

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian yang Relevan

Forecasting inflow yang akurat merupakan aspek krusial dalam menunjang optimalisasi operasi Pembangkit Listrik Tenaga Air (PLTA), menjaga keandalan sistem energi, serta merancang perencanaan pembangkitan listrik yang lebih efektif dan efisien. Tantangan utama dalam forecasting inflow terletak pada karakteristik data hidrologi yang bersifat nonlinier dan nonstasioner, sehingga model statistik konvensional seperti ARIMA, SVM, dan ANFIS sering kali tidak mampu memberikan hasil prediksi yang andal. Untuk menjawab tantangan tersebut, berbagai penelitian terkini telah mengembangkan pendekatan berbasis machine learning dan deep learning, khususnya model Long Short-Term Memory (LSTM), yang terbukti mampu memodelkan ketergantungan temporal secara dinamis [11], [12].

Salah satu pendekatan yang paling banyak digunakan adalah Long Short-Term Memory (LSTM), yang terbukti unggul dalam memodelkan data deret waktu nonlinier dan menangkap dependensi jangka panjang pada sistem hidrologi. Kratzert et al. menunjukkan bahwa LSTM mampu mempelajari perilaku hidrologi regional dan lokal secara lebih akurat dibandingkan metode statistik konvensional, sehingga banyak digunakan untuk prediksi debit sungai dan inflow waduk. Temuan ini diperkuat oleh Feng et al. yang membuktikan bahwa LSTM memiliki performa prediksi inflow yang lebih stabil pada kondisi hidrologi yang fluktuatif.

Penelitian selanjutnya mulai mengembangkan prediksi inflow pada berbagai skala waktu untuk mendukung operasi waduk. Li et al. mengusulkan model LSTM multi-timescale yang mampu memprediksi inflow harian hingga musiman, yang dinilai sangat relevan untuk perencanaan operasi PLTA berbasis waduk tahunan. Wang et al. memperluas pendekatan ini dengan mengintegrasikan prediksi inflow berbasis *deep learning* ke dalam pengambilan keputusan operasi pembangkit listrik tenaga air di bawah pengaruh variabilitas iklim, menunjukkan bahwa penggunaan prediksi inflow yang akurat dapat meningkatkan keandalan produksi dan mengurangi risiko defisit energi pada periode kering. Penelitian terbaru oleh Zhang et al. juga membandingkan LSTM dengan

model *transformer*, dan menyimpulkan bahwa LSTM masih memiliki keunggulan dalam kestabilan prediksi inflow pada data hidrologi dengan panjang historis terbatas.

Pendekatan Bi-LSTM yang menggabungkan teknik dekomposisi data, ensemble learning, serta integrasi dengan model fisik telah menunjukkan peningkatan akurasi forecasting yang signifikan. Sebagai contoh, model VMD-BiLSTM yang memanfaatkan Variational Mode Decomposition dan arsitektur Bi-LSTM terbukti menghasilkan performa yang tinggi dalam peramalan inflow harian [13]. Di sisi lain, integrasi model WRF-Hydro dengan LSTM sebagai post-processing berhasil meningkatkan hasil simulasi aliran sungai [12]. Model DEL-LSTM yang dikembangkan oleh Qi et al, juga memperlihatkan efektivitas pendekatan ensemble dalam meningkatkan akurasi prediksi inflow. Umumnya, model-model tersebut mencapai performa tinggi dengan nilai Nash-Sutcliffe Efficiency (NSE) di atas 0,95 dan Mean Absolute Percentage Error (MAPE) di bawah 15%.

Selain itu, arsitektur deep learning hybrid seperti CNN-LSTM telah menunjukkan kemampuan yang unggul dalam menangkap keterkaitan spasial dan temporal secara simultan, yang sulit dicapai oleh model konvensional [14]. Studi komparatif yang dilakukan oleh Skariah dan Suriyakala juga mengonfirmasi bahwa model forecasting tunggal memiliki keterbatasan dalam hal akurasi, sementara pendekatan hybrid dan LSTM memberikan peningkatan performa yang signifikan [15].

Zhang et al. secara khusus menyoroti pentingnya integrasi prediksi inflow dan optimasi operasi PLTA dalam menghadapi kondisi iklim ekstrem seperti kekeringan, di mana pendekatan terintegrasi tersebut terbukti lebih adaptif dibandingkan strategi operasi konvensional yang bersifat reaktif. Dalam konteks Indonesia, Suwignyo et al. menekankan bahwa koordinasi hidro-termal yang optimal sangat berpengaruh terhadap Biaya Pokok Penyediaan (BPP), khususnya pada sistem kelistrikan dengan penetrasi PLTA yang besar.

Selain itu, keterkaitan langsung antara hasil optimasi operasi PLTA dengan indikator ekonomi sistem seperti BPP dan *fuel-mix* masih relatif terbatas, terutama pada studi kasus sistem kelistrikan Indonesia bagian timur. Penelitian terkait implementasi sistem pendukung keputusan berbasis dashboard juga masih jarang mengintegrasikan prediksi hidrologi, optimasi operasi, dan evaluasi dampak sistem secara *real-time* dalam satu kerangka terpadu [16], [17]. Adapun penelitian tersebut adalah sebagai berikut:

Tabel 2. 1 Penelitian sebelumnya yang relevan

No.	Penulis	Penelitian	Gap/Kesenjangan
1	[11]	Judul: <i>A Decomposition-Ensemble Learning Model Based on LSTM Neural Network for Daily Reservoir Inflow Forecasting.</i> Kasus: Prediksi inflow harian waduk. Metode: Decomposition–Ensemble berbasis LSTM (dekomposisi sinyal + LSTM ensemble). Hasil: Pendekatan ensemble LSTM meningkatkan akurasi dan stabilitas prediksi inflow dibandingkan LSTM tunggal	Meningkatkan akurasi prediksi inflow harian dengan ensemble LSTM, namun belum mengintegrasikan hasil prediksi ke dalam optimasi operasi PLTA dan evaluasi dampak ekonomi sistem.
2	[12]	Judul: <i>Improving Streamflow Prediction in the WRF-Hydro Model with LSTM-Based Post-Processing.</i> Kasus: Prediksi debit sungai berbasis model hidrologi fisik (WRF-Hydro). Metode: LSTM sebagai <i>post-processing</i> hasil WRF-Hydro. Hasil: Integrasi LSTM secara signifikan mengurangi error prediksi dan meningkatkan kinerja model fisik.	Menggunakan LSTM sebagai post-processing model hidrologi fisik, tetapi belum mengaitkan hasil prediksi dengan strategi pembangkitan atau pengaruhnya terhadap biaya sistem tenaga.
3	[18]	Judul: <i>Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets.</i> Kasus: Prediksi debit sungai (streamflow) pada ribuan DAS di berbagai wilayah dengan karakteristik hidrologi berbeda. Metode: Long Short-Term Memory (LSTM) berbasis <i>large-sample hydrology</i>. Hasil: Model LSTM mampu menangkap pola hidrologi kompleks secara konsisten dan mengungguli model hidrologi konvensional, terutama pada kondisi nonlinier dan variabilitas iklim tinggi.	Menunjukkan kemampuan LSTM dalam menangkap perilaku hidrologi kompleks, namun belum menghubungkan prediksi debit dengan optimasi produksi energi PLTA.

4	[5]	Judul: <i>Multi-timescale reservoir inflow forecasting using LSTM networks.</i> Kasus: Prediksi inflow waduk pada skala harian, bulanan, dan musiman. Metode: LSTM multi-horizon (multi-timescale forecasting). Hasil: Model LSTM efektif untuk prediksi inflow jangka pendek hingga menengah dan mendukung perencanaan operasi waduk tahunan	Studi multi-timescale forecasting ini mendukung perencanaan waduk, tetapi belum mengevaluasi dampak hasil prediksi terhadap penurunan biaya pembangkitan atau fuel-mix sistem.
5	[7]	Judul: <i>Deep learning-based inflow forecasting for hydropower reservoir operation under climate variability.</i> Kasus: Operasi PLTA di bawah pengaruh variabilitas iklim. Metode: Deep learning (LSTM) terintegrasi dengan skema operasi PLTA. Hasil: Prediksi inflow berbasis LSTM meningkatkan keandalan operasi PLTA dan mengurangi risiko defisit energi pada periode kering	Mengintegrasikan deep learning dengan operasi PLTA, namun evaluasinya lebih berfokus pada keandalan energi dibandingkan analisis ekonomi sistem seperti BPP.
6	[19]	Judul: <i>Comparative study of LSTM and transformer models for hydrological inflow forecasting.</i> Kasus: Prediksi inflow hidrologi pada data deret waktu. Metode: Perbandingan LSTM dan Transformer. Hasil: LSTM menunjukkan kestabilan dan akurasi yang lebih baik pada data historis terbatas, sedangkan Transformer unggul pada data besar	Komparatif LSTM dan Transformer menilai performa model prediksi, tetapi tidak mengaitkannya dengan pengambilan keputusan operasional pembangkit.
7	[13]	Judul: <i>An Ensemble Modeling Approach to Forecast Daily Reservoir Inflow Using Bi-LSTM, VMD, and Energy Entropy Method.</i> Kasus: Prediksi inflow harian waduk. Metode: Ensemble Bi-LSTM + Variational Mode Decomposition (VMD) + Energy Entropy.	Pendekatan ensemble Bi-LSTM meningkatkan akurasi inflow, namun belum mengintegrasikan hasilnya dalam skema optimasi pembangkitan berbasis batasan elevasi waduk.

		Hasil: Model ensemble menghasilkan akurasi prediksi inflow yang lebih tinggi dibandingkan metode tunggal	
8	[14]	Judul: <i>A Hybrid CNN-LSTM Approach for Monthly Reservoir Inflow Forecasting.</i> Kasus: Prediksi inflow waduk bulanan. Metode: Hybrid Convolutional Neural Network (CNN) dan LSTM. Hasil: Model CNN-LSTM lebih efektif dalam menangkap fitur spasial dan temporal dibandingkan LSTM konvensional	Model hybrid CNN-LSTM efektif untuk prediksi bulanan, tetapi belum diterapkan dalam konteks sistem tenaga nyata atau evaluasi dampak biaya sistem.
9	[15]	Judul: <i>Forecasting Reservoir Inflow Combining Exponential Smoothing, ARIMA, and LSTM Models.</i> Kasus: Prediksi inflow waduk berbasis data historis. Metode: Model hybrid Exponential Smoothing, ARIMA, dan LSTM. Hasil: Pendekatan hybrid meningkatkan akurasi prediksi dibandingkan metode statistik atau LSTM tunggal	Pendekatan hybrid statistik dan LSTM meningkatkan performa prediksi, namun tidak dikembangkan hingga tahap implementasi operasional PLTA.
10	[20]	Judul: <i>Integrated inflow forecasting and hydropower operation optimization under climate extremes.</i> Kasus: Operasi PLTA saat kondisi iklim ekstrem (kekeringan). Metode: Integrasi prediksi inflow dan optimasi operasi waduk. Hasil: Pendekatan terintegrasi lebih adaptif dan efisien dibandingkan operasi konvensional dalam menghadapi kondisi ekstrem	Mengintegrasikan forecasting dan optimasi di bawah kondisi ekstrem, tetapi belum mengevaluasi dampaknya terhadap parameter ekonomi sistem tenaga regional.
11	[10]	Judul: <i>Optimization of hydro-thermal coordination in Indonesian power systems.</i> Kasus: Sistem kelistrikan Indonesia dengan koordinasi PLTA dan PLTU. Metode: Optimasi koordinasi hidro-termal.	Optimasi koordinasi hidro-termal berhasil menurunkan BPP, namun belum memanfaatkan inflow forecasting berbasis AI sebagai input dinamis dalam perencanaan operasi.

		Hasil: Optimasi operasi PLTA secara signifikan menurunkan biaya operasi sistem dan Biaya Pokok Penyediaan (BPP)	
12	[16]	Judul: <i>Decision support systems for hydropower operation: A review.</i> Kasus: Studi literatur sistem pendukung keputusan operasi PLTA. Metode: Review sistematis DSS, optimasi, dan pemodelan. Hasil: DSS terbukti meningkatkan kualitas pengambilan keputusan operasi PLTA, namun integrasi dengan prediksi berbasis AI masih terbatas	Menekankan pentingnya DSS dalam operasi PLTA, tetapi belum menunjukkan implementasi terintegrasi dengan model prediksi berbasis deep learning.
13	[17]	Judul: <i>Real-time dashboard for energy system operation using machine learning.</i> Kasus: Monitoring dan pengambilan keputusan operasi sistem energi. Metode: Machine learning terintegrasi dashboard web <i>real-time</i> . Hasil: Dashboard interaktif meningkatkan respon operator dan efektivitas perencanaan operasi berbasis data	Dashboard berbasis machine learning meningkatkan pengambilan keputusan operasional, namun belum mengintegrasikan forecasting hidrologi dan optimasi pembangkitan dalam satu kerangka end-to-end.
14	[21]	Judul: A review of deep learning and machine learning techniques for hydrological inflow forecasting Kasus: tinjauan penerapan teknik AI untuk memprediksi inflow hidrologi seperti aliran reservoir. Metode: membandingkan model deep learning (mis. LSTM) dan machine learning tradisional (SVM, Random Forest, Boosted Regression Tree) Hasil: review menunjukkan bahwa AI, terutama deep learning, menjanjikan peningkatan akurasi prediksi inflow serta memberikan wawasan kelebihan/kelemahan tiap teknik.	Meningkatkan akurasi prediksi inflow namun masih ada kesenjangan seperti terbatasnya dataset berkualitas tinggi, variasi geografis yang kurang teruji, dan kebutuhan model yang lebih general serta sistem prediksi nyata yang lebih robust untuk berbagai kondisi hidrologi.

Pemetaan penelitian sebelumnya dilakukan dengan menelaah berbagai jurnal dan merangkum temuan-temuannya berdasarkan beberapa kategori, seperti model yang digunakan, jenis dan karakteristik data beserta sumbernya, serta metode penelitian dan skenario yang diterapkan. Identifikasi ini bertujuan untuk memperjelas posisi dan kontribusi studi yang dilakukan. Meskipun berbagai penelitian telah berhasil meningkatkan akurasi prediksi inflow menggunakan LSTM maupun pendekatan hybrid, sebagian besar studi masih terbatas pada aspek pengembangan model prediksi dan belum mengintegrasikannya secara komprehensif ke dalam optimasi operasi pembangkitan serta evaluasi dampak ekonomi terhadap kinerja sistem tenaga secara menyeluruh.

Penelitian terkait optimasi hidro-termal di Indonesia juga umumnya belum memanfaatkan forecasting berbasis deep learning sebagai variabel adaptif dalam perencanaan operasi. Selain itu, belum terdapat studi yang secara spesifik mengkaji PLTA Poso dengan analisis kuantitatif terhadap penurunan Biaya Pokok Penyediaan (BPP) dan perbaikan fuel-mix pada sistem kelistrikan Sulawesi Bagian Selatan (Sulbagsel).

Berdasarkan tinjauan tersebut, penelitian ini menempati posisi *state of the art* dengan mengintegrasikan prediksi inflow Danau Poso berbasis LSTM untuk berbagai horizon waktu (jangka pendek hingga jangka panjang), optimasi pola operasi PLTA Poso, serta analisis dampaknya terhadap BPP dan komposisi fuel-mix sistem Sulawesi Bagian Selatan. Selain itu, penelitian ini dilengkapi dengan pengembangan dashboard web interaktif sebagai sistem pendukung keputusan operasional, sehingga menjembatani kesenjangan antara pengembangan metode akademik dan kebutuhan praktis perencanaan operasi sistem tenaga listrik. Pendekatan terintegrasi end-to-end ini memberikan kontribusi ilmiah sekaligus praktis dalam meningkatkan efisiensi biaya, keandalan operasi, dan pemanfaatan energi terbarukan pada sistem kelistrikan regional.


2.2 Landasan Teori

2.2.1 Bi-LSTM Seq2Seq Quantile Regression Model

LSTM (*Long Short-Term Memory*), yang merupakan varian dari *Recurrent Neural Network* (RNN), mengatasi masalah *vanishing gradient* dengan memanfaatkan *memory cells* dan *gated mechanisms* untuk mempertahankan ketergantungan jangka panjang. Gerbang-gerbang ini yaitu *forget gate*, *input gate*, dan *output gate* yang mengatur aliran informasi dengan menggunakan fungsi aktivasi sigmoid, yang memungkinkan seleksi

data yang relevan untuk disimpan dan mempercepat proses *backpropagation* [22]. BiLSTM seperti yang ditunjukkan pada Gambar 2.1 mampu meningkatkan model LSTM standar dengan menggabungkan dua jaringan LSTM independen, yaitu *forward* dan *backward*. Kedua lapisan ini digabungkan dan diteruskan ke lapisan berikutnya, memungkinkan BiLSTM untuk menangkap informasi baik dari masa lalu maupun masa depan pada setiap langkah waktu.

Model Quantile BiLSTM mengembangkan Bidirectional LSTM (BiLSTM) untuk probabilistic forecasting dengan memprediksi beberapa kuantil, bukan hanya satu estimasi titik. Pendekatan ini mengestimasi hubungan kuantil kondisional antara variabel, yang menangkap ketidakpastian dalam prediksi. Dalam penelitian ini, kami menggunakan tiga kuantil, yaitu 10%, 50%, dan 90%, yang masing-masing mewakili kondisi kering, normal, dan basah [22], [23].



Gambar 2. 1 Arsitektur LSTM [21]

2.2.2 Perhitungan Elevasi PLTA Poso

Berikut adalah proses dan persamaan perhitungan level elevasi danau Poso:

$$Q_{out} = P \times 27.03$$

Di mana P adalah produksi daya (MW), Q_{out} adalah aliran keluar ($m^3 s$) dan 27.03 adalah faktor konversi.

$$V_{initial} = \frac{E_{prev} - 509.0212}{2.7747 \times 10^{-9}}$$

Di mana $V_{initial}$ adalah volume danau awal (m^3), E_{prev} adalah elevasi danau sebelumnya (m), 509.0212 dan 2.7747×10^{-9} adalah konstanta kalibrasi.

$$V_{final} = (Q_{in} \times 86400) - (Q_{out} \times 86400) + V_{init}$$

Di mana Q_{in} prediksi aliran masuk ($m^3 s$) 86400 adalah jumlah detik dalam satu hari untuk mengkonversi dari m^3/dtk ke volume harian, V_{final} adalah volume danau yang telah diperbaharui (m^3).

$$E_{new} = (2.7747 \times 10^{-9} \times V_{final}) + 509.0212$$

Di mana E_{new} adalah elevasi danau yang diperbarui (m).