BAB V
PENUTUP

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan pada Bab 4, kesimpulan dari penelitian ini adalah sebagai berikut:

1. **Hasil Evaluasi Klasifikasi**: Pemodelan HMM-XGBoost (Skenario B) cenderung lebih baik dibandingkan model XGBoost tanpa HMM (Skenario A) dalam memprediksi arah pergerakan harga. Penambahan fitur probabilitas rezim HMM meningkatkan presisi sebesar +5,94% (dari 0,3723 menjadi 0,3944) dan *F1-score* sebesar +2,68% (dari 0,3542 menjadi 0,3637) pada Solana, serta meningkatkan presisi sebesar +10,20% (dari 0,3726 menjadi 0,4106) dan *F1-score* sebesar +4,54% (dari 0,3635 menjadi 0,3800) pada Ripple. Peningkatan kinerja ini sejalan dengan berkurangnya tebakan sinyal beli palsu pada *fase Sideways* sebesar 13 sampel pada Solana (dari 43 menjadi 30 sampel) dan 55 sampel pada Ripple (dari 85 menjadi 30 sampel).
2. **Hasil Ranking Fitur Terpenting:** Indikator *Relative Strength Index* (RSI) mendominasi sebagai pemicu sinyal harga lokal utama di peringkat pertama dengan nilai kontribusi terbesar (*Gain* 0,0611 pada Solana dan 0,0776 pada Ripple). Fitur probabilitas rezim HMM bertindak sebagai penyaring kontekstual makro, di mana pada Ripple fitur probabilitas *Sideways* (*prob_sideways*) berhasil menempati peringkat ke-9 (*Gain* 0,0502), probabilitas *Bullish* (*prob_bull*) di peringkat ke-11 (*Gain* 0,0485), dan probabilitas *Bearish* (*prob_bear*) di peringkat ke-15 (*Gain* 0,0463). Pada Solana, fitur *prob_bull* berada di peringkat ke-9 (*Gain* 0,0496), *prob_sideways* di peringkat ke-11 (*Gain* 0,0492), dan *prob_bear* di peringkat ke-19 (*Gain* 0,0450).
3. **Hasil Evaluasi Backtesting:** Sinyal keputusan pemodelan HMM-XGBoost dalam simulasi perdagangan mengurangi kerugian dibandingkan *Buy and Hold* saat pasar mengalami penurunan tajam (*fase Bearish*), meski ROI kedua skenario tetap negatif. Dibandingkan strategi pasif *Buy and Hold* yang mengalami kerugian berat dengan *Return on Investment* (ROI) sebesar -58,00% pada Solana dan -54,97% pada Ripple, pemodelan XGBoost

berhasil menekan kerugian secara drastis. Lebih lanjut, Skenario B (dengan HMM) menunjukkan hasil yang lebih baik daripada Skenario A (tanpa HMM). Pada aset Ripple, integrasi HMM memotong 114 transaksi palsu (turun dari 170 menjadi 56 transaksi), meningkatkan persentase kemenangan transaksi (*Win Rate*) dari 50,59% menjadi 57,14% (membaik +6,55%), meningkatkan ROI dari -13,18% menjadi -3,72% (membaik +9,46%), serta memangkas risiko *Maximum Drawdown* dari 13,41% menjadi 4,83% (membaik 8,58%). Pada aset Solana, integrasi HMM memotong 10 transaksi palsu (turun dari 58 menjadi 48 transaksi), meningkatkan *Win Rate* dari 48,28% menjadi 50,00% (membaik +1,72%), meningkatkan ROI dari -6,00% menjadi -4,62% (membaik +1,38%), serta memangkas risiko *Maximum Drawdown* dari 6,71% menjadi 6,10% (membaik 0,61%).

5.2 Saran

Berdasarkan keterbatasan yang ditemukan dalam penelitian ini, saran berikut dapat dipertimbangkan untuk penelitian selanjutnya.

1. Penelitian selanjutnya dapat menguji pada periode dan kondisi pasar yang lebih beragam, termasuk fase bullish, serta menambah aset lain. Data uji penelitian ini didominasi tren turun sehingga hasilnya belum tentu berlaku di kondisi pasar lain.
2. Peningkatan kinerja kedua model perlu dikaji dengan *walk-forward validation*, pengulangan eksperimen dengan beberapa random *seed*, dan uji signifikansi statistik. Selisih akurasi dan *F1-score* antarskenario masih kecil dan *F1-score* kedua model masih di bawah 0,45.
3. Pelabelan dan strategi eksekusi dapat dieksplorasi lebih lanjut, misalnya dengan variasi nilai k pada ATR, variasi ambang keyakinan, atau posisi short, agar hasil backtesting dapat melampaui ROI nol dan tidak hanya mengurangi kerugian.
4. Fitur tambahan seperti volume yang sudah difilter, sentimen, atau data *on-chain*, serta pembandingan dengan model lain seperti LightGBM atau LSTM, dapat dicoba untuk melihat apakah fitur rezim HMM tetap memberi kontribusi.