

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan keseluruhan analisis dan pembahasan hasil penelitian yang telah dipaparkan pada Bab 4, dapat ditarik beberapa simpulan utama terkait perbandingan dan optimasi model LSTM, GRU, dan RNN untuk prediksi harga saham perbankan BBKA, BBRI, dan BMRI.

Secara umum, ketiga model *deep learning* yang telah dioptimasi LSTM, GRU, dan RNN menunjukkan kapabilitas yang sangat baik dan kompetitif dalam memprediksi harga saham harian ketiga bank tersebut. Hal ini secara konsisten dibuktikan dengan pencapaian nilai metrik evaluasi yang sangat positif pada data uji. Sebagai contoh, nilai R^2 untuk semua model pada ketiga saham secara konsisten berada di atas 0.99 (berkisar antara 0.9903 hingga 0.9963), yang mengindikasikan bahwa lebih dari 99% variabilitas harga saham aktual mampu dijelaskan oleh model-model prediksi. Selain itu, nilai *error* rata-rata juga tercatat rendah, dengan MAE berkisar antara 50.04 hingga 84.88 dan RMSE antara 66.63 hingga 112.97, yang menunjukkan bahwa prediksi yang dihasilkan memiliki kedekatan yang tinggi dengan nilai harga aktual.

Dalam analisis perbandingan kinerja setelah proses optimasi *hyperparameter*, model GRU menunjukkan keunggulan yang paling konsisten. Secara spesifik, GRU menghasilkan performa terbaik untuk prediksi harga saham BBKA dengan mencapai nilai MAE 80.48, RMSE 108.43, MAPE 1.02%, dan R^2 0.9936. Model ini juga unggul pada saham BBRI, dengan mencatatkan MAE 50.04, RMSE 66.63, MAPE 1.28%, dan R^2 0.9909. Untuk saham BMRI, performa ketiga model (LSTM, GRU, dan RNN) ditemukan sangat mirip dan sama-sama sangat baik, dengan nilai R^2 identik sebesar 0.9963. Meskipun demikian, model RNN menunjukkan keunggulan numerik yang sangat tipis pada metrik MAE 56.19 dan MAPE 1.32%. Temuan ini mengindikasikan bahwa meskipun ketiga model mampu memberikan prediksi akurat, GRU cenderung menawarkan efektivitas terbaik untuk mayoritas kasus dalam penelitian ini.

Proses optimasi *hyperparameter* menggunakan Optuna juga terbukti memainkan peran krusial dalam mencapai tingkat kinerja prediksi yang tinggi. Hasil *tuning* menunjukkan bahwa setiap jenis model (LSTM, GRU, RNN) dan setiap saham cenderung memiliki kombinasi *hyperparameter* (jumlah unit, *dropout rate*, *learning rate*) optimal yang berbeda-beda. Hal ini menggarisbawahi pentingnya melakukan *tuning* secara individual untuk setiap model dan kasus spesifik, serta mengindikasikan adanya karakteristik unik dalam cara masing-masing arsitektur model berinteraksi dengan data dan *hyperparameter* tertentu.

Terakhir, pada tahap *forecasting* untuk prediksi harga saham 30 hari ke depan, observasi menunjukkan bahwa meskipun model-model yang telah dioptimasi mampu menangkap arah tren umum pergerakan harga saham, tingkat presisi absolut dari prediksi cenderung mengalami penurunan dibandingkan dengan kinerjanya pada periode data uji historis. Penurunan presisi ini mengindikasikan adanya kompleksitas inheren dalam prediksi jangka panjang di pasar saham, yang sangat dipengaruhi oleh faktor-faktor eksternal dinamis yang tidak sepenuhnya tercakup hanya dengan menggunakan data harga historis sebagai input model. Oleh karena itu, prediksi yang dihasilkan lebih tepat diinterpretasikan sebagai indikasi tren umum daripada sebagai nilai harga yang pasti dan presisi.

5.2 Saran

Berdasarkan temuan dan keterbatasan dalam penelitian ini, berikut adalah beberapa saran yang dapat dipertimbangkan untuk penelitian selanjutnya atau pengembangan praktis:

1. Eksplorasi Fitur Tambahan: Penelitian ini hanya menggunakan data harga penutupan historis. Untuk meningkatkan akurasi dan robustitas model, penelitian selanjutnya disarankan untuk mengintegrasikan fitur-fitur lain seperti volume perdagangan, indikator teknikal (misalnya, *Moving Averages*, *RSI*, *MACD*), atau bahkan data fundamental perusahaan jika memungkinkan, yang dapat memberikan konteks pasar yang lebih kaya bagi model.

2. Pengembangan Optimasi *Hyperparameter*: Meskipun optimasi telah dilakukan pada tiga *hyperparameter* kunci, penelitian mendatang dapat memperluas ruang lingkup optimasi dengan menyertakan *hyperparameter* lain seperti *batch size*, jenis *optimizer*, fungsi aktivasi, atau jumlah lapisan dalam arsitektur model. Penggunaan jumlah *trial* yang lebih besar dalam Optuna atau eksplorasi algoritma optimasi *hyperparameter* lainnya juga dapat dipertimbangkan.
3. Peningkatan Metodologi *Forecasting*: Untuk meningkatkan presisi *forecasting* jangka panjang, dapat dieksplorasi penggunaan teknik *rolling forecast* yang lebih dinamis, model *ensemble* yang menggabungkan kekuatan beberapa model, atau bahkan model *hybrid* yang mengintegrasikan pendekatan statistik dengan *deep learning*. Penelitian juga bisa fokus pada evaluasi *forecasting* dengan berbagai horizon waktu (lebih pendek atau lebih panjang dari 30 hari).
4. Integrasi Faktor Eksternal: Mengingat keterbatasan presisi pada *forecasting* jangka panjang yang kemungkinan dipengaruhi faktor eksternal, penelitian selanjutnya sangat disarankan untuk mencoba memasukkan variabel-variabel eksogen seperti data sentimen berita, indikator ekonomi makro (inflasi, suku bunga), atau kebijakan pemerintah yang relevan untuk melihat dampaknya terhadap akurasi prediksi.

Saran-saran ini diharapkan dapat menjadi panduan untuk pengembangan model prediksi harga saham yang lebih akurat, komprehensif, dan aplikatif di masa mendatang.