

Peramalan Indeks Ultraviolet di Kota Bandung Menggunakan Metode *Long Short-Term Memory*

IDA BAGUS WIRA KRISHNA SATYAPUTRA, HERLINA NAPITUPULU,
NURUL GUSRIANI

Departemen Matematika, Fakultas MIPA, Universitas Padjadjaran
Jl. Raya Bandung Sumedang KM 21 Jatinangor Sumedang 45363
Email: ida20001@mail.unpad.ac.id, herlina@unpad.ac.id,
nurul.gusriani@unpad.ac.id

Abstrak

Peramalan nilai indeks Ultraviolet (UV) merupakan salah satu langkah proaktif yang memungkinkan masyarakat memitigasi risiko kesehatan akibat paparan UV berlebih, sekaligus membantu dalam manajemen lingkungan. Penelitian ini bertujuan untuk menghasilkan nilai peramalan indeks UV di Kota Bandung pada tanggal 1–30 April 2024 menggunakan Metode *Long Short-Term Memory* (LSTM). Metode LSTM merupakan pengembangan dari metode *Recurrent Neural Network* (RNN). RNN diubah dengan menambahkan mekanisme *gate* untuk menyimpan informasi jangka panjang sehingga mengurangi resiko munculnya *exploding gradients* dan *vanishing gradients*. Model LSTM dalam penelitian ini dibangun menggunakan 1 *input layer* dengan 400 unit *cell* dan 1 *output dense layer* dengan fungsi *update* bobot *adam optimizer*, *randomizer* bobot *Glorot uniform distribution*, dan 400 jumlah *epoch*. Performa model peramalan diuji menggunakan RMSE dan MAPE. Pada data *training* menghasilkan nilai RMSE sebesar 0,28 dan MAPE sebesar 11%. Untuk data *testing* menghasilkan nilai RMSE sebesar 0,48 dan MAPE sebesar 14%. Hasil peramalan indeks UV di Kota Bandung menunjukkan bahwa selama bulan April nilai rata-rata indeks UV adalah 2,27, hal ini mengartikan bahwa masyarakat Kota Bandung dapat beraktivitas diluar tanpa perlu mengkhawatirkan bahaya sinar UV.

Kata kunci: Peramalan; machine learning; long short term memory; indeks UV.

Abstract

Forecasting Ultraviolet (UV) index values is one of the proactive measures that allows people to mitigate health risks due to excessive UV exposure, while also assisting in environmental management. This research aims to produce UV index forecasting values in Bandung City on 1-30 April 2024, using the Long Short-Term Memory (LSTM) Method. The LSTM method is a development of the Recurrent Neural Network (RNN) method. RNN is changed by adding a gate mechanism to store long-term information so as to reduce the risk of exploding gradients and vanishing gradients. The LSTM model in this study was built using 1 input layer with 400 unit cells and 1 output dense layer with adam optimizer weight update function, uniform distribution Glorot weight randomizer, and 400 number of epochs. The performance of the forecasting model was tested using RMSE and MAPE. The training data resulted in an RMSE value of 0.28 and MAPE of 11%. For testing data, the RMSE value is 0.48 and the MAPE is 14%. The results of forecasting the UV index in Bandung City show that during April the average value of the UV index is 2.27, this means that the people of Bandung city can do activities outside without worrying about the dangers of UV rays.

Keywords: Forecasting; machine learning; long short term memory; UV index.

1. PENDAHULUAN

Penelitian tentang prediksi maupun klasifikasi indeks ultraviolet (UVI) telah dilakukan di beberapa negara, dengan fokus pada metodologi dan kondisi lingkungan yang berbeda. Studi-studi tersebut bertujuan untuk meningkatkan kesehatan masyarakat dengan memberikan prakiraan UVI yang akurat, yang membantu mengurangi risiko yang terkait dengan paparan sinar UV. Penelitian tersebut mencakup berbagai wilayah, termasuk Australia, Qatar, Kanada, dan Indonesia. Penelitian [1] berfokus pada Indeks UV di Kanada, yakni mengoptimalkan penentuan UVI menggunakan model prediksi numerik Global Environmental Multiscale (GEM) dari Environment and Climate Change Canada (ECCC). Studi tersebut melibatkan kode transfer radiasi resolusi spektral tinggi untuk meningkatkan prakiraan UVI di bawah kondisi langit cerah maupun berawan. Penelitian [2] berfokus pada negara Qatar, sebuah negara di Semenanjung Arab, yang telah mengembangkan kemampuan peramalan Indeks UV khusus untuk lingkungan yang ‘kaya’ debu. Studi tersebut menggunakan model WRF-Chem (*Weather Research and Forecasting model coupled with Chemistry*) untuk memprediksi tingkat Indeks UV terkhusus untuk kondisi langit cerah dan badai debu dari data yang diambil satelit OMI Aura NASA. Penelitian [3] menggunakan teknik klasifikasi untuk mengklasifikasikan kategori tingkat indeks UV untuk memberikan rekomendasi berupa himbauan terhadap aktivitas sehari-hari dari dampak sinar UV di Indonesia, negara tropis dengan paparan sinar UV yang tinggi. Penelitian [4] mengembangkan model Convolutional Neural Network yang diintegrasikan dengan Long Short-Term Memory Network (CLSTM), untuk memprediksi UVI di Brisbane, Australia. Studi prediksi indeks UV lainnya di Australia oleh [5] menggunakan metode yang disebut dengan Model Enhanced Joint Hybrid Explainable Deep Neural Network (EJH-X-DNN). Selain penelitian-penelitian tersebut, pada penelitian [6] metode LSTM digunakan untuk meramalkan UVI dengan memodelkannya sebagai masalah deret waktu. Pada penelitian tersebut sebuah perangkat lunak dikembangkan untuk mengumpulkan data dari kumpulan *soft sensors*. Model *Long Short Term Memory* (LSTM), sangat cocok untuk peramalan deret waktu karena kemampuannya untuk menangkap dependensi jangka panjang [7] bahkan mampu memodelkan pola temporal yang kompleks [8]. Hal ini membuat model ini ideal untuk memprediksi UVI, yang dipengaruhi oleh berbagai faktor temporal seperti waktu dan kondisi cuaca [6].

Kajian dengan objek peramalan tingkat indeks UV di Kota Bandung menggunakan LSTM saat ini belum ada. Hal ini menjadi motivasi dilakukannya penelitian untuk peramalan tingkat indeks UV di Kota Bandung menggunakan model Long Short-Term Memory (LSTM). Lokasi Indonesia yang berada di dekat khatulistiwa menyebabkan tingginya paparan radiasi UV, yang dapat menimbulkan risiko kesehatan seperti kerusakan kulit dan kanker. Dengan pemanasan global yang memperburuk intensitas radiasi UV, kesadaran akan paparan UV menjadi sangat penting. LSTM dipilih karena kinerjanya yang lebih baik dibandingkan metode tradisional seperti ARIMA [9]. Kinerja model dalam penelitian ini dievaluasi menggunakan Root Mean Square Error (RMSE) dan Mean Absolute Percentage Error (MAPE), dengan tujuan meramalkan tingkat indeks UV untuk April 2024. Kemampuan model LSTM dalam peramalan tersebut dapat menjadi referensi untuk menyelesaikan masalah peramalan sejenis. Pada implementasinya, hasil peramalan ini dapat dimanfaatkan sebagai dasar untuk menentukan tingkat urgensi serta prioritas tindakan pencegahan yang perlu dilakukan.

2. METODE PENELITIAN

2.1. Ultraviolet Index. Radiasi matahari merupakan faktor alami yang penting karena membentuk iklim bumi dan memiliki pengaruh penting terhadap lingkungan. Spektrum ultraviolet (UV) memainkan peran penting dalam banyak proses di biosfer. UV memiliki beberapa efek positif, tetapi mungkin juga sangat berbahaya jika melebihi batas aman [10]. Beberapa spesies biologis kehilangan kemampuan mereka untuk melindungi diri dari radiasi UV, menyebabkan subjek mengalami kerusakan yang parah. Hal ini juga berlaku untuk tubuh manusia, khususnya kulit dan mata. Manusia harus membatasi paparan sinar matahari dengan menggunakan tindakan perlindungan agar tidak menyebabkan penyakit. Paparan sinar matahari yang berlebihan dapat memainkan peran utama dalam mengembangkan kanker kulit [11], menyebabkan kerusakan pada mata [12], dan mempengaruhi sistem kekebalan tubuh [13]. Indeks UV (UVI) adalah parameter penting yang dirancang untuk menginformasikan masyarakat tentang potensi risiko kesehatan yang terkait dengan paparan ultraviolet (UV) [14]. UVI berfungsi sebagai indikator tingkat radiasi UV, membantu individu memahami bahaya paparan UV dan mengambil tindakan pencegahan yang diperlukan.

Indeks UV diperkenalkan di Kanada pada tahun 1992 sebagai tanggapan terhadap kekhawatiran yang berkembang tentang potensi peningkatan radiasi ultraviolet (UV) karena penipisan ozon. Pada tahun 1994, Organisasi Meteorologi Dunia dan Organisasi Kesehatan Dunia mengadopsi indeks ini sebagai indikator standar tingkat UV [15]. Nilai indeks UV dikelompokkan ke dalam kategori paparan. Untuk kategori paparan dan nilai indeks UV dapat dilihat pada Tabel 1.

Apabila nilai indeks UV dibawah 2, masyarakat bisa berada diluar tanpa mengkhawatirkan efek buruk dari sinar UV. Untuk nilai indeks UV 3 sampai 7 masyarakat disarankan untuk menggunakan sunscreen, memakai topi, dan menghindari berlama-lama dibawah matahari pada pukul 10.00 hingga 16.00. Untuk nilai indeks UV 8 sampai 11 keatas masyarakat disarankan untuk tidak berada di luar ruangan pada pukul 10.00 hingga 16.00 dikarenakan tingginya paparan sinar UV [15].

TABEL 1. Indeks *ultraviolet* [14]

Kategori Paparan	Rentang UVI
Rendah	<2
Moderat	3 sampai 5
Tinggi	6 sampai 7
Sangat Tinggi	8 sampai 10
Ekstrim	11+

2.2. Long Short-Term Memory. LSTM (Long Short-Term Memory) adalah jenis arsitektur jaringan saraf tiruan berbasis recurrent neural network (RNN) yang dirancang untuk mengatasi masalah vanishing gradient dan memungkinkan pemrosesan data sekuensial dengan ketergantungan jangka panjang [16]. Model dasar LSTM terdiri dari sebuah cell, input gate, output gate, dan forget gate. Awalnya forget gate bukan bagian dari LSTM namun disarankan pada [17] untuk membuat jaringan kembali ke kondisi awal. Cell mengingat nilai dalam interval waktu yang berubah-ubah dan tiga gates mengatur aliran informasi pada cell [18]. Mekanisme gate ini membantu unit cell memori untuk menyimpan informasi dalam jangka waktu panjang yang membuat gradien kesalahan memiliki nilai yang independen dari perhitungan untuk setiap tahap waktu perhitungan [19].

Seperti pada model Recurrent Neural Networks (RNN), vektor yang dinyatakan sebagai *the hidden state* dari *cell* dinyatakan sebagai $\mathbf{h}_t \in \mathbb{R}^d$ dengan d adalah jumlah *unit cell neuron*. Vektor *candidate cell state* dinyatakan oleh $\tilde{\mathbf{c}}_t \in \mathbb{R}^d$ pada langkah waktu t yang menggambarkan informasi yang bertahan untuk meramalkan *cell state* pada interval waktu selanjutnya. Untuk vektor *cell state* dinyatakan oleh $\mathbf{c}_t \in \mathbb{R}^d$ pada setiap langkah waktu t . Vektor *input gate* dinyatakan sebagai $\mathbf{i}_t \in \mathbb{R}^d$, vektor *output gate* dinyatakan sebagai $\mathbf{o}_t \in \mathbb{R}^d$, dan vektor *forget gate* dinyatakan sebagai $\mathbf{f}_t \in \mathbb{R}^d$, untuk nilai input data dinyatakan sebagai $\mathbf{x}_t \in \mathbb{R}^m$ untuk setiap langkah waktu t . Secara matematis vektor *forget gate*, vektor *input gate*, vektor *candidate cell state*, vektor *output gate*, dan vektor *cell state* dinyatakan sebagai persamaan (1)-(4) [20]. Fungsi aktivasi Sigmoid dan tanh dinyatakan sebagai $\sigma(s)$ dan $\tanh(s)$ diberikan pada persamaan (5)-(6).

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \mathbf{h}_{t-1} + \mathbf{V}_f \mathbf{x}_t + \mathbf{b}_f) \quad (1)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \mathbf{h}_{t-1} + \mathbf{V}_i \mathbf{x}_t + \mathbf{b}_I) \quad (2)$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c \mathbf{h}_{t-1} + \mathbf{V}_c \mathbf{x}_t + \mathbf{b}_c) \quad (3)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o \mathbf{h}_{t-1} + \mathbf{V}_o \mathbf{x}_t + \mathbf{b}_o) \quad (4)$$

$$\sigma(s) = \frac{1}{1 + \exp(-s)} \quad (5)$$

$$\tanh(s) = \frac{\exp(s) - \exp(-s)}{\exp(s) + \exp(-s)} \quad (6)$$

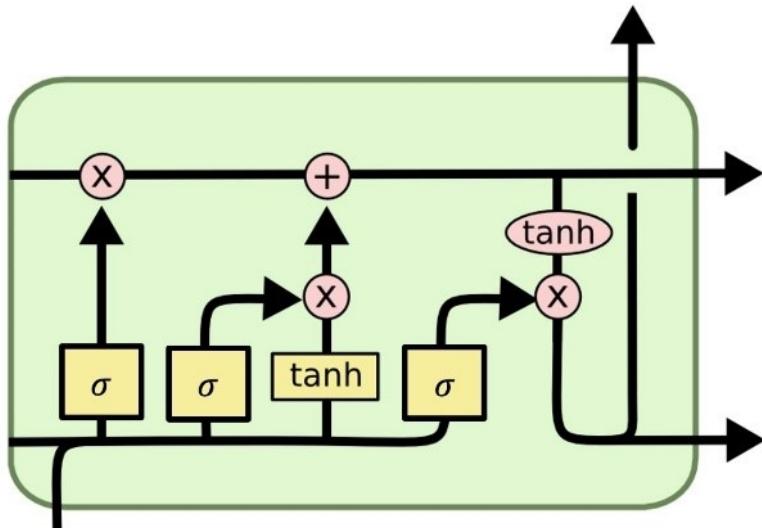
Pada persamaan (1) dan persamaan (2), *forget gate* (\mathbf{f}_t) dan *input gate* (\mathbf{i}_t) menentukan berapa banyak informasi masa lalu yang dapat digunakan dalam *cell state* (\mathbf{c}_t) saat ini dan berapa banyak informasi saat ini yang dapat disebarluaskan untuk peramalan dalam tahap waktu selanjutnya. Fungsi aktivasi pada persamaan (6) yaitu fungsi $\tanh(s)$ digunakan untuk mengatur nilai yang melalui jaringan berada pada rentang nilai $(-1, 1)$, sedangkan fungsi aktivasi Sigmoid (σ) pada persamaan (5) digunakan untuk mentransformasi nilai *input*, *forget*, dan *output* agar berada dalam interval $(0, 1)$.

Forget gate (\mathbf{f}_t) digunakan untuk menentukan informasi yang harus dihapus dari *cell* sebelumnya. Perhitungan dalam *forget gate* (\mathbf{f}_t) menghasilkan nilai antara 0 dan 1, dimana 1 berarti bahwa data disimpan dan 0 berarti data dibuang. Konsep ini diterapkan juga untuk *gate* lainnya yaitu *input gate* (\mathbf{i}_t) dan *output gate* (\mathbf{o}_t). Untuk memperbarui data pada *cell state* yang lama perlu dihapus informasi yang sudah ditentukan sebelumnya pada *forget gate* dan ditambahkan data baru untuk memperbarui *state*. Perhitungan *cell state* dan *hidden state* diuraikan pada persamaan (7) dan (8), dengan \odot merupakan perkalian berdasarkan elemen bersesuaian.

$$\mathbf{c}_t = \mathbf{f}_t \odot \mathbf{c}_{(t-1)} + \mathbf{i}_t \odot \tilde{\mathbf{c}}_t \quad (7)$$

$$\mathbf{h}_t = \mathbf{o}_t \odot \tanh(\mathbf{c}_t) \quad (8)$$

Arsitektur LSTM terdiri dari sekumpulan sub-jaringan yang terhubung secara berulang, yang dikenal sebagai blok memori. Blok memori ini digunakan untuk mempertahankan statusnya dari waktu ke waktu dan mengatur aliran informasi. Struktur LSTM dapat dilihat pada Gambar 1.



GAMBAR 1. Struktur LSTM [21]

2.3. Fully Connected (Dense) Layer. *Fully connected (dense) layer* dapat dideskripsikan sebagai suatu perkalian dense matrix dari vektor input dengan weight matrix yang dapat dilatih, dengan kemungkinan opsi, penambahan vektor bias yang dapat dilatih pada output [22]. Formula output dari masing-masing *layer* dapat dinyatakan dalam persamaan (9),

$$y_{t+1} = a(\mathbf{W}\mathbf{h}_t + \mathbf{b}), \quad (9)$$

dimana \mathbf{W} adalah weight matrix, \mathbf{b} adalah vektor bias, dan a adalah fungsi aktivasi nonlinear. Fungsi aktivasi yang umum digunakan adalah Rectified Linear Unit (ReLU), fungsi sigmoid logistik, atau fungsi tanh.

2.4. Adam Optimizer. *Adam optimizer* merupakan metode algoritma optimisasi berbasis stokastik orde pertama dari fungsi objektif stokastik untuk memperbarui bobot jaringan yang berulang berdasarkan data pelatihan [23]. *Adam optimizer* bertujuan menghitung *adaptive learning rate* untuk setiap parameter. *Learning rate* menentukan seberapa banyak perubahan bobot pada jaringan. *Adam optimizer* banyak digunakan dalam *neural network* dikarenakan mampu bekerja dengan data maupun parameter yang besar [24]. Algoritma *Adam optimizer* adalah sebagai berikut [25].

Require: α : Stepsize
Require: $\beta_1, \beta_2 \in [0, 1]$: Tingkat peluruhan eksponensial untuk estimasi *moment*
Require: $f(\theta)$: Fungsi Objektif stokastik dengan parameter θ
Require: θ_0 : Vektor parameter inisial
 $m_0 \leftarrow 0$ (inisiasi vektor *first moment*)
 $v_0 \leftarrow 0$ (inisiasi vektor *second moment*)
 $t \leftarrow 0$ (inisiasi *timestep*)
while θ_t not converged **do**

```

 $t \leftarrow t + 1$ 
 $g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1})$ . (Hitung gradien pada timestep  $t$ )
 $m_t \leftarrow \beta_1 m_{t-1} + (1 - \beta_1) g_t$  (Perbaharui estimasi first moment yang bias)
 $v_t \leftarrow \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$  (Perbaharui estimasi second raw moment yang bias)
 $\hat{m}_t \leftarrow \frac{m_t}{1 - \beta_1^t}$  (Hitung estimasi first moment dengan bias terkoreksi)
 $\hat{v}_t \leftarrow \frac{v_t}{1 - \beta_2^t}$  (Hitung estimasi second raw moment dengan bias terkoreksi)
 $\theta \leftarrow \theta_{t-1} - \alpha \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}}$  (Perbaharui parameter-parameter)
end while
return  $\theta_{t-1}$  (Parameter yang dihasilkan)

```

2.5. Root Mean Square Error. *Root Mean Square Error* (RMSE) merupakan pengukuran kesalahan dalam forecasting yang menghitung akar kuadrat dari rata-rata kuadrat kesalahan antara nilai aktual dan nilai prediksi [26]. Persamaan RMSE dapat dilihat pada persamaan (10),

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_t - \hat{x}_t^*)^2} \quad (10)$$

Semakin rendah nilai RMSE, kemampuan model peramalan yang digunakan semakin baik dan begitupun sebaliknya.

2.6. Mean Absolute Percentage Error. *Mean Absolute Percentage Error* (MAPE) merupakan pengukuran kesalahan dalam peramalan yang menggunakan kesalahan absolut tiap periode dibagi dengan nilai aktual pada periode tersebut lalu dirata-ratakan dan dicari persentasenya [27]. MAPE dirumuskan sebagai berikut,

$$MAPE = \frac{\sum_{i=1}^n |x_t - \hat{x}_t^*|}{n} \times 100\% \quad (11)$$

MAPE memiliki interval galat yang dapat dijadikan dasar pengukuran atau performa suatu model peramalan, interval nilai beserta kategorinya disajikan pada Tabel 2.

TABEL 2. Kriteria nilai MAPE [28]

Interval nilai MAPE	Kategori
$\leq 10\%$	Model peramalan sangat baik
$10\% < MAPE \leq 20\%$	Model peramalan baik
$20\% < MAPE \leq 50\%$	Model peramalan layak
$> 50\%$	Model peramalan buruk

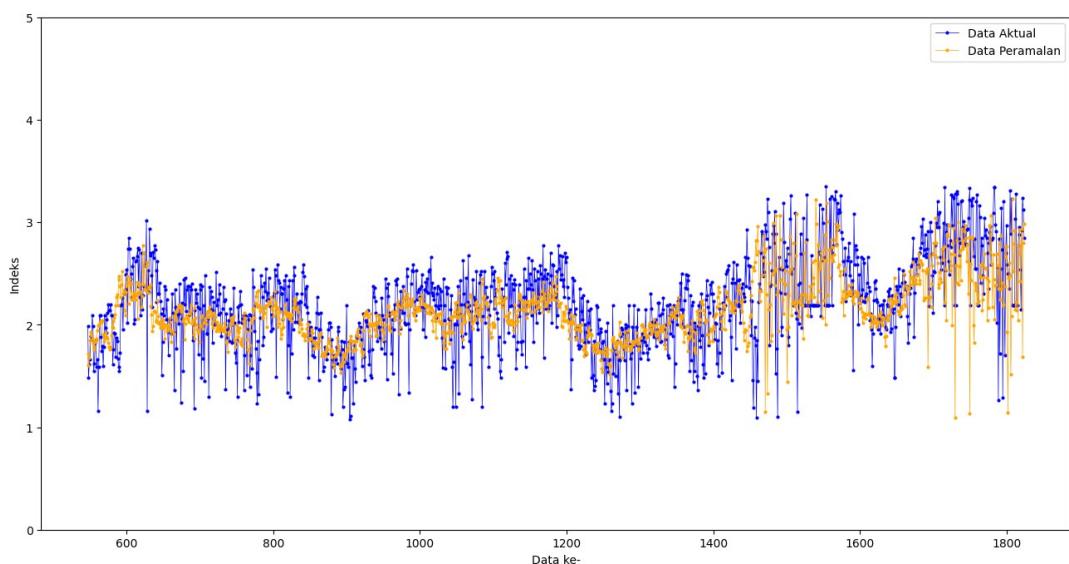
3. HASIL DAN PEMBAHASAN

3.1. Data Penelitian. Objek yang digunakan dalam penelitian ini adalah nilai indeks UV di Kota Bandung. Pada penelitian ini data yang digunakan merupakan data sekunder yang diperoleh dari website <https://power.larc.nasa.gov/data-access-viewer/>. Data nilai indeks UV yang digunakan mulai dari 1 Januari 2019 – 31 Maret 2024. Data diramalkan menggunakan metode LSTM untuk selanjutnya dianalisis performa model peramalan menggunakan RMSE dan MAPE lalu dilakukan peramalan untuk data tanggal 1 – 30 April 2024. Sebelum diramalkan, data yang digunakan melewati tiga tahap *data preprocessing* yang pertama yaitu *cleaning data*. Pada *cleaning data*, dilakukan pemeriksaan adanya *data outliers* yang merupakan data dengan nilai yang berbeda secara signifikan dibandingkan dengan data lain. Digunakan metode kuartil untuk memeriksa adanya *data outlier*. Tahap kedua adalah partisi data. Dalam tahap ini keseluruhan data dibagi menjadi dua dataset berbeda yaitu *data*

training dan *data testing*. Tahap terakhir adalah *scaling data*. Hal ini bertujuan untuk mengubah data menjadi bernilai [0, 1]. *Scaling data* digunakan agar nilai *input* dan *output* bernilai [0, 1] mengikuti sifat fungsi Sigmoid yang menghasilkan nilai *output* (0, 1).

3.2. Peramalan Data Indeks UV di Kota Bandung dengan Metode Long Short-Term Memory. Pada penelitian ini, model LSTM dibangun dengan 400 unit *cell* dan dilatih selama 400 *epoch*. Bobot awal LSTM diinisialisasi menggunakan *glorot uniform distribution*, sedangkan inisialisasi bias adalah nol. Model LSTM menggunakan *huber loss function* dan bobot diperbarui menggunakan *Adam optimizer*. Model yang dipilih untuk peramalan adalah model yang memiliki nilai RMSE dan MAPE terendah dari percobaan yang telah dilakukan. Langkah terakhir adalah mengolah output dari hasil perhitungan *cell* LSTM dengan *dense layer*, lalu menggunakan *inverse scaling* untuk didapatkan hasil akhir peramalan. Eksperimen numerik dilakukan dengan bantuan Bahasa pemrograman Python.

3.3. Performa Model Long Short-Term Memory. Setelah proses pelatihan model dilakukan, didapat hasil peramalan data untuk hari ke-15 hingga ke-1917. Berikut disajikan hasil data training dan testing pada Gambar 2.



GAMBAR 2. Grafik perbandingan data aktual dengan data peramalan indeks UV di Kota Bandung

Pada Gambar 2 terdapat titik-titik berwarna biru yang merupakan data aktual dari 1 Januari 2019 – 31 Maret 2024. Titik berwarna jingga menggambarkan hasil prediksi oleh model LSTM mulai dari 15 Januari 2019 – 31 Maret 2024.

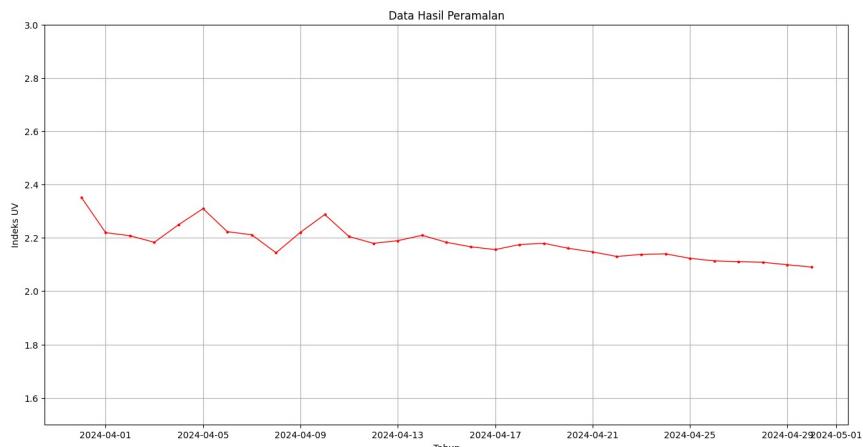
Hasil peramalan indeks UV menghasilkan nilai RMSE untuk data *training* sebesar 0,285 dan RMSE data *testing* sebesar 0,483. MAPE pada *training* diperoleh sebesar 11% dan MAPE data *testing* diperoleh sebesar 14%. Nilai MAPE untuk data *training* dan *testing* menunjukkan model peramalan LSTM masuk kedalam kategori baik.

3.4. Hasil Peramalan Nilai Indeks UV di Kota Bandung. Hasil nilai peramalan nilai Indeks UV di Kota Bandung 30 hari kedepan yakni pada tanggal 1 – 30 April 2024 dapat dilihat dalam Tabel 3.

TABEL 3. Hasil peramalan indeks UV di Kota Bandung

Hari ke-	Tanggal	Hasil peramalan	Hari ke-	Tanggal	Hasil Peramalan
1918	01/04/24	2,28	1933	16/04/24	2,30
1919	02/04/24	2,60	1934	17/04/24	2,32
1920	03/04/24	2,35	1935	18/04/24	2,31
1921	04/04/24	2,21	1936	19/04/24	2,24
1922	05/04/24	2,16	1937	20/04/24	2,19
1923	06/04/24	2,09	1938	21/04/24	2,20
1924	07/04/24	2,44	1939	22/04/24	2,22
1925	08/04/24	2,78	1940	23/04/24	2,19
1926	09/04/24	2,28	1941	24/04/24	2,20
1927	10/04/24	2,56	1942	25/04/24	2,16
1928	11/04/24	2,26	1943	26/04/24	2,16
1929	12/04/24	2,41	1944	27/04/24	2,14
1930	13/04/24	2,46	1945	28/04/24	2,11
1931	14/04/24	2,27	1946	29/04/24	2,10
1932	15/04/24	2,26	1947	30/04/24	2,10

Disajikan pula grafik hasil peramalan indeks UV di Kota Bandung untuk tanggal 1 – 30 April 2024 pada Gambar 3.



GAMBAR 3. Grafik hasil peramalan indeks UV di Kota Bandung tanggal 1 - 30 April 2024

Hasil peramalan indeks UV di Kota Bandung April 2024 menunjukkan rata-rata indeks UV di Kota Bandung bernilai 2,27. Berdasarkan kategori paparan indeks UV, dapat disimpulkan bahwa masyarakat Kota Bandung dapat beraktivitas di luar tanpa perlu mengkhawatirkan bahaya sinar UV selama bulan April.

4. SIMPULAN

Berdasarkan proses penelitian yang telah dilakukan, berikut disampaikan simpulan hasil penelitian yang diperoleh:

- (1) Hasil peramalan pada data indeks UV di Kota Bandung menggunakan metode LSTM dengan 400 unit *cell* dan 400 *epoch* mendapatkan nilai RMSE data *training* sebesar 0,28 dan nilai RMSE data *testing* sebesar 0,43. Nilai MAPE data *training* didapatkan sebesar 11% dan MAPE data *testing* sebesar 14%. Berdasarkan nilai MAPE, performa model LSTM termasuk dalam kategori baik.

- (2) Hasil peramalan nilai indeks UV di Kota Bandung April 2024 memiliki rata-rata indeks UV bernilai 2,27. Masyarakat Kota Bandung dapat beraktivitas di luar tanpa perlu mengkhawatirkan bahaya sinar UV selama bulan April 2024.

Ucapan Terimakasih.

Penulis mengucapkan terima kasih kepada Universitas Padjadjaran yang telah memfasilitasi terlaksananya penelitian ini. Penulis juga mengucapkan terima kasih kepada para penelaah yang telah memberikan saran guna penyempuran artikel ini.

DAFTAR PUSTAKA

- [1] Tereszchuk, K.A., Rochon, Y.J., McLinden, C.A. and Vaillancourt, P.A., 2018, Optimizing UV Index determination from broadband irradiances. *Geoscientific Model Development*, 11(3), pp.1093-1113.
- [2] Roshan, D.R., Koc, M., Abdallah, A., Martin-Pomares, L., Isaifan, R. and Fountoukis, C., 2020, UV index forecasting under the influence of desert dust: evaluation against surface and satellite-retrieved data. *Atmosphere*, 11(1), p.96. doi: 10.3390/ATMOS11010096
- [3] Syahab, A.S., Widiyanto, A., Anuggilarso, L.R. and Wijaya, A.B., 2022, Comparison of Machine Learning Algorithms for Classification of Ultraviolet Index. *Jurnal Teknologi Informasi dan Pendidikan*, 15(2), pp.132-146. doi: 10.24036/jtip.v15i2.692
- [4] Al-Musaylh, M.S., Ghimire, S., Al-Daffaie, K., Ali, M., Deo, R.C., Downs, N., Igoe, D.P. and Parisi, A.V., 2023. Multi-step solar UV index prediction using deep learning methods, doi: <https://doi.org/10.21203/rs.3.rs-2449044/v1>
- [5] Prasad, S.S., Deo, R.C., Salcedo-Sanz, S., Downs, N.J., Casillas-Pérez, D. and Parisi, A.V., 2023, Enhanced joint hybrid deep neural network explainable artificial intelligence model for 1-hr ahead solar ultraviolet index prediction. *Computer Methods and Programs in Biomedicine*, 241, p.107737.
- [6] Oliveira, P., Fernandes, B., Analide, C. and Novais, P., 2020, Multi-step ultraviolet index forecasting using long short-term memory networks. In International Symposium on Distributed Computing and Artificial Intelligence (pp. 187-197). Cham: Springer International Publishing. doi: 10.1007/978-3-030-53036-5_20
- [7] Hochreiter, S. and Schmidhuber, J. 1997. Long short-term memory. *Neural Comput.* 9, 8 (1997), pp. 1735–1780.
- [8] Sonata, I and Heryadi, S., 2024, Comparison of LSTM and Transformer for Time Series Data Forecasting, *2024 7th International Conference on Informatics and Computational Sciences (ICICoS)*, Semarang, Indonesia, 2024, pp. 491-495, doi: 10.1109/ICICoS62600.2024.10636892.
- [9] Zhang, Q., Li, F., Long, F., and Ling, Q., 2018, Vehicle Emission Forecasting Based on Wavelet Transform and Long Short-Term Memory Network,” IEEE Access, vol. 6, pp. 56984–56994, 2018, doi: 10.1109/ACCESS.2018.2874068.
- [10] Vanicek, K., Frei, T., Litynska, Z., and Schmalwieser, A., 1999, “UV-Index for the Public COST-713 participating countries,” 1999.
- [11] Jenan, Al-Matouq. (2024). Advances in Skin Cancer. Available from: 10.5772/intechopen.1005790
- [12] Liu, Z.Z., Chen, S., Yu, T., Ma, G., Huang, X., Yu, C. and Lin, H., 2020, Effects of sunlight on the eye. *International Eye Science*, pp.191-196. doi: 10.18240/IER.2021.01.10
- [13] Grandi, C., Lancia, A., D’Ovidio, M.C.,2024, P-012 Solar Radiation And Immune Effects: Implications For Outdoor Workers In Light Of A Changing Climate, *Occupational Medicine*, Volume 74, Issue Supplement_1, Page 0, <https://doi.org/10.1093/occmed/kqae023.0445>
- [14] Baset, Y.A., Hamed, S., Reda, S., Farag, H., Ghany, H.A. and Faramawy, S., 2023. Design and metrological studies of a reference UV-index detector. *Physica Scripta*, 98(4), p.045509. doi: 10.1088/1402-4896/acc288
- [15] Rehfuss, E, 2002, Global solar UV index: a practical guide. *World Health Organization*.
- [16] Hochreiter, S., and Schmidhuber, J., 1997, Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. doi:10.1162/neco.1997.9.8.17
- [17] Gers, F., Schmidhuber, J., and Cummins, F., 2000, Learning to Forget: Continual Prediction with LSTM, *Neural Comput*, vol. 12, pp. 2451–2471, doi: 10.1162/089976600300015015.
- [18] Van Houdt, G., Mosquera, C., and Nápoles, G, 2020, A review on the long short-term memory model, *Artif Intell Rev*, vol. 53, no. 8, pp. 5929–5955, doi: 10.1007/s10462-020-09838-1.
- [19] Lillicrap, T. P., and Santoro, A., 2019, Backpropagation through time and the brain, *Curr Opin Neurobiol*, vol. 55, pp. 82–89, doi: <https://doi.org/10.1016/j.conb.2019.01.011>.
- [20] Fischer, T. and Krauss, C., 2018, Deep learning with long short-term memory networks for financial market predictions. *European journal of operational research*, 270(2), pp.654-669.

- [21] Kumar, S. L., 2021, Predictive analytics of covid-19 pandemic: Statistical modelling perspective, *Walailak J Sci Technol*, vol. 18, no. 16, doi: 10.48048/wjst.2021.15583.
- [22] Karim, F., Majumdar, S. and Darabi, H., 2019, Insights into LSTM fully convolutional networks for time series classification. *IEEE Access*, 7, pp.67718-67725.
- [23] Chang, Z., Zhang, Y., and Chen, W. Electricity price prediction based on hybrid model of adam optimized LSTM neural network and wavelet transform, *Energy*, vol. 187, doi: 10.1016/j.energy.2019.07.134.
- [24] Wibowo, A., Wirayawan, P. W., and Nuqoyati, N. I. Optimization of neural network for cancer microRNA biomarkers classification, *Journal of Physics: Conference Series*, Institute of Physics Publishing, Jun. 2019. doi: 10.1088/1742-6596/1217/1/012124.
- [25] Kingma, D. P. and Ba, J., 2014, Adam: A method for stochastic optimization. *arXiv preprint*, doi: <https://doi.org/10.48550/arXiv.1412.6980>
- [26] Sharma, D. K., Chatterjee, M., Kaur, G., & Vavilala, S., 2022, 3 - Deep learning applications for disease diagnosis, *Deep Learning for Medical Applications with Unique Data*, pp. 31-51. Academic Press. Gupta, D. Kose, U., Khanna, A., and Balas, V.E. Eds., Academic Press, pp. 31-51. doi: <https://doi.org/10.1016/B978-0-12-824145-5.00005-8>.
- [27] de Myttenaere, A. Golden, B. Le Grand, and Rossi, F. "Mean Absolute Percentage Error for regression models," *Neurocomputing*, vol. 192, pp. 38–48, 2016, doi: <https://doi.org/10.1016/j.neucom.2015.12.114>.
- [28] Lewis, C. D., 1982, *Industrial and Business Forecasting Methods: A Practical Guide to Exponential Smoothing and Curve Fitting* Butterworth scientific, Butterworth Scientific: London, UK