

## BAB V

### SIMPULAN DAN SARAN

#### 5.1 Simpulan

Berdasarkan hasil analisis data historis harga saham sektor perbankan Indonesia yang mencakup BBKA, BBRI, dan BMRI, dapat disimpulkan bahwa karakteristik data saham perbankan menunjukkan pola pergerakan yang relatif stabil namun tetap bersifat non-linear dan volatil, sebagaimana lazim ditemukan pada data finansial. Saham perbankan dengan kapitalisasi besar seperti BBKA dan BBRI cenderung memiliki fluktuasi yang lebih terkendali dan tren jangka panjang yang lebih jelas dibandingkan saham dengan volatilitas ekstrem di sektor lain, meskipun tetap dipengaruhi oleh dinamika pasar dan sentimen ekonomi. Karakteristik ini menjadikan data saham perbankan cocok untuk pendekatan pemodelan deret waktu berbasis *deep learning*, namun tetap menuntut metode yang mampu menangani *noise* dan ketidakstasioneran data.

Terkait pengaruh penerapan *Hybrid* model, hasil penelitian menunjukkan bahwa kombinasi kedua metode tersebut memberikan lebih efektif pada kondisi tertentu terhadap kinerja model *Long Short-Term Memory* (LSTM). EMD berperan dalam memecah sinyal harga saham menjadi beberapa *Intrinsic Mode Functions* (IMF) sehingga struktur data menjadi lebih terorganisasi dan pola fluktuasi dapat dipelajari secara lebih efektif oleh LSTM. Sementara itu, MRFO membantu menemukan konfigurasi *hyperparameter* yang lebih sesuai dengan karakteristik masing-masing saham, sehingga proses pelatihan model menjadi lebih adaptif terhadap data yang bersifat non-linear dan volatil. Meskipun kontribusi EMD dan MRFO tidak dievaluasi secara terpisah, hasil eksperimen menunjukkan bahwa pipeline *Hybrid* secara keseluruhan mampu meningkatkan kualitas pembelajaran model.

Berkaitan dengan signifikansi peningkatan kinerja prediksi, hasil uji statistik menunjukkan bahwa model *Hybrid* EMD–MRFO–LSTM menghasilkan

peningkatan performa yang signifikan secara statistik hanya pada saham BBKA. Hal ini dibuktikan melalui hasil *paired t-test* yang menunjukkan nilai *p-value* jauh di bawah tingkat signifikansi 0,05, sehingga peningkatan kinerja prediksi pada saham BBKA dapat dinyatakan nyata dan konsisten. Sebaliknya, pada saham BBRI dan BMRI, meskipun secara deskriptif model *Hybrid* menunjukkan penurunan nilai error, peningkatan tersebut belum signifikan secara statistik. Temuan ini mengindikasikan bahwa efektivitas model *Hybrid* bersifat *data-dependent* dan dipengaruhi oleh karakteristik sinyal masing-masing saham.

Dari sisi perbandingan nilai evaluasi antara *base model* LSTM dan model *Hybrid* EMD–MRFO–LSTM, hasil pengukuran menggunakan metrik *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE), dan *Root Mean Squared Error* (RMSE) menunjukkan bahwa model *Hybrid* secara umum menghasilkan nilai error yang lebih rendah pada sebagian besar konfigurasi pelatihan, khususnya pada *epoch* rendah hingga menengah. Pada saham BBKA, penurunan MAPE yang terukur, seperti dari 10,55% menjadi 1,82% pada *epoch* 50, menunjukkan bahwa model *Hybrid* lebih efektif dibandingkan *base model*. Pada saham BBRI, pola serupa juga ditemukan dengan penurunan MAPE yang cukup besar. Namun, pada saham BMRI, performa model *Hybrid* tidak selalu lebih baik dibandingkan *base model*, terutama pada *epoch* tinggi, yang menunjukkan bahwa model *Hybrid* memerlukan pemilihan konfigurasi pelatihan yang lebih cermat agar tidak mengalami penurunan performa.

Secara keseluruhan, penelitian ini menyimpulkan bahwa model *Hybrid* EMD–MRFO–LSTM mampu memberikan peningkatan kinerja prediksi yang terukur dibandingkan *base model* LSTM, terutama pada saham BBKA dan dalam kondisi pelatihan tertentu. Namun, peningkatan tersebut tidak bersifat universal untuk seluruh saham dan konfigurasi, sehingga penerapan model *Hybrid* perlu disesuaikan dengan karakteristik data dan tujuan analisis agar hasil yang diperoleh tetap optimal.

## 5.2 Saran

Berdasarkan keterbatasan yang ditemukan dalam penelitian ini, beberapa saran dapat diberikan untuk pengembangan penelitian selanjutnya. Pertama, diperlukan peningkatan kapasitas perangkat komputasi agar proses optimasi menggunakan algoritma *Manta Ray Foraging Optimization* (MRFO) dapat dilakukan dengan ukuran populasi (*population size*) yang lebih besar, yaitu jumlah kandidat solusi yang dievaluasi pada setiap proses optimasi. Peningkatan ukuran populasi memungkinkan algoritma mengeksplorasi ruang pencarian *hyperparameter* secara lebih luas dan beragam, sehingga peluang untuk menemukan konfigurasi parameter yang lebih optimal menjadi lebih besar.

Selain itu, penelitian selanjutnya juga disarankan untuk menggunakan jumlah iterasi optimasi (*number of iterations*) yang lebih tinggi, yang merepresentasikan banyaknya siklus pencarian solusi terbaik dalam algoritma MRFO. Penambahan jumlah iterasi diharapkan dapat meningkatkan proses *convergence* dan kestabilan solusi, sehingga parameter terbaik yang diperoleh tidak hanya optimal secara lokal, tetapi juga lebih *robust* terhadap variasi data.

Kedua, penelitian berikutnya dapat menambahkan berbagai fitur tambahan seperti indikator teknikal (misalnya *Relative Strength Index* (RSI), *Moving Average Convergence Divergence* (MACD), dan *volume* transaksi), serta data berbasis sentimen dari berita atau media sosial guna memperkaya konteks prediksi dan meningkatkan kemampuan model dalam menangkap dinamika pasar saham. Ketiga, cakupan objek penelitian dapat diperluas dengan melibatkan lebih banyak saham dari berbagai sektor industri agar kemampuan *generalization* model dapat diuji secara lebih komprehensif.

Selain itu, penelitian lanjutan juga dapat mengeksplorasi *forecasting horizon* yang berbeda, seperti prediksi jangka pendek hingga menengah ( $t+3$ ,  $t+5$ , atau  $t+10$ ), serta melakukan perbandingan performa dengan arsitektur model lain seperti *Gated Recurrent Unit* (GRU), *Bidirectional LSTM* (BiLSTM), atau *Transformer*, untuk menentukan pendekatan yang paling sesuai dalam konteks pasar saham Indonesia.