

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Kualitas Layanan dalam Jaringan

Kualitas Layanan atau *Quality of Service* (QoS) dalam jaringan merupakan ukuran kinerja untuk menyediakan layanan jaringan kepada pengguna. QoS menjadi hal penting yang perlu di perhatikan karena dapat memengaruhi kepuasan pengguna, seperti *Streaming Video*, *Video Call*, *Game Online*, atau layanan real-time lainnya.

Menurut TIPHON (Telecommunications and Internet Protocol Harmonization Over Networks), QoS dapat diukur dengan empat metrik utama yaitu:

1. *Latency* adalah waktu tunda (delay) yang dibutuhkan oleh sebuah paket data untuk berpindah dari titik asal ke titik tujuan. Biasanya latency yang tinggi akan menyebabkan paket datang terlambat.
2. *Jitter* adalah variasi waktu pengiriman, ketika 2 paket dikirimkan secara bersama, tetapi bisa tiba di tempat tujuan dengan jarak waktu berbeda. *Jitter* dengan nilai yang tinggi akan menyebabkan gangguan dalam transmisi data berurutan, sehingga paket dapat dianggap hilang atau tidak dapat digunakan.
3. *Throughput* adalah jumlah data yang berhasil ditransmisikan melalui jaringan dalam satuan waktu tertentu (Mbps). Tingginya nilai throughput yang terjadi menunjukkan jaringan mampu mengalirkan data dengan baik.
4. *Packet Loss Ratio* (PLR) adalah banyaknya data yang hilang selama proses transmisi.

Keempat metrik tersebut saling berkaitan untuk menunjukkan tingkat kestabilan suatu jaringan. Selain itu, faktor eksternal seperti cuaca, kepadatan pengguna, dan lokasi geografis juga dapat memengaruhi kualitas layanan jaringan (Ratiandi Yacoub et al., 2024).

Dengan memahami berbagai metrik dan faktor eksternal dapat membantu memprediksi kondisi kualitas layanan di masa yang akan datang. Inilah yang menjadi dasar penting dalam penelitian ini.

2.1.2 *Packet Loss Ratio (PLR) dalam jaringan Telekomunikasi*

Packet Loss Ratio adalah metrik kritis dalam mengevaluasi kendala jaringan serta salah satu metrik utama dalam mengukur kualitas layanan (*QoS*). *Packet Loss Ratio* didefinisikan sebagai sebuah persentase data yang hilang atau data tidak sampai pada tujuan selama proses terjadinya transmisi, dibandingkan dengan total data yang dikirim.

Biasanya penyebab utama terjadinya *Packet Loss Ratio* antara lain, kemacetan jaringan, kerusakan *hardware*, serangan *cyber*, kesalahan konfigurasi. Sehingga paket yang dikirim oleh pengirim bisa tidak sampai ke tujuan atau terlambat sampai akhirnya diabaikan.

Packet Loss Ratio atau PLR dapat dihitung dengan rumus:

$$\text{PLR} = \frac{\text{Jumlah Paket Hilang}}{\text{Total Paket Dikirim}} \times 100\%$$

Misalnya, jika 5 paket hilang dari 150 data yang dikirim *Packet Loss Ratio* yang akan terjadi adalah 3,33%.

Ketika *Packet Loss Ratio* memiliki nilai yang tinggi maka kinerja jaringan akan menurun dan sebaliknya ketika kinerja jaringan baik maka *Packet Loss Ratio* memiliki nilai yang minimum atau bahkan mendekati 0. Tingginya nilai *Packet Loss Ratio* dapat menyebabkan penurunan kualitas layanan jaringan, seperti kualitas buruk pada panggilan suara, terjadi gangguan saat streaming

video, atau aplikasi berbasis real-time menjadi lambat. Dilihat dari standart industry (ITU-T G.1010) batas maksimal terjadinya *Packet Loss Ratio* dari panggilan suara (VoIP) <3%, *Streaming Video* <1%, dan Game online <1%. Rasio ini didefinisikan sebagai suatu fraksi dari jumlah total paket yang telah dikirimkan tetapi tidak sampai di tujuan (Abdullah et al., 2024).

2.1.3 Faktor Utama yang Memengaruhi *Packet Loss Ratio*

Packet Loss Ratio (PLR) tidak terjadi secara acak, namun dipengaruhi oleh berbagai performa jaringan. Faktor-faktor yang memengaruhi *Packet Loss Ratio* antara lain:

1. Kondisi fisik dan lingkungan seperti cuaca, interfensi bangunan, dan jarak dari *Base Transceiver Station* (BTS).
2. Kepadatan trafik yang memicu antrian panjang hingga terjadi *delay* atau *packet drop*.
3. Kualitas perangkat jaringan yang rusak atau tidak dikonfigurasi dengan benar.

Hingga mobilitas pengguna yang dapat menganggu kestabilan transmisi dan meningkatkan potensi terjadinya *Packet Loss Ratio* (Ratiandi Yacoub et al., 2024). Oleh karena itu, dengan memahami faktor tersebut dapat membantu mengenali kondisi yang paling rentan terjadi. Penggunaan Metode prediksi berbasis *deep learning*, menjadi solusi yang relevan karena mampu menangkap pola temporal dan multivariant yang memengaruhi *Packet Loss Ratio* tersebut.

2.1.4 Data Deret Waktu (*Time Series*)

Data deret waktu atau *data time series* adalah kumpulan observasi yang diurutkan berdasarkan waktu, urutan ini sangat penting karena nilai saat ini seringkali bergantung pada nilai-nilai sebelumnya. Karakteristik utama data deret waktu meliputi:

1. Dependensi Temporal: Nilai data pada suatu waktu t memiliki korelasi dengan nilai data pada waktu $t - 1$, $t - 2$, dan seterusnya.
2. Tren: Peningkatan atau penurunan jangka panjang dalam data.
3. Musiman: Pola berulang yang terjadi pada interval waktu yang tetap (harian, mingguan, bulanan, tahunan).
4. Siklus: Fluktuasi yang tidak tetap dan terjadi dalam periode yang lebih panjang daripada musiman.

Data metrik kualitas layanan jaringan adalah contoh klasik dari data deret waktu. Perilaku jaringan pada suatu jam sangat dipengaruhi oleh perilaku pada jam-jam sebelumnya, menunjukkan adanya dependensi temporal. Selain itu, pola penggunaan jaringan sering kali menunjukkan musiman harian (puncak *traffic* di malam hari) atau mingguan (*traffic* lebih tinggi di hari kerja). Oleh karena itu, teknik analisis dan pemodelan yang khusus untuk data deret waktu sangat relevan dalam penelitian ini.

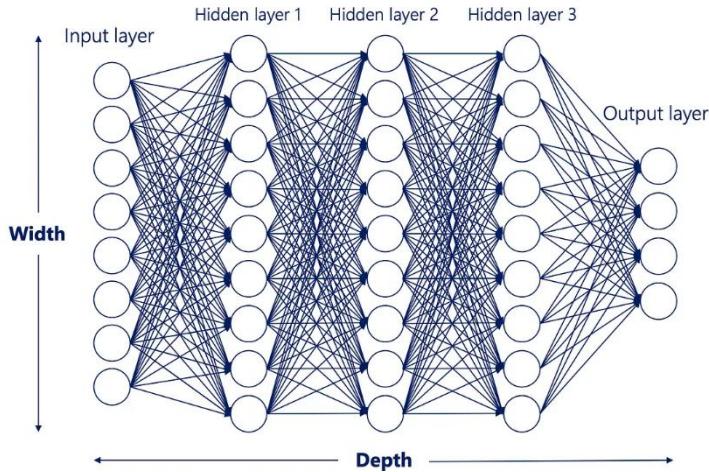
2.1.5 *Deep Learning*

Deep Learning adalah sub bidang dari *Artificial Intelligence* (AI) dan *Machine Learning* yang menggunakan arsitektur jaringan saraf tiruan (*Artificial Neural Network*) dengan banyak lapisan (*Deep Neural Networks*). *Deep Learning* dapat secara otomatis dapat mengekstrak fitur-fitur yang relevan dari data mentah, serta dapat mengurangi kebutuhan akan rekayasa fitur manual yang ekstensif. Hal ini sering digunakan secara luas dalam berbagai bidang karena arsitektur jaringannya yang mempu menyesuaikan dengan kompleksitas data (Zaheer et al., 2023).

Arsitektur jaringan *Deep Learning* pada Gambar 2.1. memiliki tiga layer utama, yaitu:

1. *Input layer* adalah lapisan yang menerima data awal.
2. *Hidden layer* atau mengandung *neuron* dengan fungsi aktivasi dalam mengidentifikasi pola, yang terdiri dari beberapa lapisan tersembunyi.

3. *Output layer* yang menghasilkan prediksi atau klasifikasi berdasarkan pembelajaran model



Gambar 2. 1. Ilustrasi Dasar Arsitektur *Deep Learning*.

Sumber: [Medium](#).

Dalam konteks *data time series*, metode *Deep Learning* sangat cocok digunakan untuk dataset yang besar karena memiliki kemampuan mengingat urutan data serta yang kompleks.

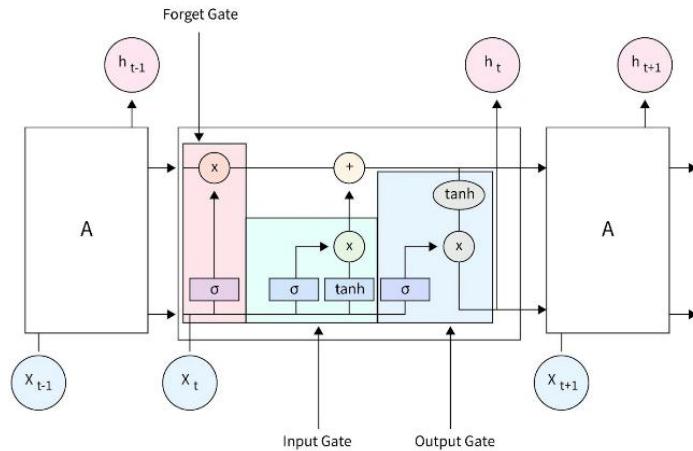
Dengan demikian, penerapan *Deep Learning* dalam berbagai studi, termasuk memprediksi *Packet Loss Ratio* dapat membantu memberikan pendekatan dengan akurasi tinggi untuk meningkatkan kualitas layanan, efisiensi dalam proses analisis dalam, Karena model mampu mengenali pola data yang kompleks secara otomatis.

2.1.6 *Long Short-Term Memory (LSTM)*

Long Short-Term Memory (LSTM) adalah salah satu jenis arsitektur saraf tiruan yang termasuk dalam keluarga *Recurrent Neural Network* (RNN). Arsitektur tersebut dirancang khusus untuk menangani *data time series* atau

data sekuensial. Algoritma LSTM memungkinkan model untuk mengingat informasi penting dalam jangka Panjang, sehingga dapat sangat efektif dalam mengenali pola dalam data.

Model Long Short-Term Memory (LSTM) dirancang dengan sejumlah lapisan khusus yang mampu mempelajari serta menghasilkan prediksi berdasarkan pola historis pada data deret waktu (time series). Ilustrasi arsitektur LSTM disajikan pada Gambar 2.2.



Gambar 2. 2 Arsitektur *Long Short-Term Memory*

Sumber: [Scaler](#)

Pada Gambar 2.2 ditampilkan arsitektur dari model Long Short-Term Memory (LSTM), yang terdiri dari tiga komponen utama, yaitu:

- Input Gate* (X_t) dan *Hidden State* Sebelumnya (h_{t-1})

Pada setiap langkah waktu (*Time Step*), unit LSTM menerima masukan berupa data input saat ini (X_t) serta hidden state dari langkah sebelumnya (h_{t-1}).

- Forget Gate*

Tahapan ini untuk menentukan informasi dari *cell state* sebelumnya yang perlu dipertahankan atau dilupakan. Proses ini dikendalikan

oleh fungsi aktivasi sigmoid (σ) yang menghasilkan nilai antara 0 (dibuang) hingga 1 (dipertahankan sepenuhnya).

c. *Input Gate*

Input gate mengatur informasi baru yang akan ditambahkan ke dalam *cell state*. Proses ini terdiri dari dua langkah:

- Fungsi aktivasi *sigmoid* (σ) menentukan bagian mana dari informasi yang penting untuk disimpan.
- Fungsi aktivasi *tanh* menghasilkan kandidat nilai baru yang akan ditambahkan ke dalam *cell state*.

d. *Cell State (c_t)*

Cell state diperbarui dengan menggabungkan informasi lama setelah melalui *forget gate* dan informasi baru dari *input gate*. Dengan mekanisme ini, LSTM mampu mempertahankan informasi yang relevan dalam jangka panjang).

e. *Output Gate*

Output gate mengatur informasi mana yang akan diteruskan menjadi *hidden state* baru (h_t). Proses ini melibatkan fungsi *sigmoid* untuk menentukan bagian penting dari *cell state*, kemudian dikalikan dengan fungsi *tanh* dari *cell state* saat ini.

f. *Hidden State (h_t)*

Hidden state yang dihasilkan pada langkah waktu ke- t akan digunakan sebagai masukan untuk langkah berikutnya (h_{t+1}), sekaligus dapat diteruskan ke lapisan *Dense* untuk menghasilkan prediksi akhir.

Struktur ini membuat LSTM dapat mempertahankan informasi penting dan membuang informasi yang tidak relevan secara otomatis, dan menjadikannya unggul dalam memproses data sekuensial. Dengan kemampuannya, LSTM menjadi pilihan tepat untuk memodelkan fluktuasi performa jaringan secara akurat (Rizki et al., 2020).

2.1.7 Klasifikasi Biner

Klasifikasi adalah tugas dimana algoritma belajar untuk memprediksi kategori atau kelas diskrit dari data input. Sedangkan klasifikasi biner adalah jenis klasifikasi dengan dua kemungkinan output, seperti “ya” atau “tidak”

Dalam penelitian ini, prediksi lonjakan *Packet Loss Ratio (PLR)* diformulasikan sebagai klasifikasi biner, di mana model akan memprediksi apakah PLR pada periode berikutnya akan mengalami:

1. Lonjakan (1): Nilai PLR melebihi ambang batas tertentu.
2. Normal (0): Nilai PLR masih dalam rentang yang wajar.

2.1.8 *Hyperparameter Tuning*

Hyperparameter Tuning adalah proses sistematis untuk menemukan kombinas hyperparameter optimal yang akan menghasilkan model terbaik. Tanpa tuning yang tepat model dapat mengalami *underfitting* (kinerja buruk pada data pelatihan dan pengujian) atau *overfitting* (kinerja sangat baik pada data pelatihan tapi buruk pada data pengujian).

Pada penelitian ini, Keras Tuner digunakan sebagai alat untuk melakukan *hyperparameter tuning* dengan algoritma Hyperband. Pendekatan ini memungkinkan diperolehnya konfigurasi model yang optimal dalam memprediksi *Packet Loss Ratio (PLR)*.

2.2 Penelitian Terkait

Telah banyak penelitian yang dilakukan dengan menggunakan metode *Deep Learning*, khususnya *Long Short-Term Memory (LSTM)*. Beberapa penelitian terkait disajikan sebagai referensi pada Tabel 2.1.

Tabel 2. 1 Penelitian Terdahulu

No.	Peneliti	Objek	Variabel	Algoritma	Jumlah Data	Akurasi
1.	(Devi Rahmayanti, 2025)	Simulasi Jaringan Seluler	<i>Packet Loss Ratio, Latency, Throughput.</i>	KNN, SVM, LSTM.	100.000 Data Train, 200 Data Train	LSTM: MAPE 3.2% RMSE 0.017%
2.	(Purnawansyah et al., 2024)	Jarinan Kampus (<i>Real-Time Traffic Monitoring</i>)	<i>Packet Loss Ratio, Latency, Throughput, Bit Rate.</i>	LSTM, CNN, Esemble Learning.	255.148 Data.	LSTM-CNN: 100%, MCC&Kappa: 1.00
3.	(Saini et al., 2024)	<i>AI-Driven Traffic Dropping Pada Jaringan Modern.</i>	<i>Packet Loss Ratio, Jitter, Latency, Queue Size, Traffic Volume.</i>	CNN, RNN, Reinforcement Learning.	-	-
2.	(Zaheer et al., 2023)	Harga Saham Shanghai Composite Index	-	CNN, LSTM, RNN, Hybrid.	5951 Hari, Data Time Series.	R ² : 0,986 (Pada lapisan RNN Tunggal).
3.	(Luthfia nsyah & Wasito, 2023)	Harga Saham BBRI	-	LSTM & Regresi Linear	Data Time Series, Saham Selama 22 Tahun (2001-2022)	RMSE: 26.634 (Regresi Linear Python)
6.	(Saha & Ghosh, 2020)	Jaringan Next Generation Network	<i>Packet Loss Ratio, Jitter, Latency, Throughput.</i>	Decession Tree, Logistic Regression.	190.166 Data	Decession Tree: 89.6%

Berdasarkan penelitian-penelitian terdahulu, dapat disimpulkan bahwa metode *Deep Learning*, khususnya *Long Short-Term Memory* (LSTM), telah banyak digunakan secara efektif dalam memprediksi data deret waktu (*time series*) di berbagai bidang, termasuk jaringan telekomunikasi. Selain itu, variabel *Packet Loss Ratio*, *Jitter*, *Latency*, dan *Throughput* merupakan metrik penting dalam mengukur dan memprediksi kualitas layanan jaringan.

Namun, tidak semua penelitian sebelumnya menggunakan keempat variabel tersebut secara bersamaan. Misalnya, beberapa penelitian lebih menekankan pada throughput, sementara penelitian lain hanya menggunakan packet loss dan delay.

Selain penelitian-penelitian yang tercantum pada Tabel 2.1, Pundir dan Sandhu (2021) melakukan tinjauan sistematis terhadap penerapan *Machine Learning* dalam meningkatkan kualitas layanan (*Quality of Service* atau QoS) pada jaringan sensor. Penelitian tersebut menyimpulkan bahwa *Packet Loss Ratio*, *Jitter*, *Latency*, dan *Throughput* termasuk ke dalam metrik kualitas layanan yang paling penting. Berbagai teknik *Machine Learning*, seperti *Artificial Neural Network* (ANN), *Support Vector Machine* (SVM), *Random Forest*, dan *Reinforcement Learning*, telah digunakan untuk mengoptimalkan kualitas layanan dengan cara mempelajari pola dari data historis.

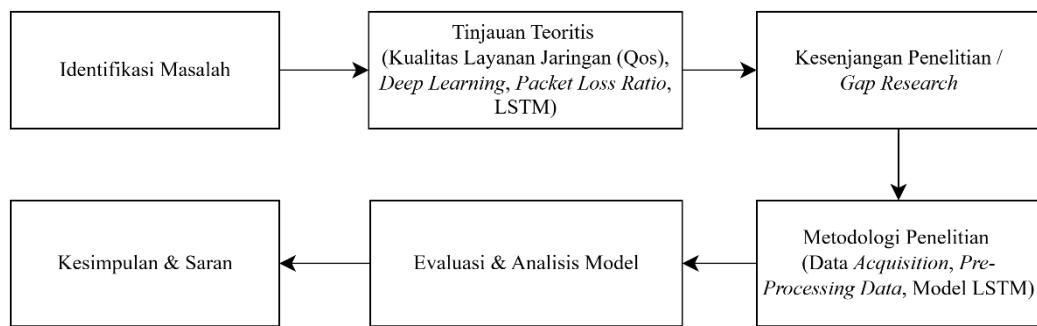
Adapun penelitian yang dilakukan oleh (Tarjono et al., 2025) menerapkan klasifikasi biner dengan target variabel 0 dan 1 untuk mendeteksi kejadian hujan, serta menggunakan hyperparameter tuning untuk meningkatkan kinerja model deep learning.

Meskipun demikian, terdapat kesenjangan penelitian (*research gap*), yakni belum banyak studi yang secara khusus memfokuskan pada prediksi lonjakan *Packet Loss Ratio* (PLR) sebagai permasalahan klasifikasi biner. Mengingat keberhasilan metode *Deep Learning* dalam berbagai konteks prediktif yang serupa, penerapan model *Long Short-Term Memory* (LSTM) dalam memprediksi PLR menjadi sangat relevan. Penelitian ini secara sistematis menerapkan strategi

penanganan ketidakseimbangan kelas (*class weight*) guna memastikan model memiliki kemampuan *recall* yang tinggi dalam mendeteksi lonjakan, yang sangat krusial dalam konteks sistem peringatan dini.

2.3 Kerangka Pemikiran

Kerangka pemikiran dari penilitian ini digambarkan pada Gambar 2.1.



Gambar 2. 3 Diagram Alir Kerangka Pemikiran

Pada gambar 2.1 di atas menggambarkan alur logis dari penilitian, di mana terdapat enam tahapan utama. Tahap awal dimulai dengan identifikasi masalah, di mana tingginya nilai *Packet Loss Ratio* (PLR) dapat berdampak pada penurunan kualitas layanan jaringan. Untuk memahami konteks permasalahan secara mendalam, dilakukan tinjauan teoritis terhadap konsep-konsep dasar, seperti *Deep Learning*, kualitas layanan jaringan, metrik-metrik pada jaringan telekomunikasi, serta arsitektur model *Long Short-Term Memory* (LSTM).

Berdasarkan studi-studi terdahulu, ditemukan adanya kesenjangan penelitian, di mana penelitian ini berfokus pada prediksi lonjakan *Packet Loss Ratio* (PLR) sebagai permasalahan klasifikasi biner yang memerlukan pendekatan sistematis dengan model *Long Short-Term Memory* (LSTM). Selanjutnya, penelitian dilanjutkan pada tahap metodologi, yang mencakup proses mulai dari pengumpulan data hingga pembangunan model prediksi. Model yang dibangun akan dievaluasi menggunakan metrik klasifikasi biner, seperti *Accuracy*, *Precision*, *Recall*, *F1*-

Score, dan *ROC AUC*. Hasil evaluasi tersebut kemudian akan dianalisis dan diinterpretasikan untuk menilai performa model serta relevansinya terhadap tujuan penelitian. Penelitian ini akan ditutup dengan penarikan kesimpulan yang menjawab rumusan masalah, serta penyampaian saran untuk penelitian selanjutnya berdasarkan keterbatasan dan peluang yang ditemukan..