

TUGAS AKHIR

**PREDIKSI CURAH HUJAN DASARIAN
SUMATERA SELATAN DENGAN LONG SHORT-TERM
MEMORY**



Oleh:

Rheza Rijaya 2024250001

**PROGRAM STUDI INFORMATIKA
FAKULTAS ILMU KOMPUTER DAN REKAYASA
UNIVERSITAS MULTI DATA PALEMBANG
PALEMBANG
2024**

**Fakultas Ilmu Komputer dan Rekayasa
Universitas Multi Data Palembang**

Program Studi Informatika
Tugas Akhir Sarjana Komputer
Semester Genap Tahun 2023/2024

**PREDIKSI CURAH HUJAN DASARIAN SUMATERA SELATAN
DENGAN LONG SHORT-TERM MEMORY**

Rheza Rijaya 2024250001

Abstrak

Hujan adalah peristiwa presipitasi atau jatuhnya cairan dalam wujud cair atau beku dari atmosfer ke permukaan bumi. Hujan dapat membawa manfaat serta bencana bagi kehidupan di muka bumi. Adanya prakiraan curah hujan yang akurat dapat membantu mitigasi bencana alam yang dapat mengganggu kehidupan manusia. Iklim Indonesia yang beragam menyebabkan hasil prediksi curah hujan lebih sulit untuk mencapai akurasi yang tinggi, dimana hal ini juga terjadi di Sumatera Selatan. Penelitian ini bertujuan untuk membuat suatu sistem yang dapat memprediksi curah hujan dasarian di daerah Sumatera Selatan, yang dapat membantu proses prakiraan musim. Metode yang digunakan adalah *Long Short-Term Memory*. Hasil performa model secara per-*timestep* untuk RMSE di antara 43,89 dan 45,17, dan akurasi untuk kategori tingkatan curah hujan di antara 63,79% dan 68,01%, serta performa secara per-bulan untuk RMSE di antara 31,25 dan 56,50, dan akurasi untuk kategori tingkatan curah hujan di antara 53,26% dan 78,47%.

Kata kunci: Curah Hujan, Dasarian, Long Short-Term Memory

BAB 1

PENDAHULUAN

1.1. Latar Belakang Masalah

Hujan adalah peristiwa presipitasi atau jatuhnya cairan dalam wujud cair atau beku dari atmosfer ke permukaan bumi karena adanya proses kondensasi uap air di atmosfer (Winarno dkk., 2019). Hujan dapat membawa manfaat serta bencana bagi kehidupan di muka bumi. Berdasarkan penelitian yang dilakukan untuk memetakan bencana hidrometeorologi di Daerah Aliran Sungai Enim, Sumatera Selatan, didapatkan bahwa morfologi sungai yang berubah karena kegiatan manusia serta proyeksi curah hujan yang terus meningkat pada periode 2020-2035 dan 2031-2045, akan menyebabkan probabilitas bencana yang lebih tinggi (Milanda & Setiawan, 2019). Kemudian, kebakaran lahan dan hutan yang terjadi di Banyuasin, Sumatera Selatan pada tahun 2018-2020 memiliki korelasi yang signifikan antara peningkatan jumlah *hotspot* dan penurunan curah hujan (Zaskia dkk., 2023). Perubahan pola curah hujan karena perubahan iklim juga memiliki dampak penurunan produksi tanaman, terutama produksi padi di Sumatera Selatan hingga rata-rata 1,37% per tahun (Ruminta dkk., 2018). Oleh karena itu, adanya prakiraan curah hujan yang akurat dapat membantu mitigasi bencana alam yang dapat mengganggu kehidupan manusia.

Di Indonesia, terdapat 2 musim yaitu musim kemarau dan musim hujan. Dalam penentuan jenis musim, curah hujan dasarian merupakan indikator yang digunakan oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Curah

hujan dasarian adalah curah hujan akumulasi selama 10 hari, dimana dalam 1 bulan dibagi menjadi 3 dasarian, yaitu dasarian 1 pada tanggal 1 sampai tanggal 10, dasarian 2 pada tanggal 11 sampai tanggal 20, dan dasarian 3 pada tanggal 21 sampai akhir bulan. Suatu lokasi dapat dinyatakan musim kemarau jika curah hujan dasarian pada minimal 3 dasarian berurutan kurang dari 50 milimeter, atau total curah hujan untuk 3 dasarian tersebut kurang dari 150 milimeter (dengan syarat curah hujan dasarian pertama kurang dari 50 milimeter). Sebaliknya, suatu lokasi dapat dinyatakan musim hujan jika curah hujan dasarian pada minimal 3 dasarian berurutan lebih besar atau sama dengan 50 milimeter, atau total curah hujan 3 dasarian tersebut lebih besar atau sama dengan 150 milimeter (dengan syarat curah hujan dasarian pertama lebih besar atau sama dengan 50 milimeter) (BMKG, 2023).

Curah hujan atau parameter cuaca lain umumnya diprediksi menggunakan metode *Numerical Weather Prediction* (NWP). Metode ini menggunakan beberapa persamaan diferensial parsial (PDP) yang dapat menyatakan perubahan keadaan atmosfer. Dengan mengintegrasikan persamaan diferensial parsial tersebut jika diberikan kondisi awal berupa keadaan atmosfer di saat ini, akan didapatkan keadaan atmosfer di waktu yang akan datang yang dapat dijadikan prediksi (Pu & Kalnay, 2018). Metode ini digunakan oleh BMKG dalam memprediksi curah hujan dasarian, dimana model yang digunakan adalah model dari *European Centre for Medium-Range Weather Forecasts* (ECMWF).

Iklim Indonesia yang beragam karena dipengaruhi beberapa aktivitas iklim seperti *El Niño Southern Oscillation* (ENSO), *Indian Ocean Dipole* (IOD), Sirkulasi Monsun Asia–Australia, dan *Inter Tropical Convergence Zone* (ITCZ),

menyebabkan hasil prediksi curah hujan lebih sulit untuk mencapai akurasi yang tinggi (BMKG, 2023). Dalam penelitian untuk membandingkan hasil prediksi curah hujan bulanan dengan model ECMWF pada tahun 1981-2020 di Pulau Jawa yang belum dimodifikasi dan hasil prediksi yang telah dikoreksi bias-nya, didapatkan bahwa hasil prediksi yang telah dikoreksi bias-nya memiliki *Brier Skill Score* yang lebih baik (Ratri dkk., 2019). Kemudian, pada perbandingan hasil prediksi curah hujan tahun 2015-2019 dengan model ECMWF di Sulawesi dan hasil prediksi yang telah diperbaiki bias-nya dengan metode *Linear Scaling* (LS) dan *Quantile Mapping* (QM), didapatkan bahwa hasil koreksi bias memiliki nilai yang lebih mendekati nilai observasi (Kurnia dkk., 2020). Dengan menggunakan metode *distribution mapping* untuk koreksi bias prediksi curah hujan bulanan dengan model *Regional Climate Model* (RCM) CORDEX-SEA di Pulau Sumatera, didapatkan R^2 serta koefisien korelasi (r) terhadap data observasi yang lebih baik (Nur dkk., 2021). Hal ini menunjukkan bahwa model NWP global masih memiliki bias yang dapat mengurangi ketepatan prediksi curah hujan di wilayah Indonesia, dan diperlukan juga metode lain yang dapat memprediksi curah hujan dengan lebih baik.

Berdasarkan hasil wawancara dengan Bapak Raga Ramanda Syailendra selaku Staff Bidang Data dan Informasi di BMKG Sumatera Selatan, proses prediksi musim di Sumatera Selatan dilakukan 2 kali dalam satu tahun, yaitu untuk musim kemarau dan musim hujan. Pada proses tersebut, terdapat pembahasan per regional dengan data prediksi curah hujan dasarian dari BMKG pusat, dimana sumber utamanya adalah dari model ECMWF. Pembahasan tersebut bertujuan

untuk menyesuaikan hasil prediksi curah hujan dengan hasil analisis variabel dinamika atmosfer (seperti IOD, ENSO, *Madden-Julian Oscillation*), dimana adanya dinamika atmosfer dapat menyebabkan akurasi hasil prediksi curah hujan berkurang, dan akhirnya berdampak pada hasil prediksi musim. Dengan adanya model prediksi tambahan yang dapat menyesuaikan dengan dinamika atmosfer, diharapkan dapat membantu *forecaster* untuk memprediksi curah hujan dengan lebih akurat, dan akhirnya dapat membantu meningkatkan akurasi prediksi musim.

Berdasarkan permasalahan yang telah dipaparkan, dibutuhkan suatu perangkat lunak yang dapat memprediksi curah hujan dasarian, khususnya di daerah Sumatera Selatan. Diharapkan perangkat lunak yang dibuat dapat membantu pihak terkait, terutama BMKG Sumatera Selatan dalam memprediksi curah hujan dasarian, yang akhirnya dapat membantu dalam proses prediksi musim serta membantu mitigasi bencana hidrometeorologi khususnya di Sumatera Selatan.

1.2. Rumusan Masalah

Berdasarkan penjelasan pada latar belakang, dibutuhkan suatu perangkat lunak yang dapat memprediksi curah hujan dasarian di daerah Sumatera Selatan untuk membantu proses prakiraan musim di Sumatera Selatan.

1.3. Analisis terhadap Batasan

1.3.1. Analisis terhadap Aspek Ekonomis

Untuk analisis terhadap aspek ekonomis pada penelitian ini, hanya dilakukan kepada satu organisasi yang terkait sebagai pengguna, yaitu BMKG Sumatera Selatan. Karena perangkat lunak yang dirancang sifatnya mendukung

kegiatan yang sudah berjalan, maka aspek ekonomis yang dapat dianalisis adalah nilai ekonomis yang dapat diperoleh dengan penggunaan perangkat lunak yang diajukan. Berdasarkan hasil wawancara, didapatkan bahwa nilai ekonomis yang diperoleh lebih ke arah sumber daya manusia, karena perangkat lunak yang diusulkan dapat memangkas waktu proses prakiraan musim. Terutama pada proses visualisasi yang jika dilakukan manual satu per satu dapat berlangsung 10-15 menit per peta visualisasi, sedangkan jika dilakukan dengan *script* yang otomatis dapat menghasilkan 12 peta visualisasi per 10 menit. Kemudian, untuk perangkat lunak yang digunakan seperti MATLAB dan ArcGIS sudah disediakan dari BMKG pusat. Namun karena digunakan pada beberapa perangkat, biaya yang dikeluarkan cukup besar yaitu pada kisaran ratusan juta rupiah.

Dari sisi pengguna, berdasarkan (Peraturan Menteri Keuangan Nomor 113 Tahun 2023 tentang Standar Biaya Keluaran Tahun Anggaran 2024, 2023), hasil dari penelitian ini dapat digolongkan sebagai Purwarupa Hasil Riset dan Inovasi pada SBK (Standar Biaya Keluaran) Umum di kategori SBK Riset dan Inovasi. Besaran biaya untuk golongan Purwarupa Hasil Riset dan Inovasi adalah sebesar Rp 500.000.000 (lima ratus juta rupiah).

Dari sisi pengembang, untuk melakukan pengembangan perangkat lunak terdapat biaya perangkat, biaya pengembang, dan biaya *deployment*. Biaya perangkat yang diperlukan adalah sekitar Rp 7.040.000, dimana diasumsikan perangkat komputer bernilai Rp 6.500.000 (dengan spesifikasi Prosesor *Quad Core* 2 GHz, RAM 16GB, GPU NVIDIA dengan minimal VRAM 4GB, dan Penyimpanan SSD), serta biaya listrik sebesar Rp 540.000 jika diasumsikan tarif

dasar listrik adalah Rp 1.500/kWh, daya yang diperlukan komputer adalah 450 Watt atau 0,45 kWh, dan penggunaan 8 jam per hari selama 20 hari dalam 5 bulan. Kemudian untuk biaya pengembang yang diperlukan adalah sebesar Rp 40.000.000, dimana diasumsikan waktu pengerjaan adalah 5 bulan dengan biaya per bulannya adalah Rp 8.000.000 (500 US\$ dengan kurs Rp 16.000/US\$) untuk kategori *junior full-stack developer* (Glints & Monk's Hill Ventures, 2023). Untuk *deployment* perangkat lunak yang telah jadi, biaya yang diperlukan adalah sekitar Rp 311.900 per bulan (per 15 Mei 2024), dimana diasumsikan menggunakan layanan *Virtual Private Server* (VPS) Niagahoster KVM 2 dengan kapasitas 2 vCPU dan 8GB RAM. Pemilihan spesifikasi layanan *deployment* berdasarkan pada penggunaan sumber daya untuk *web server* dan inferensi model, jumlah pengguna di BMKG Sumatera Selatan (kurang dari 25 pengguna), serta aktivitas penggunaan secara bersamaan oleh beberapa pengguna terutama saat proses prediksi musim.

1.3.2. Analisis terhadap Aspek Manufakturabilitas

Untuk analisis terhadap aspek manufakturabilitas pada penelitian ini, hanya dilakukan kepada satu organisasi yang terkait sebagai pengguna, yaitu BMKG Sumatera Selatan. Pada Tabel 1.1 terdapat hasil analisis aspek manufakturabilitas berdasarkan wawancara yang telah dilakukan. Penentuan waktu implementasi berdasarkan pada (Sommerville, 2011) yang menyatakan bahwa umumnya waktu per sub-pekerjaan pada suatu proyek berlangsung selama 1 minggu, dan tidak lebih lama dari 2 bulan. Serta adanya waktu kontingensi juga dapat ditambahkan untuk mengantisipasi permasalahan yang mungkin terjadi.

Sehingga sub-pekerjaan pada proyek ini adalah implementasi model, implementasi antarmuka, dan *deployment* agar dapat diakses dari *web browser*. Untuk implementasi model, waktu yang dibutuhkan adalah 3 bulan, hal ini karena memerlukan waktu kontingensi yang lebih lama untuk mengantisipasi kendala saat pengolahan data, pelatihan model, dan evaluasi model. Untuk implementasi antarmuka, waktu yang dibutuhkan adalah 1 bulan, hal ini karena antarmuka hanya memiliki beberapa fitur yang tergolong tidak kompleks. Terakhir, untuk *deployment* memerlukan waktu 1 bulan. Walau *deployment* dapat dilakukan dalam waktu 1 minggu, waktu kontingensi yang lebih lama diperlukan untuk mengantisipasi kendala pengaturan *server* dan pengujian keandalan.

Tabel 1.1 Hasil Analisis Aspek Manufakturabilitas

No	Aspek	Respon
1	Model prediksi curah hujan dasarian Sumatera Selatan (3 bulan)	OK
2	Dapat digunakan dengan mudah melalui antarmuka yang ramah pengguna, visualisasi hasil prediksi, dan pengunduhan <i>file</i> hasil prediksi (1 bulan)	OK
3	Dapat diakses melalui <i>web browser</i> (1 bulan)	OK
	Total : 5 bulan	

1.3.3. Analisis terhadap Aspek Sustainability

Untuk analisis terhadap aspek sustainability pada penelitian ini, hanya dilakukan kepada satu organisasi yang terkait sebagai pengguna, yaitu BMKG Sumatera Selatan. Pada Tabel 1.2 terdapat hasil analisis aspek sustainability berdasarkan wawancara yang telah dilakukan. Dalam *User Experience*, waktu respon perangkat lunak yang baik umumnya berada di antara 0,1 hingga 1 detik untuk menjaga fokus pengguna. Namun setelah 1 detik, pengguna dapat merasakan waktu untuk menunggu suatu proses, dan setelah 10 detik fokus pengguna umumnya telah beralih ke hal lainnya. Biasanya suatu aktivitas memerlukan waktu 1 menit dari awal hingga akhir dengan memperhatikan kriteria sebelumnya pada setiap sub-aktivitas (Nielsen, 2009). Karena sistem yang diimplementasikan memproses data yang cukup besar dan bergantung pada koneksi internet, maka setiap aktivitas pada sistem ini dapat diberi batasan waktu eksekusi maksimum 1 menit.

Tabel 1.2 Hasil Analisis Aspek Sustainability

No	Aspek	Respon
1	Dapat memprediksi curah hujan dasarian Sumatera Selatan dalam waktu maksimal 1 menit	OK
2	Dapat menghasilkan visualisasi hasil prediksi dalam bentuk peta dalam waktu maksimal 1 menit	OK

3	Dapat menciptakan <i>file</i> hasil prediksi yang dapat diunduh dalam waktu maksimal 1 menit	OK
---	--	----

1.4. Analisis terhadap Karakteristik Solusi

Pada tahap ini dilakukan analisis mengenai karakteristik solusi berdasarkan masalah yang ditemukan melalui wawancara dengan pihak terkait, dimana hasil analisis dapat dilihat pada Tabel 1.3.

Tabel 1.3 Hasil Analisis Karakteristik Solusi

No	Masalah	Solusi
1	Hasil prediksi curah hujan dasarian Sumatera Selatan yang kurang akurat	Perangkat lunak yang mampu memprediksi curah hujan dasarian Sumatera Selatan
2	Kesulitan dalam memvisualisasikan hasil prediksi curah hujan dasarian	Perangkat lunak yang mampu memvisualisasikan hasil prediksi curah hujan dasarian
3	Kesulitan dalam memperoleh <i>file</i> hasil prediksi curah hujan dasarian	Perangkat lunak yang mampu menyediakan hasil prediksi curah hujan dasarian dalam bentuk <i>file</i>

1.5. Pemilihan Solusi

Salah satu metode lain yang dapat digunakan untuk memprediksi curah hujan adalah dengan *Machine Learning* yang sifatnya *data-driven*. *Machine Learning* dapat mempelajari pola pada data secara otomatis, dan pola tersebut dapat digunakan untuk memprediksi atau mengambil suatu keputusan pada data yang baru (Murphy, 2012). Dengan *Machine Learning*, persamaan atau proses cuaca yang terjadi tidak perlu didefinisikan secara eksplisit dan secara otomatis akan mempelajari pola cuaca dari data yang diberikan. Metode *Machine Learning* yang dapat digunakan dalam prediksi cuaca yang termasuk curah hujan umumnya bersifat *supervised learning*, contohnya adalah *Naive Bayes*, *k-Nearest Neighbor*, *Support Vector Machine*, *Decision Tree*, dan *Neural Network*. Namun jenis metode *Machine Learning* yang paling sering digunakan akhir-akhir ini dalam prediksi cuaca adalah *Neural Network* (de Burgh-Day & Leeuwenburg, 2023).

Umumnya data cuaca bersifat *time series* dan tersebar di koordinat sebagai *grid* yang teratur. Sehingga untuk permasalahan ini, jenis *Neural Network* yang paling umum dan paling cocok adalah *Long Short-Term Memory (LSTM)*, *Gated Recurrent Unit (GRU)*, *Convolutional Neural Network (CNN)* 1 dimensi, dan *CNN-LSTM*. *LSTM* dan *GRU* dapat digunakan pada permasalahan *time series* karena mampu menyimpan informasi (*state*) dari urutan data yang diproses sebelumnya. *CNN* 1 dimensi juga dapat digunakan pada permasalahan *sequence* yang salah satunya *time series* dengan memanfaatkan fitur lokal pada urutan data (Zhang dkk., 2023). *CNN-LSTM* dapat digunakan pada permasalahan

spasiotemporal karena dapat mengambil fitur spasial dengan metode konvolusi, serta memanfaatkan LSTM untuk mengambil fitur secara temporal (Lidkk., 2022).

Penelitian yang menggunakan algoritma C4.5 untuk memprediksi cuaca di wilayah Jalur Pantura, Jawa Tengah, menghasilkan akurasi 81,94% dengan *root node* pada *decision tree* berupa parameter kelembapan (Pramudito, 2022). Kemudian, pada penelitian yang membandingkan beberapa algoritma seperti C4.5, *Naive Bayes*, dan *k-Nearest Neighbor* (kNN) untuk memprediksi kejadian hujan atau tidak hujan di daerah Jatiwangi, Majalengka, menghasilkan performa akurasi pada *cross validation* dengan *Naive Bayes* sebesar 81,15%, kNN sebesar 85,61%, dan C4.5 sebesar 88,03% (Alfian Al Arif dkk., 2022). Penelitian lain yang membandingkan metode SVM, *Naive Bayes*, kNN, *Decision Tree*, dan *Multilayer Perceptron* (MLP) untuk memprediksi kejadian hujan atau tidak hujan di kota Lahore, Pakistan, menghasilkan performa skor F_1 terbaik untuk kelas hujan dan tidak hujan pada algoritma SVM sebesar 0,958 dan 0, *Naive Bayes* sebesar 0,946 dan 0,318, kNN sebesar 0,946 dan 0,357, *Decision Tree* sebesar 0,961 dan 0,381, dan MLP sebesar 0,965 dan 0,401 (Aftab dkk., 2018).

Pada penelitian yang dilakukan untuk memprediksi curah hujan harian Kabupaten Malang, didapatkan bahwa dengan LSTM, performa terbaik yang diperoleh dengan metrik *Root Mean Squared Error* (RMSE) adalah sebesar 10,16 dan akurasi sebesar 58,54%, dengan pelatihan selama 150 *epoch* (Frecenta dkk., 2022). Kemudian, pada penelitian untuk memprediksi curah hujan harian Kota Surabaya dengan data dari dua stasiun cuaca, LSTM mampu menghasilkan nilai *Mean Squared Error* (MSE) sebesar 0,49, nilai *Mean Absolute Error* (MAE)

sebesar 0,54, dan nilai R^2 sebesar 0,497 (Badriyah dkk., 2022). Pada penelitian lain yang dilakukan untuk memprediksi curah hujan dengan data dari Stasiun Geofisika Lampung Utara, didapatkan bahwa LSTM mampu mencapai performa terbaik dengan nilai RMSE sebesar 16,81 dan nilai *Mean Absolute Deviation* (MAD) sebesar 10,43 (Carnegie & Chairani, 2023).

Penelitian yang menggunakan GRU untuk memprediksi curah hujan di Kota Bandung, mencapai performa terbaik dengan nilai RMSE sebesar 10,02 dan nilai R^2 sebesar 0,10 (Nabil & Ramdhani, 2023). Kemudian, dengan data dari Stasiun Geofisika Lampung Utara, GRU mampu memprediksi curah hujan dengan performa terbaik pada nilai RMSE sebesar 19,23 dan MAD sebesar 11,05 (Carnegie & Chairani, 2023). Penelitian lain dengan data cuaca Kota Lampung yang telah dilengkapi data *Southern Oscillation Index* (SOI), GRU mampu memprediksi curah hujan harian dengan nilai akurasi sebesar 86,41% (Fadilah dkk., 2021).

Penelitian yang menggunakan metode CNN 1 dimensi untuk memprediksi curah hujan bulanan Kota Innisfail, Queensland dengan data cuaca yang telah dilengkapi data indeks iklim, menghasilkan performa nilai RMSE sebesar 142,133, MAE sebesar 114,654, dan *Nash-Sutcliffe Efficiency* (NSE) sebesar 0,732 (Haidar & Verma, 2018). Kemudian, penelitian yang dilakukan untuk memprediksi kejadian hujan dan tidak hujan dengan resolusi per jam di India dan Amerika Utara menggunakan CNN 1 dimensi, menghasilkan performa terbaik dengan akurasi sebesar 84,97% di Amerika Utara dan 89,83% di India (Patel dkk., 2018). Penelitian lain yang menggunakan CNN 1 dimensi untuk memprediksi curah hujan bulanan

global mampu mencapai performa dengan nilai RMSE sebesar 2,44 dan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 1,7281 (Aswin dkk., 2018).

Penelitian yang menggunakan metode CNN-LSTM untuk memprediksi variabel cuaca yang termasuk curah hujan di daerah Sungai Nil, Afrika dengan data berupa citra satelit, mampu menghasilkan performa nilai MSE 5.8×10^{-6} (Fan dkk., 2022). Kemudian, penelitian yang dilakukan dengan CNN-LSTM untuk memprediksi curah hujan di daerah Karnataka, India, mampu mencapai performa untuk nilai akurasi sebesar 86,2% (Salma & A, 2022). Penelitian lain yang dilakukan untuk memprediksi curah hujan akumulasi 3 jam pada 25 titik di Kota Lanzhou, China dan sekitarnya dengan metode CNN-LSTM, menghasilkan performa akurasi rata-rata 77% untuk 5 kategori curah hujan dan akurasi rata-rata 85% untuk penentuan hujan dan tidak hujan (Li dkk., 2022).

Berdasarkan penelitian terdahulu yang telah dipaparkan, 3 metode yang memiliki performa terbaik adalah LSTM, GRU, dan CNN 1 dimensi.

1.6. Skenario Pemanfaatan Produk oleh Pengguna

Perangkat lunak yang dibuat mampu memprediksi curah hujan dasarian di daerah Sumatera Selatan. Perangkat lunak ini berjalan sebagai *web server*, sehingga antarmuka dapat diakses dari *web browser* pada semua jenis perangkat. Pengguna dapat mengunggah *file* data cuaca dengan format .csv yang ketentuan kolomnya dijelaskan pada Bagian 3.4 tentang Pengumpulan Data. Kemudian perangkat lunak mampu memprediksi curah hujan dasarian berdasarkan data cuaca yang telah

diberikan, serta memvisualisasikan hasil prediksi tersebut dan menyediakan *file* hasil prediksi dengan format .csv yang dapat diunduh.

1.7. Tujuan

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mengembangkan perangkat lunak yang dapat memprediksi curah hujan dasarian di daerah Sumatera Selatan, memvisualisasikan hasil prediksi tersebut, serta menyediakan *file* hasil prediksi yang dapat diunduh, yang dapat membantu proses prediksi musim di Sumatera Selatan.
2. Menerapkan *Long Short-Term Memory* (LSTM) untuk memprediksi curah hujan dasarian di daerah Sumatera Selatan dengan berdasarkan data curah hujan dasarian di masa lalu.

DAFTAR PUSTAKA

- Aftab, S., Ahmad, M., Hameed, N., Salman, M., Ali, I., & Nawaz, Z. (2018). Rainfall Prediction in Lahore City using Data Mining Techniques. *International Journal of Advanced Computer Science and Applications*, 9(4). <https://doi.org/10.14569/IJACSA.2018.090439>
- Agarap, A. F. (2018). *Deep Learning using Rectified Linear Units (ReLU)*.
- Alfian Al Arif, Muhammad Firdaus, Rahmaddeni, & Yustis Maruhawa. (2022). Perbandingan Metode Data Mining untuk Prediksi Curah Hujan dengan Algoritma C4.5, Naïve Bayes, dan KNN: Comparison of Data Mining Methods for Prediction of Rainfall with C4.5, Naïve Bayes, and KNN Algorithm. *SENTIMAS: Seminar Nasional Penelitian dan Pengabdian Masyarakat*, 1(1), 187–197.
- Allan, R. J., Nicholls, N., Jones, P. D., & Butterworth, I. J. (1991). A Further Extension of the Tahiti-Darwin SOI, Early ENSO Events and Darwin Pressure. *Journal of Climate*, 4(7), 743–749. [https://doi.org/10.1175/1520-0442\(1991\)004<0743:AFEOTT>2.0.CO;2](https://doi.org/10.1175/1520-0442(1991)004<0743:AFEOTT>2.0.CO;2)
- Almeida, J. (2023, Oktober 28). *Iterative Development: A Starter's Guide*. DistantJob. <https://distantjob.com/blog/iterative-development/>
- Aswin, S., Geetha, P., & Vinayakumar, R. (2018). Deep Learning Models for the Prediction of Rainfall. *2018 International Conference on Communication and Signal Processing (ICCSP)*, 0657–0661. <https://doi.org/10.1109/ICCSP.2018.8523829>
- Badriyah, J., Fariza, A., & Harsono, T. (2022). Prediksi Curah Hujan Menggunakan Long Short Term Memory. *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 6(3), 1297. <https://doi.org/10.30865/mib.v6i3.4008>
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *J. Mach. Learn. Res.*, 13(null), 281–305.
- BMKG. (2023). *Buletin Prakiraan Musim Hujan 2023/2024 di Indonesia*. Badan Meteorologi Klimatologi dan Geofisika.
- BMKG. (2024). *Streamline*. <https://web-meteo.bmkg.go.id/id/pengamatan/streamline>

- Carnegie, M. D. A., & Chairani. (2023). Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan. *Jurnal Media Informatika Budidarma*, 7(3), 1022–1032. <https://doi.org/10.30865/mib.v7i3.6213>
- Chakraborty, D., & Elzarka, H. (2019). Advanced machine learning techniques for building performance simulation: a comparative analysis. *Journal of Building Performance Simulation*, 12(2), 193–207. <https://doi.org/10.1080/19401493.2018.1498538>
- Chollet, F. (2018). *Deep Learning with Python*. Manning Publications Co.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*.
- de Burgh-Day, C. O., & Leeuwenburg, T. (2023). Machine learning for numerical weather and climate modelling: a review. *Geoscientific Model Development*, 16(22), 6433–6477. <https://doi.org/10.5194/gmd-16-6433-2023>
- Edwards, R. (2020, Januari 4). *Feature Engineering – Cyclical Variables*. The Data School. <https://www.thedataschool.com.au/ryan-edwards/feature-engineering-cyclical-variables/>
- Fadilah, R., Djamal, E. C., & Ilyas, R. (2021). Rainfall Prediction Due to El Nino Factors Using Recurrent Neural Networks. *Journal of Physics: Conference Series*, 1845(1), 012025. <https://doi.org/10.1088/1742-6596/1845/1/012025>
- Fan, M., Imran, O., Singh, A., & Ajila, S. A. (2022). Using CNN-LSTM Model for Weather Forecasting. *2022 IEEE International Conference on Big Data (Big Data)*, 4120–4125. <https://doi.org/10.1109/BigData55660.2022.10020940>
- Frecenta, H., Puspaningrum, E. Y., & Maulana, H. (2022). Prediksi Curah Hujan di Kab.Malang Menggunakan LSTM (Long Short Term Memory). *Jurnal Informatika dan Sistem Informasi (JIFoSI)*, 3(1), 51–55.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Husak, G., Rowland, J., Harrison, L., Hoell, A., & Michaelsen, J. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific Data*, 2(1), 150066. <https://doi.org/10.1038/sdata.2015.66>
- Gadam, S. (2023, Januari 26). *What is iterative and incremental development? Process, examples*. LogRocket. <https://blog.logrocket.com/product-management/what-is-iterative-incremental-development-process-examples/>

- Glints, & Monk's Hill Ventures. (2023). *Southeast Asia Startup Talent Report 2023*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Haidar, A., & Verma, B. (2018). Monthly Rainfall Forecasting Using One-Dimensional Deep Convolutional Neural Network. *IEEE Access*, 6, 69053–69063. <https://doi.org/10.1109/ACCESS.2018.2880044>
- Hasanah, F. N., & Untari, R. S. (2020). *Buku Ajar Rekayasa Perangkat Lunak* (M. Suryawinata, Ed.). UMSIDA Press.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Kanamitsu, M., Ebisuzaki, W., Woollen, J., Yang, S.-K., Hnilo, J. J., Fiorino, M., & Potter, G. L. (2002). NCEP–DOE AMIP-II Reanalysis (R-2). *Bulletin of the American Meteorological Society*, 83(11), 1631–1644. <https://doi.org/10.1175/BAMS-83-11-1631>
- Karim, R. (2019, Januari 21). *Counting No. of Parameters in Deep Learning Models by Hand*. Towards Data Science. <https://towardsdatascience.com/counting-no-of-parameters-in-deep-learning-models-by-hand-8f1716241889>
- Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization*.
- Können, G. P., Jones, P. D., Kaltofen, M. H., & Allan, R. J. (1998). Pre-1866 Extensions of the Southern Oscillation Index Using Early Indonesian and Tahitian Meteorological Readings. *Journal of Climate*, 11(9), 2325–2339. [https://doi.org/10.1175/1520-0442\(1998\)011<2325:PEOTSO>2.0.CO;2](https://doi.org/10.1175/1520-0442(1998)011<2325:PEOTSO>2.0.CO;2)
- Kurnia, W. G., Muharsyah, R., & Widiyanto, S. (2020). Performa Koreksi Bias Prakiraan Curah Hujan Model European Centre Medium Weather Forecast (ECMWF) di Sulawesi. *Buletin GAW Bariri (BGB)*, 1(2), 77–86.
- Landset, S., Khoshgoftaar, T. M., Richter, A. N., & Hasanin, T. (2015). A survey of open source tools for machine learning with big data in the Hadoop ecosystem. *Journal of Big Data*, 2(1), 24. <https://doi.org/10.1186/s40537-015-0032-1>
- Li, W., Gao, X., Hao, Z., & Sun, R. (2022). Using deep learning for precipitation forecasting based on spatio-temporal information: a case study. *Climate Dynamics*, 58(1–2), 443–457. <https://doi.org/10.1007/s00382-021-05916-4>

- Milanda, R., & Setiawan, B. (2019). Pengaruh Perubahan Iklim pada Kenaikan Muka Air Sungai dan Potensi Bencana Hidrometeorologi di Daerah Aliran Sungai Enim Sumatra Selatan. *Prosiding Seminar Nasional Hari Air Dunia 2019*, 66–73.
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. The MIT Press.
- Nabil, P. S., & Ramdhani, Y. (2023). Application of bidirectional gated recurrent unit algorithm for rainfall prediction. *Jurnal Teknik Informatika C.I.T Medicom*, 15(4), 188–198.
<https://doi.org/10.35335/cit.Vol15.2023.522.pp188-198>
- Naser, M. Z., & Alavi, A. H. (2023). Error Metrics and Performance Fitness Indicators for Artificial Intelligence and Machine Learning in Engineering and Sciences. *Architecture, Structures and Construction*, 3(4), 499–517.
<https://doi.org/10.1007/s44150-021-00015-8>
- National Centers for Environmental Prediction. (2024). *Equatorial Pacific Sea Surface Temperatures (SST)*. National Centers for Environmental Prediction.
<https://www.ncei.noaa.gov/access/monitoring/enso/sst>
- Nielsen, J. (2009, Oktober 4). *Powers of 10: Time Scales in User Experience*. Nielsen Norman Group. <https://www.nngroup.com/articles/powers-of-10-time-scales-in-ux/>
- Nur, I. A., Hidayat, R., Latifah, A. L., & Misnawati. (2021). Pengaruh Koreksi Bias dan Metode Ensemble Pada Data Curah Hujan Dari Empat Model Luaran Regional Climate Model (RCM) CORDEX-SEA di Sumatera. *Jurnal Pengelolaan Sumberdaya Alam dan Lingkungan*, 11(1), 49–56.
<https://doi.org/10.29244/jpsl.11.1.49-56>
- Patel, M., Patel, A., & Ghosh, Dr. R. (2018). *Precipitation Nowcasting: Leveraging bidirectional LSTM and 1D CNN*.
- Peraturan Menteri Keuangan Nomor 113 Tahun 2023 tentang Standar Biaya Keluaran Tahun Anggaran 2024 (2023).
<https://jdih.kemenkeu.go.id/in/dokumen/peraturan/f86d8260-6fc3-49b5-6002-08dbdb753701>
- Pezzè, M., & Young, M. (2008). *Software Testing and Analysis: Process, Principles, and Techniques*.
- Pramudito, H. D. (2022). *Data Mining Implementation On Java North Coast Weather Forecast Dataset Using C4.5 Algorithm*. 13, 2407–3903.

- Prasetyaningtyas, K. (2024, April 22). *Prakiraan Hujan Dasarian*. Badan Meteorologi, Klimatologi, dan Geofisika.
<https://www.bmkg.go.id/iklim/prakiraan-hujan-dasarian.bmkg>
- Pu, Z., & Kalnay, E. (2018). Numerical Weather Prediction Basics: Models, Numerical Methods, and Data Assimilation. Dalam *Handbook of Hydrometeorological Ensemble Forecasting* (hlm. 1–31). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-40457-3_11-1
- Purcell, E. J., Varberg, D., Rigdon, S. E., & Gressando, J. (2004). *Kalkulus* (A. Safitri, Ed.; 8 ed., Vol. 2). Erlangga.
- Ratri, D. N., Whan, K., & Schmeits, M. (2019). A Comparative Verification of Raw and Bias-Corrected ECMWF Seasonal Ensemble Precipitation Reforecasts in Java (Indonesia). *Journal of Applied Meteorology and Climatology*, 58(8), 1709–1723. <https://doi.org/10.1175/JAMC-D-18-0210.1>
- Rayner, N. A., Parker, D. E., Horton, E. B., Folland, C. K., Alexander, L. V., Rowell, D. P., Kent, E. C., & Kaplan, A. (2003). Global analyses of sea surface temperature, sea ice, and night marine air temperature since the late nineteenth century. *Journal of Geophysical Research: Atmospheres*, 108(D14). <https://doi.org/10.1029/2002JD002670>
- Ropelewski, C. F., & Jones, P. D. (1987). An Extension of the Tahiti–Darwin Southern Oscillation Index. *Monthly Weather Review*, 115(9), 2161–2165. [https://doi.org/10.1175/1520-0493\(1987\)115<2161:AEOTTS>2.0.CO;2](https://doi.org/10.1175/1520-0493(1987)115<2161:AEOTTS>2.0.CO;2)
- Ruminta, Handoko, & Nurmala, T. (2018). Indikasi Perubahan Iklim dan Dampaknya Terhadap Produksi Padi di Indonesia (Studi Kasus : Sumatera Selatan dan Malang Raya). *Jurnal Agro*, 5(1), 48–60.
<https://doi.org/10.15575/1607>
- Saji, N., & Yamagata, T. (2003). Possible impacts of Indian Ocean Dipole mode events on global climate. *Climate Research*, 25(2), 151–169.
<https://doi.org/10.3354/cr025151>
- Salma, S., & A, A. (2022). Hybrid CNN-LSTM Model: Rainfall Analysis and Prediction for Karnataka Region. *Journal of Theoretical and Applied Information Technology*, 100(22), 6715–6727.
- Smagulova, K., & James, A. P. (2019). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313–2324. <https://doi.org/10.1140/epjst/e2019-900046-x>
- Sommerville, I. (2011). *Software Engineering* (9th Edition). Pearson.

- Speedtest. (2024). *Indonesia Median Country Speeds May 2024*.
<https://www.speedtest.net/global-index/indonesia>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, *15*, 1929–1958.
- Stull, R. (2015). *Practical Meteorology : An Algebra-based Survey of Atmospheric Science*. Department of Earth, Ocean & Atmospheric Sciences, University of British Columbia. <https://doi.org/https://dx.doi.org/10.14288/1.0300441>
- Wahyuningrum, T. (2021). *Buku Referensi Mengukur Usability Perangkat Lunak*. Penerbit Deepublish.
- Winarno, G. D., Harianto, S. P., & Santoso, R. (2019). *Klimatologi Pertanian*. Pusaka Media.
- Yang, N., Shi, H., Tang, H., & Yang, X. (2022). Geographical and temporal encoding for improving the estimation of PM2.5 concentrations in China using end-to-end gradient boosting. *Remote Sensing of Environment*, *269*, 112828. <https://doi.org/10.1016/j.rse.2021.112828>
- Yang, S., Yu, X., & Zhou, Y. (2020). LSTM and GRU Neural Network Performance Comparison Study: Taking Yelp Review Dataset as an Example. *2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI)*, 98–101.
<https://doi.org/10.1109/IWECAI50956.2020.00027>
- Zaskia, A., Saharjo, B. H., & Albar, I. (2023). Pengaruh Curah Hujan Terhadap Kejadian Kebakaran Hutan dan Lahan di Kabupaten Banyuasin Provinsi Sumatera Selatan. *Jurnal Silvikultur Tropika*, *14*(03), 195–200.
<https://firms.modaps.eosdis.nasa.gov/>
- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2023). *Dive into Deep Learning*. Cambridge University Press.
- Zheng, A., Shelby, N., & Volckhausen, E. (2019). Evaluating Machine Learning Models. *Machine Learning in the AWS Cloud*.