

## **BAB V**

### **PENUTUPAN**

Bab ini menjelaskan hasil penelitian akhir yang didapatkan setelah menerapkan metode *Long Short-Term Memory* (LSTM) multivariat dalam memprediksi harga saham penutupan. Uraian tersebut berisi kesimpulan yang dibuat berdasarkan hasil dan pembahasan penelitian, serta saran-saran yang ditulis sebagai referensi untuk pengembangan penelitian lebih lanjut dan penerapan model dalam konteks yang tepat.

#### **5.1 Kesimpulan**

Berdasarkan tujuan penelitian yang telah ditentukan, yaitu menganalisis akurasi metode Long Short-Term Memory (LSTM) multivariat dalam memprediksi harga saham harian ( $t+1$ ) Bank HIMBARA menggunakan harga penutupan (Close) dan BI-Rate sebagai variabel eksternal, ditemukan bahwa model LSTM multivariat mampu memberikan hasil prediksi yang cukup baik pada keempat saham yang diteliti, yaitu BBNI, BBRI, BBTN, dan BMRI. Kinerja tersebut terlihat dari nilai Mean Absolute Percentage Error (MAPE) yang mencapai 1,46% untuk BBNI, 1,70% untuk BBRI, 2,21% untuk BBTN, dan 1,50% untuk BMRI, dengan rata-rata MAPE sebesar 1,72%. Nilai MAPE pada setiap saham yang kurang dari 2% menunjukkan bahwa model berhasil memberikan prediksi yang hampir mendekati harga yang sebenarnya. Dengan demikian, menggunakan LSTM multivariat dengan harga penutupan dan BI-Rate sebagai variabel input dapat menghasilkan prediksi yang cukup baik dalam memperkirakan harga saham harian perusahaan Bank HIMBARA.

Hasil penelitian juga menunjukkan beberapa temuan lain yang berkaitan dengan penggunaan *BI-Rate* dan konfigurasi model. Pertama, pengaruh *BI-Rate* sebagai variabel eksternal berbeda pada setiap saham. Pada BBNI, penggunaan *BI-Rate* memberikan peningkatan kinerja model. Hal tersebut ditunjukkan dengan penurunan MAE dari Rp74,91 menjadi Rp68,33, RMSE dari Rp100,29 menjadi Rp94,02, dan MAPE dari 1,58% menjadi 1,46%. Namun, kondisi yang berbeda ditemukan pada BBRI, BBTN, dan BMRI, karena model tanpa *BI-Rate* menghasilkan kesalahan yang lebih rendah dibandingkan model yang menggunakan *BI-Rate*. Secara keseluruhan, rata-rata MAPE model tanpa *BI-Rate*

adalah 1,61%, sedangkan model dengan *BI-Rate* menghasilkan rata-rata MAPE sebesar 1,72%.

Kedua, berdasarkan pengujian terhadap delapan kombinasi *hyperparameter*, seluruh saham menunjukkan hasil terbaik ketika menggunakan 50 unit LSTM dan *batch size* sebesar 32. Sementara itu, jenis *optimizer* yang menghasilkan kinerja terbaik tidak sama pada setiap saham. BBNI dan BMRI memperoleh hasil terbaik dengan optimizer Adam, sedangkan BBRI dan BBTN memperoleh hasil terbaik dengan RMSprop. Ketiga, berdasarkan perbandingan antara model LSTM dan XGBoost dengan menggunakan variabel input yang sama, termasuk *BI-Rate*, model LSTM memberikan hasil MAE, RMSE, dan MAPE yang lebih rendah pada seluruh saham Bank HIMBARA. Namun, dari sisi waktu komputasi, XGBoost membutuhkan *runtime* yang lebih singkat sehingga memiliki keunggulan dalam hal efisiensi waktu pemrosesan.

Secara umum, hasil penelitian yang diperoleh telah memenuhi tujuan serta menjawab rumusan masalah yang telah ditetapkan. Berdasarkan hasil pengujian, model LSTM multivariat dapat diterapkan untuk memprediksi harga saham harian Bank HIMBARA dan mampu menghasilkan tingkat kesalahan prediksi yang relatif rendah. Namun, penggunaan *BI-Rate* tidak memberikan pengaruh yang sama pada setiap saham karena peningkatan kinerja hanya terlihat pada BBNI. Hal tersebut menunjukkan bahwa pengaruh variabel eksternal dapat berbeda sesuai dengan karakteristik masing-masing saham. Selain itu, meskipun LSTM memberikan hasil prediksi yang lebih baik dibandingkan XGBoost, XGBoost memiliki keunggulan dalam waktu komputasi yang lebih cepat.

## 5.2 Saran

Berdasarkan hasil dan keterbatasan penelitian yang telah dilakukan, beberapa saran yang dapat digunakan untuk penelitian selanjutnya adalah sebagai berikut.

1. Penelitian selanjutnya disarankan untuk menambahkan variabel eksternal lain yang dapat memengaruhi pergerakan harga saham, seperti inflasi, nilai tukar Rupiah, Indeks Harga Saham Gabungan (IHSG), dan indikator ekonomi lainnya. Penambahan variabel tersebut diharapkan dapat memberikan informasi yang lebih beragam bagi model dalam melakukan prediksi.

2. Penelitian selanjutnya disarankan untuk menguji algoritma *deep learning* lainnya, seperti *Gated Recurrent Unit* (GRU), *Bidirectional LSTM*, dan model *hybrid* seperti CNN-LSTM. Pengujian dapat dilakukan dengan menggunakan data dan variabel yang sama agar hasil perbandingan antaralgoritma dapat dilakukan secara lebih objektif.
3. Penelitian selanjutnya disarankan untuk melakukan optimasi model dan *feature selection* guna memperoleh konfigurasi yang lebih optimal. Selain mempertimbangkan tingkat akurasi berdasarkan MAE, RMSE, dan MAPE, waktu komputasi (*runtime*) juga dapat digunakan sebagai pertimbangan untuk mendapatkan model yang memiliki keseimbangan antara akurasi dan efisiensi komputasi.