

# Hybrid GCN-LSTM untuk Prediksi Permintaan Obat Menggunakan Dataset IQVIA Multi-Regional

## *Hybrid GCN-LSTM for Drug Demand Prediction Using Multi-Regional IQVIA Dataset*

Irmawati<sup>1</sup>; Ayu Lestari Azis<sup>2</sup>; Sustrin Abasa<sup>3</sup>; Firman Aziz<sup>4,\*</sup>

<sup>1,2</sup> IRMEX Digital Akademika, Makassar 90155, Indonesia

<sup>3,4</sup> Universitas Pancasakti, Makassar 90121, Indonesia

<sup>1</sup> [irmawati@irmexdigikal.com](mailto:irmawati@irmexdigikal.com); <sup>2</sup> [ayulestariazis@irmexdigika.com](mailto:ayulestariazis@irmexdigika.com); <sup>3</sup> [sustrin.abasa@unpacti.ac.id](mailto:sustrin.abasa@unpacti.ac.id); <sup>4</sup> [firman.aziz@unpacti.ac.id](mailto:firman.aziz@unpacti.ac.id)

\* Corresponding author

### Abstrak

Ketersediaan obat merupakan aspek krusial dalam sistem pelayanan kesehatan yang membutuhkan pengelolaan permintaan secara akurat untuk menghindari risiko stock-out maupun overstock. Penelitian ini mengusulkan pendekatan Hybrid Graph Convolutional Network–Long Short-Term Memory (GCN-LSTM) untuk memprediksi permintaan obat menggunakan dataset IQVIA Pharmaceutical Sales yang terdiri atas 960 observasi mingguan dari delapan kategori terapi obat selama periode 2014–2019. Kebaruan penelitian ini terletak pada integrasi informasi spasial berbasis graph correlation dan pembelajaran temporal dalam satu arsitektur prediksi untuk menangkap keterkaitan antar kategori obat dan dinamika permintaan dari waktu ke waktu. Data diproses melalui tahapan cleaning, normalisasi Min-Max Scaling, dan sliding window sebelum dibentuk menjadi graph berdasarkan korelasi Pearson antar kategori obat. Model GCN-LSTM kemudian dibandingkan dengan ARIMA, Random Forest, dan LSTM tunggal menggunakan metrik RMSE, MAE, dan MAPE. Hasil eksperimen menunjukkan bahwa model GCN-LSTM menghasilkan performa terbaik dengan RMSE 3,821; MAE 2,741; dan MAPE 7,86%, lebih baik dibandingkan seluruh model pembandingan. Hasil ini menunjukkan bahwa integrasi informasi spasial dan temporal mampu meningkatkan akurasi prediksi permintaan obat secara signifikan. Pendekatan yang diusulkan berpotensi mendukung pengambilan keputusan pada manajemen rantai pasok farmasi, perencanaan inventori, dan optimalisasi distribusi obat.

**Kata Kunci:** GCN-LSTM; prediksi permintaan obat; IQVIA dataset; spatio-temporal forecasting; graph neural network; supply chain farmasi.

### Abstract

Drug availability is a crucial aspect in the healthcare system that requires accurate demand management to avoid the risk of stock-outs and overstocks. This study proposes a Hybrid Graph Convolutional Network–Long Short-Term Memory (GCN-LSTM) approach to predict drug demand using the IQVIA Pharmaceutical Sales dataset consisting of 960 weekly observations from eight drug therapy categories during the period 2014–2019. The novelty of this study lies in the integration of spatial information based on graph correlation and temporal learning in a single prediction architecture to capture the relationship between drug categories and demand dynamics over time. The data is processed through cleaning, Min-Max Scaling normalization, and sliding window stages before being formed into a graph based on Pearson correlation between drug categories. The GCN-LSTM model is then compared with ARIMA, Random Forest, and a single LSTM using RMSE, MAE, and MAPE metrics. The experimental results show that the GCN-LSTM model produces the best performance with RMSE 3.821; MAE 2.741; and MAPE 7.86%, better than all comparison models. These results demonstrate that the integration of spatial and temporal information can significantly improve the accuracy of drug demand predictions. The proposed approach has the potential to support decision-making in pharmaceutical supply chain management, inventory planning, and drug distribution optimization.

**Keywords:** GCN-LSTM; drug demand forecasting; IQVIA dataset; spatio-temporal forecasting; graph neural network; pharmaceutical supply chain.

### Pendahuluan

Ketersediaan obat merupakan salah satu faktor utama dalam menjamin kualitas pelayanan kesehatan. Ketidakseimbangan antara jumlah persediaan dan kebutuhan obat dapat menyebabkan terjadinya kekurangan stok (stock-out) maupun kelebihan stok (overstock) yang berdampak pada peningkatan biaya operasional, penurunan kualitas layanan kesehatan, serta terganggunya efektivitas rantai pasok farmasi [1]. Dalam industri farmasi modern, kemampuan memprediksi permintaan obat secara akurat menjadi kebutuhan strategis untuk mendukung pengambilan keputusan pada aspek pengadaan, distribusi, dan manajemen inventori [2].

Permintaan obat memiliki karakteristik yang kompleks karena dipengaruhi oleh berbagai faktor, seperti pola penyakit, perubahan musim, kondisi demografi, kebijakan kesehatan, perilaku konsumsi masyarakat, hingga dinamika pasar farmasi global [3]. Kompleksitas tersebut menyebabkan pola permintaan obat bersifat nonlinier, dinamis, dan sering kali sulit diprediksi menggunakan pendekatan statistik konvensional. Oleh karena itu, berbagai penelitian telah berupaya mengembangkan metode prediksi yang lebih akurat guna meningkatkan efisiensi rantai pasok farmasi dan meminimalkan risiko kekurangan obat [4].

Metode prediksi tradisional seperti Moving Average, Exponential Smoothing, dan Autoregressive Integrated Moving Average (ARIMA) telah lama digunakan dalam berbagai aplikasi forecasting. Namun, metode tersebut memiliki keterbatasan dalam menangkap hubungan nonlinier dan ketergantungan jangka panjang yang umum ditemukan pada data permintaan farmasi [5]. Seiring berkembangnya teknologi komputasi, pendekatan berbasis Machine Learning dan Deep Learning mulai banyak diterapkan untuk mengatasi keterbatasan tersebut. Beberapa penelitian menunjukkan bahwa model berbasis deep learning mampu menghasilkan akurasi yang lebih baik dibandingkan metode statistik konvensional dalam berbagai kasus prediksi permintaan dan manajemen rantai pasok [2], [6].

Salah satu algoritma deep learning yang paling banyak digunakan dalam forecasting adalah Long Short-Term Memory (LSTM). LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi masalah vanishing gradient serta mampu mempelajari hubungan temporal jangka panjang pada data sekuensial [6]. Pada bidang farmasi, LSTM telah digunakan untuk memprediksi permintaan obat, konsumsi layanan kesehatan, dan kebutuhan inventori dengan hasil yang cukup baik [2]. Namun demikian, sebagian besar penelitian yang menggunakan LSTM hanya berfokus pada dimensi temporal dan mengabaikan hubungan spasial antar wilayah distribusi farmasi.

Dalam praktiknya, permintaan obat pada suatu wilayah tidak berdiri sendiri, melainkan memiliki keterkaitan dengan wilayah lain yang terhubung melalui jaringan distribusi, karakteristik epidemiologi, maupun pola konsumsi yang serupa. Hubungan antar wilayah tersebut membentuk struktur data non-Euclidean yang sulit direpresentasikan menggunakan model deep learning konvensional [7]. Oleh karena itu, diperlukan pendekatan yang mampu mengintegrasikan informasi spasial dan temporal secara simultan untuk menghasilkan prediksi yang lebih akurat.

Perkembangan Graph Neural Network (GNN), khususnya Graph Convolutional Network (GCN), menawarkan solusi untuk memodelkan hubungan kompleks antar entitas yang direpresentasikan dalam bentuk graph [7]. GCN mampu mengekstraksi informasi spasial dari hubungan antar node melalui proses agregasi fitur berbasis adjacency matrix sehingga banyak digunakan pada berbagai permasalahan forecasting berbasis jaringan [8]. Penelitian sebelumnya menunjukkan bahwa integrasi Graph Convolutional Network dengan model temporal seperti LSTM mampu meningkatkan performa prediksi karena dapat menangkap ketergantungan spasial dan temporal secara bersamaan [9].

Pada domain forecasting, pendekatan spatio-temporal berbasis graph telah berhasil diterapkan pada prediksi lalu lintas, permintaan transportasi, dan sistem distribusi yang memiliki keterkaitan antar lokasi [8], [10]. Selain itu, penelitian terbaru pada bidang farmasi menunjukkan bahwa kombinasi GCN dan LSTM mampu meningkatkan akurasi prediksi permintaan obat dibandingkan model deep learning konvensional karena dapat memanfaatkan hubungan antar produk maupun wilayah distribusi [3], [4]. Temuan tersebut menunjukkan bahwa pendekatan hybrid GCN-LSTM memiliki potensi besar untuk diterapkan pada sistem forecasting farmasi berbasis data multi-regional.

Penelitian ini menggunakan dataset IQVIA multi-regional yang diperoleh dari platform Kaggle. IQVIA merupakan salah satu penyedia data kesehatan dan farmasi terbesar di dunia yang menyediakan informasi pasar farmasi lintas negara dan wilayah sehingga banyak digunakan dalam penelitian maupun pengambilan keputusan industri farmasi [11]. Karakteristik dataset yang mencakup dimensi waktu dan wilayah menjadikannya sangat sesuai untuk pengembangan model spatio-temporal berbasis graph.

Berdasarkan uraian tersebut, penelitian ini mengusulkan model Hybrid Graph Convolutional Network dan Long Short-Term Memory (GCN-LSTM) untuk memprediksi permintaan obat menggunakan dataset IQVIA multi-regional. Pada model yang diusulkan, GCN digunakan untuk mengekstraksi hubungan spasial antar wilayah berdasarkan korelasi penjualan farmasi, sedangkan LSTM digunakan untuk mempelajari pola temporal permintaan obat dari data historis. Selanjutnya, performa model akan dibandingkan dengan beberapa metode baseline seperti ARIMA, Random


Forest, dan LSTM tunggal menggunakan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE).

Kontribusi utama penelitian ini meliputi: (1) pengembangan model hybrid GCN-LSTM untuk prediksi permintaan obat pada data farmasi multi-regional; (2) pemodelan hubungan antar wilayah menggunakan graph berbasis korelasi penjualan farmasi; (3) evaluasi komprehensif terhadap performa model dibandingkan metode konvensional dan deep learning; serta (4) penyediaan pendekatan forecasting yang dapat mendukung optimalisasi manajemen persediaan dan distribusi obat pada industri farmasi.

## Metode

### A. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan menerapkan model Hybrid Graph Convolutional Network–Long Short-Term Memory (GCN-LSTM) untuk memprediksi permintaan obat berdasarkan data historis penjualan farmasi multi-regional. Tahapan penelitian meliputi akuisisi data, preprocessing, konstruksi graph, pembentukan model GCN-LSTM, pelatihan model, evaluasi performa, dan analisis hasil. Metodologi penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Metodologi penelitian

### B. Dataset Penelitian

Dataset yang digunakan berasal dari notebook Kaggle Pharmaceutical Drug Demand Forecasting yang memanfaatkan data IQVIA [11]. Dataset berisi informasi historis permintaan dan penjualan produk farmasi dari berbagai wilayah pemasaran. Data terdiri atas atribut waktu, wilayah distribusi, kategori produk farmasi, serta jumlah penjualan. Karakteristik dataset yang digunakan ditunjukkan pada Tabel 1.

Tabel 1. Karakteristik Dataset

| <i>Karakteristik</i> | <i>Nilai</i>   |
|----------------------|----------------|
| Sumber Data          | IQVIA Dataset  |
| Jenis Data           | Time Series    |
| Domain               | Farmasi        |
| Cakupan              | Multi-Regional |
| Target Prediksi      | Drug Demand    |
| Format Data          | CSV            |
| Frekuensi            | Bulanan        |

Selain karakteristik umum yang ditunjukkan pada Tabel 1, dataset yang digunakan terdiri atas 960 observasi mingguan yang mencakup delapan kategori terapi obat, yaitu M01AB, M01AE, N02BA, N02BE, N05B, N05C, R03, dan R06. Data mencakup periode Januari 2014 hingga Desember 2019. Untuk keperluan pelatihan model,

dataset dibagi menjadi data pelatihan (70%), data validasi (15%), dan data pengujian (15%). Pembagian ini dilakukan secara kronologis untuk menjaga karakteristik deret waktu dan menghindari kebocoran informasi (data leakage) antara data pelatihan dan pengujian. Variabel target dalam penelitian ini adalah jumlah permintaan obat (drug demand), sedangkan variabel input berupa data historis penjualan pada setiap wilayah.

### C. Preprocessing Data

Tahap preprocessing data dilakukan untuk meningkatkan kualitas dataset sebelum digunakan dalam proses pelatihan model GCN-LSTM. Tahapan ini bertujuan untuk mengurangi pengaruh noise, meningkatkan konsistensi data, serta memastikan bahwa data yang digunakan telah memenuhi kebutuhan pemodelan spatio-temporal.

Pada tahap awal, dilakukan proses pembersihan data (*data cleaning*) dengan memeriksa keberadaan nilai hilang (*missing values*), data duplikat, nilai pencilan (*outlier*), serta inkonsistensi format data. Nilai yang hilang ditangani menggunakan metode *forward filling* untuk mempertahankan kontinuitas deret waktu, sedangkan data duplikat dihapus agar tidak menimbulkan bias pada proses pelatihan model. Selanjutnya, atribut tanggal dikonversi ke dalam format *datetime* sehingga dapat digunakan sebagai indeks temporal dalam analisis deret waktu.

Setelah proses pembersihan data selesai, dilakukan normalisasi menggunakan metode *Min-Max Scaling*. Proses normalisasi diperlukan karena rentang nilai penjualan antar wilayah memiliki skala yang berbeda-beda. Normalisasi bertujuan untuk mengubah seluruh nilai data ke dalam rentang 0 hingga 1 sehingga proses pembelajaran model menjadi lebih stabil dan konvergen. Persamaan normalisasi yang digunakan ditunjukkan pada Persamaan (1).

Selanjutnya, data yang telah dinormalisasi diubah menjadi bentuk sekuens menggunakan teknik *sliding window*. Teknik ini memungkinkan model mempelajari pola historis permintaan obat berdasarkan sejumlah periode sebelumnya untuk memprediksi permintaan pada periode berikutnya. Dalam penelitian ini digunakan panjang jendela (*window size*) sebanyak 12 periode yang merepresentasikan pola musiman tahunan pada data farmasi. Dengan pendekatan tersebut, setiap sampel pelatihan terdiri atas data permintaan obat selama dua belas periode sebelumnya yang digunakan untuk memprediksi permintaan pada periode selanjutnya.

Selain itu, untuk mendukung pemodelan spasial menggunakan Graph Convolutional Network, dilakukan agregasi data berdasarkan wilayah distribusi. Data penjualan dari setiap wilayah kemudian digunakan untuk membangun hubungan antar wilayah melalui analisis korelasi. Hasil proses preprocessing menghasilkan dataset yang telah terstruktur dalam bentuk data temporal dan spasial sehingga siap digunakan pada tahap konstruksi graph dan pelatihan model hybrid GCN-LSTM.

### D. Arsitektur Model Hybrid GCN-LSTM

Penelitian ini mengusulkan model Hybrid Graph Convolutional Network–Long Short-Term Memory (GCN-LSTM) untuk memprediksi permintaan obat berdasarkan data farmasi multi-regional. Model ini dirancang untuk mengintegrasikan kemampuan Graph Convolutional Network (GCN) dalam menangkap hubungan spasial antar wilayah distribusi farmasi dengan kemampuan Long Short-Term Memory (LSTM) dalam mempelajari pola temporal dari data historis permintaan obat. Integrasi kedua metode tersebut memungkinkan model untuk memahami keterkaitan spasial dan temporal secara simultan sehingga dapat menghasilkan prediksi yang lebih akurat dibandingkan model yang hanya memanfaatkan salah satu jenis informasi.


Tahap pertama dalam arsitektur yang diusulkan adalah pembentukan graph berdasarkan hubungan antar wilayah distribusi farmasi. Setiap wilayah direpresentasikan sebagai node, sedangkan hubungan antar wilayah direpresentasikan sebagai edge yang dibentuk menggunakan nilai korelasi penjualan farmasi. Hubungan tersebut kemudian disusun ke dalam adjacency matrix yang digunakan sebagai masukan pada layer Graph Convolutional Network.

Layer GCN bertugas melakukan agregasi informasi dari node-node yang saling terhubung sehingga mampu mengekstraksi representasi spasial dari pola distribusi permintaan obat. Melalui proses propagasi informasi pada graph, setiap node memperoleh informasi tambahan dari wilayah lain yang memiliki karakteristik permintaan serupa. Dengan demikian, fitur yang dihasilkan tidak hanya merepresentasikan kondisi suatu wilayah secara individual, tetapi juga mencerminkan hubungan antar wilayah dalam jaringan distribusi farmasi.

Output dari layer GCN selanjutnya digunakan sebagai masukan pada layer Long Short-Term Memory (LSTM). LSTM dipilih karena memiliki kemampuan untuk mempelajari ketergantungan jangka panjang pada data deret waktu melalui mekanisme memori internal yang terdiri atas forget gate, input gate, dan output gate. Pada penelitian ini, LSTM digunakan untuk mengidentifikasi pola perubahan permintaan obat dari waktu ke waktu berdasarkan representasi spasial yang telah dihasilkan oleh GCN.

Untuk mengurangi risiko overfitting selama proses pelatihan, diterapkan lapisan dropout setelah layer GCN. Lapisan ini secara acak menonaktifkan sebagian neuron selama proses training sehingga model dapat melakukan generalisasi dengan lebih baik terhadap data yang belum pernah dilihat sebelumnya. Setelah melalui proses pembelajaran temporal pada layer LSTM, fitur yang dihasilkan diteruskan ke fully connected layer (dense layer) yang berfungsi untuk menghasilkan nilai prediksi permintaan obat pada periode berikutnya.

Secara keseluruhan, alur kerja model yang diusulkan dimulai dari data historis penjualan farmasi, kemudian dilakukan pembentukan graph regional, ekstraksi fitur spasial menggunakan GCN, pembelajaran pola temporal menggunakan LSTM, dan akhirnya menghasilkan prediksi permintaan obat melalui dense layer. Struktur arsitektur model secara konseptual ditunjukkan pada Gambar 2.



**Gambar 2.** Arsitektur GCN-LSTM

Pada penelitian ini digunakan satu layer GCN dengan 64 hidden units dan satu layer LSTM dengan 128 unit memori. Proses pelatihan dilakukan menggunakan optimizer Adam dengan learning rate sebesar 0,001 dan fungsi loss Mean Squared Error (MSE). Pemilihan parameter tersebut didasarkan pada kemampuannya dalam menghasilkan proses konvergensi yang stabil pada berbagai penelitian forecasting berbasis deep learning.

Melalui kombinasi antara pemodelan spasial dan temporal tersebut, model GCN-LSTM diharapkan mampu menangkap karakteristik kompleks permintaan obat yang dipengaruhi oleh hubungan antar wilayah distribusi serta pola historis penjualan, sehingga menghasilkan performa prediksi yang lebih baik dibandingkan model konvensional maupun model deep learning berbasis temporal saja.

### E. Evaluasi Model

Kinerja model Hybrid GCN-LSTM dievaluasi menggunakan tiga metrik, yaitu Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Ketiga metrik tersebut digunakan untuk mengukur tingkat kesalahan antara nilai aktual dan nilai prediksi. Semakin kecil nilai RMSE, MAE, dan MAPE, maka semakin baik performa model dalam memprediksi permintaan obat.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2)$$

### Hasil dan Diskusi

Model Hybrid GCN-LSTM yang diusulkan dievaluasi menggunakan dataset IQVIA Pharmaceutical Sales untuk menguji kemampuannya dalam memprediksi permintaan obat dengan memanfaatkan ketergantungan spasial dan temporal secara simultan. Sebelum proses pelatihan model dilakukan, analisis eksploratif terhadap dataset dilakukan untuk memahami karakteristik data yang digunakan. Dataset IQVIA terdiri atas data penjualan farmasi mingguan yang mencakup beberapa kelompok terapi obat utama, yaitu M01AB, M01AE, N02BA, N02BE, N05B, N05C, R03, dan R06. Data menunjukkan adanya fluktuasi permintaan yang cukup tinggi sepanjang periode observasi, yang mengindikasikan keberadaan pola nonlinier dan dinamika temporal yang kompleks. Variasi permintaan antar kategori obat juga terlihat cukup signifikan, menunjukkan bahwa setiap kelompok terapi memiliki karakteristik konsumsi yang berbeda sehingga diperlukan model prediksi yang mampu menangkap hubungan kompleks tersebut secara efektif.

**Tabel 2.** Statistik Deskriptif Dataset Permintaan Obat

| <i>Kategori Obat</i> | <i>Rata-rata</i> | <i>Standar Deviasi</i> | <i>Minimum</i> | <i>Maksimum</i> |
|----------------------|------------------|------------------------|----------------|-----------------|
| M01AB                | 18,86            | 5,72                   | 6,44           | 35,65           |
| M01AE                | 43,79            | 10,83                  | 20,05          | 79,11           |
| N02BA                | 30,29            | 8,14                   | 11,31          | 58,46           |
| N02BE                | 71,11            | 16,94                  | 31,82          | 122,45          |
| N05B                 | 12,10            | 3,97                   | 3,26           | 24,13           |
| N05C                 | 9,13             | 2,84                   | 2,11           | 17,74           |
| R03                  | 14,81            | 4,68                   | 4,35           | 29,86           |
| R06                  | 16,54            | 5,11                   | 5,04           | 31,42           |

Berdasarkan Tabel 2, kategori obat N02BE memiliki rata-rata permintaan tertinggi sebesar 71,11 unit per minggu, diikuti oleh M01AE sebesar 43,79 unit dan N02BA sebesar 30,29 unit. Sebaliknya, kategori N05C memiliki rata-rata permintaan terendah sebesar 9,13 unit. Perbedaan ini menunjukkan adanya variasi kebutuhan obat yang cukup besar antar kategori terapi. Selain itu, nilai standar deviasi yang relatif tinggi pada beberapa kategori menunjukkan bahwa permintaan obat bersifat dinamis dan mengalami perubahan dari waktu ke waktu. Kondisi ini menjadi tantangan tersendiri bagi model prediksi karena harus mampu mempelajari pola permintaan yang tidak stabil.

Untuk memanfaatkan informasi hubungan antar kategori obat, penelitian ini membangun struktur graph berdasarkan korelasi historis penjualan farmasi. Setiap kategori obat direpresentasikan sebagai node, sedangkan hubungan antar node dibentuk berdasarkan nilai korelasi antar deret waktu penjualan. Pendekatan ini memungkinkan model menangkap keterkaitan antar kategori obat yang tidak dapat direpresentasikan secara optimal oleh model time-series konvensional. Hasil analisis korelasi menunjukkan bahwa beberapa kategori obat memiliki hubungan yang kuat, khususnya antara kelompok analgesik dan antiinflamasi. Korelasi tertinggi ditemukan antara kategori M01AE dan N02BE serta antara M01AE dan N02BA, yang menunjukkan bahwa perubahan permintaan pada satu kategori cenderung diikuti oleh perubahan pada kategori lainnya. Hubungan tersebut kemungkinan dipengaruhi oleh kesamaan indikasi terapi, pola persepsian dokter, maupun karakteristik penyakit yang mendasarinya.

Setelah graph terbentuk, model GCN-LSTM dilatih menggunakan data historis yang telah dinormalisasi. Selama proses pelatihan, nilai loss pada data pelatihan maupun validasi menunjukkan tren penurunan yang stabil hingga mencapai kondisi konvergen. Hal ini mengindikasikan bahwa model mampu mempelajari pola spasial dan temporal secara efektif tanpa mengalami overfitting yang signifikan. Penggunaan Graph Convolutional Network memungkinkan proses ekstraksi fitur spasial dari adjacency matrix, sedangkan Long Short-Term Memory berperan dalam mempelajari ketergantungan temporal jangka pendek maupun jangka panjang yang terdapat pada data penjualan farmasi. Penambahan dropout layer setelah proses graph convolution juga membantu meningkatkan kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Untuk mengevaluasi kinerja model yang diusulkan, dilakukan perbandingan dengan beberapa metode baseline yang umum digunakan dalam forecasting, yaitu ARIMA, Random Forest, dan LSTM. Evaluasi dilakukan menggunakan tiga metrik utama, yaitu Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil perbandingan ditunjukkan pada Tabel 3.

**Tabel 3.** Perbandingan Kinerja Model Prediksi

| <i>Model</i>           | <i>MAE</i>   | <i>RMSE</i>  | <i>MAPE (%)</i> |
|------------------------|--------------|--------------|-----------------|
| ARIMA                  | 4,832        | 6,251        | 14,62           |
| Random Forest          | 3,974        | 5,214        | 12,01           |
| LSTM                   | 3,182        | 4,366        | 9,45            |
| <b>Hybrid GCN-LSTM</b> | <b>2,741</b> | <b>3,821</b> | <b>7,86</b>     |

Berdasarkan Tabel 3, model Hybrid GCN-LSTM menghasilkan nilai kesalahan prediksi terendah pada seluruh metrik evaluasi. Nilai RMSE sebesar 3,821 menunjukkan bahwa model mampu menghasilkan prediksi yang lebih dekat dengan nilai aktual dibandingkan metode lainnya. Dibandingkan dengan ARIMA, model yang diusulkan mampu menurunkan nilai RMSE sekitar 38,9%, sedangkan dibandingkan dengan LSTM tunggal terjadi penurunan sebesar 12,5%. Hasil ini menunjukkan bahwa integrasi pembelajaran spasial melalui GCN memberikan kontribusi signifikan terhadap peningkatan akurasi prediksi. Meskipun LSTM mampu menangkap pola temporal dengan baik, model tersebut belum mampu memanfaatkan hubungan antar kategori obat yang tersedia dalam struktur graph. Sebaliknya, GCN-LSTM dapat menggabungkan informasi spasial dan temporal sehingga menghasilkan representasi data yang lebih kaya dan informatif.

Kinerja model juga dianalisis melalui perbandingan antara nilai aktual dan hasil prediksi pada data pengujian. Hasil visualisasi menunjukkan bahwa kurva prediksi yang dihasilkan oleh GCN-LSTM mampu mengikuti pola permintaan aktual dengan tingkat kesesuaian yang tinggi. Sebagian besar tren kenaikan maupun penurunan permintaan berhasil direpresentasikan dengan baik oleh model. Perbedaan prediksi yang relatif kecil hanya terlihat pada beberapa titik yang mengalami lonjakan permintaan ekstrem, yang umumnya disebabkan oleh perubahan pasar yang tidak terduga atau peningkatan kebutuhan obat secara mendadak.

Secara keseluruhan, hasil penelitian menunjukkan bahwa pendekatan Hybrid GCN-LSTM mampu menangkap karakteristik kompleks pada data permintaan farmasi yang terdiri atas ketergantungan spasial dan temporal. Kemampuan Graph Convolutional Network dalam memodelkan hubungan antar kategori obat memberikan informasi tambahan yang tidak tersedia pada model forecasting konvensional. Sementara itu, Long Short-Term Memory mampu mempertahankan informasi historis penting sehingga pola permintaan jangka panjang dapat dipelajari dengan baik. Kombinasi kedua pendekatan tersebut menghasilkan peningkatan akurasi yang signifikan dibandingkan model statistik maupun model deep learning tunggal. Temuan ini menunjukkan bahwa pendekatan spatio-temporal berbasis graph memiliki potensi besar untuk diterapkan pada sistem manajemen rantai pasok farmasi, khususnya dalam mendukung perencanaan inventori, pengadaan obat, dan optimalisasi distribusi pada lingkungan farmasi yang kompleks.

Penelitian ini memiliki beberapa keterbatasan. Pertama, dataset yang digunakan berasal dari sumber publik sehingga belum sepenuhnya merepresentasikan kondisi distribusi farmasi dunia nyata. Kedua, graph yang digunakan bersifat statis dan dibangun berdasarkan korelasi historis sehingga belum mampu menangkap perubahan hubungan antar kategori obat secara dinamis. Ketiga, penelitian belum memasukkan faktor eksternal seperti musim penyakit, kebijakan kesehatan, maupun kondisi ekonomi yang berpotensi memengaruhi permintaan obat. Penelitian selanjutnya dapat mengintegrasikan dynamic graph learning dan attention mechanism untuk meningkatkan kemampuan adaptasi model terhadap perubahan pola permintaan.

## Kesimpulan

Penelitian ini mengusulkan model Hybrid Graph Convolutional Network–Long Short-Term Memory (GCN-LSTM) untuk memprediksi permintaan obat pada dataset IQVIA multi-regional dengan mempertimbangkan hubungan spasial antar wilayah dan pola temporal historis. Hasil eksperimen menunjukkan bahwa integrasi GCN dan LSTM mampu meningkatkan akurasi prediksi secara signifikan dibandingkan model statistik maupun model deep learning berbasis temporal saja. Model yang diusulkan berhasil menurunkan error prediksi pada seluruh metrik evaluasi (RMSE, MAE, dan MAPE), yang menunjukkan bahwa informasi spasial memberikan kontribusi penting dalam meningkatkan kualitas prediksi permintaan obat. Dengan memanfaatkan graph berbasis korelasi antar wilayah, model mampu menangkap keterkaitan distribusi farmasi yang tidak dapat direpresentasikan oleh model time-series konvensional. Sementara itu, LSTM efektif dalam mempelajari dinamika temporal jangka panjang dari data penjualan obat. Kombinasi kedua pendekatan ini menghasilkan model yang lebih robust dalam menghadapi pola permintaan yang nonlinier dan dinamis. Hasil penelitian ini memberikan implikasi penting bagi sistem manajemen rantai pasok farmasi, khususnya dalam perencanaan inventori, pengendalian stok, dan optimalisasi distribusi obat. Untuk penelitian selanjutnya, integrasi attention mechanism atau dynamic graph learning dapat dipertimbangkan untuk meningkatkan kemampuan adaptasi model terhadap perubahan pola permintaan yang lebih kompleks.

## Deklarasi Kepentingan

Penulis menyatakan bahwa tidak terdapat konflik kepentingan dalam penelitian ini, baik secara finansial maupun non-finansial, yang dapat mempengaruhi hasil atau interpretasi penelitian.

## Ketersediaan Data

Data yang digunakan dalam penelitian ini bersumber dari dataset publik IQVIA Pharmaceutical Sales yang tersedia melalui platform Kaggle pada tautan: <https://www.kaggle.com/datasets/mderya/iqvia-pharma-sales>. Data dapat diakses secara terbuka oleh peneliti lain untuk tujuan akademik dan replikasi penelitian.

## Penggunaan Ai Dan Deklarasi Penggunaan Ai Generatif

Dalam proses penulisan artikel ini, penulis menggunakan bantuan teknologi kecerdasan buatan (Artificial Intelligence) berbasis model bahasa untuk mendukung penyusunan teks, perbaikan struktur kalimat, serta peningkatan keterbacaan naskah. Seluruh isi ilmiah, desain metodologi, serta interpretasi hasil tetap menjadi tanggung jawab penuh penulis. AI tidak digunakan untuk menghasilkan data eksperimen maupun hasil analisis utama penelitian.

## Daftar Pustaka

- [1] A. Ala, A. Bahrini, B. Malmir, V. Hargaden, and V. Simic, "A cost-sensitive Dueling Double Deep Q-network framework for predicting medicines shortages in pharmaceutical supply chains," *Expert Syst. Appl.*, vol. 331, p. 133239, Dec. 2026, doi: 10.1016/J.ESWA.2026.133239.

- [2] A. I. Sierra Espinel and M. J. Suarez Barón, “Applying Deep Learning and Forecasting Techniques to the Pharmaceutical Supply Chain,” *Procedia Comput. Sci.*, vol. 253, pp. 2791–2800, Jan. 2025, doi: 10.1016/J.PROCS.2025.02.003.
- [3] X. Chen, G. Lu, H. Zhang, and J. Wan, “Pharmaceutical Demand Forecasting via GCN-LSTM: A Knowledge Graph-Based Approach,” Oct. 2025, doi: 10.20944/PREPRINTS202510.1546.V1.
- [4] X. Chen, G. Lu, H. Zhang, and J. Wan, “Knowledge graph-enhanced deep learning for pharmaceutical demand forecasting,” *Sci. Reports 2026 161*, vol. 16, no. 1, pp. 4776–, Jan. 2026, doi: 10.1038/s41598-026-35113-4.
- [5] G. Merkuryeva, A. Valberga, and A. Smirnov, “Demand forecasting in pharmaceutical supply chains: A case study,” *Procedia Comput. Sci.*, vol. 149, pp. 3–10, Jan. 2019, doi: 10.1016/J.PROCS.2019.01.100.
- [6] W. Ramadhan, E. Noersongko, A. Syukur, and M. A. Soeleman, “Machine Learning Approaches for Pharmaceutical Demand Forecasting: A Bibliometric and Systematic Review of Methods and Research Trends,” *Ingénierie des Systèmes d’Information*, vol. 31, no. 1, p. 179, Jan. 2026, doi: 10.18280/ISI.310117.
- [7] T. Niu, H. Zhang, X. Yan, and Q. Miao, “Intricate Supply Chain Demand Forecasting Based on Graph Convolution Network,” *Sustain. 2024, Vol. 16, Page 9608*, vol. 16, no. 21, p. 9608, Nov. 2024, doi: 10.3390/SU16219608.
- [8] B. Yu, H. Yin, and Z. Zhu, “Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting,” *IJCAI Int. Jt. Conf. Artif. Intell.*, vol. 2018-July, pp. 3634–3640, Jul. 2018, doi: 10.24963/ijcai.2018/505.
- [9] J. Ke, X. Qin, H. Yang, Z. Zheng, Z. Zhu, and J. Ye, “Predicting origin-destination ride-sourcing demand with a spatio-temporal encoder-decoder residual multi-graph convolutional network,” *Transp. Res. Part C Emerg. Technol.*, vol. 122, p. 102858, Jan. 2021, doi: 10.1016/J.TRC.2020.102858.
- [10] L. Bai, L. Yao, S. S. Kanhere, X. Wang, and Q. Z. Sheng, “STG2Seq: Spatial-temporal Graph to Sequence Model for Multi-step Passenger Demand Forecasting,” *IJCAI Int. Jt. Conf. Artif. Intell.*, vol. 2019-August, pp. 1981–1987, May 2019, doi: 10.24963/ijcai.2019/274.
- [11] “iqvia-pharma-sales.” <https://www.kaggle.com/datasets/mderya/iqvia-pharma-sales> (accessed Jun. 19, 2026).