

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan mengenai penerapan metode *hybrid Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) dan *Long Short-Term Memory* (LSTM) untuk memprediksi jumlah penonton program televisi Stasiun Dangdut, dapat ditarik kesimpulan sebagai berikut:

1. Implementasi model *hybrid* GARCH-LSTM pada penelitian ini berhasil dilakukan secara sistematis melalui beberapa tahapan utama. Tahap awal melibatkan pemodelan komponen linier menggunakan ARIMA (dengan model terbaik MA(1)) untuk mengekstraksi residual. Pengujian pada residual tersebut membuktikan adanya efek heteroskedastisitas (efek ARCH), yang menjadi landasan kuat untuk memodelkan volatilitas. Pemodelan volatilitas kemudian dilakukan menggunakan GARCH(1,2) pada data *log return*. Selanjutnya, nilai volatilitas bersyarat dari GARCH digabungkan dengan data historis jumlah penonton sebagai masukan (*input*) untuk melatih arsitektur LSTM. Integrasi ini menunjukkan bahwa GARCH secara efektif menangkap dinamika volatilitas, sementara LSTM bertugas mempelajari pola non-linier pada data penonton.
2. Model *hybrid* GARCH-LSTM yang dikembangkan menunjukkan kinerja yang cukup baik dalam memprediksi jumlah penonton program televisi Stasiun Dangdut. Evaluasi pada data uji menghasilkan nilai *Root Mean Squared Error* (RMSE) sebesar 9583,49; *Mean Absolute Error* (MAE) sebesar 7093,46; dan *Mean Absolute Percentage Error* (MAPE) sebesar 0,2015 atau sekitar 20,15%. Nilai evaluasi ini menunjukkan bahwa secara rata-rata hasil prediksi model memiliki tingkat kesalahan sekitar 20% terhadap data aktualnya. Analisis visual pada kurva *training* dan *validation loss* juga mengindikasikan bahwa model tidak mengalami *overfitting* dan memiliki kemampuan generalisasi yang baik. Meskipun model sangat baik dalam menangkap tren pola pergerakan

penonton secara umum, model masih memiliki keterbatasan dalam mereplikasi lonjakan ekstrem harian yang dipengaruhi faktor eksternal.

3. Sistem antarmuka grafis (GUI) berbasis *web* menggunakan *framework* Streamlit telah berhasil dikembangkan dengan arsitektur alur analisis yang terstruktur dan interaktif. Sistem ini mengintegrasikan seluruh tahapan pemodelan, mulai dari Uji Stasioneritas, transformasi Log Return, Pemodelan ARIMA, Uji Efek ARCH, Pemodelan GARCH, hingga Pemodelan LSTM dan Hasil Forecast, ke dalam antarmuka berbasis halaman (*multi-page*) yang terhubung melalui tombol navigasi direktif. Setiap halaman dilengkapi dengan kotak informasi konseptual, elemen kontrol interaktif (seperti *slider*, *dropdown*, dan *number input*) untuk konfigurasi parameter secara fleksibel, serta komponen visualisasi grafik interaktif dan kotak interpretasi naratif otomatis yang menyajikan hasil komputasi secara langsung tanpa perlu memuat ulang halaman. Pada tahap akhir, sistem menyediakan fitur *forecast* ke depan dengan horizon waktu yang dapat ditentukan pengguna, dilengkapi tabel hasil prediksi harian dan kartu ringkasan metrik. Dengan demikian, sistem ini tidak hanya mewujudkan model komputasi yang kompleks menjadi aplikasi yang intuitif, tetapi juga memfasilitasi eksplorasi analitis yang transparan dan mudah dipahami oleh pengguna non-teknis di pihak stasiun televisi.

5.2. Saran Pengembangan

Pada pengembangan penelitian selanjutnya, beberapa saran yang dapat dipertimbangkan adalah sebagai berikut:

1. Menambahkan variabel eksternal (eksogen) ke dalam pemodelan, seperti *dummy* hari libur, akhir pekan (*weekend*), momentum acara spesial, atau kehadiran bintang tamu populer. Penambahan variabel ini diharapkan dapat membantu model dalam mempelajari dan menangkap pola lonjakan penonton yang ekstrem dan bersifat mendadak.
2. Mengembangkan metode *hyperparameter tuning* yang lebih sistematis pada arsitektur LSTM, misalnya menggunakan *Grid Search*, *Random Search*, atau

Bayesian Optimization. Pendekatan ini bertujuan untuk menemukan kombinasi parameter yang lebih optimal (seperti *learning rate*, *batch size*, jumlah *hidden layer*, dan *dropout rate*) guna meminimalkan tingkat kesalahan (RMSE, MAE, dan MAPE).

3. Mengeksplorasi dan membandingkan pendekatan *hybrid* ini dengan arsitektur *Deep Learning* berbasis deret waktu lainnya, seperti GRU (*Gated Recurrent Unit*) atau model berbasis *Transformer*. Hal ini dapat memberikan wawasan mengenai model mana yang memiliki performa paling sensitif dan akurat terhadap perubahan volatilitas data penyiaran.