

BAB V PENUTUP

5.1. Kesimpulan

Berdasarkan penelitian yang telah dilakukan bahwa untuk melakukan implementasi prediksi diperlukan tahap penencarian model yang sesuai dengan karakteristik dari masing-masing dataset. Dari penelitian tersebut dapat disimpulkan sebagai berikut:

1. Model LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit) dan BiLSTM (Bidirectional Long Short-Term Memory) digunakan dalam analisis prediksi data *time series cryptocurrency*. Untuk mengimplementasikan ketiga model ini, diperlukan tahapan yang penting. Pertama, data *time series cryptocurrency* harus dinormalisasi untuk mempermudah pembelajaran oleh model. Selanjutnya, data dibagi menjadi interval data (x) sebagai input model dan target data (y) sebagai pola yang akan dipelajari. Data kemudian dibagi menjadi tiga bagian: train (untuk pelatihan model), valid (untuk validasi hasil model dengan menghitung nilai RMSE), dan test (untuk percobaan prediksi). Model LSTM, GRU, dan BiLSTM dibentuk sesuai dengan arsitektur masing-masing model. Selanjutnya, pelatihan model dilakukan dengan berbagai kombinasi hyperparameter seperti *dropout*, jumlah unit, learning rate, *optimizer*, jumlah *epoch*, dan ukuran batch. setelah didapatkan hasil dari setiap model, model terbaik ditentukan berdasarkan rmse terkecil dan dilakukan prediksi menggunakan data test yang belum pernah ditemukan model.
2. Akurasi model LSTM dan GRU dalam memprediksi *cryptocurrency* ETH dan SOL akan mengalami perubahan dengan perubahan parameter seperti *epoch*, learning rate, *optimizer*, *dropout*, jumlah unit, dan *batch size*. Dalam penelitian ini, ditemukan bahwa perubahan parameter-parameter tersebut menghasilkan variasi dalam akurasi model. Peningkatan jumlah *epoch* dapat meningkatkan akurasi model hingga suatu batas tertentu sebelum mencapai titik jenuh, sedangkan penurunan

learning rate cenderung meningkatkan akurasi. Berdasarkan hasil penelitian, *optimizer RMSprop* memberikan hasil yang lebih baik dibandingkan dengan Adam dan AdaGrad dalam memprediksi harga Solana (SOL) dan Ethereum (ETH).

3. Model LSTM, GRU, dan BiLSTM semuanya memiliki performa yang baik dalam memprediksi harga SOL dan ETH, tergantung pada kombinasi parameter yang digunakan. Melalui penelitian ini, telah ditemukan model dan parameter terbaik berdasarkan jumlah RMSE terkecil untuk memprediksi *cryptocurrency* ETH dan SOL. Untuk Ethereum (ETH), model BiLSTM dengan *dropout* 0.005, unit 64, *learning rate* 0.005, *optimizer RMSprop*, *epoch* 150, dan *batch size* 64 memberikan hasil RMSE 0.0230. Sedangkan untuk Solana (SOL), model BiLSTM dengan *dropout* 0.3, unit 64, *learning rate* 0.005, *optimizer RMSprop*, *epoch* 150, dan *batch size* 32 memberikan hasil RMSE 0.0073. sehingga model terbaik berdasarkan nilai terkecil adalah BiLSTM dengan *optimizer RMSprop* serta *epoch* 150.

Dengan demikian, penelitian ini memberikan pemahaman tentang cara kerja model LSTM, GRU, dan BiLSTM dalam memprediksi data *time series cryptocurrency* Solana dan Ethereum. Selain itu, penelitian ini juga mengidentifikasi kombinasi parameter terbaik untuk memperoleh akurasi prediksi yang optimal. Hasil ini dapat menjadi landasan bagi penelitian lebih lanjut dalam bidang prediksi *cryptocurrency* dan memberikan kontribusi pada pengambilan keputusan dalam investasi atau analisis pasar.

5.2. Saran

Berdasarkan kesimpulan yang telah dijelaskan sebelumnya, terdapat beberapa saran yang dapat diberikan:

1. Selain LSTM, GRU, dan BiLSTM, terdapat berbagai jenis model lain yang dapat dieksplorasi untuk prediksi data *time series cryptocurrency*. Misalnya, model seperti Transformer atau WaveNet dapat menjadi alternatif yang

menarik untuk dipertimbangkan. Melakukan eksperimen dengan model-model ini dapat memberikan wawasan baru dan memperluas pemahaman terhadap prediksi *cryptocurrency*.

2. Selain parameter-parameter yang telah diuji dalam penelitian ini, masih ada parameter lain yang dapat dieksplorasi. Misalnya, penggunaan fungsi aktivasi yang berbeda, penyesuaian lain pada arsitektur model, atau metode pengoptimalan yang berbeda. Melakukan eksperimen dengan parameter-parameter ini dapat membantu mengoptimalkan performa model dan meningkatkan akurasi prediksi.
3. Penggunaan dataset yang lebih luas dan lebih diversifikasi dapat menjadi langkah selanjutnya. Melibatkan data dari berbagai *cryptocurrency* dan sumber yang berbeda dapat memberikan gambaran yang lebih lengkap tentang dinamika pasar dan memperkaya analisis prediksi. Selain itu, mempertimbangkan faktor eksternal seperti berita atau sentimen pasar juga dapat meningkatkan keakuratan prediksi.
4. Untuk memperoleh hasil yang lebih solid dan dapat dipercaya, perlu dilakukan validasi dan evaluasi tambahan. Misalnya, melakukan validasi lintas waktu (*out-of-sample validation*) untuk menguji performa model di masa depan atau menggunakan metrik evaluasi tambahan seperti Precision, Recall, atau F1-score. Hal ini akan memberikan pemahaman yang lebih lengkap tentang sejauh mana model dapat diandalkan dalam prediksi *cryptocurrency*.

Dengan mengikuti saran-saran di atas, penelitian lebih lanjut dapat dilakukan untuk terus meningkatkan performa prediksi *cryptocurrency* dan memberikan kontribusi yang lebih berarti dalam bidang ini.