



Digital Twin Rantai Pasok UMKM Berbasis GNN untuk Prediksi Permintaan dan Optimasi Persediaan

Andi Nurul Aksa¹, Ismail²

Program Studi Sistem Informasi, Universitas Lamappapoleonro^{1,2}
Jl. Salotungo No. 62 Watansoppeng, Soppeng, Sulawesi Selatan-Indonesia^{1,2}
andiaksa@unipol.ac.id*¹, ismail@unipol.ac.id²

Kata Kunci :

Digital Twin;
Graph Neural
Network; Rantai
Pasok UMKM;
Prediksi
Permintaan;
Optimasi
Persediaan.

ABSTRAK

Ketidakpastian permintaan dan keterbatasan visibilitas antaraktor menyebabkan UMKM sering mengalami kelebihan atau kekurangan persediaan. Penelitian ini mengembangkan Digital Twin rantai pasok UMKM berbasis Graph Neural Network (GNN) yang mengintegrasikan representasi graf heterogen, prediksi spasial-temporal, dan simulasi generatif untuk mendukung keputusan persediaan secara closed-loop. Eksperimen terkontrol menggunakan data simulasi 150 minggu pada graf berarah yang terdiri atas 36 simpul dan 78 relasi pemasok-gudang-UMKM-produk. Model residual GCN-GRU dibandingkan dengan naive forecast, Random Forest, dan LSTM menggunakan MAE, RMSE, MAPE, serta R^2 . Prediksi selanjutnya dihubungkan dengan kebijakan order-up-to yang mengoptimalkan safety factor per simpul melalui simulasi Monte Carlo. Hasil menunjukkan bahwa GCN-GRU memperoleh MAE 4,995, RMSE 6,749, MAPE 9,887%, dan R^2 0,818, lebih baik daripada LSTM dengan MAE 5,318 dan R^2 0,802. Integrasi Digital Twin menurunkan biaya persediaan menjadi 26.814,62 unit biaya, atau 9,64% lebih rendah daripada kebijakan berbasis LSTM, sekaligus menurunkan rata-rata persediaan 10,85% dengan service level 99,96%. Uji sensitivitas hingga 20% gangguan pasokan mempertahankan keunggulan biaya Digital Twin. Kebaruan penelitian terletak pada penyatuan pembelajaran graf spasial-temporal dan simulasi generatif untuk mengoptimalkan kebijakan persediaan node-specific dalam satu siklus Digital Twin yang dapat diperbarui secara dinamis.

Keywords

Digital Twin;
Graph Neural
Network;
MSME Supply
Chain; Demand
Forecasting;
Inventory
Optimization.

ABSTRACT

Demand uncertainty and limited visibility across actors often expose micro, small, and medium enterprises (MSMEs) to excess inventory or stockouts. This study develops a Graph Neural Network (GNN)-based supply chain Digital Twin that integrates heterogeneous graph representation, spatiotemporal forecasting, and generative simulation for closed-loop inventory decisions. A controlled experiment used 150 weeks of simulated data on a directed graph comprising 36 nodes and 78 supplier-warehouse-MSME-product relations. The residual GCN-GRU model was compared with naive forecasting, Random Forest, and LSTM using MAE, RMSE, MAPE, and R^2 . Forecasts were then connected to an order-up-to policy that optimized node-specific safety factors through Monte Carlo simulation. The GCN-GRU achieved an MAE of 4.995, RMSE of 6.749, MAPE of 9.887%, and R^2 of 0.818, outperforming the LSTM with an MAE of 5.318 and R^2 of 0.802. The Digital Twin reduced inventory cost to 26,814.62 cost units, 9.64% lower than the LSTM-based policy, while reducing average inventory by 10.85% and maintaining a 99.96% service level. Sensitivity tests with supply disruptions up to 20% preserved the cost advantage. The novelty lies in combining spatiotemporal graph learning and generative simulation to



optimize node-specific inventory policies within a dynamically updated Digital Twin cycle.

---Jurnal JISTI @2026---

PENDAHULUAN

Transformasi digital mengubah pengelolaan rantai pasok dari proses yang bersifat reaktif menjadi sistem berbasis data yang mampu memantau, memprediksi, dan menguji skenario keputusan. Perubahan ini sangat relevan bagi usaha mikro, kecil, dan menengah (UMKM) karena aktivitas pembelian, penyimpanan, produksi, dan penjualan umumnya berlangsung dengan kapasitas modal serta ruang penyimpanan yang terbatas. Ketika permintaan berubah cepat, keputusan persediaan yang hanya mengandalkan pengalaman dapat menghasilkan overstock, stockout, pemborosan biaya, dan penurunan kualitas layanan pelanggan.

Digital Twin merupakan representasi virtual yang diperbarui menggunakan data dari objek atau proses fisik sehingga kondisi, perilaku, dan skenario masa depan dapat dianalisis secara sinkron. Dalam konteks rantai pasok, Digital Twin menyediakan ruang eksperimen untuk menghubungkan data operasional dengan simulasi tanpa mengganggu sistem aktual. Kajian mutakhir menempatkan Digital Twin sebagai teknologi penting untuk visibilitas, ketahanan, prediksi, dan optimasi rantai pasok, tetapi implementasinya masih menghadapi tantangan integrasi data, sinkronisasi model, dan pengukuran manfaat operasional (Tao et al., 2024; Zaidi et al., 2024).

Sebagian besar model prediksi permintaan masih memperlakukan setiap produk atau unit usaha sebagai deret waktu yang berdiri sendiri. Asumsi tersebut kurang sesuai dengan struktur rantai pasok karena permintaan sebuah produk dapat dipengaruhi oleh promosi, harga, gangguan pemasok, substitusi antarpoduk, serta pola transaksi pada UMKM lain yang terhubung. Graph Neural Network (GNN) menawarkan mekanisme pembelajaran yang memanfaatkan fitur simpul sekaligus relasi antarsimpul, sehingga dependensi struktural dapat dipelajari bersama dengan pola temporal (Niu et al., 2024; Li et al., 2024).

Perkembangan penelitian GNN pada rantai pasok menunjukkan pergeseran dari representasi tabular menuju pembelajaran graf yang lebih eksplisit. GNN telah digunakan untuk prediksi permintaan, estimasi fungsi produksi, analisis jaringan pemasok, dan dukungan keputusan rantai pasok (Chang et al., 2025; Sifuentes-Domínguez et al., 2026). Meskipun demikian, banyak penelitian berhenti pada evaluasi akurasi prediksi, sementara dampaknya terhadap kebijakan replenishment, biaya persediaan, dan service level belum diuji dalam mekanisme operasional yang terintegrasi.

Pada sisi lain, penelitian Digital Twin rantai pasok sering menekankan simulasi, optimasi, dan analisis gangguan, namun model prediktif yang digunakan belum selalu mampu merepresentasikan hubungan spasial atau relasional yang kompleks. Integrasi simulasi dengan machine learning telah berkembang sebagai pendekatan Sim-ML, tetapi literatur menunjukkan bahwa penyatuan antara model pembelajaran, simulasi operasional, dan pembaruan keputusan masih menjadi ruang penelitian yang terbuka (Badakhshan et al., 2024; Corsini et al., 2024). Kondisi ini menimbulkan kesenjangan antara model prediksi yang akurat dan Digital Twin yang benar-benar dapat menjalankan siklus sense-predict-simulate-optimize.

Bagi UMKM, kesenjangan tersebut semakin penting karena keputusan persediaan harus mempertimbangkan keterbatasan kas, kapasitas penyimpanan, lead time, dan risiko gangguan pasokan. Sistem yang hanya meningkatkan akurasi prediksi belum tentu menurunkan biaya jika ketidakpastian prediksi tidak diterjemahkan ke dalam safety stock dan reorder policy yang sesuai. Oleh karena itu, model perlu dievaluasi tidak hanya menggunakan MAE atau RMSE, tetapi juga melalui indikator operasional seperti total biaya, rata-rata persediaan, tingkat stockout, dan service level.



Penelitian ini mengembangkan Digital Twin rantai pasok UMKM berbasis residual Graph Convolutional Network-Gated Recurrent Unit (GCN-GRU). Graf heterogen merepresentasikan pemasok, gudang produk, dan pasangan UMKM-produk, sedangkan GCN menangkap dependensi antaraktor dan GRU mempelajari dinamika permintaan. Prediksi model kemudian menjadi input simulasi generatif Monte Carlo untuk mengoptimalkan safety factor tiap simpul dan menjalankan kebijakan order-up-to secara dinamis.

Kebaruan penelitian terletak pada tiga aspek. Pertama, penggunaan graf heterogen untuk memodelkan interaksi pemasok-gudang-UMKM-produk, bukan hanya korelasi antarseri permintaan. Kedua, pengembangan residual GCN-GRU yang memprediksi perubahan permintaan dari nilai terakhir sehingga lebih stabil pada data UMKM yang fluktuatif. Ketiga, penyatuan prediksi GNN dan simulasi generatif dalam closed-loop Digital Twin untuk menghasilkan kebijakan persediaan node-specific, bukan satu safety factor yang sama untuk seluruh unit.

Penelitian bertujuan: (1) membangun representasi Digital Twin untuk rantai pasok UMKM berbasis graf; (2) menguji performa GCN-GRU terhadap naive forecast, Random Forest, dan LSTM; (3) mengukur dampak prediksi terhadap biaya dan kinerja persediaan; serta (4) menguji ketahanan kebijakan pada beberapa tingkat gangguan pasokan. Kontribusi yang diharapkan adalah kerangka analitis yang menjembatani machine learning, sistem informasi bisnis digital, dan optimasi operasional UMKM.

METODE PENELITIAN

1. Desain Penelitian

Penelitian menggunakan pendekatan kuantitatif eksperimental berbasis simulasi terkontrol. Rancangan ini dipilih untuk menguji hubungan kausal antara kualitas prediksi, parameter kebijakan persediaan, dan kinerja operasional pada kondisi yang dapat direplikasi. Data simulasi tidak diklaim sebagai data transaksi lapangan; data tersebut membentuk prototipe Digital Twin yang selanjutnya dapat dikalibrasi menggunakan data riil UMKM. Tahapan penelitian mencakup konstruksi graf, pembangkitan data operasional, pra-pemrosesan, pembelajaran GNN, simulasi kebijakan persediaan, optimasi parameter, serta evaluasi sensitivitas:

Tahapan Penelitian



Gambar 1. Alur Desain Penelitian


2. Arsitektur Digital Twin Rantai Pasok UMKM

Arsitektur Digital Twin dibangun dalam lima lapisan, yaitu sumber data, model graf, mesin prediksi, simulasi-generatif, dan layanan keputusan. Lapisan sumber data menerima transaksi permintaan, posisi stok, harga, promosi, lead time, dan kejadian gangguan. Lapisan graf menyimpan entitas dan relasi sebagai digital thread. Mesin prediksi menghasilkan estimasi permintaan satu langkah ke depan, kemudian simulator membangkitkan skenario ketidakpastian untuk menguji kombinasi safety



factor. Hasil optimasi dikirim ke dashboard keputusan berupa reorder point, order-up-to level, proyeksi biaya, dan risiko stockout:

Arsitektur Digital Twin Rantai Pasok UMKM Berbasis GNN



Gambar 2. Arsitektur Digital Twin Berbasis GNN

3. Dataset dan Variabel Penelitian

Penelitian menggunakan horizon 150 minggu. Proses pembangkitan data memasukkan tren, musiman, promosi acak, perubahan indeks harga, lead time, korelasi antarsimpul, dan gangguan pasokan. Permintaan dasar setiap pasangan UMKM-produk dibentuk berbeda agar model menghadapi heterogenitas skala. Dependensi jaringan dibangun dengan meneruskan sebagian sinyal pemasok dan gudang menuju simpul hilir, sedangkan noise acak merepresentasikan variasi yang tidak terobservasi:

Tabel 2. Variabel Dataset Simulasi

Variabel	Bentuk	Peran dalam Model
Permintaan	Unit/minggu	Target prediksi dan konsumsi persediaan
Stok	Unit	Status fisik pada Digital Twin
Indeks harga	Rasio	Efek elastisitas permintaan
Promosi	Biner	Lonjakan permintaan temporer
Lead time	Minggu	Waktu tunggu replenishment
Gangguan	Biner	Keterlambatan atau penurunan pasokan

Sumber: Hasil pengolahan data penelitian

4. Konstruksi Graf Heterogen


Rantai pasok direpresentasikan sebagai graf berarah $G=(V,E)$, dengan V sebagai himpunan simpul dan E sebagai himpunan relasi. Graf terdiri atas enam simpul pemasok, enam simpul gudang-produk, dan 24 simpul pasangan UMKM-produk. Relasi supplier-to-warehouse merepresentasikan aliran pengadaan, warehouse-to-retailer merepresentasikan distribusi produk, sedangkan relasi antar-UMKM berdekatan digunakan untuk menangkap keterkaitan pasar. Self-loop ditambahkan pada proses konvolusi agar karakteristik internal simpul tetap dipertahankan:



Tabel 3. Skema Simpul dan Relasi Graf

Jenis Simpul	Jumlah	Fitur Utama	Relasi
Pemasok	6	Kapasitas dan sinyal gangguan	Pemasok → Gudang
Gudang-produk	6	Ketersediaan produk agregat	Gudang → UMKM-produk
UMKM-produk	24	Permintaan, stok, harga, promosi	Antar-UMKM dan self-loop
Total	36	Enam fitur per periode	78 relasi berarah

Sumber: Hasil pengolahan data penelitian



Gambar 3. Struktur Graf Rantai Pasok UMKM

Sumber: Hasil eksperimen simulasi menggunakan Python

Seluruh fitur diperiksa terhadap nilai hilang dan distandardisasi secara node-wise menggunakan parameter data latih untuk menghindari data leakage. Sampel temporal dibentuk dengan sliding window delapan minggu untuk memprediksi permintaan minggu berikutnya. Sebanyak 142 window dibagi secara kronologis menjadi 99 data latih, 21 data validasi, dan 22 data uji. Pembagian kronologis dipilih agar evaluasi merepresentasikan penggunaan model pada periode masa depan

5. Model Residual GCN-GRU

GCN digunakan untuk mengagregasi informasi dari tetangga pada setiap periode, sedangkan GRU mengendalikan aliran informasi temporal melalui mekanisme gerbang (Kipf & Welling, 2017; Cho et al., 2014). Dengan $A \sim$ sebagai matriks adjacency yang telah ditambah self-loop dan $D \sim$ sebagai matriks derajat, transformasi graf dirumuskan sebagai berikut:

$$H_t^{(l+1)} = \sigma(D \sim^{(-1/2)} A \sim D \sim^{(-1/2)} H_t^{(l)} W^{(l)})$$

Representasi hasil konvolusi pada delapan periode dimasukkan ke GRU untuk mempelajari dependensi temporal. Model menggunakan residual target, yaitu selisih antara permintaan aktual periode berikutnya dan permintaan periode terakhir pada window. Strategi residual mengurangi beban model untuk mempelajari level absolut yang berbeda antar-UMKM dan memusatkan pembelajaran pada perubahan permintaan.

$$\hat{y}_-(i, t+1) = y_-(i, t) + f_{GCN-GRU}(X_-(t-7:t), A)_i$$



Fungsi kerugian menggunakan mean squared error pada data terstandardisasi. Optimasi parameter dilakukan dengan Adam, early stopping berdasarkan validation loss, dan gradient clipping untuk menjaga stabilitas pelatihan (Kingma & Ba, 2015).

Empat pendekatan dibandingkan: naive forecast sebagai baseline persistence; Random Forest dengan fitur lag dan statistik window; LSTM lokal yang mempelajari pola temporal tanpa graf; serta residual GCN-GRU sebagai model utama. Konfigurasi dipertahankan konsisten pada pembagian data dan target yang sama.

Tabel 4. Konfigurasi Eksperimen

Parameter	Nilai
Sequence length	8 minggu
Pembagian data	99 train; 21 validation; 22 test
GCN hidden dimension	32
GRU hidden dimension	48
Optimizer	Adam; learning rate 0,003
Batching	Full graph temporal window
Early stopping	Patience 20 epoch
Baseline	Naive, Random Forest, LSTM

Sumber: Hasil pengolahan data penelitian

Prediksi permintaan dihubungkan dengan kebijakan periodic review order-up-to. Pada awal setiap minggu, Digital Twin menghitung target persediaan berdasarkan prediksi selama protection period, simpangan residual, lead time, dan safety factor z_i . Order ditempatkan jika inventory position berada di bawah target. Rumus reorder point dan order-up-to level dinyatakan sebagai berikut:

$$ROP_{(i,t)} = L_i \hat{y}_{(i,t)} + z_i \sigma_i \sqrt{L_i}$$

$$S_{(i,t)} = (L_i + 1) \hat{y}_{(i,t)} + z_i \sigma_i \sqrt{(L_i + 1)}$$

Untuk setiap simpul, simulator membangkitkan skenario permintaan dari distribusi residual empiris. Kandidat safety factor pada rentang 0,50-2,00 diuji menggunakan Monte Carlo, kemudian dipilih nilai yang meminimalkan total biaya dengan kendala service level minimal 98%. Komponen biaya terdiri atas holding cost 0,80 unit, shortage cost 3,50 unit, dan ordering cost 0,12 unit per unit pesanan. Kebijakan baseline menggunakan safety factor tetap 1,65.

$$TC = \sum_t \sum_i (0,80 I_{(i,t)} + 3,50 B_{(i,t)} + 0,12 Q_{(i,t)})$$

Performa prediksi dievaluasi menggunakan Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), dan coefficient of determination (R^2). Dampak operasional dievaluasi menggunakan total biaya, rata-rata persediaan, stockout rate, dan service level. Uji sensitivitas menambahkan gangguan pasokan sebesar 0%, 5%, 10%, 15%, dan 20% pada periode uji untuk menilai ketahanan kebijakan.

HASIL DAN PEMBAHASAN

1. Karakteristik Dataset dan Digital Twin

Dataset membentuk 36 simpul dengan 78 relasi berarah selama 150 minggu. Permintaan memiliki nilai minimum 15.32, maksimum 112.74, rata-rata 49.52, dan standar deviasi 16.76 unit per minggu. Tingkat promosi sebesar 11.83% dan kejadian gangguan pasokan sebesar 6.89%. Variasi tersebut menunjukkan bahwa data mencakup kondisi normal, lonjakan penjualan, serta perubahan pasokan yang diperlukan untuk menguji kemampuan adaptasi model.



Tabel 5. Karakteristik Dataset Digital Twin

Indikator	Nilai
Periode observasi	150 minggu
Simpul graf	36
Relasi berarah	78
Window supervised	142
Rata-rata permintaan	49.522 unit/minggu
Standar deviasi permintaan	16.762
Rata-rata stok teramati	70.356 unit
Rata-rata lead time	1.048 minggu
Tingkat promosi	11.833%
Tingkat gangguan	6.889%

Sumber: Hasil pengolahan data penelitian


2. Kinerja Prediksi Permintaan

Hasil pengujian menunjukkan peningkatan performa secara konsisten dari baseline sederhana menuju model yang memanfaatkan struktur graf. Naive forecast memiliki error tertinggi karena hanya mengulang nilai terakhir. Random Forest memperbaiki hasil melalui fitur lag dan statistik, sedangkan LSTM menangkap dinamika temporal. GCN-GRU memperoleh hasil terbaik karena memanfaatkan informasi temporal dan relasional secara bersamaan.

Tabel 6. Perbandingan Kinerja Model Prediksi

Model	MAE	RMSE	MAPE	R ²
Naive	6.571	8.578	13.322%	0.706
Random Forest	5.607	7.192	11.729%	0.793
LSTM	5.318	7.049	10.601%	0.801
GCN-GRU	4.995	6.748	9.887%	0.818

Sumber: Hasil pengolahan data penelitian




Gambar 4. Perbandingan Permintaan Aktual dan Hasil Prediksi

Sumber: Hasil eksperimen simulasi menggunakan Python



Perbandingan Kinerja Model Prediksi



Gambar 5. Perbandingan Metrik Kesalahan Prediksi

Sumber: Hasil eksperimen simulasi menggunakan Python

Tabel 7. Peningkatan Relatif Model GCN-GRU

Perbandingan	Penurunan MAE	Penurunan RMSE	Penurunan MAPE	ΔR^2
GCN-GRU vs Random Forest	10.93%	6.16%	15.71%	0.025
GCN-GRU vs LSTM	6.08%	4.26%	6.73%	0.017

Sumber: Hasil pengolahan data penelitian

GCN-GRU menurunkan MAE sebesar 6.08% dan RMSE sebesar 4.26% dibandingkan LSTM. Peningkatan ini menegaskan bahwa informasi tetangga pada graf memberikan sinyal tambahan yang tidak tersedia pada model temporal lokal. Nilai R^2 sebesar 0.818 menunjukkan bahwa model menjelaskan 81,80% variasi permintaan pada data uji. Walaupun selisih error terhadap LSTM tidak ekstrem, dampak operasionalnya perlu dinilai melalui simulasi persediaan karena pengurangan error pada periode lonjakan dapat menghindari stok yang berlebihan maupun kekurangan.


3. Hasil Optimasi Persediaan

Prediksi setiap model digunakan pada kebijakan persediaan yang sama agar perbedaan kinerja berasal dari kualitas prediksi dan optimasi safety factor. Digital Twin GNN mengoptimalkan safety factor per simpul dengan rata-rata 0,927, sedangkan tiga kebijakan pembandingan menggunakan nilai tetap 1,65. Hasil memperlihatkan bahwa safety stock yang lebih adaptif mampu menekan holding cost tanpa meningkatkan shortage secara signifikan.

Tabel 8. Kinerja Kebijakan Persediaan

Kebijakan	Total Biaya	Rata-rata Stok	Service Level	Stockout	Safety Factor
Moving Average	30,801.59	65.265	100.000%	0.000%	1.650
Random Forest	31,340.06	66.530	100.000%	0.000%	1.650
LSTM	29,676.36	62.591	100.000%	0.000%	1.650
Digital Twin GNN	26,814.62	55.803	99.961%	0.189%	0.927

Sumber: Hasil pengolahan data penelitian



Gambar 6. Perbandingan Biaya dan Kinerja Persediaan
Sumber: Hasil eksperimen simulasi menggunakan Python

Dibandingkan kebijakan berbasis LSTM, Digital Twin GNN menurunkan total biaya sebesar 9.64% dan rata-rata persediaan sebesar 10.85%. Dibandingkan moving average, penurunan biaya mencapai 12.94% dan penurunan rata-rata persediaan 14.50%. Service level tetap berada pada 99,961% dengan stockout rate 0,189%. Temuan ini menunjukkan bahwa akurasi prediksi yang lebih baik memberi manfaat terbesar ketika dikombinasikan dengan optimasi parameter kebijakan, bukan hanya digunakan sebagai angka ramalan.


4. Uji Sensitivitas Gangguan Pasokan

Uji sensitivitas dilakukan untuk menilai apakah keunggulan Digital Twin tetap bertahan ketika tambahan gangguan dimasukkan pada periode pengujian. Hasil menunjukkan bahwa kebijakan Digital Twin GNN mempertahankan total biaya lebih rendah pada semua tingkat gangguan. Service level mengalami variasi kecil, namun tetap di atas 99,82% sampai gangguan 15% dan 99,90% pada gangguan 20%.

Tabel 9. Sensitivitas terhadap Gangguan Pasokan

Gangguan	Biaya LSTM	Biaya DT-GNN	Service LSTM	Service DT-GNN
0%	29,676.36	26,814.62	100.000%	99.961%
5%	29,454.41	26,604.38	100.000%	99.951%
10%	29,018.71	26,156.96	100.000%	99.963%
15%	28,872.65	26,101.14	99.938%	99.823%
20%	28,492.82	25,696.88	99.995%	99.903%

Sumber: Hasil pengolahan data penelitian



Gambar 7. Sensitivitas Biaya dan Service Level terhadap Gangguan
Sumber: Hasil eksperimen simulasi menggunakan Python.



5. Pembahasan

Hasil prediksi mendukung argumen bahwa permintaan dalam rantai pasok tidak sepenuhnya bersifat lokal. Ketika simpul UMKM menerima sinyal dari gudang, pemasok, dan unit lain yang berkaitan, GCN dapat menyaring informasi yang relevan sebelum pola temporal diproses oleh GRU. Temuan ini konsisten dengan penelitian yang menunjukkan bahwa struktur graf meningkatkan prediksi permintaan pada jaringan produk dan rantai pasok yang kompleks (Niu et al., 2024; Li et al., 2024).

Kontribusi utama tidak hanya terdapat pada peningkatan R^2 dari 0,802 pada LSTM menjadi 0,818 pada GCN-GRU, tetapi pada translasi hasil prediksi menjadi kebijakan operasional. Literatur machine learning untuk demand forecasting sering berfokus pada error statistik, sementara pengelola persediaan membutuhkan ukuran finansial dan layanan (Douaioui et al., 2024). Dalam penelitian ini, error yang lebih rendah menghasilkan pengurangan safety stock dan holding cost melalui simulator Digital Twin.

Simulasi generatif berfungsi sebagai lapisan penghubung antara ketidakpastian model dan keputusan replenishment. Alih-alih menetapkan satu safety factor berdasarkan asumsi distribusi yang sama, residual setiap simpul digunakan untuk membangkitkan skenario node-specific. Pendekatan ini sejalan dengan arah penelitian Digital Twin yang menggabungkan simulasi, machine learning, dan optimasi untuk ketahanan produksi-distribusi (Corsini et al., 2024; Cimino et al., 2024).

Dari perspektif sistem informasi bisnis digital, Digital Twin bertindak sebagai digital thread yang mengintegrasikan data transaksi, status persediaan, relasi pemasok, model prediksi, dan rekomendasi keputusan. Kerangka ini dapat dikembangkan menjadi dashboard bagi pemilik UMKM, agregator, koperasi, atau pengelola marketplace. Informasi yang disajikan tidak terbatas pada jumlah pesanan, tetapi mencakup alasan risiko, proyeksi biaya, serta skenario dampak gangguan. Dari sisi novelty, penelitian ini berbeda dari Digital Twin yang hanya menyalin status fisik dan dari model GNN yang berhenti pada prediksi. Siklus closed-loop mengubah data menjadi representasi graf, menghasilkan prediksi, menguji banyak skenario, memilih kebijakan, lalu memperbarui state persediaan. Struktur tersebut memperkuat posisi Digital Twin sebagai sistem keputusan dinamis, bukan visualisasi statis.

Uji sensitivitas menunjukkan bahwa keunggulan biaya tetap stabil sampai tambahan gangguan 20%. Namun, penurunan biaya pada tingkat gangguan yang lebih tinggi sebagian dipengaruhi oleh menurunnya aliran barang dan tidak boleh ditafsirkan sebagai kondisi operasional yang lebih baik. Oleh karena itu, evaluasi perlu membaca biaya bersama service level dan volume permintaan terpenuhi. Digital Twin GNN tetap menjaga service level tinggi, sehingga efisiensi biaya tidak diperoleh melalui pengorbanan layanan yang besar.

SIMPULAN

Penelitian menghasilkan prototipe Digital Twin rantai pasok UMKM yang mengintegrasikan graf heterogen, residual GCN-GRU, dan simulasi generatif dalam satu siklus keputusan. Representasi 36 simpul dan 78 relasi memungkinkan model membaca dependensi pemasok-gudang-UMKM-produk bersama dinamika temporal permintaan.

GCN-GRU menjadi model prediksi terbaik dengan MAE 4,995, RMSE 6,749, MAPE 9,887%, dan R^2 0,818. Dibandingkan LSTM, model menurunkan MAE 6,08% dan RMSE 4,26%. Hasil tersebut menunjukkan bahwa informasi relasional memberikan nilai tambah terhadap model yang hanya menggunakan pola temporal lokal.

Integrasi prediksi dengan optimasi safety factor node-specific menurunkan total biaya persediaan 9,64% dan rata-rata persediaan 10,85% dibandingkan kebijakan LSTM, dengan service level 99,96%. Keunggulan biaya tetap terlihat pada skenario gangguan pasokan sampai 20%, sehingga kerangka memiliki potensi sebagai sistem pendukung keputusan persediaan UMKM yang adaptif.



Kebaruan penelitian terletak pada closed-loop Digital Twin yang menghubungkan pembelajaran graf spasial-temporal dengan simulasi generatif dan optimasi persediaan. Namun, hasil merupakan bukti konsep berbasis simulasi; generalisasi praktis memerlukan kalibrasi dan validasi menggunakan data transaksi, persediaan, lead time, serta biaya riil UMKM.

SARAN

Penelitian lanjutan disarankan menggunakan data longitudinal dari beberapa UMKM dan pemasok untuk menguji generalisasi antarsektor. Model dapat dikembangkan dengan temporal graph attention, dynamic graph learning, dan explainable GNN agar perubahan hubungan serta alasan rekomendasi dapat dipahami pengguna. Optimasi berikutnya juga perlu memasukkan keterbatasan modal, kapasitas gudang, produk kedaluwarsa, minimum order quantity, emisi logistik, dan sasaran multiobjektif. Pada sisi implementasi, Digital Twin perlu diintegrasikan dengan sistem point-of-sale, marketplace, dan dashboard notifikasi agar pembaruan state serta rekomendasi replenishment dapat dilakukan secara real time.

DAFTAR PUSTAKA

- Badakhshan, E., Mustafee, N., & Bahadori, R. (2024). Application of simulation and machine learning in supply chain management: A synthesis of the literature using the Sim-ML literature classification framework. *Computers & Industrial Engineering*, 198, 110649. <https://doi.org/10.1016/j.cie.2024.110649>
- Chang, S., Lin, Z., Yan, B., Bembde, S., Xiu, Q., Wong, C. H., & Leskovec, J. (2025). Learning production functions for supply chains with graph neural networks. *Proceedings of the AAAI Conference on Artificial Intelligence*, 39(27), 27878–27886. <https://doi.org/10.1609/aaai.v39i27.35004>
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. *Proceedings of EMNLP*, 1724–1734. <https://doi.org/10.3115/v1/D14-1179>
- Cimino, A., Longo, F., Mirabelli, G., Solina, V., & Veltri, P. (2024). Enhancing internal supply chain management in manufacturing through a simulation-based digital twin platform. *Computers & Industrial Engineering*, 198, 110670. <https://doi.org/10.1016/j.cie.2024.110670>
- Corsini, R. R., Costa, A., Fichera, S., & Framinan, J. M. (2024). Digital twin model with machine learning and optimization for resilient production–distribution systems under disruptions. *Computers & Industrial Engineering*, 191, 110145. <https://doi.org/10.1016/j.cie.2024.110145>
- Douaioui, K., Oucheikh, R., Benmoussa, O., & Mabrouki, C. (2024). Machine learning and deep learning models for demand forecasting in supply chain management: A critical review. *Applied System Innovation*, 7(5), 93. <https://doi.org/10.3390/asi7050093>
- Kipf, T. N., & Welling, M. (2017). Semi-supervised classification with graph convolutional networks. *International Conference on Learning Representations*.
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *International Conference on Learning Representations*.
- Li, J., Fan, L., Wang, X., Sun, T., & Zhou, M. (2024). Product demand prediction with spatial graph neural networks. *Applied Sciences*, 14(16), 6989. <https://doi.org/10.3390/app14166989>
- Niu, T., Zhang, H., Yan, X., & Miao, Q. (2024). Intricate supply chain demand forecasting based on graph convolution network. *Sustainability*, 16(21), 9608. <https://doi.org/10.3390/su16219608>
- Sifuentes-Domínguez, S., Mejia-Muñoz, J.-M., Cruz-Mejia, O., Pizarro-Gurrola, R., Domínguez-Flores, A.-S., & Ortega-Máynez, L. (2026). Predicting demand in supply chain management: A decision support system using graph convolutional networks. *Future Internet*, 18(1), 26. <https://doi.org/10.3390/fi18010026>



-
- Tao, F., Zhang, H., & Zhang, C. (2024). Advancements and challenges of digital twins in industry. *Nature Computational Science*, 4, 169–177. <https://doi.org/10.1038/s43588-024-00603-w>
- Zaidi, S. A. H., Khan, S. A., & Chaabane, A. (2024). Unlocking the potential of digital twins in supply chains: A systematic review. *Supply Chain Analytics*, 7, 100075. <https://doi.org/10.1016/j.sca.2024.100075>