

## BAB V

### SIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan kesimpulan yang telah dipaparkan, berikut merupakan beberapa saran yang diajukan:

1. Prediksi harga *cryptocurrency* menggunakan CNN menunjukkan variasi performa. CNN untuk BTC, ETH, dan USDT menghasilkan metrik performa dengan rata-rata RMSE 959.88, MAE 729.43, dan MAPE 6.32%. Namun, LSTM lebih unggul dengan rata-rata RMSE 483.66, MAE 402.21, dan MAPE 2.92%, menunjukkan kesalahan lebih minim dan performa optimal. LSTM adalah pilihan terbaik untuk dikombinasikan dengan XGBoost dan LightGBM dalam model *hybrid*.
2. Model *hybrid* LSTM + XGBoost menunjukkan peningkatan performa dibandingkan model tunggal (CNN dan LSTM). Rata-rata metrik performa mencapai RMSE 455.58, MAE 328.79, MAPE 2.24%, dan dikarenakan nilai MAPE >10%, performa model termasuk "Sangat Optimal". LSTM + XGBoost lebih unggul karena menggabungkan kekuatan LSTM dan XGBoost.
3. Model *hybrid* LSTM + LightGBM menghasilkan performa terbaik dalam memprediksi harga *cryptocurrency*. Rata-rata nilai metriknya adalah RMSE 368.07, MAE 268.72, dan MAPE 2.04%, termasuk kategori "Sangat Optimal" dengan nilai MAPE >10%. Secara keseluruhan, LSTM + LightGBM adalah model paling optimal dan efektif dalam.
4. Model *hybrid* LSTM + XGBoost menunjukkan rata-rata RMSE 455.58, MAE 328.79, dan MAPE 2.24%, termasuk kategori "Sangat Optimal" dengan nilai MAPE >10% dan kesalahan prediksi minimal dibandingkan CNN dan LSTM. Namun, LSTM + LightGBM lebih unggul dengan RMSE 368.07, MAE 268.72, dan MAPE 2.04%. Secara keseluruhan, LSTM + LightGBM adalah model paling optimal dan efektif untuk memprediksi harga *cryptocurrency*.

## 5.2 Limitasi

Terdapat beberapa limitasi dalam penelitian yang menjadi tantangan dan berpengaruh terhadap hasil prediksi, di antaranya adalah:

1. Fluktuasi pasar *cryptocurrency* dalam periode yang digunakan dalam penelitian sangat berdampak pada keakuratan prediksi dan performa model.
2. Proses *tuning* memerlukan waktu dan sumber daya komputasi yang besar sehingga dapat menjadi salah satu keterbatasan dalam penelitian.
3. Data historis mencakup periode 2018-2023, dengan demikian pola ataupun anomali diluar periode tidak tertangkap oleh model.
4. Kombinasi antara algoritma dapat menghasilkan model *hybrid* yang kompleks dan beresiko *overfitting* pada data penelitian.
5. Data historis yang stabil dapat berdampak kepada performa model prediksi, karena menjadi sulit bagi model untuk memperkirakan pergerakan dari *cryptocurrency*.

## 5.3 Saran

Berdasarkan kesimpulan yang telah dijelaskan, terdapat beberapa saran yang diajukan agar dapat meningkatkan kualitas penelitian:

1. Penelitian selanjutnya sebaiknya menggunakan dataset lebih meluas, komprehensif, dan memperhatikan karakteristik *cryptocurrency* seperti volatilitas dan stabilitas, yang dapat mempengaruhi model prediksi, contohnya Tether (USDT) yang relatif stabil.
2. Disarankan untuk menambahkan jenis model *machine learning* dan *deep learning*. Selain model CNN, LSTM, XGBOOST, dan LightGBM, dapat digunakan model alternatif yang canggih seperti AutoLSTM dan Prophet.
3. Penelitian selanjutnya sebaiknya berfokus pada prediksi jangka pendek dan jangka panjang untuk memberikan insight strategis dan gambaran luas mengenai pasar *cryptocurrency*.