EVALUASI MODEL BI-LSTM DAN BI-GRU DALAM MEMPREDIKSI *DIRECT NORMAL IRRADIANCE* SEBAGAI VERIFIKASI PYRHELIOMETER CHP1

Roy Handoko[1], Sudarno Wiharjo[2], Yan Mitha Djaksana[3]
Program Studi Magister Teknik Informatika,
Universitas Pamulang[1,2,3]
Jl. Raya Puspiptek No. 46, Buaran, Kec. Pamulang, Kota Tangerang Selatan, Banten
rhandk@gmail.com[1], sudarnogm@gmail.com[2], dosen01994@unpam.ac.id[3]

Abstrak

Iradiasi matahari langsung atau *Direct Normal Irradiance* (DNI) berperan penting dalam observasi iklim global dan optimalisasi Pembangkit Listrik Tenaga Surya (PLTS). Kalibrasi *pyrheliometer* umumnya mengacu pada ISO 9059 melalui perbandingan instrumen operasional dengan standar referensi. Penelitian ini mengembangkan instrumen verifikasi virtual berbasis *Deep Learning* untuk merekonstruksi keluaran *pyrheliometer* CHP1 dengan mempertimbangkan hubungan nonlinier antara respons sensor *thermopile* dan dinamika meteorologi. Dua arsitektur *bidirectional*, yaitu *Bidirectional Long Short-Term Memory* (Bi-LSTM) dan *Bidirectional Gated Recurrent Unit* (Bi-GRU), dilatih menggunakan data multivariat iradiasi dan parameter meteorologi hasil kalibrasi di Kota Kupang pada September 2025. Evaluasi dilakukan menggunakan koefisien determinasi, RMSE, dan MAPE. Hasil menunjukkan bahwa arsitektur *bidirectional* memberikan performa unggul dibandingkan arsitektur *unidirectional*. Bi-GRU menghasilkan kinerja terbaik dengan koefisien determinasi 0,986, RMSE 1,153 W/m², dan MAPE 0,096%, sedangkan Bi-LSTM mencapai koefisien determinasi 0,885 dan MAPE 0,309%. Temuan ini menunjukkan potensi Bi-GRU sebagai model verifikasi virtual yang mampu mendukung evaluasi respons *pyrheliometer* secara lebih adaptif. Pengembangan selanjutnya diarahkan pada validasi lintas periode, lokasi, kondisi cuaca, dan instrumen.

Kata kunci: Pyrheliometer, Kalibrasi, Bi-LSTM, Bi-GRU, Verifikasi.

Abstract

Direct Normal Irradiance (DNI) plays an important role in global climate observation and the optimization of solar photovoltaic systems. Pyrheliometer calibration commonly refers to ISO 9059 by comparing an operational instrument with a reference standard. This study develops a Deep Learning-based virtual verification instrument to reconstruct the output of a CHP1 pyrheliometer while capturing nonlinear relationships between thermopile sensor response and meteorological dynamics. Two bidirectional architectures, Bidirectional Long Short-Term Memory (Bi-LSTM) and Bidirectional Gated Recurrent Unit (Bi-GRU), were trained using multivariate irradiance and meteorological data obtained from a calibration campaign in Kupang City during September 2025. Model performance was evaluated using the coefficient of determination, RMSE, and MAPE. The results show that bidirectional architectures achieved stronger performance than their unidirectional counterparts. Bi-GRU delivered the best performance, with a coefficient of determination of 0.986, an RMSE of 1.153 W/m², and a MAPE of 0.096%, while Bi-LSTM achieved a coefficient of determination of 0.885 and a MAPE of 0.309%. These findings demonstrate the potential of Bi-GRU as an adaptive virtual verification model for pyrheliometer response reconstruction. Further development may focus on validation across different periods, locations, weather conditions, and instruments.

***Keywords**: Pyrheliometer, Calibration, Bi-LSTM, Bi-GRU, Verification.*

PENDAHULUAN

Kebutuhan energi listrik di Indonesia dan dunia terus mengalami peningkatan yang eksponensial seiring dengan laju pertumbuhan industri dan populasi. Di tengah ancaman pemanasan global, transisi menuju teknologi energi terbarukan menjadi urgensi guna memenuhi kebutuhan energi sekaligus menekan emisi gas rumah kaca (Shahsavari & Akbari, 2018). Indonesia berada di garis khatulistiwa, memiliki paparan potensi energi surya yang masif dan stabil sepanjang tahun, hal ini menjadikan Pembangkit Listrik Tenaga Surya (PLTS) sebagai pilar utama bauran energi masa depan (Afif & Martin, 2022). Dalam merancang dan mengevaluasi efisiensi sistem tenaga surya, ketersediaan data pengukuran intensitas radiasi matahari sangat dibutuhkan. Data intensitas radiasi

matahari juga dibutuhkan dalam menentukan parameter tingkat kenyamanan termal untuk desain arsitektur bangunan ramah lingkungan (Adrian, 2024). Di berbagai perusahaan pembangkit listrik, data ini menjadi dasar informasi utama yang digunakan untuk operasional sistem energi (Mubiyn & Ilminnafik, 2024).

Salah satu parameter terpenting dari radiasi matahari adalah radiasi langsung atau *Direct Normal Irradiance* (DNI). DNI merupakan spektrum energi matahari yang menjalar lurus dan langsung mencapai permukaan bumi tanpa mengalami hamburan oleh partikel atmosfer. Parameter spesifik ini hanya dapat diukur menggunakan pyrheliometer. Desain optik pyrheliometer dibatasi oleh *full opening view angle* yang sangat rapat, yaitu kurang dari 5 derajat, sehingga instrumen tersebut beroperasi dengan *sun tracker* (Nouri dkk., 2015). Elemen pendeteksi utama yang digunakan dalam Pyrheliometer adalah *thermopile*. Mekanisme ini bekerja berdasarkan prinsip termodinamika menggunakan konversi gradien suhu antara permukaan lapisan hitam yang menyerap radiasi dan permukaan referensi menjadi keluaran sinyal tegangan miliVolt (mV) yang linier terhadap intensitas cahaya.

Dalam menjaga kualitas dan akurasi data yang dihasilkan, kalibrasi berkala harus dilakukan sesuai standar global dokumen ISO/IEC 17025: 2017. Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) memiliki prosedur pelaksanaan kalibrasi instrumen radiasi secara *outdoor* dengan pedoman pada dokumen ISO 9059:1990. Dalam proses ini, keluaran pyrheliometer operasional disandingkan berdampingan dengan pyrheliometer absolut bertipe *cavity* standar, yang mengantongi ketertelusuran metrologi hingga ke *World Radiometric Reference* (WRR) di Davos, Swiss (Mudike dkk., 2021). Kendati metode *outdoor* tersebut merupakan praktik baku di ranah internasional, pendekatan kalkulasi di dalamnya masih meninggalkan celah kelemahan matematis. Kalibrasi konvensional murni bertumpu pada regresi linier, yang tujuan akhirnya menghasilkan faktor koreksi. Hal ini bertolak belakang dengan realitas termodinamika, Dimana sensor *thermopile* pada dasarnya memiliki sensitivitas yang mudah terdistorsi secara non-linier oleh fluktuasi variabel meteorologi yang ekstrem dan dinamis di lapangan (Cobos dkk., 2018).

Ketidakmampuan metode kalibrasi linier konvensional dalam menetralisir dinamika cuaca menghasilkan *residual error* (Kim dkk., 2019). Apabila residu terakumulasi dari waktu ke waktu tanpa kompensasi algoritmik, kualitas data iradiasi akan mengalami *drift* (pergeseran), merusak validitas pencatatan cuaca, serta menaikkan *budget* ketidakpastian instrumen di level yang tidak bisa ditoleransi (Balenzategui dkk., 2022). Oleh sebab itu, diperlukan inovasi di luar perhitungan statistika linier tradisional. Penelitian ini menawarkan metodologi dengan mengadopsi kecerdasan buatan. Jaringan saraf tiruan mendalam terbukti memiliki daya komputasi luar biasa kuat untuk membedah, memetakan, dan menyusun koefisien determinasi data sekuensial *time-series* yang multivariat secara non-linier (Arifin & Hyunjin, 2023). Arsitektur *Recurrent Neural Network* (RNN), melalui variannya seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), lahir dengan anatomi seluler spesifik berbekal unit memori gerbang (*gating mechanism*) yang didesain mumpuni menangani deret masalah ketergantungan temporal Panjang (Asad dkk., 2025).

Penelitian ini merancang komputasi hibrida berstruktur *Bidirectional*, yaitu Bi-LSTM dan Bi-GRU. Melalui evaluasi antara kedua arsitektur tersebut, penelitian ini bertujuan mengintegrasikan data suhu, angin dan SZA untuk menghasilkan model prediktif verifikasi virtual (Jaihuni dkk., 2022). Model verifikasi virtual ini dikembangkan untuk mengevaluasi dan merekonstruksi keluaran pyrheliometer CHP1 berdasarkan pola hubungan antara DNI dan variabel meteorologi. Karena arsitektur bidirectional memproses informasi dalam dua arah pada satu jendela sekuensial, model pada penelitian ini diposisikan sebagai metode verifikasi offline atau near-real-time setelah seluruh data dalam jendela input tersedia. Oleh karena itu, penelitian ini tidak mengklaim bahwa model dapat langsung digunakan sebagai sistem koreksi real-time kausal tanpa latensi.

PENELITIAN RELEVAN

Kaitannya dengan kerentanan fisik Instrument terhadap dinamika cuaca,Cobos dkk., (2018) memaparkan bahwa konstanta faktor kalibrasi pyrheliometer terdistorsi sebagai fungsi linier dari sudut elevasi matahari, meskipun belum membahas parameter angin dan suhu secara komprehensif. Dalam ketidakpastian pengukuran, Balenzategui dkk. (2022) menyatakan faktor pembentuk ketidakpastian kalibrasi standar *absolute cavity* secara deterministik, namun belum mendayagunakan kemampuan adaptif algoritma cerdas. Untuk akurasi, Azouzoute dkk., (2019) mengevaluasi

pyranometer thermopile dengan referensi, namun penelitian tersebut berfokus pada radiasi global, bukan radiasi langsung sesuai standar pyrheliometer.

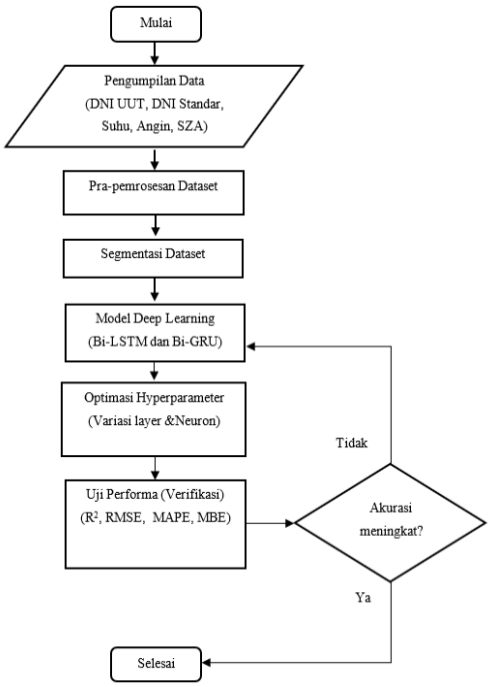
Kaitannya dengan regresi linier, penggunaan *Deep Learning* menjadi paradigma baru. Arifin & Hyunjin (2023) mendemonstrasikan keunggulan *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dibanding metode empirik konvensional dalam mengekstraksi nilai radiasi DNI, mengurangi RMSE hingga di bawah 26%. Elaborasi pemodelan hibrida oleh Vanlalchhuanawmi dkk., (2025) memvalidasi bahwa algoritma turunan *Recurrent Neural Network* (RNN) mempunyai performa yang unggul terhadap fluktuasi deret waktu jangka panjang. Parasyris dkk., (2022) juga menyatakan bahwa jaringan LSTM memiliki keunggulan dalam menangkap fitur kecepatan angin dan suhu jauh melebihi metode otoregresif klasik SARIMA.

Pada penelitian Jaihuni dkk., (2022), yang melakukan komparasi beberapa model RNN dalam prediksi radiasi matahari. Penelitian tersebut menyatakan mekanisme komputasi *Bidirectional* memiliki akurasi yang unggul, di mana Bi-GRU unggul pada seluruh metrik evaluasi dengan nilai koefisien determinan 0,958. Keunggulan Bi-GRU divalidasi oleh Kumar dkk., (2024) untuk mengestimasi pasokan fotovoltaik pada cuaca ekstrem.

Kesenjangan penelitian terlihat dari kebanyakan penerapan *Deep Learning* hanya dimanfaatkan sebagai *forecasting* cuaca, bukan untuk kalibrasi instrumen *real-time*. Walaupun terdapat penelitian regresi non-linier untuk *pyranometer* (Viswanath dkk., 2020) dan pemanfaatan Jaringan Saraf Tiruan untuk kalibrasi *cup anemometer* lapangan (Koo & Yoon, 2022), literatur yang membahas verifikasi pyrheliometer standar internasional dengan *deep learning* belum banyak diteliti. Berdasarkan kajian literatur tersebut, kebaruan penelitian ini adalah evaluasi arsitektur Bi-LSTM dan Bi-GRU sebagai model verifikasi virtual untuk merekonstruksi keluaran pyrheliometer CHP1 dengan mempertimbangkan DNI, suhu udara, kecepatan angin, dan Solar Zenith Angle. Model dalam penelitian ini diterapkan pada skenario offline atau near-real-time setelah satu jendela input tersedia, sehingga tidak diposisikan sebagai sistem prediksi real-time kausal tanpa latensi.

METODE PENELITIAN

Metodologi penelitian dirancang menggunakan kerangka kerja eksperimental deskriptif kuantitatif. Desain penelitian ini bertujuan memformulasikan penyelesaian analitik terhadap kelemahan proses kalibrasi fisik pyrheliometer dengan pendekatan pemodelan komputasi deret waktu berbasis *Deep Learning*. Proses rekayasa perangkat lunak ini secara sistematis dibagi menjadi empat tahapan esensial, mulai dari pengumpulan data hingga uji performa, yang alurnya divisualisasikan pada Gambar 1.



Gambar 1. Diagram Alir Perancangan Penelitian

a. Pengumpulan Data
Ruang lingkup pengumpulan data mencakup data primer dan sekunder dari aktivitas observasi eksperimental kalibrasi pyrheliometer di kawasan *rooftop* Kota Kupang, Nusa Tenggara Timur pada 3 dan 4 September 2025. Kota Kupang secara strategis dipilih karena memiliki karakteristik indeks *clear sky* (langit cerah) yang tinggi dan konsisten, meminimalisir gangguan *aureole* yang dapat menurunkan kualitas kalibrasi. Instrumen yang digunakan meliputi Pyrheliometer Uji tipe Kipp & Zonen CHP1 dan Pyrheliometer Standar Referensi tipe Absolute Cavity PM06 yang tertelusur ke *World Radiometric Reference* (WRR). Kedua sensor dipasang sejajar pada *Sun Tracker*. Keluaran instrumen dikumpulkan melalui *datalogger* dengan interval pencatatan setiap 2 menit. Data iklim sekunder berupa Suhu Udara Ambien (TA) dan Kecepatan Angin (WS) diunduh sinkron dari *Automatic Weather Station* (AWS) Center BMKG. Sementara itu, posisi *Solar Zenith Angle* (SZA) dikalkulasi secara matematis melalui bahasa pemrograman Python berdasarkan koordinat absolut dan waktu pencatatan.

b. Pra-pemrosessan Data
Himpunan data mentah dibersihkan melalui mekanisme *Quality Control* (QC) ketat yang terdiri dari *Range Check* dan *Step Check*. Data diisolasi khusus pada intensitas Iradiasi Standar (DNI) di atas 700 W/m². Data dengan deviasi antara PM06 dan CHP1 yang melebihi batas toleransi 2% diidentifikasi sebagai *outlier* dan dihapus dari set analitik. Setelah dataset dilakukan QC, seluruh matriks input dinormalisasi menggunakan StandardScaler (*Z-score normalization*) guna menjamin komputasi konvergensi gradien berlangsung tanpa bias antar fitur. Persamaan normalisasi data dirumuskan sebagai berikut:

$$Z_{norm} = \frac{z_i - \mu}{\sigma} \quad (1)$$

c. Perancangan Segmentasi dan Arsitektur Model
Penelitian ini membangun dua kerangka evaluasi pengujian untuk membuktikan ketangguhan dan elastisitas model terhadap fluktuasi jumlah data pelatihan:
1. Skenario Segmentasi Data 80:10:10: Proporsi 80% alokasi untuk proses pelatihan (*training*), 10% untuk validasi metrik (*validating*), dan sisa 10% untuk pengujian akhir (*testing*).
2. Skenario Sensitivitas 70:15:15: Mengurangi volume pasokan memori pelatihan menjadi 70%, dengan menambah porsi uji validasi dan tes masing-masing 15% untuk menyimulasikan kendala kekurangan data kalibrasi.

Model dirancang menggunakan arsitektur Bi-LSTM dan Bi-GRU. Guna menemukan titik keseimbangan antara generalisasi data dan risiko *overfitting*, dilakukan *Hyperparameter Tuning* menggunakan metode *Grid Search*.

d. Teknik Analisis dan Uji Coba
Evaluasi akhir dari performa jaringan untuk memastikan kelayakannya sebagai instrumen kalibrasi virtual dikuantifikasi menggunakan empat parameter uji presisi matematis, yaitu Koefisien Determinasi (R^2), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *Mean Bias Error* (MBE). Persamaan matematis untuk mengevaluasi kinerja akurasi tersebut dinyatakan dalam rumus berikut:

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

$$\mathrm{RMSE} = \sqrt{\frac{1}{m}\sum_{i=1}^{m}(y_i - \hat{y}_i)^2} \quad (3)$$

$$\mathrm{MAPE} = \frac{100\%}{m}\sum_{i=1}^{m}\left|\frac{\hat{y}_i - y_i}{y_i}\right| \quad (4)$$

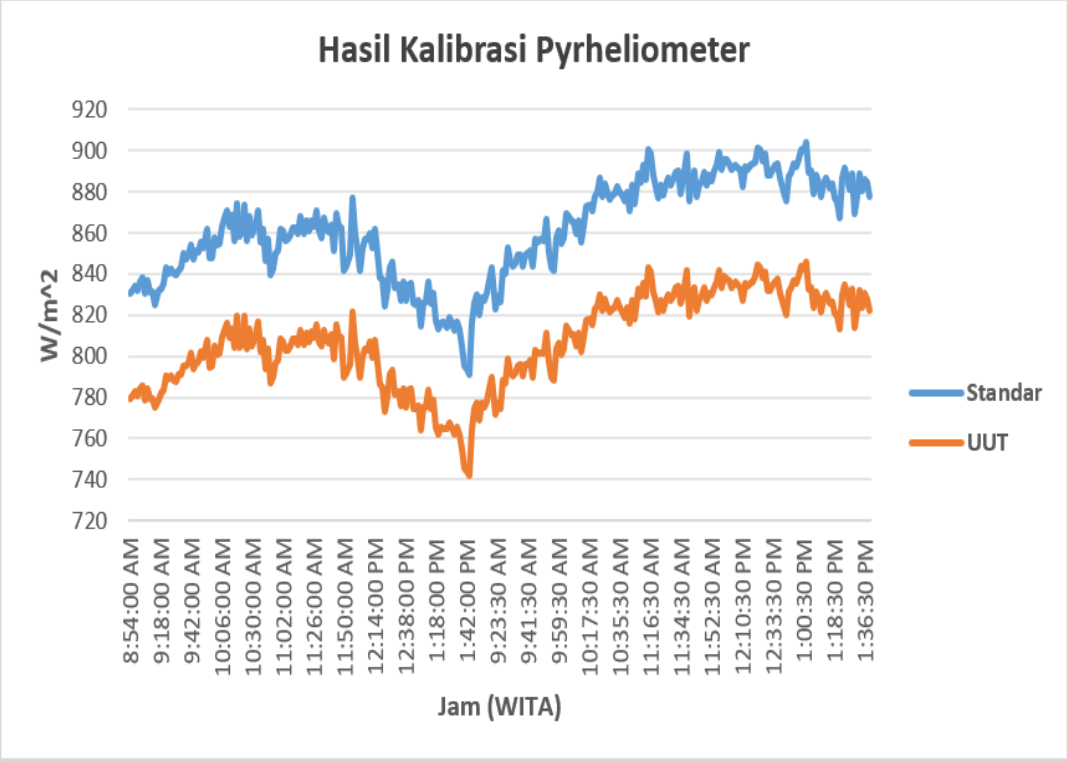
$$\mathrm{MBE} = \frac{1}{m}\sum_{i=1}^{m}(\hat{y}_i - y_i) \quad (5)$$

HASIL DAN PEMBAHASAN

a. Hasil Pra-Pemrosesan data

Secara statistik menunjukkan instrumen pyrheliometer beroperasi dengan baik merespons sinar matahari, di mana kurva pergerakan DNI instrumen standar (PM06) selalu mampu diikuti oleh instrumen uji (CHP1). Akan tetapi, masalah degradasi sensitivitas (*offset*) terlihat sangat jelas. Analisis deskriptif mencatat bahwa nilai rerata PM06 berada pada 861,15 W/m², sementara CHP1 hanya mendeteksi sebesar 806,95 W/m². Terdapat *residual error* sistematis berupa pelemahan bias 54,2 W/m² pada sensor UUT.

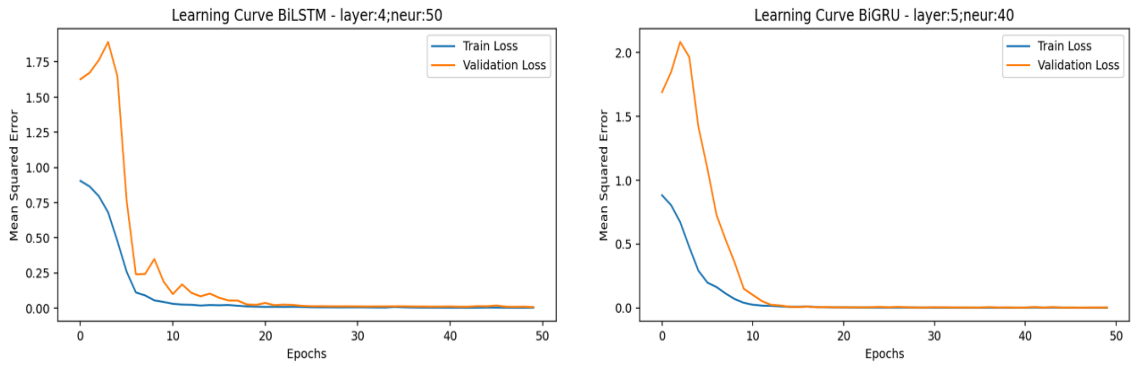
Korelasi pearson menunjukkan mengungkap bahwa bias sensitivitas ini merupakan adanya pengaruh dinamika lingkungan. Iradiasi DNI memunculkan korelasi positif moderat terhadap suhu ambien udara sebesar 0,46, hal ini menunjukkan kenaikan radiasi memicu fluktuasi panas pada *thermopile*, sejalan dengan prinsip kerentanan sensor termal yang dijelaskan oleh Nouri dkk. (2015). DNI juga menunjukkan hubungan berbanding terbalik dengan koefisien korelasi pearson sebesar -0,31 terhadap SZA. Hal ini menunjukkan semakin besar sudut zenith, partikel atmosfer yang ditembus semakin tebal sehingga DNI melemah. Fenomena ini secara empiris mengonfirmasi studi Cobos et al. (2018) yang menegaskan bahwa elevasi matahari mendistorsi konstanta kalibrasi secara langsung. Selisih rata-rata sebesar 54,2 W/m² menunjukkan adanya bias awal antara keluaran CHP1 dan PM06 pada dataset penelitian. Selisih tersebut selanjutnya menjadi dasar pengembangan model verifikasi virtual yang memetakan keluaran CHP1 beserta variabel suhu udara, kecepatan angin, dan Solar Zenith Angle terhadap nilai DNI referensi PM06. Efektivitas model dalam mengurangi residual dievaluasi berdasarkan nilai RMSE, MAPE, MBE, dan koefisien determinasi pada data pengujian.



Gambar 2. Hasil Kalibrasi Pyrheliometer

b. Analisi *Learning Curve*

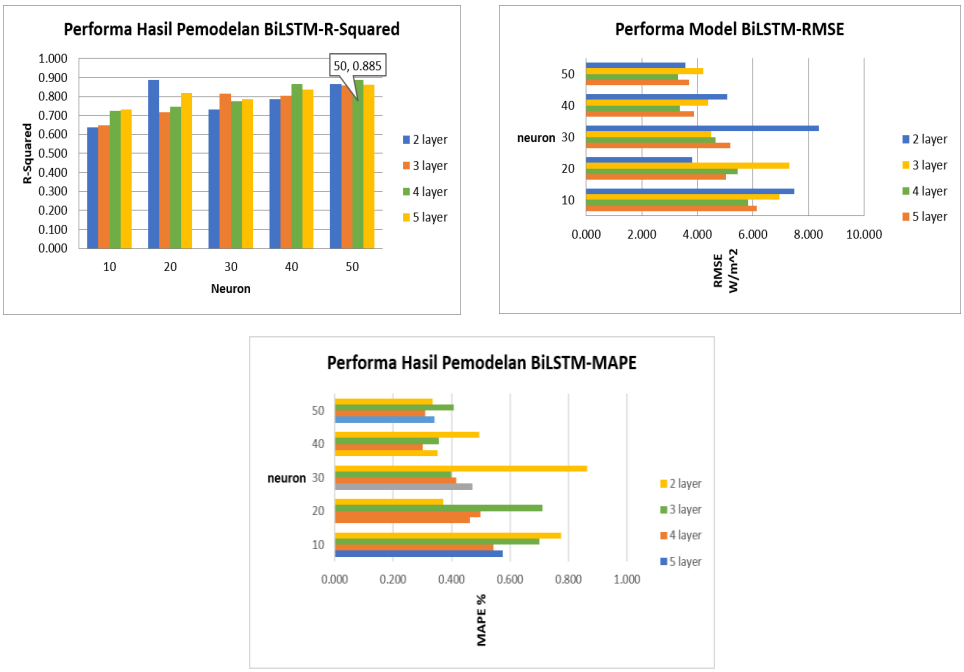
Profil konvergensi pembelajaran algoritma membuktikan stabilitas internal model selama iterasi. Pada segmentasi 80:10:10, model Bi-LSTM menunjukkan pergerakan yang lambat namun konsisten, dengan *validation loss* memuncak di awal sebelum akhirnya stabil pada *epoch* ke-20. Hal ini berbanding terbalik dengan model Bi-GRU menampilkan efisiensi arsitektur yang luar biasa cepat, menempuh stabilitas konvergensi garis paralel mulai di siklus putaran ke-12.



Gambar 3. Kurva Pembelajaran Model Bi-LSTM dan Bi-GRU

c. Analisis Pengujian DNI Pyrheliometer Menggunakan Bi-LSTM

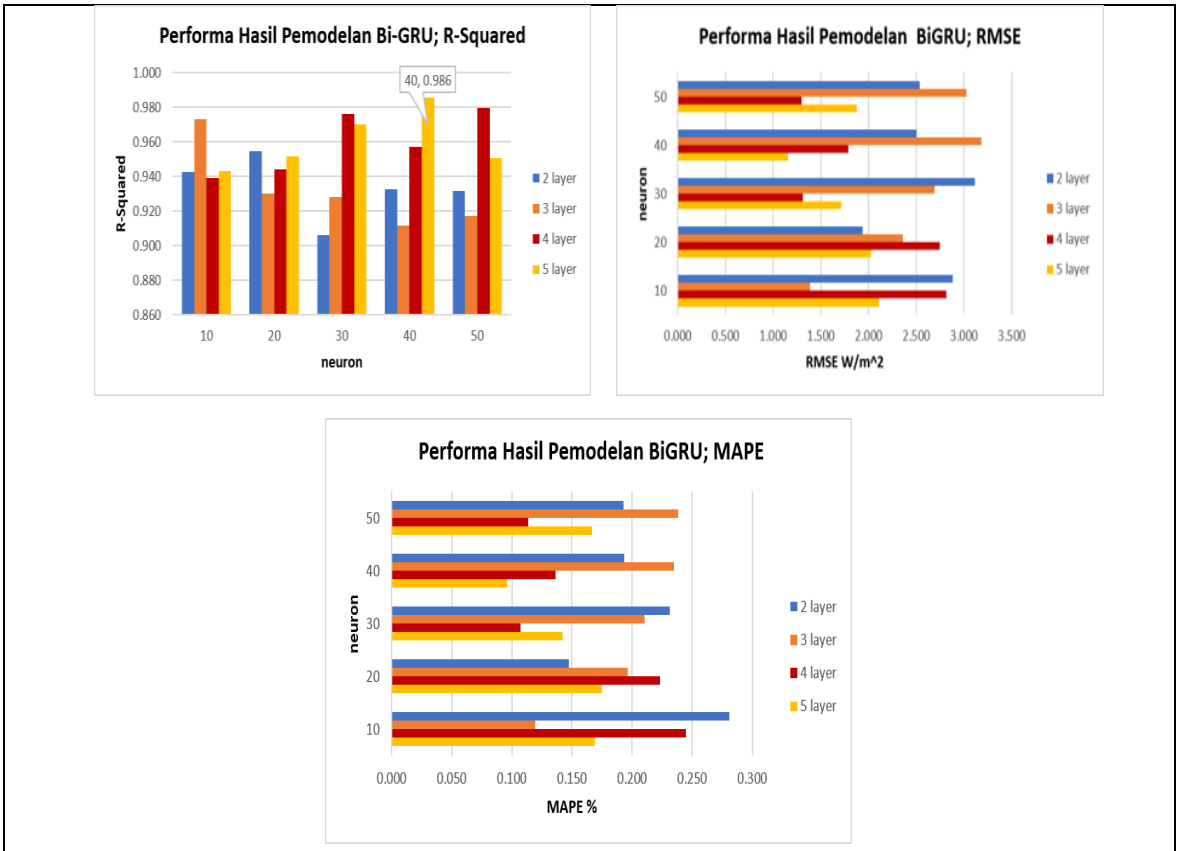
Pengujian DNI Pyrheliometer berbasis Bi-LSTM divariasikan berdasarkan kombinasi jumlah *hidden layer* 2 sampai 5 *layer* dan lebar neuron 10 sampai 50 *neuron* dengan interval 10 untuk tiap-tiap *layer*, dijalankan dengan *batch size* 32 dan selama 50 *epoch*, fungsi optimasi dan aktifasi mengunakan Adam dan ReLU menghasilkan koefisien determinasi sebesar 0,885, RMSE sebesar 3,301 W/m², dan MAPE sebesar 0,309%. Eksperimen juga mengonfirmasi kelemahan struktural memori mekanis Bi-LSTM; menambah kedalaman menjadi 5 *layer* berujung pada ledakan galat, di mana RMSE membengkak menjadi 6,139 W/m². Pada fase ini, jaringan Bi-LSTM terlampau masif sehingga menghafal *noise* cuaca, memicu *overfitting*.



Gambar 4. Performa Model Bi-LSTM

Berdasarkan gambar 4 menunjukkan model ini menghasilkan koefisien determinasi sebesar 0.885, yang menunjukkan hubungan linier yang sangat kuat karena mampu menjelaskan 88.5% variasi data aktual. Meskipun arsitektur 2 *layer* memiliki koefisien determinasi yang sedikit lebih tinggi yaitu 0.886, arsitektur 4 *layer* tetap dipilih karena unggul secara signifikan pada parameter penekanan *error*. Model 4 *layer* ini menghasilkan RMSE terendah dari total 20 percobaan, yakni sebesar 3.301 W/m². Penambahan arsitektur menjadi 5 *layer* terbukti membuat model menjadi *overfitting*, yang ditandai dengan meningkatnya nilai RMSE menjadi 6.139 W/m². Tingkat MAPE model ini tergolong sangat presisi di angka 0.309%. Nilai tersebut sangat minimum dan berada jauh di bawah ambang batas toleransi pada umumnya yaitu sebesar 5% hingga 10%.

d. Analisis Pengujian DNI Pyrheliometer Menggunakan Bi-GRU
Pengujian DNI Pyrheliometer berbasis Bi-GRU divariasikan berdasarkan kombinasi jumlah kedalaman *hidden layer* 2 sampai 5 *layer* dan lebar neuron 10 sampai 50 *neuron* dengan interval 10 untuk tiap-tiap *layer*, dijalankan dengan *batch size* 32 dan selama 50 *epoch*, fungsi optimasi dan aktifasi mengunakan Adam dan ReLU



Gambar 5. Performa Model Bi-GRU

Berdasarkan Gambar 5 menunjukkkan kombinasi arsitektur 5 *hidden layer* dengan 40 neuron ditetapkan sebagai model Bi-GRU terbaik karena menghasilkan tingkat akurasi tertinggi di antara seluruh pengujian. Model ini mencapai nilai koefisien determinasi sebesar 0.986. Angka ini menunjukkan hubungan linier yang sangat kuat, di mana model mampu menjelaskan variasi karakteristik data aktual DNI hingga 98,6% dengan sangat presisi. Model ini menghasilkan RMSE terendah dibandingkan seluruh hasil pengujian lainnya, yaitu hanya sebesar 1.153 W/m². Nilai MAPE yang dihasilkan pada penelitian ini merupakan terkecil yaitu sebesar 0.096%. Nilai MAPE terendah ini mengonfirmasi bahwa hasil prediksi model memiliki tingkat akurasi dan presisi yang sangat tinggi.

e. Analisis Uji Sensitivitas dan Perbandingan Arsitektur
Pengujian dilakukan pada segmentasi data 70:15:15. Pengurangan 10% data latih ini mengganggu bobot memori mekanis Bi-LSTM, di mana konfigurasi terbaiknya mundur ke 3 *layer* dengan 50 neuron, nilai korelas menurun menjadi 0,791, dan RMSE meningkat menjadi 4,894 W/m². Sebaliknya, arsitektur Bi-GRU tetap memiliki akurasi yang unggul pada konfigurasi 3 *layer* 40 neuron, menghasilkan nilai koefisien determinasi 0,885 dan MAPE 0,261%. Perbandingan hasil pengujian menunjukkan bahwa model bidirectional menghasilkan kinerja yang lebih baik dibandingkan model unidirectional berdasarkan metrik evaluasi yang digunakan. Model LSTM unidirectional memperoleh koefisien determinasi sebesar 0,851 dan RMSE sebesar 15,803 W/m², sedangkan model GRU unidirectional memperoleh koefisien determinasi sebesar 0,770 dan RMSE sebesar 19,202 W/m². Sementara itu, model Bi-LSTM dan Bi-GRU menghasilkan nilai kesalahan yang lebih rendah. Hasil tersebut menunjukkan bahwa pemrosesan urutan data dalam dua arah pada satu jendela input membantu model mengenali pola hubungan antara DNI, suhu

udara, kecepatan angin, dan Solar Zenith Angle secara lebih baik. Meskipun demikian, penelitian ini tidak melakukan uji signifikansi statistik, sehingga perbedaan performa tersebut diinterpretasikan berdasarkan nilai metrik evaluasi model.

SIMPULAN

Pemodelan nonlinier menggunakan arsitektur Bi-LSTM dan Bi-GRU telah dikembangkan sebagai model verifikasi virtual untuk merekonstruksi keluaran DNI pyrheliometer CHP1 berdasarkan instrumen referensi PM06. Model mengintegrasikan keluaran CHP1 dengan variabel suhu udara, kecepatan angin, dan Solar Zenith Angle untuk mempelajari hubungan nonlinier antara respons instrumen dan kondisi lingkungan. Pada skenario pembagian data 80:10:10, model Bi-GRU dengan konfigurasi lima hidden layer dan 40 neuron menghasilkan performa terbaik dengan koefisien determinasi sebesar 0,986, RMSE sebesar 1,153 W/m², dan MAPE sebesar 0,096%. Model Bi-GRU juga menunjukkan performa yang lebih baik dibandingkan Bi-LSTM dan model unidirectional berdasarkan metrik evaluasi yang digunakan. Pada skenario 70:15:15, performa Bi-GRU menurun, tetapi masih menghasilkan koefisien determinasi sebesar 0,885 dan MAPE sebesar 0,261%. Hasil tersebut menunjukkan bahwa Bi-GRU memiliki potensi sebagai prototipe model verifikasi virtual untuk mendukung evaluasi keluaran pyrheliometer CHP1. Namun, penelitian ini masih terbatas pada data observasi selama dua hari di satu lokasi, satu unit instrumen uji, satu instrumen referensi, serta kondisi iradiasi tertentu. Oleh karena itu, hasil penelitian belum dapat digeneralisasikan sebagai dasar implementasi langsung pada seluruh jaringan observasi BMKG. Validasi eksternal menggunakan periode pengamatan yang lebih panjang, musim dan lokasi yang berbeda, variasi tipe instrumen, serta kondisi cuaca yang lebih beragam diperlukan sebelum model dapat dipertimbangkan untuk penerapan operasional.

DAFTAR PUSTAKA

Adrian, B. (2024). *Rancang Bangun Sistem Monitoring Intensitas Radiasi Matahari Menggunakan Sensor Pyranometer di Gedung DTNTF UGM*.

Afif, F., & Martin, A. (2022). *Tinjauan Potensi dan Kebijakan Energi Surya di Indonesia*. *6*(1), 43–52.

Arifin, R., & Hyunjin, L. (2023). Enhancing the Performance of Solar Radiation Decomposition Models Using Deep Learning. *Journal of the Korean Solar Energy Society*, *43*(3), 73–86. https://doi.org/10.7836/kses.2023.43.3.073

Asad, D. M., Shahriar, M., & Chowdhury, A. H. (2025). Load Forecasting for Dhaka City Using RNN, LSTM, and GRU Architectures with Meteorological and Temporal Data. *2025 International Conference on Electrical, Computer and Communication Engineering (ECCE)*, 1–6. https://doi.org/10.1109/ECCE64574.2025.11013779

Azouzoute, A., Merrouni, A. A., Bennouna, E. G., & Gennioui, A. (2019). Accuracy measurement of pyranometer vs reference cell for PV resource assessment. *Energy Procedia*, *157*, 1202–1209. https://doi.org/10.1016/j.egypro.2018.11.286

Balenzategui, J. L., Molero, M., Silva, J. P., Fabero, F., Cuenca, J., Mejuto, E., & De Lucas, J. (2022). Uncertainty in the Calibration Transfer of Solar Irradiance Scale: From Absolute Cavity Radiometers to Standard Pyrheliometers. *Solar*, *2*(2), 158–185. https://doi.org/10.3390/solar2020010

Cobos, F., Valenzuela, R. X., Ramírez, L., Zarzalejo, L. F., Nouri, B., Wilbert, S., & García, G. (2018). Assessment of the impact of meteorological conditions on pyrheliometer calibration. *Solar Energy*, *168*, 44–59. https://doi.org/10.1016/j.solener.2018.03.046

Jaihuni, M., Basak, J. K., Khan, F., Okyere, F. G., Sihalath, T., Bhujel, A., Park, J., Lee, D. H., & Kim, H. T. (2022). A novel recurrent neural network approach in forecasting short term solar irradiance. *ISA Transactions*, *121*, 63–74. https://doi.org/10.1016/j.isatra.2021.03.043

Kim, T., Ko, W., & Kim, J. (2019). Analysis and Impact Evaluation of Missing Data Imputation in Day-ahead PV Generation Forecasting. *Applied Sciences*, *9*(1), 204. https://doi.org/10.3390/app9010204

Koo, J., & Yoon, S. (2022). In-situ sensor virtualization and calibration in building systems. *Applied Energy*, *325*, 119864. https://doi.org/10.1016/J.APENERGY.2022.119864

Kumar, R., Krishna Goswami, B., Motiram Mhatre, S., & Agrawal, S. (2024). Naive Bayes in Focus: A Thorough Examination of its Algorithmic Foundations and Use Cases. *International Journal of Innovative Science and Research Technology (IJISRT)*, 2078–2081. https://doi.org/10.38124/ijisrt/IJISRT24MAY1438

Mubiyn, S. N., & Ilminnafik, N. (2024). Pengukuran Intensitas Radiasi Matahari di Wilayah Kabupaten Nganjuk Tahun 2016. *Jurnal Energi Baru dan Terbarukan*, *5*(1), 20–26. https://doi.org/10.14710/jebt.2024.21580

Mudike, R., Barbate, I., Tripathi, A. K., Nikhil, P. G., & Banerjee, C. (2021). Calibration of solar radiometers with traceability to the world radiometric reference using an absolute cavity radiometer. *Measurement: Journal of the International Measurement Confederation*, *179*. https://doi.org/10.1016/j.measurement.2021.109475

Nouri, B., Wilbert, S., García, G., Ramírez, L., Zarzalejo, L., Valenzuela, R., Ferrera, F., & Prahl, C. (2015). Report on established joint calibration facility for pyrheliometers at PSA to be operated as ACCESS facility. Dalam *Sfera2 Project. FP7-INFRA-312643*. http://sfera2.sollab.eu/uploads/images/jra/Files/SFERA2PyrhelCal_D11_2_151221.pdf

Parasyris, A., Alexandrakis, G., Kozyrakis, G. V, Spanoudaki, K., & Kampanis, N. A. (2022). Predicting Meteorological Variables on Local Level with SARIMA, LSTM and Hybrid Techniques. *Atmosphere*, *13*(878). https://doi.org/10.3390/atmos13060878

Shahsavari, A., & Akbari, M. (2018). Potential of solar energy in developing countries for reducing energy-related emissions. *Renewable and Sustainable Energy Reviews*, *90*, 275–291. https://doi.org/10.1016/J.RSER.2018.03.065

Vanlalchhuanawmi, C., Deb, S., Islam, M. M., & Ustun, T. S. (2025). Solar radiation prediction: A multi-model machine learning and deep learning approach. *AIP Advances*, *15*(5). https://doi.org/10.1063/5.0237246

Viswanath, A., Kumar M, D., Srihari, B., & Prabhu, E. (2020). Calibration of a Pyranometer using Regression Analysis. *Fifth International Conference on Communication and Electronics Systems (ICCES 2020)*.