

**INTEGRASI ANALISIS DIFERENSIAL DAN DEEP LEARNING UNTUK
PREDIKSI KEBUTUHAN OBAT PROGRAM BPJS PRB**

SKRIPSI

Diajukan Sebagai Salah Satu Syarat Untuk Mendapatkan
Gelar Sarjana Komputer (S.Kom) Program Studi Informatika



CHALIDAH AZ-ZAHRAH H

105841107321

PROGRAM STUDI INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS MUHAMMADIYAH MAKASSAR

2025

**INTEGRASI ANALISIS DIFERENSIAL DAN DEEP LEARNING UNTUK
PREDIKSI KEBUTUHAN OBAT PROGRAM BPJS PRB**

SKRIPSI

**Diajukan Sebagai Salah Satu Syarat Untuk Mendapatkan
Gelar Sarjana Komputer (S.Kom) Program Studi Informatika**

Disusun dan Diajukan Oleh:

CHALIDAH AZ-ZAHRAH H

105841107321

PROGRAM STUDI INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS MUHAMMADIYAH MAKASSAR

2025

ii



MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR
FAKULTAS TEKNIK



PENGESAHAN

Skripsi atas nama Chalidah Azzahrah H dengan nomor induk Mahasiswa 105841107321, dinyatakan diterima dan disahkan oleh Panitia Ujian Tugas Akhir/Skripsi sesuai dengan Surat Keputusan Dekan Fakultas Teknik Universitas Muhammadiyah Makassar Nomor : 0004/SK-Y/55202/091004/2025, sebagai salah satu syarat guna memperoleh gelar Sarjana Komputer pada Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar pada hari Jumat, 12 September 2025.

Panitia Ujian :

1. Pengawas Umum

Makassar,

19 Rabi'ul Awwal 1447 H
12 September 2025 M

a. Rektor Universitas Muhammadiyah Makassar

Dr. Ir. H. Abd. Rakhim Nanda, ST., MT., IPU

b. Dekan Fakultas Teknik Universitas Muhammadiyah Makassar

Prof. Dr. Eng. Muhammad Isran Ramli, S.T., MT., ASEAN Eng.

2. Penguji

a. Ketua

Prof. Dr. Ir. Hafsa Niwana, MT

B. Sekretaris

Ir. Ida S. Kom, MT

3. Anggota

1. Chyquitha Danuputri, S.Kom, M.Kom

2. Ir. Muhammad Faisal, S.Si., MT., Ph.D., Ipm:

3. Lukman, S.Kom, MT

Pembimbing I

Pembimbing II

(Fahrin Irfanina Rachman S.Kom., M.T)

(Muhviddin M. Hayat, S.Kom, MT)

Dekan



Ir. Muh. Syafaat S. Kuba, S.T., M.T.
NBM : 795 288

Gedung Menara Iqra Lantai 3

Jl. Sultan Alauddin No. 259, Telp. (0411) 866 932 Fax (0411) 865 588, Makassar 90221

Web: <https://teknik.unismuh.ac.id/>, e-mail: teknik@unismuh.ac.id





MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR
FAKULTAS TEKNIK



HALAMAN PENGESAHAN

Tugas Akhir ini diajukan untuk memenuhi syarat ujian guna memperoleh gelar Sarjana Komputer (S.Kom) Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar.

Judul Skripsi : **INTEGRASI ANALISIS DIFERENSIAL DAN DEEP LEARNING
UNTUK PREDIKSI KEBUTUHAN OBAT PROGRAM BPJS PRB**

Nama : Chalidah Az-zahrah H


Stambuk : 105 84 11073 21

Makassar, 12 September 2025

Telah Diperiksa dan Disetujui
Oleh Dosen Pembimbing;

Pembimbing I

Pembimbing II


(Fahrir Irhamna Rachman S.Kom., M.T)


(Muhyiddin A. Wahyati, S.Kom, MT)

Mengetahui,

Ketua Prodi Informatika



Rizki Yustiana Bakti, S.T., M.T.

NBM : 1307 284

Gedung Menara Iqra Lantai 3

Jl. S. Soetrisno Al-Jodid No. 259 Telp. (0411) 866 972 Fax (0411) 865 589 Makassar 90221

Web : <http://teknik.unismuh.ac.id/>, e-mail : teknik@unismuh.ac.id



KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Segala puji bagi Allah SWT yang selalu memberikan kita banyak nikmat, yaitu nikmat sehat, waras, kelapangan, dan yang paling besar yaitu nikmat hidayah yang diberikan Allah hanya kepada hamba-Nya yang dikehendaki. Tidak lupa, shalawat serta salam semoga selalu tercurahkan kepada Nabi Muhammad SAW, sang revolutioner sejati dan teladan bagi seluruh umat, yang telah menyebarkan Islam melalui dakwah secara sembunyi-sembunyi dan terbuka. Berkat perjuangan beliau, hingga saat ini kita dapat merasakan nikmatnya berislam. Dengan pertolongan-Nya, penulis dapat menyelesaikan proposal skripsi berjudul **“INTEGRASI ANALISIS DIFERENSIAL DAN DEEP LEARNING UNTUK PREDIKSI KEBUTUHAN OBAT PROGRAM BPJS PRB ”** tepat pada waktunya.

Penulisan skripsi ini disusun oleh penulis sebagai bagian dari persyaratan untuk menyelesaikan Program Sarjana (S1) di Program Studi Informatika, Fakultas Teknik, Universitas Muhammadiyah Makassar. Penulis berharap skripsi ini dapat memberikan referensi tambahan bagi para pembaca, khususnya mahasiswa informatika, dan masyarakat umum. Pada kesempatan ini, penulis ingin menyampaikan rasa syukur dan terima kasih yang sebesar-besarnya kepada:

1. Allah Subhanahu Wa Ta'ala atas nikmat kesehatan, kewartaan, kelonggaran sehingga penulis dapat dengan penuh semangat mengerjakan laporan ini.
2. Kedua orang tua penulis yang selalu merawat dengan penuh kasih sayang dan memberikan dukungan tanpa henti, baik dalam bentuk material maupun nonmaterial. Penulis sangat berterima kasih atas doa-doa yang tiada henti, yang senantiasa menyelimuti dengan perasaan tenang dan semangat dalam menjalankan penelitian ini, bahkan di saat-

saat yang paling sulit sekalipun. Tanpa cinta dan dukungan mereka, mungkin tidak akan mampu melewati setiap cobaan yang ada. Segala upaya yang penulis lakukan ini, dengan sepenuh hati dan penuh pengorbanan, penulis persembahkan untuk diri penulis sendiri dan kedua orang tua sebagai bentuk rasa hormat dan terima kasih yang mendalam. Mereka adalah pilar kekuatan penulis, dan dedikasi ini adalah bukti kecil dari betapa besar peran mereka dalam setiap langkah yang ambil.

3. Bapak Prof. Dr. H. Ambo Asse, M.Ag., sebagai Rektor Perguruan Tinggi Unniversitas Muhammadiyah Makassar.
4. Bapak Muhyiddin A.M Hayat S.Kom.,MT selaku ketua Prodi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar.
5. Bapak Fachrim Irhamna Rachman. S.Kom.,M.T selaku Dosen Pembimbing I dan Ibu Rizki Yusliana Bakti, S.T.,M.T selaku pembimbing II.
6. Seluruh Dosen dan Staf Fakultas Teknik Unversitas Muhammadiyah Makassar
7. Kepada Arya, Oca, Lis, Riska, Ayu, Reza, Widi dan seluruh penghuni kamar Kostnya Arya yang merupakan teman seperjuangan penulis, penulis ingin mengucapkan terima kasih yang sebesar-besarnya atas dukungan dan kehadiran kalian yang selalu ada dalam segala situasi. Kehadiran kalian telah menjadi sumber kekuatan dan inspirasi bagi penulis dalam menyelesaikan penelitian ini. Semoga apa yang kita cita- citakan di masa depan dapat tercapai, dan ketika saat itu tiba, berharap kita tetap saling mendukung dan tidak hanya menjadi penonton di media sosial. Dukungan dan persahabatan kalian sangat berarti, dan penulis berharap ikatan ini akan terus terjaga seiring waktu.

Semoga Tuhan Yang Maha Esa senantiasa melimpahkan segala nikmat yang lebih besar kepada beliau. Dengan harapan, laporan ini dapat memberikan manfaat dan barokah kepada pembaca secara umum dan terkhusus bagi penulis.

Makassar, September 2025

Chalidah Az-zahrah H



DAFTAR ISI

KATA PENGANTAR.....	v
DAFTAR ISI	viii
DAFTAR GAMBAR	x
DAFTAR TABLE.....	xi
BAB I	1
PENDAHULUAN.....	1
A. Latar Belakang.....	1
B. Rumusan Masalah	3
C. Tujuan Penelitian.....	3
D. Manfaat Penelitian.....	3
E. Ruang Lingkup Penelitian.....	3
F. Sistem Penulisan	4
BAB II.....	5
TINJAUAN PUSTAKA.....	5
A. Landasan Teori	5
B. Penelitian Terkait.....	13
C. Kerangka Berpikir	15
BAB III.....	17
METODE PENELITIAN.....	17
A. Waktu dan Tempat Penelitian.....	17
B. Alat dan Bahan	18
C. Perancangan Sistem.....	18
D. Teknik Pengujian Sistem	25
E. Teknik Analisis Data.....	25
BAB IV	27
HASIL DAN PEMBAHASAN	27
A. Pengambilan Data.....	27
B. Preprocessing Data	28
C. Penerapan Analisis Difrensial.....	31
D. Proses dan Hasil dari Analisis Diferensial.....	33

E.	Proses Latihan Model dan Peran Data Diferensial (Original, Delta_1, Delta_2).....	36
F.	Time Step yang Diambil dan Penanganan Data Nol.....	37
G.	Hasil Prediksi dan Evaluasi Akurasi (MSE, MAE, MAPE).....	39
H.	Evaluasi Kinerja Model Prediksi.....	41
I.	Hasil Evaluasi Per Produk.....	41
J.	Kasus dengan Error Tinggi.....	42
BAB V.....		31
KESIMPULAN DAN SARAN.....		31
A.	Kesimpulan.....	31
B.	Saran.....	32
DAFTAR PUSTAKA.....		32



DAFTAR GAMBAR

Gambar 1 Kerangka Berfikir.....	16
Gambar 2 Flowchart.....	22
Gambar 3 Flowchart LSTM.....	24
Gambar 4 Pengambilan Data	27
Gambar 5 Data Transaksi	28
Gambar 6 Tabel sebelum cleaning	29
Gambar 7 Tahap Setelah CLeaning.....	30
Gambar 8 Hasil Transformasi Data.....	31
Gambar 9 Output dari Hasil Proses Analisis Difrensial.....	35
Gambar 10 Proses Pelatihan dan Penyimpanan ke dalam Model Masing-masing Obat.....	37
Gambar 11 Kumpulan model hasil training yang diexport	39
Gambar 12 Hasil dari export ke Excell untuk semua obat.....	40
Gambar 13 Grafik Mean Absolute Error (MAE) pada Tiap Produk.....	42
Gambar 14 Hasil Output Tabel evaluasi di Excell	44



DAFTAR TABLE

Tabel 1 Waktu Penelitian.....	17
Tabel 2 Contoh Evaluasi Model terhadap Beberapa Obat	41



BAB I

PENDAHULUAN

A. Latar Belakang

Program Rujuk Balik (PRB) dari program BPJS Kesehatan merupakan salah satu inovasi layanan kesehatan berkelanjutan untuk pasien penyakit kronis dengan kondisi stabil yang masih memerlukan pengobatan atau asuhan keperawatan jangka panjang (Kusumawati & Rahayu, 2023). Tujuan program Rujuk Balik (PRB) adalah untuk meningkatkan kualitas pelayanan kesehatan bagi peserta yang menderita penyakit kronis. Dengan berbagai manfaat seperti mempermudah akses ke layanan Kesehatan serta memfasilitasi peserta dalam memperoleh obat yang dibutuhkan (Kusumawati & Rahayu, 2023).

Berdasarkan Peraturan Menteri Kesehatan Republik Indonesia Nomor 28 Tahun 2024 tentang Pedoman Pelaksanaan Program Jaminan Kesehatan Nasional, Pelaksanaan Program Rujuk Balik (PRB) untuk pasien penyakit kronis diwajibkan apabila kondisi pasien telah stabil dan disertai surat rujuk balik dikeluarkan oleh dokter spesialis atau subspesialis (Kusumawati & Rahayu, 2023). Pelayanan obat kronis program rujuk balik tersebut diberikan untuk penyakit Diabetes Melitus, hipertensi, jantung, asma, Penyakit Paru Obstruktif Kronis (PPOK), epilepsi, gangguan kesehatan jiwa kronis, stroke dan Sistemik Lupus Eritematosus (SLE) (Sudradjat et al., 2020).

Meningkatnya angka rujukan ini bila tidak diimbangi dengan pelaksanaan program rujuk balik (PRB) pasien penyakit kronis yang optimal dapat mengakibatkan penumpukan dan terhambatnya pelayanan kesehatan berkelanjutan bagi pasien (Rahmat et al., 2024). Oleh karena itu, diperlukan cara untuk memudahkan prediksi pemakaian obat di seluruh Kimia Farma atau Apotek.

Telah dilakukan beberapa penelitian sebelumnya untuk memprediksi penyediaan kebutuhan obat pada program rujuk balik. Pada tahun 2023, Sulaiman Martawinata, dan Prastuti Soewondo melakukan penelitian dengan pendekatan kualitatif melalui wawancara mendalam serta telaah dokumen

untuk mengkaji hubungan antara komponen input, proses, dan output terkait ketersediaan obat PRB pada kasus hipertensi. Hasil penelitian menunjukkan bahwa masih terjadi kekosongan obat PRB untuk pasien hipertensi. Hal ini disebabkan oleh berbagai kendala, baik dari sisi input-seperti keterbatasan sumber daya manusia, minimnya sarana pendukung, dan belum optimalnya implementasi kebijakan-maupun dari sisi proses, seperti hambatan dalam perencanaan, distribusi dan pemanfaatan obat (Martawinata et al., 2023).

Analisis diferensial, atau lebih tepatnya kalkulus diferensial, memiliki berbagai penerapan penting. Ini mencakup analisis algoritma, optimasi, pemodelan sistem, dan pengembangan kecerdasan buatan. Pendekatan metode kecerdasan buatan Deep Learning. Subbidang kecerdasan buatan yang berfokus pada pembelajaran dari data, dapat digunakan untuk membangun sistem ini. Deep Learning adalah salah satu teknik Machine Learning andal yang tersedia saat ini. Deep Learning menggunakan pendekatan jaringan saraf tiruan dalam mempelajari pola – pola yang kompleks (Rachman et al., 2024).

Berbagai studi telah dilakukan mengenai penerapan algoritma Deep Learning dalam memprediksi ketersediaan obat, salah satunya adalah algoritma LSTM (*Long Short Term Memory*). Algoritma LSTM (*Long Short Term Memory*) merupakan salah satu jenis arsitektur dari *Recurrent Neural Network* (RNN) yang biasa digunakan pada masalah – masalah yang berkaitan dengan Deep Learning (Khumaidi et al., 2022). Penelitian yang dilakukan oleh Fajri Yanti dan kawan – kawan yang membahas tentang Implementasi algoritma LSTM pada peramalan stok obat.

Hasil dari beberapa penelitian tersebut menunjukkan bahwa hasil yang didapatkan sudah baik. Sehingga, pada penelitian ini akan dilakukan pembuatan sistem Analisis Diferensial dan Deep Learning untuk memprediksi kebutuhan obat program BPJS PRB.

B. Rumusan Masalah

Berdasarkan uraian latar belakang yang telah dipaparkan sebelumnya, penelitian dapat menyusun perumusan masalah berikutnya:

Bagaimana Mengintegrasikan Analisis Diferensial dan Deep Learning untuk prediksi kebutuhan obat pada program BPJS PRB.

C. Tujuan Penelitian

Berdasarkan perumusan masalah yang telah diidentifikasi, tujuan dari penelitian ini adalah sebagai berikut:

Untuk mengetahui cara Mengintegrasikan Analisis Diferensial dan Deep Learning untuk prediksi kebutuhan obat pada program BPJS PRB

D. Manfaat Penelitian

Penelitian ini diharapkan memberikan kontribusi yang signifikan baik secara teoritis maupun praktis, sebagai berikut:

1. Secara Teoritis:
 - a. Mendukung pengembangan ilmu pengetahuan, khusus dalam bidang informatika dan ilmu komunikasi.
 - b. Memberikan sistem prediksi yang membantu BPJS dalam pengelolaan kebutuhan obat.
2. Secara Praktis:
 - a. Bagi Peneliti:
 - 1) Memahami proses kerja Machine Learning dan bentuk implementasinya.
 - 2) Menambah portofolio yang bermanfaat bagi peneliti di masa depan.
 - b. Bagi Universitas
 - 1) Menyediakan referensi bagi peneliti dimasa mendatang
 - 2) Sebagai bahan evaluasi bagi universitas dalam mengembangkan keilmuan, khususnya terkait program berbasis AI.

E. Ruang Lingkup Penelitian

Berdasarkan perumusan masalah di atas, dapat disusun beberapa Batasan penelitian, yaitu:

1. Pengambilan data yang digunakan merupakan data historis penggunaan obat PRB

- dari Apotek Kimia Farma Cendrawasih.
2. Fokus pada jenis – jenis obat yang umum digunakan dalam penanganan penyakit kronis sesuai cakupan PRB.
 3. Sistem Output hanya akan memberikan prediksi jumlah kebutuhan obat.

F. Sistem Penulisan

Secara garis besar, laporan tugas akhir ini dibagi menjadi beberapa bab sebagai berikut:

BAB I PENDAHULUAN

Bab ini menguraikan latar belakang masalah, perumusan masalah, Batasan masalah, tujuan, manfaat, serta sistematika penulisan.

BAB II TINJAUAN PUSTAKA

Bab ini memaparkan teori – teori yang mendasari penulisan dalam pelaksanaan skripsi.

BAB III METODE PENELITIAN

Bab ini membahas metode penelitian serta alat yang digunakan dalam pengembangan sistem.

BAB II

TINJAUAN PUSTAKA

A. Landasan Teori

1. Deep Learning

Deep Learning merupakan cabang dari kecerdasan buatan dan machine learning yang merupakan pengembangan dari jaringan saraf berlapis-lapis (multi-layer neural network) untuk meningkatkan akurasi dalam menjalankan berbagai tugas seperti deteksi objek, pengenalan suara, penerjemahan bahasa, dan lainnya. Berbeda dengan metode machine learning tradisional, deep learning mampu secara otomatis mempelajari representasi dari data seperti gambar, video, atau teks tanpa memerlukan aturan eksplisit atau pengetahuan dari manusia. Deep Learning terdiri dari kumpulan algoritma dalam machine learning yang dirancang untuk belajar pada berbagai level abstraksi. Pendekatan ini umumnya menggunakan jaringan saraf tiruan, di mana tiap tingkat dalam model statistik mencerminkan konsep pada level yang berbeda — konsep yang lebih kompleks dibangun dari konsep yang lebih sederhana, dan sebaliknya, konsep dasar dapat membantu membentuk konsep yang lebih tinggi. Selain itu, Deep Learning merupakan subbidang dari machine learning yang algoritmanya terinspirasi oleh cara kerja otak manusia, yang dikenal dengan Artificial Neural Networks (ANN). Jaringan ini memiliki tiga lapisan atau lebih, dan mampu belajar serta menyesuaikan diri terhadap volume data yang besar, serta menyelesaikan permasalahan kompleks yang sulit ditangani oleh algoritma machine learning konvensional (Raup et al., n.d.).

2. Analisis Diferensial

Analisis biaya diferensial merupakan proses estimasi atau konsekuensi dari tindakan-tindakan alternatif yang dapat diambil alih oleh para pengambil keputusan. Informasi akuntansi diferensial merupakan informasi akuntansi yang berkaitan dengan pemilihan alternatif. Informasi akuntansi diferensial merupakan taksiran perbedaan biaya, pendapatan dan atau aktiva dalam

alternatif tindakan tertentu dibandingkan dengan alternatif tindakan yang lain (Tiwa et al., 2022).

Analisis diferensial, yang merupakan bagian dari kalkulus, memiliki berbagai aplikasi penting dalam Teknik Informatika. Ini membantu memahami perubahan, optimasi algoritma, dan pengembangan model matematika dalam berbagai bidang, seperti simulasi, kecerdasan buatan, dan pengembangan perangkat lunak.

3. LSTM

Algoritma Long Short-Term Memory (LSTM) merupakan salah satu metode dalam Deep Learning yang telah banyak dimanfaatkan oleh para peneliti untuk melakukan prediksi dalam berbagai bidang, seperti pengenalan pola, deteksi objek, dan lain-lain. LSTM adalah pengembangan dari Recurrent Neural Network (RNN) yang dilengkapi dengan sel memori. Algoritma ini pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 (Jansen et al., 2023).

LSTM dapat mengatasi masalah pergerakan harga yang memiliki ketergantungan jangka panjang, yang tidak dapat ditangani dengan baik oleh model RNN tradisional. LSTM memiliki kemampuan untuk "mengingat" informasi dari jangka waktu yang lebih lama, sehingga dapat mengenali pola dan tren kompleks dalam data historis (Pratama & Utama, 2023).

Rumus atau mekanisme Long Short-Term Memory (LSTM) pada prediksi seperti yang kamu lakukan (prediksi penjualan obat per bulan berbasis time series) tidak bisa dijelaskan hanya dengan satu formula sederhana, karena LSTM adalah arsitektur kompleks berbasis sel memori dan gate. Namun, saya akan jelaskan secara bertahap dalam dua bagian:

1. Konsep Umum LSTM untuk Time Series

Misalnya kamu punya 18 bulan penjualan obat:

$[x_1, x_2, x_3, \dots, x_{18}] \rightarrow \text{input time series}$

Kalau kamu pakai timesteps = 3, maka kamu ubah data jadi potongan-potongan seperti ini:

Input (X)	→ Target (Y)
$[x_1, x_2, x_3]$	→ x_4
$[x_2, x_3, x_4]$	→ x_5
$[x_3, x_4, x_5]$	→ x_6
...	

LSTM akan mencoba belajar dari urutan data masa lalu (X) untuk memprediksi data selanjutnya (Y).

1. Rumus Internal Sel LSTM

Satu unit LSTM bekerja dengan 4 komponen utama:

- Forget gate (f)
- Input gate (i)
- Candidate state ($\sim c$)
- Output gate (o)

Notasi:

- x_t : input sekarang
- h_{t-1} : hidden state sebelumnya
- c_{t-1} : cell state sebelumnya

Dengan input saat ini x_t dan hidden state sebelumnya h_{t-1} :

a. Forget gate

Tentukan seberapa banyak informasi masa lalu yang dibuang.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \dots\dots\dots (1)$$

b. Input gate + Candidate

Tentukan apa informasi baru yang akan ditambahkan.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \dots\dots\dots (2)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \dots\dots\dots (3)$$

2. Memperbarui Cell State

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t. \dots\dots\dots (4)$$

3. Output Gate dan Hidden State

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \dots\dots\dots (5)$$

$$h_t = o_t * \tanh(c_t) \dots\dots\dots (6)$$

- W, b : bobot dan bias yang dipelajari oleh model.
- σ : fungsi aktivasi sigmoid.
- $\tanh$: fungsi aktivasi hyperbolic tangent (tanh).
-

4. Tensorflow

Dikembangkan oleh tim Google Brain, Tensorflow adalah library open source untuk komputasi numerik dan machine learning skala besar. Tensorflow menggabungkan banyak model, algoritma machine learning untuk menyediakan API front-end untuk membangun aplikasi dengan framework, sekaligus menjalankan aplikasi tersebut dengan formula tinggi.

Tensorflow memiliki kemampuan untuk melatih dan menjalankan jaringan saraf tiruan untuk berbagai tugas, seperti klasifikasi tulisan tangan, pengenalan citra, pemetaan kata (Word Embedding), Recurrent Neural Network (RNN), model sequence-to-sequence untuk penerjemahan, pemrosesan Bahasa parsial (Partial Differential Equations atau PDE)

(Muharram & Suryadi, 2022).

5. Scikit Learn

Scikit-Learn merupakan Library Python yang dirancang untuk mempermudah implementasi Machine Learning dengan menyediakan *API* yang dikembangkan oleh sejumlah kontributor dari berbagai negara. Library ini banyak digunakan di lingkungan industri maupun akademik. Dari segi kinerja, Scikit-Learn tergolong optimal karena dibangun di atas modul NumPy (Numerical Python) dan SciPy (Scientific Python), sehingga proses perhitungannya menjadi lebih efisien. Meski begitu, Scikit-Learn memiliki kekurangan yaitu kurang cocok digunakan untuk pengolahan data berskala besar (Fahmi et al., 2023).

6. Supervised Learning

Supervised Learning merupakan metode dalam Machine Learning yang memanfaatkan data yang telah diberi label atau dataset yang sudah diketahui oleh pembuatnya. Data yang telah dilabelkan tersebut berfungsi untuk melatih algoritma dengan bimbingan, sehingga algoritma dapat mengklasifikasi atau memprediksi suatu kasus dengan tingkat akurasi yang baik (Nurhalizah & Ardianto, 2024).

Supervised Learning adalah salah satu metode dalam Machine Learning yang digunakan untuk memperoleh informasi atau melakukan prediksi dengan memanfaatkan data berupa fitur pada setiap sampel serta label yang sesuai sebagai input. Metode ini terbagi menjadi dua jenis yaitu klasifikasi dan regresi. Klasifikasi menggunakan label dalam bentuk kategori, sedangkan regresi menggunakan label berupa nilai numerik atau bilangan real. Tujuan utama dari teknik ini adalah untuk memprediksi keluaran dengan membandingkannya terhadap pengalaman atau data pembelajaran sebelumnya (Fahmi et al., 2023).

7. Confusion Matrix

Confusion Matrix merupakan sebuah tabel yang digunakan untuk menunjukkan jumlah data uji yang berhasil diklasifikasikan dengan benar maupun salah. Tabel ini mempermudah proses evaluasi akurasi dari sebuah sistem klasifikasi. Melalui Confusion Matrix, kinerja sistem klasifikasi dapat dianalisis secara lebih mendetail, termasuk dalam mengidentifikasi letak kesalahan klasifikasi. Meskipun, tergolong sederhana, confusion matrix adalah metode yang efektif untuk menilai performa suatu sistem klasifikasi, dengan fokus utama pada pengukuran tingkat akurasi dalam mengklasifikasikan data uji. Confusion Matrix digunakan untuk mengevaluasi tingkat akurasi dari suatu proses klasifikasi yang telah dilakukan. Tingkat akurasi ini mengindikasikan proporsi jumlah prediksi yang benar (Nurhidayat & Dewi, 2023).

8. PRB (Program Rujuk Balik)

Program Rujuk Balik (PRB) dari program BPJS Kesehatan merupakan salah satu inovasi layanan kesehatan berkelanjutan untuk pasien penyakit kronis dengan kondisi stabil yang masih memerlukan pengobatan atau asuhan keperawatan jangka panjang. (Kusumawati & Rahayu, 2023). Tujuan program Rujuk Balik (PRB) adalah untuk meningkatkan kualitas pelayanan kesehatan bagi peserta yang menderita penyakit kronis. Dengan berbagai manfaat seperti mempermudah akses ke layanan Kesehatan serta memfasilitasi peserta dalam memperoleh obat yang dibutuhkan (Rahayu & Kusumawati, 2023).

Penyakit kronis adalah kondisi yang berlangsung dalam jangka waktu lama, dapat dikendalikan namun sulit untuk disembuhkan secara total. Menurut World Health Organization (WHO), penyakit kronis berkembang secara perlahan dan disebabkan oleh berbagai faktor seperti biologis, genetik, perilaku, serta lingkungan. Berdasarkan data WHO tahun 2017, penyakit kronis menjadi penyebab utama kematian di dunia, dengan rincian 17,5 juta kematian akibat penyakit kardiovaskular, 8,8 juta karena kanker, 3,9 juta

akibat penyakit pernapasan kronis, dan 1,6 juta disebabkan oleh diabetes melitus. Sebagai upaya untuk mengurangi beban anggaran di sektor kesehatan, pemerintah menjalankan program rujuk balik. Melalui program ini, pasien tetap dapat menerima pengobatan jangka panjang di fasilitas kesehatan tingkat pertama dengan biaya yang lebih rendah. Program ini juga membantu mengurangi beban biaya perawatan di fasilitas kesehatan tingkat lanjutan yang bermitra dengan BPJS Kesehatan (Wakiyah Saharani et al., n.d.).

9. Mean Squared Error (MSE)

Metode Mean Squared Error (MSE) adalah rata-rata dari kuadrat selisih antara nilai aktual dan nilai prediksi, digunakan untuk mengukur tingkat kesalahan dalam peramalan. MSE sangat penting dalam evaluasi model prediksi penjualan obat karena memberikan gambaran jelas tentang seberapa jauh prediksi model dari nilai aktual. Metrik ini membantu mengidentifikasi dan mengoreksi kesalahan prediksi, meningkatkan akurasi model. (Ita Bela & Bhakti, 2022). Semakin kecil nilai MSE, semakin baik model dalam meramalkan penjualan obat, karena menunjukkan perbedaan yang lebih kecil antara nilai prediksi dan nilai aktual. Selain itu, MSE memudahkan pemilihan model terbaik dari beberapa kandidat dengan membandingkan nilai MSE mereka (Yusuf Syahrul Basyar, 2024).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \dots\dots\dots (7)$$

Dimana :

- Mean $\rightarrow \frac{1}{n}$: Rata-rata dari error.
- Error $\rightarrow Y_i - \hat{Y}_i$: Selisih antara nilai aktual dan prediksi.
- Squared $\rightarrow (\cdot)^2$: Error dikuadratkan agar semua nilai positif dan menekankan error besar.

10. Mean Absolute Error (MAE)

Metode Mean Absolute Error (MAE) adalah rata-rata dari nilai absolut kesalahan prediksi. Untuk mengetahui metode prediksi dengan akurasi tinggi, penting untuk menghitung tingkat kesalahan dalam prediksi tersebut. Semakin kecil tingkat kesalahan yang dihasilkan, semakin baik prediksinya. MAE adalah standar umum yang digunakan untuk mengukur kesalahan prediksi dan menilai akurasi model (Ita Bela & Bhakti, 2022). Dengan menggunakan MAE, perusahaan dapat mengevaluasi performa berbagai model prediksi dan memilih model yang paling sesuai berdasarkan tingkat kesalahannya. Selain itu, MAE dapat digunakan untuk membandingkan kinerja model prediksi dari berbagai periode waktu atau berbagai jenis obat, memastikan strategi penjualan yang lebih baik dan pelayanan yang optimal kepada pelanggan (Yusuf Syahrul Basyar, 2024).

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \dots\dots\dots (8)$$

Dimana :

- Y_i : Data aktual penjualan obat pada periode ke- i
- $\hat{Y}_i$: Data hasil prediksi penjualan obat pada periode ke- i
- n : Jumlah total periode data penjualan obat

11. Root Mean Squared Error (RMSE)

Root Mean Square Error (RMSE) adalah metode yang digunakan untuk mengevaluasi suatu model dengan menghitung seberapa besar tingkat akurasinya. Nilai RMSE diperoleh dari selisih antara data aktual penjualan obat dan data prediksi penjualan obat yang dikuadratkan, kemudian dibagi dengan jumlah periode prediksi, dan akhirnya diakarkan. Rumus untuk menentukan nilai RMSE adalah sebagai berikut:

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} \dots\dots\dots (9)$$

Dimana :

- Y_i : Data aktual penjualan obat pada periode ke- i
- $\hat{Y}_i$: Data hasil prediksi penjualan obat pada periode ke- i
- n : Jumlah total periode data penjualan obat

B. Penelitian Terkait

1. Sinta Amanad Pratiwi, Ahmad Fauzi, Santi Arum Puspita Lestari, Yana Cahyana, 2024

Pada penelitian yang dilakukan oleh Sinta Amanad Pratiwi dan kawan-kawan yang berjudul “Prediksi Persediaan Obat Pada Apotek Menggunakan Algoritma Decision Tree”. Hasil penelitian menunjukkan bahwa algoritma Decision Tree mampu memprediksi ketersediaan obat di apotek dengan tingkat akurasi yang tinggi, sekitar 98,71% pada rasio data 80:20. Selain itu, model ini juga menunjukkan performa yang sangat baik berdasarkan metrik evaluasi lainnya seperti Presisi, Recall, dan F1-Score yang masing-masing sekitar 0.9872. Hasil ini konsisten dan stabil di berbagai rasio data, serta menunjukkan bahwa Decision Tree sangat efektif dalam memprediksi persediaan obat, sehingga dapat membantu pengelolaan stok di apotek secara lebih akurat dan efisien (Pratiwi et al., 2024).

2. Fajri Yanti, Betha Nurina Sari, Sofi Defiyanti

Pada penelitian yang dilakukan oleh Fajri Yanti dan kawan-kawan yang berjudul ”Implementasi Algoritma LSTM pada Peramalan Stok Obat (Studi Kasus : Puskesmas Beber)”. Hasil penelitian menunjukkan bahwa metode LSTM sangat efektif dalam memprediksi stok obat di Puskesmas Beber. Evaluasi menggunakan MAPE menunjukkan nilai terendah sebesar 4.82% pada obat 4, dan sebagian besar obat seperti obat 1, obat 2, obat 4, dan obat 5 termasuk dalam kategori kinerja sangat baik, sementara obat 3 termasuk

kategori baik. Temuan ini mendukung penggunaan LSTM untuk membantu perencanaan stok obat yang lebih akurat, mengurangi risiko kekurangan atau kelebihan stok, serta meningkatkan efisiensi pengelolaan persediaan di puskesmas (Yanti et al., 2024).

3. Jason Nathaniel, Ventje Jeremias Lewi Engel

Pada penelitian yang dilakukan oleh Jason dan Ventje yang berjudul "Penerapan Nonpooling CNN-LSTM Untuk Prediksi Pemakaian Obat Rumah Sakit". Hasil penelitian menunjukkan bahwa model Nonpooling CNN-LSTM memiliki RMSE terendah, yaitu 39,635 untuk prediksi 30 hari dan 54,68 untuk prediksi 90 hari, sehingga lebih akurat dibandingkan dengan model CNN-LSTM dan LSTM lainnya. Model ini efektif dalam memprediksi penggunaan obat di rumah sakit, terutama untuk prediksi jangka panjang, dan mampu mengatasi kekurangan Max Pooling yang dapat menghilangkan informasi penting. Selain itu, pengujian menunjukkan bahwa performa model sangat dipengaruhi oleh pemilihan parameter, dan model ini cenderung mengalami overfitting jika parameter terlalu tinggi. Prediksi 30 hari ke depan lebih akurat dibandingkan prediksi 90 hari karena akumulasi error dari data sebelumnya (Nathaniel et al., 2022).

4. Maulana Ichwan Anshory, Yusuf Priyandari dan Yuniaristanto

Pada penelitian yang dilakukan oleh Maulana Ichwan Anshory dan kawan-kawan yang berjudul "Peramalan Penjualan Sediaan Farmasi Menggunakan Long Short Term Memory : Studi Kasus Pada Apotik Suganda". Hasil penelitian menunjukkan bahwa metode Long Short-term Memory (LSTM) dapat digunakan untuk peramalan penjualan sediaan farmasi di Apotek Suganda dan diharapkan mampu meningkatkan akurasi peramalan dibandingkan metode tradisional lainnya. Parameter yang dipilih adalah yang menghasilkan Mean Absolute Percentage Error (MAPE) terkecil, sehingga model LSTM dapat diandalkan untuk mendukung proses pengambilan keputusan dalam pengelolaan persediaan farmasi (Anshory et

al., 2020).

5. Bashaer Abdurahman Mousa dan belal Al-khateeb

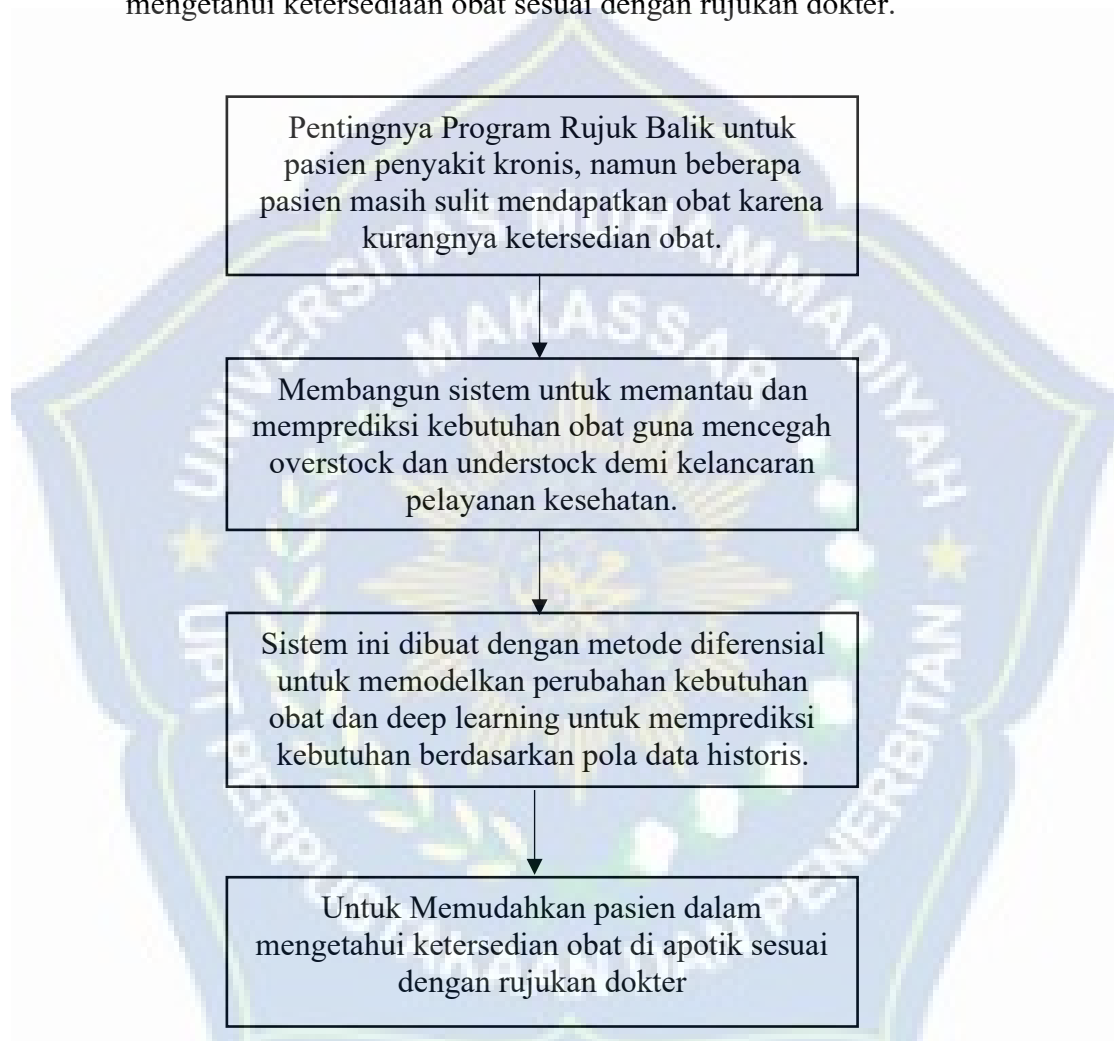
Pada penelitian yang dilakukan oleh Bashaer dan Belal yang berjudul "Predicting Medicine Demand Using Deep Learning Techniques". Hasil penelitian menunjukkan bahwa model deep learning, khususnya Recurrent Neural Network (RNN) dengan tiga lapisan, mencapai performa terbaik dalam memprediksi permintaan obat berdasarkan data deret waktu. Model ini menunjukkan tingkat kesalahan yang rendah, seperti MSE, MAE, dan RMSE, yang mengindikasikan akurasi prediksi yang tinggi. Temuan ini menegaskan efektivitas penggunaan algoritma deep learning dalam pengelolaan inventaris farmasi, membantu mengoptimalkan persediaan, mengurangi limbah dari obat kadaluwarsa, dan memastikan ketersediaan obat bagi pasien. Selain itu, penelitian ini menekankan pentingnya membandingkan berbagai model untuk memilih yang paling akurat dan menyarankan eksplorasi model lain seperti Transformers dan CNN di masa depan (Mousa & Al-khateeb, 2020).

6. Hasil penelitian menunjukkan bahwa model Long Short-Term Memory (LSTM) cukup efektif dalam memprediksi penjualan obat berdasarkan data transaksi pasien BPJS di Indonesia. Model ini mampu memberikan prediksi yang akurat dengan nilai rata-rata kesalahan yang rendah, seperti MSE, MAE, dan RMSE yang menunjukkan performa baik. Meskipun demikian, nilai R^2 yang negatif mengindikasikan bahwa model masih perlu pengembangan lebih lanjut untuk meningkatkan akurasi prediksi. Penelitian ini menegaskan potensi LSTM dalam pengelolaan persediaan obat dan mendukung pengambilan keputusan strategis di sektor kesehatan (Yusuf Syahrul Basyar, 2024).

C. Kerangka Berpikir

Gambar 1 di bawah ini adalah kerangka berpikir yang menggambarkan alur pemikiran penelitian. Kerangka ini disusun untuk menunjukkan

pentingnya Program Rujuk Balik bagi pasien penyakit kronis, tantangan yang dihadapi terkait ketersediaan obat, serta solusi yang ditawarkan melalui pembangunan sistem pemantauan dan prediksi kebutuhan obat dengan metode diferensial dan deep learning. Dengan adanya sistem ini diharapkan dapat membantu kelancaran pelayanan kesehatan serta memudahkan pasien dalam mengetahui ketersediaan obat sesuai dengan rujukan dokter.



Gambar 1 Kerangka Berfikir

BAB III

METODE PENELITIAN

A. Waktu dan Tempat Penelitian

1. Tempat Penelitian

Penelitian ini dilakukan secara luar jaringan dengan mengumpulkan data transaksi penjualan obat kepada pasien BPJS Program Rujuk Balik (PRB).

2. Waktu penelitian

Penelitian ini dilakukan selama bulan Mei – Juli 2025

Tabel 1 Waktu Penelitian

NO	KEGIATAN	MEI				JUNI				JULI			
		I	II	III	IV	I	II	III	IV	I	II	III	IV
1	Studi Literatur												
2	Penyusunan proposal												
3	Pengumpulan Data												
4	Pengolahan Data												
5	Pembuatan Sistem												
6	Pengujian Sistem												
7	Penulisan Laporan Akhir												

B. Alat dan Bahan

1. Kebutuhan Hardware
 - a. Chip Apple M1 dan GPU 8-core
 - b. RAM 8GM & SSD 256GB
2. Kebutuhan Software
 - a. MacOS
 - b. Google Colab
 - c. Excel
 - d. Scikit-Learn
 - e. Python

C. Perancangan Sistem

Flowchart atau diagram alur adalah representasi visual yang menggambarkan urutan langkah-langkah dan Keputusan yang diperlukan untuk menyelesaikan suatu proses dalam program. Setiap langkah digambarkan dalam bentuk diagram dan dihubungkan oleh garis atau panah yang menunjukkan arah aliran proses.

1. Pengumpulan Data

Data diambil dari sistem informasi penjualan obat yang sudah terintegrasi dengan layanan BPJS. Setiap entri data memuat informasi penting terkait obat, seperti:

- a) Nama Obat Untuk Pasien Penyakit Kronis
- b) Harga Satuan
- c) Jumlah Obat Terjual per Bulan
- d) Total Nilai Penjualan per Bulan

Contoh data:

- a) Nama Obat: Paracetamol 500mg
- b) Harga: Rp 1.000
- c) Jumlah Penjualan Januari 2023: 500
- d) Total Penjualan Januari 2023: Rp 500.000

- e) Jumlah Penjualan Juli 2024: 620.000
- f) Total Penjualan Juli 2024: Rp 620.000

Data dikumpulkan secara berkala perbulan untuk masing-masing jenis obat.

2. Preprocessing Data

Sebelum data digunakan dalam model prediksi, dilakukan beberapa tahapan persiapan agar data lebih bersih dan siap analisis:

- a) Konversi ke format time-series, dengan sumbu waktu (bulan) sebagai acuan.
- b) Penanganan data kosong (missing values), misalnya jika ada bulan yang tidak tercatat.
- c) Normalisasi data, agar semua data berada dalam skala yang seragam, menggunakan metode seperti Min-Max Scaling.
- d) Pemisahan fitur dan label, di mana jumlah penjualan menjadi input (fitur), dan nilai penjualan selanjutnya menjadi target (label).

3. Analisis Diferensial

Analisis ini bertujuan untuk menemukan pola perubahan penjualan dari waktu ke waktu. Beberapa metode yang digunakan antara lain:

- a) Menghitung selisih antar bulan (contoh: jumlah bulan Maret - Februari).
- b) Menghitung rasio pertumbuhan bulanan, dengan rumus:
$$\text{Pertumbuhan} = \text{Selisih Jumlah} / \text{Jumlah bulan sebelumnya}$$
- c) Identifikasi pola musiman, seperti kenaikan penjualan menjelang akhir tahun.
- d) Deteksi lonjakan/turunan ekstrem, yang dapat dianggap sebagai outlier atau penyimpangan data.

Contoh hasil analisa (Paracetamol):

- a) Januari ke Februari: Naik 50
- b) Februari ke Maret: Turun 20
- c) April: Terjadi lonjakan penjualan (naik 30%)

4. Pembangunan Model Deep Learning

Model dibuat untuk memprediksi jumlah penjualan pada bulan berikutnya, berdasarkan data historis dan hasil analisa diferensial.

a) Model yang digunakan: LSTM (Long Short-Term Memory), cocok untuk data time-series.

b) Input model:

- o Jumlah penjualan beberapa bulan terakhir
- o Fitur tambahan seperti delta jumlah dan rasio pertumbuhan

c) Output model: Prediksi jumlah penjualan untuk bulan selanjutnya

LSTM mampu "mengingat" pola dari waktu ke waktu, sehingga dapat menangkap tren dan fluktuasi musiman.

5. Evaluasi Model

Setelah model dilatih, kinerjanya diuji menggunakan data aktual dari bulan terakhir. Evaluasi dilakukan menggunakan metrik berikut:

- a) MAE (Mean Absolute Error)
- b) RMSE (Root Mean Square Error)
- c) MAPE (Mean Absolute Percentage Error)

Selain metrik, hasil juga divisualisasikan dalam bentuk:

- a) Grafik prediksi vs nilai aktual per bulan
- b) Distribusi error per jenis obat

6. Visualisasi Hasil

Hasil akhir sistem ditampilkan secara visual melalui grafik dan dashboard yang mudah dipahami, antara lain:


- a) Grafik perbandingan prediksi vs penjualan aktual
- b) Tren obat-obatan dengan penjualan tertinggi
- c) Prediksi kebutuhan stok untuk 3 hingga 6 bulan ke depan
- d) Notifikasi otomatis jika diprediksi terjadi lonjakan permintaan

Visualisasi ini membantu pihak manajemen dalam mengambil keputusan terkait pengadaan dan distribusi obat.

1. Flowchart Penelitian

Pada gambar 2 di bawah ini adalah flowchart penelitian yang menggambarkan tahapan pelaksanaan penelitian mulai dari pengumpulan data hingga evaluasi model. Alur penelitian ini dimulai dengan proses pengumpulan data, dilanjutkan dengan preprocessing untuk mempersiapkan data agar siap digunakan dalam tahap training. Selanjutnya dilakukan proses pelatihan (training) dan implementasi model, kemudian diuji melalui tahap testing. Hasil pengujian selanjutnya digunakan untuk mendukung kesimpulan penelitian agar sesuai dengan tujuan yang telah ditetapkan.






Gambar 2 Flowchart

Pada gambar 2 di atas, Untuk dapat memprediksi penjualan obat secara akurat, dibutuhkan suatu sistem yang mampu mengolah data historis penjualan dan mengenali pola-pola perubahan dari waktu ke waktu. Sistem prediksi ini dirancang untuk membantu rumah sakit, apotek, atau instansi kesehatan dalam merencanakan kebutuhan stok obat berdasarkan data yang telah terkumpul. Dengan memanfaatkan pendekatan analisis data dan model deep learning, sistem ini melalui beberapa tahapan penting proses penelitian dimulai dengan melakukan pengumpulan data, pengumpulan data dilakukan secara offline dari transaksi obat di Kimia Farma Cendrawasi. Pada tahap pra-pemrosesan data, dilakukan langkah-langkah seperti pembersihan data: Menghapus data yang duplikat, menangani data yang hilang, dan memperbaiki inkonsistensi, transformasi data: Mengubah data transaksi menjadi format time series yang

sesuai untuk model LSTM, dan pembagian data: data dibagi menjadi dua bagian, yaitu data latih dan data uji. Selanjutnya training, data yang telah dilatih digunakan untuk melatih model LSTM agar dapat mengenali pola permintaan obat, lalu implementasi model untuk menentukan arsitektur jaringan LSTM seperti jumlah lapisan dan unit LSTM, kemudian menetapkan parameter seperti learning rate, batch size, dan epoch dan melatih model LSTM menggunakan data pelatihan. Selanjutnya evaluasi model dengan menghitung matrik untuk mengevaluasi akurasi prediksi model. Kemudian hasil yang dikeluarkan yaitu hasil akurasi prediksi dari model LSTM. Terakhir penarikan kesimpulan dilakukan berdasarkan hasil analisis yang telah dilakukan.

Pada gambar 3 di bawah ini adalah flowchart proses pelatihan model LSTM yang menggambarkan tahapan mulai dari persiapan data hingga penyimpanan model. Alur ini menjelaskan langkah-langkah pengolahan data, perhitungan analisis diferensial, penentuan parameter pelatihan, hingga proses training dengan fungsi aktivasi tertentu. Selanjutnya dilakukan evaluasi akurasi, dan apabila hasilnya meningkat maka model disimpan, sedangkan jika belum tercapai dilakukan pengulangan hingga batas epoch yang ditentukan.



Gambar 3 Flowchart LSTM

Pada Gambar 3 di atas, alur kerja model LSTM diawali dengan memasukkan data sebagai input, kemudian dilanjutkan dengan memuat model LSTM. Setelah itu, dilakukan proses aktivasi menggunakan fungsi ReLU untuk menambahkan elemen non-linearitas pada model. Tahap berikutnya adalah pelatihan model menggunakan data latih guna melakukan prediksi. Setelah prediksi dilakukan, fungsi aktivasi Softmax diterapkan pada lapisan output untuk menghasilkan probabilitas dari hasil prediksi.

Selanjutnya, model dievaluasi menggunakan data uji dengan menghitung metrik kinerja seperti Mean Squared Error (MSE), Mean Absolute Error (MAE), dan Root Mean Squared Error (RMSE). Hasil akhir dari proses ini berupa output prediksi dari model LSTM.

D. Teknik Pengujian Sistem

Dalam penelitian ini, teknik pengujian sistem dilakukan dengan menguji performa model Long Short-Term Memory (LSTM) dalam memprediksi penjualan obat berdasarkan data transaksi pasien BPJS. Proses pengujian mencakup beberapa tahap penting yang bertujuan untuk mengevaluasi seberapa efektif dan akurat model LSTM dalam melakukan prediksi penjualan.

Pengujian dilakukan dengan pembagian data transaksi obat menjadi dua bagian: 80% sebagai data latih dan 20% sebagai data uji. Model LSTM dilatih menggunakan data latih ini dengan parameter yang telah ditentukan seperti learning rate, batch size, dan epoch. Setelah model dilatih, prediksi dilakukan terhadap data uji. Untuk mengevaluasi akurasi dan efektivitas model LSTM, beberapa metrik evaluasi digunakan, termasuk Mean Squared Error (MSE), Mean Absolute Error (MAE), Root Mean Squared Error (RMSE). Setelah evaluasi model LSTM, hasilnya berupa nilai kesalahan terkecil untuk memastikan bahwa model LSTM memberikan hasil yang optimal.

E. Teknik Analisis Data

Analisis data adalah suatu proses yang dilakukan secara sistematis dengan tujuan untuk mengelola dan memahami informasi yang diperoleh dari

wawancara, observasi, serta dokumentasi. Proses ini melibatkan pengelompokan data ke dalam kategori tertentu, pemecahan data menjadi bagian-bagian kecil, penyusunan ulang informasi (sistesis), pengenalan pola-pola, pemilihan data yang relevan, dan penarikan kesimpulan. Tujuan utama dari analisis data adalah untuk memudahkan pemahaman terhadap informasi yang dikumpulkan, baik oleh peneliti sendiri maupun oleh pihak lain yang akan membaca hasil penelitian. Agar memperoleh hasil yang maksimal, peneliti perlu melalui beberapa tahapan dalam proses analisis data.

1. Pengumpulan Data:

Proses pengumpulan data melibatkan pengambilan informasi yang bersumber dari data historis dari transaksi obat di PT Kimia Farma Apotek (KFA) yang mencakup beberapa jenis data yaitu: Nama Pasien, No. Keanggotaan BPJS, No. SEP, No. Transaksi, No. Resep, Tanggal Pelayanan, Nama Obat, Kode SAP, Qty, HNA, Harga, dan Nama Penjamin.

2. Preprocessing:

Langkah selanjutnya adalah persiapan data untuk tahap pengolahan. Dalam penelitian ini, proses preprocessing melibatkan beberapa langkah penting seperti menghapus duplikasi, menangani data yang hilang, memperbaiki inkonsistensi data, Konversi data transaksi menjadi format time series, dan membagi data menjadi set pelatihan dan set pengujian.

3. Penyajian Data:

Peneliti menyajikan data yang telah direduksi secara sistematis dan terstruktur. Tujuan penyajian ini adalah untuk memudahkan pemahaman informasi yang terkandung dalam data.

4. Kesimpulan:

Peneliti menyajikan kesimpulan berdasarkan data yang telah dianalisis, dengan tujuan memberikan jawaban terhadap permasalahan yang diteliti. Apotik sebagai end user dari penelitian ini tetapi permintaan pasien sebagai inputan sistemnya.

BAB IV

HASIL DAN PEMBAHASAN

A. Pengambilan Data

Pengambilan data transaksi pasien BPJS dalam penelitian ini dilakukan melalui sistem manajemen Apotek Kimia Farma Cendrawasih dengan menggunakan basis data internal apotek. Data yang dikumpulkan mencakup detail lengkap dari setiap transaksi penjualan obat pasien BPJS, seperti nomor transaksi, nama pasien, tanggal transaksi, jenis dan jumlah obat, serta total biaya yang dibayarkan. Data ini diambil untuk periode Januari 2022 hingga Juli 2024, guna memberikan gambaran tren penjualan obat yang representatif dalam rentang waktu tersebut.

Gambar 4 di bawah ini menunjukkan Ilustrasi proses pengambilan data, yang menampilkan alur ekstraksi data dari sistem manajemen apotek.

POS frontend

pos.kimiafarma.co.id/report/insurance_payment?utf8=/&insurer_id=22689&member_no=&start_time=2023-01-01&end_time=2023-12-31

Total Pembayaran dari periode 01 Januari 2023 s/d 31 Desember 2023

Rp. 1.586.867.500

BRUS KESIHATAN MAKASSAR PASIEN RILUK BAUK

Rp. 1.586.867.500

No. Transaksi	No. Resep	Tgl L RN	Nama Pasien	Kode SAP	Nama Obat	Qty	URA	Harga/Obat	Entalase	Total Harga	Total/Ruanggung	Pdt RS	
11111110272191724	367280317/31122022	19091629	31-12-2022	SUGI NIKUNG	13003208	AMLODIPINE 10MG TAB(100 GRAM BROS)	30	Rp. 98	Rp. 117	0 Rp.	23.190 Rp.	23.190	Sehatku Jantung Dan Pembuluh Dar
					12003808	METFORMIN TAB 500 MG (3000 TAB) (HEXA)	90	Rp. 275	Rp. 227	0 Rp.	24.750 Rp.	24.750	Pain Tansulasi
11111110272191724	367280317/31122022	19091629	31-12-2022	MUH. ILHAM MUBARAK ARIF	13003800	DIKAPOTE ER 100MG TAB(100)	60	Rp. 17.289	Rp. 1.925	0 Rp.	1.037.250 Rp.	1.037.250	Pain Tansulasi
					11001572	VITAMIN B1 100MG TAB(SULA) (DUS100 TAB) (BUN)	30	Rp. 4	Rp. 124	0 Rp.	1.19.220 Rp.	1.19.220	Pain Tansulasi
					12003806	METFORMIN TAB 500 MG (3000 TAB) (HEXA)	60	Rp. 275	Rp. 227	0 Rp.	24.750 Rp.	24.750	Pain Tansulasi
11111110272191724	367280317/31122022	19091629	31-12-2022	HJ. DUDARMAE	13003221	LANTUS SOLICOSTER PEN INJUS	2	Rp. 80.909	Rp. 161.818	0 Rp.	243.116 Rp.	243.116	Pain Tansulasi
					11001571	VITAMIN B KOMPLEKS (SPLANT) (DUS100 TAB) (BUN)	30	Rp. 182	Rp. 369	0 Rp.	23.190 Rp.	23.190	Pain Tansulasi
					13007608	RAMPRIL 5MG TAB(100 DEX) (BUN)	30	Rp. 635	Rp. 255	0 Rp.	23.190 Rp.	23.190	Pain Tansulasi
11111110272191724	367280317/31122022	19091629	31-12-2022	JUHARUS HADEE	Y3000029	HERBESSEER CD 100MG CAP(400B) (BUN)	30	Rp. 5.241	Rp. 7.444	0 Rp.	23.190 Rp.	23.190	Pain Tansulasi
					11001571	VITAMIN B KOMPLEKS (SPLANT) (DUS100 TAB) (BUN)	30	Rp. 182	Rp. 369	0 Rp.	23.190 Rp.	23.190	Pain Tansulasi
					11001499	AMLODIPINE 10 MG (DUS 50 TAB) (BUN)	30	Rp. 300	Rp. 117	0 Rp.	23.190 Rp.	23.190	Pain Tansulasi
					11001571	VITAMIN B KOMPLEKS (SPLANT) (DUS100 TAB) (BUN)	30	Rp. 182	Rp. 369	0 Rp.	23.190 Rp.	23.190	Pain Tansulasi
					11001488	AMLODIPINE 5 MG (DUS 50 TAB) (BUN)	30	Rp. 375	Rp. 88	0 Rp.	23.190 Rp.	23.190	Pain Tansulasi
					13007602	SANIKASITEN 10MG TAB(100 GRAM BROS)	30	Rp. 350	Rp. 157	0 Rp.	23.190 Rp.	23.190	Pain Tansulasi

Gambar 4 Pengambilan Data

Setelah melakukan pengambilan data transaksi pasien BPJS dari system manajemen apotik, kemudian hasilnya disimpan dalam format excel.

[illegible]

The screenshot shows a data table with the following columns (from left to right):

- Transaction ID (e.g., 10267012, 10267014, 10267015, etc.)
- Date (e.g., 2023/05/12, 2023/05/13, 2023/05/14, etc.)
- Time (e.g., 10:00:00, 10:01:00, 10:02:00, etc.)
- Location (e.g., LAMPUNG, LAMPUNG, LAMPUNG, etc.)
- Amount (e.g., 1000000, 1000000, 1000000, etc.)
- Status (e.g., Success, Success, Success, etc.)
- Transaction Type (e.g., Transaksi, Transaksi, Transaksi, etc.)

The table is displayed in a software application with a search bar at the top and a status bar at the bottom. The status bar shows "Ready" and "Accessibility: Investigate".

B. Preprocessing Data

Tahap Pra-pemrosesan Data merupakan langkah krusial dalam menyiapkan dan membersihkan data mentah agar layak digunakan dalam proses analisis. Prosedur ini dilakukan secara manual dan melibatkan serangkaian langkah untuk memastikan bahwa data berada dalam kondisi yang sesuai dan siap untuk dianalisis lebih lanjut.

Berikut Langkah – Langkah dalam *Preprocessing Data*:

1. *Cleaning* (Pembersihan)


Tahap pembersihan data merupakan langkah penting dalam proses pengolahan data, yang bertujuan untuk memastikan bahwa data yang digunakan memiliki kualitas yang baik dan dapat diandalkan. Pada tahap ini, dilakukan serangkaian pemeriksaan untuk mendeteksi inkonsistensi, duplikasi, atau kesalahan dalam data. Data yang tidak lengkap,

Gambar 6 di bawah ini menunjukkan data mentah yang diperoleh sebelum dilakukan proses pembersihan (data cleaning). Terlihat bahwa masih terdapat data kosong, data yang duplikat, serta format data yang tidak konsisten. Kondisi ini dapat mengganggu proses analisis maupun pemodelan karena data yang tidak valid atau redundan akan menghasilkan perhitungan yang kurang akurat. Oleh karena itu, diperlukan tahap cleaning untuk memperbaiki kualitas data.

[illegible]

Gambar 6 Tabel sebelum cleaning

Gambar 7 di bawah ini menampilkan hasil data setelah melalui proses cleaning. Pada tahap ini, data kosong telah dihapus, data ganda (duplikat) sudah dihilangkan, serta format data telah disesuaikan agar lebih rapi dan konsisten. Dengan demikian, dataset menjadi lebih bersih, valid, dan siap digunakan untuk tahap preprocessing selanjutnya, seperti normalisasi, pembentukan fitur, maupun pemodelan.



A	B	C	D	E	F	G	H	I	J	K	L
Tgl LUPH	Kode SAP	Nama Obat	Qty	HNA	Harga/Obat (Rp.)	Embalase (Rp.)	Total/Harga (Rp.)	Total Ditanggung (Rp.)			
31/12/2023	13085206	AMLODIPINE 10MG TAB@100 GSAM BPJS	30	96	117.0	0	23940	23940.0			
	12005556	METFORMIN TAB 500 MG @200 TAB (HEXA)	90	275	227.0	0	119220	119220.0			
31/12/2023	13078390	DEPAKOTE ER 500MG TAB@100	60	17289	1925.0	0	243116	243116.0			
	11001572	VITAMIN B1 100MG TAB(SUPLI)(DUS100TAB)-BIN	30	0	124.0	0					
31/12/2023	12005556	METFORMIN TAB 500 MG @200 TAB (HEXA)	60	275	227.0	0	243116	243116.0			
	13000221	LANTUS SOLOSTER PEN BPJS	2	80909	113158.0	0					
	11001571	VITAMIN B KOMPLEKS(SPLMN)(DUS100TAB)-BIN	30	182	106.0	0					
31/12/2023	13027608	RAMIPRIL 5MG TAB@100 GDX BPJS	30	635	225.0	0	233250	233250.0			
	13000023	HERBESSER CD 100MG CAP@100BPJS	30	5241	7444.0	0					
	11001571	VITAMIN B KOMPLEKS(SPLMN)(DUS100TAB)-BIN	30	182	106.0	0					
31/12/2023	11001449	AMLODIPINE 10 MG (DUS 50 TAB)-BIN	30	300	117.0	0	6690	6690.0			
	11001571	VITAMIN B KOMPLEKS(SPLMN)(DUS100TAB)-BIN	30	182	106.0	0					
31/12/2023	11001448	AMLODIPINE 5 MG (DUS 50 TAB)-BIN	30	270	88.0	0	28200	28200.0			
	13067052	SIMVASTATIN 10MG TAB@100 GHX BPJS	30	350	157.0	0					
	11001571	VITAMIN B KOMPLEKS(SPLMN)(DUS100TAB)-BIN	30	182	106.0	0					
	12005556	METFORMIN TAB 500 MG @200 TAB (HEXA)	60	275	227.0	0					
	12005739	ISOSORBID DINITRAT 5 MG (YARIN)	30	295	135.0	0					
31/12/2023	13000576	INSULIN NOVOMIX FLEXPEN30 BPJS	5	100880	142401.0	0	722115	722115.0			
	13087281	BISOPROLOL 2.5MG TAB@100 GHX BPJS	30	550	180.0	0					
	13067052	SIMVASTATIN 10MG TAB@100 GHX BPJS	30	350	157.0	0					
31/12/2023	13000508	CANDESARTAN 8MG TAB GDX BPJS	30	284	419.0	0	12570	12570.0			
31/12/2023	13027608	RAMIPRIL 5MG TAB@100 GDX BPJS	30	635	225.0	0	14640	14640.0			
	13067052	SIMVASTATIN 10MG TAB@100 GHX BPJS	30	350	157.0	0					
	11001571	VITAMIN B KOMPLEKS(SPLMN)(DUS100TAB)-BIN	30	182	106.0	0					
31/12/2023	12005556	METFORMIN TAB 500 MG @200 TAB (HEXA)	90	275	227.0	0	36030	36030.0			
	13087291	GLIMEPIRIDE 2MG TAB@100 GHX BPJS	30	950	257.0	0					

Gambar 7 Tahap Setelah Cleaning

2. Transformasi Data

Tahap transformasi data merupakan proses penting dalam mengolah data mentah agar menjadi format yang lebih terstruktur dan sesuai untuk keperluan analisis atau pemodelan, terutama dalam penerapan Machine Learning seperti LSTM. Dalam penelitian ini, proses transformasi mencakup penyusunan data deret waktu (time series) dengan cara mengelompokkan data menjadi input dan target yang akan digunakan dalam pelatihan model prediktif. Transformasi ini bertujuan untuk menangkap pola

historis dalam data sehingga model dapat melakukan prediksi secara lebih akurat.

Gambar 8 di bawah ini memperlihatkan hasil dari proses transformasi data yang telah dilakukan. Data mentah yang sebelumnya belum terstruktur diubah menjadi bentuk yang lebih terorganisir, khususnya dalam format deret waktu (time series). Setiap baris data merepresentasikan urutan waktu tertentu dengan variabel-variabel yang sudah dipisahkan sesuai kebutuhan analisis. Dengan adanya transformasi ini, data menjadi lebih siap digunakan sebagai input dan target pada tahap pelatihan model LSTM. Hasil transformasi ini memungkinkan model untuk menangkap pola historis pada data sehingga dapat meningkatkan akurasi dalam melakukan prediksi.

Kode Obat	Nama Obat	January 2022				February 2022			
		Total Terjual	Total Permintaan	Rata-rata Harian	Selisih Bulanan	Total Terjual	Total Permintaan	Rata-rata Harian	Selisih Bulanan
11000006	ALERGON 10 MG TABLET SALUT SELAPUT	0	0	0	0	0	0	0	0
11000014	ALAM MIFENAMAR 500 MG (DUS 100 TAB)	0	0	0	0	0	0	0	0
11000072	GUMIFRIDE 5 MG (DUS 100 TAB)	0	0	0	0	0	0	0	0
11000073	GUMIFRIDE 1 MG (DUS 50 TAB)	90	10980	3	0	0	0	0	0
11000074	GUMIFRIDE 2 MG (DUS 50 TAB)	30	3660	1	0	0	0	0	0
11000075	GUMIFRIDE 3 MG (DUS 50 TAB)	0	0	0	0	0	0	0	0
11000076	GUMIFRIDE 4 MG (DUS 50 TAB)	60	7180	2	0	60	7180	2	0
11000113	HYDROXY RETARD KAPSA (100)	360	887040	12	0	210	443520	7	150
11000113	HYDROXY RETARD KAPSA (DUS 100 KPS)	0	0	0	0	0	0	0	0
11000147	AMOROXOL 30 MG (DUS 100 TAB)	0	0	0	0	0	0	0	0
11000150	AMGLOPRIME 5 MG (DUS 50 TAB)	2760	214320	92	0	3060	232560	102	800
11000151	AMGLOPRIME 10 MG (DUS 50 TAB)	8840	372480	128	0	1800	174600	60	2040
11000171	CLOROCOLINE 75 MG (DUS 100 TAB)	90	27900	3	0	0	0	0	0
11000187	DILTIAZEM 30 MG (DUS 100 TAB)	0	0	0	0	0	0	0	0
11000200	FURONITAZOL 40 MG (DUS 100 TAB)	165	24090	5,5	0	135	19710	6,5	-30
11000204	HYDROXYDROTHIAZIDE 25 MG (DUS 100 TAB)	0	0	0	0	0	0	0	0
11000204	HYDROXYDROTHIAZIDE 25 MG (DUS 100 TAB)	0	0	0	0	0	0	0	0
11000217	LEVOTILDIAZEM 500 MG (DUS 50 TAB)	0	0	0	0	0	0	0	0
11000227	NIFEDIPINE 10 MG (DUS 100 TAB)	0	0	0	0	0	42710	1	0
11000258	SALURITAMOL 1 MG (DUS 100 TAB)	0	0	0	0	90	6120	3	0
11000284	MINOXIDIL 20 MG (DUS 50 TAB)	30	2760	1	0	60	5580	2	30
11000286	MINOXIDIL 20 MG (DUS 50 TAB)	60	12660	2	0	150	46310	5	90
11000275	VITAMIN B12 100 MG (DUS 100 TAB)	-30	2400	-1	0	0	0	0	0
11000424	CAPTOPRIL 25 MG (DUS 100 TAB)	0	0	0	0	-30	2880	-1	0
11000485	VITAMIN B12 50 MG (SUPLEMEN)(DUS 100 TAB)	0	0	0	0	0	0	0	0
11000486	VITAMIN B6 20 MG (SUPLEMEN)(DUS 100 TAB)	0	0	0	0	0	0	0	0
11000487	VITAMIN B12 100 MG (SUPLEMEN)(DUS 100 TAB)	30	2910	1	0	0	0	0	0
11000488	VITAMIN B6 50 MG (SUPLEMEN)(DUS 100 TAB)	0	0	0	0	30	7200	1	-30
11001445	ALLOPURINOL 100 MG (DUS 100 TAB) - BIN	0	0	0	0	0	0	0	0
11001448	AMGLOPRIME 5 MG (DUS 50 TAB) - BIN	0	0	0	0	0	0	0	0
11001449	AMGLOPRIME 10 MG (DUS 50 TAB) - BIN	0	0	0	0	0	0	0	0
11001461	CAPTOPRIL 25 MG (DUS 100 TAB) - BIN	0	0	0	0	0	0	0	0
11001460	CLONIDINE 0,15 MG (DUS 100 TAB) - BIN	0	0	0	0	0	0	0	0
11001470	CLOROCOLINE 75 MG (DUS 100 TAB) - BIN	0	0	0	0	0	0	0	0
11001491	FUROSEMIDE 40 MG (DUS 100 TAB) - BIN	0	0	0	0	0	0	0	0
11001499	HYDROXYDROTHIAZIDE 25 MG (DUS 100 TAB) - BIN	0	0	0	0	0	0	0	0

Gambar 8 Hasil Transformasi Data

C. Penerapan Analisis Difrensial

Dalam tahap awal analisis, data penjualan obat BPJS PRB diformat ulang dari file Excel berjudul *rekap_bulanan_spacer_kecil (2).xlsx* yang memiliki

struktur multi-level kolom (header dua tingkat). Struktur seperti ini umum ditemui pada laporan rekap otomatis dari sistem informasi manajemen farmasi. Oleh karena itu, langkah pertama dalam program adalah menyatukan kedua header menjadi satu nama kolom yang lebih mudah dikelola. Misalnya, kolom yang semula terbagi menjadi (“Total Terjual”, “Januari”) akan digabung menjadi “Total Terjual_Januari”. Setelah itu, hanya kolom yang relevan — yaitu Kode Obat, Nama Obat, dan seluruh kolom Total Terjual — yang diekstrak menjadi satu DataFrame baru untuk dianalisis.

Secara matematis, pendekatan diferensial diskrit yang digunakan dalam analisis ini dapat dituliskan sebagai berikut:

- Turunan pertama (delta 1 / kecepatan perubahan):

$$\Delta_1(t) = x_t - x_{t-1} \dots\dots\dots (10)$$

- Turunan kedua (delta 2 / percepatan perubahan):

$$\Delta_2(t) = \Delta_1(t) - \Delta_1(t - 1) = (x_t - x_{t-1}) - (x_{t-1} - x_{t-2}) \dots\dots\dots (11)$$

di mana x_{t_txt} adalah jumlah penjualan pada waktu t , yang bisa merepresentasikan bulan ke- t atau urutan pengamatan. Model ini membantu untuk melihat tidak hanya besar perubahan penjualan dari waktu ke waktu, tetapi juga pola akselerasinya, apakah tren meningkat, melambat, atau stagnan.

Sebagai ilustrasi, dapat dilihat dari salah satu baris sampel berikut yang mewakili data obat dengan kode **13005137** dan nama **ACARBOSE 50MG TAB@100 GDX**. Nilai total terjual dari obat ini pada berbagai bulan terlihat berfluktuasi, seperti: 90, 0, 0, ..., dan seterusnya. Setelah dilakukan proses diferensial tingkat pertama (Δ_1), misalnya antara bulan 1 dan bulan 2, perubahannya menjadi **90 - 0 = 90**; meskipun angka ini tampak besar, hal ini

terjadi karena data disusun secara berurutan dari beberapa sub-kolom (misalnya kuantitas, nilai rupiah, jumlah resep, dsb) dan bukan angka bulanan tunggal. Turunan diferensial kedua (Δ_2) kemudian menghitung perbedaan dari hasil delta pertama, misalnya: jika perubahan sebelumnya adalah +30 dan sekarang -30, maka $\Delta_2 = -60$. Ketiga jenis data ini (Original, Delta_1, Delta_2) digabung dan disimpan menjadi satu file baru yang akan digunakan pada proses pelatihan model prediksi berbasis deep learning. Pendekatan ini bertujuan agar model tidak hanya belajar dari nilai penjualan aktual, namun juga dari kecenderungan perubahan dan percepatannya.

D. Proses dan Hasil dari Analisis Diferensial

Setelah proses transformasi kolom dan pemisahan data total penjualan dilakukan, analisis diferensial diterapkan untuk mengetahui pola perubahan penjualan dari waktu ke waktu. Pada tahap ini, program Python menghitung dua bentuk diferensial diskrit: Δ_1 (delta satu) sebagai turunan pertama dan Δ_2 (delta dua) sebagai turunan kedua. Perhitungan dilakukan terhadap kolom-kolom penjualan obat yang disusun dalam bentuk urutan waktu (berdasarkan bulan dan kategori transaksi seperti jumlah unit, nominal rupiah, atau resep). Proses `.diff(axis=1)` secara otomatis menghitung selisih antar kolom waktu yang berdekatan dalam satu baris (obat).

Sebagai contoh nyata dari baris data untuk obat ACARBOSE 50MG TAB@100 GDX (kode 13005137), proses perhitungan diferensial (Δ) dapat dijelaskan sebagai berikut:

Data awal (Original) untuk tiga bulan pertama adalah:

- Bulan 1: 90
- Bulan 2: 0
- Bulan 3: 0

$\Delta 1$ (Perubahan Pertama):

- $\Delta 1_1 = \text{Bulan 2} - \text{Bulan 1} = 0 - 90 = -90$
- $\Delta 1_2 = \text{Bulan 3} - \text{Bulan 2} = 0 - 0 = 0$

$\Delta 2$ (Perubahan Kedua):

- $\Delta 2_1 = \Delta 1_2 - \Delta 1_1 = 0 - (-90) = 90$

Nilai-nilai ini tampak ekstrem karena data disusun berdasarkan urutan atribut dalam satu bulan (jumlah unit, rupiah, resep), bukan per bulan secara terpisah. Meskipun demikian, pola fluktuasi ini tetap dapat digunakan oleh model machine learning untuk mengenali pola lonjakan atau penurunan yang tajam, terutama pada kasus lonjakan pembelian (restok) atau penghentian sementara penggunaan obat PRB.

Output hasil akhir dari analisis ini berupa sebuah file Excel baru berjudul `output_differensial_diskrit.xlsx` yang berisi tiga versi data:

1. Original – data aktual penjualan
2. Delta_1 – hasil perubahan antar waktu (turunan pertama)
3. Delta_2 – hasil perubahan antar Delta_1 (turunan kedua)

File ini menjadi pondasi utama dalam pelatihan model prediksi, di mana setiap baris mewakili satu obat dengan jejak historis pola pergerakan nilai transaksi dari waktu ke waktu dalam tiga perspektif: nilai absolut, kecepatan perubahan, dan percepatannya.

Gambar 9 di bawah ini menampilkan hasil perhitungan analisis diferensial pada data penjualan obat. Analisis diferensial dilakukan untuk mengetahui perubahan jumlah kebutuhan obat dari waktu ke waktu (delta). Hasil ini

nantinya akan digunakan sebagai input dalam proses pemodelan agar sistem dapat mengenali pola perubahan kebutuhan obat secara historis.

Kode Obat	Nama Obat	March 2024_Total Terju	May 2024_Total Terju	June 2024_Total Terju	July 2024_Total Terju	Jenis
11002397	ACARBOSE 100 MG (DUS 100 TAB)	240	240	90	90	Original
11002397	ACARBOSE 100 MG (DUS 100 TAB)	-90	0	-150	0	Delta_1
11002397	ACARBOSE 100 MG (DUS 100 TAB)	-90	30	-150	150	Delta_2
13000087	ACARBOSE 100MG TAB@100 BPJS	0	0	45	90	Original
13000087	ACARBOSE 100MG TAB@100 BPJS	0	0	45	45	Delta_1
13000087	ACARBOSE 100MG TAB@100 BPJS	0	0	45	0	Delta_2
13005138	ACARBOSE 100MG TAB@100 GDK	0	0	0	0	Original
13005138	ACARBOSE 100MG TAB@100 GDK	0	0	0	0	Delta_1
13005138	ACARBOSE 100MG TAB@100 GDK	0	0	0	0	Delta_2
11002396	ACARBOSE 50 MG (DUS 100 TAB)	330	180	210	0	Original
11002396	ACARBOSE 50 MG (DUS 100 TAB)	90	-150	30	-210	Delta_1

Gambar 9 Output dari Hasil Proses Analisis Diferensial

Langkah 3: Membagi Model untuk Masing-masing Obat dan Alasannya

Dalam proses pengembangan model prediksi penjualan, pendekatan yang digunakan adalah memisahkan pelatihan model berdasarkan kode obat. Hal ini dilakukan karena pola penjualan setiap obat dalam program BPJS PRB cenderung unik dan tidak seragam, tergantung pada tingkat kebutuhan pasien, penyakit yang ditangani, serta stok yang tersedia di fasilitas layanan. Oleh karena itu, alih-alih membangun satu model umum untuk seluruh obat, dilakukan pendekatan per-obat, di mana setiap kode obat akan memiliki model LSTM (Long Short-Term Memory) tersendiri yang dilatih secara independen.

Program melakukan iterasi terhadap seluruh daftar kode obat unik pada dataset hasil analisis diferensial. Untuk setiap kode obat, akan dipilih data yang terdiri dari tiga baris: Original, Delta_1, dan Delta_2. Jika ketiga jenis data ini tidak tersedia secara lengkap, maka proses pelatihan untuk obat tersebut dilewati. Pemisahan ini penting untuk memastikan bahwa setiap model mendapatkan konteks historis yang sama dari segi nilai aktual, kecepatan, dan percepatan penjualan, sehingga model tidak salah menangkap sinyal atau tren musiman. Dengan demikian, model per-obat lebih adaptif dan relevan terhadap pola khas penjualan masing-masing item.

E. Proses Latihan Model dan Peran Data Diferensial (Original, Delta_1, Delta_2)

Untuk membangun model prediksi, data Original, Delta_1, dan Delta_2 disatukan dalam satu array tiga dimensi. Setiap baris data bulanan dari obat direpresentasikan sebagai vektor tiga elemen: $[x(t), \Delta 1(t), \Delta 2(t)]$, yang masing-masing merepresentasikan nilai penjualan aktual, perubahan penjualan antar waktu, dan perubahan dari perubahan (percepatan). Data ini kemudian dinormalisasi menggunakan MinMaxScaler agar seluruh nilai berada dalam skala yang seragam, penting untuk stabilitas dan konvergensi model LSTM.

Dalam konteks ini, peran masing-masing elemen adalah sebagai berikut:

- Original: menunjukkan nilai real dari total penjualan. Ini adalah target utama yang ingin diprediksi di masa depan.
- Delta_1: memberikan konteks terhadap dinamika atau arah tren penjualan. Jika nilai positif, berarti penjualan naik; jika negatif, berarti penjualan menurun.
- Delta_2: menandai perubahan terhadap kecepatan tren, apakah tren naik tersebut makin cepat, makin lambat, atau mulai menurun. Ini penting untuk mengantisipasi perubahan mendadak atau transisi pola.

Model LSTM kemudian dilatih dengan sliding window sepanjang 3 time step, artinya model belajar memprediksi kondisi penjualan bulan ke-4 berdasarkan pola 3 bulan sebelumnya. Untuk setiap obat yang memiliki data cukup panjang dan tidak seluruhnya nol, proses pelatihan dijalankan selama 50 epoch. Model hasil pelatihan disimpan ke dalam folder saved_models dengan nama berdasarkan kode obat, misalnya model_13005137.h5.

Gambar 10 di bawah ini memperlihatkan proses training model untuk setiap obat berdasarkan dataset yang sudah melalui tahap analisis diferensial. Selama proses pelatihan, model mempelajari pola data historis dengan parameter yang sudah ditentukan. Setelah pelatihan selesai, model disimpan

[illegible]

Dengan menyatukan data original dan dua bentuk diferensial, model tidak hanya belajar dari apa yang terjadi, tetapi juga bagaimana dan seberapa cepat perubahan tersebut terjadi, sehingga prediksi yang dihasilkan diharapkan lebih sensitif terhadap tren, anomali, maupun

F. Time Step yang Diambil dan Penanganan Data Nol

Dalam pemodelan time series menggunakan jaringan saraf seperti LSTM, pendekatan umum yang digunakan adalah menyusun data input dalam bentuk jendela waktu atau sliding window. Pada penelitian ini, digunakan panjang window sebanyak 3 langkah waktu (time steps), yang artinya model mempelajari tiga titik waktu berturut-turut untuk memprediksi titik waktu keempat. Setiap jendela terdiri dari tiga baris data historis (dalam bentuk: original, delta_1, dan delta_2), dan setiap baris mencakup tiga fitur: nilai aktual, kecepatan perubahan, dan percepatan. Dengan struktur input seperti ini, model dapat mengamati dinamika pergerakan penjualan dengan lebih kontekstual, bukan hanya dari nilai absolut, namun juga kecenderungan arah dan akselerasinya.

F. Time Step yang Diambil dan Penanganan Data Nol

Dalam pemodelan time series menggunakan jaringan saraf seperti LSTM, pendekatan umum yang digunakan adalah menyusun data input dalam bentuk jendela waktu atau sliding window. Pada penelitian ini, digunakan panjang window sebanyak 3 langkah waktu (time steps), yang artinya model mempelajari tiga titik waktu berturut-turut untuk memprediksi titik waktu keempat. Setiap jendela terdiri dari tiga baris data historis (dalam bentuk: original, delta_1, dan delta_2), dan setiap baris mencakup tiga fitur: nilai aktual, kecepatan perubahan, dan percepatan. Dengan struktur input seperti ini, model dapat mengamati dinamika pergerakan penjualan dengan lebih kontekstual, bukan hanya dari nilai absolut, namun juga kecenderungan arah dan akselerasinya.

Dalam pemodelan time series menggunakan jaringan saraf seperti LSTM, pendekatan umum yang digunakan adalah menyusun data input dalam bentuk jendela waktu atau sliding window. Pada penelitian ini, digunakan panjang window sebanyak 3 langkah waktu (time steps), yang artinya model mempelajari tiga titik waktu berturut-turut untuk memprediksi titik waktu keempat. Setiap jendela terdiri dari tiga baris data historis (dalam bentuk: original, delta_1, dan delta_2), dan setiap baris mencakup tiga fitur: nilai aktual, kecepatan perubahan, dan percepatan. Dengan struktur input seperti ini, model dapat mengamati dinamika pergerakan penjualan dengan lebih kontekstual, bukan hanya dari nilai absolut, namun juga kecenderungan arah dan akselerasinya.

Namun, dalam proses penyusunan input data ke dalam jendela-jendela time series tersebut, terdapat tantangan berupa banyaknya nilai nol (0) dalam data historis, khususnya untuk obat-obatan yang jarang ditebus atau hanya tersedia dalam bulan-bulan tertentu. Untuk menghindari distorsi dalam

pelatihan model, digunakan aturan penyaringan di mana jendela yang seluruh elemennya nol — baik pada input (window) maupun target prediksi — akan dilewati dan tidak digunakan dalam pelatihan. Hal ini dikontrol melalui kondisi:

```
if np.all(window == 0) or target == 0:  
    continue
```

Dengan demikian, hanya jendela yang memuat aktivitas penjualan yang bermakna (bukan nol total) yang digunakan untuk melatih model. Strategi ini membantu mengurangi overfitting terhadap data stagnan, serta meningkatkan sensitivitas model terhadap tren nyata dalam pergerakan penjualan. Akibat dari penyaringan ini, beberapa obat dengan riwayat penjualan sangat jarang atau tidak aktif akan secara otomatis dilewati karena tidak memenuhi syarat minimum data yang cukup untuk pelatihan.

Gambar 11 di bawah ini menunjukkan hasil berupa kumpulan model prediksi yang telah berhasil dilatih dan diekspor. Setiap file model merepresentasikan satu obat tertentu, sehingga sistem mampu melakukan prediksi kebutuhan obat secara spesifik berdasarkan pola data obat tersebut. Penyimpanan model dalam jumlah banyak ini memudahkan pengelolaan dan implementasi prediksi pada obat yang berbeda.


model_11000000.5 model_11001489.5 model_11002968.5 model_11004447.5 model_11005926.5 model_11007405.5 model_11008884.5 model_11010363.5 model_11011842.5 model_11013321.5 model_11014800.5 model_11016279.5 model_11017758.5 model_11019237.5 model_11020716.5 model_11022195.5 model_11023674.5 model_11025153.5 model_11026632.5 model_11028111.5 model_11029590.5 model_11031069.5 model_11032548.5 model_11034027.5 model_11035506.5 model_11036985.5 model_11038464.5 model_11039943.5 model_11041422.5 model_11042901.5 model_11044380.5 model_11045859.5 model_11047338.5 model_11048817.5 model_11050296.5 model_11051775.5 model_11053254.5 model_11054733.5 model_11056212.5 model_11057691.5 model_11059170.5 model_11060649.5 model_11062128.5 model_11063607.5 model_11065086.5 model_11066565.5 model_11068044.5 model_11069523.5 model_11071002.5 model_11072481.5 model_11073960.5 model_11075439.5 model_11076918.5 model_11078397.5 model_11079876.5 model_11081355.5 model_11082834.5 model_11084313.5 model_11085792.5 model_11087271.5 model_11088750.5 model_11090229.5 model_11091708.5 model_11093187.5 model_11094666.5 model_11096145.5 model_11097624.5 model_11099103.5 model_11100582.5 model_11102061.5 model_11103540.5 model_11105019.5 model_11106498.5 model_11107977.5 model_11109456.5 model_11110935.5 model_11112414.5 model_11113893.5 model_11115372.5 model_11116851.5 model_11118330.5 model_11119809.5 model_11121288.5 model_11122767.5 model_11124246.5 model_11125725.5 model_11127204.5 model_11128683.5 model_11130162.5 model_11131641.5 model_11133120.5 model_11134599.5 model_11136078.5 model_11137557.5 model_11139036.5 model_11140515.5 model_11141994.5 model_11143473.5 model_11144952.5 model_11146431.5 model_11147910.5 model_11149389.5 model_11150868.5 model_11152347.5 model_11153826.5 model_11155305.5 model_11156784.5 model_11158263.5 model_11159742.5 model_11161221.5 model_11162700.5 model_11164179.5 model_11165658.5 model_11167137.5 model_11168616.5 model_11170095.5 model_11171574.5 model_11173053.5 model_11174532.5 model_11176011.5 model_11177490.5 model_11178969.5 model_11180448.5 model_11181927.5 model_11183406.5 model_11184885.5 model_11186364.5 model_11187843.5 model_11189322.5 model_11190801.5 model_11192280.5 model_11193759.5 model_11195238.5 model_11196717.5 model_11198196.5 model_11199675.5 model_11201154.5 model_11202633.5 model_11204112.5 model_11205591.5 model_11207070.5 model_11208549.5 model_11210028.5 model_11211507.5 model_11212986.5 model_11214465.5 model_11215944.5 model_11217423.5 model_11218902.5 model_11220381.5 model_11221860.5 model_11223339.5 model_11224818.5 model_11226297.5 model_11227776.5 model_11229255.5 model_11230734.5 model_11232213.5 model_11233692.5 model_11235171.5 model_11236650.5 model_11238129.5 model_11239608.5 model_11241087.5 model_11242566.5 model_11244045.5 model_11245524.5 model_11247003.5 model_11248482.5 model_11249961.5 model_11251440.5 model_11252919.5 model_11254398.5 model_11255877.5 model_11257356.5 model_11258835.5 model_11260314.5 model_11261793.5 model_11263272.5 model_11264751.5 model_11266230.5 model_11267709.5 model_11269188.5 model_11270667.5 model_11272146.5 model_11273625.5 model_11275104.5 model_11276583.5 model_11278062.5 model_11279541.5 model_11281020.5 model_11282499.5 model_11283978.5 model_11285457.5 model_11286936.5 model_11288415.5 model_11289894.5 model_11291373.5 model_11292852.5 model_11294331.5 model_11295810.5 model_11297289.5 model_11298768.5 model_11299247.5 model_11300726.5 model_11302205.5 model_11303684.5 model_11305163.5 model_11306642.5 model_11308121.5 model_11309600.5 model_11311079.5 model_11312558.5 model_11314037.5 model_11315516.5 model_11316995.5 model_11318474.5 model_11319953.5 model_11321432.5 model_11322911.5 model_11324390.5 model_11325869.5 model_11327348.5 model_11328827.5 model_11330306.5 model_11331785.5 model_11333264.5 model_11334743.5 model_11336222.5 model_11337701.5 model_11339180.5 model_11340659.5 model_11342138.5 model_11343617.5 model_11345096.5 model_11346575.5 model_11348054.5 model_11349533.5 model_11351012.5 model_11352491.5 model_11353970.5 model_11355449.5 model_11356928.5 model_11358407.5 model_11359886.5 model_11361365.5 model_11362844.5 model_11364323.5 model_11365802.5 model_11367281.5 model_11368760.5 model_11370239.5 model_11371718.5 model_11373197.5 model_11374676.5 model_11376155.5 model_11377634.5 model_11379113.5 model_11380592.5 model_11382071.5 model_11383550.5 model_11385029.5 model_11386508.5 model_11387987.5 model_11389466.5 model_11390945.5 model_11392424.5 model_11393903.5 model_11395382.5 model_11396861.5 model_11398340.5 model_11399819.5 model_11401298.5 model_11402777.5 model_11404256.5 model_11405735.5 model_11407214.5 model_11408693.5 model_11410172.5 model_11411651.5 model_11413130.5 model_11414609.5 model_11416088.5 model_11417567.5 model_11419046.5 model_11420525.5 model_11422004.5 model_11423483.5 model_11424962.5 model_11426441.5 model_11427920.5 model_11429399.5 model_11430878.5 model_11432357.5 model_11433836.5 model_11435315.5 model_11436794.5 model_11438273.5 model_11439752.5 model_11441231.5 model_11442710.5 model_11444189.5 model_11445668.5 model_11447147.5 model_11448626.5 model_11450105.5 model_11451584.5 model_11453063.5 model_11454542.5 model_11456021.5 model_11457500.5 model_11458979.5 model_11460458.5 model_11461937.5 model_11463416.5 model_11464895.5 model_11466374.5 model_11467853.5 model_11469332.5 model_11470811.5 model_11472290.5 model_11473769.5 model_11475248.5 model_11476727.5 model_11478206.5 model_11479685.5 model_11481164.5 model_11482643.5 model_11484122.5 model_11485601.5 model_11487080.5 model_11488559.5 model_11490038.5 model_11491517.5 model_11492996.5 model_11494475.5 model_11495954.5 model_11497433.5 model_11498912.5 model_11500391.5 model_11501870.5 model_11503349.5 model_11504828.5 model_11506307.5 model_11507786.5 model_11509265.5 model_11510744.5 model_11512223.5 model_11513702.5 model_11515181.5 model_11516660.5 model_11518139.5 model_11519618.5 model_11521097.5 model_11522576.5 model_11524055.5 model_11525534.5 model_11527013.5 model_11528492.5 model_11529971.5 model_11531450.5 model_11532929.5 model_11534408.5 model_11535887.5 model_11537366.5 model_11538845.5 model_11540324.5 model_11541803.5 model_11543282.5 model_11544761.5 model_11546240.5 model_11547719.5 model_11549198.5 model_11550677.5 model_11552156.5 model_11553635.5 model_11555114.5 model_11556593.5 model_11558072.5 model_11559551.5 model_11561030.5 model_11562509.5 model_11563988.5 model_11565467.5 model_11566946.5 model_11568425.5 model_11569904.5 model_11571383.5 model_11572862.5 model_11574341.5 model_11575820.5 model_11577299.5 model_11578778.5 model_11580257.5 model_11581736.5 model_11583215.5 model_11584694.5 model_11586173.5 model_11587652.5 model_11589131.5 model_11590610.5 model_11592089.5 model_11593568.5 model_11595047.5 model_11596526.5 model_11598005.5 model_11599484.5 model_11600963.5 model_11602442.5 model_11603921.5 model_11605400.5 model_11606879.5 model_11608358.5 model_11609837.5 model_11611316.5 model_11612795.5 model_11614274.5 model_11615753.5 model_11617232.5 model_11618711.5 model_11620190.5 model_11621669.5 model_11623148.5 model_11624627.5 model_11626106.5 model_11627585.5 model_11629064.5 model_11630543.5 model_11632022.5 model_11633501.5 model_11634980.5 model_11636459.5 model_11637938.5 model_11639417.5 model_11640896.5 model_11642375.5 model_11643854.5 model_11645333.5 model_11646812.5 model_11648291.5 model_11649770.5 model_11651249.5 model_11652728.5 model_11654207.5 model_11655686.5 model_11657165.5 model_11658644.5 model_11660123.5 model_11661602.5 model_11663081.5 model_11664560.5 model_11666039.5 model_11667518.5 model_11668997.5 model_11670476.5 model_11671955.5 model_11673434.5 model_11674913.5 model_11676392.5 model_11677871.5 model_11679350.5 model_11680829.5 model_11682308.5 model_11683787.5 model_11685266.5 model_11686745.5 model_11688224.5 model_11689703.5 model_11691182.5 model_11692661.5 model_11694140.5 model_11695619.5 model_11697098.5 model_11698577.5 model_11699956.5 model_11701435.5 model_11702914.5 model_11704393.5 model_11705872.5 model_11707351.5 model_11708830.5 model_11710309.5 model_11711788.5 model_11713267.5 model_11714746.5 model_11716225.5 model_11717704.5 model_11719183.5 model_11720662.5 model_11722141.5 model_11723620.5 model_11725099.5 model_11726578.5 model_11728057.5 model_11729536.5 model_11731015.5 model_11732494.5 model_11733973.5 model_11735452.5 model_11736931.5 model_11738410.5 model_11739889.5 model_11741368.5 model_11742847.5 model_11744326.5 model_11745805.5 model_11747284.5 model_11748763.5 model_11750242.5 model_11751721.5 model_11753200.5 model_11754679.5 model_11756158.5 model_11757637.5 model_11759116.5 model_11760595.5 model_11762074.5 model_11763553.5 model_11765032.5 model_11766511.5 model_11767990.5 model_11769469.5 model_11770948.5 model_11772427.5 model_11773906.5 model_11775385.5 model_11776864.5 model_11778343.5 model_11779822.5 model_11781301.5 model_11782780.5 model_11784259.5 model_11785738.5 model_11787217.5 model_11788696.5 model_11790175.5 model_11791654.5 model_11793133.5 model_11794612.5 model_11796091.5 model_11797570.5 model_11799049.5 model_11800528.5 model_11802007.5 model_11803486.5 model_11804965.5 model_11806444.5 model_11807923.5 model_11809402.5 model_11810881.5 model_11812360.5 model_11813839.5 model_11815318.5 model_11816797.5 model_11818276.5 model_11819755.5 model_11821234.5 model_11822713.5 model_11824192.5 model_11825671.5 model_11827150.5 model_11828629.5 model_11830108.5 model_11831587.5 model_11833066.5 model_11834545.5 model_11836024.5 model_11837503.5 model_11838982.5 model_11840461.5 model_11841940.5 model_11843419.5 model_11844898.5 model_11846377.5 model_11847856.5 model_11849335.5 model_11850814.5 model_11852293.5 model_11853772.5 model_11855251.5 model_11856730.5 model_11858209.5 model_11859688.5 model_11861167.5 model_11862646.5 model_11864125.5 model_11865604.5 model_11867083.5 model_11868562.5 model_11870041.5 model_11871520.5 model_11873000.5 model_11874479.5 model_11875958.5 model_11877437.5 model_11878916.5 model_11880395.5 model_11881874.5 model_11883353.5 model_11884832.5 model_11886311.5 model_11887790.5 model_11889269.5 model_11890748.5 model_11892227.5 model_11893706.5 model_11895185.5 model_11896664.5 model_11898143.5 model_11899622.5 model_11901101.5 model_11902580.5 model_11904059.5 model_11905538.5 model_11907017.5 model_11908496.5 model_11909975.5 model_11911454.5 model_11912933.5 model_11914412.5 model_11915891.5 model_11917370.5 model_11918849.5 model_11920328.5 model_11921807.5 model_11923286.5 model_11924765.5 model_11926244.5 model_11927723.5 model_11929202.5 model_11930681.5 model_11932160.5 model_11933639.5 model_11935118.5 model_11936597.5 model_11938076.5 model_11939555.5 model_11941034.5 model_11942513.5 model_11943992.5 model_11945471.5 model_11946950.5 model_11948429.5 model_11949908.5 model_11951387.5 model_11952866.5 model_11954345.5 model_11955824.5 model_11957303.5 model_11958782.5 model_11960261.5 model_11961740.5 model_11963219.5 model_11964698.5 model_11966177.5 model_11967656.5 model_11969135.5 model_11970614.5 model_11972093.5 model_11973572.5 model_11975051.5 model_11976530.5 model_11978009.5 model_11979488.5 model_11980967.5 model_11982446.5 model_11983925.5 model_11985404.5 model_11986883.5 model_11988362.5 model_11989841.5 model_11991320.5 model_11992799.5 model_11994278.5 model_11995757.5 model_11997236.5 model_11998715.5 model_12000194.5 model_12001673.5 model_12003152.5 model_12004631.5 model_12006110.5 model_12007589.5 model_12009068.5 model_12010547.5 model_12012026.5 model_12013505.5 model_12014984.5 model_12016463.5 model_12017942.5 model_12019421.5 model_12020900.5 model_12022379.5 model_12023858.5 model_12025337.5 model_12026816.5 model_12028295.5 model_12029774.5 model_12031253.5 model_12032732.5 model_12034211.5 model_12035690.5 model_12037169.5 model_12038648.5 model_12040127.5 model_12041606.5 model_12043085.5 model_12044564.5 model_12046043.5 model_12047522.5 model_12049001.5 model_12050480.5 model_12051959.5 model_12053438.5 model_12054917.5 model_12056396.5 model_12057875.5 model_12059354.5 model_12060833.5 model_12062312.5 model_12063791.5 model_12065270.5 model_12066749.5 model_12068228.5 model_12069707.5 model_12071186.5 model_12072665.5 model_12074144.5 model_12075623.5 model_12077102.5 model_12078581.5 model_12080060.5 model_12081539.5 model_12083018.5 model_12084497.5 model_12085976.5 model_12087455.5 model_12088934.5 model_12090413.5 model_12091892.5 model_12093371.5 model_12094850.5 model_12096329.5 model_12097808.5 model_12099287.5 model_12100766.5 model_12102245.5 model_12103724.5 model_12105203.5 model_12106682.5 model_12108161.5 model_12109640.5 model_12111119.5 model_12112598.5 model_12114077.5 model_12115556.5 model_12117035.5 model_12118514.5 model_12119993.5 model_12121472.5 model_12122951.5 model_12124430.5 model_12125909.5 model_12127388.5 model_12128867.5 model_12130346.5 model_12131825.5 model_12133304.5 model_12134783.5 model_12136262.5 model_12137741.5 model_12139220.5 model_12140699.5 model_12142178.5 model_12143657.5 model_12145136.5 model_12146615.5 model_12148094.5 model_12149573.5 model_12151052.5 model_12152531.5 model_12154010.5 model_12155489.5 model_12156968.5 model_12158447.5 model_12159926.5 model_12161405.5 model_12162884.5 model_12164363.5 model_12165842.5 model_12167321.5 model_12168800.5 model_12170279.5 model_12171758.5 model_12173237.5 model_12174716.5 model_12176195.5 model_12177674.5 model_12179153.5 model_12180632.5 model_12182111.5 model_12183590.5 model_12185069.5 model_12186548.5 model_12188027.5 model_12189506.5 model_12190985.5 model_12192464.5 model_12193943.5 model_12195422.5 model_12196901.5 model_12198380.5 model_12199859.5 model_12201338.5 model_12202817.5 model_12204296.5 model_12205775.5 model_12207254.5 model_12208733.5 model_12210212.5 model_12211691.5 model_12213170.5 model_12214649.5 model_12216128.5 model_12217607.5 model_12219086.5 model_12220565.5 model_12222044.5 model_12223523.5 model_12225002.5 model_12226481.5 model_12227960.5 model_12229439.5 model_12230918.5 model_12232397.5 model_12233876.5 model_12235355.5 model_12236834.5 model_12238313.5 model_12239792.5 model_12241271.5 model_12242750.5 model_12244229.5 model_12245708.5 model_12247187.5 model_12248666.5 model_12250145.5 model_12251624.5 model_12253103.5 model_12254582.5 model_12256061.5 model_12257540.5 model_12259019.5 model_12260498.5 model_12261977.5 model_12263456.5 model_12264935.5 model_12266414.5 model_12267893.5 model_12269372.5 model_12270851.5 model_12272330.5 model_12273809.5 model_12275288.5 model_12276767.5 model_12278246.5 model_12279725.5 model_12281204.5 model_12282683.5 model_12284162.5 model_12285641.5 model_12287120.5 model_12288599.5 model_12290078.5 model_12291557.5 model_12293036.5 model_12294515.5 model_12295994.5 model_12297473.5 model_12298952.5 model_12300431.5 model_12301910.5 model_12303389.5 model_12304868.5 model_12306347.5 model_12307826.5 model_12309305.5 model_12310784.5 model_12312263.5 model_12313742.5 model_12315221.5 model_12316700.5 model_12318179.5 model_12319658.5 model_12321137.5 model_12322616.5 model_12324095.5 model_12325574.5 model_12327053.5 model_12328532.5 model_12330011.5 model_12331490.5 model_12332969.5 model_12334448.5 model_12335927.5 model_12337406.5 model_12338885.5 model_12340364.5 model_12341843.5 model_12343322.5 model_12344801.5 model_12346280.5 model_12347759.5 model_12349238.5 model_12350717.5 model_12352196.5 model_12353675.5 model_12355154.5 model_12356633.5 model_12358112.5 model_12359591.5 model_12361070.5 model_12362549.5 model_12364028.5 model_12365507.5 model_12366986.5 model_12368465.5 model_12369944.5 model_12371423.5 model_12372902.5 model_12374381.5 model_12375860.5 model_12377339.5 model_12378818.5 model_12380297.5 model_12381776.5 model_12383255.5 model_12384734.5 model_12386213.5 model_12387692.5 model_12389171.5 model_12390650.5 model_12392129.5 model_12393608.5 model_12395087.5 model_12396566.5 model_12398045.5 model_12399524.5 model_12401003.5 model_12402482.5 model_12403961.5 model_12405440.5 model_12406919.5 model_12408398.5 model_12409877.5 model_12411356.5 model_12412835.5 model_12414314.5 model_12415793.5 model_12417272.5 model_12418751.5 model_12420230.5 model_12421709.5 model_12423188.5 model_12424667.5 model_12426146.5 model_12427625.5 model_12429104.5 model_12430583.5 model_12432062.5 model_12433541.5 model_12435020.5 model_12436499.5 model_12437978.5 model_12439457.5 model_12440936.5 model_12442415.5 model_12443894.5 model_12445373.5 model_12446852.5 model_12448331.5 model_12449810.5 model_12451289.5 model_12452768.5 model_12454247.5 model_12455726.5 model_12457205.5 model_12458684.5 model_12460163.5 model_12461642.5 model_12463121.5 model_12464600.5 model_12466079.5 model_12467558.5 model_12469037.5 model_12470516.5 model_12471995.5 model_12473474.5 model_12474953.5 model_12476432.5 model_12477911.5 model_12479390.5 model_12480869.5 model_12482348.5 model_12483827.5 model_12485306.5 model_12486785.5 model_12488264.5 model_12489743.5 model_12491222.5 model_12492701.5 model_12494180.5 model_12495659.5 model_12497138.5 model_12498617.5 model_12500096.5 model_12501575.5 model_12503054.5 model_12504533.5 model_12506012.5 model_12507491.5 model_12508970.5 model_12510449.5 model_12511928.5 model_12513407.5 model_12514886.5 model_12516365.5 model_12517844.5 model_12519323.5 model_12520

• Tidak ada nilai NaN

- Model yang sesuai tersedia

Walaupun metrik tersebut belum secara eksplisit dihitung dalam program ini, hasil yang diekspor ke Excel sudah cukup lengkap untuk perhitungan manual atau otomatis pada tahap berikutnya menggunakan pandas, sklearn.metrics, atau langsung di Excel.

Gambar 12 di bawah ini menampilkan hasil akhir prediksi kebutuhan obat yang sudah diekspor ke dalam format Excel. Setiap baris menunjukkan nilai hasil prediksi untuk obat tertentu, sehingga informasi dapat dengan mudah dianalisis maupun digunakan dalam pengambilan keputusan terkait ketersediaan obat. Dengan output berbentuk Excel, hasil penelitian menjadi lebih praktis untuk diintegrasikan dengan sistem manajemen farmasi.



Bulan	Aktual Perkiraan Rasio Persediaan
April 2022	270 156,5219 0,427891 42,78908
May 2022	218 207,5811 0,611205 1,155406
June 2022	210 215,0911 0,624243 2,424917
July 2022	270 232,4247 0,862719 140,0781
Aug 2022	240 105,7717 0,212193 21,21933
September	240 218,3877 0,890826 8,005127
October 2	90 216,4519 1,495204 140,5506
November	90 174,2621 0,936246 93,62467

- Walaupun metrik tersebut belum secara eksplisit dihitung dalam program ini, hasil yang diekspor ke Excel sudah cukup lengkap untuk perhitungan manual atau otomatis pada tahap berikutnya menggunakan `pandas`, `sklearn.metrics`, atau langsung di Excel.

Bulan	Aktual	Proyeksi Eki	Proyeksi Jan
2 April 2022	279	156,5235	8.427691
3 May 2022	219	307,5815	8,611205
4 Juni 2022	219	281,0911	8,674249
5 July 2022	279	232,4247	9,140278
6 Aug 2022	240	185,0737	9,212492
7 September	283	238,9877	8,890261
8 October 2	93	216,4955	1,489504
9 November	93	174,2621	9,536246

40

H. Evaluasi Kinerja Model Prediksi

Evaluasi model dilakukan untuk menilai sejauh mana akurasi prediksi yang dihasilkan oleh model terhadap data penjualan obat di apotek. Evaluasi ini menggunakan beberapa metrik, antara lain Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Seluruh metrik dihitung terhadap data aktual (ground truth) yang telah di-inverse transform dari skala normalisasi.

I. Hasil Evaluasi Per Produk

Evaluasi dilakukan untuk masing-masing kode obat dalam dataset. Hasil menunjukkan bahwa sebagian besar prediksi model cukup mendekati nilai aktual, dengan rata-rata MAE berada pada kisaran 30 hingga 80 unit tergantung pada volume penjualan obat tersebut. Beberapa contoh performa model terhadap obat tertentu dapat dilihat pada Tabel 4.1 berikut.

Tabel 2 di bawah ini merupakan contoh evaluasi model terhadap beberapa obat, menunjukkan perbandingan antara **Total Aktual** (jumlah obat yang sebenarnya) dan **Total Prediksi** (jumlah obat yang diprediksi oleh model), beserta nilai metrik evaluasi seperti **MAE**, **RMSE**, dan **MAPE**

Tabel 2 Contoh Evaluasi Model terhadap Beberapa Obat

Nama Obat	Total Aktual	Total Prediksi	MAE	RMSE	MAPE
ACARBOSE 100MG	1.350	1.281	39	49	3,1%
AMLODIPIN 10MG (MARIN)	26.930	25.970	1.413	1.797	5,2%
BISOPROLOL 5MG	0	22	22	22	inf

Sebagaimana terlihat pada tabel, prediksi model terhadap obat ACARBOSE 100MG dan AMLODIPIN 10MG menunjukkan kesalahan relatif yang masih dapat diterima, dengan MAPE masing-masing sebesar 3,1% dan 5,2%. Hal ini menunjukkan bahwa model cukup akurat dalam memprediksi

volume penjualan obat-obat tersebut.

Gambar 13 di bawah ini merupakan visualisasi dari nilai **Mean Absolute Error (MAE)** untuk tiap produk obat, yang disajikan dalam bentuk grafik batang. Grafik ini menunjukkan seberapa besar rata-rata kesalahan prediksi model untuk setiap jenis obat, di mana semakin rendah nilai MAE, semakin akurat prediksi yang dihasilkan.



Gambar 13 Grafik Mean Absolute Error (MAE) pada Tiap Produk

J. Kasus dengan Error Tinggi

Terdapat pula beberapa kasus di mana prediksi model menghasilkan error yang cukup tinggi. Salah satu contohnya adalah pada produk AMLODIPINE 10MG (DUS 50 TAB), dengan nilai aktual sebesar 47.605, namun diprediksi hanya sebesar 32.187. Hal ini menyebabkan nilai MAE sebesar 1.499 dan nilai MAPE sangat tinggi (sekitar 1.479%), yang menunjukkan kesalahan prediksi yang signifikan.

Selain itu, terdapat sejumlah obat seperti CAPTOPRIL 25MG, BISOPROLOL 5MG, dan VITAMIN B1, yang memiliki nilai aktual sebesar 0 tetapi diprediksi oleh model memiliki permintaan. Hal ini menyebabkan nilai MAPE menjadi tak terdefinisi (infinite), karena pembagian oleh nol dalam perhitungan MAPE.

K. Analisis Error

Secara umum, metrik MAE dan RMSE memperlihatkan bahwa tingkat kesalahan prediksi berada dalam rentang wajar untuk sebagian besar obat, terutama untuk produk dengan volume penjualan menengah hingga tinggi. Namun, pada obat dengan volume penjualan yang sangat rendah atau tidak ada penjualan sama sekali, performa model cenderung menurun, yang tercermin dari nilai error relatif (MAPE) yang tinggi atau tak terdefinisi.

Untuk meningkatkan akurasi prediksi pada kategori ini, evaluasi dapat menggunakan metrik yang lebih stabil terhadap nilai nol, seperti Symmetric Mean Absolute Percentage Error (SMAPE). Alternatif lain adalah melakukan filtering terhadap data dengan penjualan nol untuk menghindari distorsi dalam evaluasi agregat.

Gambar 14 di bawah ini menampilkan **Hasil Output Tabel Evaluasi di Excel**, yang berisi daftar produk obat beserta metrik evaluasi model prediksi. Tabel ini menyajikan data lengkap untuk setiap produk, termasuk **Total Prediksi**, **Total Aktual**, serta nilai-nilai metrik kesalahan seperti **MAE**, **MSE**, **RMSE**, dan **MAPE** yang digunakan untuk mengukur performa model.

1	Kode Obat	Nama Obat	Total Prediksi	Total Aktual	MAE	MSE	RMSE	MAPE
2	11002397	ACARBOSE 100 MG (DUS 100 TAB)	1607,523302	1620	55,52175499	5120,376851	71,55680856	40,59753991
3	13000087	ACARBOSE 100MG TAB@100 BPJS	767,7714586	825	51,25665307	4492,774606	67,02816278	52,81099056
4	13005138	ACARBOSE 100MG TAB@100 GDX	1281,176238	1350	39,42414977	2405,570471	49,04661528	47,029829
5	11002396	ACARBOSE 50 MG (DUS 100 TAB)	1967,310072	2040	83,14541861	10031,72464	100,1584976	34,38397495
6	13000086	ACARBOSE 50MG TAB@100 BPJS	307,9662278	330	28,51780124	1388,820495	37,26688202	30,51654659
7	13005137	ACARBOSE 50MG TAB@100 GDX	998,6832225	1020	25,81212322	1118,346591	33,44168941	22,42166466
8	13000146	ADALAT OROS 30MG TAB@30 BPJS	2470,778815	2520	35,75737625	2247,116625	47,40376171	34,20090578
9	11000006	ALERGINE 10 MG TABLET SALUT SELAPUT	10,65230727	10	0,652307272	0,425504777	0,652307272	6,52307272
10	11001445	ALLOPURINOL 100 MG (DUS 100 TAB)-BJN	123,1457877	120	11,54980183	144,7458771	12,03103807	29,74833449
11	13026995	ALLOPURINOL 100MG TAB@100 GHEX	225,6159908	240	9,641163349	144,9509687	12,03955849	23,04287404
12	13087275	ALLOPURINOL 100MG TAB@100 GHX BPJS	1396,749158	1410	40,03940161	2091,140073	45,72898504	62,21708758
13	13087276	ALLOPURINOL 300MG TAB@100 GHX BPJS	32,72820354	30	2,728203535	7,443094529	2,728203535	9,094011784
14	11000147	AMBROXOL 30 MG (DUS 100 TAB)	17,48113632	16	1,481136322	2,193764804	1,481136322	9,257102013
15	12013471	AMLODIPIN 10 MG DUS @100 (MARIN)	25970,4906	26930	1413,648131	2625563,406	1620,359036	26,69715458
16	13077877	AMLODIPIN 10MG TAB GTE	231,2997115	210	21,29971147	453,6777085	21,29971147	10,14271975
17	13068976	AMLODIPIN 10MG TAB@30 GBN	66,26543999	60	6,265439987	39,25573823	6,265439987	10,44239998
18	13000444	AMLODIPIN 10MG TAB@30 GLA	103,6271788	120	16,37282118	268,0692735	16,37282118	13,64401765
19	12013470	AMLODIPIN 5 MG DUS@100 (MARIN)	19264,52963	20310	776,3483899	746700,0797	864,1180936	80,20756372
20	11000151	AMLODIPINE 10 MG (DUS 50 TAB)	63,7834096	60	1,891704798	4,21169779	2,052242137	6,305682659
21	11001449	AMLODIPINE 10 MG (DUS 50 TAB)-BJN	32187,61955	34605	1499,012967	3518249,117	1875,699634	1479,894066
22	13085206	AMLODIPINE 10MG TAB@100 GSAM BPJS	107062,8889	106988	1548,273509	3538288,88	1881,033992	106,2907668
23	13026871	AMLODIPINE 10MG TAB@50 BPJS	4712,873279	4480	727,1266313	1123743,227	1060,067558	1057,613933
24	11000150	AMLODIPINE 5 MG (DUS 50 TAB)	20456,48438	21630	201,3063049	51995,4867	228,0251887	5,490398656
25	11001448	AMLODIPINE 5 MG (DUS 50 TAB)-BJN	46844,19635	47005	1321,918943	2785475,574	1668,974408	371,6715059
26	13026964	AMLODIPINE 5MG TAB@50 BPJS	24000,49829	24250	905,0098229	1140466,276	1067,926156	564,438899
27	12009826	AMLODIPINE BESYLATE 10MG @30 TAB (PEHA)	16871,48053	15405	1001,368155	1643238,336	1281,888582	934,3193592
28	13078591	AMOXICILLIN 500MG GMER	46,57722282	44	2,577222824	6,642077485	2,577222824	5,8573246
29	13067803	AMOXICILLIN 125MG SYR GHX	2,017945051	2	0,017945051	0,000322025	0,017945051	0,89725256
30	13005326	APIDRA SOLOSTAR 100IU/ML PEN@5	58,04064843	61	3,141437641	14,11544415	3,757052588	71,84709274
31	13000201	APIDRA SOLOSTAR PEN BPJS	435,3353994	415	9,492160387	117,3893082	10,83463466	52,78483439
32	12002360	APTOR TABLET @ 100 TAB	1489,446235	1592	77,17749726	12191,95353	110,4171795	76,74924339
33	13016851	AQUA DANONE 1500ML	3,298454762	3	0,298454762	0,089075245	0,298454762	9,94849205
34	13003123	ARDIUM 500MG TAB@60	16,92811668	15	1,928116679	3,717633929	1,928116679	12,85411119
35	11000014	ASAM MEFENAMAT 500 MG (DUS 100 TAB)	10,94299555	10	0,942995548	0,889240604	0,942995548	9,429955482
36	12000710	ASPILET CHEWABLE @ 100 TAB	1432,954105	1530	103,3088585	13622,61383	116,7159536	114,6289973
37	13076631	ASPILETS 80MG TAB@100 BPJS	7498,118958	8390	1074,687781	1289231,04	1135,443103	339,6004661
38	13010336	BECOM C KPL@100	22,36034632	20	2,360346317	5,571234798	2,360346317	11,80173159

Gambar 14 Hasil Output Tabel evaluasi di Excell

BAB V

KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil analisis dan implementasi model peramalan penjualan obat menggunakan Metode Analisis Difrensial dan LSTM, dapat disimpulkan beberapa hal sebagai berikut:

1. Model mampu memberikan hasil peramalan penjualan obat dengan baik, terutama untuk produk-produk yang memiliki pola penjualan musiman dan tren yang stabil. Model ini secara otomatis menangkap komponen tren, musiman, dan liburan tanpa memerlukan banyak penyesuaian dari pengguna.
2. Evaluasi model menggunakan metrik RMSE, MAE, dan MAPE menunjukkan performa yang cukup baik. Meskipun terdapat sedikit deviasi untuk beberapa produk, secara umum model mampu memberikan prediksi yang cukup akurat dan layak dijadikan acuan untuk pengambilan keputusan stok dan pengadaan obat di masa mendatang.
3. Implementasi sistem ini dapat membantu apotek atau institusi kesehatan dalam mengelola inventaris obat secara lebih efisien dengan memprediksi kebutuhan di masa depan, menghindari overstock maupun stockout, serta meningkatkan efisiensi operasional.
4. Analisis visual yang disajikan menunjukkan kecocokan antara data aktual dan hasil peramalan, terutama pada produk-produk dengan data historis yang cukup panjang dan stabil. Hal ini membuktikan bahwa Prophet merupakan pilihan yang tepat untuk kasus peramalan penjualan berbasis time series.

B. Saran

Sebagai tindak lanjut dari penelitian ini, terdapat beberapa saran yang dapat dijadikan pertimbangan untuk pengembangan lebih lanjut:

1. Integrasi Algoritma Klustering untuk Pengelompokan Produk. Disarankan untuk menggunakan algoritma klustering seperti K-Means atau DBSCAN dalam mengelompokkan produk obat berdasarkan pola historis penjualannya. Dengan melakukan segmentasi terhadap produk yang memiliki karakteristik serupa, model peramalan dapat dikembangkan secara lebih spesifik per kelompok produk, sehingga akurasi prediksi dapat ditingkatkan.
2. Eksperimen dengan Sliding Window dan Timestep. Untuk pengembangan model berbasis deep learning seperti LSTM atau GRU, disarankan untuk mengeksplorasi penggunaan teknik sliding window dan penyesuaian nilai timestep. Parameter ini sangat memengaruhi kemampuan model dalam memahami dependensi temporal pada data deret waktu dan dapat berdampak langsung pada kualitas peramalan.
3. Pendekatan Event-Driven dalam Proses Pelatihan Model. Model Prophet saat ini dilatih secara statis berdasarkan data historis yang tersedia. Akan tetapi, untuk implementasi skala besar atau real-time, pendekatan *event-driven* dapat diterapkan. Artinya, pelatihan ulang model dilakukan hanya ketika terjadi perubahan signifikan seperti lonjakan permintaan akibat promosi, hari libur nasional, atau pandemi. Hal ini dapat meningkatkan efisiensi dan adaptabilitas sistem terhadap perubahan kondisi pasar.

DAFTAR PUSTAKA

Algoritma, P., Dan, K. N., Ekstraksi, F., & Analisis, N. D. (2023). *KOMPUTA* :

- Jurnal Ilmiah Komputer dan Informatika KOMPUTA : Jurnal Ilmiah Komputer dan Informatika*. 12(1), 91–100.
- Anshory, M. I., & Priyandari, Y. (2020). *Peramalan Penjualan Sediaan Farmasi Menggunakan Long Short-term Memory : Studi Kasus pada Apotik Suganda*. 19(2), 159–174. <https://doi.org/10.20961/performa.19.2.45962>
- Baharuddin, M. M., Hasanuddin, T., & Azis, H. (2019). *ANALISIS PERFORMA METODE K-NEAREST NEIGHBOR UNTUK*. 11(28), 269–274.
- Fahmi, M. N., Tinggi, S., Islam, A., & Islam, N. (2023). *Implementasi Mechine Learning menggunakan Python Library: Scikit-Learn (Supervised dan Unsupervised Learning)*. 2, 87–96.
- Informatika, T., Tarumanagara, U., Letjen, J., No, S. P., & Barat, J. (2023). *PENERAPAN METODE LONG SHORT- TERM MEMORY DALAM MEMPREDIKSI DATA METEOROLOGI DI KALIMANTAN TIMUR*. 8(2), 348–352.
- Khumaidi, A., Raafi, R., & Solihin, I. P. (2022). *Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung*. 15(1), 13–18.
- Kusumawati, F., & Rahayu, E. (2023). *Analisis Kendala Pengadaan Obat Program Rujuk Balik (PRB) di Fasilitas Kesehatan Tingkat Pertama (Studi Kasus Pada Puskesmas BLUD di Kabupaten Indragiri Hilir)*. 3(1), 56–67.
- Martawinata, S., Soewondo, P., Magister, P., Kesehatan, I., Masyarakat, F. K., Adminitrasi, D., & Masyarakat, F. K. (2023). *Analisis ketersediaan obat Program Rujuk Balik (PRB) Kasus Hipertensi Di Kota Palembang*.
- Mousa, B. A., & Al-khateeb, B. (2020). *PREDICTING MEDICINE DEMAND USING DEEP*.
- Muharram, R. F., & Suryadi, A. (2022). *Jurnal Widya Implementasi artificial intelligence untuk deteksi masker secara realtime dengan tensorflow dan ssdmobilenet Berbasis python Jurnal Widya*. 3, 281–290.
- Nathaniel, J., Jeremias, V., & Engel, L. (2022). *Penerapan Nonpooling CNN-LSTM Untuk Prediksi Pemakaian Obat Rumah Sakit*.
- Nurhalizah, R. S., & Ardianto, R. (2024). *Analisis Supervised dan Unsupervised*

- Learning pada Machine Learning : Systematic Literature Review*. 4(1), 61–72.
- P, I. W. S. E., Wijaya, A. Y., & Soelaiman, R. (2016). *Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) pada Caltech 101*. 5(1).
- Pratama, M. L., & Utama, H. (2023). *PENDEKATAN DEEP LEARNING MENGGUNAKAN*. 2(2), 43–50.
- Pratiwi, S. A., Fauzi, A., Arum, S., Lestari, P., & Cahyana, Y. (2024). *Prediksi Persediaan Obat Pada Apotek Menggunakan Algoritma Decision Tree*. 4(4), 2381–2388. <https://doi.org/10.30865/klik.v4i4.1681>
- Rachman, F. I., Bakti, R. Y., Wahyuni, T., & Virgiawan, D. A. (2024). *PENGENALAN BAHASA ISYARAT MENGGUNAKAN DETEKSI OBJEK DEEP LEARNING Sign Language Recognition Using Deep Learning Object Detection*. 9(November), 1–6.
- Rahmat, D., Yang, T., & Esa, M. (2024). Keputusan Menteri Kesehatan RI. In *Menkes RI*.
- Salintohe, D. I., Musdar, I. A., Informatika, T., Machine, T., Network, C. N., & Hias, T. (2022). *IMPLEMENTASI MACHINE LEARNING UNTUK MENGIDENTIFIKASI TANAMAN HIAS PADA APLIKASI*. 9(1), 1–15.
- Sudradjat, J., Pascasarjana, P., Ilmu, M., & Universitas, A. (2020). *IMPLEMENTASI KEBIJAKAN PROGRAM RUJUK BALIK PESERTA*. 7, 251–259.
- Tiwa, J. D., Ilat, V., Walandouw, S. K., Akuntansi, J., Ekonomi, F., Bisnis, D., & Ratulangi, U. S. (2022). *Analisis Biaya Diferensial Dalam Pengambilan Keputusan Menerima Atau Menolak Pesanan Khusus Pada RM . New Ayam Bandung Di Kota Manado*. 5(2), 791–798.
- Yanti, F., Sari, B. N., & Defiyanti, S. (2024). *IMPLEMENTASI ALGORITMA LSTM PADA PERAMALAN STOK OBAT (STUDI KASUS : PUSKESMAS BEBER)*. 8(4), 6082–6089.
- Anshory, M. I., Priyandari, Y., & Yuniaristanto, Y. (2020). Peramalan Penjualan Sediaan Farmasi Menggunakan Long Short-term Memory: Studi Kasus pada

- Apotik Suganda. *Performa: Media Ilmiah Teknik Industri*, 19(2).
<https://doi.org/10.20961/performa.19.2.45962>
- Fahmi, M. N., Tinggi, S., Islam, A., & Islam, N. (2023). *Implementasi Mechine Learning menggunakan Python Library : Scikit-Learn (Supervised dan Unsupervised Learning)*. 2, 87–96.
- Ita Bela, Z., & Bhakti, D. (2022). SISTEM PREDIKSI PENJUALAN OBAT MENGGUNAKAN METODE SINGLE MOVING AVERAGE (STUDI KASUS: APOTEK WILUJENG KECAMATAN PANCENG KAB.GRESIK). *INDEXIA: Informatic and Computational Intelligent Journal*, 4(1), 47–58.
- Jansen, D., Handhayani, T., & Hendryli, J. (2023). *PENERAPAN METODE LONG SHORT-TERM MEMORY DALAM MEMPREDIKSI DATA METEOROLOGI DI KALIMANTAN TIMUR*. 8(2). <http://dataonline.bmkg.go.id/>.
- Khumaidi, A., Raafi, R., & Solihin, I. P. (2022). *Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung*. 15(1), 13–18.
- Kusumawati, F., & Rahayu, E. (2023). *Analisis Kendala Pengadaan Obat Program Rujuk Balik (PRB) di Fasilitas Kesehatan Tingkat Pertama (Studi Kasus Pada Puskesmas BLUD di Kabupaten Indragiri Hilir)*. 3(1), 56–67.
- Martawinata, S., Soewondo, P., Magister, P., Kesehatan, I., Masyarakat, F. K., Adminitrasi, D., & Masyarakat, F. K. (2023). *Analisis ketersediaan obat Program Rujuk Balik (PRB) Kasus Hipertensi Di Kota Palembang*.
- Mousa, B. A., & Al-khateeb, B. (2020). *PREDICTING MEDICINE DEMAND USING DEEP*.
- Muharram, R. F., & Suryadi, A. (2022). *Jurnal Widya Implementasi artificial intelligence untuk deteksi masker secara realtime dengan tensorflow dan ssdmobilenet Berbasis python Jurnal Widya*. 3, 281–290.
- Nathaniel, J., Jeremias, V., & Engel, L. (2022). *Penerapan Nonpooling CNN-LSTM Untuk Prediksi Pemakaian Obat Rumah Sakit*.

Nurhalizah, R. S., & Ardianto, R. (2024). *Analisis Supervised dan Unsupervised Learning pada Machine Learning : Systematic Literature Review*. 4(1), 61–72.

Nurhidayat, R., & Dewi, K. E. (2023). *KOMPUTA : Jurnal Ilmiah Komputer dan Informatika PENERAPAN ALGORITMA K-NEAREST NEIGHBOR DAN FITUR EKSTRAKSI N-GRAM DALAM ANALISIS SENTIMEN BERBASIS ASPEK*. 12(1).

<https://www.kaggle.com/datasets/hafidahmusthaanah/skincare-review?select=00.+Review.csv>.

Pratama, M. L., & Utama, H. (2023). *PENDEKATAN DEEP LEARNING MENGGUNAKAN*. 2(2), 43–50.

Pratiwi, S. A., Fauzi, A., Arum, S., Lestari, P., & Cahyana, Y. (2024). *Prediksi Persediaan Obat Pada Apotek Menggunakan Algoritma Decision Tree*. 4(4), 2381–2388. <https://doi.org/10.30865/klik.v4i4.1681>

Rachman, F. I., Bakti, R. Y., Wahyuni, T., & Virgiawan, D. A. (2024). *PENGENALAN BAHASA ISYARAT MENGGUNAKAN DETEKSI OBJEK DEEP LEARNING Sign Language Recognition Using Deep Learning Object Detection*. 9(November), 1–6.

Rahayu, E., & Kusumawati, F. (2023). Analisis Kendala Pengadaan Obat Program Rujuk Balik (PRB) di Fasilitas Kesehatan Tingkat Pertama (Studi Kasus Pada Puskesmas BLUD di Kabupaten Indragiri Hilir). *Jurnal Jaminan Kesehatan Nasional*, 3(1). <https://doi.org/10.53756/jjkn.v3i1.126>

Rahmat, D., Yang, T., & Esa, M. (2024). Keputusan Menteri Kesehatan RI. In *Menkes RI*.

Raup, A., Ridwan, W., Khoeriyah, Y., Yuliati Zaqiah, Q., & Islam Negeri Sunan Gunung Djati Bandung, U. (n.d.). *Deep Learning dan Penerapannya dalam Pembelajaran*. <http://Jiip.stkipyapisdompou.ac.id>

Sudradjat, J., Pascasarjana, P., Ilmu, M., & Universitas, A. (2020). *IMPLEMENTASI KEBIJAKAN PROGRAM RUJUK BALIK PESERTA*. 7, 251–259.

Tiwa, J. D., Ilat, V., Walandouw, S. K., Akuntansi, J., Ekonomi, F., Bisnis, D., & Ratulangi, U. S. (2022). *Analisis Biaya Diferensial Dalam Pengambilan Keputusan Menerima Atau Menolak Pesanan Khusus Pada RM . New Ayam Bandung Di Kota Manado*. 5(2), 791–798.

Wakiyah Saharani, N., Ramlan, P., Adri, K., & Studi Administrasi Kesehatan, P. (n.d.). *EVALUASI PELAKSANAAN PROGRAM RUJUK BALIK TERHADAP KEPATUHAN PASIEN BPJS KESEHATAN DI KLINIK FELLA KABUPATEN SIDENRENG RAPPANG*.

Yanti, F., Sari, B. N., & Defiyanti, S. (2024). *IMPLEMENTASI ALGORITMA LSTM PADA PERAMALAN STOK OBAT (STUDI KASUS : PUSKESMAS BEBER)*. 8(4), 6082–6089.

Yusuf Syahrul Basyar. (2024). *PREDIKSI PERJUALAN OBAT MENGGUNAKAN MODEL LSTM DAN ANALISIS TIME SERIES PADA DATA TRANSAKSI PASIEN BPJS*.



```

import pandas as pd

# Baca Excel dengan 2 baris header
df_raw = pd.read_excel("rekap_bulanan_spacer_kecil (2).xlsx", header=[0,
1])

# Buat nama kolom baru
new_columns = []
for col in df_raw.columns:
    if "Kode Obat" in col[0] or "Nama Obat" in col[0]:
        new_columns.append(col[0].strip()) # Ambil hanya level-0 header
    else:
        # Gabungkan dua level untuk kolom lain
        combined = f"{col[0].strip()} {col[1].strip()}" if col[1] else
col[0].strip()
        new_columns.append(combined.strip())

# Set nama kolom baru
df_raw.columns = new_columns

# Temukan nama kolom yang sesuai
kode_obat_col = next(col for col in df_raw.columns if "Kode Obat" in col)
nama_obat_col = next(col for col in df_raw.columns if "Nama Obat" in col)
terjual_cols = [col for col in df_raw.columns if "Total Terjual" in col]

# Konversi kolom 'Kode Obat' ke string dan bersihkan nilai .0 jika perlu
df_raw[kode_obat_col] = (
    df_raw[kode_obat_col]
    .apply(lambda x: str(int(x)) if isinstance(x, float) and
x.is_integer() else str(x))
    .str.strip()
)

# Ambil subset data
df_terjual = df_raw[[kode_obat_col, nama_obat_col] + terjual_cols].copy()

# Tampilkan hasil
print("Kolom DataFrame:")
print(df_terjual.columns.tolist())

# Tampilkan 5 data pertama
print(df_terjual.head())

```

```

df_delta1 = df_terjual.copy()
df_delta1[terjual_cols] = df_terjual[terjual_cols].diff(axis=1).fillna(0)
df_delta1["Jenis"] = "Delta_1" #untuk memprediksi kecepatan

```

```
df_delta2 = df_terjual.copy()
df_delta2[terjual_cols] = df_delta1[terjual_cols].diff(axis=1).fillna(0)
df_delta2["Jenis"] = "Delta_2" #percepatan
```

```
df_terjual["Jenis"] = "Original"

df_final = pd.concat([df_terjual, df_delta1, df_delta2],
axis=0).reset_index(drop=True)

df_final.to_excel("output_differensial_diskrit.xlsx", index=False)

print(df_final.head(10))
```

```
import pandas as pd
import numpy as np
import tensorflow as tf
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense
import os

# Baca Excel, pastikan Kode Obat dibaca sebagai string
file_path = 'output_differensial_diskrit.xlsx'
df = pd.read_excel(file_path, dtype={'Kode Obat': str})

# Pastikan Kode Obat bersih dari spasi atau sisa karakter aneh
df['Kode Obat'] = df['Kode Obat'].str.strip()

# Ambil kolom bulan (Total Terjual)
month_cols = [col for col in df.columns if "Total Terjual" in col]

# Ambil list unik Kode Obat (sudah pasti string)
kode_obat_list = df['Kode Obat'].unique()

# Buat folder untuk simpan model
os.makedirs('saved_models', exist_ok=True)

# Fungsi bantu untuk buat input LSTM
def create_lstm_input(data, timesteps=3):
    X, y = [], []
    for i in range(len(data) - timesteps):
        window = data[i:i+timesteps, :]
        target = data[i+timesteps, 0]
```

```

        # Lewati jika seluruh nilai dalam window adalah 0 atau target 0
        if np.all(window == 0) or target == 0:
            continue

        X.append(window)
        y.append(target)
    return np.array(X), np.array(y)

# Loop tiap Kode Obat
for kode in kode_obat_list:
    subset = df[df['Kode Obat'] == kode]

    if subset.shape[0] != 3:
        print(f"Skipping {kode}: tidak ada 3 jenis data (Original,
Delta_1, Delta_2)")
        continue

    df_original = subset[subset['Jenis'] ==
'Original'][month_cols].values.flatten()
    df_delta1 = subset[subset['Jenis'] ==
'Delta_1'][month_cols].values.flatten()
    df_delta2 = subset[subset['Jenis'] ==
'Delta_2'][month_cols].values.flatten()

    combined = np.stack([df_original, df_delta1, df_delta2], axis=1)

    if np.isnan(combined).any():
        print(f"Skipping {kode}: ada data kosong")
        continue

    scaler = MinMaxScaler()
    combined_scaled = scaler.fit_transform(combined)

    X, y = create_lstm_input(combined_scaled, timesteps=3)
    if len(X) < 1:
        print(f"Skipping {kode}: tidak cukup data untuk sliding window")
        continue

    # Buat dan latih model
    model = Sequential()
    model.add(LSTM(64, activation='tanh', input_shape=(X.shape[1],
X.shape[2])))
    model.add(Dense(1))
    model.compile(optimizer='adam', loss='mse')
    model.fit(X, y, epochs=50, verbose=0)

    # Pastikan nama file disimpan sebagai string yang aman

```

```

    kode_str = kode.replace('/', '_').replace('\\', '_') # Jika ada
    karakter tidak valid
    model.save(f'saved_models/model_{kode_str}.h5')
    print(f"Model selesai untuk Kode Obat: {kode_str} dan disimpan.")

print("Semua model selesai dibuat.")

```

```

import os
import pandas as pd
from tensorflow.keras.models import load_model
from sklearn.preprocessing import MinMaxScaler

# Buat folder hasil prediksi jika belum ada
os.makedirs('hasil_prediksi', exist_ok=True)

# Buat penampung sheet name untuk hindari duplikat
used_sheet_names = set()

# Gunakan ExcelWriter dalam blok 'with'
with
pd.ExcelWriter('hasil_prediksi/prediksi_vs_aktual_baru_dengan_Tanh.xlsx',
engine='openpyxl') as writer:

    for kode in kode_obat_list:
        subset = df[df['Kode Obat'] == kode]

        if subset.shape[0] != 3:
            continue

        df_original = subset[subset['Jenis'] ==
'Original'][month_cols].values.flatten()
        df_delta1 = subset[subset['Jenis'] ==
'Delta_1'][month_cols].values.flatten()
        df_delta2 = subset[subset['Jenis'] ==
'Delta_2'][month_cols].values.flatten()

        if len(df_original) < 7:
            continue

        combined = np.stack([df_original, df_delta1, df_delta2], axis=1)

        if np.isnan(combined).any():
            continue

        scaler = MinMaxScaler()
        combined_scaled = scaler.fit_transform(combined)

```

```

X, y_true = create_lstm_input(combined_scaled, timesteps=3)
if len(X) < 1:
    continue

try:
    model = load_model(f'saved_models/model_{kode}.h5')
except:
    print(f"Model untuk kode {kode} tidak ditemukan.")
    continue

y_pred_scaled = model.predict(X, verbose=0)

dummy = np.zeros((len(y_pred_scaled), 3))
dummy[:, 0] = y_pred_scaled.flatten()
y_pred_inversed = scaler.inverse_transform(dummy)[:, 0]

dummy_y_true = np.zeros((len(y_true), 3))
dummy_y_true[:, 0] = y_true.flatten()
y_true_inversed = scaler.inverse_transform(dummy_y_true)[:, 0]

date_labels = month_cols[3:]

df_result = pd.DataFrame({
    'Bulan': date_labels[:len(y_true_inversed)],
    'Aktual Penjualan': y_true_inversed,
    'Prediksi Penjualan': y_pred_inversed
})

try:
    nama_obat = subset[subset['Jenis'] == 'Original']['Nama
Obat'].values[0]
except IndexError:
    nama_obat = "Unknown"

# Buat nama sheet gabungan
nama_sheet = f"{kode}_{nama_obat}"
illegal_chars = ['\\', '/', '*', '[', ']', ':', '?']
for char in illegal_chars:
    nama_sheet = nama_sheet.replace(char, '_')
nama_sheet = nama_sheet.strip()[:31]

# Tangani jika sheet name duplikat
original_sheet = nama_sheet
i = 1
while nama_sheet in used_sheet_names:
    nama_sheet = f"{original_sheet[:28]}_{i}"
    i += 1
used_sheet_names.add(nama_sheet)

```

```

df_result.to_excel(writer, sheet_name=nama_sheet, index=False)

print(f"Hasil prediksi disimpan untuk Kode Obat: {kode}")

# Writer otomatis ditutup setelah keluar dari blok 'with'
print("☑ Semua hasil prediksi berhasil disimpan ke Excel.")

```

```

import os
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_absolute_error, mean_squared_error
from tensorflow.keras.models import load_model

# Fungsi buat input LSTM + filter window nol
def create_lstm_input(data, timesteps=3):
    X, y = [], []
    for i in range(len(data) - timesteps):
        window = data[i:i+timesteps, :]
        target = data[i+timesteps, 0]
        if np.all(window == 0) or target == 0:
            continue
        X.append(window)
        y.append(target)
    return np.array(X), np.array(y)

# Load data
file_path = 'output_differensial_diskrit.xlsx'
df = pd.read_excel(file_path, dtype={'Kode Obat': str})

# Identifikasi kolom bulan dan kode obat
month_cols = [col for col in df.columns if "Total Terjual" in col]
kode_obat_list = df['Kode Obat'].unique()

# Pastikan direktori hasil ada
os.makedirs('hasil_prediksi', exist_ok=True)

# Buat writer Excel
writer = pd.ExcelWriter('hasil_prediksi/evaluasi_prediksi_tanh.xlsx',
engine='openpyxl')

# List hasil evaluasi
evaluasi_data = []

# Loop tiap obat

```

```

for kode in kode_obat_list:
    subset = df[df['Kode Obat'] == kode]

    if subset.shape[0] != 3:
        continue

    df_original = subset[subset['Jenis'] ==
'Original'][month_cols].values.flatten()
    df_delta1 = subset[subset['Jenis'] ==
'Delta_1'][month_cols].values.flatten()
    df_delta2 = subset[subset['Jenis'] ==
'Delta_2'][month_cols].values.flatten()

    if len(df_original) < 7:
        continue

    combined = np.stack([df_original, df_delta1, df_delta2], axis=1)

    if np.isnan(combined).any():
        continue

    scaler = MinMaxScaler()
    combined_scaled = scaler.fit_transform(combined)

    # Buat input LSTM
    X, y_true = create_lstm_input(combined_scaled, timesteps=3)
    if len(X) < 1:
        continue

    try:
        model = load_model(f'saved_models/model_{kode}.h5')
    except:
        print(f"Model untuk kode {kode} tidak ditemukan.")
        continue

    y_pred_scaled = model.predict(X, verbose=0)

    # Invers transform
    dummy = np.zeros((len(y_pred_scaled), 3))
    dummy[:, 0] = y_pred_scaled.flatten()
    y_pred_inversed = scaler.inverse_transform(dummy)[:, 0]

    dummy_y_true = np.zeros((len(y_true), 3))
    dummy_y_true[:, 0] = y_true.flatten()
    y_true_inversed = scaler.inverse_transform(dummy_y_true)[:, 0]

    # Hitung metrik evaluasi
    mae = mean_absolute_error(y_true_inversed, y_pred_inversed)

```

```

    mse = mean_squared_error(y_true_inversed, y_pred_inversed)
    rmse = np.sqrt(mse)
    mape = np.mean(np.abs((y_true_inversed - y_pred_inversed) /
y_true_inversed)) * 100
    total_pred = np.sum(y_pred_inversed)
    total_aktual = np.sum(y_true_inversed)
    nama_obat = subset['Nama Obat'].iloc[0] # Ambil nama obat

    evaluasi_data.append([kode, nama_obat, total_pred, total_aktual, mae,
mse, rmse, mape])
    print(f"Evaluasi selesai untuk Kode Obat: {kode}")

# Simpan tabel evaluasi ke Excel
df_evaluasi = pd.DataFrame(evaluasi_data, columns=[
    'Kode Obat', 'Nama Obat', 'Total Prediksi', 'Total Aktual', 'MAE',
'MSE', 'RMSE', 'MAPE'
])
df_evaluasi.to_excel(writer, sheet_name='Evaluasi_Prediksi', index=False)

# Selesai
writer.close()
print("Tabel evaluasi berhasil diekspor ke Excel.")

```

```

from tensorflow.keras.models import load_model
import openpyxl
import os
from sklearn.metrics import mean_squared_error, mean_absolute_error,
mean_absolute_percentage_error
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler

mse_list = []
mae_list = []
rmse_list = []
mape_list = []

# Buat folder hasil prediksi (jika belum ada)
os.makedirs('hasil_prediksi', exist_ok=True)

# Buat list gabungan semua hasil
all_results = []

for kode in kode_obat_list:
    subset = df[df['Kode Obat'] == kode]

    if subset.shape[0] != 3:

```

```

        continue

    df_original = subset[subset['Jenis'] ==
'Original'][month_cols].values.flatten()
    df_delta1 = subset[subset['Jenis'] ==
'Delta_1'][month_cols].values.flatten()
    df_delta2 = subset[subset['Jenis'] ==
'Delta_2'][month_cols].values.flatten()

    if len(df_original) < 7:
        continue

    combined = np.stack([df_original, df_delta1, df_delta2], axis=1)

    if np.isnan(combined).any():
        continue

    scaler = MinMaxScaler()
    combined_scaled = scaler.fit_transform(combined)

    X, y_true = create_lstm_input(combined_scaled, timesteps=3)
    if len(X) < 1:
        continue

    try:
        model = load_model(f'saved_models/model_{kode}.h5')
    except:
        print(f"Model untuk kode {kode} tidak ditemukan.")
        continue

    y_pred_scaled = model.predict(X, verbose=0)

    dummy = np.zeros((len(y_pred_scaled), 3))
    dummy[:, 0] = y_pred_scaled.flatten()
    y_pred_inversed = scaler.inverse_transform(dummy)[:, 0]

    dummy_y_true = np.zeros((len(y_true), 3))
    dummy_y_true[:, 0] = y_true.flatten()
    y_true_inversed = scaler.inverse_transform(dummy_y_true)[:, 0]

    date_labels = month_cols[3:]

    df_result = pd.DataFrame({
        'Kode Obat': kode,
        'Nama Obat': subset['Nama Obat'].values[0],
        'Bulan': date_labels[:len(y_true_inversed)],
        'Aktual': y_true_inversed,
        'Prediksi': y_pred_inversed
    })

```

```

    })

    df_result['Selisih'] = df_result['Prediksi'] - df_result['Aktual']
    df_result['Persentase Error (%)'] = np.where(
        df_result['Aktual'] != 0,
        np.abs(df_result['Selisih']) / df_result['Aktual'] * 100,
        0
    )

    # 🚫 Buang baris yang nilai aktualnya <= 0
    df_result = df_result[df_result['Aktual'] > 0]

    if df_result.empty:
        continue

    # ✅ Hitung MSE, MAE, RMSE, dan MAPE
    mse = mean_squared_error(df_result['Aktual'], df_result['Prediksi'])
    mae = mean_absolute_error(df_result['Aktual'], df_result['Prediksi'])
    rmse = np.sqrt(mse)
    mape = mean_absolute_percentage_error(df_result['Aktual'],
    df_result['Prediksi']) * 100

    mse_list.append(mse)
    mae_list.append(mae)
    rmse_list.append(rmse)
    mape_list.append(mape)

    # ✅ Simpan hasil prediksi
    all_results.append(df_result)

# Gabungkan semua hasil jadi satu sheet
if all_results:
    final_df = pd.concat(all_results, ignore_index=True)

    final_df.to_excel('hasil_prediksi/prediksi_vs_aktual_all_obat_tanh.xlsx',
    index=False)
    print("✅ File Excel gabungan berhasil disimpan:
    hasil_prediksi/prediksi_vs_aktual_all_obat_tanh.xlsx")
else:
    print("⚠️ Tidak ada hasil yang bisa diekspor.")

# Tampilkan error akumulasi
if mse_list:
    avg_mse = np.mean(mse_list)
    avg_mae = np.mean(mae_list)
    avg_rmse = np.mean(rmse_list)
    avg_mape = np.mean(mape_list)

```

```

print("\n📊 RATA-RATA ERROR (SEMUA OBAT):")
print(f"◇ MSE : {avg_mse:.4f}")
print(f"◇ MAE : {avg_mae:.4f}")
print(f"◇ RMSE : {avg_rmse:.4f}")
print(f"◇ MAPE : {avg_mape:.2f}%")
else:
    print("\n⚠️ Tidak ada data yang valid untuk dihitung error-nya.")

```

```

import pandas as pd
import numpy as np
import tensorflow as tf
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense
from sklearn.metrics import mean_squared_error, mean_absolute_error,
mean_absolute_percentage_error
import os

# Load file
file_path = 'output_differensial_diskrit.xlsx'
df = pd.read_excel(file_path)

# Ambil kolom bulan dan kode obat
month_cols = [col for col in df.columns if "Total Terjual" in col]
kode_obat_list = df['Kode Obat'].unique()

# Folder simpan model
os.makedirs('saved_models', exist_ok=True)

# Fungsi buat input LSTM + filter window nol
def create_lstm_input(data, timesteps=3):
    X, y = [], []
    for i in range(len(data) - timesteps):
        window = data[i:i+timesteps, :]
        target = data[i+timesteps, 0]
        if np.all(window == 0) or target == 0:
            continue
        X.append(window)
        y.append(target)
    return np.array(X), np.array(y)

# Fungsi validasi silang berbasis time series
def walk_forward_validation(X, y, n_splits=3, epochs=50):
    fold_size = len(X) // (n_splits + 1)
    mse_list, mae_list, rmse_list, mape_list = [], [], [], []

    for i in range(n_splits):

```

```

split = (i + 1) * fold_size
X_train, y_train = X[:split], y[:split]
X_test, y_test = X[split:split + fold_size], y[split:split +
fold_size]

if len(X_test) == 0:
    continue

model = Sequential()
model.add(LSTM(64, activation='tanh', input_shape=(X.shape[1],
X.shape[2])))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')
model.fit(X_train, y_train, epochs=epochs, verbose=0)

y_pred = model.predict(X_test, verbose=0)

mse = mean_squared_error(y_test, y_pred)
mae = mean_absolute_error(y_test, y_pred)
rmse = np.sqrt(mse)
mape = mean_absolute_percentage_error(y_test, y_pred) * 100

mse_list.append(mse)
mae_list.append(mae)
rmse_list.append(rmse)
mape_list.append(mape)

return {
    'mse': np.mean(mse_list),
    'mae': np.mean(mae_list),
    'rmse': np.mean(rmse_list),
    'mape': np.mean(mape_list)
}

# List untuk hasil evaluasi
evaluasi_semua_obat = []

# Loop setiap obat
for kode in kode_obat_list:
    subset = df[df['Kode Obat'] == kode]

    if subset.shape[0] != 3:
        print(f"⏏ Skipping {kode}: tidak ada 3 jenis data (Original,
Delta_1, Delta_2)")
        continue

    df_original = subset[subset['Jenis'] ==
'Original'][month_cols].values.flatten()

```

```

df_delta1 = subset[subset['Jenis'] ==
'Delta_1'][month_cols].values.flatten()
df_delta2 = subset[subset['Jenis'] ==
'Delta_2'][month_cols].values.flatten()

combined = np.stack([df_original, df_delta1, df_delta2], axis=1)

if np.isnan(combined).any():
    print(f"⏏ Skipping {kode}: ada data kosong (NaN)")
    continue

scaler = MinMaxScaler()
combined_scaled = scaler.fit_transform(combined)

X, y = create_lstm_input(combined_scaled, timesteps=3)
if len(X) < 1:
    print(f"⏏ Skipping {kode}: tidak cukup data setelah filter")
    continue

result = walk_forward_validation(X, y, n_splits=3, epochs=50)

evaluasi_semua_obat.append({
    'Kode Obat': kode,
    'MSE': result['mse'],
    'MAE': result['mae'],
    'RMSE': result['rmse'],
    'MAPE (%)': result['mape']
})

print(f"✅ [{kode}] MSE: {result['mse']:.2f}, MAE:
{result['mae']:.2f}, RMSE: {result['rmse']:.2f}, MAPE:
{result['mape']:.2f}%")

# Simpan evaluasi ke Excel
if evaluasi_semua_obat:
    df_eval = pd.DataFrame(evaluasi_semua_obat)
    df_eval.to_excel("hasil_validasi_crossval.xlsx", index=False)
    print(f"\n✅ Hasil evaluasi cross-validation disimpan ke:
hasil_validasi_crossval.xlsx")
else:
    print(f"⚠ Tidak ada model yang berhasil divalidasi.")
print("Semua model selesai dibuat.")

```



**MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR
UPT PERPUSTAKAAN DAN PENERBITAN**

Alamat kantor: Jl.Sultan Alauddin NO.259 Makassar 90221 Tlp.(0411) 866972,881593, Fax.(0411) 865588

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

SURAT KETERANGAN BEBAS PLAGIAT

UPT Perpustakaan dan Penerbitan Universitas Muhammadiyah Makassar,
Menerangkan bahwa mahasiswa yang tersebut namanya di bawah ini:

Nama : Chalidah Azzahrah H

Nim : 105841107321

Program Studi : Teknik Informatika

Dengan nilai:

No	Bab	Nilai	Ambang Batas
1	Bab 1	8%	10 %
2	Bab 2	15%	25 %
3	Bab 3	9%	10 %
4	Bab 4	2%	10 %
5	Bab 5	2%	5 %

Dinyatakan telah lulus cek plagiat yang diadakan oleh UPT- Perpustakaan dan Penerbitan
Universitas Muhammadiyah Makassar Menggunakan Aplikasi Turnitin.

Demikian surat keterangan ini diberikan kepada yang bersangkutan untuk dipergunakan
seperlunya.

Makassar, 26 Agustus 2025

Mengetahui,

Kepala UPT- Perpustakaan dan Penerbitan,



Nursimah, S.Hum, M.I.P

NBM. 964 591

Bab I Chalidah Azzahrah H

105841107321

by Tahap Tutup

Submission date: 22-Aug-2025 01:00PM (UTC+0700)

Submission ID: 2733296596

File name: BAB_I_103.docx (254.6K)

Word count: 1276

Character count: 7986



Dipindai dengan CamScanner

Bab I Chalidah Azzahrah H 105841107321

ORIGINALITY REPORT

8%

SIMILARITY INDEX

4%

INTERNET SOURCES

4%

PUBLICATIONS

8%

STUDENT PAPERS

PRIMARY SOURCES

1

Submitted to Udayana University

Student Paper

2%

2

repec.org

Internet Source

2%

3

doku.pub

Internet Source

2%

4

Submitted to Universitas Maritim Raja Ali Haji

Student Paper

2%

Exclude quotes

Off

Exclude matches

< 2%

Exclude bibliography

Off



Dipindai dengan CamScanner

Bab II Chalidah Azzahrah H
105841107321

by Tahap Tutup

Submission date: 21-Aug-2025 12:11PM (UTC+0700)

Submission ID: 2732732365

File name: BAB_2_CHALIDAH.docx (38.79K)

Word count: 2338

Character count: 14593

Bab II Chalidah Azzahrah H 105841107321

ORIGINALITY REPORT

15%

SIMILARITY INDEX

18%

INTERNET SOURCES



0%

STUDENT PAPERS

PRIMARY SOURCES

1	digilibadmin.unismuh.ac.id Internet Source	3%
2	ejournal.itn.ac.id Internet Source	2%
3	ejournal.unsrat.ac.id Internet Source	2%
4	ojs.unikom.ac.id Internet Source	2%
5	jiki.jurnal-id.com Internet Source	2%
6	doku.pub Internet Source	2%
7	jurnalfpk.uinsby.ac.id Internet Source	2%

Exclude quotes Off

Exclude matches < 2%

Exclude bibliography Off



Dipindai dengan CamScanner

Bab III Chalidah Azzahrah H
105841107321

by Tahap Tutup

Submission date: 22-Aug-2025 01:17PM (UTC+0700)

Submission ID: 2733302853

File name: BAB_III.docx (259.27K)

Word count: 1276

Character count: 7986

Bab III Chalidah Azzahrah H.105841107321

ORIGINALITY REPORT

9%
SIMILARITY INDEX

5%
INTERNET SOURCES

4%
PUBLICATIONS

8%
STUDENT PAPERS

PRIMARY SOURCES

- 1** Submitted to Udayana University
Student Paper 2%
- 2** repec.org
Internet Source 2%
- 3** doku.pub
Internet Source 2%
- 4** Submitted to Universitas Maritim Raja Ali Haji
Student Paper 2%
- 5** docplayer.info
Internet Source 2%

Exclude quotes Off
Exclude bibliography Off

Exclude matches < 2%

Bab IV Chalidah Azzahrah H 105841107321

by Tahap Tutup

Submission date: 21-Aug-2025 12:13PM (UTC+0700)

Submission ID: 2732733008

File name: BAB_4_CHALIDAH.docx (1.93M)

Word count: 2377

Character count: 14703

Bab IV Chalidah Azzahrah H 105841107321

ORIGINALITY REPORT

2%	2%	1%	1%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	www.grafiati.com Internet Source	1%
2	cowles.econ.yale.edu Internet Source	<1%
3	Submitted to Universitas Muhammadiyah Palembang Student Paper	<1%
4	Ahmad Fauzi, Nurlaelatul Maulidah, Riki Supriyadi, Hiya Nalatissifa, Sri Diantika. "Prediksi Harga Properti Di Indonesia Menggunakan Algoritma Random Forest", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1%
5	es.scribd.com Internet Source	<1%

Exclude quotes

Off

Exclude matches

Off

Exclude bibliography

Off



Dipindai dengan CamScanner

Bab V Chalidah Azzahrah H

105841107321

by Tahap Tutup

Submission date: 22-Aug-2025 01:05PM (UTC+0700)

Submission ID: 2733298593

File name: BAB_V_125.docx (18.46k)

Word count: 357

Character count: 2411



Dipindai dengan CamScanner

Bab V Chalidah Azzahrah H 105841107321

ORIGINALITY REPORT

2%	2%	0%	0%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	lib.ui.ac.id	2%
	Internet Source	

Exclude quotes

Off

Exclude matches

< 2%

Exclude bibliography

Off