PENERAPAN METODE *DEEP LEARNING* UNTUK MEMPREDIKSI JUMLAH PENYAKIT DI PUSKESMAS TILANGO

JURNAL

DJUHURIATI HASAN
NIM: A01420005

PROGRAM STUDI SISTEM INFORMASI
FAKULTAS SAINS DAN ILMU KOMPUTER
UNIVERSITAS MUHAMMADIYAH GORONTALO
GORONTALO
2024

PENERAPAN METODE DEEP LEARNING UNTUK MEMPREDIKSI JUMLAH PENYAKIT DI PUSKESMAS TILANGO

Djuhuriati Hasan[1*], Wahyudin Hasyim[2], Rubiyanto Maku[3]
[1,2,3]Program Studi Sistem Informasi, Universitas Muhammadiyah Gorontalo
email: djuhriatihasann@umgo.ac.id[1*]

Abstrak: Puskesmas Tilango menghadapi peningkatan jumlah kasus penyakit utama yang signifikan, termasuk Infeksi Saluran Pernapasan Akut (ISPA), hipertensi, arthritis, TBC-, Dyspepsia dan Dermatitis Kontak Alergi. Penelitian ini bertujuan untuk memprediksi jumlah kasus penyakit utama menggunakan metode Deep Learning dengan algoritma Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM), yang diterapkan pada enam kategori penyakit. Berdasarkan hasil evaluasi, model RNN dengan parameter tertentu menghasilkan prediksi terbaik pada ISPA dengan RMSE 0,138, menunjukkan bahwa RNN unggul dalam memprediksi pola jangka pendek. Sebaliknya, model LSTM dengan parameter optimal menunjukkan kinerja lebih baik pada pola jangka panjang dengan RMSE 0,125 pada ISPA. Perbandingan hasil ini menunjukkan bahwa LSTM lebih unggul dalam prediksi jangka panjang. Implementasi model prediktif ini diharapkan dapat membantu Puskesmas Tilango dalam pengelolaan sumber daya kesehatan yang lebih efektif dan tepat waktu.

Kata Kunci: **Prediksi, Penyakit*, Recurrent Neural Network, Long Short-Term Memory.***

Abstract: *Currently, the internet has become an essential requirement in the digital era. The demand for quick access to information makes the internet a crucial tool. Therefore, it is imperative to have a stable and reliable internet connection at Universitas Muhammadiyah Gorontalo. This is necessary for the staff, lecturers, and students to facilitate the teaching and learning process, as well as other academic activities. The objective of this research is to analyze the internet network at Universitas Muhammadiyah Gorontalo using Quality of Service (QOS) parameters to determine its quality and performance capabilities. The parameters of throughput, delay, jitter, and packet loss were obtained through testing using Wireshark software. The results indicate that the internet network at the University of Muhammadiyah Gorontalo is of good quality. The measured throughput value was 228.866 bit/s with an index value of 4. The delay was 51.736 ms with an index value of 4, and the jitter was 1.026 ms with an index value of 3. Additionally, there was a packet loss of 9% with an index value of 3.*

Keywords : Quality Of Service **(QOS), *Throughput, Delay, Jitter, Packet Loss, Wireshark***

PENDAHULUAN

Pusat Kesehatan Masyarakat (Puskesmas) merupakan fasilitas utama dalam memberikan layanan kesehatan di Indonesia. Salah satu tantangan yang dihadapi Puskesmas Tilango adalah peningkatan jumlah kasus penyakit utama seperti ISPA, hipertensi, arthritis, dan lainnya, yang dapat mencapai lebih dari 800 kasus per bulan. Tantangan ini memerlukan strategi pengelolaan sumber daya yang lebih efektif untuk mencegah kekurangan obat-obatan dan menjaga kualitas layanan.

Deep Learning, khususnya algoritma Recurrent Neural Networks (RNN) dan Long Short-Term Memory (LSTM), menawarkan pendekatan yang potensial untuk menganalisis pola data sekuensial dalam jumlah besar. Penelitian ini bertujuan untuk menerapkan metode Deep Learning dalam memprediksi jumlah kasus penyakit utama di Puskesmas Tilango, dengan harapan dapat mendukung pengambilan keputusan berbasis data yang lebih akurat.

TINJAUAN PUSTAKA

Deep Learning

Deep Learning adalah cabang pembelajaran mesin yang menggunakan beberapa lapisan pemrosesan untuk ekstraksi fitur, klasifikasi, dan analisis pola secara non-linear. Metode ini memungkinkan analisis data pada berbagai tingkat abstraksi, menghasilkan akurasi lebih tinggi dibandingkan metode pembelajaran mesin tradisional [7]. LSTM, salah satu algoritma Deep Learning, dirancang untuk mengatasi permasalahan vanishing gradient dan memiliki kemampuan mengolah data sekuensial dan hubungan jangka panjang [4].

Prediksi

Prediksi adalah proses memperkirakan sesuatu di masa depan berdasarkan data historis. Dalam konteks kesehatan, prediksi memungkinkan analisis pola penyakit dan perencanaan sumber daya yang lebih efektif. Sistem prediksi berbasis Deep Learning seperti RNN dan LSTM menawarkan keunggulan dalam mengenali pola kompleks yang sulit dianalisis menggunakan metode tradisional [6].

Puskesmas sebagai Fasilitas Kesehatan

Puskesmas berperan sebagai pusat layanan kesehatan masyarakat yang bertujuan meningkatkan kesejahteraan masyarakat melalui pencegahan, pengobatan, dan promosi kesehatan. Tantangan utama Puskesmas Tilango adalah manajemen penyakit utama dengan prevalensi tinggi, seperti ISPA, hipertensi, dan arthritis, yang membutuhkan alokasi sumber daya yang tepat guna.

Penelitian Terkait

Penelitian sebelumnya menunjukkan potensi Deep Learning untuk prediksi di bidang kesehatan. Aisyah et al. (2023) menggunakan LSTM untuk prediksi risiko tuberkulosis, menghasilkan akurasi tinggi dengan RMSE 0,12. Saladan et al. (2023) memanfaatkan LSTM untuk memprediksi kunjungan wisatawan, menunjukkan kemampuan algoritma ini dalam analisis data sekuensial. Studi ini melanjutkan pendekatan tersebut dengan menerapkan metode RNN dan LSTM untuk memprediksi jumlah kasus penyakit utama di Puskesmas Tilango.

METODE

Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksploratif dan aplikatif. Pendekatan kuantitatif dipilih karena penelitian ini menganalisis data numerik secara komprehensif menggunakan teknik Deep Learning. Pendekatan eksploratif dilakukan untuk mengeksplorasi penerapan teknologi Deep Learning di lingkungan Puskesmas, sementara pendekatan aplikatif fokus pada implementasi model prediksi untuk penggunaan praktis dalam manajemen kesehatan.

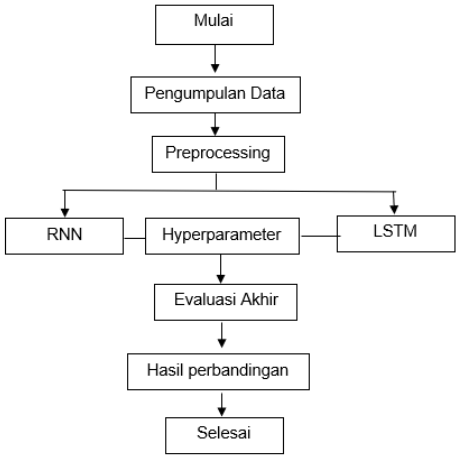
Objek dan Lokasi Penelitian

Objek penelitian ini adalah data penyakit utama yang dikumpulkan dari Puskesmas Tilango, Kecamatan Tilango, Provinsi Gorontalo. Pemilihan lokasi didasarkan pada prevalensi tinggi penyakit utama, seperti ISPA, hipertensi, dan arthritis, yang membutuhkan pengelolaan sumber daya yang lebih efektif.

Data Penelitian

Data yang digunakan adalah jumlah kasus penyakit utama di Puskesmas Tilango dari Januari 2019 hingga September 2024, dengan total 690 data. Dataset terdiri dari variabel waktu (tanggal), kategori penyakit, dan jumlah kasus. Penyakit utama yang dianalisis meliputi ISPA, hipertensi, arthritis, dyspepsia, dermatitis kontak alergi, dan TBC.

Tahapan Penelitian



HASIL DAN PEMBAHASAN

Pengumpulan Data

Penelitian ini menggunakan data bulanan penyakit utama yang dikumpulkan dari Puskesmas Tilango, Gorontalo, selama periode Januari 2019 hingga September 2024, dengan total 690 data. Dataset mencakup informasi seperti jenis penyakit, kode ICD-X, jumlah kasus, distribusi berdasarkan jenis kelamin, serta peringkat penyakit berdasarkan prevalensi bulanan. Penyakit utama yang dianalisis meliputi ISPA, hipertensi, arthritis, dyspepsia, TBC, dan dermatitis kontak alergi, sementara penyakit dengan jumlah kasus rendah atau tidak konsisten, seperti tonsilitis dan schizophrenia, dihapus untuk meningkatkan kualitas analisis. Setelah pembersihan data, normalisasi menggunakan metode *min-max scaling* diterapkan untuk memastikan data siap digunakan dalam pengembangan model prediksi berbasis algoritma Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM).

Tahap Preprocessing

1. Transformasi Data

Proses transformasi data menghasilkan 69 baris dengan satu kolom waktu yang diubah menjadi format tanggal lengkap (tahun, bulan, dan hari), serta enam kolom yang merepresentasikan jenis penyakit utama. Transformasi ini dilakukan menggunakan teknik unpivot pada Python atau Microsoft Excel untuk memastikan data siap digunakan dalam model prediksi. Selama proses ini, kolom-kolom yang tidak relevan, seperti diare, gout, pulpitis, abses furuncle, myalgia, tonsilitis, schizophrenia, dan lainnya, dihapus karena memiliki terlalu banyak nilai nol atau jumlah kasus yang sangat rendah sehingga tidak memberikan kontribusi signifikan dalam analisis. Langkah ini bertujuan untuk meningkatkan kualitas dataset agar optimal dalam pelatihan model berbasis Deep Learning.

Tabel 1. Data yang sudah di tranformasi

Date	Arthritis	Dermatitis Kontak Allergi	Dyspepsia	Hipertensi	Ispa	TBC-
2019-01-01	98	81	76	105	489	0
2019-02-01	72	82	101	109	609	0
2019-03-01	87	79	66	90	463	30
2019-04-01	47	68	72	65	388	26
2019-05-01	59	53	58	53	350	21
...	...	...	...	...	...	...
...	...	...	...	...	...	...
...	...	...	...	...	...	...
2024-03-01	55	38	64	60	288	45
2024-04-01	38	39	52	64	186	40
2024-05-01	65	56	60	71	229	40
2024-06-01	45	44	45	73	196	85
2024-07-01	37	47	53	36	133	50
2024-08-01	24	27	67	54	182	50
2024-09-01	51	50	79	61	237	40

2. Normalisasi

Pada tahap normalisasi ini, data asli diubah menjadi nilai dalam rentang [0,1] menggunakan metode skala min-max.

Tabel 2. Data Normalisasi

Date	Arthritis	Dermatitis Kontak Allergi	Dyspepsia	Hipertensi	Ispa	TBC-
2019-01-01	0,7781	0,7680	0,6197	0,3007	0,7270	0,1000
2019-02-01	0,5800	0,7763	0,7906	0,3124	0,9000	0,1000
2019-03-01	0,6943	0,7515	0,5513	0,2571	0,6895	0,3824
2019-04-01	0,3895	0,6608	0,5923	0,1844	0,5814	0,3447
2019-05-01	0,4810	0,5371	0,4966	0,1495	0,5267	0,2976
...	...	...	...	...	...	...
...	...	...	...	...	...	...
...	...	...	...	...	...	...
2024-03-01	0,4505	0,4134	0,5376	0,1698	0,4373	0,5235
2024-04-01	0,3210	0,4216	0,4556	0,1815	0,2903	0,4765
2024-05-01	0,5267	0,5619	0,5103	0,2018	0,3523	0,4765
2024-06-01	0,3743	0,4629	0,4077	0,2076	0,3047	0,9000
2024-07-01	0,3133	0,4876	0,4624	0,1000	0,2139	0,5706
2024-08-01	0,2143	0,3227	0,5581	0,1524	0,2845	0,5706
2024-09-01	0,4200	0,5124	0,6402	0,1727	0,3638	0,4765

3. Pembagian Data Latih dan Uji

Untuk keperluan prediksi, data dibagi menjadi dua bagian: data pelatihan dan data pengujian. Sebanyak 80% data digunakan untuk pelatihan model, sementara 20% sisanya digunakan untuk pengujian. Pembagian dilakukan secara manual, di mana data dari Januari 2019 hingga Juli 2023 digunakan sebagai data pelatihan, dan data dari Juni 2023 hingga September 2024 digunakan sebagai data pengujian. Proses ini dilakukan setelah data dinormalisasi, memastikan bahwa model dapat belajar dari pola historis dan menguji performanya pada data baru.

4. Pembentukan struktur pola *Time Series*

Proses rekonstruksi data atau pembentukan deret waktu (time series) dilakukan untuk mempersiapkan data agar sesuai dengan kebutuhan model prediksi berbasis Deep Learning. Proses ini mencakup berbagai percobaan, menghasilkan satu hingga lima pola deret waktu berdasarkan urutan variabel input dan output. Pembentukan pola ini merujuk pada metode yang digunakan dalam penelitian Wardani (2021), dengan format pola sebagai berikut:

$\{X_t, X_{t+1}\}, \{X_{t-1}, X_t, X_{t+1}\}, \{X_{t-2}, X_{t-1}, X_t, X_{t+1}\}, \{X_{t-3}, X_{t-2}, X_t, X_{t+1}\}, \{X_{t-4}, X_{t-3}, X_{t-2}, X_{t-1}, X_t, X_{t+1}\}$.

Tabel 3 Pola data *time series*

X1	X2	X3	X4	X5	X6	Target
0,7781	0,5800	0,6943	0,3895	0,4810	0,4124	0,5876
0,5800	0,6943	0,3895	0,4810	0,4124	0,5876	0,6029
0,6943	0,3895	0,4810	0,4124	0,5876	0,6029	0,5724
0,3895	0,4810	0,4124	0,5876	0,6029	0,5724	0,7171
0,4810	0,4124	0,5876	0,6029	0,5724	0,7171	0,9000
...	...	...	...	...	...	...
...	...	...	...	...	...	...
0,4505	0,2067	0,2829	0,2981	0,3438	0,2905	0,1762
0,2067	0,2829	0,2981	0,3438	0,2905	0,1762	0,3362
0,2829	0,2981	0,3438	0,2905	0,1762	0,3362	0,4276
0,2981	0,3438	0,2905	0,1762	0,3362	0,4276	0,3057

Pengujian dan Evaluasi Algoritma RNN dan LSTM

1. Inisalisasi Parameter

Pada tahap ini, algoritma Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM) diimplementasikan untuk memprediksi jumlah penyakit utama di Puskesmas Tilango. Parameter utama yang diinisialisasi meliputi:

1. Time Step: Menentukan jumlah langkah waktu yang digunakan untuk mempelajari pola data sekuensial.
2. Hidden Neurons: Jumlah neuron pada lapisan tersembunyi untuk menangkap hubungan non-linear dalam data.
3. Batch Size: Jumlah sampel data yang digunakan dalam setiap iterasi pelatihan.
4. Epoch: Jumlah iterasi pelatihan melalui seluruh dataset untuk memperbaiki bobot model.

Seluruh parameter dioptimalkan menggunakan metode percobaan untuk menghasilkan kinerja terbaik. Pemilihan parameter dilakukan dengan mempertimbangkan kemampuan model untuk menangani kompleksitas data sekuensial. Parameter terbaik untuk algoritma RNN adalah **time step 3, hidden neurons 25, batch size 36, dan epoch 140**, sedangkan untuk algoritma LSTM adalah **time step 11, hidden neurons 50, batch size 32, dan epoch 110**.

2. Hasil Evalusi Algoritma RNN dan LSTM

a. Algoritma Recurrent Neural Network

Tabel 4 Hasil Evaluasi

Jenis Penyakit	RMSE
Arthritis	0,183
Dermatitis Kontak Allergi	0,239
Dyspepsia	0,189
Hipertensi	0,164
Ispa	0,138
TBC-	0,189

Hasil evaluasi model RNN dengan parameter epoch 140, batch size 36, hidden layer 25, dan time step 3 menunjukkan bahwa model memiliki kinerja prediksi terbaik pada kasus ISPA (Infeksi Saluran Pernapasan Akut) dengan nilai RMSE terendah, yaitu 0,138, yang mengindikasikan akurasi prediksi yang tinggi. Pada kasus Hipertensi, model juga menghasilkan performa yang cukup baik dengan RMSE 0,164, meskipun masih di bawah ISPA. Sementara itu, penyakit lain seperti Arthritis, Dispepsia, dan TBC- memiliki nilai RMSE antara 0,183 hingga 0,189, menunjukkan tingkat kesalahan prediksi yang serupa pada ketiga penyakit ini. Nilai RMSE tertinggi, yaitu 0,239, terdapat pada Dermatitis Kontak Alergi, menunjukkan bahwa model mengalami kesulitan dalam mempelajari pola data penyakit ini, mungkin akibat variasi data yang lebih besar atau pola yang kurang teratur. Secara keseluruhan, performa model RNN bervariasi sesuai dengan karakteristik data penyakit yang diprediksi. keseluruhan, performa model RNN bervariasi sesuai dengan karakteristik data penyakit yang diprediksi.

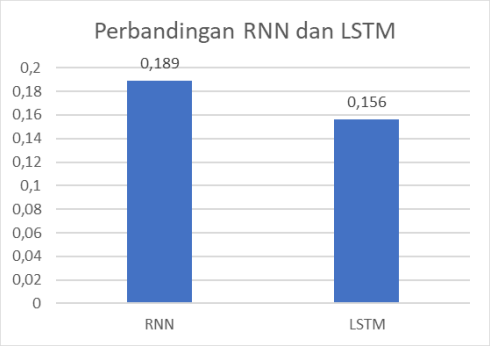
b. Algoritma *Long Short-Term Memory*

Tabel 5 Hasil Evaluasi

Jenis Penyakit	RMSE
Arthritis	0,156
Dermatitis Kontak Allergi	0,228
Dyspepsia	0,182
Hipertensi	0,146
Ispa	0,125
TBC-	0,167

Hasil evaluasi model LSTM dengan parameter 110 epoch, batch size 32, hidden layer 50, dan time step 11 menunjukkan bahwa performa model bervariasi pada setiap jenis penyakit. Model menunjukkan akurasi prediksi terbaik pada kasus ISPA (Infeksi Saluran Pernapasan Akut) dengan nilai RMSE terendah sebesar 0,125, menunjukkan kemampuan prediksi yang baik untuk ISPA. Pada kasus Hipertensi, model juga memberikan hasil prediksi yang cukup baik dengan RMSE 0,146. Nilai RMSE untuk Arthritis dan TBC- masing-masing adalah 0,156 dan 0,167, yang menunjukkan tingkat kesalahan prediksi yang hampir sama pada kedua penyakit ini, meskipun sedikit lebih tinggi daripada pada ISPA dan Hipertensi. Dispepsia memiliki nilai RMSE sebesar 0,182, sedangkan Dermatitis Kontak Alergi memiliki RMSE tertinggi, yaitu 0,228, yang mengindikasikan bahwa model kesulitan dalam memprediksi pola data untuk penyakit ini, mungkin karena adanya variasi data yang lebih besar atau pola yang kompleks. Secara keseluruhan, performa model LSTM cukup baik pada beberapa penyakit, namun mengalami kesulitan pada penyakit dengan pola data yang lebih rumit atau berfluktuasi.

3. Hasil Perbandingan Algoritma RNN dan LSTM



Gambar 1 Perbandingan Algoritma RNN dan LSTM

Grafik perbandingan di atas memperlihatkan bahwa model LSTM memiliki kinerja yang lebih baik dibandingkan RNN dalam memprediksi penyakit Arthritis, dengan tingkat kesalahan sebesar 0,156 untuk LSTM dan 0,189 untuk RNN. Dalam hal ini, nilai kesalahan yang lebih rendah menunjukkan akurasi yang lebih tinggi. Keunggulan LSTM berasal dari kemampuannya untuk "mengingat" informasi dalam periode yang lebih panjang, yang sangat penting dalam menganalisis data medis yang memiliki urutan. Oleh karena itu, jika harus memilih di antara kedua model ini, LSTM lebih disarankan karena memiliki kesalahan yang lebih kecil dan kemampuan yang lebih baik dalam menangani data sekuensial.

4. Hasil Prediksi

a. Algoritma Recurrent Neural Network

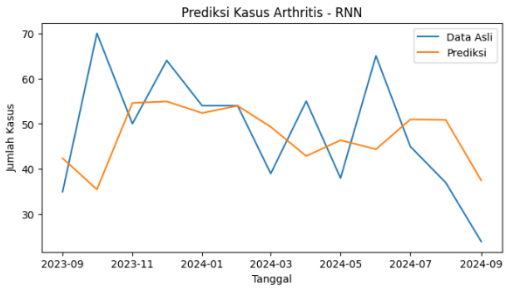
Proses RNN pada penelitian ini menggunakan prediksi dari enam kategori penyakit utama yaitu Arthritis, Dermatitis Kontak Alergi, Dyspepsia, Hipertensi, Ispa, dan TBC- dengan kolom date sebagai index, setelah itu parameter yang di bangun untuk pe model-an ini tersusun dari time step 3, batch size 36, hidden neuron 25, dan epoch 140. Hasil prediksi yang didapatkan akan dibandingkan dengan nilai aktual dari data setiap penyakit.

1. Penyakit Arthritis

Tabel 6 Hasil Prediksi Penyakit Arthritis

Tanggal	Arthritis	Prediksi	Error
2023-09-01	35	42	-7
2023-10-01	70	35	35
2023-11-01	50	55	-5
2023-12-01	64	55	9
2024-01-01	54	52	2
2024-02-01	54	54	0
2024-03-01	39	49	-10
2024-04-01	55	43	12
2024-05-01	38	46	-8
2024-06-01	65	44	21
2024-07-01	45	51	-6
2024-08-01	37	51	-14
2024-09-01	24	38	-14

Kemudian didapatkan hasil prediksi pada tabel 24, yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 2 Grafik hasil prediksi

Grafik dan tabel menunjukkan hasil prediksi model RNN terhadap jumlah kasus arthritis dari September 2023 hingga September 2024, dibandingkan dengan data aktual. Grafik mengungkapkan bahwa prediksi model (garis oranye) lebih halus dibandingkan data asli (garis biru), mencerminkan kurangnya respons model terhadap variasi signifikan pada pola kasus. Dalam tabel, beberapa perbedaan mencolok terlihat. Contohnya, pada Oktober 2023, data asli menunjukkan 70 kasus, sementara prediksi RNN hanya 35,49 kasus, menghasilkan error -34,51. Hal serupa terjadi pada Juni 2024, dengan data asli 65 kasus dan prediksi 44,37 kasus, sehingga error mencapai -20,62. Kondisi ini menunjukkan

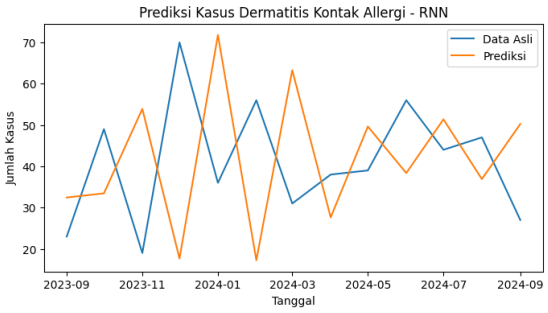
bahwa model kesulitan menangkap lonjakan besar dalam pola data. Namun, pada bulan-bulan tertentu dengan pola data yang lebih stabil, prediksi RNN lebih akurat. Misalnya, pada Januari 2024, prediksi 52,38 mendekati angka aktual 54 (error 1,62). Begitu juga pada Februari 2024, prediksi 53,99 sangat dekat dengan data asli 54, menghasilkan error hanya 0,01. Hasil ini menunjukkan bahwa model RNN bekerja lebih baik pada pola data yang stabil, tetapi memiliki keterbatasan dalam menangani perubahan mendadak pada pola kasus arthritis.

2. Penyakit Dermatitis Kontak Alergi

Tabel 7 Hasil Prediksi Penyakit Dermatitis Kontak Alergi

Tanggal	Alergi	Prediksi	Error
2023-09-01	23	32	-9
2023-10-01	49	33	16
2023-11-01	19	54	-35
2023-12-01	70	18	52
2024-01-01	36	72	-36
2024-02-01	56	17	39
2024-03-01	31	63	-32
2024-04-01	38	28	10
2024-05-01	39	50	-11
2024-06-01	56	38	18
2024-07-01	44	51	-7
2024-08-01	47	37	10
2024-09-01	27	50	-23

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 3 Grafik hasil prediksi

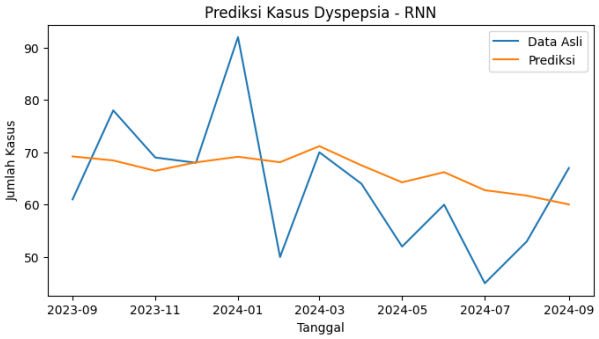
Grafik ini membandingkan prediksi model RNN dengan data asli jumlah kasus dermatitis kontak alergi dari September 2023 hingga September 2024. Hasil menunjukkan bahwa performa model tidak konsisten, dengan beberapa prediksi mendekati data asli, sementara lainnya menyimpang jauh. Pada September 2023, model memprediksi 32,45 kasus, sedangkan data asli menunjukkan 23 kasus, menghasilkan error -9,45. Di Oktober 2023, prediksi 33,45 kasus mendekati data asli 49 kasus, dengan error 15,55. Namun, pada November 2023, model memprediksi 53,91 kasus, jauh di atas data asli 19 kasus, dengan error -34,91. Pada Desember 2023, prediksi model hanya 17,65 kasus dibandingkan data asli 70 kasus, dengan error positif 52,35. Error terbesar terjadi pada Januari 2024, saat model memprediksi 71,81 kasus, sedangkan data asli hanya 36 kasus, menghasilkan error -35,81. Meskipun demikian, pada bulan-bulan seperti April dan Mei 2024, prediksi lebih akurat, dengan error masing-masing 10,37 dan -10,63.

3. Penyakit Dyspepsia

Tabel 8 Hasil Prediksi Penyakit Dyspepsia

Tanggal	Dyspepsia	Prediksi	Error
2023-09-01	61	69	-8
2023-10-01	78	68	10
2023-11-01	69	66	3
2023-12-01	68	68	0
2024-01-01	92	69	23
2024-02-01	50	68	-18
2024-03-01	70	71	-1
2024-04-01	64	68	-4
2024-05-01	52	64	-12
2024-06-01	60	66	-6
2024-07-01	45	63	-18
2024-08-01	53	62	-9
2024-09-01	67	60	7

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 4 Grafik hasil prediksi

Grafik dan tabel ini menampilkan hasil prediksi jumlah kasus dispepsia dari September 2023 hingga September 2024 menggunakan model RNN, dibandingkan dengan data asli. Garis biru pada grafik merepresentasikan data asli, sedangkan garis oranye menunjukkan hasil prediksi model RNN. Pada September 2023, data asli mencatat 61 kasus, sementara prediksi model sebesar 69,20, menghasilkan error -8,20. Pada Oktober 2023, kasus meningkat menjadi 78, tetapi prediksi hanya mencapai 68,45, dengan error 9,55, menunjukkan kurangnya sensitivitas model terhadap lonjakan data. Kesalahan terbesar terjadi pada Januari 2024, dengan data asli 92 kasus dan prediksi 69,14, menghasilkan error 22,86. Sebaliknya, pada Februari 2024, ketika data asli turun drastis menjadi 50 kasus, model memprediksi 68,10, dengan error -18,10. Hal ini menandakan ketidakmampuan model dalam menangkap perubahan ekstrem pada pola kasus. Mulai April hingga Juni 2024, prediksi model menunjukkan peningkatan akurasi. Pada April 2024, data asli mencatat 64 kasus dan prediksi 67,52, menghasilkan error -3,52. Pada Mei 2024, data asli 52 kasus dengan prediksi 64,27, menghasilkan error -12,27. Di Juni 2024, error mengecil menjadi -6,20, dengan data asli 60 kasus dan prediksi 66,20. Pada akhir periode,

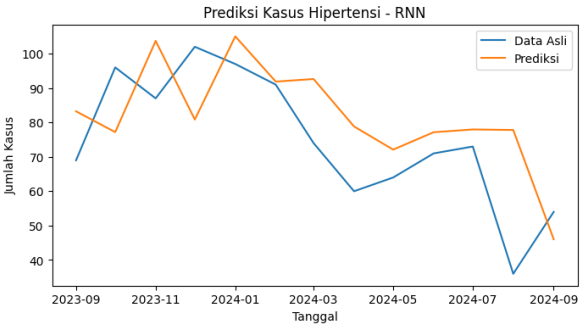
yaitu September 2024, data asli mencatat 67 kasus, sedangkan prediksi model adalah 60,04, menghasilkan error 6,96.

4. Penyakit Hipertensi

Tabel 9 Hasil Prediksi Penyakit Hipertensi

Tanggal	Hipertensi	Prediksi	Error
2023-09-01	69	83	-14
2023-10-01	96	77	19
2023-11-01	87	104	-17
2023-12-01	102	81	21
2024-01-01	97	105	-8
2024-02-01	91	92	-1
2024-03-01	74	93	-19
2024-04-01	60	79	-19
2024-05-01	64	72	-8
2024-06-01	71	77	-6
2024-07-01	73	78	-5
2024-08-01	36	78	-42
2024-09-01	54	46	8

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 5 Grafik hasil prediksi

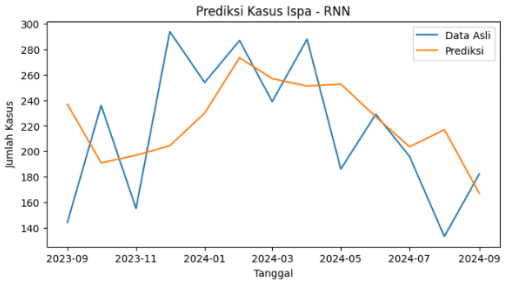
Grafik dan tabel ini menampilkan hasil prediksi jumlah kasus hipertensi dari September 2023 hingga September 2024 menggunakan model RNN, dengan perbandingan antara data asli (garis biru) dan prediksi model (garis oranye). Grafik menunjukkan adanya variasi jumlah kasus hipertensi yang signifikan dari bulan ke bulan. Secara umum, model RNN berupaya mengikuti pola data asli, tetapi terdapat perbedaan mencolok pada beberapa bulan. Menurut tabel, error atau selisih antara prediksi dan data asli bervariasi setiap bulan. Misalnya, pada Desember 2023, prediksi model sebesar 80,84 lebih rendah dibandingkan data asli 102, menghasilkan error positif sebesar 21,15. Sebaliknya, pada Januari 2024, prediksi model sebesar 105,02 lebih tinggi dari data asli 97, menghasilkan error negatif sebesar 8,02. Error terbesar tercatat pada Mei 2024, ketika prediksi model mencapai 77,15, sedangkan data asli hanya 64, dengan error sebesar 13,15. Hal ini mengindikasikan bahwa model cenderung kesulitan menangkap fluktuasi signifikan pada pola data.

5. Penyakit Ispa

Tabel 10 Hasil Prediksi Penyakit Ispa

Tanggal	Ispa	Prediksi	Error
2023-09-01	144	237	-93
2023-10-01	236	191	45
2023-11-01	155	197	-42
2023-12-01	294	204	90
2024-01-01	254	230	24
2024-02-01	287	273	14
2024-03-01	239	257	-18
2024-04-01	288	251	37
2024-05-01	186	253	-67
2024-06-01	229	227	2
2024-07-01	196	203	-7
2024-08-01	133	217	-84
2024-09-01	182	167	15

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 6 Grafik hasil prediksi

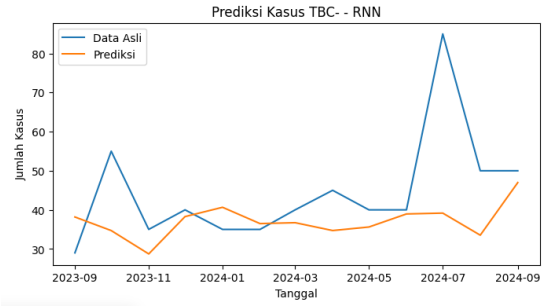
Grafik ini menampilkan prediksi jumlah kasus ISPA dari September 2023 hingga September 2024 menggunakan model RNN. Garis biru merepresentasikan data asli, sedangkan garis oranye menunjukkan prediksi model. Secara keseluruhan, model RNN berusaha mengikuti tren perubahan jumlah kasus, namun terdapat perbedaan signifikan pada beberapa periode. Dari tabel, terlihat bahwa error atau selisih antara prediksi dan data asli bervariasi. Pada September 2023, model memperkirakan 236,93 kasus, jauh di atas data asli sebesar 144, menghasilkan error 92,93, menunjukkan kesulitan model dalam memprediksi angka rendah. Sebaliknya, pada Oktober 2023, prediksi model sebesar 190,84 lebih mendekati data asli 236, dengan error 45,16. Lonjakan signifikan terlihat pada Desember 2023, saat data asli mencapai 294 kasus, sedangkan prediksi model hanya 204,29, menghasilkan error 89,70. Kasus serupa terjadi pada Mei 2024, ketika prediksi model sebesar 252,77 jauh di atas data asli 186, menghasilkan error negatif 66,77.

6. Penyakit TBC-

Tabel 11 Hasil Prediksi Penyakit TBC-

Tanggal	TBC-	Prediksi	Error
2023-09-01	29	38	-9
2023-10-01	55	35	20
2023-11-01	35	29	6
2023-12-01	40	38	2
2024-01-01	35	41	-6
2024-02-01	35	36	-1
2024-03-01	40	37	3
2024-04-01	45	35	10
2024-05-01	40	36	4
2024-06-01	40	39	1
2024-07-01	85	39	46
2024-08-01	50	34	16
2024-09-01	50	47	3

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 7 Grafik hasil prediksi

Grafik ini menampilkan prediksi jumlah kasus TBC dari model RNN dan membandingkannya dengan data asli dari September 2023 hingga September 2024. Garis biru merepresentasikan data kasus TBC yang sebenarnya, sementara garis oranye menunjukkan hasil prediksi model. Menurut tabel, model ini cukup akurat dalam memprediksi kasus TBC di beberapa bulan, meskipun terdapat beberapa selisih (error) yang cukup besar pada bulan-bulan tertentu. Misalnya, pada September 2023, jumlah kasus asli adalah 29, tetapi model memperkirakan 38,17, dengan error -9,17. Pada Oktober 2023, kasus meningkat menjadi 55, namun prediksi model hanya 34,70, menghasilkan error sebesar 20,29. Pada November dan Desember 2023, prediksi model lebih mendekati data asli dengan error masing-masing 6,27 dan 1,72, menunjukkan bahwa model dapat mengikuti tren yang stabil. Di tahun 2024, akurasi model meningkat, seperti yang terlihat pada bulan Februari, di mana prediksi model 36,48 mendekati data asli 35, dengan error -1,48. Namun, pada April 2024, kasus naik menjadi 45, sedangkan model memperkirakan 34,71, menghasilkan error 10,29. Kesalahan terbesar terjadi pada Juli 2024 ketika kasus asli melonjak ke 85, namun prediksi model hanya 39,17, menyebabkan error mencapai 45,83.

b. Algoritma *Long Short-Term Memory*

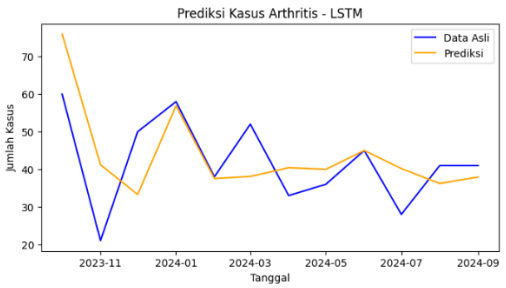
Proses LSTM pada penelitian ini menggunakan prediksi dari enam kategori penyakit utama yaitu Arthritis, Dermatitis Kontak Alergi, Dyspepsia, Hipertensi, Ispa, dan TBC- dengan kolom date sebagai index, setelah itu parameter yang di bangun untuk pe model-an ini tersusun dari time step 11, batch size 32, hidden neuron 50, dan epoch 110. Hasil prediksi yang didapatkan akan dibandingkan dengan nilai aktual dari data setiap penyakit.

1. Penyakit Arthritis

Tabel 12 Hasil Prediksi Penyakit Arthritis

Tanggal	Arthritis	Prediksi	Error
2023-10-01	60	76	16
2023-11-01	21	41	20
2023-12-01	50	33	17
2024-01-01	58	57	1
2024-02-01	38	38	0
2024-03-01	52	38	14
2024-04-01	33	40	7
2024-05-01	36	40	4
2024-06-01	45	45	0
2024-07-01	28	40	12
2024-08-01	41	36	5
2024-09-01	41	38	3

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 8 Grafik hasil prediksi

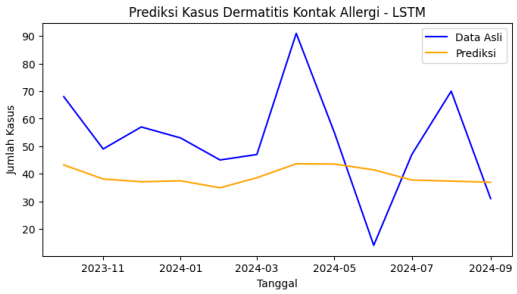
Grafik ini menampilkan perbandingan antara data asli kasus arthritis dan hasil prediksi model LSTM dari Oktober 2023 hingga September 2024. Pada Oktober 2023, jumlah kasus asli tercatat 60, sedangkan prediksi model mencapai 76,02. Di bulan November 2023, kasus asli turun menjadi 21, tetapi prediksi model tetap lebih tinggi, yaitu 41,21. Sebaliknya, pada Desember 2023, ketika jumlah kasus asli naik menjadi 50, prediksi model justru turun ke angka 33,28. Pada Januari 2024, model menunjukkan peningkatan akurasi dengan prediksi 56,88 berbanding data asli 58. Bulan Februari dan Maret 2024 juga mencatat prediksi yang cukup akurat, dengan data asli masing-masing 38 dan 52, serta prediksi 37,54 dan 38,09. Di bulan April dan Mei 2024, prediksi model tetap mendekati data asli, dengan nilai prediksi 40,41 dan 39,99 dibandingkan data asli 33 dan 36. Dari Juni hingga September 2024, pola prediksi dan data asli semakin mirip. Pada Juni, prediksi model tepat di angka 45, sesuai dengan data asli. Pada Juli dan Agustus, prediksi model sedikit lebih tinggi (40,18 dan 36,22) dibandingkan data asli yang tercatat 28 dan 41. Pada akhir periode, yaitu September 2024, data asli tercatat 41, sementara prediksi model sangat mendekati, yaitu 37,94.

2. Penyakit Dermatitis Kontak Alergi

Tabel 13 Hasil Penyakit Dermatitis Kontak Alergi

Tanggal	Alergi	Prediksi	Error
2023-10-01	68	43	25
2023-11-01	49	38	11
2023-12-01	57	37	20
2024-01-01	53	37	16
2024-02-01	45	35	10
2024-03-01	47	39	8
2024-04-01	91	44	47
2024-05-01	55	44	11
2024-06-01	14	41	27
2024-07-01	47	38	9
2024-08-01	70	37	33
2024-09-01	31	37	6

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 9 Grafik hasil prediksi

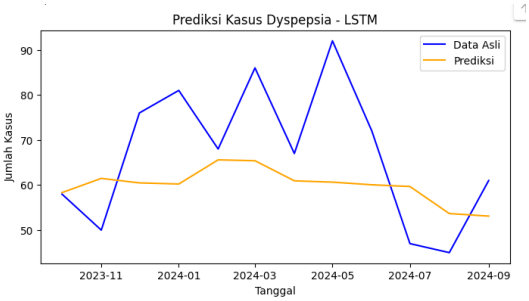
Grafik ini membandingkan data asli jumlah kasus dermatitis kontak alergi dengan hasil prediksi menggunakan model LSTM dari Oktober 2023 hingga September 2024. Garis biru menggambarkan data asli yang menunjukkan fluktuasi signifikan, sementara garis oranye merepresentasikan prediksi model yang lebih stabil. Jumlah kasus asli mencapai 68 pada Oktober 2023, kemudian menurun menjadi 49 pada November 2023, dan naik menjadi 57 pada Desember 2023. Puncak terjadi pada April 2024 dengan 91 kasus, diikuti penurunan drastis hingga 14 kasus pada Juni 2024. Setelah itu, kasus meningkat menjadi 70 pada Agustus 2024 sebelum turun kembali menjadi 31 pada September 2024. Sebaliknya, prediksi model LSTM menunjukkan tren lebih stabil, dimulai dari 43 kasus pada Oktober 2023 dan menurun perlahan hingga 36 kasus pada September 2024. Error absolut, yaitu selisih antara data asli dan prediksi, bervariasi setiap bulan. Pada Oktober 2023, error absolut mencapai 24,8, menandakan perbedaan signifikan antara prediksi dan data asli. Error ini menurun menjadi 10,9 pada November 2023, namun kembali meningkat pada Desember 2023 dan Januari 2024 dengan masing-masing error 19,9 dan 15,6. Error tertinggi terjadi pada Agustus 2024 sebesar 32,68, sedangkan error terkecil tercatat pada September 2024 sebesar 5,92, menunjukkan prediksi yang lebih akurat pada akhir periode.

3. Penyakit Dyspepsia

Tabel 14 Hasil Prediksi Penyakit Dyspepsia

Tanggal	Dyspepsia	Prediksi	Error
2023-10-01	58	58	0
2023-11-01	50	61	11
2023-12-01	76	60	16
2024-01-01	81	60	21
2024-02-01	68	66	2
2024-03-01	86	65	21
2024-04-01	67	61	6
2024-05-01	92	61	31
2024-06-01	72	60	12
2024-07-01	47	60	13
2024-08-01	45	54	9
2024-09-01	61	53	8

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 10 Grafik hasil prediksi

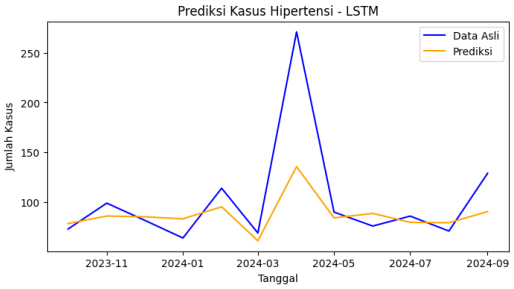
Grafik ini menampilkan perbandingan jumlah kasus dispepsia yang tercatat (garis biru) dan prediksi model LSTM (garis oranye) dari Oktober 2023 hingga September 2024. Pada Oktober 2023, model memprediksi 58,3 kasus, sangat mendekati data asli 58, dengan error absolut hanya 0,31. Namun, pada November 2023, prediksi mencapai 61,5, lebih tinggi dibandingkan data asli 50, menghasilkan error absolut 11,48. Ketidaksesuaian ini berlanjut pada Desember 2023, ketika prediksi 60,5 jauh di bawah data asli 76, dengan error absolut sebesar 15,52. Awal 2024 menunjukkan perbaikan, meskipun beberapa perbedaan masih tercatat. Pada Februari, data asli 81 dibandingkan prediksi 60,2 menghasilkan error absolut 20,77. Prediksi semakin mendekati data asli pada Maret dan April, dengan error masing-masing 20,6 dan 6,06. Pada Mei 2024, error absolut mencapai puncaknya dengan nilai 31,36, di mana prediksi 60,6 jauh di bawah data asli 92. Namun, mulai Juni hingga Agustus 2024, tren prediksi mengikuti pola menurun pada data asli. Di Juni, prediksi 60,1 dibandingkan data asli 72 menghasilkan error absolut 11,93. Pada Juli dan Agustus, prediksi masing-masing 59,6 dan 53,7 mendekati data asli 47 dan 45, dengan error 12,67 dan 8,67. Pada September 2024, prediksi model mencapai 53,1 dibandingkan data asli 61, menghasilkan error absolut sebesar 7,89.

4. Penyakit Hipertensi

Tabel 15 Hasil Penyakit Hipertensi

Tanggal	Hipertensi	Prediksi	Error Absolut
2023-10-01	73	78	5
2023-11-01	99	86	13
2023-12-01	82	85	3
2024-01-01	64	83	19
2024-02-01	114	95	19
2024-03-01	69	61	8
2024-04-01	271	136	135
2024-05-01	90	84	6
2024-06-01	76	89	13
2024-07-01	86	80	6
2024-08-01	71	79	8
2024-09-01	129	91	38

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 11 Grafik hasil prediksi

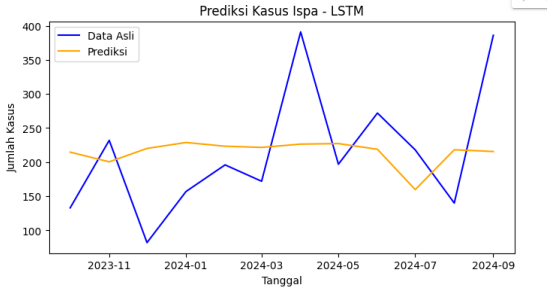
Grafik ini memperlihatkan perbandingan antara data asli jumlah kasus hipertensi (garis biru) dan hasil prediksi model LSTM (garis oranye) dari Oktober 2023 hingga September 2024. Pada Oktober 2023, model menunjukkan prediksi yang cukup akurat, dengan 78 kasus dibandingkan data asli 73, menghasilkan error absolut 5,47. Namun, akurasi menurun di bulan November, dengan prediksi 86 kasus dibandingkan data asli 99, menghasilkan error absolut 12,91. Prediksi yang paling akurat terjadi pada Desember 2023, di mana prediksi 85 kasus mendekati data asli 82, hanya berselisih 3 kasus. Dari Januari hingga Maret 2024, akurasi prediksi mengalami fluktuasi besar. Pada Januari, prediksi model mencapai 83 kasus dibandingkan data asli 64, menghasilkan error absolut 19,27. Pada Februari, model memprediksi 95 kasus dibandingkan data asli 114, dengan error absolut 18,65. Kesalahan terbesar terjadi pada Maret 2024, saat prediksi model 135 kasus jauh dari data asli 271, menghasilkan error absolut 135,32, yang menunjukkan tantangan dalam menangkap lonjakan besar. Setelah Maret, prediksi model kembali mendekati data asli, terutama dari April hingga Agustus 2024. Pada Mei, prediksi 84 kasus mendekati data asli 90, dengan error absolut 5,77. Pada Juni dan Juli, prediksi masing-masing memiliki error absolut 12,67 dan 6,19. Pada Agustus, prediksi sedikit lebih rendah dari data asli, menghasilkan error absolut 8,30. Pada bulan terakhir, September 2024, prediksi model 91 kasus kembali berbeda cukup signifikan dari data asli 129, menghasilkan error absolut sebesar 38,49.

5. Penyakit Ispa

Tabel 16 Hasil Penyakit Ispa

Tanggal	Ispa	Prediksi	Error Absolut
2023-10-01	133	215	82
2023-11-01	232	200	32
2023-12-01	82	220	138
2024-01-01	157	229	72
2024-02-01	196	223	27
2024-03-01	172	222	50
2024-04-01	391	226	165
2024-05-01	197	227	30
2024-06-01	272	219	53
2024-07-01	218	160	58
2024-08-01	140	218	78
2024-09-01	386	216	170

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 12 Grafik hasil prediksi

Grafik ini menunjukkan perbandingan antara jumlah kasus ISPA aktual (garis biru) dan prediksi model LSTM (garis oranye) dari Oktober 2023 hingga September 2024. Data tabel yang menyertai grafik menyoroti kesalahan prediksi model pada berbagai bulan selama periode tersebut. Pada Oktober 2023, model memprediksi 214,69 kasus, jauh lebih tinggi dibandingkan data asli yang tercatat sebanyak 133 kasus, menghasilkan error absolut sebesar 81,69. Pada bulan berikutnya, November 2023, model memprediksi 200,48 kasus dibandingkan data asli 232, dengan error absolut menurun menjadi 31,51. Namun, pada Desember 2023, prediksi model kembali meleset, memproyeksikan 220,13 kasus sementara data asli hanya 82 kasus, menghasilkan error absolut sebesar 138,13. Pada awal 2024, akurasi prediksi mulai meningkat. Pada Januari, model memprediksi 228,34 kasus dibandingkan data asli 157, menghasilkan error absolut 71,34. Pada Februari, prediksi model adalah 223,39 kasus dibandingkan data asli 196, dengan error absolut menurun menjadi 27,39. Namun, pada April 2024, terjadi lonjakan tajam pada data asli hingga 391 kasus, sementara model hanya memprediksi 226,47, menghasilkan error absolut sebesar 164,52, menunjukkan bahwa model kesulitan menangkap perubahan mendadak. Dari Mei hingga September 2024, prediksi model menunjukkan peningkatan akurasi di beberapa bulan. Misalnya, pada Juni 2024, prediksi model hampir tepat, dengan 218,87 kasus dibandingkan data asli 217, menghasilkan error absolut yang kecil, yaitu 1,87. Namun, pada Agustus 2024, prediksi model sebesar 218,17 kasus lebih tinggi dari data asli 140, menghasilkan error absolut sebesar 78,17. Pada bulan terakhir, September

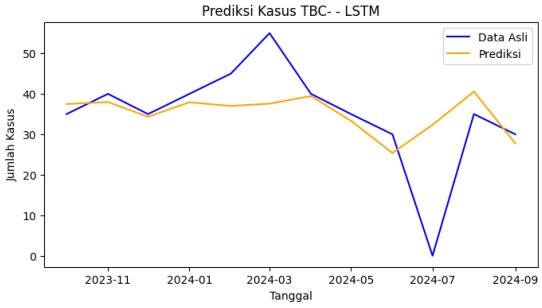
2024, prediksi model kembali meleset dengan proyeksi 215,68 kasus, jauh lebih rendah dari data asli sebanyak 386 kasus, menghasilkan error absolut sebesar 170,32.

6. Penyakit TBC-

Tabel 17 Hasil Penyakit TBC-

Tanggal	TBC-	Prediksi	Error
2023-10-01	35	37	2
2023-11-01	40	38	2
2023-12-01	35	34	1
2024-01-01	40	38	2
2024-02-01	45	37	8
2024-03-01	55	38	17
2024-04-01	40	39	1
2024-05-01	35	33	2
2024-06-01	30	25	5
2024-07-01	0	32	32
2024-08-01	35	41	6
2024-09-01	30	28	2

yang dapat divisualisasikan pada grafik prediksi berikut:



Gambar 13 Grafik hasil prediksi

Grafik dan tabel ini menyajikan hasil prediksi model LSTM untuk kasus TBC bulanan dari Oktober 2023 hingga September 2024, serta membandingkannya dengan data aktual. Garis biru pada grafik menunjukkan jumlah kasus TBC yang sebenarnya setiap bulan, sedangkan garis oranye menampilkan prediksi model. Secara umum, model menunjukkan akurasi yang cukup baik pada periode awal. Dari Oktober 2023 hingga Januari 2024, error absolut antara prediksi dan data asli relatif kecil, berkisar antara 0,65 hingga 2,48 kasus. Namun, akurasi model mulai menurun pada Februari 2024, ketika data asli mencatat 55 kasus sementara prediksi model hanya mencapai 37,00, menghasilkan error absolut sebesar 17,42. Hal ini menunjukkan bahwa model kurang mampu mendeteksi peningkatan signifikan pada data aktual. Pada Maret 2024, prediksi model kembali mendekati data asli dengan error absolut yang sangat kecil, hanya 0,53 kasus. Namun, pada bulan-bulan berikutnya, selisih antara prediksi dan data asli kembali meningkat. Periode Mei hingga Juli 2024 mencatat perbedaan yang paling mencolok. Misalnya, pada Juni, data asli mencatat 30 kasus, tetapi model hanya memprediksi 25,38 kasus, sehingga error absolut mencapai 4,61. Pada Juli, data asli mencatat nol kasus, sementara model tetap memprediksi 32,34 kasus, menghasilkan error absolut yang tinggi sebesar 32,34. Prediksi bulan Juli ini menunjukkan kelemahan model dalam menangkap perubahan tajam pada pola data, kemungkinan akibat faktor eksternal atau pola musiman yang tidak terdeteksi oleh model. Pada bulan Agustus 2024, akurasi model mulai membaik. Prediksi model mencapai 40,56 kasus, mendekati data asli sebesar 35, sehingga error absolut turun menjadi 5,55. Pada September 2024, akurasi prediksi meningkat lebih jauh dengan error absolut sebesar 2,23, menunjukkan bahwa model berhasil memulihkan performanya mendekati akhir periode prediksi.

KESIMPULAN DAN SARAN

Berdasarkan penerapan metode Deep Learning untuk memprediksi jumlah kasus penyakit utama di Puskesmas Tilango, dapat disimpulkan bahwa:

1. Hasil penerapan metode Deep Learning untuk memprediksi jumlah penyakit utama di Puskesmas Tilango menunjukkan bahwa baik model RNN maupun LSTM bisa digunakan, meski keduanya menunjukkan kinerja yang berbeda sesuai jenis penyakit. Berdasarkan hasil evaluasi, model RNN dengan parameter *epoch* 140, *batch size* 36, *hidden layer* 25, dan *time step* 3 menghasilkan nilai RMSE yang lebih rendah, yaitu 0,138, pada sebagian besar penyakit. Hal ini menunjukkan bahwa RNN lebih cocok untuk memprediksi pola jangka pendek, sehingga memberikan akurasi yang lebih tinggi. Sementara itu, model LSTM dengan parameter *epoch* 110, *batch size* 32, *hidden layer* 50, dan *time step* 11 memiliki performa yang lebih baik pada penyakit dengan pola jangka panjang, seperti ISPA, dengan nilai RMSE terendah, yaitu 0,125. Pengaturan *time step* yang lebih panjang dan jumlah *hidden layer* yang lebih besar memungkinkan LSTM untuk menangkap pola yang lebih kompleks dalam data.
2. Berdasarkan analisis hasil prediksi dengan metode Deep Learning pada data penyakit utama, dapat disimpulkan bahwa prediksi ini kurang memuaskan. Perbedaan yang cukup besar antara hasil prediksi dan data

aktual menunjukkan bahwa model ini belum sepenuhnya akurat dalam memprediksi nilai yang diinginkan. Hal ini disebabkan oleh adanya lonjakan ekstrem dalam data, yang membuat model kesulitan mengenali pola secara konsisten.

Berdasarkan hasil penelitian ini, beberapa saran dapat diambil untuk meningkatkan akurasi prediksi jumlah kasus penyakit, terutama dalam menghadapi tantangan terkait lonjakan kasus yang belum sepenuhnya tertangani oleh model. Saran-saran berikut bertujuan untuk memperkuat kemampuan model dalam memprediksi pola data kesehatan yang fluktuatif dan membantu Puskesmas Tilango mengoptimalkan penggunaan sumber daya sesuai kebutuhan kesehatan masyarakat.

1. Untuk menangani lonjakan kasus penyakit secara lebih efektif, disarankan untuk mengeksplorasi algoritma lain.
2. Dalam penelitian lanjutan, teknik pra-pemrosesan seperti normalisasi atau dekomposisi data (misalnya, menggunakan metode penghalusan atau pemisahan data tren dan musiman) dapat diterapkan untuk mengurangi dampak lonjakan drastis pada hasil prediksi.
3. Penelitian lanjutan juga dapat fokus pada penyesuaian parameter khusus yang ditujukan untuk menangani lonjakan data, seperti tuning pada time step dan jumlah neuron, yang mungkin dapat membantu meningkatkan sensitivitas model terhadap perubahan ekstrem.

DAFTAR PUSTAKA

[1] Aisyah, D., Purboyo, T. W., & Kallista, M. (2023). Prediksi Penderita Tuberkulosis Dengan Algoritma Long Short-Term Memory. *E-Proceeding of Engineering*, *10*(1), 742–749.

[2] Fitriyanti, F. (2023). Aplikasi Jaringan Syaraf Tiruan Backpropagation dalam Prediksi Curah Hujan Bulanan di Kabupaten Wajo Sulawesi Selatan. *JPF (Jurnal Pendidikan Fisika) Universitas Islam Negeri Alauddin Makassar*, *11*(1), 44–55. https://doi.org/10.24252/jpf.v11i1.33142

[3] Hafizh, M., Hamami, F., & Kusumasari, T. F. (2023). *Prediksi Network Capacity Planning PT XYZ Menggunakan Algoritma Recurrent Neural Network (RNN)*. *10*(5), 4880.

[4] Moch Farryz Rizkilloh, & Sri Widiyanesti. (2022). Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM). *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, *6*(1), 2531. https://doi.org/10.29207/resti.v6i1.3630

[5] Nurillah, R. A. S., Imrona, M., & Alamsyah, A. (2021). *Prediksi Pola Penyebaran Penyakit DBD di Kota Pagar Alam Menggunakan Long Short Term Memory (LSTM)*. *8*(1), 867–882.

[6] Paskalis, E., Orpa, K., & Ripanti, E. F. (2019). Model Prediksi Awal Masa Studi Mahasiswa. *JUSTIN (Jurnal Sistem Dan Teknologi Informasi)*, *7*(4), 272278. https://jurnal.untan.ac.id/index.php/justin/article/view/33163

[7] Pramunendar, R. A., Prabowo, D. P., & Megantara, R. A. (2022). Metode Recurrent Neural Network (Rnn) Dengan Arsitektur Lstm Untuk Analisis Sentimen Opini Publik Terkait Vaksin Covid-19. *Jurnal Informatika Upgris*, *8*(1), 44–48.

[8] Radikto, Mulyana, D. I., Rofik, M. A., & Zakaria, Mo. Z. Z. (2022). Klasifikasi Kendaraan pada Jalan Raya menggunakan Algoritma Convolutional Neural Network (CNN). *Jurnal Pendidikan Tambusai*, *6*(1), 1668–1679.

[9] Rozy, F., Fitri Boy, A., & Affandi, E. (2020). Implementasi Data Mining K-Means Clustering Dalam Pengelompokkan Data

Penyakit Pasien Pada Puskesmas Bestari Petisah. *Jurnal CyberTech*, *3*(5).

[10] Saladan, F., Jumlah Kunjungan Wisatawan Di Toraja Utara Menggunakan, P., Michael, A., Boas Gallaran, F., Studi Teknik Informatika, P., Kristen Indonesia Toraja, U., Toraja, T., Selatan, S., & Studi Manajemen, P. (2023). Prediksi Jumlah Kunjungan Wisatawan Di Toraja Utara Menggunakan Metode Long Short Term Me mory. *11 Infinity*, *3*(1), 2777 0451.https://doi .org/10.47178/infinity.v3i1.2189

[11] Suyudi, M. A. D., Djamal, E. C., & Maspupah, A. (2019). Prediksi Harga Saham menggunakan Metode Recurrent Neural Network. *Seminar Nasional Aplikasi Teknologi Informasi (SNATi)*, 1907–5022.

[12] Wardani, W. W. K. (2021). *Prediksi Harga Saham Syariah Menggunakan Metode Recurrent Neural Network Long Short Term Memory*. http://digilib.uinsby.ac.id/id/eprint/49542%0Ahttp://digilib.uinsby.ac.id/49542/2/Wulan Wahyu Kusuma Wardani_H72217053.pdf

[13] Wijaya, Y. F., & Triayudi, A. (2023). Perbandingan Algoritma Klasifikasi Data Mining Pada Prediksi Penyakit Diabetes. *Journal of Computer System and Informatics (JoSYC)*, *5*(1). https://doi.org/10.47065/josyc .v5i1.4614