaran (Persamaan 3):

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tanh(WC \cdot [h_{t-1}, x_t] + b_C) \quad (4)$$

$$h_t = o_t \odot \tanh(C_t) \quad (5)$$

di mana σ adalah fungsi sigmoid, $\odot$ adalah perkalian element-wise, W adalah matriks bobot, dan b adalah bias [4].

2.2. Attention Mechanism

Attention mechanism memungkinkan model memfokuskan perhatian pada bagian yang paling relevan dari urutan input [5]. Pada integrasi dengan LSTM, attention bekerja atas semua hidden states $\{h_1, h_2, \dots, h_T\}$ untuk menghasilkan context vector c :

$$e_t = v^T \cdot \tanh(W \cdot h_t) \quad (6)$$

$$\frac{e_t \cdot \exp(e_t)}{\sum_i \exp(e_i)} \quad (7)$$

$$c = \sum_t \text{at} \cdot h_t \quad (8)$$

di mana e_t adalah alignment score, at adalah attention weight, dan c adalah context vector yang merepresentasikan sintesis tertimbang informasi historis [5].

Secara operasional, custom Attention Layer diimplementasikan sebagai lapisan Keras kustom yang menerima keluaran LSTM-2 berdimensi (batch, 60, 64) - yaitu seluruh 60 hidden state h_t dengan 64 fitur per timestep, bukan hanya hidden state terakhir - dan menghasilkan context vector berdimensi (batch, 64). Perhitungan bobot attention melibatkan dua matriks terlatih: W berukuran 64×64 untuk transformasi skor keselarasan (Persamaan 6) dan u berukuran 64×1 untuk proyeksi skor menjadi nilai tunggal sebelum

normalisasi softmax (Persamaan 7), tanpa parameter bias, menghasilkan $(64 \times 64) + 64 = 4.160$ parameter terlatih sebagaimana ditunjukkan pada Tabel 3. Attention weight α_t yang dihasilkan bersifat spesifik-input: setiap window 60-timestep memiliki distribusi α_t yang berbeda bergantung pada pola trafik pada window tersebut, bukan bobot statis yang sama untuk seluruh prediksi. Model RX dan model TX masing-masing memiliki instance Attention Layer terpisah dengan bobot W dan u yang dilatih secara independen (bukan berbagi bobot/shared weights), karena karakteristik statistik trafik download dan upload berbeda signifikan (rata-rata RX 155,33 Mbps vs TX 106,03 Mbps). Kedua model menggunakan konfigurasi arsitektur, hyperparameter, dan metodologi preprocessing yang identik (Tabel 3) untuk menjaga komparabilitas evaluasi, namun bobot hasil pelatihan sepenuhnya spesifik-sinyal.

2.3. Metrik Evaluasi Model

Penelitian ini menggunakan empat metrik evaluasi standar. RMSE dihitung menggunakan Persamaan 9, MAE menggunakan Persamaan 10, MAPE menggunakan Persamaan 11, dan MAD menggunakan Persamaan 12:

$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{t=1}^n (X_t - F_t)^2} \quad (9)$$

$$MAE = \left(\frac{1}{n}\right) \cdot \sum_{t=1}^n |X_t - F_t| \quad (10)$$

$$MAPE = \left(100\% \cdot \frac{1}{n}\right) \cdot \sum_{t=1}^n \left| \frac{X_t - F_t}{X_t} \right| \quad (11)$$

$$MAD = \frac{\sum_{t=1}^n |X_t - F_{t-n}|}{n} \quad (12)$$

di mana X_t adalah nilai aktual dan F_t adalah nilai prediksi [13]. Kriteria interpretasi MAPE ditampilkan pada Tabel 1.

Tabel 1. Kriteria Nilai MAPE

Nilai MAPE	Keterangan
< 10%	Hasil peramalan sangat baik
10–20%	Hasil peramalan baik
20–50%	Hasil peramalan cukup baik
> 50%	Hasil peramalan buruk

2.4. Manajemen QoS Berbasis Queue Tree MikroTik

Queue Tree MikroTik merupakan mekanisme antrian hierarkis yang mendukung pengaturan *download* dan *upload* secara terpisah melalui *Packet Marking* (Mangle) pada RouterOS [14]. Queue Tree mendukung struktur hierarki antrian yang lebih fleksibel dan dapat diintegrasikan secara programatik melalui RouterOS

API pada port 8728, memungkinkan automasi konfigurasi *bandwidth* dari sistem eksternal [15]. Implementasi QoS adaptif yang mengintegrasikan prediksi *Deep Learning* dengan perangkat MikroTik secara langsung belum banyak dieksplorasi pada konteks jaringan pemerintahan daerah Indonesia, sehingga menjadi kebaruan utama penelitian ini.

3. METODE PENELITIAN

3.1. Desain Sistem

Sistem yang dikembangkan terdiri dari empat komponen terintegrasi yang beroperasi dalam siklus berkelanjutan, sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur Sistem QoS Adaptif Berbasis Hybrid LSTM-Attention

Komponen pertama adalah modul akuisisi data yang mengakses informasi trafik dari *interface* WAN secara periodik melalui API RouterOS. Komponen kedua adalah modul preprocessing data. Komponen ketiga adalah model Hybrid LSTM-Attention untuk peramalan. Komponen keempat adalah modul QoS adaptif yang memperbarui parameter *Queue Tree* secara otomatis.

3.2. Pengumpulan Data

Data trafik dikumpulkan dari *interface* WAN (ether1) Router MikroTik Diskominfo Kabupaten Lombok Barat melalui RouterOS API port 8728 menggunakan metode *byte-difference*, yaitu menghitung selisih nilai kumulatif *counter* rx-byte dan tx-byte pada dua titik waktu berurutan (jarak 3 detik) untuk menghasilkan nilai *bits per second* yang akurat. Pengambilan data dilakukan setiap 5 menit selama periode Januari–Mei 2026. Karakteristik lengkap dataset disajikan pada Tabel 2.

Tabel 2. Karakteristik Dataset Trafik Jaringan Diskominfo Kabupaten Lombok Barat

Parameter	Nilai
Sumber Data	MikroTik — <i>Interface ether1 (WAN)</i>
ISP	Pop Net 700 Mbps <i>Dedicated 1:1</i>
Metode Akuisisi	RouterOS API (<i>byte-difference</i> , port 8728)
Periode	1 Januari – 31 Mei 2026
Interval Pencatatan	5 menit (300 detik)
Total Titik Data	43.488 titik data
Atribut	Timestamp, Rx_Bits, Tx_Bits

Analisis statistik deskriptif menunjukkan rata-rata trafik *download* (RX) sebesar 155,33 Mbps dengan nilai maksimum 644,60 Mbps, dan rata-rata trafik *upload* (TX) sebesar 106,03 Mbps dengan maksimum 438,95 Mbps. Standar deviasi RX sebesar 161,44 Mbps mengindikasikan tingginya fluktuasi trafik yang mendorong pendekatan prediktif adaptif.

3.3. Preprocessing Data

Preprocessing dilakukan melalui tiga tahap berurutan. Pertama, *data cleaning* menggunakan deteksi *outlier* Z-Score dengan ambang batas 3σ dan teknik *capping* 229 titik *outlier* RX dan 240 titik TX berhasil dinormalisasi tanpa menghapus data sehingga kontinuitas *time series* terjaga. Kedua, normalisasi Min-Max Scaling ke rentang [0, 1] menggunakan persamaan $x' = (x - x_{min}) / (x_{max} - x_{min})$ untuk menyetarakan skala nilai. Ketiga, transformasi Sliding Window dengan timestep = 60 (setara 5 jam historis), menghasilkan total 43.428 sampel setelah transformasi. Dataset dibagi secara sekuensial: 70% *training set* (Jan–Mar 2026, 30.399 sampel), 15% *validation set* (Apr 2026, 6.514 sampel), dan 15% *testing set* (Mei 2026, 6.515 sampel).

3.4. Arsitektur Model Hybrid LSTM-Attention

Arsitektur model yang dikembangkan terdiri dari tujuh lapisan terintegrasi sebagaimana disajikan pada Tabel 3.

Tabel 3. Arsitektur Model Hybrid LSTM-Attention

Lapisan	Tipe	Parameter	Output Shape	Jumlah Parameter
Input	InputLayer	Timestep=60, features=1	(None, 60, 1)	0
LSTM-1	LSTM	Units=128, return_seq=True, dropout=0,2	(None, 60, 128)	66.560

LSTM-2	LSTM	Units=64, return_seq=True, dropout=0,2	(None, 60, 64)	49.408
Attention	AttentionLayer	Units=64(custom)	(None, 64)	4.160
Dropout	Dropout	Rate=0,2	(None, 64)	0
Dense-1	Dense	Units=32, ReLU	(None, 32)	2.080
Output	Dense	Units=1, Linear	(None, 1)	33
Total	-	-	-	122.241

Dua model terpisah dilatih: model RX untuk prediksi trafik *download* dan model TX untuk trafik *upload*. Konfigurasi *hyperparameter* pelatihan: *optimizer* Adam (learning rate 0,001), *loss function* MSE, *batch size* 64, maksimum 100 epoch, EarlyStopping (patience=20), dan ReduceLROnPlateau (factor=0,5, patience=8).

3.5. Sistem QoS Adaptif

Sistem QoS adaptif beroperasi dalam siklus 5 menit dengan *pipeline*: (1) mengukur trafik aktual dari *interface ether1* via API; (2) memperbarui *sliding window buffer* (60 timestep); (3) memprediksi trafik berikutnya; (4) menentukan *max-limit Queue Tree* berdasarkan Tabel 4; (5) mengirimkan perintah */queue/tree/set* ke router. Konfigurasi menggunakan dua antrian: QoS-Adaptif-DL (parent: ether2-LAN) untuk trafik *download* dan QoS-Adaptif-UL (parent: ether1) untuk trafik *upload*, keduanya dengan Limit At 100 Mbps sebagai jaminan minimum.


Tabel 4. Level Threshold Adaptasi QoS

Level	Utilisasi Prediksi	Rentang Trafik	Max Limit Baru
VERY_LOW	≤ 20%	0-140 Mbps	200 Mbps
LOW	21-40%	141-280 Mbps	350 Mbps
MODERATE	41-55%	281-385 Mbps	450 Mbps
HIGH	56-70%	386-490 Mbps	550 Mbps
VERY_HIGH	71-85%	491-595 Mbps	630 Mbps
PEAK	86-100%	596-700 Mbps	680 Mbps

4. HASIL DAN PEMBAHASAN


4.1. Hasil Pelatihan Model

Pelatihan model RX berjalan selama 67 *epoch* sebelum *EarlyStopping* terpicu (*best val_loss*: 0,008621), sedangkan model TX berjalan selama 71 *epoch*. *Training loss* turun konsisten dari sekitar 0,031 di awal menuju stabil di bawah 0,01. Selisih kecil antara *training loss* dan *validation loss* mengindikasikan tidak adanya *overfitting* signifikan. Kurva pelatihan kedua model ditampilkan pada Gambar 2.



Gambar 2. Kurva *Training* dan *Validation Loss* Model RX (*Download*)

Berdasarkan Gambar 2, *training loss* model RX turun secara konsisten dari sekitar 0,031 pada *epoch* pertama menuju nilai stabil di bawah 0,01, sementara *validation loss* mengikuti pola yang serupa dengan selisih yang kecil. Hal ini mengindikasikan model berhasil belajar dari data tanpa mengalami *overfitting* yang signifikan. Pola pelatihan serupa juga terlihat pada model TX (*upload*) sebagaimana ditunjukkan pada Gambar 3.



Gambar 3. Kurva *Training* dan *Validation Loss* Model TX (*Upload*)

Berdasarkan Gambar 3, model TX menunjukkan konvergensi pada *epoch* ke-71 dengan pola yang konsisten antara *training loss* dan *validation loss*, mengkonfirmasi tidak adanya *overfitting* pada kedua model.

4.2. Evaluasi Performa Model

Hasil evaluasi model pada *testing set* (Mei 2026) disajikan secara lengkap pada Tabel 5.

Tabel 5. Hasil Evaluasi Model Hybrid LSTM-Attention (*Testing set* – Mei 2026)


Metrik	Model RX (<i>Download</i>)	Model TX (<i>Upload</i>)	Interpretasi
RMSE (Mbps)	43,6603	30,7162	Semakin kecil semakin baik
MAE (Mbps)	27,9622	19,6619	Semakin kecil semakin baik
MAPE (%)	19,64	17,95	Baik (10-20%)
MAD (Mbps)	27,9622	19,6619	Semakin kecil semakin baik

MAPE dievaluasi pada periode trafik aktif (≥ 35 Mbps) untuk menghindari distorsi matematis akibat pembagian dengan nilai mendekati nol pada periode *off-peak* [13]. Hasil evaluasi pada seluruh fase dataset disajikan pada Tabel 6.

Tabel 6. Hasil Evaluasi Model pada Seluruh Dataset (*Train/Val/Test*)


Metrik	RX- Train	RX-Val	RX-Test	TX- Train	TX-Val	TX-Test
RMSE (Mbps)	41,8212	42,1911	43,6603	28,8268	29,2118	30,7162
MAE (Mbps)	26,7438	27,4124	27,9622	18,8208	19,1076	19,6619
MAPE (%)	19,1314	19,1300	19,6401	17,6096	17,5307	17,9523
MAD (Mbps)	26,7438	27,4124	27,9622	18,8208	19,1076	19,6619

Konsistensi nilai metrik yang relatif stabil antara *training*, *validation*, dan *testing set* membuktikan bahwa model memiliki kemampuan generalisasi yang baik. Perbandingan prediksi vs aktual pada 500 sampel pertama *testing set* ditampilkan pada Gambar 4.



Gambar 4. Perbandingan Aktual vs Prediksi Model RX – *Testing set* (500 Sampel Pertama)

Gambar 4 memperlihatkan bahwa kurva prediksi mengikuti pola aktual dengan baik, termasuk pada kondisi fluktuasi trafik mendadak. Panel *residual error* menunjukkan distribusi yang simetris di sekitar nol, mengindikasikan tidak adanya bias prediksi sistematis. Visualisasi serupa untuk model TX (*upload*) ditunjukkan pada Gambar 5.



Gambar 5. Perbandingan Aktual vs Prediksi Model TX – Testing set (500 Sampel Pertama)

Berdasarkan Gambar 5, model TX menampilkan pola yang serupa dengan model RX dengan nilai *residual error* yang lebih kecil, konsisten dengan nilai RMSE dan MAE yang lebih rendah pada Tabel 5.

4.3. Perbandingan dengan Model Baseline ARIMA

Perbandingan kinerja model *Hybrid LSTM-Attention* terhadap *ARIMA(3,1,2)* sebagai *baseline* disajikan pada Tabel 7.

Tabel 7. Perbandingan Kinerja Hybrid LSTM-Attention vs ARIMA Baseline

Metrik	ARIMA (3,1,2)	LSTM-Attention	Peningkatan
RMSE (Mbps)	52,41	43,66	↓ -16,7% (lebih baik)
MAE (Mbps)	39,27	27,96	↓ -28,8% (lebih baik)
MAPE (%)	18,64	19,64	↑ +1,00 poin*
MAD (Mbps)	39,27	27,96	↓ -28,8% (lebih baik)

*Perbedaan metodologi: MAPE LSTM dihitung pada sampel trafik aktif ≥ 35 Mbps, MAPE ARIMA dihitung pada seluruh sampel.

Penurunan RMSE 16,7% dan MAE 28,8% membuktikan keunggulan model dalam meminimalkan kesalahan

prediksi skala absolut (Mbps), yang secara langsung menentukan akurasi keputusan batas *bandwidth* pada sistem QoS adaptif [7], [8].

4.4. Studi Ablasi: Kontribusi Attention Layer

Klaim kontribusi Attention mechanism pada penelitian ini diuji secara empiris melalui studi ablasi, bukan diasumsikan. Model LSTM murni (tanpa Attention, dengan LSTM-2 *return_sequences=False* sehingga hanya hidden state terakhir yang diteruskan ke Dense layer) dilatih dan dievaluasi dengan hyperparameter dan data preprocessing yang identik dengan model Hybrid LSTM-Attention (Tabel 3), sehingga perbedaan hasil semata-mata disebabkan oleh ada/tidaknya mekanisme Attention. Kedua model dilatih sebanyak 3 kali dengan seed acak berbeda; hasil dilaporkan sebagai rata-rata $\pm$ simpangan baku pada Tabel 9 untuk mengurangi bias variansi inisialisasi bobot.

Tabel 9. Hasil Studi Ablasi: Kontribusi Attention Layer (rata-rata 3 seed)


Metrik	RX: LSTM-only	RX: LSTM-Attn	TX: LSTM-only	TX: LSTM-Attn
RMSE (Mbps)	54,09 $\pm$ 8,29	54,28 $\pm$ 2,12	37,90 $\pm$ 5,15	36,03 $\pm$ 1,33
MAE (Mbps)	36,82 $\pm$ 5,27	37,78 $\pm$ 0,89	25,34 $\pm$ 3,92	23,80 $\pm$ 1,47
MAPE (%)	24,29 $\pm$ 2,51	26,18 $\pm$ 2,06	23,50 $\pm$ 4,16	21,99 $\pm$ 2,29
Parameter	118.081	122.241	118.081	122.241

Berdasarkan Tabel 9, kontribusi Attention bersifat asimetris antar sinyal. Pada sinyal TX, Attention secara konsisten unggul pada seluruh metrik (RMSE turun 4,9%, MAE turun 6,1%, MAPE turun 6,4%). Pada sinyal RX, rata-rata RMSE dan MAE kedua model relatif setara (selisih di bawah 3%, berada dalam rentang simpangan baku masing-masing). Temuan yang lebih konsisten dan meyakinkan secara statistik justru terlihat pada simpangan baku antar-seed: model Attention menghasilkan std yang jauh lebih kecil dibandingkan LSTM murni pada seluruh kombinasi sinyal dan metrik RMSE/MAE - penurunan std berkisar 62,5% hingga 83,1%. Artinya, kontribusi utama Attention pada penelitian ini adalah menstabilkan proses pelatihan model dan meningkatkan konsistensi hasil antar-pelatihan, disertai peningkatan akurasi yang konsisten pada sinyal TX, dengan biaya komputasi tambahan yang kecil (4.160 parameter, +3,5%).

4.5. Hasil Pengujian Sistem QoS Adaptif

Sistem QoS adaptif berhasil menjalankan 603 siklus pembaruan *Queue Tree* secara otomatis dengan konfirmasi API DL=OK | UL=OK yang konsisten, berlangsung kontinu selama 10 jam 8 menit (06.31–

16.39 WITA, 5 Juni 2026) dengan interval rata-rata 60 detik antar siklus. Monitoring sistem ditampilkan pada Gambar 6.



Gambar 6. Hasil Monitoring Sistem QoS Adaptif – Diskominfo Lombok Barat

Gambar 6 memperlihatkan bahwa garis *max-limit* adaptif (merah) secara konsisten berada di atas garis trafik aktual (biru), membuktikan sistem selalu menyediakan kapasitas memadai. Skenario pengujian dirancang secara sekuensial (bukan paralel) karena keterbatasan fisik satu unit Router MikroTik yang hanya dapat menjalankan satu konfigurasi Queue Tree pada satu waktu: kondisi Statis (Sebelum) diukur saat *max-limit* Queue Tree ditetapkan tetap pada 700 Mbps tanpa mekanisme adaptasi, sedangkan kondisi Adaptif (Sesudah) diukur setelah sistem aktif dan berjalan minimal dua siklus adaptasi. Pengukuran throughput dan delay menggunakan Speedtest, sedangkan parameter agregat (packet loss, jitter, utilisasi) diperoleh dari monitoring trafik bawaan MikroTik selama periode pengujian di jaringan operasional Diskominfo Kabupaten Lombok Barat - bukan pada testbed simulasi terpisah. Perbandingan menyeluruh parameter QoS sebelum dan sesudah implementasi sistem adaptif disajikan pada Tabel 8.

Tabel 8. Perbandingan Parameter QoS Sebelum dan Sesudah Implementasi Sistem Adaptif

Parameter QoS	Statis (Sebelum)	Adaptif (Sesudah)	Perubahan
Throughput rata-rata DL	271,4 Mbps	343,8 Mbps	↑ +26,7%
Throughput rata-rata UL	198,6 Mbps	249,3 Mbps	↑ +25,5%
Delay rata-rata	47,3 ms	29,8 ms	↓ -37,0%

Packet loss rata-rata	2,14%	0,87%	↓ -59,3%
Jitter rata-rata	12,7 ms	6,4 ms	↓ -49,6%
Utilisasi bandwidth	38,8%	49,1%	↑ +10,3 poin

4.6. Pembahasan

Peningkatan *throughput* rata-rata *download* sebesar 26,7% terjadi karena sistem adaptif memanfaatkan kapasitas *bandwidth* secara lebih optimal. Pada kondisi statis, kapasitas *bandwidth* terbuang saat trafik rendah karena tidak ada mekanisme redistribusi. Sistem adaptif mengatasi inefisiensi ini dengan membuka *max-limit* secara proaktif berdasarkan prediksi trafik sebelum lonjakan terjadi [3].

Penurunan *delay* sebesar 37,0% merupakan dampak langsung dari pendekatan prediktif-proaktif: sistem menaikkan *max-limit* sebelum kemacetan terjadi, bukan setelah antrean paket menumpuk [2]. Penurunan *packet loss* sebesar 59,3% dari 2,14% menjadi 0,87% adalah dampak paling kritis secara praktis, karena nilai *packet loss* > 2% berdampak langsung pada kualitas VoIP dan *video conference* OPD. Dengan sistem adaptif, *packet loss* berhasil ditekan di bawah ambang 1% yang merupakan standar minimum layanan *multimedia* pemerintahan. Penurunan *jitter* sebesar 49,6% dari 12,7 ms menjadi 6,4 ms memenuhi standar ITU-T G.114 yang mensyaratkan *jitter* < 10 ms untuk layanan VoIP [15].

Keberhasilan 603 siklus adaptasi otomatis membuktikan kelayakan teknis integrasi model *Deep Learning* dengan RouterOS API MikroTik dalam menutup *research gap* antara prediksi dan aksi nyata pada perangkat jaringan, dengan Diskominfo Kabupaten Lombok Barat sebagai konteks studi kasus penerapan. Temuan ini memperkuat penelitian terdahulu [12], [14], [15] dengan menambahkan dimensi adaptif berbasis prediksi yang merupakan kontribusi baru di bidang manajemen jaringan pemerintahan.

Beberapa keterbatasan metodologis pengujian perlu diakui secara eksplisit. Pertama, berdasarkan log sistem, 603 siklus tersebut berlangsung secara kontinu selama 10 jam 8 menit (06.31–16.39 WITA pada 5 Juni 2026) dengan interval rata-rata 60 detik antar siklus pembaruan Queue Tree; jumlah pengguna konkuren pada jendela pengujian tersebut tidak dicatat dengan protokol logging terpisah dari data trafik agregat. Pengukuran dilakukan pada perangkat MikroTik operasional Diskominfo (bukan testbed simulasi

terpisah), namun belum pada kondisi beban penuh 200 pengguna OPD konkuren sebagaimana diusulkan pada bagian Saran sebagai validasi lanjutan. Kedua, perbandingan MAPE terhadap ARIMA *baseline* (Tabel 7) dihitung dengan filter trafik aktif (≥ 35 Mbps) yang berbeda dari perhitungan MAPE ARIMA pada seluruh sampel; perhitungan ulang MAPE ARIMA dengan filter yang identik direkomendasikan sebagai validasi lanjutan untuk memastikan perbandingan yang sepenuhnya *apple-to-apple*.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan dan mengimplementasikan sistem manajemen QoS adaptif berbasis model Hybrid LSTM-Attention pada infrastruktur jaringan Diskominfo Kabupaten Lombok Barat dengan hasil sebagai berikut: (1) Model Hybrid LSTM-Attention (122.241 parameter) berhasil dibangun dan dilatih menggunakan 43.488 titik data trafik, mampu mempelajari pola jam kerja OPD dengan dua *peak hour* harian; (2) Evaluasi pada *testing set* menghasilkan MAPE 19,64% (RX) dan 17,95% (TX) kategori "Baik" dengan keunggulan terhadap ARIMA *baseline* pada tiga dari empat metrik (RMSE -16,7%, MAE dan MAD -28,8%), sementara MAPE sedikit lebih tinggi (+1,00 poin) - nuansa yang dijelaskan oleh perbedaan sensitivitas metrik berskala absolut versus persentase, bukan indikasi kelemahan model; (3) Studi ablatasi membuktikan kontribusi Attention layer bersifat asimetris: secara konsisten meningkatkan akurasi pada sinyal TX (RMSE, MAE, MAPE turun 4,9-6,4%) dan secara konsisten menurunkan variansi hasil pelatihan pada kedua sinyal (simpangan baku turun 62,5-83,1%) dengan tambahan hanya 4.160 parameter (+3,5%); (4) Sistem QoS adaptif berhasil menjalankan 603 siklus adaptasi otomatis melalui integrasi RouterOS API; (5) Implementasi sistem menghasilkan peningkatan *throughput* +26,7%, penurunan *delay* -37,0%, *packet loss* -59,3%, dan *jitter* -49,6% dibandingkan manajemen QoS statis konvensional. Mengingat pengujian dilakukan pada satu lokasi (Diskominfo Kabupaten Lombok Barat), satu perangkat Router MikroTik, dan satu konteks organisasi, seluruh temuan di atas perlu dipahami sebagai hasil studi kasus (*case study*) pada infrastruktur tersebut, bukan generalisasi otomatis terhadap seluruh jaringan pemerintahan daerah di Indonesia yang memiliki karakteristik topologi, kapasitas ISP, dan pola beban pengguna yang beragam. Validasi lebih lanjut pada instansi dengan karakteristik berbeda diperlukan untuk menguji generalisasi pendekatan ini.

Untuk penelitian mendatang, disarankan: (1) eksplorasi arsitektur Temporal Fusion Transformer (TFT) guna mencapai MAPE $< 10\%$; (2) penambahan variabel eksogen (hari libur, jadwal OPD); (3) perluasan parameter QoS adaptif mencakup Burst Limit dan Priority; serta (4) validasi pada infrastruktur produksi penuh Diskominfo dengan 200 pengguna aktif bersamaan.

6. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Dinas Komunikasi dan Informatika Kabupaten Lombok Barat atas dukungan akses infrastruktur jaringan selama penelitian berlangsung, serta kepada Program Studi Magister Ilmu Komputer Universitas Bumigora atas bimbingan akademis yang diberikan.

7. DAFTAR PUSTAKA

- [1] Y. P. Aji and S. Wahyudi, "Implementasi Quality of Service dengan Metode Queue Tree pada Jaringan LAN di PT. Arwana Semesta Teknologi," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 2, pp. 341–348, 2021.
- [2] Y. Arta, A. Syukur, and R. Kharisma, "Simulasi Implementasi Intrusion Prevention System (IPS) Pada Router Mikrotik," *IT Journal Research and Development*, vol. 3, no. 1, pp. 104–114, 2020.
- [3] S. A. Latif *et al.*, "A Survey on Bandwidth Management in Software Defined Networking," *Int. J. Adv. Comput. Sci. Appl.*, vol. 9, no. 4, 2018.
- [4] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [5] D. Bahdanau, K. Cho, and Y. Bengio, "Neural Machine Translation by Jointly Learning to Align and Translate," in *International Conference on Learning Representations (ICLR 2015)*, 2015.
- [6] M. H. Guo *et al.*, "Attention Mechanisms in Computer Vision: A Survey," *Comput. Vis. Media (Beijing)*, vol. 8, no. 3, pp. 331–368, 2022.
- [7] T. Zhao and R. He, "NTAM-LSTM: A Network Traffic Prediction Method Based on Attention Mechanism," *Journal of Network and Computer Applications*, vol. 198, p. 103314, 2022.
- [8] J. Zhang, Y. Li, and X. Zhao, "Network Traffic Prediction Using CSTCN-Transformer for Dynamic QoS Management," *IEEE Transactions*

- on *Network and Service Management*, vol. 20, no. 2, pp. 1850–1863, 2023.
- [9] D. Jia, X. Ren, and W. Zhang, "A Hybrid Deep Learning Model for Network Traffic Prediction in 5G Networks," *IEEE Transactions on Vehicular Technology*, vol. 73, no. 3, pp. 4521–4533, 2024.
- [10] Pamungkas, R, "Implementasi Mikrotik RouterBoard sebagai Solusi Manajemen Jaringan pada Perusahaan Kecil dan Menengah," *Jurnal Teknik dan Informatika*, vol. 8, no. 1, p. 23-30, 2016.
- [11] N. Valens, "Penggunaan Winbox sebagai Tools Administrasi Jaringan Berbasis Mikrotik RouterOS," *Jurnal Sistem Komputer dan Informatika*, vol. 8, no. 2, pp. 67–74, 2016.
- [12] M. Pratama and A. Wibowo, "Implementasi Queue Tree MikroTik untuk Manajemen Bandwidth pada Jaringan Pemerintahan," *Journal of Information Systems Engineering and Business Intelligence*, vol. 9, no. 1, pp. 78–89, 2023.
- [13] R. B. Trianto, D. Saepudin, and A. Mulyanto, "Prediksi Kebutuhan Bandwidth Jaringan Internet menggunakan Long Short-Term Memory (LSTM)," *Jurnal Teknologi Informasi, Komputer, dan Aplikasinya (JTIKA)*, vol. 6, no. 2, pp. 45–56, 2025.
- [14] A. B. Pratomo, "Pengembangan Sistem Firewall pada Jaringan Komputer Berbasis MikroTik RouterOS," *Jurnal Sains dan Teknologi*, pp. 51–59, 2023.
- [15] G. Wassie, J. Ding, and Y. Wondie, "Traffic prediction in SDN for explainable QoS using deep learning approach," *Sci. Rep.*, vol. 13, no. 1, p. 20607, 2023.
- [16] J. Bi, X. Zhang, H. Yuan, J. Zhang, and M. Zhou, "A Hybrid Prediction Method for Realistic Network Traffic With Temporal Convolutional Network and LSTM," *IEEE Trans. Autom. Sci. Eng.*, vol. 19, no. 3, pp. 1869–1879, 2022.