

BAB V PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat ditarik kesimpulan sebagai berikut:

1. Implementasi metode *Learning to Rank* berbasis *LambdaMART* dengan arsitektur *Dual Pipeline* berhasil diterapkan untuk mengidentifikasi dan memeringkat risiko transaksi fraud pada dataset Credit Card Fraud Detection (284.807 transaksi, rasio fraud 0,17%). Data dikelompokkan ke dalam query berbasis jendela waktu 1 jam menggunakan formula $qid = \lfloor \text{Time}/3600 \rfloor$, menghasilkan 6 query aktif pada data pengujian.
2. Proses transformasi data transaksi ke format *Learning to Rank* dilakukan melalui tiga tahap: Proses transformasi data dilakukan melalui *time-based split* 70/15/15 untuk mencegah data leakage, diikuti ekstraksi fitur *xgb_score* menggunakan 5-Fold Time Series Cross-Validation OOF dengan *XGBoost*, dan transformasi logit untuk meregangkan distribusi probabilitas OOF sehingga *LambdaMART* dapat menemukan split point yang optimal.
3. Model Hybrid LTR (*XGBoost* OOF + *LambdaMART*) mencapai performa terbaik dengan $NDCG@10 = 0,8161$, mengungguli *Pure LambdaMART* ($NDCG@10 = 0,8126$), *XGBoost* Baseline (0,8104), *Random Forest* (0,7842), dan *Logistic Regression* (0,6578). Model mencapai $NDCG@10 = 1,0000$ pada query terbaik ($qid=42$) dengan seluruh 10 posisi teratas ditempati oleh transaksi fraud. Hasil ini membuktikan bahwa pendekatan LTR mampu memprioritaskan transaksi fraud secara efektif dan lebih operasional dibandingkan pendekatan klasifikasi biner konvensional. Hasil ini mengonfirmasi bahwa pendekatan *Learning to Rank* merupakan solusi yang secara akademik dapat dipertanggungjawabkan dan relevan secara

operasional untuk mengatasi keterbatasan klasifikasi biner dalam konteks deteksi fraud dengan sumber daya investigasi terbatas, sebagaimana diidentifikasi dalam latar belakang penelitian ini.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan, beberapa saran untuk pengembangan penelitian selanjutnya adalah sebagai berikut:

1. Penggunaan *graded relevance* sebagai pengganti *binary relevance*, misalnya dengan menetapkan skor relevansi berdasarkan nominal transaksi ($rel = Class \times \log(1 + Amount)$), sehingga fraud bernilai besar diprioritaskan lebih tinggi dalam daftar investigasi.
2. Validasi framework pada dataset transaksi keuangan digital Indonesia atau Asia Tenggara yang mencerminkan karakteristik fraud lokal, mengingat dataset yang digunakan dalam penelitian ini berasal dari transaksi Eropa tahun 2013.
3. Implementasi pipeline LTR pada skenario data streaming real-time, di mana query diperbarui setiap jam secara otomatis dan model dilatih ulang secara inkremental.
4. Eksplorasi model LTR berbasis neural network (seperti *ListNet* atau *DLCM*) sebagai alternatif *LambdaMART* untuk menangkap pola non-linear yang lebih kompleks dalam data transaksi keuangan digit.