

Hybrid Decomposition ICEEMDAN-EWT Deep Learning Framework for Wind Speed Forecasting

Dedi Arman Alif Hidayat ^{1*}, Muhamad Hilmi Muchtar Aditya Pradana ^{2*}, Ahmad Saikhu ^{3*}

^{*} Department of Informatics, Institut Teknologi Sepuluh Nopember (ITS), Surabaya
6025232004@student.its.ac.id¹, hilmi@its.ac.id², saikhu@its.ac.id³

Article Info

Article history:

Received 2025-07-15

Revised 2025-07-28

Accepted 2025-07-30

Keyword:

ICEEMDAN,
IMF,
EWT,
BiLSTM,
Wind Speed Prediction.

ABSTRACT

Accurate wind speed forecasting plays a crucial role in supporting early warning systems for extreme wind events. However, the inherent non-linearity and non-stationarity of wind speed data pose significant challenges. This study addresses these issues by evaluating the effectiveness of targeted Empirical Wavelet Transform (EWT) denoising applied to specific Intrinsic Mode Functions (IMFs) derived from Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (ICEEMDAN). Daily wind speed data from 2000 to 2023 were decomposed using ICEEMDAN, and denoising was selectively applied to IMF1, IMF2, and IMF3. Each IMF was then modeled using a Bidirectional Long Short-Term Memory (BiLSTM) network under a time-series cross-validation framework. Among all model configurations, the ICEEMDAN+EWT(IMF1 & IMF2)+BiLSTM model achieved the highest predictive accuracy, with an R^2 of 0.8885, RMSE of 0.501, and MAPE of 7.64%. This result outperformed both the baseline BiLSTM model ($R^2 = 0.0501$) and the ICEEMDAN+BiLSTM model without EWT denoising ($R^2 = 0.6433$). Moreover, denoising on IMF1 alone also yielded a strong performance ($R^2 = 0.8879$), emphasizing the importance of early component selection. Conversely, applying EWT to IMF2 or IMF3 individually resulted in lower R^2 values of 0.6639 and 0.6327, respectively, indicating limited individual contribution. These findings confirm that selective denoising, especially on the high-frequency IMFs, substantially enhances forecasting accuracy. The proposed approach holds significant potential to improve the timeliness and reliability of wind-related early warning systems, thus contributing to more effective disaster risk reduction strategies.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Peringatan dini angin kencang memiliki peranan vital dalam upaya melindungi keselamatan masyarakat, meminimalkan risiko kerusakan infrastruktur, dan mengurangi potensi dampak bencana akibat cuaca ekstrem.[1]. Informasi prediksi kecepatan angin yang akurat sangat dibutuhkan untuk mendukung sistem peringatan tersebut, sehingga masyarakat dan pemangku kepentingan dapat mengambil langkah antisipasi secara tepat waktu. Namun, prediksi kecepatan angin masih menghadapi tantangan besar karena dipengaruhi oleh dinamika atmosfer yang acak, memiliki pola yang berubah-ubah, dan sangat

fluktuatif, sehingga diperlukan pendekatan khusus agar hasil prediksi dapat diandalkan[2].

Memprediksi kecepatan angin merupakan tantangan kompleks karena sifatnya yang non-linear dan dipengaruhi oleh berbagai variabel seperti temperatur, tekanan udara, kelembapan, dan kondisi geografis [3]. Berbagai pendekatan telah diterapkan, termasuk sistem *Numerical Weather Prediction* (NWP) dan metode statistik, yang berupaya memperkirakan perilaku angin dalam berbagai rentang waktu. Namun, banyak model yang ada cenderung memerlukan sumber daya komputasi yang besar, lebih cocok untuk proyeksi jangka menengah hingga panjang, dan kurang optimal untuk prediksi jangka pendek atau real-time [4].

Model-model seperti *Autoregressive Integrated Moving Average* (ARIMA) dan *Autoregressive Moving Average* (ARMA) menawarkan solusi yang lebih sederhana, namun sering kali tidak dapat menangani data yang kompleks dan tidak stabil, sehingga akurasinya terbatas dalam situasi non-linear [5]. Keterbatasan ini mendorong penelitian untuk beralih ke teknik *Machine Learning*, yang memiliki kemampuan lebih baik dalam mengenali pola non-linear dalam data kecepatan angin.

Namun, penerapan teknik *machine learning* tidak terlepas dari tantangan. Salah satu tantangan utamanya adalah bagaimana menangani data kecepatan angin yang memiliki pola tidak tetap dan berubah-ubah seiring waktu dan dipengaruhi oleh noise yang signifikan [6]. Hal ini membuat proses ekstraksi fitur menjadi krusial, karena tanpa representasi data yang baik, performa model prediksi dapat menurun.

Untuk menjawab tantangan tersebut, berbagai metode dekomposisi sinyal telah dikembangkan. Salah satu pendekatan awal yang digunakan adalah *Wavelet Decomposition* (WD), yang memungkinkan analisis sinyal dalam domain waktu-frekuensi. Meskipun demikian, metode ini memerlukan pemilihan jenis wavelet sebagai fungsi dasar, yang bersifat subjektif dan sangat memengaruhi hasil analisis karena proses dekomposisi bergantung pada basis fungsi yang telah ditentukan sebelumnya [7]. Sebagai alternatif, *Empirical Mode Decomposition* (EMD) menawarkan pendekatan yang lebih adaptif tanpa memerlukan fungsi dasar tertentu. Namun, metode ini memiliki kelemahan utama berupa mode aliasing, yaitu pencampuran skala waktu yang berbeda dalam satu komponen [8].

Untuk mengatasi masalah tersebut, *Ensemble Empirical Mode Decomposition* (EEMD) dikembangkan dengan menambahkan noise putih adaptif guna mengurangi mode aliasing, meskipun metode ini masih menyisakan tantangan berupa residu noise yang sulit dihilangkan [9]. *Variational Mode Decomposition* (VMD) lebih lanjut mengatasi mode aliasing dan menghasilkan residu noise yang lebih rendah, tetapi membutuhkan penentuan jumlah mode secara manual, yang dapat menjadi tantangan dalam pengolahan data skala besar [10].

Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) dengan penambahan noise adaptif menghasilkan mode lebih stabil dan error rekonstruksi lebih kecil dibandingkan dengan EMD dan EEMD [11], meskipun masih menghadapi *pseudo-modes* dan residu noise pada mode awal [12]. Untuk menyempurnakan metode ini, *Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise* (ICEEMDAN) dikembangkan sebagai solusi paling canggih. ICEEMDAN tidak hanya mengatasi *pseudo-modes* dan residu noise, tetapi juga mampu secara otomatis menentukan jumlah mode dekomposisi, sehingga lebih stabil, efisien, dan cocok untuk data kompleks seperti kecepatan angin [13].

Selain menggunakan ICEEMDAN, integrasi dengan metode dekomposisi lain seperti *Empirical Wavelet*

Transform (EWT) terbukti mampu meningkatkan akurasi dalam prediksi kecepatan angin [14]. EWT merupakan teknik dekomposisi adaptif yang secara dinamis mendefinisikan batasan spektral berdasarkan karakteristik spektrum Fourier sinyal, sehingga dapat memisahkan sinyal menjadi beberapa komponen berbasis frekuensi tanpa tumpang tindih. Keunggulan utama dari EWT adalah kemampuannya dalam menangkap informasi lokal pada sinyal, terutama ketika sinyal tersebut mengandung variasi frekuensi tinggi dan rendah secara bersamaan [15].

Pada penelitian sebelumnya, Karijadi *et al* [14] menggunakan pendekatan *hybrid* CEEMDAN-EWT untuk prediksi kecepatan angin yang menunjukkan bahwa kombinasi CEEMDAN dan EWT secara signifikan meningkatkan akurasi peramalan dibandingkan dengan penggunaan CEEMDAN atau EWT secara terpisah. Namun, CEEMDAN memiliki kelemahan, yaitu *mode mixing*, suatu kondisi di mana satu komponen hasil dekomposisi sinyal (IMF) mengandung campuran osilasi dari skala waktu atau frekuensi yang sangat berbeda yang dapat mempengaruhi efisiensi dekomposisi pada data yang tidak stasioner, sehingga Untuk mengatasi kelemahan ini, kami mengadopsi ICEEMDAN, penyempurnaan lanjutan dari CEEMDAN, yang dirancang sebagai solusi terhadap masalah tersebut.

Kombinasi ICEEMDAN dan EWT dipilih dalam penelitian ini karena kemampuan komplementer keduanya dalam menangani sifat non-linear, non-stasioner, dan penuh noise dari data kecepatan angin, yang tidak dapat diatasi secara optimal oleh masing-masing metode secara terpisah. ICEEMDAN menguraikan sinyal kompleks menjadi Intrinsic Mode Functions (IMFs) dengan karakteristik frekuensi berbeda, mengisolasi noise frekuensi tinggi pada IMF [13]. Namun, IMF awal masih mengandung noise signifikan akibat fluktuasi jangka pendek, yang dapat menurunkan akurasi prediksi jika tidak disaring. EWT mengatasi kelemahan ini dengan menerapkan denoising adaptif berbasis wavelet, yang secara presisi menghilangkan sub-band frekuensi tertinggi yang diasumsikan sebagai noise, sambil mempertahankan informasi sinyal yang relevan [14].

Setelah melalui tahap dekomposisi sinyal menggunakan ICEEMDAN dan EWT untuk meningkatkan kualitas representasi data, langkah berikutnya adalah memilih model prediksi yang mampu memanfaatkan informasi temporal secara optimal. Pada penelitian ini, *Bidirectional Long Short-Term Memory* (Bi-LSTM) menjadi pilihan tepat karena kemampuannya dalam memproses ketergantungan jangka panjang dari dua arah dalam data deret waktu [16]. Model Bi-LSTM menggunakan mekanisme “forward” dan “backward” LSTM secara paralel, memungkinkan penangkapan pola dari masa lalu hingga masa kini serta dari masa depan ke masa sekarang secara simultan yang secara signifikan meningkatkan performa prediksi dibandingkan LSTM konvensional [17].

Dengan memanfaatkan hasil dekomposisi sinyal dari ICEEMDAN dan EWT, model Bi-LSTM memiliki kemampuan untuk lebih terfokus pada pola-pola penting dari

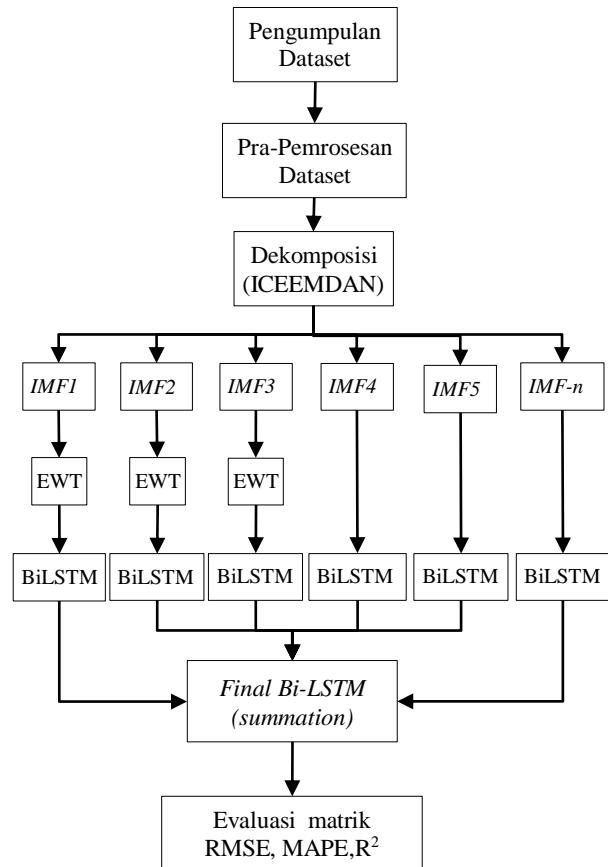
masing-masing komponen sinyal yang telah terpisah secara jelas. Pemisahan ini membuka peluang bagi model untuk mengenali pola musiman, fluktuasi jangka pendek, serta variasi frekuensi tinggi dan rendah yang sebelumnya tersamar dalam data mentah. Evaluasi kinerja dalam penelitian ini mempertimbangkan akurasi prediksi. Untuk mengukur akurasi, digunakan tiga metrik utama yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2), yang menilai kesalahan prediksi serta kemampuan model dalam menangkap pola data.

Pendekatan ini tidak hanya bertujuan untuk meningkatkan kualitas prakiraan secara ilmiah, tetapi juga untuk memberikan kontribusi nyata dalam konteks kebencanaan. Hasil prediksi yang lebih presisi diharapkan dapat memperkuat sistem peringatan dini angin kencang, sehingga masyarakat dan pemangku kepentingan dapat mengambil tindakan lebih cepat dan tepat dalam mengurangi risiko kerusakan, meningkatkan kesiapsiagaan, serta mendukung upaya mitigasi bencana secara lebih efektif di berbagai wilayah rawan di Indonesia.

II. METODE

Penelitian ini mengusulkan sebuah kerangka kerja prediksi hybrid yang secara sistematis mengintegrasikan dekomposisi sinyal, *denoising* selektif, dan pemodelan *deep learning*. Sebagaimana diilustrasikan pada Gambar 1, metodologi penelitian diawali dengan pengumpulan dan pra-pemrosesan dataset kecepatan angin harian, yang mencakup penanganan nilai hilang dan normalisasi data. Selanjutnya, sinyal yang telah bersih didekomposisi menggunakan ICEEMDAN untuk mengurainya menjadi beberapa komponen frekuensi yang disebut *Intrinsic Mode Functions* (IMFs).

Untuk mengatasi noise yang umumnya terkonsentrasi pada komponen berfrekuensi tinggi, proses *denoising* menggunakan EWT diterapkan secara selektif hanya pada tiga IMF pertama yaitu IMF1, IMF2, dan IMF3 serta kombinasi dari ketiga IMF tersebut (IMF1-IMF2, IMF1-IMF3, IMF2-IMF3 dan IMF1-IMF2-IMF3) untuk mendapatkan hasil prediksi yang terbaik. Sementara itu, komponen IMF lainnya (IMF4 hingga IMF-n) yang cenderung lebih stabil digunakan secara langsung tanpa *denoising*. Setiap komponen, baik yang telah di-*denoise* maupun yang tidak, diprediksi secara independen menggunakan model BiLSTM yang terpisah, namun dengan *hyperparameter* yang sama. Tahap akhir adalah agregasi melalui penjumlahan (summation), di mana hasil prediksi dari seluruh model BiLSTM individual digabungkan untuk membentuk prediksi kecepatan angin final. Kinerja model akhir kemudian dievaluasi menggunakan metrik RMSE, MAPE, dan R^2 , yang divalidasi dengan skema *K-fold Time Series Cross-Validation* untuk memastikan kemampuan generalisasi model.



Gambar 1. Diagram Pemodelan Penelitian

A. Pengumpulan Dataset

Data kecepatan angin yang digunakan pada penelitian ini diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Indonesia, tepatnya diambil dari Stasiun Meteorologi Stasiun Meteorologi Soekarno Hatta, Tangerang, Banten dengan elevasi stasiun sebesar 11 meter selama periode 24 tahun, mulai dari tahun 2000 hingga 2023 dengan resolusi temporal harian, di mana setiap baris data merepresentasikan pengukuran maksimum kecepatan angin per hari dengan pendekatan metode *univariate forecasting*.

Pemilihan pendekatan *univariate forecasting* dalam penelitian ini didasarkan pada fakta bahwa data kecepatan angin harian menunjukkan korelasi temporal yang kuat (seperti tren musiman atau siklus harian), sehingga sangat cocok untuk peramalan jangka pendek. Studi terbaru menunjukkan bahwa model *univariate* dapat menangkap informasi temporal ini secara efektif tanpa perlu memanfaatkan variabel tambahan. Selain itu, pendekatan *univariate* juga terbukti lebih efisien dalam proses dekomposisi dan pemodelan terutama ketika data harian hanya memiliki sedikit sampel karena tidak memerlukan normalisasi atau transformasi tambahan yang sering muncul dalam model *multivariate* [14]. Pendekatan *multivariate*, meskipun potensial menawarkan akurasi lebih tinggi, seringkali membawa beban komputasi besar serta risiko

rendahnya korelasi antar variabel yang tidak selalu menjamin peningkatan performa.

B. Pra Pemrosesan Dataset

Tahap ini merupakan tahap fundamental dalam analisis data yang bertujuan untuk membersihkan dan mentransformasi data mentah menjadi format yang siap untuk dianalisis. Proses ini sangat penting untuk meningkatkan kualitas dan akurasi model yang akan dikembangkan dengan cara menghilangkan *noise* dan mengatasi inkonsistensi data. Pada penelitian ini, langkah awal Pra Pemrosesan data dimulai dengan memuat dataset dari *file CSV*. Setelah itu, dilakukan penanganan terhadap nilai yang hilang (*missing values*) yang teridentifikasi sebagai *NaN* pada data sinyal. Masalah ini diatasi dengan menggunakan metode imputasi rata-rata, di mana setiap nilai yang hilang digantikan dengan nilai rata-rata dari keseluruhan kolom sinyal, sehingga memastikan kelengkapan dan konsistensi data sebelum diproses lebih lanjut.

C. Data Dekomposisi ICEEMDAN

ICEEMDAN merupakan pengembangan dari metode EMD yang dirancang untuk mengatasi kelemahan utama pada EMD dan EEMD, yaitu efek mode mixing dan kestabilan residual sinyal. Dalam konteks penelitian ini, ICEEMDAN digunakan sebagai tahap awal dekomposisi sinyal kecepatan angin untuk memisahkan komponen-komponen sinyal berdasarkan karakteristik frekuensinya.

ICEEMDAN digunakan untuk mengurai sinyal asli yang kompleks menjadi komponen-komponen yang lebih sederhana dan lebih mudah diinterpretasikan, yang disebut *Intrinsic Mode Functions* (IMF). Data kecepatan angin yang telah dibersihkan kemudian didekomposisi menggunakan metode ICEEMDAN untuk menghasilkan sejumlah komponen IMF(s) dan satu komponen residu. Setiap IMF mewakili osilasi atau komponen frekuensi yang berbeda dalam data, mulai dari frekuensi tertinggi (pada IMF pertama) hingga frekuensi terendah. Proses dekomposisi ini penting karena mengubah masalah *univariate forecast* yang kompleks menjadi beberapa masalah *forecast* yang lebih sederhana dan lebih mudah dikelola.

Secara umum, algoritma ICEEMDAN bekerja dengan menambahkan *white noise* secara adaptif ke sinyal asli, yang kemudian diolah melalui proses ensemble untuk mengurangi efek mode mixing. Proses dimulai dengan penambahan sejumlah *white noise* pada sinyal input, diikuti dengan dekomposisi EMD terhadap noise tersebut untuk memperoleh komponen pertama dari noise, yaitu *IMF₁ noise*. Selanjutnya, IMF pertama dari sinyal diperoleh dengan menghitung rata-rata dari hasil pengurangan antara sinyal yang telah diberi noise dan IMF pertama dari noise itu sendiri, sesuai persamaan:

$$IMF_1 = \frac{1}{N} \sum_{i=1}^N (x(t) + \epsilon w_i(t) - EMD(w_i(t))) \quad (1)$$

di mana $w_{i(t)}$ adalah *white noise* ke- i , ϵ adalah rasio noise adaptif, dan N adalah jumlah ensemble. Setelah IMF pertama diperoleh, residual sinyal dihitung dengan mengurangkan IMF_1 dari sinyal asli:

$$r_1(t) = x(t) - IMF_1(t) \quad (2)$$

Langkah ini kemudian diulang untuk memperoleh IMF-IMF berikutnya dari sinyal residual $r_1(t)$, hingga seluruh komponen IMF dan residual akhir dihasilkan. Dengan pendekatan ini, ICEEMDAN mampu menghasilkan dekomposisi yang stabil, terhindar dari mode mixing, dan menjaga pemisahan spektral antar IMF. Keunggulan inilah yang membuat ICEEMDAN sangat cocok digunakan sebagai tahap prapemrosesan dalam sistem prediksi berbasis deep learning, seperti yang diterapkan dalam penelitian ini [18].

D. Denoising EWT

EWT merupakan teknik analisis spektral yang dikembangkan untuk mendekomposisi sinyal nonstasioner secara adaptif ke dalam beberapa subband frekuensi berdasarkan karakteristik spektral dari sinyal itu sendiri. Berbeda dengan transformasi wavelet konvensional yang menggunakan fungsi basis tetap, EWT membangun wavelet secara empiris melalui segmentasi spektrum *Fourier* dari sinyal. Proses ini dimulai dengan mengidentifikasi batas spektral dari sinyal menggunakan metode deteksi puncak pada spektrum *modulus Fourier*. Setelah batas spektral ditentukan, domain frekuensi dibagi ke dalam beberapa interval subband, dan untuk setiap interval tersebut dibangun pasangan fungsi filter *low-pass* dan *band-pass* yang halus. Wavelet empiris ini kemudian digunakan untuk memproyeksikan sinyal ke masing-masing subband, sehingga menghasilkan komponen-komponen yang mewakili struktur frekuensi dominan dari sinyal [14].

Secara matematis, komponen $f_k(t)$ dari sinyal $f(t)$ pada subband ke- k dapat dituliskan sebagai:

$$f_k(t) = \mathcal{F}^{-1}[\mathbf{f}(w) \cdot X_k(w)] \quad (3)$$

di mana $\mathbf{f}(w)$ adalah transformasi Fourier dari sinyal asli dan $X_k(w)$ adalah filter empiris untuk subband ke- k . Transformasi ini tidak hanya bersifat adaptif terhadap spektrum sinyal, tetapi juga mampu mempertahankan sifat lokalitas waktu dan frekuensi yang penting dalam menganalisis sinyal-sinyal kompleks seperti data kecepatan angin. Dalam konteks penelitian ini, EWT diterapkan sebagai tahap *denoising* terhadap IMF-IMF hasil dekomposisi ICEEMDAN, terutama pada komponen-komponen yang mengandung fluktuasi tinggi dan noise dominan.

Pemilihan IMF yang akan melalui proses *denoising* merupakan langkah strategis yang didasarkan pada analisis spektrum frekuensi dan observasi visual dari hasil dekomposisi awal. Metode ICEEMDAN mengurutkan komponen berdasarkan frekuensi, di mana IMF pertama (IMF1) merepresentasikan osilasi dengan frekuensi tertinggi, diikuti oleh IMF2, dan seterusnya, hingga komponen frekuensi terendah pada sinyal residu. Dalam analisis sinyal, komponen berfrekuensi tinggi sering kali menjadi tempat utama bagi *noise* acak dan fluktuasi jangka pendek yang tidak terstruktur [19].

Analisis eksplorasi pada hasil prediksi dari masing-masing IMF menggunakan BiLSTM yang diukur menggunakan koefisien determinasi (R^2) juga nantinya sebagai justifikasi bahwa IMF yang ke-berapa yang memiliki nilai R^2 yang rendah, maka IMF tersebut akan dilakukan *denoising* menggunakan EWT.

Setelah sinyal asli diurai menjadi beberapa IMF melalui metode ICEEMDAN, langkah selanjutnya adalah proses *denoising* atau penghilangan derau. Tahap ini sangat penting karena komponen IMF dengan frekuensi tinggi, terutama IMF awal (IMF 1, IMF 2, dan IMF 3), sering kali didominasi oleh derau (*noise*) acak yang dapat mengganggu performa model [14]. Untuk mengatasi hal ini, penelitian ini menerapkan *Empirical Wavelet Transform* (EWT), sebuah metode adaptif yang membangun bank filter wavelet berdasarkan spektrum sinyal itu sendiri. Tujuannya adalah untuk memisahkan komponen sinyal yang sebenarnya dari derau secara lebih presisi.

Tiga IMF pertama hasil dekomposisi ICEEMDAN (IMF1, IMF2, IMF3) serta kombinasi ketiganya dipilih untuk diproses lebih lanjut karena mengandung frekuensi tinggi yang rentan noise [20]. Proses EWT dilakukan secara terpisah dan kombinatif pada ketiga IMF tersebut untuk memecahnya menjadi beberapa sub-band frekuensi. Komponen frekuensi tertinggi yang dianggap sebagai noise dihilangkan, lalu sub-band sisanya direkonstruksi menjadi IMF versi denoised. IMF lainnya dan sinyal residu dianggap cukup stabil sehingga langsung digunakan untuk prediksi. Hasil dari proses EWT ini adalah sebuah sinyal tunggal yang telah dibersihkan (*denoised*), yang kemudian digabungkan kembali dengan IMF berfrekuensi lebih rendah lainnya untuk membentuk set data final yang akan digunakan sebagai masukan untuk model BiLSTM.

E. Prediksi BiLSTM

BiLSTM adalah arsitektur jaringan saraf tiruan yang dirancang khusus untuk data sekuensial, seperti data deret waktu (*time series*). Arsitektur ini merupakan pengembangan dari *Long Short-Term Memory* (LSTM) standar yang memiliki kemampuan untuk mengatasi masalah *vanishing gradient* dan mempelajari dependensi jangka panjang dalam data. Keunggulan utama LSTM terletak pada unit memorinya yang canggih, terdiri dari sebuah *cell state* yang berfungsi sebagai memori jangka panjang, serta tiga gerbang: *forget gate* untuk membuang informasi yang tidak relevan, *input*

gate untuk memperbarui *cell state* dengan informasi baru, dan *output gate* untuk menghasilkan keluaran berdasarkan *cell state* saat ini. BiLSTM menyempurnakan kemampuan ini dengan memproses data dalam dua arah, yaitu arah maju (*forward*) dan arah mundur (*backward*) [19].

Prediksi dilakukan menggunakan model Bi-LSTM yang mampu menangkap pola temporal dua arah. Model dilatih dengan pendekatan *sliding window* (*window size* = 30) dan *early stopping* untuk mencegah *overfitting* [21]. Evaluasi dilakukan dengan *K-fold Time Series Cross-Validation* (K=5), menjaga urutan data agar tidak terjadi kebocoran informasi [22]. Data dibagi menjadi 80% pelatihan, 10% validasi (dari pelatihan), dan 20% pengujian, setelah pembentukan input sliding window untuk memastikan pemisahan temporal yang konsisten dengan penggunaan konfigurasi *hyperparameter*.

TABEL 1.
KONFIGURASI HYPERPARAMETER

Proses	Hyper parameter	Nilai		
ICEEMDA N	<i>trials</i>	100		
	<i>epsilon</i>	0.005		
	<i>Max imf</i>	20		
	<i>Seed</i>	42		
EWT	<i>Num bands</i>	3		
BiLSTM	<i>Window size</i>	30	<i>Batch size</i>	32
	<i>Prediction steps</i>	1	<i>optimizer</i>	adam
	<i>Train ratio</i>	0.8	<i>Learning rate</i>	0.001
	<i>LSTM layer 1</i>	64	<i>Validation split</i>	0.2 (train), 0.1 (cross-validation)
	<i>LSTM layer 2</i>	32	<i>Early stopping patience</i>	10
	<i>Dropout rate</i>	0.2	<i>N splits (cross validation)</i>	5
	<i>epochs</i>	100		

Untuk menjamin perbandingan yang adil dan objektif di antara semua konfigurasi model yang diuji, setiap eksperimen dirancang untuk berjalan dalam kondisi yang terkontrol dan setara. Konsistensi ini mencakup penggunaan dataset, periode waktu, dan tahap pra-pemrosesan (penanganan nilai hilang dan normalisasi) yang identik untuk setiap model, mulai dari model BiLSTM dasar hingga kombinasi hybrid yang paling kompleks. Arsitektur inti BiLSTM beserta seluruh hyperparameter, seperti window size, jumlah lapisan, optimizer, dan learning rate seperti yang tercantum pada TABEL 1., dijaga tetap konstan di semua

skenario prediksi. Selain itu, protokol evaluasi yang sama, yaitu K-fold Time Series Cross-Validation (K=5) dan metrik kinerja (RMSE, MAPE, R²), diterapkan secara seragam. Pendekatan yang ketat ini memastikan bahwa perbedaan performa yang teramat dapat digambarkan secara langsung pada efektivitas metode dekomposisi dan denoising (ICEEMDAN-EWT) yang diterapkan, bukan karena adanya variasi dalam pengaturan eksperimental.

F. Evaluasi Kinerja

Dalam penelitian ini, untuk mengevaluasi kinerja model prediksi yang dihasilkan pada metode prediksi kecepatan angin menggunakan kombinasi ICEEMDAN dan EWT yang diintegrasikan dengan model Bi-LSTM digunakan tiga metrik evaluasi utama yaitu Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), dan koefisien determinasi (R²).

1) Root Mean Square Error (RMSE)

RMSE adalah metrik yang digunakan untuk mengukur perbedaan antara nilai kecepatan angin yang diprediksi oleh model dan nilai yang sebenarnya diamati. RMSE dihitung dengan menggunakan Persamaan 1,

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

di mana y_i adalah nilai kecepatan angin aktual, \hat{y}_i adalah nilai yang diprediksi, dan n adalah jumlah sampel. RMSE memberikan bobot lebih besar pada kesalahan yang lebih besar, sehingga lebih sensitif terhadap outlier. Dalam konteks penelitian ini, nilai RMSE yang lebih kecil menunjukkan bahwa model ICEEMDAN-EWT dan Transformer mampu memprediksi kecepatan angin dengan lebih akurat.

2) Mean Absolute Percentage Error (MAPE)

MAPE mengukur tingkat akurasi model prediksi dengan menghitung rata-rata kesalahan absolut dalam bentuk persentase, yang memudahkan interpretasi hasil dalam konteks aplikasi praktis, sehingga mudah dipahami tanpa memerlukan konteks skala data. Perhitungan MAPE menggunakan Persamaan 2.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

3) Koefisien Determinasi (R²)

Koefisien Determinasi, yang lebih dikenal sebagai R-squared (R²), adalah ukuran statistik yang digunakan untuk mengevaluasi kinerja model regresi. Metrik ini mengkuantifikasi proporsi varians dalam variabel dependen (target) yang dapat dijelaskan oleh variabel independen (prediktor) dalam sebuah model. Dengan kata lain, R²

menunjukkan seberapa baik model prediksi mampu meniru atau mencocokkan variasi yang ada pada data aktual. Nilai R² berkisar antara 0 hingga 1, di mana setiap nilai memberikan interpretasi yang jelas mengenai kecocokan model.

Secara konseptual, nilai R² yang mendekati 1 mengindikasikan bahwa sebagian besar variabilitas dalam data observasi telah berhasil dijelaskan oleh model. Sebaliknya, nilai R² yang mendekati 0 menunjukkan bahwa model gagal menjelaskan sebagian besar variabilitas data, yang berarti variabel prediktor yang dipilih memiliki hubungan yang sangat lemah dengan variabel target. Metode perhitungan R² adalah menggunakan persamaan 3.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

III. HASIL DAN PEMBAHASAN

Pada tahap ini, akan diuraikan dan dibahas secara mendalam temuan-temuan yang diperoleh dari serangkaian eksperimen yang telah dilakukan. Analisis dimulai dari hasil tahap pra-pemrosesan data, dekomposisi sinyal menggunakan ICEEMDAN, proses denoising dengan EWT, hingga evaluasi akhir dari performa model prediksi BiLSTM. Setiap hasil akan dianalisis untuk memahami efektivitas dari setiap komponen metode yang diusulkan dalam meningkatkan akurasi prediksi.

A. Pra-Pemrosesan Data

Dataset yang digunakan dalam penelitian ini memiliki rentang waktu dari 1 Januari 2000 hingga 31 Desember 2023. Berdasarkan rentang waktu tersebut, secara teoritis seharusnya terdapat 8.766 titik data harian. Namun, setelah dilakukan pemeriksaan integritas data, ditemukan bahwa dataset hanya berisi 8.761 titik data aktual. Investigasi lebih lanjut menunjukkan tidak adanya data yang terduplicasi. Selisih antara jumlah data yang diharapkan dan yang ada disebabkan oleh adanya lima data harian yang hilang. Secara spesifik, tanggal-tanggal yang hilang dari catatan dataset adalah 2 September 2014, 15 Januari 2016, 29 Januari 2016, 22 Agustus 2018, dan 26 Februari 2019. Untuk mengatasi masalah ini dan memastikan kontinuitas data deret waktu, diterapkan metode imputasi data menggunakan interpolasi linear. Metode ini dipilih untuk mengisi nilai-nilai yang hilang dengan mengestimasi nilai berdasarkan titik data tetangga terdekatnya, yaitu data sebelum dan sesudah tanggal yang hilang. Dengan demikian, dataset yang digunakan untuk analisis lebih lanjut menjadi utuh, konsisten, dan siap untuk tahap pemodelan.

B. Dekomposisi Signal oleh ICEEMDAN

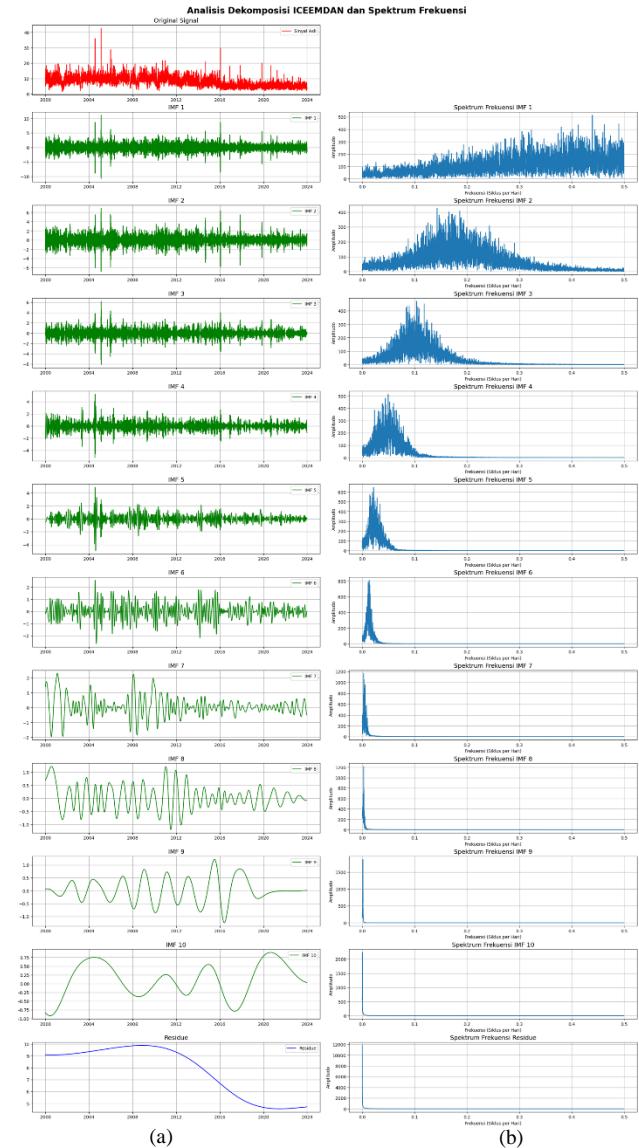
Setelah tahap pra-pemrosesan data selesai, sinyal deret waktu yang telah bersih dari nilai yang hilang (*missing value*), kemudian didekomposisi menggunakan algoritma ICEEMDAN. Proses ini bertujuan mengurai sinyal asli yang kompleks dan non-stasioner menjadi beberapa komponen yang lebih sederhana dan lebih mudah dianalisis. Hasil dari

dekomposisi ini, seperti yang diilustrasikan dengan jelas pada Gambar 2, adalah serangkaian IMF dan sebuah sinyal residu yang secara visual menunjukkan bagaimana sinyal asli (ditampilkan di panel paling atas) berhasil dipecah menjadi komponen-komponen penyusunnya, di mana setiap komponen memiliki karakteristik frekuensi yang berbeda.

Seperi ditunjukkan pada Gambar 2, hasil analisis dekomposisi sinyal menggunakan metode ICEEMDAN, serta representasi spektrum frekuensi dari masing-masing komponen IMF dan residu. Sinyal asli yang ditampilkan di bagian paling atas tampak bersifat non-stasioner dan kompleks, mencerminkan adanya komponen frekuensi tinggi hingga rendah yang tumpang tindih dalam domain waktu. Melalui proses dekomposisi ICEEMDAN, sinyal berhasil dipisahkan menjadi sepuluh IMF dan satu komponen residu yang secara berurutan merepresentasikan skala frekuensi dari tinggi ke rendah.

Spektrum frekuensi di sisi kanan menunjukkan bahwa IMF 1 hingga IMF 3 memiliki dominasi frekuensi tinggi dengan distribusi spektral yang lebar, serta amplitudo yang relatif besar di rentang frekuensi menengah ke atas. Hal ini menunjukkan bahwa ketiga IMF tersebut mengandung komponen noise dan fluktuasi cepat yang signifikan, yang umumnya bersifat tidak informatif atau mengganggu dalam proses pemodelan atau prediksi. Karakteristik inilah yang menjadi dasar kuat untuk melakukan proses denoising menggunakan metode Empirical Wavelet Transform (EWT) pada IMF 1, IMF 2, dan IMF 3. EWT mampu memisahkan sinyal menjadi subband frekuensi yang lebih halus dan terstruktur, sehingga efektif dalam mereduksi noise tanpa menghilangkan informasi penting dari komponen sinyal.

Sementara itu, IMF 4 hingga IMF 10 menunjukkan penurunan frekuensi secara bertahap dan semakin terlokalisasi di domain frekuensi rendah. Komponen-komponen ini mengandung osilasi yang lebih stabil dan informasi sinyal jangka menengah hingga panjang. Residu di bagian bawah memperlihatkan tren jangka panjang sinyal asli dengan frekuensi sangat rendah, ditandai oleh puncak spektral yang terkonsentrasi di sekitar nol.



Gambar 2. (a).Hasil Dekomposisi ICEEMDAN, (b) Spektrogram masing-masing IMF

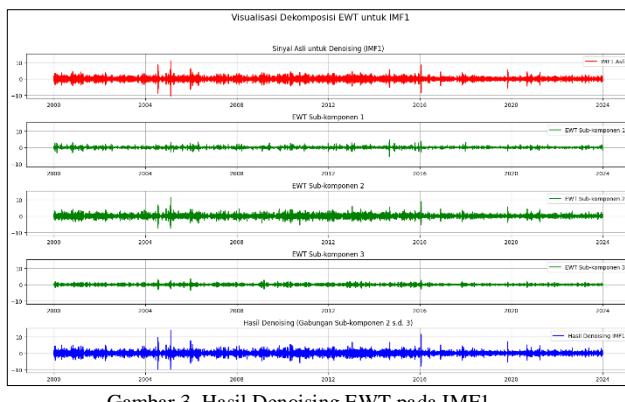
Dengan demikian, berdasarkan pola spektrum frekuensi yang diperoleh, pemilihan IMF 1, IMF 2, dan IMF 3 sebagai kandidat untuk proses denoising menggunakan EWT merupakan langkah yang tepat secara ilmiah. Strategi ini memungkinkan penghilangan komponen noise frekuensi tinggi sekaligus mempertahankan struktur sinyal utama yang tersebar pada IMF tingkat bawah dan residu, menghasilkan sinyal yang lebih bersih dan representatif untuk analisis lanjutan seperti forecasting atau klasifikasi.

C. Denoising EWT

Metode denoising yang diterapkan pada komponen IMF yang dihasilkan oleh ICEEMDAN menggunakan EWT yang berfungsi untuk meningkatkan kualitas sinyal dengan menghilangkan komponen *noise* frekuensi tinggi. EWT

diterapkan secara selektif pada IMF1, IMF2 dan IMF3 serta kombinasi dari ketiganya.

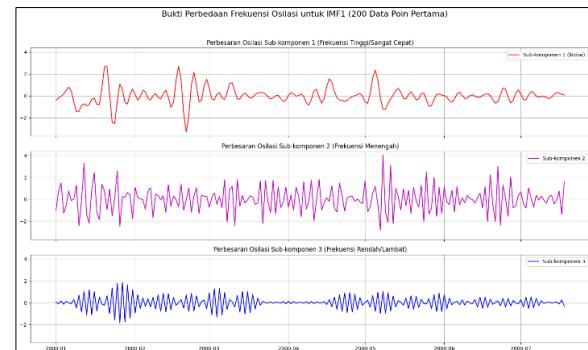
Proses ini dimulai setelah validasi bahwa setidaknya dua IMF dihasilkan oleh ICEEMDAN, dengan konfigurasi EWT yang menggunakan tiga band frekuensi (tinggi, menengah dan rendah) untuk setiap IMF yang diproses. Tujuan utama EWT adalah mengidentifikasi batas frekuensi adaptif berdasarkan spektrum sinyal dan memisahkan komponen frekuensi menjadi sub-band, di mana komponen frekuensi tertinggi diasumsikan sebagai noise dan dihapus untuk menghasilkan sinyal yang lebih bersih.



Gambar 3. Hasil Denoising EWT pada IMF1

Hasil EWT menunjukkan bahwa untuk setiap IMF yang diproses (misalnya, IMF1), dekomposisi menghasilkan matriks komponen EWT yang divisualisasikan melalui plot terperinci. Plot ini mencakup sinyal IMF asli di bagian atas, diikuti oleh setiap komponen EWT secara berurutan, dan sinyal yang telah dibersihkan (denoised) di bagian bawah. Komponen frekuensi tertinggi (sub-komponen 1) secara konsisten dihapus dari matriks EWT, berdasarkan asumsi bahwa ini mewakili noise, dan sisa komponen dijumlahkan untuk membentuk sinyal denoised. Agar terlihat lebih jelas, berikut plot pembesaran dari masing-masing sub-komponen EWT yang tertera pada gambar 4.

Osilasi yang tidak diinginkan pada sub-komponen 1 yang ditandai dengan fluktuasi cepat dan tidak terstruktur akan dihilangkan, sehingga menghasilkan sinyal denoised dengan osilasi yang lebih teratur dan amplitudo yang lebih stabil, mencerminkan komponen frekuensi menengah hingga rendah yang lebih relevan untuk analisis. Hasil dari proses ini secara efektif menghasilkan versi yang telah dibersihkan dari ketiga IMF awal. Dengan kata lain, output dari tahap ini dapat dianggap sebagai *denoised IMF1*, *denoised IMF2*, dan *denoised IMF3*.



Gambar 4. Pembesaran Plot EWT

Sinyal-sinyal yang telah bersih dari *noise* ini kemudian menggantikan posisi tiga IMF asli. Dengan demikian, set fitur final yang menjadi input untuk model prediksi BiLSTM adalah kombinasi dari denoised IMF1 hingga denoised IMF3, yang digabungkan dengan komponen-komponen asli berfrekuensi lebih rendah, yaitu IMF4 hingga IMF terakhir. Pendekatan ini memastikan bahwa model belajar dari data yang deraunya telah diminimalkan, namun informasi tren dan siklus penting dari data asli tetap dipertahankan.

D. Prediksi BiLSTM

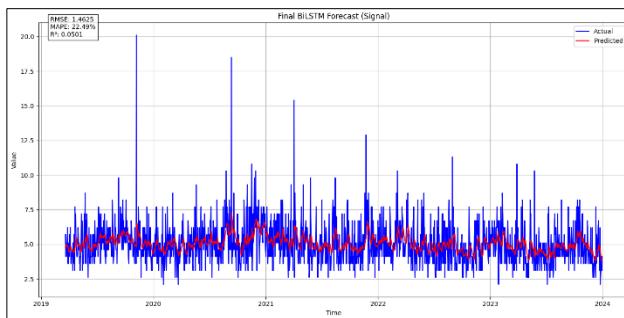
Setelah proses denoising melalui EWT berhasil diterapkan pada IMF1, IMF2, dan IMF3 yang dihasilkan oleh ICEEMDAN, tahap berikutnya melibatkan pemodelan prediktif menggunakan BiLSTM. Data urutan (*time series*) dibuat menggunakan *window_size* sebesar 30 dan langkah prediksi (*prediction_steps*) sebesar 1, diikuti oleh penskalaan data menggunakan MinMaxScaler untuk menormalisasi nilai antara 0 dan 1. Pendekatan ini memungkinkan BiLSTM untuk mempelajari pola temporal yang kompleks dalam data kecepatan angin dengan memanfaatkan arah maju dan mundur, meningkatkan kemampuan model dalam menangkap dinamika jangka pendek dan panjang.

Proses pelatihan BiLSTM dilakukan secara menyeluruh untuk setiap IMF (Denoised IMF1, Denoised IMF2, Denoised IMF3, dan IMF4 hingga IMF10) melalui pendekatan *cross-validation* dengan lima lipatan (*n_splits*=5) menggunakan TimeSeriesSplit. Untuk setiap lipatan, model BiLSTM yang terdiri dari dua lapisan LSTM bidirectional dengan 64 dan 32 unit masing-masing, dilengkapi dropout 0.2 untuk mencegah overfitting, dilatih dengan optimizer Adam dan *loss function Mean Square Error (MSE)*, serta *early stopping* untuk mengoptimalkan konvergensi berdasarkan pemantauan nilai *loss function*. Hasil prediksi pada set validasi untuk setiap lipatan divisualisasikan melalui plot yang membandingkan nilai aktual dan prediksi dengan metrik kinerja RMSE, MAPE, dan R².

1) Prediksi BiLSTM Tanpa ICEEMDAN dan Tanpa EWT

Berbeda dengan pipeline sebelumnya yang memanfaatkan dekomposisi ICEEMDAN dan denoising EWT untuk memisahkan dan membersihkan komponen sinyal, pendekatan ini fokus pada penerapan langsung BiLSTM pada

sinyal asli tanpa adanya proses dekomposisi dan *denoising* IMF.



Gambar 5 Hasil Prediksi Tanpa ICEEMDAN dan Tanpa EWT

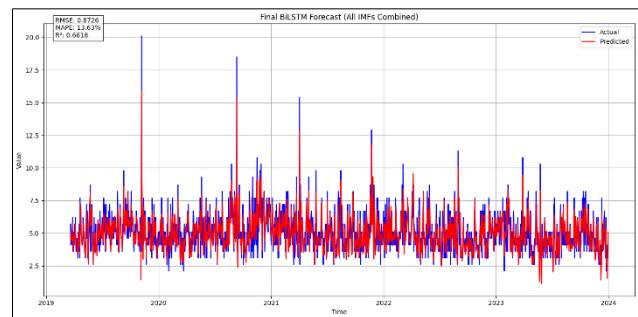
Berdasarkan hasil prediksi gambar 5, prediksi model BiLSTM tanpa melalui proses dekomposisi sinyal seperti ICEEMDAN dan EWT, terlihat bahwa performa model masih belum optimal. Hal ini tercermin dari nilai RMSE sebesar 1.4625 dan MAPE yang relatif tinggi, yaitu 22.49%, yang mengindikasikan adanya kesalahan prediksi yang cukup signifikan terhadap data aktual. Selain itu, nilai koefisien determinasi (R^2) yang sangat rendah, yakni hanya sebesar 0.0501, menunjukkan bahwa model hanya mampu menjelaskan sekitar 5% variasi dari data aktual, yang mengindikasikan keterbatasan model dalam menangkap pola dinamis dari sinyal kecepatan angin yang bersifat kompleks dan non-linier.

Secara visual, model cenderung hanya mengikuti tren umum dari data tanpa mampu merepresentasikan fluktuasi ekstrem atau lonjakan (spike) yang sering terjadi. Kelemahan ini dapat dikaitkan dengan tidak adanya proses dekomposisi sinyal yang berperan dalam memisahkan komponen sinyal utama dari noise serta mengidentifikasi struktur frekuensi yang relevan. Dengan demikian, pendekatan BiLSTM murni tanpa dukungan dekomposisi sinyal cenderung mengalami *underfitting* terhadap data yang kompleks.

Untuk meningkatkan performa prediksi, integrasi metode dekomposisi seperti ICEEMDAN dan EWT sangat disarankan agar model dapat mengolah representasi sinyal yang lebih informatif, menangkap karakteristik lokal, dan mengurangi tingkat kesalahan prediksi, sehingga lebih layak diterapkan dalam konteks sistem peringatan dini angin kencang.

2) Prediksi BiLSTM Menggunakan ICEEMDAN dan Tanpa EWT

Pada tahap ini, model BiLSTM telah dikembangkan dengan menerapkan metode dekomposisi sinyal menggunakan ICEEMDAN, namun belum disertai dengan proses filtrasi lanjutan menggunakan EWT. Pendekatan ini bertujuan untuk mengevaluasi sejauh mana kontribusi ICEEMDAN dalam meningkatkan performa model BiLSTM secara independen, sebelum integrasi lebih lanjut dengan metode EWT dilakukan.



Gambar 6 Hasil Prediksi Menggunakan ICEEMDAN

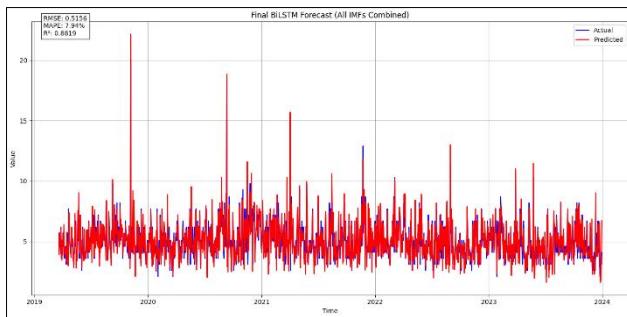
Berdasarkan gambar 6, hasil visualisasi dan evaluasi model BiLSTM yang dioptimalkan dengan dekomposisi ICEEMDAN menunjukkan peningkatan performa yang signifikan dibandingkan dengan model baseline tanpa proses dekomposisi. Hal ini tercermin dari penurunan nilai RMSE menjadi 0.8726 dan MAPE menjadi 13.63%, serta peningkatan nilai koefisien determinasi (R^2) menjadi 0.6618.

Peningkatan nilai R^2 ini mengindikasikan bahwa model mampu menjelaskan sekitar 66% variasi dari data aktual, menandakan adanya peningkatan kemampuan model dalam merepresentasikan karakteristik sinyal kecepatan angin yang bersifat non-stasioner dan kompleks. Secara visual, hasil prediksi yang ditampilkan dalam garis merah tampak mengikuti pola fluktuasi data aktual (garis biru) dengan lebih baik, termasuk dalam menangkap puncak-puncak ekstrem yang sebelumnya gagal direpresentasikan oleh model BiLSTM tanpa dekomposisi.

3) Prediksi BiLSTM Menggunakan ICEEMDAN dan EWT (Denoising IMF1, IMF2 dan IMF3)

Pada tahap ini, pendekatan prediksi kecepatan angin telah mencapai fase lanjutan dengan mengimplementasikan skema dekomposisi hybrid yang menggabungkan ICEEMDAN dan EWT. Proses ini difokuskan pada *denoising* EWT pada tiga IMF (IMF1 hingga IMF3 dan kombinasinya) yang mewakili komponen sinyal berfrekuensi tinggi dan paling rentan terhadap noise. Integrasi EWT bertujuan untuk menyaring fluktuasi yang tidak relevan serta mempertajam representasi sinyal sebelum dimasukkan ke dalam model BiLSTM, sehingga diharapkan mampu meningkatkan akurasi dan stabilitas prediksi.

Mengacu pada Gambar 7, menunjukkan performa yang sangat baik, dengan nilai RMSE sebesar 0.5156, MAPE hanya 7.94%, dan koefisien determinasi (R^2) sebesar 0.8819. Nilai R^2 yang mendekati 1 menandakan bahwa model mampu menjelaskan lebih dari 88% variasi dalam data aktual, yang merupakan capaian terbaik dibandingkan tahap-tahap sebelumnya.



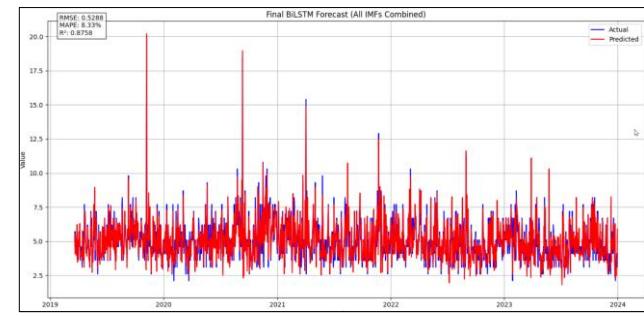
Gambar 7. Hasil Prediksi Menggunakan ICEEMDAN dan EWT (IMF1, IMF2, IMF3)

Secara visual, garis prediksi (merah) tampak sangat berdekatan dan sejajar dengan garis aktual (biru) pada hampir seluruh rentang waktu dari tahun 2019 hingga 2024. Hal ini menunjukkan bahwa model tidak hanya mampu mengikuti tren umum, tetapi juga merepresentasikan fluktuasi lokal dan anomali dengan akurasi tinggi, termasuk saat terjadi lonjakan kecepatan angin.

4) Prediksi BiLSTM Menggunakan ICEEMDAN dan EWT pada IMF1, IMF2 dan IMF3

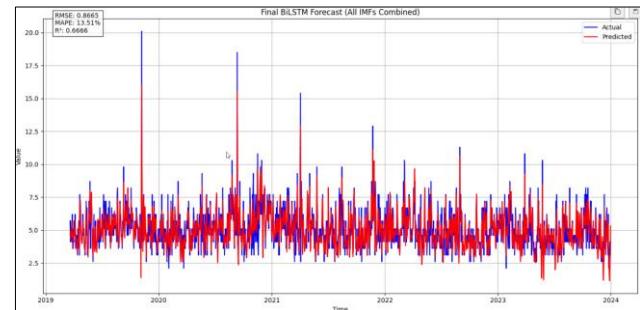
Pada tahap ini, dilakukan eksperimen lanjutan terhadap model prediksi kecepatan angin menggunakan pendekatan BiLSTM yang dikombinasikan dengan dekomposisi ICEEMDAN dan proses denoising menggunakan EWT, yang difokuskan pada seleksi dan kombinasi IMF tertentu. Strategi ini bertujuan untuk mengevaluasi kontribusi masing-masing komponen IMF terhadap performa model, baik secara individual maupun dalam kombinasi terbatas. Proses ini diawali dengan penerapan EWT pada IMF1 saja, yang merepresentasikan sinyal berfrekuensi paling tinggi dan sangat sensitif terhadap noise, diikuti dengan penerapan EWT secara terpisah pada IMF2 dan IMF3. Hasil prediksi dari masing-masing perlakuan ini menunjukkan adanya perbedaan kemampuan model dalam menangkap karakteristik sinyal yang berbeda tergantung pada spektrum frekuensi yang difokuskan.

Berdasarkan hasil prediksi pada Gambar 8, hasil prediksi menunjukkan kinerja yang sangat baik dengan nilai RMSE sebesar 0.5288, MAPE sebesar 8.33%, dan koefisien determinasi (R^2) sebesar 0.8758. Angka-angka ini menunjukkan bahwa model mampu menjelaskan hampir 88% variasi data aktual, dengan tingkat kesalahan absolut yang relatif rendah. Nilai RMSE yang mendekati setengah satuan skala dan nilai MAPE di bawah 10% mengindikasikan bahwa model telah berhasil memprediksi dengan tingkat presisi yang tinggi pada sebagian besar rentang waktu.



Gambar 8 Hasil Prediksi Menggunakan ICEEMDAN dan EWT pada IMF1

Pada Gambar 9, menampilkan hasil prediksi kecepatan angin menggunakan model BiLSTM yang telah dipadukan dengan proses dekomposisi ICEEMDAN dan denoising berbasis EWT yang diterapkan khusus pada komponen IMF2. Pendekatan ini bertujuan untuk mengevaluasi kontribusi frekuensi menengah terhadap akurasi prediksi, mengingat IMF2 merepresentasikan dinamika sinyal yang berada di antara noise tinggi (IMF1) dan tren jangka panjang.



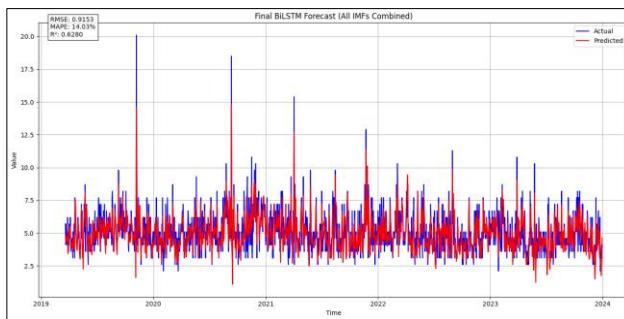
Gambar 9 Hasil Prediksi Menggunakan ICEEMDAN dan EWT pada IMF2

Secara kuantitatif, Gambar 9, menunjukkan RMSE sebesar 0.8665, MAPE sebesar 13.51%, dan koefisien determinasi (R^2) sebesar 0.6666. Nilai-nilai ini menandakan bahwa model hanya mampu menjelaskan sekitar 66,66% variasi data aktual, dan tingkat kesalahan prediksi relatif meningkat dibandingkan dengan skenario denoising pada IMF1.

Berdasarkan hasil yang diperoleh dari penerapan denoising EWT pada IMF2, terlihat bahwa akurasi prediksi mengalami penurunan jika dibandingkan dengan denoising pada IMF1, baik dari segi nilai RMSE, MAPE, maupun koefisien determinasi (R^2). Temuan ini semakin memperkuat bahwa kontribusi dominan terhadap peningkatan akurasi prediksi berasal dari pemrosesan IMF1. Sebagai bagian dari rangkaian eksperimen untuk mengevaluasi efektivitas masing-masing komponen sinyal, tahapan selanjutnya adalah menerapkan proses denoising EWT pada IMF3, yang mewakili frekuensi yang lebih rendah dibanding IMF1 dan IMF2. Gambar berikut menyajikan hasil prediksi model BiLSTM ketika denoising dilakukan hanya pada IMF3 yang tergambar pada Gambar 10.

Model denoising EWT pada IMF3 menghasilkan RMSE sebesar 0.9153, yang menunjukkan tingkat kesalahan absolut

rata-rata model relatif tinggi dibandingkan dengan skenario denoising pada IMF1 maupun IMF2. Selain itu, nilai MAPE tercatat sebesar 14.03%, yang juga menunjukkan tingkat kesalahan persentase yang lebih besar dibandingkan dua IMF sebelumnya.



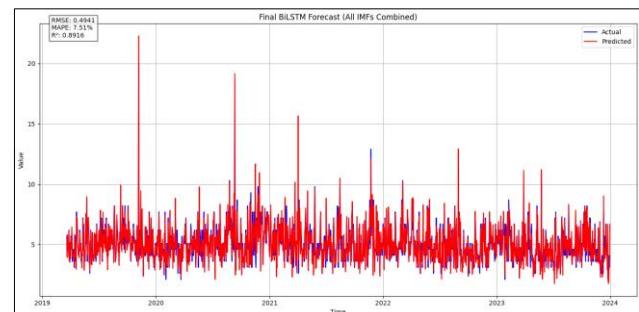
Gambar 10 Hasil Prediksi Menggunakan ICEEMDAN dan EWT pada IMF3

Hal ini mengindikasikan bahwa akurasi model menurun ketika denoising hanya dilakukan pada IMF3. Lebih lanjut, nilai R^2 sebesar 0.6280 menunjukkan bahwa model hanya mampu menjelaskan sekitar 62.8% variasi dari data aktual. Angka ini lebih rendah dari R^2 pada IMF2 (66.66%) dan jauh lebih rendah dari IMF1 (87.58%).

5) Prediksi BiLSTM Menggunakan ICEEMDAN dan EWT pada Gabungan dua IMF

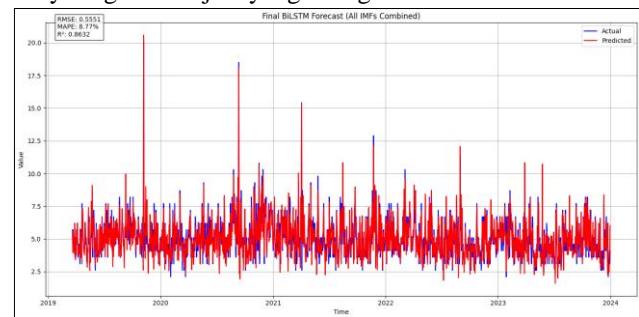
Pada tahap ini ditampilkan hasil prediksi kecepatan angin menggunakan model BiLSTM yang telah diintegrasikan dengan dekomposisi ICEEMDAN dan pemrosesan denoising menggunakan EWT pada berbagai kombinasi pasangan IMF, yaitu IMF1&IMF2, IMF1&IMF3, dan IMF2&IMF3. Setiap kombinasi diuji untuk mengevaluasi kontribusi masing-masing lapisan frekuensi terhadap kualitas prediksi model secara komprehensif.

Pada Gambar 11, menunjukkan hasil prediksi dengan EWT diterapkan pada IMF1 dan IMF2. Hasil evaluasi kuantitatif menunjukkan nilai RMSE sebesar 0.4941, MAPE sebesar 7.51%, dan R^2 sebesar 0.8916. Ini merupakan hasil terbaik dari ketiga kombinasi, dengan kesalahan prediksi terkecil dan akurasi tertinggi. Secara visual, garis prediksi (merah) sangat berdekatan dengan garis aktual (biru), baik dalam menangkap pola fluktuatif harian maupun lonjakan ekstrem. Kombinasi IMF1 dan IMF2 mewakili spektrum frekuensi tinggi dan menengah yang dominan mengandung noise dan dinamika lokal. Oleh karena itu, proses denoising pada kedua komponen ini sangat efektif dalam menyajikan sinyal yang bersih dan informatif ke model BiLSTM.



Gambar 11 Hasil Prediksi Menggunakan ICEEMDAN dan EWT pada IMF1&IMF2

Selanjutnya pada Gambar 12, menunjukkan hasil prediksi dengan denoising EWT pada IMF1 dan IMF3. Nilai RMSE sebesar 0.5551, MAPE sebesar 8.77%, dan R^2 sebesar 0.8632. Meskipun hasilnya masih tergolong baik, performanya menurun dibandingkan dengan kombinasi IMF1&2. Hal ini menunjukkan bahwa kontribusi IMF3 yang merepresentasikan komponen frekuensi rendah (cenderung memuat tren jangka panjang) tidak sekuat IMF2 dalam membantu model mengenali dinamika sinyal. Meski demikian, denoising pada IMF1 tetap memberikan dampak besar dalam meningkatkan performa, karena mampu menyaring noise tajam yang sering kali muncul di data cuaca.

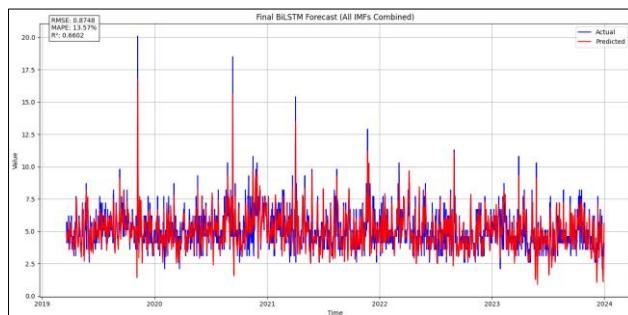


Gambar 12. Hasil Prediksi Menggunakan ICEEMDAN dan EWT pada IMF1 dan IMF3

Selanjutnya pada Gambar 13. merepresentasikan hasil prediksi ketika denoising EWT diterapkan hanya pada IMF2 dan IMF3, tanpa menyertakan IMF1. Hasil evaluasi kuantitatif menunjukkan nilai RMSE sebesar 0.8748, MAPE sebesar 13.57%, dan R^2 sebesar 0.6602. Ini adalah hasil terburuk di antara ketiga kombinasi yang diuji. Nilai RMSE yang cukup tinggi menunjukkan bahwa kesalahan absolut prediksi masih besar, sementara MAPE di atas 13% mengindikasikan bahwa model memiliki akurasi relatif yang moderat terhadap data aktual. Nilai koefisien determinasi (R^2) sebesar 0.6602 mengartikan bahwa model hanya mampu menjelaskan sekitar 66% dari variasi total dalam data aktual.

Berdasarkan hasil evaluasi terhadap tiga kombinasi denoising EWT pada pasangan IMF, dapat disimpulkan bahwa performa prediksi terbaik dicapai ketika EWT diterapkan pada IMF1 dan IMF2, dengan nilai RMSE sebesar 0.4941, MAPE 7.51%, dan koefisien determinasi (R^2) sebesar 0.8916.

Kombinasi ini secara konsisten menghasilkan prediksi yang paling akurat dan stabil, baik secara kuantitatif maupun visual. Hal ini menunjukkan bahwa IMF1 dan IMF2 merupakan komponen yang paling kritis dalam membawa informasi dinamis penting dan noise dominan yang harus disaring.



Gambar 13. Hasil Prediksi Menggunakan ICEEMDAN dan EWT pada IMF2 dan IMF3

Sementara itu, kombinasi IMF1 dan IMF3 masih memberikan hasil yang cukup baik, dengan R^2 sebesar 0.8632 dan MAPE 8.77%, namun performanya sedikit menurun karena IMF3 yang berisi tren jangka panjang tidak sekuat IMF2 dalam menyumbangkan sinyal fluktuatif. Di sisi lain, kombinasi IMF2 dan IMF3, yang mengecualikan IMF1, menunjukkan hasil terburuk di antara ketiganya, dengan R^2 hanya 0.6602 dan MAPE sebesar 13.57%.

Ini menegaskan bahwa tidak adanya denoising pada IMF1 berdampak signifikan terhadap menurunnya akurasi prediksi, mengingat IMF1 mengandung komponen frekuensi tinggi yang penting namun rawan noise. Dengan demikian, proses denoising yang mencakup IMF1, terutama bila dikombinasikan dengan IMF2, terbukti menjadi strategi paling efektif dalam meningkatkan performa model BiLSTM untuk estimasi kecepatan angin berbasis dekomposisi ICEEMDAN-EWT.

6) Pengaruh Pemilihan IMF terhadap Akurasi Prediksi ICEEMDAN-EWT-BiLSTM

Sebagai bagian dari strategi untuk meningkatkan akurasi prediksi kecepatan angin berbasis model hybrid ICEEMDAN-EWT-BiLSTM, dilakukan analisis terhadap kontribusi masing-masing komponen IMF yang dihasilkan dari proses dekomposisi sinyal. Evaluasi ini bertujuan untuk mengonfirmasi bahwa penerapan denoising menggunakan EWT memang tepat difokuskan pada IMF1, IMF2, dan IMF3, yang mengandung fluktuasi tinggi dan tingkat noise dominan. Analisis dilakukan dengan membandingkan nilai koefisien determinasi (R^2) dari prediksi BiLSTM pada masing-masing IMF sebelum dan sesudah proses denoising.

Berdasarkan TABEL 2, menunjukkan bahwa IMF1 memberikan kontribusi perbaikan paling signifikan, dengan peningkatan absolut nilai R^2 sebesar 70.22%, dari 0.2226 menjadi 0.9248 setelah proses denoising menggunakan EWT. Perbaikan ini menegaskan bahwa IMF1 mengandung

informasi penting yang sebelumnya tersembunyi oleh noise frekuensi tinggi, dan hanya dapat dimanfaatkan secara optimal setelah dilakukan pemurnian sinyal. Peningkatan ini juga berdampak langsung terhadap akurasi prediksi global model, yang meningkat secara keseluruhan setelah IMF1 didenoise.

Kontribusi signifikan juga ditunjukkan oleh IMF2, yang mengalami peningkatan nilai R^2 sebesar 20.93%, dari 0.6858 menjadi 0.8951. Sementara itu, IMF3, meskipun peningkatannya lebih kecil secara absolut (1.26%, dari 0.9675 ke 0.9801), tetap menunjukkan adanya efek positif dari proses denoising, khususnya pada sinyal dengan karakteristik frekuensi menengah yang masih terdampak noise parsial.

TABEL 2.
NILAI KOEFISIEN DETERMINASI (R^2) PADA MASING-MASING IMF MENGGUNAKAN ICEEMDAN-EWT-BiLSTM

Komponen	R^2 Sebelum Denoise EWT	R^2 Setelah Denoise EWT	Perubahan Absolut R^2
IMF1	0.2226	0.9248	70.22 %
IMF2	0.6858	0.8951	20.93 %
IMF3	0.9675	0.9801	1.26 %
IMF4	0.9821	0.9835	0.14 %
IMF5	0.9864	0.9897	0.13 %
IMF6	0.9868	0.987	0.02 %
IMF7	0.9975	0.9981	0.06 %
IMF8	0.9992	0.9993	0.01 %
IMF9	0.992	0.9924	0.04 %
IMF10	0.9905	0.9907	0.02 %

Sebaliknya, untuk IMF4 hingga IMF10, peningkatan nilai R^2 setelah denoising tergolong sangat kecil (<1%), bahkan pada IMF10 menunjukkan sedikit penurunan. Hal ini mengindikasikan bahwa IMF pada urutan menengah hingga akhir telah relatif bersih dan stabil, sehingga tidak memerlukan pemrosesan tambahan. Nilai R^2 pada IMF7 hingga IMF9 yang mendekati 1.000 menunjukkan bahwa model BiLSTM tanpa denoising sudah mampu mempelajari pola prediktif secara efektif dari komponen sinyal ini.

Dengan demikian, temuan ini menegaskan bahwa denoising hanya perlu diterapkan secara selektif, yakni pada IMF yang menunjukkan nilai prediksi rendah dan indikasi noise tinggi, yaitu IMF1 hingga IMF3. Pendekatan ini tidak hanya meningkatkan akurasi prediksi secara signifikan, tetapi juga menjaga efisiensi komputasi karena menghindari pemrosesan yang tidak diperlukan pada IMF lain yang sudah bersih.

E. Rekapitulasi Akurasi Prediksi dari Berbagai Kombinasi IMF pada ICEEMDAN-EWT-BiLSTM

Pada tahap ini, dilakukan evaluasi menyeluruh terhadap performa prediksi kecepatan angin berdasarkan berbagai kombinasi IMF yang diproses menggunakan metode ICEEMDAN-EWT-BiLSTM. Tujuan dari analisis ini adalah

untuk memahami pengaruh pemilihan IMF terhadap kualitas prediksi dan mengevaluasi efektivitas proses denoising menggunakan EWT. TABEL 3, menyajikan hasil evaluasi model berdasarkan metrik RMSE, MAPE, dan koefisien determinasi (R^2).

Hasil evaluasi menunjukkan bahwa kombinasi denoising pada IMF1 dan IMF2 memberikan performa terbaik, dengan nilai RMSE terendah sebesar 0.501, MAPE 7.64%, dan R^2 tertinggi sebesar 0.8885. Pencapaian ini mengindikasikan bahwa kedua IMF tersebut memuat informasi penting namun terdistorsi oleh *noise*, yang berhasil dimurnikan melalui proses denoising EWT. Keberhasilan kombinasi ini menegaskan bahwa pemilihan IMF yang tepat untuk pemrosesan lanjutan merupakan faktor krusial dalam meningkatkan akurasi model secara keseluruhan.

TABEL 3.
REKAPITULASI HASIL EVALUASI MODEL PREDIKSI

No	Metode	RMSE	MAPE	R2
1	ICEEMDAN+EWT (IMF1) + BiLSTM	0.5024	7.96%	0.8879
2	ICEEMDAN+EWT (IMF2) + BiLSTM	0.8699	13.74%	0.6639
3	ICEEMDAN+EWT (IMF3) + BiLSTM	0.9094	13.99%	0.6327
4	ICEEMDAN+EWT (IMF1 & IMF2) + BiLSTM	0.501	7.64%	0.8885
5	ICEEMDAN+EWT (IMF1 & IMF2 & IMF3) + BiLSTM	0.5114	7.84%	0.8838
6	ICEEMDAN+EWT (IMF2 & IMF3) + BiLSTM	0.8839	13.71%	0.653
7	ICEEMDAN+EWT (IMF1 & IMF3) + BiLSTM	0.5409	8.63%	0.8701
8	ICEEMDAN + BiLSTM	0.8962	13.8%	0.6433
9	BiLSTM	1.4625	22.49%	0.0501

Sebaliknya, ketika IMF diproses secara individual, performanya relatif lebih rendah. Misalnya, model dengan hanya IMF2 menghasilkan nilai R^2 sebesar 0.6639 dan RMSE sebesar 0.8699, sedangkan IMF3 justru menghasilkan R^2 terendah di antara semua skenario hybrid, yaitu 0.6327, menunjukkan bahwa informasi prediktif dari IMF3 relatif terbatas atau tidak sepenuhnya relevan secara mandiri. Sementara model dengan hanya IMF1 memberikan performa cukup baik dengan R^2 sebesar 0.8879, tetapi tidak melebihi kombinasi IMF1 dan IMF2.

Kemudian, penambahan IMF3 pada kombinasi IMF1 dan IMF2 tidak meningkatkan akurasi secara signifikan, justru menghasilkan sedikit penurunan performa ($R^2 = 0.8388$ dibanding 0.8885 sebelumnya). Hal ini menunjukkan bahwa tidak semua penambahan IMF memberikan manfaat aditif, dan pemrosesan yang berlebihan pada IMF yang kurang relevan justru dapat memperburuk generalisasi model.

Model baseline BiLSTM tanpa ICEEMDAN maupun EWT memberikan performa terburuk dengan RMSE sebesar 1.4625, MAPE sebesar 22.49%, dan R^2 hanya 0.0501, menandakan bahwa model gagal memahami pola temporal dalam data mentah yang kompleks. Sementara itu, model ICEEMDAN + BiLSTM tanpa EWT menunjukkan performa

yang sedikit lebih baik ($R^2 = 0.6433$), namun masih jauh di bawah model yang disertai proses *denoising*. Hal ini memperkuat bukti bahwa proses *denoising* EWT memainkan peran penting dalam mengurangi sisa noise yang tidak sepenuhnya diatasi oleh dekomposisi ICEEMDAN.

Secara keseluruhan, hasil ini menggarisbawahi pentingnya strategi pemilihan IMF yang selektif dan berbasis evaluasi performa. *Denoising* secara khusus pada IMF1 dan IMF2 terbukti sangat efektif dalam meningkatkan akurasi prediksi, sedangkan pemrosesan IMF lainnya tidak selalu diperlukan. Strategi ini tidak hanya meningkatkan efisiensi komputasi, tetapi juga menjaga stabilitas model dalam menangani dinamika sinyal angin yang kompleks.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi kecepatan angin berbasis hybrid ICEEMDAN-EWT-BiLSTM yang menunjukkan peningkatan akurasi signifikan dibandingkan pendekatan konvensional. Proses utama mencakup dekomposisi sinyal menggunakan ICEEMDAN, kemudian dilakukan seleksi IMF dengan performa prediksi rendah yaitu IMF yang menghasilkan nilai R^2 rendah saat diprediksi dengan BiLSTM. IMF terpilih (IMF1 dan IMF2) kemudian diproses dengan *denoising* EWT sebelum diprediksi ulang menggunakan BiLSTM. Strategi ini terbukti efektif, dengan hasil terbaik ditunjukkan oleh kombinasi IMF1 dan IMF2, yang mencapai R^2 sebesar 0.8885, RMSE 0.501, dan MAPE 7.64%.

IMF lainnya (IMF4 hingga IMF10) menunjukkan akurasi tinggi bahkan tanpa denoising, sehingga tidak memerlukan pemrosesan tambahan. Pendekatan selektif ini tidak hanya meningkatkan kualitas prediksi, tetapi juga menghemat beban komputasi secara signifikan. Selain itu, IMF menengah hingga akhir (IMF4 hingga IMF10) cenderung memiliki nilai R^2 yang tinggi meskipun tidak dilakukan denoising, sehingga pemrosesan tambahan pada IMF tersebut tidak diperlukan, yang pada akhirnya menghemat sumber daya komputasi tanpa mengorbankan kualitas prediksi.

Meskipun demikian, framework ini memiliki kompleksitas komputasi yang tinggi karena mencakup beberapa tahap pengolahan sinyal. Implementasi real-time dimungkinkan dengan optimalisasi perangkat keras seperti GPU, penerapan parallel processing, serta pemisahan proses pelatihan yang dilakukan offline dan proses prediksi yang dilakukan secara online.

Sebagai catatan penting, model ini masih terbatas pada pendekatan univariate, yang hanya mengandalkan data historis kecepatan angin. Untuk meningkatkan kemampuan prediksi dalam konteks yang lebih luas, integrasi variabel eksogen seperti suhu, tekanan udara, dan topografi sangat disarankan. Pengembangan lanjutan juga dapat mencakup otomatisasi seleksi IMF berbasis optimisasi, serta eksplorasi arsitektur deep learning alternatif seperti Transformer, GRU, atau TCN guna meningkatkan generalisasi dan adaptivitas model.

DAFTAR PUSTAKA

- [1] X. Zhao, Q. Sun, W. Tang, S. Yu, and B. Wang, "A comprehensive wind speed forecast correction strategy with an artificial intelligence algorithm," *Front Environ Sci*, vol. 10, Nov. 2022, doi: 10.3389/fenvs.2022.1034536.
- [2] C. Bariş, C. Yanarateş, and A. Altan, "A robust chaos-inspired artificial intelligence model for dealing with nonlinear dynamics in wind speed forecasting," *PeerJ Comput Sci*, vol. 10, 2024, doi: 10.7717/PEERJ-CS.2393.
- [3] H. Zhang, J. Wang, Y. Qian, and Q. Li, "Point and interval wind speed forecasting of multivariate time series based on dual-layer LSTM," *Energy*, vol. 294, May 2024, doi: 10.1016/j.energy.2024.130875.
- [4] M. U. Yousuf, I. Al-Bahadly, and E. Avci, "Wind speed prediction for small sample dataset using hybrid first-order accumulated generating operation-based double exponential smoothing model," *Energy Sci Eng*, vol. 10, no. 3, pp. 726–739, Mar. 2022, doi: 10.1002/ese3.1047.
- [5] R. Yang, H. Liu, N. Nikitas, Z. Duan, Y. Li, and Y. Li, "Short-term wind speed forecasting using deep reinforcement learning with improved multiple error correction approach," *Energy*, vol. 239, Jan. 2022, doi: 10.1016/j.energy.2021.122128.
- [6] J. Du, S. Chen, L. Pan, and Y. Liu, "A Wind Speed Prediction Method Based on Signal Decomposition Technology Deep Learning Model," *Energies (Basel)*, vol. 18, no. 5, Mar. 2025, doi: 10.3390/en18051136.
- [7] Q. Yang and D. An, "EMD and wavelet transform based fault diagnosis for wind turbine gear box," *Advances in Mechanical Engineering*, vol. 2013, 2013, doi: 10.1155/2013/212836.
- [8] D. Dong, S. Wang, Q. Guo, W. Zou, X. Li, and Z. Wang, "Enhanced Short-Term Wind Speed Prediction by ICEEMDAN and Feature Engineering," in *Proceedings - 2023 China Automation Congress, CAC 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 1063–1068. doi: 10.1109/CAC59555.2023.10451255.
- [9] H. Yao, Y. Tan, J. Hou, Y. Liu, X. Zhao, and X. Wang, "Short-Term Wind Speed Forecasting Based on the EEMD-GS-GRU Model," *Atmosphere (Basel)*, vol. 14, no. 4, Apr. 2023, doi: 10.3390/atmos14040697.
- [10] H. Wei, T. Qi, G. Feng, and H. Jiang, "Comparative Research on Noise Reduction of Transient Electromagnetic Signals Based on Empirical Mode Decomposition and Variational Mode Decomposition," *Radio Sci*, vol. 56, no. 10, Oct. 2021, doi: 10.1029/2020RS007135.
- [11] X. Xia and X. Wang, "A Novel Hybrid Model for Short-Term Wind Speed Forecasting Based on Twice Decomposition, PSR, and IMVO-ELM," *Complexity*, vol. 2022, 2022, doi: 10.1155/2022/4014048.
- [12] Z. Tian and J. Wang, "A Novel Wind Speed Interval Prediction System Based on Neural Network and Multi-objective Grasshopper Optimization," *International Transactions on Electrical Energy Systems*, vol. 2022, 2022, doi: 10.1155/2022/5823656.
- [13] Q. Zhuang, L. Gao, W. Li, and X. Shu, "Ultra-Short-Term Wind Power Prediction Based on ICEEMDAN-Nons-Transformer," in *2024 International Conference on Energy and Electrical Engineering (EEE)*, IEEE, Jul. 2024, pp. 1–6. doi: 10.1109/EEE59956.2024.10709682.
- [14] I. Karijadi, S. Y. Chou, and A. Dewabharata, "Wind power forecasting based on hybrid CEEMDAN-EWT deep learning method," *Renew Energy*, vol. 218, Dec. 2023, doi: 10.1016/j.renene.2023.119357.
- [15] J. Gilles, "Empirical wavelet transform," *IEEE Transactions on Signal Processing*, vol. 61, no. 16, pp. 3999–4010, 2013, doi: 10.1109/TSP.2013.2265222.
- [16] B. S. Bommidi, V. Kosana, K. Teeparthi, and S. Madasthu, "Hybrid attention-based temporal convolutional bidirectional LSTM approach for wind speed interval prediction," *Environmental Science and Pollution Research*, vol. 30, no. 14, pp. 40018–40030, Mar. 2023, doi: 10.1007/s11356-022-24641-x.
- [17] Y. Liu, J. He, Y. Wang, Z. Liu, L. He, and Y. Wang, "Short-Term Wind Power Prediction Based on CEEMDAN-SE and Bidirectional LSTM Neural Network with Markov Chain," *Energies (Basel)*, vol. 16, no. 14, Jul. 2023, doi: 10.3390/en16145476.
- [18] M. A. Colominas, G. Schlotthauer, and M. E. Torres, "Improved complete ensemble EMD: A suitable tool for biomedical signal processing," *Biomed Signal Process Control*, vol. 14, no. 1, pp. 19–29, 2014, doi: 10.1016/j.bspc.2014.06.009.
- [19] J. Liu, Y. Wu, X. Cheng, B. Li, and P. Yang, "Short-term wind power prediction based on ICEEMDAN-Correlation reconstruction and BWO-BiLSTM," *Electrical Engineering*, 2024, doi: 10.1007/s00202-024-02574-7.
- [20] L. Jian, X. Wang, H. Hao, H. Wang, and L. Yang, "Fusion of PSO-SVM and ICEEMDAN for high stability GNSS-MR sea level height estimation," *All Earth*, vol. 36, no. 1, pp. 1–15, 2024, doi: 10.1080/27669645.2024.2331328.
- [21] Z. Zhan and S. K. Kim, "Versatile time-window sliding machine learning techniques for stock market forecasting," *Artif Intell Rev*, vol. 57, no. 8, Aug. 2024, doi: 10.1007/s10462-024-10851-x.
- [22] A. A. Saputra, K. Ma'Ruf, R. J. Setiawan, Darmono, and N. Azizah, "Enhancing Predictive Accuracy of LSTM Neural Networks for Diabetes Risk through K-Fold Cross-Validation: Comparison with K-Nearest Neighbors and Expert Systems," in *2024 International Conference on Decision Aid Sciences and Applications, DASA 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/DASA63652.2024.10836564.