

# Perbandingan Kinerja LSTM, Bi-LSTM, dan Prophet untuk Prediksi Kekeringan berdasarkan SPEI (Standardized Precipitation-Evapotranspiration Index)

Hana Amalina, Eri Zuliarso\*

Fakultas Teknologi Informasi dan Industri, Magister Teknologi Informasi, Universitas Stikubank, Semarang, Indonesia

Email: <sup>1</sup>hanaamalina0010@mhs.unisbank.ac.id, <sup>2,\*</sup>eri299@edu.unisbank.ac.id

Email Penulis Korespondensi: eri299@edu.unisbank.ac.id

Submitted: 11/07/2025; Accepted: 01/09/2025; Published: 02/09/2025

**Abstrak**—Kekeringan merupakan bencana alam yang berdampak luas terhadap pertanian dan ketersediaan air, terutama di wilayah Waduk Gajah Mungkur Kabupaten Wonogiri, Indonesia. Ketidakstabilan curah hujan akibat perubahan iklim global dan variabilitas iklim lokal menjadi penyebab utama bencana ini. Prediksi kekeringan yang akurat sangat penting untuk merumuskan strategi mitigasi berkelanjutan. Penelitian ini bertujuan untuk menganalisis karakteristik kekeringan di Waduk Gajah Mungkur Kabupaten Wonogiri menggunakan Standardized Precipitation Evapotranspiration Index (SPEI) serta membandingkan performa tiga model prediksi, yaitu Long Short-Term Memory (LSTM), Bidirectional LSTM (Bi-LSTM), dan Prophet dalam memprediksi SPEI. Data yang digunakan meliputi curah hujan dan suhu udara dari tahun 1995 hingga 2024. Hasil analisis menunjukkan bahwa semakin panjang skala waktu SPEI, pola kekeringan cenderung lebih terkonsentrasi secara temporal. Pada SPEI skala 6 bulan yang merepresentasikan kekeringan jangka panjang selama 1995–2024, terdeteksi 55 bulan kekeringan, dengan episode dominan terjadi pada 1996–1997, 2000–2007, 2019, dan 2023–2024. Evaluasi performa model menunjukkan adanya kecenderungan numerik di mana Bi-LSTM unggul untuk prediksi SPEI skala 1 bulan, sementara LSTM tampak lebih baik pada skala 3 dan 6 bulan. Namun, uji signifikansi statistik menunjukkan performa ketiga model sebanding ( $p > 0,05$ ), sehingga faktor lain seperti efisiensi komputasi dapat menjadi pertimbangan penting dalam aplikasi praktis.

**Kata Kunci:** Kekeringan; SPEI; LSTM; Bi-LSTM; Prophet

**Abstract**—Drought is a natural disaster with widespread impacts on agriculture and water availability, particularly in the Gajah Mungkur Reservoir area of Wonogiri Regency, Indonesia. Rainfall instability driven by global climate change and local climate variability is the primary cause of this disaster. Accurate drought prediction is essential for formulating sustainable mitigation strategies. This study aims to analyze drought characteristics in the Gajah Mungkur Reservoir, Wonogiri Regency, using the Standardized Precipitation Evapotranspiration Index (SPEI) and to compare the performance of three prediction models: Long Short-Term Memory (LSTM), Bidirectional LSTM (Bi-LSTM), and Prophet in predicting SPEI. The dataset includes monthly rainfall and air temperature data from 1995 to 2024. The analysis reveals that longer SPEI time scales tend to show more temporally concentrated drought patterns. At the 6-month SPEI scale, which represents long-term drought, a total of 55 drought months were detected between 1995 and 2024, with major drought episodes occurring in 1996–1997, 2000–2007, 2019, and 2023–2024. Model performance evaluation shows a numerical trend in which Bi-LSTM outperforms others for 1-month SPEI prediction, while LSTM performs better at the 3- and 6-month scales. However, statistical significance testing indicates that the performance differences among the three models are not significant ( $p > 0,05$ ), suggesting that other factors such as computational efficiency may be important considerations in practical applications.

**Keywords:** Drought; SPEI; LSTM; Bi-LSTM; Prophet

## 1. PENDAHULUAN

Kekeringan merupakan salah satu bencana alam yang memiliki dampak luas dan signifikan, terutama di wilayah dengan ketergantungan tinggi pada sektor pertanian dan ketersediaan air bersih. Kekeringan biasanya terjadi ketika curah hujan lebih rendah dari rata-rata selama periode yang berkepanjangan [1], [2]. Secara global, kejadian kekeringan ekstrem diperkirakan akan semakin sering dan parah [3]. Aktivitas manusia yang memengaruhi dinamika atmosfer menjadi salah satu penyebab utama meningkatnya tingkat keparahan, jumlah, dan cakupan kekeringan dalam beberapa dekade belakangan ini [4].

Kekeringan menyebabkan gangguan pada keseimbangan sumber daya air akibat evapotranspirasi yang berlebihan dan kekurangan kadar kelembapan [5]. Akibat fenomena tersebut terjadi pengurangan sumber air pada sungai dan waduk, kerusakan lahan pertanian karena tidak mendapat irigasi yang cukup, dan kegiatan sehari-hari masyarakat terganggu [6], [7], [8].

Di Indonesia, khususnya di wilayah waduk Gajah Mungkur, kabupaten Wonogiri, kekeringan sering terjadi akibat ketidakstabilan curah hujan yang disebabkan oleh perubahan iklim global dan variabilitas iklim lokal [9]. Bencana tersebut memberikan dampak signifikan pada sektor pertanian, ketersediaan air bersih, dan kesejahteraan masyarakat. Dampaknya, wilayah tersebut mengalami kerugian ekonomi besar dan penurunan kualitas hidup masyarakat [10].

Tantangan utama dalam memprediksi kekeringan adalah memilih indeks yang mampu merepresentasikan secara akurat kemungkinan terjadinya kekeringan [11]. Indeks kekeringan berperan penting sebagai sistem peringatan dini untuk mendeteksi awal dan akhir periode kekeringan, serta membantu dalam mengenali karakteristik, tingkat keparahan, dan distribusi spasialnya [12], [13], [14]. Oleh karena itu, penggunaan indeks standar yang andal dalam prediksi kekeringan menjadi aspek penting untuk mendukung pengambilan keputusan yang efektif.

Salah satu indeks standar yang umum digunakan untuk mengukur intensitas dan durasi kekeringan adalah dengan menggunakan *Standardized Precipitation Evapotranspiration Index* (SPEI). SPEI menyediakan pendekatan kuantitatif yang dapat mengidentifikasi kondisi kekeringan berdasarkan data curah hujan dan evapotranspirasi potensial dalam berbagai skala waktu. Kelebihan utama SPEI terletak pada kemampuannya untuk mempertimbangkan keseimbangan air dengan mengintegrasikan curah hujan dan evapotranspirasi potensial, sehingga lebih sensitif terhadap perubahan iklim dibandingkan indeks lain seperti *Standardized Precipitation Index* (SPI). SPEI juga fleksibel karena dapat dihitung pada berbagai skala waktu (misalnya, 1, 3, 6, atau 12 bulan), memungkinkan analisis kekeringan dalam jangka pendek hingga panjang [13], [15], [16].

Selain itu, SPEI telah terbukti efektif dalam berbagai penelitian di wilayah dengan iklim beragam. Misalnya, SPEI digunakan untuk menganalisis pola kekeringan di wilayah Asia Tengah dan Asia [17], [18], [19], [20], [21], [22], [23], [24], [25], [26]. Di Afrika, SPEI mendukung sistem peringatan dini kekeringan dan membantu mitigasi dampak kekeringan [27], [28], [29], [30]. Di Indonesia, SPEI dimanfaatkan untuk menganalisis kekeringan di wilayah Jawa, Sumatra, Sulawesi Selatan, mendukung monitoring, sistem peringatan dini, serta strategi mitigasi dan adaptasi bencana kekeringan [31], [32], [33]. Prediksi kekeringan yang akurat sangat dibutuhkan dalam upaya menemukan solusi berkelanjutan untuk mengurangi dampak negatif dari kekeringan [34], [35]. Seiring berkembangnya teknologi komputasi, model *machine learning* (ML) maupun *deep learning* (DL) semakin banyak dimanfaatkan dalam studi hidrologi untuk menangani fenomena kompleks seperti prediksi kekeringan. Saat ini telah banyak model ML yang digunakan dalam prediksi indeks kekeringan, salah satunya adalah Prophet. Prophet merupakan model ML yang paling baru dikembangkan. Model tersebut menggunakan pendekatan regresi aditif untuk memodelkan tren dan musiman secara eksplisit, sehingga sangat efektif untuk memprediksi indeks kekeringan seperti SPEI yang dipengaruhi oleh pola musiman curah hujan [36]. Basak *et al.* membandingkan model Prophet, *support vector regression* (SVR) dan *multiple linear regression* (MLR) untuk memprediksi kekeringan di wilayah barat India. Hasil penelitian menunjukkan bahwa Prophet menunjukkan akurasi yang baik mengungguli model SVR dan MLR [37]. Rahman *et al.* melakukan estimasi evapotranspirasi menggunakan model Prophet dan SVR. Evapotranspirasi merupakan variabel yang diperlukan untuk menghitung SPEI. Hasil penelitian membuktikan bahwa Prophet memberikan performa yang lebih baik dibanding SVR dalam prediksi evapotranspirasi [38]. Hossain *et al.* melakukan prediksi kekeringan meteorologis di wilayah barat daya Banglades menggunakan model Prophet dan *Seasonal Autoregressive Integrated Moving Average* (SARIMA). Hasil penelitian menunjukkan bahwa Prophet memberikan performa prediksi yang lebih baik dibanding SARIMA dan mampu menangani tren *non-linear* dan musiman yang kompleks [39].

Selain itu, beberapa model DL, seperti *Long Short-Term Memory* (LSTM) dan *Bidirectional LSTM* (Bi-LSTM) [40], [41], [42], [43], [44] juga digunakan dalam prediksi kekeringan. Berbeda dengan ML yang memerlukan input manusia untuk mendefinisikan fitur-fitur penting dari data, model DL dapat mempelajarinya secara otomatis [45]. Dikshit *et al.* melakukan prediksi SPEI menggunakan LSTM serta model ML seperti *Random Forests* (RF) dan *Artificial Neural Network* (ANN) di New South Wales. Hasil penelitian menunjukkan bahwa LSTM memberikan performa terbaik dengan nilai koefisien determinasi mencapai lebih dari 0,99 [40]. Penelitian yang dilakukan Shang *et al.* juga menunjukkan bahwa model LSTM mampu mengungguli model *Autoregressive Integrated Moving Average* (ARIMA) dalam prediksi SPEI di Cekungan sungai Kuning, Tiongkok [41]. Bi-LSTM merupakan salah satu jenis varian dari LSTM dengan tambahan lapisan *backpropagation* pada struktur asli LSTM. Tambahan struktur tersebut membuat Bi-LSTM memiliki keunggulan dibanding LSTM yakni mampu mempertimbangkan informasi dari masa lalu dan masa depan secara bersamaan, sehingga meningkatkan kemampuannya untuk menangkap hubungan dalam data deret waktu [46]. Penelitian yang dilakukan oleh Dong *et al.* di wilayah Tiongkok menunjukkan bahwa Bi-LSTM memiliki keunggulan dalam memprediksi SPEI skala 3 bulan dibanding model lain [42]. Selain itu, penelitian terkait prediksi kekeringan di wilayah Barcelona oleh Granata *et al.* menunjukkan bahwa model Bi-LSTM menunjukkan performa prediksi yang baik dengan koefisien determinasi mencapai 0,899 [43].

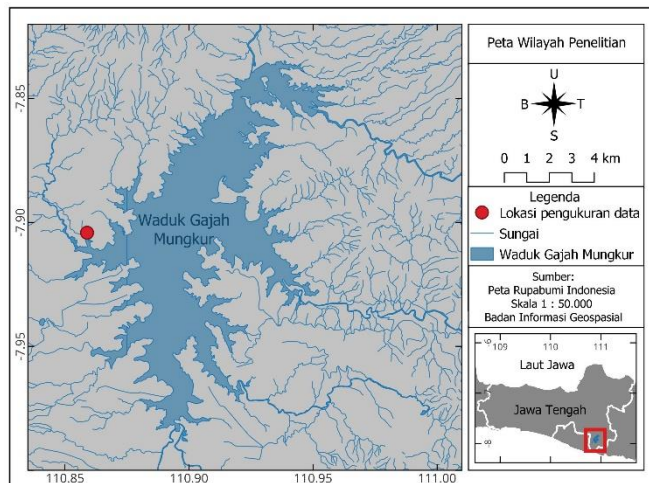
Berdasarkan studi literatur sebelumnya, diketahui bahwa model Prophet, LSTM, dan Bi-LSTM memiliki keunggulan performa dalam memprediksi kekeringan dibanding model lainnya. Sementara itu, penelitian terkait prediksi kekeringan di Waduk Gajah Mungkur Wonogiri menggunakan model Prophet, LSTM, dan Bi-LSTM masih jarang dilakukan. Oleh karena itu, penelitian ini bertujuan untuk: i) mengidentifikasi karakteristik kondisi kekeringan di wilayah Waduk Gajah Mungkur Kabupaten Wonogiri berdasarkan SPEI, serta ii) melakukan analisis perbandingan performa model LSTM, Bi-LSTM, dan Prophet dalam memprediksi SPEI. Hasil penelitian ini diharapkan dapat memberikan analisis kondisi kekeringan serta mengidentifikasi model prediksi terbaik untuk memprediksi kekeringan di Waduk Gajah Mungkur Wonogiri. Model terpilih ini selanjutnya dapat menjadi landasan ilmiah untuk pengembangan sistem peringatan dini kekeringan yang akurat guna mendukung pengambilan kebijakan strategis dalam manajemen sumber daya air dan meningkatkan ketahanan masyarakat terhadap dampak kekeringan.

## 2. METODOLOGI PENELITIAN

### 2.1 Wilayah Penelitian

Penelitian ini difokuskan pada wilayah Waduk Gajah Mungkur yang terletak di Kabupaten Wonogiri, Provinsi Jawa Tengah seperti yang terlihat pada Gambar 1. Waduk Gajah Mungkur memiliki fungsi sebagai irigasi, pembangkit

listrik, sumber air minum, perikanan budidaya, transportasi, serta pariwisata [47]. Di sisi lain, kondisi geografis dan iklim di Wonogiri menunjukkan adanya variasi yang cukup mencolok, yang turut mempengaruhi aktivitas dan kehidupan masyarakat. Untuk mengatasi tantangan yang ditimbulkan oleh perubahan cuaca ekstrem, dibutuhkan langkah-langkah adaptasi yang tepat. Hal ini mencakup pengelolaan sumber daya air secara optimal serta perencanaan tata ruang yang disesuaikan dengan karakteristik topografi dan iklim lokal [48].



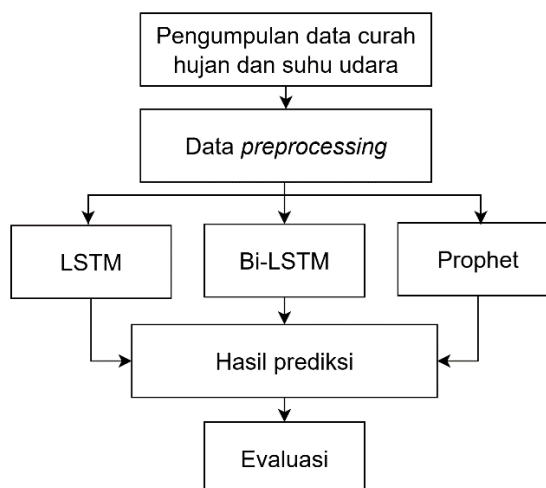
Gambar 1. Peta wilayah penelitian

## 2.2 Sumber Data

Data yang digunakan berupa data pengukuran in situ curah hujan serta data suhu udara di wilayah Waduk Gajah Mungkur, Kabupaten Wonogiri seperti yang terlihat pada Gambar 1. Data tersebut diperoleh dari stasiun pengamatan cuaca Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), Stasiun Klimatologi Jawa Tengah dalam interval bulanan selama tahun 1995 – 2024 dan telah melalui proses validasi. Data curah hujan memiliki data kosong sebesar 13% sedangkan data suhu udara memiliki data kosong sebesar 19%. Data tersebut menjadi sumber utama dalam proses pengolahan dan analisis data pada penelitian ini.

## 2.3 Tahapan Penelitian

Tahapan yang dilakukan dalam penelitian ini secara umum digambarkan dalam diagram alir pada Gambar 2. Tahap awal penelitian berupa pengumpulan data curah hujan dan suhu udara. Setelah data terkumpul, dilanjutkan dengan *preprocessing* data, meliputi pengisian data kosong serta perhitungan SPEI. Data kosong tersebut diisi menggunakan nilai rata-rata normal bulanan, yang dihitung berdasarkan bulan yang sama dari tahun-tahun lainnya. Data curah dan suhu udara yang sudah lengkap digunakan untuk menghitung SPEI pada skala 1 bulan, 3 bulan, dan 6 bulan.



Gambar 2. Diagram alir penelitian

Data curah hujan, suhu udara, serta SPEI (tiga variabel) dalam rentang tahun 1995-2021 selanjutnya digunakan untuk melatih model LSTM, Bi-LSTM, dan Prophet. Keluaran ketiga model berupa prediksi SPEI dalam rentang tahun 2022-2024 yang selanjutnya dilakukan evaluasi terhadap data SPEI aktual menggunakan metrik akurasi *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi ( $R^2$ ).

### 2.3.1 Perhitungan SPEI

Dalam penelitian ini, indeks SPEI dihitung pada tiga skala waktu yang berbeda, yaitu 1 bulan (SPEI-1), 3 bulan (SPEI-3), dan 6 bulan (SPEI-6). Perhitungan ini didasarkan pada deret neraca air iklim bulanan yang diakumulasikan selama n bulan, yakni nilai bulan berjalan ditambah dengan nilai dari n-1 bulan sebelumnya; n = 1 untuk SPEI-1, n = 3 untuk SPEI-3, dan n = 6 untuk SPEI-6. Dengan demikian, nilai SPEI-3 untuk bulan Maret merupakan hasil penjumlahan nilai SPEI bulanan untuk Januari, Februari, dan Maret.

**Tabel 1.** Sebagian data curah hujan bulanan (P), suhu udara bulanan (T), evapotranspirasi potensial bulanan (PET), neraca air bulanan (D), dan SPEI skala 1 bulan (SPEI-1), 3 bulan (SPEI-3), dan 6 bulan (SPEI-6)

Bulan	P (mm)	T (°C)	PET	D	SPEI-1	SPEI-3	SPEI-6
Januari 1995	367	26,8	146,52	272,48	1,08		
Februari 1995	430	27,3	141,85	419,15	1,47		
Maret 1995	288	27,3	154,57	154,43	0,45	1,65	
April 1995	182	27,8	156,91	-110,91	-1,63	0,57	
Mei 1995	86	27,5	152,01	-132,01	-0,91	-1,13	
Juni 1995	102	26,7	131,55	-90,55	0,47	-1,43	0,65
...	...	...	...	...	...	...	...
September 2024	49	28,2	167,54	-119,54	0,84	0,20	-1,97
Oktober 2024	149	29,1	199,01	-60,01	1,00	0,72	-0,63
November 2024	356	28,0	168,49	281,51	1,47	1,26	0,81
Desember 2024	422	26,7	145,95	415,05	1,83	1,96	1,48

Untuk menghitung SPEI, langkah pertama adalah menentukan neraca air bulanan ( $D_i$ ), yaitu selisih antara curah hujan bulanan ( $P_i$ ) dan evapotranspirasi potensial bulanan ( $PET_i$ ) pada bulan ke-(i). PET dihitung berdasarkan persamaan Thornthwaite sebagai berikut [49].

$$PET = 16 \left( \frac{L}{12} \right) \left( \frac{N}{30} \right) \left( \frac{10T}{I} \right)^m \quad (1)$$

dengan L adalah Panjang hari (jam), N adalah Jumlah hari dalam bulan, T adalah Suhu udara rata-rata (°C), I adalah Indeks panas tahunan, m adalah koefisien yang bergantung pada I. Nilai I dan m diperoleh berdasarkan persamaan berikut:

$$I = \sum_{j=1}^{12} \left( \frac{T_j}{5} \right)^{1.514} \quad (2)$$

$$m = 6.75 \times 10^{-7} I^3 - 7.71 \times 10^{-5} I^2 + 1.79 \times 10^{-2} I + 0.492 \quad (3)$$

Dengan  $T_j$  adalah Suhu udara rata-rata bulanan untuk bulan ke-(j) (°C), j adalah Indeks bulan, dari 1 (Januari) hingga 12 (Desember)

Langkah selanjutnya adalah menentukan neraca air bulanan ( $D_i$ ), yaitu selisih antara curah hujan bulanan ( $P_i$ ) dan evapotranspirasi potensial bulanan ( $PET_i$ ). PET dihitung berdasarkan persamaan Thornthwaite [49]. Nilai-nilai ini kemudian diakumulasikan selama (k) bulan sesuai dengan skala waktu yang diinginkan berdasarkan persamaan berikut [13]:

$$D_i = P_i - PET_i \quad (4)$$

$$D_{cum,i,k} = \sum_{j=i-k+1}^i D_j \quad (5)$$

dengan  $D_{cum,i,k}$  adalah Jumlah defisit air untuk bulan (i) pada skala waktu (k), dan j adalah Bulan dalam periode akumulasi, dari (i - k + 1) hingga (i).

Data akumulasi dimodelkan dalam probabilitas kumulatif menggunakan distribusi log-logistik untuk menghasilkan probabilitas kumulatif yang dinyatakan dalam persamaan berikut.

$$F(x) = \left[ 1 + \left( \frac{\alpha}{x-\gamma} \right)^\beta \right]^{-1} \quad (6)$$

dengan  $\alpha$ ,  $\beta$ , dan  $\gamma$  masing-masing adalah parameter skala, bentuk dan lokasi.

Selanjutnya, probabilitas kumulatif diubah menjadi nilai SPEI menggunakan invers dari distribusi normal standar berdasarkan persamaan berikut:

$$SPEI_i = \Phi^{-1}(F) \quad (7)$$

Dengan  $\Phi^{-1}$  adalah Fungsi invers distribusi normal standar (mean = 0, standar deviasi = 1), F adalah Probabilitas kumulatif dari distribusi log-logistik, serta  $SPEI_i$  adalah Nilai SPEI untuk bulan (i) pada skala (k). Perhitungan indeks kekeringan SPEI dalam penelitian ini dilakukan menggunakan *package* SPEI pada platform R. *Package* ini mengintegrasikan perhitungan evapotranspirasi potensial (PET) dengan metode Thornthwaite, neraca air, dan estimasi indeks SPEI secara lengkap berdasarkan skala waktu tertentu (1, 3, dan 6 bulan). Metode Thornthwaite dalam *package*

ini menggunakan suhu udara rata-rata bulanan dan estimasi panjang hari berdasarkan lintang lokasi. Mengingat sensitivitas metode ini terhadap bias suhu, dilakukan pemeriksaan kelengkapan dan validitas data suhu sebelum penghitungan, guna meminimalkan potensi deviasi.

Sebagian data input curah hujan bulanan (P), suhu udara bulanan (T), serta hasil perhitungan evapotranspirasi potensial bulanan (PET), neraca air bulanan (D), dan SPEI skala 1 bulan (SPEI-1), 3 bulan (SPEI-3), dan 6 bulan (SPEI-6) dapat dilihat pada Tabel 1. Variasi nilai SPEI tersebut menggambarkan kondisi neraca air kumulatif pada berbagai klasifikasi yang secara umum diinterpretasikan berdasarkan Tabel 2. Episode kekeringan ditentukan sebagai periode berdurasi satu bulan atau lebih di mana nilai SPEI berada pada atau di bawah  $-1$  [50].

**Tabel 2.** Klasifikasi Indeks SPEI [51]

Klasifikasi	Nilai SPEI
Basah ekstrem	$\geq 2$
Sangat-Basah	1,5 - 1,99
Agak-Basah	1 - 1,49
Normal	(-)0,99 - 0,99
Agak-Kering	(-)1 - (-)1,49
Sangat-Kering	(-)1,5 - (-)1,99
Kering ekstrem	$\leq -2$

### 2.3.2 Pembangunan Model Prediksi dan Evaluasi

Setelah nilai SPEI dihitung, langkah selanjutnya adalah proses training pada model machine learning. Pada proses *training* digunakan data tahun 1995 – 2021, sedangkan pada proses *testing* digunakan data tahun 2022 – 2024. Adapun model yang digunakan dalam prediksi SPEI adalah LSTM, Bi-LSTM, dan Prophet. Pemisahan ini dilakukan berdasarkan pertimbangan ketersediaan data dan kebutuhan evaluasi performa model pada data terbaru, sekaligus menjaga proporsi wajar antara data *training* dan data *testing* untuk menjaga generalisasi model. Implementasi model dilakukan menggunakan bahasa pemrograman Python dengan pustaka Keras dan TensorFlow untuk LSTM dan Bi-LSTM, serta Prophet API dari Facebook untuk model Prophet.

LSTM adalah *jenis Recurrent Neural Network* (RNN) yang dirancang untuk memproses data deret waktu dengan akurasi tinggi. Model ini mampu menyimpan informasi dari data masa lalu, mempelajarinya, dan menggunakannya untuk menghasilkan keluaran saat ini. Berbeda dengan RNN konvensional, LSTM mengatasi masalah *vanishing gradient* melalui mekanisme *memory cell* dan *gates* (*input, forget, output*), sehingga efektif untuk menangani ketergantungan jangka panjang dalam data deret waktu [52].

Bi-LSTM adalah varian LSTM yang memproses data deret waktu dalam dua arah, yaitu maju (*forward*) dan mundur (*backward*), menggunakan dua jaringan LSTM paralel. Pendekatan ini memungkinkan model untuk menangkap konteks temporal dari kedua arah, meningkatkan akurasi prediksi dengan memanfaatkan informasi sebelum dan sesudah titik waktu tertentu, dengan jumlah epoch pelatihan yang lebih efisien dibandingkan LSTM [46].

Prophet adalah model prediksi deret waktu berbasis regresi aditif yang dikembangkan oleh Facebook. Model ini mampu mengidentifikasi komponen deret waktu seperti tren dan musiman, lalu menggabungkannya untuk menghasilkan prediksi. Prophet hanya memerlukan dua kolom input (*ds* untuk tanggal dan *y* untuk nilai), sehingga relatif sederhana dan tidak memerlukan pengetahuan mendalam tentang deret waktu. Prophet secara otomatis mendeteksi pola musiman dan memberikan parameter yang mudah disesuaikan, meskipun performanya bergantung pada karakteristik tren dan musiman dalam data [36].

Faktor utama yang berperan dalam meningkatkan performa model ML dan DL adalah optimasi *hyperparameter*. Berbagai metode telah dikembangkan untuk menentukan kombinasi *hyperparameter* yang optimal, termasuk *grid search* [53], metode *trial and error*, algoritma genetika, dan *particle swarm optimization* [54]. Dalam penelitian ini, model LSTM dan Bi-LSTM dioptimalkan menggunakan Random Search melalui Keras Tuner. Untuk model LSTM, *hyperparameter* yang disesuaikan meliputi jumlah lapisan LSTM (1 atau 2 lapisan), jumlah unit pada setiap lapisan LSTM (32, 64, 96, atau 128), tingkat dropout pada setiap lapisan LSTM (0.1, 0.2, 0.3, 0.4, atau 0.5), dan *learning rate* ( $1e-4$  hingga  $1e-2$  dengan sampling logaritmik). Untuk model Bi-LSTM, *hyperparameter* yang disesuaikan meliputi jumlah unit pada lapisan Bi-LSTM (32, 64, 96, atau 128), tingkat dropout (0.1, 0.2, 0.3, 0.4, atau 0.5), dan *learning rate* ( $1e-4$  hingga  $1e-2$  dengan sampling logaritmik). Kedua model menggunakan lapisan Dense dengan 1 unit untuk output prediksi dan dioptimalkan dengan loss function MSE menggunakan optimizer Adam. Untuk model Prophet, optimisasi *hyperparameter* seperti *changepoint prior scale* dan *seasonality prior scale* dilakukan secara otomatis menggunakan *framework* optimisasi Optuna.

Untuk mengevaluasi performa prediksi model LSTM, Bi-LSTM, dan Prophet, digunakan metrik akurasi yang terdiri dari *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi ( $R^2$ ). MAE mengukur rata-rata deviasi absolut antara nilai prediksi dan nilai aktual. Nilai MAE yang lebih kecil menunjukkan prediksi yang lebih akurat. RMSE menghitung akar kuadrat dari rata-rata kuadrat error, sehingga menunjukkan sensitivitas terhadap error besar. Nilai RMSE yang lebih rendah mengindikasikan model dengan performa prediksi yang lebih baik.  $R^2$  mengukur proporsi variansi data aktual yang dapat dijelaskan oleh model, dengan nilai berkisar antara 0 hingga 1. Nilai  $R^2$  yang mendekati 1 menunjukkan bahwa model mampu menjelaskan sebagian besar

variabilitas data, sedangkan nilai mendekati 0 menunjukkan model yang kurang mampu menangkap pola data. Persamaan dari masing-masing metrik akurasi dinyatakan dalam persamaan berikut [55], [56].

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \tag{8}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \tag{9}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{10}$$

Dengan  $(\hat{y}_i)$  adalah nilai prediksi,  $(y_i)$  adalah nilai aktual,  $\bar{y}$  adalah rata-rata nilai aktual, dan  $(n)$  adalah jumlah data yang digunakan dalam evaluasi model.

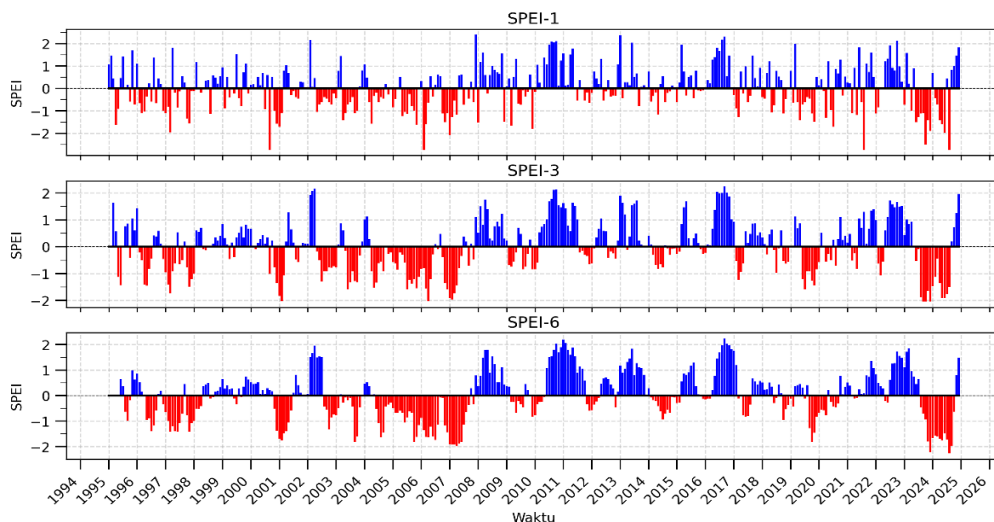
Selain evaluasi berdasarkan nilai metrik, dilakukan uji signifikansi statistik untuk memastikan bahwa perbedaan performa antar model bukanlah karena faktor kebetulan. Uji signifikansi statistik dilakukan menggunakan metode uji non-parametrik karena distribusi galat dari model prediksi sering kali tidak mengikuti distribusi normal [57]. Uji Friedman dipilih untuk membandingkan performa ketiga model secara bersamaan pada keseluruhan set data *testing*. Uji ini cocok digunakan untuk membandingkan tiga atau lebih grup data yang saling berhubungan [57]. Jika hasil Uji Friedman menunjukkan adanya perbedaan yang signifikan secara statistik ( $p < 0,05$ ), maka analisis dilanjutkan dengan uji Wilcoxon signed-rank sebagai uji *post-hoc* untuk melakukan perbandingan berpasangan antar model. Langkah ini bertujuan untuk mengidentifikasi secara spesifik pasangan model mana yang memiliki performa yang berbeda secara signifikan. Tingkat signifikansi ( $\alpha$ ) yang digunakan dalam penelitian ini adalah 0,05.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil

##### 3.1.1 Analisis Karakteristik Kekeringan


Analisis SPEI pada skala waktu yang berbeda merepresentasikan variasi dalam neraca air kumulatif. SPEI-1 mewakili neraca air dalam satu bulan sehingga sangat peka terhadap perubahan jangka pendek pada curah hujan dan suhu. SPEI-3 membandingkan total curah hujan selama tiga bulan tertentu dengan akumulasi curah hujan pada periode tiga bulan yang sama dalam data historis sehingga mencerminkan kondisi kekeringan jangka menengah. Sementara itu, SPEI-6 menggunakan akumulasi data selama enam bulan sehingga mampu menggambarkan pola kekeringan jangka panjang. SPEI-3 dan SPEI-6 lebih efektif dalam memvisualisasikan karakteristik kekeringan yang berlangsung lebih lama meskipun kurang responsif terhadap perubahan mendadak [58], [59], [60].



**Gambar 3.** Hasil perhitungan SPEI skala 1 bulan (SPEI-1), skala 3 bulan (SPEI-3) dan skala 6 bulan (SPEI-6) di wilayah Waduk Gajah Mungkur Kabupaten Wonogiri tahun 1995 – 2024.

Hasil perhitungan SPEI pada skala waktu 1, 3, dan 6 bulan di Waduk Gajah Mungkur Kabupaten Wonogiri selama tahun 1995 – 2024 dapat dilihat pada Gambar 3. SPEI-1 menunjukkan nilai tertinggi 2,39 terjadi pada Desember 2007 dan nilai terendah -2,73 yang terjadi pada September 2000. Pada SPEI-3, nilai tertinggi sebesar 2,24 terjadi pada September 2016 dan nilai terendah sebesar -2,04 terjadi pada September 2023. Sementara itu, SPEI-6 memiliki nilai tertinggi sebesar 2,24 terjadi pada September 2016 dan nilai terendah sebesar -2,26 terjadi pada Agustus 2024.

Gambar 4 menunjukkan *heatmap* klasifikasi intensitas kekeringan berdasarkan SPEI-1, SPEI-3, dan SPEI-6. Pada SPEI-1 yang mencerminkan kondisi kekeringan jangka pendek, terdeteksi 6 bulan kering ekstrem, 17 bulan sangat kering, 39 bulan agak kering, 240 bulan normal, serta 58 bulan agak basah hingga basah ekstrem. Kondisi kekeringan terdistribusi secara merata, dengan episode kekeringan terjadi pada tahun 1995-1998, 2000-2009, 2014, serta 2017-2024.



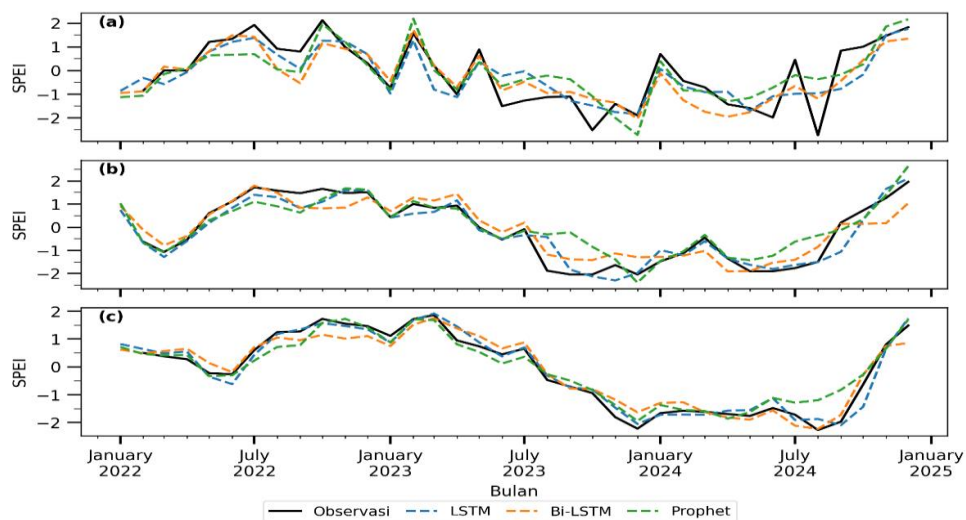
**Gambar 4.** *Heatmap* klasifikasi intensitas kekeringan berdasarkan SPEI-1, SPEI-3, dan SPEI-6

Pada SPEI-3 yang mewakili kekeringan jangka menengah mengungkapkan 5 bulan kering ekstrem, 17 bulan sangat kering, 30 bulan agak kering, 250 bulan normal, serta 58 bulan agak basah hingga basah ekstrem. Pada skala waktu 3 bulan, kondisi kekeringan tidak tersebar merata, melainkan menunjukkan pola terkonsentrasi secara temporal, dengan episode kekeringan dominan terjadi pada tahun 1995–1998, 2000–2007, 2017, 2019, serta 2022–2024.

Sementara itu pada SPEI-6, yang merepresentasikan kekeringan jangka panjang, menunjukkan 2 bulan kering ekstrem, 26 bulan sangat kering, 27 bulan agak kering, 249 bulan normal, serta 56 bulan agak basah hingga basah ekstrem. Pada skala waktu 6 bulan ini kondisi kekeringan semakin terkonsentrasi secara temporal, dengan episode kekeringan terjadi pada tahun 1996-1997, 2000-2007, 2019, 2023-2024.

### 3.1.2 Performa Model

Performa model LSTM, Bi-LSTM, dan Prophet dalam memprediksi SPEI pada skala waktu 1 bulan, 3 bulan, dan 6 bulan dapat dilihat pada Gambar 5. Secara umum, ketiga model mampu menghasilkan prediksi dengan pola yang sesuai dengan data observasi. Model LSTM terlihat memberikan performa sedikit lebih baik dibanding Prophet dan Bi-LSTM pada prediksi SPEI-3 dan SPEI-6. Pada SPEI-6, terlihat bahwa model Bi-LSTM memiliki performa sedikit lebih baik dibanding LSTM dan Prophet.



**Gambar 5.** Grafik antara data observasi SPEI (garis hitam) dan prediksi model SPEI model LSTM (garis biru), Bi-LSTM (garis jingga), dan Prophet (garis hijau) untuk (a) SPEI-1, (b) SPEI-3, dan (c) SPEI-6.

**Tabel 3.** Perbandingan metrik akurasi model prediksi SPEI

	LSTM			Bi-LSTM			Prophet		
	MAE	RMSE	R <sup>2</sup>	MAE	RMSE	R <sup>2</sup>	MAE	RMSE	R <sup>2</sup>
SPEI-1	0,57	0,74	0,69	0,52	0,68	0,74	0,59	0,76	0,67

	LSTM			Bi-LSTM			Prophet		
	MAE	RMSE	R <sup>2</sup>	MAE	RMSE	R <sup>2</sup>	MAE	RMSE	R <sup>2</sup>
SPEI-3	0,29	0,43	0,90	0,40	0,49	0,87	0,41	0,61	0,79
SPEI-6	0,18	0,24	0,97	0,27	0,32	0,94	0,25	0,36	0,93

Tabel 3 menunjukkan metrik akurasi model LSTM, Bi-LSTM, dan Prophet dalam memprediksi SPEI. Pada SPEI-1, model Bi-LSTM menjadi yang terbaik dengan MAE 0,52, RMSE 0,68, dan R<sup>2</sup> 0,74, sedikit lebih unggul dibandingkan LSTM dan Prophet. Selanjutnya pada prediksi SPEI-3, ketiga model menunjukkan peningkatan performa dibanding prediksi SPEI-1. LSTM menunjukkan akurasi prediksi SPEI-3 terbaik dengan MAE 0,29, RMSE 0,48 dan R<sup>2</sup> 0,90. Sementara itu pada prediksi SPEI-6, ketiga model menunjukkan performa terbaik dibanding pada prediksi SPEI-1 dan SPEI-3. Model LSTM menunjukkan performa prediksi SPEI-6 terbaik dengan MAE 0,18, RMSE 0,24, dan R<sup>2</sup> 0,97. Hasil ini mengungkapkan bahwa LSTM sangat handal untuk memprediksi kekeringan jangka menengah hingga jangka panjang seperti SPEI-3 dan SPEI-6. Sebaliknya, Bi-LSTM tampak lebih cocok untuk prediksi kekeringan jangka pendek, dengan hasil yang lebih konsisten di skala waktu tersebut.

### 3.2 Pembahasan

#### 3.2.1 Karakteristik Kekeringan wilayah Waduk Gajah Mungkur

Variabilitas indeks kekeringan SPEI pada skala waktu yang berbeda menunjukkan karakteristik intensitas dan distribusi temporal kekeringan yang beragam di Waduk Gajah Mungkur Kabupaten Wonogiri selama periode 1995–2024. Pada skala waktu pendek (SPEI-1), kekeringan bersifat sporadis dan tersebar merata, mencerminkan respons cepat terhadap fluktuasi curah hujan dan suhu dalam periode bulanan. Hal ini sesuai dengan temuan Vicente-Serrano *et al.* yang menyatakan bahwa SPEI pada skala pendek lebih sensitif terhadap peristiwa kekeringan meteorologis jangka pendek [13]. Sebaliknya, pada skala waktu yang lebih panjang seperti SPEI-3 dan SPEI-6, pola kekeringan cenderung terkonsentrasi secara temporal pada tahun-tahun tertentu, yang mengindikasikan bahwa kekeringan bersifat lebih persisten dan terakumulasi. Pola ini menandakan transisi dari kekeringan meteorologis menuju kekeringan agrikultur dan hidrologis yang memiliki dampak lebih luas dan jangka panjang [61].

Perbedaan pola ini juga memperkuat pentingnya pemilihan skala waktu yang sesuai dalam analisis kekeringan, tergantung pada tujuan manajemen sumber daya air atau mitigasi bencana. Penggunaan SPEI pada berbagai skala waktu memberikan gambaran yang lebih komprehensif mengenai dinamika kekeringan dari jangka pendek hingga jangka panjang [15]. Dengan demikian, strategi adaptasi terhadap kekeringan di daerah ini perlu mempertimbangkan karakteristik waktu dan keterkaitan antar skala kekeringan tersebut.

Perbedaan intensitas dan durasi kekeringan pada skala waktu ini dapat dikaitkan dengan fenomena iklim seperti *El Niño-Southern Oscillation* (ENSO). Penelitian sebelumnya menunjukkan bahwa El Niño sering kali meningkatkan probabilitas kekeringan (SPEI < -0,84) pada skala 12 bulan di beberapa wilayah [62]. Episode kekeringan jangka pendek pada 2002 dan 2019 bertepatan dengan peristiwa El Niño yang kuat, yang diketahui mengurangi curah hujan di banyak wilayah tropis dan subtropis [63]. El Niño yang terjadi pada tahun 2023 juga dilaporkan menyebabkan bencana kekeringan di sejumlah wilayah di Pulau Jawa [64]. Kekeringan jangka panjang pada SPEI-6, terutama pada periode 1999–2009 dan 2011–2015, mungkin juga dipengaruhi oleh kombinasi ENSO dan *Pacific Decadal Oscillation* (PDO), yang memperkuat intensitas dan durasi kekeringan pada skala waktu lebih panjang [65]. Selain itu, peningkatan suhu akibat perubahan iklim global kemungkinan memperburuk kekeringan jangka panjang melalui peningkatan evapotranspirasi, yang sangat mempengaruhi SPEI pada skala enam bulan atau lebih [13].

#### 3.2.2 Performa dan limitasi model

Hasil evaluasi performa model prediksi SPEI menunjukkan variasi akurasi antar model tergantung pada skala waktu yang diprediksi. Secara deskriptif, pada skala jangka pendek (SPEI-1), model Bi-LSTM menunjukkan kecenderungan performa terbaik, mengungguli LSTM dan Prophet. Kemampuan ini diduga berasal dari arsitekturnya yang mampu menangkap dependensi temporal dua arah, yang sangat berguna untuk memahami dinamika jangka pendek dalam data iklim [66]. Sebaliknya, pada skala menengah (SPEI-3) dan panjang (SPEI-6), model LSTM tampak lebih unggul secara numerik. Hal ini mengindikasikan potensi efektivitas LSTM dalam menangkap pola jangka menengah hingga panjang dalam data iklim yang bersifat sekuensial [52].

Meskipun demikian, keunggulan performa model yang teramati secara deskriptif ini tidak terbukti signifikan secara statistik. Hasil uji Friedman menunjukkan nilai  $p > 0,05$  untuk semua skala waktu, yang berarti tidak ada cukup bukti untuk menyatakan satu model lebih baik dari yang lain. Salah satu faktor utama yang dapat menjelaskan rendahnya signifikansi ini adalah jumlah data pengujian yang relatif terbatas ( $n=36$ ). Ukuran sampel ini membatasi kekuatan statistik dari pengujian, sehingga sulit untuk mendeteksi perbedaan halus antar model sebagai sesuatu yang signifikan.

Oleh karena itu, meskipun ada tren yang menunjukkan spesialisasi model pada skala waktu tertentu, kesimpulan yang lebih kuat dari hasil ini adalah bahwa ketiga model memiliki performa yang sebanding secara statistik dalam memprediksi SPEI pada dataset ini. Adapun peningkatan performa prediksi seiring bertambahnya skala waktu (dari SPEI-1 ke SPEI-6) yang diamati pada semua model konsisten dengan penelitian sebelumnya [41], [67],

[68], [69], [70], [71]. Peningkatan performa ini terjadi karena berkurangnya osilasi dalam data deret waktu kekeringan jangka panjang dibandingkan dengan deret waktu kekeringan jangka pendek.

Model yang digunakan dalam penelitian ini memiliki keterbatasan masing-masing. Prophet merupakan model yang sederhana dan cepat, namun mengandalkan asumsi aditif terhadap komponen tren dan musiman sehingga kurang efektif dalam menangkap pola nonlinier dan interaksi kompleks dalam data iklim, terutama pada prediksi jangka panjang [36]. Bi-LSTM cenderung membutuhkan waktu pelatihan lebih lama dan jumlah data yang lebih besar untuk menghindari overfitting. Sedangkan LSTM dapat mengalami degradasi performa jika konfigurasi *hyperparameter* tidak optimal atau jika terjadi ketidakseimbangan data pelatihan. Selain itu, potensi kesalahan prediksi juga dapat muncul akibat noise dalam input data, misalnya fluktuasi curah hujan atau suhu yang ekstrem, kesalahan pengukuran, atau keterbatasan dalam kualitas data historis.

Secara keseluruhan, penerapan indeks kekeringan SPEI yang dikombinasikan dengan teknik *machine learning* dan *deep learning* memberikan instrumen yang efektif untuk memantau, memprediksi, dan mengevaluasi kondisi kekeringan. Pendekatan ini mampu mengidentifikasi dinamika kekeringan pada berbagai skala waktu. Hasil penelitian ini dapat digunakan sebagai dasar dalam perumusan kebijakan adaptif di tingkat daerah, khususnya dalam sektor pertanian, pengelolaan sumber daya air, dan manajemen risiko bencana.

Keakuratan model dalam memetakan risiko kekeringan jangka pendek hingga panjang membuka peluang integrasi ke dalam sistem peringatan dini berbasis data yang berguna untuk meningkatkan kesiapsiagaan pemerintah daerah terhadap kekeringan. Penelitian lanjutan disarankan untuk menggabungkan pendekatan *hybrid* dan mempertimbangkan variabel iklim tambahan seperti indeks sirkulasi atmosfer, fenomena ENSO, atau perubahan penggunaan lahan, guna meningkatkan akurasi prediksi serta mendukung strategi mitigasi kekeringan yang berkelanjutan. Sebagai langkah lanjut, pengembangan sistem prediksi yang terintegrasi dalam *dashboard* manajemen bencana daerah sangat direkomendasikan agar hasil model dapat diakses secara waktu nyata dan dimanfaatkan langsung oleh pengambil kebijakan.

#### 4. KESIMPULAN

Penelitian ini telah mengidentifikasi karakteristik kekeringan serta melakukan prediksi indeks kekeringan SPEI di wilayah Waduk Gajah Mungkur, Kabupaten Wonogiri, pada berbagai skala waktu (1, 3, dan 6 bulan) menggunakan model LSTM, Bi-LSTM, dan Prophet. Hasil penelitian menunjukkan bahwa karakteristik kekeringan berbeda antar skala waktu, di mana semakin panjang skala SPEI, distribusi kekeringan cenderung lebih terkonsentrasi secara temporal. Berdasarkan SPEI-6 yang merepresentasikan kekeringan jangka panjang selama periode 1995–2024, terdeteksi sebanyak 55 bulan kekeringan yang terdiri dari 2 bulan kering ekstrem, 26 bulan sangat kering, dan 27 bulan agak kering. Episode kekeringan terjadi pada tahun 1996–1997, 2000–2007, 2019, serta 2023–2024, yang mencerminkan sifat kekeringan yang persisten dan meluas. Dari aspek evaluasi performa prediksi, terdapat kecenderungan numerik di mana model Bi-LSTM menunjukkan hasil terbaik untuk SPEI-1 (MAE: 0,52; RMSE: 0,68;  $R^2$ : 0,74), sementara LSTM tampak unggul untuk SPEI-33 (MAE: 0,29; RMSE: 0,48; dan  $R^2$ : 0,90) dan SPEI-6 (MAE: 0,18; RMSE: 0,24;  $R^2$ : 0,97). Meskipun demikian, uji signifikansi statistik (Uji Friedman) menunjukkan bahwa perbedaan performa ini tidak signifikan secara statistik ( $p > 0.05$ ). Hasil ini mengindikasikan bahwa ketiga model memiliki performa prediksi yang sebanding secara statistik pada dataset penelitian ini. Oleh karena itu, pemilihan model dalam aplikasi praktis dapat mempertimbangkan faktor lain di luar akurasi, seperti efisiensi komputasi atau kemudahan implementasi. Secara praktis, hasil penelitian bermanfaat bagi pengambil kebijakan daerah dalam perencanaan mitigasi kekeringan dan pengelolaan sumber daya air. Sebagai pengembangan ke depan, disarankan untuk mengintegrasikan sistem prediksi kekeringan ke dalam *dashboard* manajemen bencana daerah, guna meningkatkan respon adaptif terhadap potensi kekeringan serta mendukung pengambilan keputusan yang berbasis data.

#### REFERENCES

- [1] B. Zahraie, M. Nasser, and F. Nematizadeh, "Exploring Spatiotemporal Meteorological Correlations for Basin Scale Meteorological Drought Forecasting using Data Mining Methods," *Arab. J. Geosci.*, vol. 10, no. 19, p. 419, Oct. 2017, doi: 10.1007/s12517-017-3211-x.
- [2] C. R. Schwalm *et al.*, "Global Patterns of Drought Recovery," *Nature*, vol. 548, no. 7666, pp. 202–205, Aug. 2017, doi: 10.1038/nature23021.
- [3] S. M. Vicente-Serrano, G. Van der Schrier, S. Begueria, C. Azorin-Molina, and J.-I. Lopez-Moreno, "Contribution of Precipitation and Reference Evapotranspiration to Drought Indices under Different Climates," *J. Hydrol.*, vol. 526, pp. 42–54, Jul. 2015, doi: 10.1016/j.jhydrol.2014.11.025.
- [4] N. Khan, D. A. Sachindra, S. Shahid, K. Ahmed, M. S. Shiru, and N. Nawaz, "Prediction of Droughts over Pakistan using Machine Learning Algorithms," *Adv. Water Resour.*, vol. 139, p. 103562, May 2020, doi: 10.1016/j.advwatres.2020.103562.
- [5] M. C. Anderson *et al.*, "The Evaporative Stress Index as an Indicator of Agricultural Drought in Brazil: An Assessment based on Crop Yield Impacts," *Remote Sens. Environ.*, vol. 174, pp. 82–99, Mar. 2016, doi: 10.1016/j.rse.2015.11.034.
- [6] L. Xu, N. Chen, X. Zhang, and Z. Chen, "An Evaluation of Statistical, NMME and Hybrid Models for Drought Prediction in China," *J. Hydrol.*, vol. 566, pp. 235–249, Nov. 2018, doi: 10.1016/j.jhydrol.2018.09.020.
- [7] N. Khan, S. Shahid, E.-S. Chung, S. Kim, and R. Ali, "Influence of Surface Water Bodies on the Land Surface Temperature

- of Bangladesh,” *Sustainability*, vol. 11, no. 23, p. 6754, Nov. 2019, doi: 10.3390/su11236754.
- [8] R. G. Gavilan, J. Caro-Castro, and J. Trinanes, “A New Generation of Real-Time Environmental Monitoring Systems to Study the Impact of El Niño on Disease Dynamics,” *Curr. Opin. Biotechnol.*, vol. 81, p. 102924, Jun. 2023, doi: 10.1016/J.COPBIO.2023.102924.
- [9] M. D. Setiawati *et al.*, “Climate Change and Anthropogenic Pressure on Bintan Islands, Indonesia: An Assessment of the Policies Proposed by Local Authorities,” *Reg. Stud. Mar. Sci.*, vol. 66, p. 103123, 2023, doi: <https://doi.org/10.1016/j.rsma.2023.103123>.
- [10] M. Z. Ramdhani, F. Arifianto, and G. Giarno, “Perbandingan Standardized Precipitation Index dan Standardized Anomaly Index untuk Penentuan Tingkat Kekeringan di Kabupaten Sragen, Jawa Tengah,” *Semesta Tek.*, vol. 26, no. 1, pp. 86–96, 2023, doi: 10.18196/st.v26i1.16310.
- [11] Y. Zhang, H. Yang, H. Cui, and Q. Chen, “Comparison of the Ability of ARIMA, WNN and SVM Models for Drought Forecasting in the Sanjiang Plain, China,” *Nat. Resour. Res.*, vol. 29, no. 2, pp. 1447–1464, Apr. 2020, doi: 10.1007/s11053-019-09512-6.
- [12] Z. Tarawneh and Y. Khalayleh, “Improved Estimate of Multiyear Drought for Water Resources Management Studies,” *J. Water Clim. Chang.*, vol. 7, no. 4, pp. 721–730, Dec. 2016, doi: 10.2166/wcc.2016.151.
- [13] S. M. Vicente-Serrano, S. Beguería, and J. I. López-Moreno, “A Multiscalar Drought Index Sensitive to Global Warming: The Standardized Precipitation Evapotranspiration Index,” *J. Clim.*, vol. 23, no. 7, pp. 1696–1718, Apr. 2010, doi: 10.1175/2009JCLI2909.1.
- [14] J. Das, A. Gayen, P. Saha, and S. K. Bhattacharya, “Meteorological Drought Analysis Using Standardized Precipitation Index over Luni River Basin in Rajasthan, India,” *SN Appl. Sci.*, vol. 2, no. 9, p. 1530, Sep. 2020, doi: 10.1007/s42452-020-03321-w.
- [15] S. Beguería, S. M. Vicente-Serrano, F. Reig, and B. Latorre, “Standardized Precipitation Evapotranspiration Index (SPEI) Revisited: Parameter Fitting, Evapotranspiration Models, Tools, Datasets and Drought Monitoring,” *Int. J. Climatol.*, vol. 34, no. 10, pp. 3001–3023, Aug. 2014, doi: 10.1002/joc.3887.
- [16] B. Y. Tam, A. J. Cannon, and B. R. Bonsal, “Standardized Precipitation Evapotranspiration Index (SPEI) for Canada: Assessment of Probability Distributions,” *Can. Water Resour. J. / Rev. Can. des ressources hydriques*, vol. 48, no. 3, pp. 283–299, Jul. 2023, doi: 10.1080/07011784.2023.2183143.
- [17] K. Pyarali, J. Peng, M. Disse, and Y. Tuo, “Development and Application of High Resolution SPEI Drought Dataset for Central Asia,” *Sci. Data*, vol. 9, no. 1, p. 172, Apr. 2022, doi: 10.1038/s41597-022-01279-5.
- [18] M. F. U. Moazzam, G. Rahman, S. Munawar, N. Farid, and B. G. Lee, “Spatiotemporal Rainfall Variability and Drought Assessment during Past Five Decades in South Korea Using SPI and SPEI,” *Atmosphere (Basel)*, vol. 13, no. 2, p. 292, Feb. 2022, doi: 10.3390/atmos13020292.
- [19] S. Ali *et al.*, “The Role of Climate Change and Its Sensitivity on Long-Term Standardized Precipitation Evapotranspiration Index, Vegetation and Drought Changing Trends over East Asia,” *Plants*, vol. 13, no. 3, p. 399, Jan. 2024, doi: 10.3390/plants13030399.
- [20] Q. He, M. Wang, K. Liu, and B. Wang, “High-resolution Standardized Precipitation Evapotranspiration Index (SPEI) reveals trends in drought and vegetation water availability in China,” *Geogr. Sustain.*, vol. 6, no. 2, p. 100228, Apr. 2025, doi: 10.1016/j.geosus.2024.08.007.
- [21] C. Liu, C. Yang, Q. Yang, and J. Wang, “Spatiotemporal Drought Analysis by the Standardized Precipitation Index (SPI) and Standardized Precipitation Evapotranspiration Index (SPEI) in Sichuan Province, China,” *Sci. Rep.*, vol. 11, no. 1, p. 1280, Jan. 2021, doi: 10.1038/s41598-020-80527-3.
- [22] X. Shi, Y. Yang, H. Ding, F. Chen, and M. Shi, “Analysis of the Variability Characteristics and Applicability of SPEI in Mainland China from 1985 to 2018,” *Atmosphere (Basel)*, vol. 14, no. 5, p. 790, Apr. 2023, doi: 10.3390/atmos14050790.
- [23] J. Zhao, Q. Liu, H. Lu, Z. Wang, K. Zhang, and P. Wang, “Future Droughts in China Using the Standardized Precipitation Evapotranspiration Index (SPEI) Under Multi-spatial Scales,” *Nat. Hazards*, vol. 109, no. 1, pp. 615–636, Oct. 2021, doi: 10.1007/s11069-021-04851-1.
- [24] H. Zhao, Y. Huang, X. Wang, X. Li, and T. Lei, “The Performance of SPEI Integrated Remote Sensing Data for Monitoring Agricultural Drought in the North China Plain,” *F. Crop. Res.*, vol. 302, p. 109041, Oct. 2023, doi: 10.1016/j.fcr.2023.109041.
- [25] L. Wan *et al.*, “Drought Characteristics and Dominant Factors Across China: Insights from High-Resolution Daily SPEI Dataset Between 1979 and 2018,” *Sci. Total Environ.*, vol. 901, p. 166362, Nov. 2023, doi: 10.1016/j.scitotenv.2023.166362.
- [26] Z. Wang, Q. Zhang, S. Sun, and P. Wang, “Interdecadal Variation of the Number of Days with Drought in China Based on the Standardized Precipitation Evapotranspiration Index (SPEI),” *J. Clim.*, vol. 35, no. 6, pp. 2003–2018, Mar. 2022, doi: 10.1175/JCLI-D-20-0985.1.
- [27] J. Peng *et al.*, “A Pan-African High-Resolution Drought Index Dataset,” *Earth Syst. Sci. Data*, vol. 12, no. 1, pp. 753–769, Mar. 2020, doi: 10.5194/essd-12-753-2020.
- [28] M. A. Worku, “Spatiotemporal Analysis of Drought Severity Using SPI and SPEI: Case Study of Semi-Arid Borana Area, Southern Ethiopia,” *Front. Environ. Sci.*, vol. 12, Mar. 2024, doi: 10.3389/fenvs.2024.1337190.
- [29] M. B. Mukhawana, T. Kanyerere, and D. Kahler, “Review of In-Situ and Remote Sensing-Based Indices and Their Applicability for Integrated Drought Monitoring in South Africa,” *Water*, vol. 15, no. 2, p. 240, Jan. 2023, doi: 10.3390/w15020240.
- [30] K. T. Alito, M. S. Kerebih, and D. A. Hailu, “Characterization of Drought Detection With Remote Sensing Based Multiple Indices and SPEI in Northeastern Ethiopian Highland,” *Air, Soil Water Res.*, vol. 18, Mar. 2025, doi: 10.1177/11786221251328833.
- [31] Suroso, D. Nadhilah, Ardiansyah, and E. Aldrian, “Drought Detection in Java Island Based on Standardized Precipitation and Evapotranspiration Index (SPEI),” *J. Water Clim. Chang.*, vol. 12, no. 6, pp. 2734–2752, Sep. 2021, doi: 10.2166/wcc.2021.022.
- [32] N. Sunusi and N. H. Auliana, “Assessing SPI and SPEI for Drought Forecasting Through the Power Law Process: A Case Study in South Sulawesi, Indonesia,” *MethodsX*, vol. 14, p. 103235, Jun. 2025, doi: 10.1016/j.mex.2025.103235.



- [33] D. P. Ariyanto, A. Aziz, K. Komariah, S. Sumani, and M. Abara, “Comparing the Accuracy of Estimating Soil Moisture Using the Standardized Precipitation Index (SPI) and the Standardized Precipitation Evapotranspiration Index (SPEI),” *SAINS TANAH - J. Soil Sci. Agroclimatol.*, vol. 17, no. 1, p. 23, Jun. 2020, doi: 10.20961/stjsa.v17i1.41396.
- [34] I. Bordi and A. Sutera, “Drought Monitoring and Forecasting at Large Scale,” in *Methods and Tools for Drought Analysis and Management*, Dordrecht: Springer Netherlands, pp. 3–27, doi: 10.1007/978-1-4020-5924-7\_1.
- [35] Y. W. Soh, C. H. Koo, Y. F. Huang, and K. F. Fung, “Application of Artificial Intelligence Models for the Prediction of Standardized Precipitation Evapotranspiration Index (SPEI) at Langat River Basin, Malaysia,” *Comput. Electron. Agric.*, vol. 144, pp. 164–173, Jan. 2018, doi: 10.1016/j.compag.2017.12.002.
- [36] S. J. Taylor and B. Letham, “Forecasting at Scale,” *Am. Stat.*, vol. 72, no. 1, pp. 37–45, Jan. 2018, doi: 10.1080/00031305.2017.1380080.
- [37] A. Basak, A. T. M. S. Rahman, J. Das, T. Hosono, and O. Kisi, “Drought Forecasting Using the Prophet Model in a Semi-Arid Climate Region of Western India,” *Hydrol. Sci. J.*, vol. 67, no. 9, pp. 1397–1417, Jul. 2022, doi: 10.1080/02626667.2022.2082876.
- [38] A. T. M. S. Rahman, T. Hosono, O. Kisi, B. Dennis, and A. H. M. R. Imon, “A Minimalistic Approach for Evapotranspiration Estimation Using the Prophet Model,” *Hydrol. Sci. J.*, vol. 65, no. 12, pp. 1994–2006, Sep. 2020, doi: 10.1080/02626667.2020.1787416.
- [39] M. A. Hossain, M. M. Rahman, S. S. Hasan, A. Mahmud, and L. Bai, “Analysis and Forecasting of Meteorological Drought Using PROPHET and SARIMA Models Deploying Machine Learning Technique for Southwestern Region of Bangladesh,” *Environ. Sustain. Indic.*, vol. 27, p. 100761, Sep. 2025, doi: 10.1016/j.indic.2025.100761.
- [40] A. Dikshit, B. Pradhan, and A. Huete, “An Improved SPEI Drought Forecasting Approach Using the Long Short-Term Memory Neural Network,” *J. Environ. Manage.*, vol. 283, p. 111979, Apr. 2021, doi: 10.1016/j.jenvman.2021.111979.
- [41] J. Shang, B. Zhao, H. Hua, J. Wei, G. Qin, and G. Chen, “Application of Informer Model Based on SPEI for Drought Forecasting,” *Atmosphere (Basel)*, vol. 14, no. 6, p. 951, May 2023, doi: 10.3390/atmos14060951.
- [42] J. Dong, L. Xing, N. Cui, L. Zhao, L. Guo, and D. Gong, “Standardized Precipitation Evapotranspiration Index (SPEI) Estimated Using Variant Long Short-Term Memory Network at Four Climatic Zones of China,” *Comput. Electron. Agric.*, vol. 213, p. 108253, Oct. 2023, doi: 10.1016/j.compag.2023.108253.
- [43] F. Granata and F. Di Nunno, “Evolving Drought Dynamics in Barcelona: Leveraging a Bayesian Ensemble Algorithm for Insightful Analysis and a Bidirectional Long Short-Term Memory Network for Predictive Modeling,” *Stoch. Environ. Res. Risk Assess.*, vol. 39, no. 4, pp. 1253–1270, Apr. 2025, doi: 10.1007/s00477-024-02900-2.
- [44] S. Yalçın, M. Eşit, and Ö. Çoban, “A New Deep Learning Method for Meteorological Drought Estimation Based-On Standard Precipitation Evapotranspiration Index,” *Eng. Appl. Artif. Intell.*, vol. 124, p. 106550, Sep. 2023, doi: 10.1016/j.engappai.2023.106550.
- [45] Y. LeCun, Y. Bengio, and G. Hinton, “Deep Learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [46] A. Graves and J. Schmidhuber, “Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures,” *Neural Networks*, vol. 18, no. 5–6, pp. 602–610, Jul. 2005, doi: 10.1016/j.neunet.2005.06.042.
- [47] A. D. H. Bahri, A. K. Mudzakir, and I. Triarso, “Analisis Kinerja Koperasi Unit Desa (KUD) Mina Tirta di Waduk Gajah Mungkur Kabupaten Wonogiri,” *J. Fish. Resour. Util. Manag. Technol.*, vol. 9, no. 3, pp. 1–25, 2020.
- [48] BPS, *Kabupaten Wonogiri dalam Angka Tahun 2025*. Wonogiri: BPS Kabupaten Kabupaten Wonogiri, 2025.
- [49] C. W. Thornthwaite, “An Approach Toward a Rational Classification of Climate,” *Geogr. Rev.*, vol. 38, no. 1, p. 55, Jan. 1948, doi: 10.2307/210739.
- [50] V. Potop, C. Boroneanț, M. Možný, P. Štěpánek, and P. Skalák, “Observed Spatiotemporal Characteristics of Drought on Various Time Scales Over the Czech Republic,” *Theor. Appl. Climatol.*, vol. 115, no. 3, pp. 563–581, 2014, doi: 10.1007/s00704-013-0908-y.
- [51] A. Shekhar and C. A. Shapiro, “What Do Meteorological Indices Tell Us About a Long-Term Tillage Study?,” *Soil Tillage Res.*, vol. 193, pp. 161–170, Oct. 2019, doi: 10.1016/j.still.2019.06.004.
- [52] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [53] F. Friedrichs and C. Igel, “Evolutionary Tuning of Multiple SVM Parameters,” *Neurocomputing*, vol. 64, pp. 107–117, Mar. 2005, doi: 10.1016/j.neucom.2004.11.022.
- [54] P. R. Lorenzo, J. Nalepa, M. Kawulok, L. S. Ramos, and J. R. Pastor, “Particle Swarm Optimization for Hyper-parameter Selection in Deep Neural Networks,” in *Proceedings of the Genetic and Evolutionary Computation Conference*, New York, NY, USA: ACM, Jul. 2017, pp. 481–488. doi: 10.1145/3071178.3071208.
- [55] F. A. Prodhan, J. Zhang, S. S. Hasan, T. P. Pangali Sharma, and H. P. Mohana, “A Review of Machine Learning Methods for Drought Hazard Monitoring and Forecasting: Current Research Trends, Challenges, and Future Research Directions,” *Environ. Model. Softw.*, vol. 149, p. 105327, Mar. 2022, doi: 10.1016/j.envsoft.2022.105327.
- [56] T. Chai and R. R. Draxler, “Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? — Arguments Against Avoiding RMSE in the Literature,” *Geosci. Model Dev.*, vol. 7, no. 3, pp. 1247–1250, Jun. 2014, doi: 10.5194/gmd-7-1247-2014.
- [57] J. Demsar, “Statistical Comparisons of Classifiers Over Multiple Data Sets,” *J. Mach. Learn. Res.*, vol. 7, pp. 1–30, 2006.
- [58] K. F. Fung, Y. F. Huang, and C. H. Koo, “Assessing drought conditions through temporal pattern, spatial characteristic and operational accuracy indicated by SPI and SPEI: case analysis for Peninsular Malaysia,” *Nat. Hazards*, vol. 103, no. 2, pp. 2071–2101, 2020, doi: 10.1007/s11069-020-04072-y.
- [59] B. Bera, P. K. Shit, N. Sengupta, S. Saha, and S. Bhattacharjee, “Trends and Variability of Drought in the Extended Part of Chhota Nagpur Plateau (Singbhum Protocontinent), India Applying SPI and SPEI Indices,” *Environ. Challenges*, vol. 5, p. 100310, 2021, doi: https://doi.org/10.1016/j.envc.2021.100310.
- [60] S. M. Vicente-Serrano *et al.*, “Performance of Drought Indices for Ecological, Agricultural, and Hydrological Applications,” *Earth Interact.*, vol. 16, no. 10, pp. 1–27, 2012.
- [61] M. D. Svoboda, B. A. Fuchs, and others, *Handbook of Drought Indicators and Indices*, vol. 2. World Meteorological



Organization Geneva, Switzerland, 2016.

- [62] S. M. Vicente-Serrano *et al.*, “A Multiscalar Global Evaluation of the Impact of ENSO on Droughts,” *J. Geophys. Res.*, vol. 116, no. D20, p. D20109, Oct. 2011, doi: 10.1029/2011JD016039.
- [63] D. Manatsa, T. Mushore, and A. Lenouo, “Improved predictability of droughts over southern Africa using the standardized precipitation evapotranspiration index and ENSO,” *Theor. Appl. Climatol.*, vol. 127, no. 1–2, pp. 259–274, Jan. 2017, doi: 10.1007/s00704-015-1632-6.
- [64] S. Sanjaya, B. Koes Paulina Cantik, and A. Septya Wardaningrum, “Analisis Derajat Bencana Kekeringan di Pulau Jawa Akibat Fenomena El-Nino 2023,” *J. Tek. Sumber Daya Air*, vol. 4, no. 2, pp. 115–126, 2024, doi: 10.56860/jtsda.v4i2.124.
- [65] P. Nguyen, S. Min, and Y. Kim, “Combined Impacts of the El Niño-Southern Oscillation and Pacific Decadal Oscillation on Global Droughts Assessed Using the Standardized Precipitation Evapotranspiration Index,” *Int. J. Climatol.*, vol. 41, no. S1, Jan. 2021, doi: 10.1002/joc.6796.
- [66] M. Schuster and K. K. Paliwal, “Bidirectional Recurrent Neural Networks,” *IEEE Trans. Signal Process.*, vol. 45, no. 11, pp. 2673–2681, 1997, doi: 10.1109/78.650093.
- [67] S. S. Band *et al.*, “Evaluation of Time Series Models in Simulating Different Monthly Scales of Drought Index for Improving Their Forecast Accuracy,” *Front. Earth Sci.*, vol. 10, Feb. 2022, doi: 10.3389/feart.2022.839527.
- [68] K. Sundararajan *et al.*, “A Contemporary Review on Drought Modeling Using Machine Learning Approaches,” *Comput. Model. Eng. Sci.*, vol. 128, no. 2, pp. 447–487, 2021, doi: 10.32604/cmescs.2021.015528.
- [69] N. A. Hasan, Y. Dongkai, and F. Al-Shibli, “SPI and SPEI Drought Assessment and Prediction Using TBATS and ARIMA Models, Jordan,” *Water*, vol. 15, no. 20, p. 3598, Oct. 2023, doi: 10.3390/w15203598.
- [70] J. A. Melchor Varela and osephe I. Ramírez Hernández, “Prediction of Hydrological Drought by the Standardized Precipitation Evapotranspiration Index in Chihuahua, Mexico, Using Machine Learning Algorithms,” *Atmósfera*, vol. 38, Jul. 2024, doi: 10.20937/ATM.53355.
- [71] M. Lotfirad, H. Esmaceli-Gisavandani, and A. Adib, “Drought Monitoring and Prediction Using SPI, SPEI, and Random Forest Model in Various Climates of Iran,” *J. Water Clim. Chang.*, vol. 13, no. 2, pp. 383–406, Feb. 2022, doi: 10.2166/wcc.2021.287.