

BAB I

PENDAHULUAN

1.1 Latar Belakang

Prediksi kebutuhan stok tunai pada mesin ATM merupakan aspek krusial dalam manajemen kas perbankan. Ketersediaan tunai yang optimal dapat meningkatkan kepuasan pelanggan sekaligus mengurangi biaya operasional akibat pengisian ulang yang berlebihan atau kekurangan stok yang berpotensi menyebabkan ketidaknyamanan bagi nasabah [1]. Oleh karena itu, diperlukan metode prediksi yang akurat dan efisien untuk memperkirakan kapan stok tunai ATM akan habis.

Berbagai pendekatan telah dilakukan dalam penelitian sebelumnya untuk melakukan prediksi stok tunai ATM. Metode statistik seperti ARIMA sering digunakan untuk memodelkan data deret waktu dengan pola musiman [2]. Namun, metode ini memiliki keterbatasan dalam menangani hubungan spasial antar ATM dan sulit beradaptasi dengan pola transaksi yang tidak stasioner. Selain itu, metode machine learning tradisional seperti Random Forest, XGBoost, dan SVM telah diterapkan untuk meningkatkan akurasi prediksi dengan memanfaatkan fitur relevan [3]. Namun, metode ini tidak mempertimbangkan aspek spasial dalam pola transaksi ATM.

Dalam beberapa tahun terakhir, pendekatan deep learning seperti LSTM telah digunakan untuk menangkap pola temporal yang kompleks dalam data transaksi ATM. Meskipun efektif dalam memahami pola deret waktu, model ini tidak mampu secara eksplisit mempertimbangkan hubungan spasial antar ATM [4]. Berbagai pendekatan berbasis prediksi spatio-temporal mulai dikembangkan. Salah satunya merupakan pendekatan ConvLSTM, yang menggabungkan CNN untuk menangkap pola spasial dan LSTM untuk pola temporal. Namun, metode ini masih memiliki keterbatasan dikarenakan bekerja hanya dengan grid tetap dan kurang fleksibel dalam menangani hubungan antar ATM yang tidak beraturan.

GCN menjadi alternatif lain yang mulai digunakan untuk memodelkan hubungan antar ATM secara eksplisit. GCN mampu menangkap informasi spasial dalam bentuk struktur graf, namun memiliki kelemahan dalam menangani hubungan yang dinamis karena bobot antar node bersifat tetap [5]. Untuk mengatasi kelemahan ini, GAT digunakan sebagai solusi yang lebih adaptif dalam menangani hubungan spasial dalam data spatio-temporal.

GAT menggunakan mekanisme *attention* yang memungkinkan model untuk memberikan bobot berbeda pada hubungan antar ATM secara dinamis berdasarkan relevansi masing-masing node. Dengan begitu, GAT mampu secara fleksibel mempelajari hubungan spasial yang tidak tetap dan menyesuaikan bobot koneksi antar ATM sesuai dengan perubahan pola transaksi. GAT dapat menangkap pola temporal secara efektif, menghasilkan prediksi yang lebih akurat dan adaptif terhadap perubahan kondisi operasional ATM [6].

Dengan keunggulan ini, penelitian ini saya usulkan menggunakan pendekatan GAT dalam prediksi stok tunai ATM pada database berisikan informasi mengenai setiap *Automatic Teller Machine* (ATM) dari client PT Collega Inti Pratama untuk meningkatkan akurasi prediksi dan efisiensi pada setiap ATM tersebut. Dengan mempertimbangkan aspek spasial dan temporal secara simultan, pendekatan ini diharapkan dapat memberikan solusi yang lebih robust dalam manajemen stok tunai ATM.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, berikut merupakan rumusan masalah yang dirumuskan:

1. Bagaimana keefektifitasan metode GAT (*Graph Attention Network*) dalam peningkatan efisiensi prediksi ketersediaan stok uang tunai pada ATM (*Automatic Teller Machine*)?
2. Sejauh mana Tingkat keakurasian prediksi stok uang tunai dapat ditingkatkan melalui pendekatan GAT (*Graph Attention Network*).

1.3 Tujuan dan Manfaat

Berdasarkan penjelasan dari latar belakang penelitian dan rumusan masalah yang dihasilkan maka tujuan dari penelitian yang ini dicapai:

1. Mengembangkan model prediksi yang mampu meningkatkan efisiensi pengelolaan stok uang tunai pada ATM (*Automatic Teller Machine*) dengan pendekatan GAT (*Graph Attention Network*).
2. Menghasilkan rekomendasi untuk pengoptimalisasian pengelolaan uang tunai dalam sistem perbankan berdasarkan hasil implementasi model.
3. Mengevaluasi Tingkat akurasi model prediksi berbasis GAT (*Graph Attention Network*).

1.4 Batasan Masalah

Masalah yang dibahas dalam penelitian ini adalah sebagai berikut:

1. Penelitian berfokus pada pendekatan algoritma GAT (*Graph Attention Network*) dalam konteks prediksi berlanjut stok tunai pada ATM (*Automatic Teller Machine*).
2. Data yang terbatas pada data transaksi historis dan data pengisian ulang uang tunai ATM (*Automatic Teller Machine*).
3. Menghasilkan rekomendasi untuk optimalisasi pengelolaan uang tunai dalam sistem perbankan berdasarkan hasil implementasi model.

1.5 Metode Penelitian

1. Pendekatan Penelitian

Penelitian ini menggunakan pendekatan **Graph Attention Network (GAT)** untuk memprediksi kebutuhan stok tunai ATM berdasarkan data transaksi historis. Model GAT dipilih karena kemampuannya dalam menangani data berstruktur graf dan menangkap hubungan kompleks antar ATM melalui mekanisme attention.

2. Dataset dan Preprocessing

Dataset yang digunakan dalam penelitian ini diperoleh dari client PT Collega Inti Pratama, mencakup Data transaksi ATM (volume transaksi harian, jumlah penarikan, saldo kas), Informasi spasial ATM (lokasi geografis), Faktor eksternal (hari libur, tren musiman).

Tahapan preprocessing meliputi Penanganan data hilang dengan interpolasi temporal, Normalisasi fitur menggunakan Min-Max Scaling, Encoding data kategorikal untuk informasi waktu dan transaksi, Transformasi data menjadi bentuk graf, di mana node merepresentasikan ATM, Edge menghubungkan ATM dengan

pola transaksi serupa, Atribut node & edge ditambahkan berdasarkan jumlah transaksi dan hubungan antar ATM.

3. Perancangan Model

Model yang dikembangkan berbasis Graph Attention Network (GAT) dengan dua lapisan konvolusi berbasis perhatian (GATConv).

- Lapisan pertama: 8 kepala perhatian untuk menangkap pola hubungan antar ATM.
- Lapisan kedua: 1 kepala perhatian untuk menghasilkan prediksi akhir.
- Fungsi aktivasi: **ReLU**.
- **Loss function: Cross-Entropy Loss.**
- **Optimizer: Adam** dengan learning rate **0,01**.

4. Pembagian Dataset

Data dibagi menjadi tiga subset dengan proporsi **Training set (70%)** untuk melatih model, **Validation set (20%)** untuk tuning parameter, **Testing set (10%)** untuk evaluasi akhir.

5. Evaluasi Model

Evaluasi model dilakukan dengan metrik Akurasi (Accuracy) untuk mengukur tingkat ketepatan prediksi model, Precision & Recall mengukur keakuratan prediksi kategori stok tunai, F1-score untuk menyeimbangkan precision dan recall, MAE & RMSE menilai kesalahan prediksi stok tunai, R-squared (R^2) mengukur sejauh mana model menjelaskan variasi dalam data.

6. Pengujian dan Visualisasi Hasil

- Prediksi stok tunai ATM per hari.
- Perkiraan tanggal pengisian ulang.
- Identifikasi ATM dengan kebutuhan pengisian tinggi.
- Prediksi ATM yang akan kehabisan stok dalam waktu dekat.