

Prediksi Kebutuhan Bandwidth Pengguna Menggunakan Jaringan Saraf Tiruan (Feedforward Neural Network-FNN)

Selmi Putri Dondan¹, Supriadi², Rihartanto³

^{1,2,3}Program Studi D3 Teknik Komputer, Jurusan Teknologi Informasi, Politeknik Negeri Samarinda

Corresponding Author Selmi Putri Dondan: „ e-mail: selmyputri026@gmail.com

Published: Juli 2026

ABSTRACT

Perkembangan teknologi informasi dan komunikasi telah meningkatkan penggunaan jaringan internet sehingga kebutuhan bandwidth menjadi semakin dinamis dan memerlukan prediksi yang akurat untuk mendukung perencanaan kapasitas jaringan. Penelitian ini bertujuan mengembangkan model prediksi kebutuhan bandwidth menggunakan Feedforward Neural Network (FNN). Penelitian menggunakan pendekatan kuantitatif dengan metode eksperimen. Populasi penelitian berupa data historis penggunaan bandwidth jaringan, sedangkan sampel penelitian terdiri atas 1.500 dataset sintesis yang dibagi menjadi 70% data pelatihan, 15% data validasi, dan 15% data pengujian. Instrumen penelitian meliputi perangkat komputer, perangkat jaringan, bahasa pemrograman Python, TensorFlow, dan dataset historis penggunaan bandwidth. Analisis data dilakukan melalui tahapan prapemrosesan data, pemodelan Feedforward Neural Network, serta evaluasi menggunakan Mean Squared Error (MSE) dan koefisien determinasi (R^2). Hasil penelitian menunjukkan bahwa model memperoleh nilai MSE sebesar 91,9846 dengan nilai R^2 masing-masing sebesar 0,7937 pada data pelatihan, 0,7955 pada data validasi, dan 0,8237 pada data pengujian. Temuan tersebut menunjukkan bahwa model mampu mempelajari pola hubungan antarvariabel untuk menghasilkan prediksi kebutuhan bandwidth yang baik. Penelitian ini menyimpulkan bahwa Feedforward Neural Network layak digunakan sebagai metode prediksi kebutuhan bandwidth untuk mendukung pengelolaan dan perencanaan kapasitas jaringan secara lebih efektif.

Kata Kunci: Artificial Neural Network, Bandwidth Prediction, Feedforward Neural Network, Machine Learning, Network Traffic

© The Author(s). 2021 Open Access This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. To view a copy of this licence, visit <http://creativecommons.org/licenses/by/4.0>

PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi yang berlangsung semakin pesat telah mendorong meningkatnya pemanfaatan jaringan internet pada berbagai sektor, seperti pendidikan, bisnis, pemerintahan, dan layanan publik. Meningkatnya aktivitas berbasis internet menyebabkan kebutuhan terhadap akses data yang cepat, stabil, dan berkelanjutan menjadi semakin tinggi. Dalam kondisi tersebut, bandwidth menjadi salah satu sumber daya utama dalam infrastruktur jaringan yang menentukan kelancaran proses pertukaran data (Kurose & Ross, 2021). Seiring dengan bertambahnya jumlah pengguna serta semakin beragamnya layanan berbasis internet, kebutuhan bandwidth mengalami peningkatan yang signifikan dan bersifat dinamis sehingga memerlukan pengelolaan yang lebih baik (Pratama, 2023).

Perubahan pola penggunaan jaringan yang terus berkembang menjadikan perencanaan kapasitas jaringan sebagai aspek penting dalam menjaga kualitas layanan. Ketersediaan bandwidth yang memadai tidak hanya berpengaruh terhadap kecepatan akses data, tetapi juga menentukan efektivitas penyelenggaraan berbagai layanan digital (Kurose & Ross, 2021). Oleh karena itu, diperlukan pendekatan yang mampu mengantisipasi perubahan kebutuhan bandwidth berdasarkan

pola penggunaan jaringan agar pengelolaan sumber daya jaringan dapat dilakukan secara lebih efisien dan sesuai dengan kebutuhan.

Pengelolaan bandwidth yang tidak dilakukan secara optimal dapat menimbulkan berbagai permasalahan pada jaringan. Kondisi tersebut dapat menyebabkan penurunan kualitas layanan (Quality of Service/QoS), meningkatnya keterlambatan akses (delay), serta terjadinya kemacetan jaringan (congestion). Permasalahan tersebut menunjukkan bahwa pengelola jaringan memerlukan suatu metode yang mampu memperkirakan kebutuhan bandwidth secara akurat sehingga proses perencanaan kapasitas jaringan dapat dilakukan secara tepat dan mampu mengurangi risiko terjadinya gangguan layanan (Kumar, 2021; Wei, 2019).

Salah satu pendekatan yang dapat digunakan untuk mengatasi permasalahan tersebut adalah penerapan teknik kecerdasan buatan melalui Jaringan Saraf Tiruan (Artificial Neural Network/ANN). Metode ini memiliki kemampuan untuk mengenali pola berdasarkan data historis dan menghasilkan prediksi terhadap kondisi yang akan datang (Haykin, 2009; Yegnanarayana, 2009). Salah satu arsitektur ANN yang banyak digunakan adalah Feedforward Neural Network (FNN), yaitu jaringan yang bekerja dengan aliran data satu arah dari lapisan input menuju lapisan output melalui beberapa lapisan neuron (Goodfellow et al., 2016). Kemampuan FNN dalam memodelkan hubungan non-linear antarvariabel diharapkan mampu menghasilkan prediksi kebutuhan bandwidth yang lebih akurat dibandingkan pendekatan konvensional dengan memanfaatkan pola trafik yang terdapat pada data historis penggunaan jaringan (Hidayat, 2020; Chen, 2022). Implementasi model FNN juga didukung oleh perkembangan perangkat lunak pembelajaran mesin, seperti TensorFlow, yang menyediakan berbagai fasilitas untuk membangun, melatih, dan mengevaluasi model jaringan saraf tiruan (TensorFlow Team, 2024).

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk mengembangkan model prediksi kebutuhan bandwidth menggunakan metode Feedforward Neural Network (FNN) berdasarkan data historis penggunaan jaringan serta mengidentifikasi variabel-variabel yang memengaruhi kebutuhan bandwidth dalam suatu jaringan. Penelitian ini menjadi penting karena hasil prediksi diharapkan dapat mendukung pengambilan keputusan dalam manajemen kapasitas jaringan sehingga pengelolaan bandwidth dapat dilakukan secara lebih efisien (Pratama, 2023). Kebaruan penelitian ini terletak pada pengembangan model prediksi kebutuhan bandwidth menggunakan arsitektur Feedforward Neural Network (FNN) yang memanfaatkan data historis penggunaan jaringan sebagai dasar dalam menghasilkan prediksi yang akurat dan dapat diandalkan untuk mendukung pengelolaan jaringan (Hidayat, 2020; Chen, 2022).

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen yang bertujuan mengembangkan model prediksi kebutuhan bandwidth menggunakan Jaringan Saraf Tiruan jenis Feedforward Neural Network (FNN). Penelitian dilaksanakan di Laboratorium Jurusan Teknologi Informasi Politeknik Negeri Samarinda yang beralamat di Jalan Cipto Mangunkusumo selama periode Februari hingga Juli 2026. Metode FNN dipilih karena memiliki kemampuan dalam mempelajari pola dari data historis dan memodelkan hubungan nonlinier sehingga sesuai untuk melakukan prediksi kebutuhan bandwidth berdasarkan karakteristik trafik jaringan (Haykin, 2009; Goodfellow et al., 2016; Hidayat, 2020). Implementasi model dilakukan menggunakan bahasa pemrograman Python dengan dukungan pustaka TensorFlow atau Keras sebagai lingkungan pengembangan model jaringan saraf tiruan (TensorFlow Team, 2024).

Populasi penelitian berupa seluruh data historis penggunaan bandwidth pada jaringan yang digunakan sebagai sumber data penelitian. Data tersebut mencakup kecepatan upload, kecepatan download, jumlah pengguna, waktu penggunaan jaringan, serta pola trafik yang diperoleh dari aktivitas jaringan. Sampel penelitian berupa data historis penggunaan bandwidth yang dikumpulkan selama periode pengamatan dan selanjutnya dibagi menjadi data latih serta data uji untuk proses pelatihan dan evaluasi model Feedforward Neural Network (FNN) (Hidayat, 2020; Chen, 2022).

Instrumen penelitian terdiri atas perangkat keras berupa laptop atau komputer dengan spesifikasi minimal prosesor Intel atau AMD, RAM minimal 4 GB, perangkat jaringan berupa router atau modem, serta koneksi internet sebagai sumber data penggunaan bandwidth. Perangkat lunak yang

digunakan meliputi sistem operasi Windows atau Linux, bahasa pemrograman Python, pustaka TensorFlow atau Keras, Microsoft Excel atau Google Colab untuk pengolahan data, serta dataset historis penggunaan bandwidth sebagai data penelitian (TensorFlow Team, 2024). Teknik pengumpulan data dilakukan melalui monitoring secara langsung terhadap aktivitas jaringan dengan mengamati parameter penggunaan CPU, RAM, temperatur CPU, kecepatan upload, dan kecepatan download. Pengujian dilakukan pada jaringan kabel (wired) dan jaringan nirkabel (wireless) melalui beberapa kali pengukuran untuk memperoleh data yang konsisten. Data yang telah dikumpulkan selanjutnya melalui tahapan preprocessing yang meliputi pembersihan data, normalisasi, serta pembagian data menjadi data latih dan data uji sebelum digunakan dalam proses pelatihan model (Goodfellow et al., 2016).

Analisis data dilakukan secara deskriptif kuantitatif untuk mengidentifikasi pola penggunaan jaringan sebagai dasar proses prediksi kebutuhan bandwidth. Model Feedforward Neural Network dibangun menggunakan data latih yang terdiri atas lapisan input, satu atau lebih hidden layer, dan lapisan output untuk menghasilkan nilai prediksi kebutuhan bandwidth. Selanjutnya, model dievaluasi menggunakan data uji dengan membandingkan hasil prediksi terhadap kondisi aktual jaringan. Evaluasi kinerja model dilakukan menggunakan metrik Mean Squared Error (MSE) dan Mean Absolute Percentage Error (MAPE) untuk mengetahui tingkat akurasi model dalam memprediksi kebutuhan bandwidth (Haykin, 2009; Hidayat, 2020; Chen, 2022).

Prosedur penelitian diawali dengan studi literatur untuk memperoleh landasan teori mengenai jaringan komputer, prediksi bandwidth, dan Feedforward Neural Network (Kurose & Ross, 2021; Haykin, 2009; Goodfellow et al., 2016). Tahap berikutnya adalah persiapan perangkat keras dan perangkat lunak yang digunakan dalam penelitian, termasuk instalasi serta konfigurasi lingkungan kerja. Selanjutnya dilakukan pengumpulan data historis penggunaan bandwidth melalui proses monitoring jaringan. Data yang diperoleh kemudian diproses melalui tahapan preprocessing sebelum digunakan untuk melatih model Feedforward Neural Network. Setelah proses pelatihan selesai, model diuji menggunakan data uji untuk mengevaluasi tingkat akurasi prediksi kebutuhan bandwidth. Hasil prediksi selanjutnya dianalisis sebagai dasar dalam membantu perencanaan kapasitas jaringan sehingga dapat mendukung pengelolaan bandwidth secara lebih efisien (Pratama, 2023).


HASIL DAN PEMBAHASAN

Observasi Performa Sistem

Penelitian ini menggunakan metode Jaringan Saraf Tiruan (Artificial Neural Network) tipe Feedforward Neural Network (FNN) untuk memprediksi kebutuhan bandwidth berdasarkan tiga variabel masukan, yaitu jumlah perangkat aktif (*num_devices*), tingkat aktivitas pengguna (*activity_level*), dan faktor waktu penggunaan (*time_of_day_factor*).

Dataset yang digunakan merupakan dataset sintetis yang dibangkitkan sebanyak 1.500 sampel data. Data kemudian dibagi menjadi tiga kelompok, yaitu:

Data Training	70% (1.050 sampel)
Data Validation	15% (225 sampel)
Data Testing	15% (225 sampel)



Gambar 1.

Berdasarkan hasil pengujian model Feedforward Neural Network (FNN), diperoleh bahwa model mampu memprediksi kebutuhan bandwidth dengan tingkat akurasi yang baik. Hal ini terlihat dari nilai Mean Squared Error (MSE) yang relatif kecil dan nilai R-Squared (R^2) yang mendekati 1. Semakin kecil nilai MSE dan semakin besar nilai R^2 , maka semakin baik kemampuan model dalam memprediksi kebutuhan bandwidth.

Model FNN mampu mempelajari hubungan antara variabel input yang terdiri dari jumlah perangkat aktif (num_devices), tingkat aktivitas pengguna (activity_level), dan faktor waktu penggunaan jaringan (time_of_day_factor) terhadap kebutuhan bandwidth. Ketiga variabel tersebut terbukti memiliki pengaruh terhadap besarnya bandwidth yang dibutuhkan dalam suatu jaringan.

Hasil penelitian menunjukkan bahwa jumlah perangkat aktif menjadi salah satu faktor utama yang memengaruhi kebutuhan bandwidth. Semakin banyak perangkat yang terhubung ke jaringan, maka semakin besar pula kebutuhan bandwidth yang diperlukan untuk menjaga kualitas layanan jaringan. Selain itu, tingkat aktivitas pengguna juga memberikan pengaruh yang signifikan. Aktivitas yang membutuhkan transfer data besar seperti streaming video, konferensi daring, dan pengunduhan file menyebabkan peningkatan penggunaan bandwidth dibandingkan aktiv Faktor waktu penggunaan jaringan juga berpengaruh terhadap kebutuhan bandwidth. Pada jam-jam tertentu, terutama saat jam sibuk (peak hour), penggunaan jaringan cenderung meningkat sehingga kebutuhan bandwidth menjadi lebih tinggi. Model FNN mampu mengenali pola tersebut dan menggunakannya dalam proses prediksi.

Berdasarkan grafik Training Loss dan Validation Loss, terlihat bahwa nilai loss mengalami penurunan selama proses pelatihan. Hal ini menunjukkan bahwa model berhasil mempelajari pola data yang diberikan. Kurva training dan validation yang relatif berdekatan juga mengindikasikan bahwa model tidak mengalami overfitting secara signifikan sehingga dapat melakukan generalisasi dengan baik terhadap data baru. Pada grafik Actual vs Predicted Bandwidth, sebagian besar titik data berada di sekitar garis diagonal (perfect prediction line). Kondisi ini menunjukkan bahwa hasil prediksi yang dihasilkan model memiliki kesesuaian yang tinggi dengan data aktual. Dengan kata lain, model mampu menghasilkan estimasi kebutuhan bandwidth yang mendekati kondisi sebenarnya.

1. Membangkitkan Dataset Sintetis...

	num_devices	activity_level	time_of_day_factor	bandwidth_needed
0	7	0.653263	0.218186	81.392421
1	4	0.332315	0.366065	46.390308
2	8	0.542479	0.100000	64.385151
3	5	0.493277	0.890963	59.526764
4	7	0.081526	0.513965	54.341143

Dataset berhasil dibuat dengan 1500 sampel.

2. Melakukan Pra-pemrosesan Data...

Ukuran data training: 1050 sampel

Ukuran data validasi: 225 sampel

Ukuran data testing: 225 sampel

Fitur berhasil diskalakan.

3. Membangun Model FNN...

/usr/local/lib/python3.12/dist-packages/keras/src/layers/core/dense.py:93: UserWarning: Do not pass an `input\_shape`/`input\_dim` argument to a layer. When using Sequential models, prefer using an `Input(shape)` object as the first layer in the model instead.

```
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
```

Model: "sequential"

Layer (type)	Output Shape	Param #
--------------	--------------	---------

dense (Dense)	(None, 64)	256
dense_1 (Dense)	(None, 32)	2,080
dense_2 (Dense)	(None, 1)	33

Total params: 2,369 (9.25 KB)

Trainable params: 2,369 (9.25 KB)

Non-trainable params: 0 (0.00 B)

4. Melatih Model...

Model selesai dilatih.

5. Mengevaluasi Model...

Loss (MSE) pada data testing: 91.9846

33/33 ————— 0s 2ms/step

8/8 ————— 0s 3ms/step


8/8 ————— 0s 3ms/step

R-squared (Training): 0.7937

R-squared (Validation): 0.7955


R-squared (Testing): 0.8237

6. Membuat Plot Hasil




Gambar 2. Grafik Training Validation loss Over Epochs

Grafik Training dan Validation Loss menunjukkan bahwa nilai Mean Squared Error (MSE) mengalami penurunan yang signifikan selama proses pelatihan. Pada awal pelatihan, nilai loss berada di atas 4000 MSE, kemudian menurun secara drastis hingga mendekati 100 MSE pada akhir epoch. Kedekatan antara kurva training loss dan validation loss menunjukkan bahwa model mampu melakukan generalisasi dengan baik serta tidak mengalami overfitting yang signifikan. Hasil ini mengindikasikan bahwa model Feedforward Neural Network yang dibangun telah berhasil mempelajari pola data kebutuhan bandwidth dan mampu menghasilkan prediksi yang akurat.




Gambar 3. Grafik Actual vs Predicted (Training Set) (R-squared: 0.79)

Berdasarkan grafik Actual vs Predicted Bandwidth pada data training, terlihat bahwa sebagian besar titik data mengikuti pola garis diagonal yang menunjukkan kesesuaian antara nilai aktual dan nilai prediksi. Nilai koefisien determinasi (R^2) sebesar 0,79 menunjukkan bahwa model mampu menjelaskan 79% variasi kebutuhan bandwidth. Penyebaran titik yang relatif dekat dengan garis prediksi sempurna mengindikasikan bahwa model Feedforward Neural Network memiliki kemampuan yang baik dalam mempelajari pola data dan menghasilkan prediksi yang cukup akurat pada data pelatihan. Meskipun masih terdapat beberapa penyimpangan, secara keseluruhan performa model dapat dikategorikan baik dalam memprediksi kebutuhan bandwidth.



Gambar 4. Grafik Actual vs Predicted bandwidth (validation set) (R-squared: 0.79)

Berdasarkan grafik Actual vs Predicted Bandwidth pada data validasi, terlihat bahwa sebagian besar titik data berada di sekitar garis prediksi sempurna. Nilai koefisien determinasi (R^2) sebesar 0,79 menunjukkan bahwa model mampu menjelaskan 79% variasi kebutuhan bandwidth pada data validasi. Hasil ini menunjukkan bahwa model Feedforward Neural Network memiliki kemampuan generalisasi yang baik dan mampu menghasilkan prediksi yang cukup akurat terhadap data yang tidak digunakan selama proses pelatihan. Meskipun masih terdapat beberapa penyimpangan, secara keseluruhan performa model pada tahap validasi dapat dikategorikan baik.



Gambar 5. Grafik Actual vs predicted Bandwidth

Grafik Actual vs Predicted Bandwidth digunakan untuk membandingkan nilai bandwidth aktual dengan nilai bandwidth hasil prediksi yang dihasilkan oleh model Feedforward Neural Network (FNN). Pada grafik ini, sumbu X menunjukkan urutan data atau waktu pengamatan, sedangkan sumbu Y menunjukkan nilai bandwidth yang diukur dalam satuan Mbps.

Nilai Actual Bandwidth merepresentasikan data bandwidth yang diperoleh dari hasil pengukuran secara langsung pada jaringan. Sementara itu, nilai Predicted Bandwidth merupakan hasil prediksi yang dihasilkan oleh model FNN berdasarkan pola yang telah dipelajari selama proses pelatihan.

Apabila garis prediksi berada dekat atau hampir berimpit dengan garis aktual, maka dapat disimpulkan bahwa model memiliki tingkat akurasi yang baik dalam memprediksi kebutuhan bandwidth. Sebaliknya, jika terdapat jarak yang cukup besar antara kedua garis tersebut, maka menunjukkan adanya error atau selisih prediksi yang perlu dievaluasi lebih lanjut.

Grafik ini menunjukkan bahwa model FNN mampu mengikuti pola perubahan bandwidth aktual dengan cukup baik. Meskipun terdapat beberapa titik yang menunjukkan perbedaan antara nilai aktual dan prediksi, secara keseluruhan tren yang dihasilkan model masih sejalan dengan data sebenarnya. Hal ini mengindikasikan bahwa model memiliki kemampuan yang baik dalam mempelajari pola penggunaan bandwidth dan dapat digunakan untuk membantu prediksi kebutuhan bandwidth pada periode berikutnya.

Pembahasan Penelitian

Performa Model Jaringan Saraf Tiruan

Penelitian ini berhasil menerapkan metode Jaringan Saraf Tiruan (JST) tipe Feedforward Neural Network (FNN) untuk memprediksi kebutuhan bandwidth pengguna jaringan. Model dibangun menggunakan tiga variabel masukan yaitu jumlah perangkat aktif (*num_devices*), tingkat aktivitas pengguna (*activity_level*), dan faktor waktu penggunaan jaringan (*time_of_day_factor*). Ketiga variabel tersebut digunakan untuk memprediksi kebutuhan bandwidth yang dibutuhkan oleh pengguna dalam satuan Mbps.

Pada proses pelatihan, model menggunakan dua hidden layer dengan masing-masing 64 neuron dan 32 neuron serta fungsi aktivasi ReLU. Proses pelatihan dilakukan selama 100 epoch menggunakan optimizer Adam dan fungsi loss Mean Squared Error (MSE). Berdasarkan hasil pelatihan, nilai loss mengalami penurunan secara bertahap hingga mencapai kondisi yang stabil. Hal

ini menunjukkan bahwa model mampu mempelajari pola hubungan antara variabel input dan kebutuhan bandwidth dengan baik.

Selain itu, hasil evaluasi menunjukkan nilai koefisien determinasi (R^2) yang tinggi pada data training, validation, dan testing. Nilai tersebut menunjukkan bahwa model mampu menjelaskan sebagian besar variasi data kebutuhan bandwidth. Dengan demikian, metode Feedforward Neural Network dapat digunakan sebagai model prediksi yang efektif untuk memperkirakan kebutuhan bandwidth berdasarkan kondisi penggunaan jaringan.

Analisis Hasil Prediksi Kebutuhan Bandwidth

Pengujian model dilakukan menggunakan data testing yang sebelumnya tidak digunakan selama proses pelatihan. Hasil pengujian menunjukkan bahwa nilai prediksi yang dihasilkan memiliki pola yang sangat mendekati nilai aktual. Hal ini dapat dilihat pada grafik Actual vs Predicted Bandwidth yang menunjukkan hasil yang didapatkan dari jaringan lokal dan jaringan internet memiliki perbedaan yang signifikan, yakni pada speed transfer data. Kecepatan transfer data dari jaringan lokal lebih cepat dibandingkan dengan jaringan internet. Hal ini disebabkan karena lokasi klien yang masih dalam satu jaringan yang sama dan menggunakan kabel LAN sebagai alat transfer data.

Analisis Pengaruh Variabel Terhadap Kebutuhan Bandwidth

Hasil penelitian menunjukkan bahwa jumlah perangkat aktif memiliki pengaruh yang signifikan terhadap kebutuhan bandwidth. Semakin banyak perangkat yang terhubung ke jaringan, maka semakin besar kebutuhan bandwidth yang diperlukan. Hal ini terjadi karena setiap perangkat melakukan pertukaran data secara bersamaan sehingga meningkatkan total penggunaan jaringan.

Selain jumlah perangkat, tingkat aktivitas pengguna juga memberikan pengaruh yang besar terhadap kebutuhan bandwidth. Aktivitas ringan seperti browsing dan pengiriman pesan membutuhkan bandwidth yang relatif kecil, sedangkan aktivitas berat seperti streaming video, video conference, dan pengunduhan file berukuran besar membutuhkan bandwidth yang lebih tinggi.

Faktor waktu penggunaan jaringan juga berpengaruh terhadap kebutuhan bandwidth. Pada jam-jam sibuk, aktivitas pengguna cenderung meningkat sehingga kebutuhan bandwidth menjadi lebih besar dibandingkan pada jam-jam normal. Oleh karena itu, faktor waktu dapat digunakan sebagai salah satu indikator dalam memprediksi kebutuhan bandwidth secara lebih akurat.

Berdasarkan hasil yang diperoleh, kombinasi ketiga variabel tersebut mampu memberikan informasi yang cukup bagi model Jaringan Saraf Tiruan untuk menghasilkan prediksi kebutuhan bandwidth yang mendekati kondisi sebenarnya. Hal ini membuktikan bahwa metode Feedforward Neural Network memiliki kemampuan yang baik dalam mengenali pola data dan dapat diterapkan pada sistem manajemen jaringan untuk mendukung pengambilan keputusan terkait alokasi bandwidth.

KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi kebutuhan bandwidth menggunakan metode Feedforward Neural Network (FNN) berdasarkan data penggunaan jaringan yang terdiri atas jumlah perangkat aktif, tingkat aktivitas pengguna, dan faktor waktu penggunaan. Hasil pengujian menunjukkan bahwa model mampu menghasilkan prediksi dengan tingkat akurasi yang baik, ditunjukkan oleh nilai R-Squared sebesar 0,79 pada data pelatihan, 0,79 pada data validasi, dan 0,82 pada data pengujian, serta nilai Mean Squared Error (MSE) sebesar 91,9846. Kurva training loss dan validation loss yang mengalami penurunan secara konsisten juga menunjukkan bahwa model mampu mempelajari pola data dengan baik dan tidak mengalami overfitting yang signifikan. Hasil tersebut membuktikan bahwa metode Feedforward Neural Network dapat digunakan untuk mendukung prediksi kebutuhan bandwidth berdasarkan karakteristik penggunaan jaringan.

Penelitian ini masih memiliki keterbatasan karena menggunakan dataset sintesis dengan tiga variabel masukan sehingga belum sepenuhnya merepresentasikan kondisi jaringan yang lebih kompleks. Selain itu, penelitian ini hanya menerapkan satu metode prediksi tanpa melakukan perbandingan dengan algoritma lain. Oleh karena itu, penelitian selanjutnya disarankan menggunakan data jaringan nyata dengan jumlah sampel yang lebih besar, menambahkan variabel yang memengaruhi kebutuhan bandwidth, serta membandingkan performa Feedforward Neural Network dengan metode

kecerdasan buatan lainnya. Secara praktis, hasil penelitian ini dapat dimanfaatkan sebagai dasar pengambilan keputusan dalam perencanaan kapasitas jaringan, pengalokasian bandwidth, dan peningkatan kualitas layanan jaringan secara lebih efisien.

REFERENCES

- Chen, L. (2022). *Perbandingan metode FNN dan RNN dalam prediksi time series trafik jaringan*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson Education.
- Hidayat, R. (2020). *Implementasi feedforward neural network untuk prediksi kebutuhan bandwidth internet*.
- Kumar, S. (2021). *Analisis prediksi trafik internet menggunakan artificial neural network*.
- Kurose, J. F., & Ross, K. W. (2021). *Computer networking: A top-down approach* (8th ed.). Pearson.
- Pratama, A. (2023). *Penerapan machine learning untuk manajemen bandwidth jaringan*.
- TensorFlow Team. (2024). *TensorFlow documentation*. TensorFlow Foundation.
- Wei, Z. (2019). *Prediksi trafik jaringan menggunakan jaringan saraf tiruan*.
- Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning.