

**ANALISIS PENGARUH *LEARNING RATE* DALAM MENENTUKAN *MEAN SQUARE ERROR (MSE)* PADA ALGORITMA *LONG SHORT TERM MEMORY (LSTM)***

**SKRIPSI**

**TITA LAROSE TOGATOROP**

**198160081**



**FAKULTAS TEKNIK**

**PROGRAM STUDI TEKNIK INFORMATIKA**

**UNIVERSITAS MEDAN AREA**

**2024**

**UNIVERSITAS MEDAN AREA**

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Document Accepted 7/11/24

Access From (repository.uma.ac.id)7/11/24

**ANALISIS PENGARUH *LEARNING RATE* DALAM MENENTUKAN *MEAN SQUARE ERROR (MSE)* PADA ALGORITMA *LONG SHORT TERM MEMORY (LSTM)***

**SKRIPSI**

Diajukan Sebagai salah satu syarat untuk memperoleh

Gelar Sarjana di Fakultas Teknik

Universitas Medan Area



Oleh :

**TITA LAROSE TOGATOROP**

**198160081**

**FAKULTAS TEKNIK**

**PROGRAM STUDI TEKNIK INFORMATIKA**

**UNIVERSITAS MEDAN AREA**

**2024**

**UNIVERSITAS MEDAN AREA**

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Document Accepted 7/11/24

Access From (repository.uma.ac.id)7/11/24

## HALAMAN PENGESAHAN SKRIPSI

**HALAMAN PENGESAHAN SKRIPSI**

Judul : Analisis Pengaruh *Learning Rate* Dalam Menentukan *Mean Square Error (MSE)* Pada Algoritma *Long Short Term Memory (LSTM)*

Nama Mahasiswa : Tita Larose Togatorop

NPM : 198160081

Fakultas : Teknik

Prodi : Informatika

Disetujui Oleh Komisi Pembimbing

Pembimbing

Susilawati, S.Kom, M.Kom

Dekan Fakultas Teknik

Ketua Prodi Teknik Informatika

  
Dr. Bag. Supriatno S.T, M.T  
NIDN: 0102027402

  
Rizki Moliono, S.Kom, M.Kom  
NIDN: 0109033902

Tanggal Lulus : 05 September 2021

iii

CS Dipindai dengan CamScanner

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

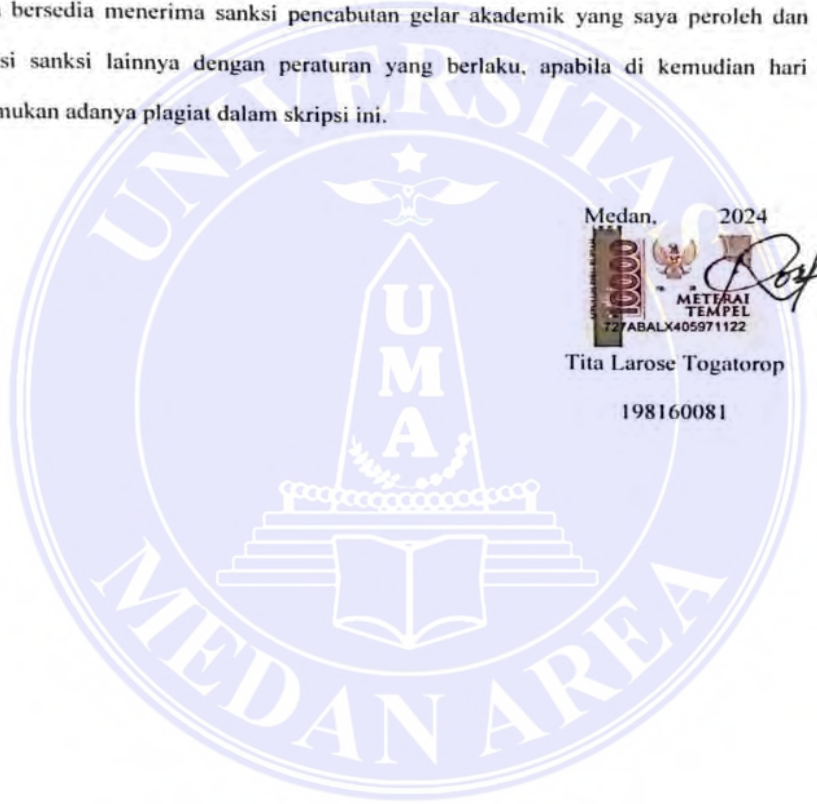
Document Accepted 7/11/24

Access From (repository.uma.ac.id)7/11/24

## HALAMAN PERNYATAAN

### HALAMAN PERNYATAAN

Saya menyatakan bahwa skripsi yang saya susun, sebagai syarat memperoleh gelar sarjana merupakan hasil karya tulis saya sendiri. Adapun bagian-bagian tertentu dalam penulisan skripsi ini yang saya kutip dari hasil karya orang lain telah dituliskan sumbernya secara jelas sesuai dengan norma, kaidah, dan etika penulisan ilmiah. Saya bersedia menerima sanksi pencabutan gelar akademik yang saya peroleh dan sanksi lainnya dengan peraturan yang berlaku, apabila di kemudian hari ditemukan adanya plagiat dalam skripsi ini.



Medan, 2024  
1000  
METRAI  
TEMPEL  
727ABALX405971122  
Tita Larose Togatorop  
198160081

## HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS

---

### HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS

---

Sebagai sivitas akademik Universitas Medan Area, saya yang bertanda tangan di bawah ini:

Nama : Tita Larose Togatorop  
NPM : 198160081  
Program Studi : Teknik Informatika  
Fakultas : Teknik  
Jenis karya : Tugas Akhir / Skripsi

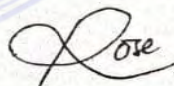
Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Medan Area **Hak Bebas Royalti Noneksklusif (*Non-exclusive Royalty-Free Right*)** atas karya ilmiah saya yang berjudul: Analisis Pengaruh Learning Rate Dalam Menentukan Mean Square Error (MSE) Pada Algoritma Long Short Term Memory (LSTM)

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Medan Area berhak menyimpan, mengalih media/format-kan, mengelola dalam bentuk pangkalan data (database), merawat, dan mempublikasikan tugas akhir/skripsi/tesis saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Medan  
Pada tanggal .....

Yang menyatakan



(Tita Larose Togatorop)

## ABSTRAK

*Long Short Term Memory (LSTM)* merupakan salah satu algoritma *Machine Learning (ML)* berbasis pendekatan *Reccurent Neural Network (RNN)*. LSTM memiliki empat lapisan *neuron* yang biasa disebut gerbang untuk mengatur memori setiap *neuron*, sehingga dapat mendeteksi data mana yang perlu dan tidak perlu digunakan. Salah satu komponen penting yang digunakan LSTM untuk menentukan nilai *Mean Square Error (MSE)* adalah *learning rate*. Pada penelitian ini *dataset* yang digunakan adalah penggunaan aplikasi di Kominfo sebanyak 6196. Adapun atribut meliputi nama pengguna, aplikasi, tanggal akses, dan bandwidth yang digunakan (GB). Data dibagi menjadi data *training* sebesar 80% dan data *testing* sebesar 20%. Model dilatih untuk 150 *epoch* dengan *batch size* 32. Dalam penelitian ini, peneliti telah menguji pengaruh berbagai nilai *learning rate* terhadap performa model LSTM dalam menganalisis nilai yang paling efektif dalam memproses MSE pada model LSTM. *Learning rate* yang digunakan adalah 0.1, 0.01, dan 0.001. Hasilnya menunjukkan bahwa *learning rate* 0.001 memberikan performa terbaik dengan menunjukkan hasil yang cenderung stabil dengan fluktuasi yang minimal dan nilai MSE yang konsisten lebih rendah pada *epoch* 100 dan *epoch* 150. *Learning rate* 0.001 memberikan performa terbaik dengan menunjukkan hasil yang cenderung stabil dengan fluktuasi yang minimal dan nilai MSE yang konsisten lebih rendah pada *epoch* 115 yaitu MSE 0,083705828. Pemilihan *learning rate* yang tepat sangat penting untuk optimisasi model LSTM. *Learning rate* 0.001 menunjukkan hasil terbaik dalam konteks penelitian ini, sehingga dapat direkomendasikan untuk penelitian selanjutnya.

**Kata Kunci : Reccurent Neural Network (RNN), Mean Square Error (MSE), Long Short Term Memory (LSTM).**

## ABSTRACT

### ABSTRACT

Long Short Term Memory (LSTM) is a Machine Learning (ML) algorithm based on the Recurrent Neural Network (RNN) approach. LSTM has four layers of neurons, commonly referred to as gates, which manage the memory of each neuron, allowing it to detect which data is necessary and which is not. One important component that LSTM uses to determine the Mean Square Error (MSE) is the learning rate. The learning rate plays a crucial role in calculating weight corrections during the training process. Choosing the learning rate is indeed a challenge, as a value that is too small will result in lengthy training times, while a value that is too large will lead to suboptimal learning due to rapid adjustments and instability during training. The chosen learning rate significantly impacts the results of the ML process. In this research, the dataset used consisted of application usage data from Kominfo, totaling 6,196 entries. The attributes included username, application, access date, and bandwidth used (GB). The data was divided into 80% training data and 20% testing data. The model was trained for 150 epochs with a batch size of 32. The researcher tested the effects of various learning rates on the performance of the LSTM model to analyze which learning rate was most effective in processing MSE. The learning rates used were 0.1, 0.01, and 0.001. The results showed that a learning rate of 0.001 provided the best performance, exhibiting stable results with minimal fluctuations and consistently lower MSE values at epoch 100 and epoch 150. Specifically, at epoch 115, the MSE reached 0.083705828. This research highlights the importance of selecting the appropriate learning rate for optimizing the LSTM model. The learning rate of 0.001 proved to be the most effective in this research context, making it a recommendation for future researches.

**Keywords:** Recurrent Neural Network (RNN), Mean Square Error (MSE), Long Short Term Memory (LSTM).

## KATA PENGANTAR

Puji dan syukur kehadiran Tuhan Yang Maha Esa yang telah melimpahkan rahmat, kebijaksanaan dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini dengan judul “**Analisis Pengaruh *Learning Rate* Dalam Menentukan *Mean Square Error (MSE)* Pada Algoritma *Long Short Term Memory (LSTM)*”** sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer di Fakultas Teknik Universitas Medan Area. Pada kesempatan ini penulis ingin menyampaikan rasa hormat dan terimakasih yang sebesar – besarnya kepada :

1. Teristimewa untuk kedua orang tuaku, Bapak Barisan Togatorop dan Ibu Lasmawarni Lumban Gaol yang menjadi pemberi semangat utama bagi penulis, Terimakasih atas segalanya dan semoga saya dapat menjadi anak yang selalu membanggakan, membahagiakan dan berbakti.
2. Abang dan adikku terkasih beserta keluarga semoga kelak kita menjadi orang yang sukses di tiap bidang kita masing – masing dan membanggakan semua keluarga kita.
3. Bapak Prof. Dr. Dadan Ramdan, M.Eng, M.Sc. selaku Rektor Universitas Medan Area.
4. Bapak Dr.Eng Supriatno S.T, M.T sebagai Dekan Fakultas Teknik Universitas Medan Area.
5. Bapak Rizki Muliono, S.Kom., M.Kom selaku Kepala Program Studi Teknik Informatika Universitas Medan Area.

6. Ibu Susilawati, S.Kom, M.Kom selaku Dosen pembimbing yang telah membantu penulis sehingga penulis dapat menyelesaikan skripsi ini.
7. Seluruh Dosen Pengajar di Fakultas Teknik Informatika Universitas Medan Area yang penuh dedikasi dalam memberikan ilmu yang bermanfaat bagi penulis serta para Staf dan Pegawai Fakultas Teknik Informatika Universitas Medan Area, terutama Bang Robby Kurniawan Sari Damanik, ST yang selalu membantu dalam pemberkasan dan informasi mulai dari judul sampai ujian.
8. Narasumber dalam penulisan skripsi ini, bapak Batara Franz Siregar, SE selaku Kepala Dinas Kominfo, Syukur B. Marbun, S.Kom selaku Kepala Bidang Informatika, dan seluruh staf yang ada di kantor Kominfo yang bersedia meluangkan waktunya pada saat penulis melakukan penelitian.
9. Keluarga Besar Op. Martupa Togatorop/br. Siburian. Terimakasih Oppungku M. Togatorop dan Br. Siburian, serta Bapa 1 sampai Bapa pudan, Inang 1 sampai Inang pudan, Namboru, Abang, Kakak, Adek, Lae, Ito, pariban yang tidak bisa saya sebut satu per satu.
10. Keluarga Besar Op. Harnoi Lumban Gaol/br. Bakara. Terimakasih Oppungku Lumban Gaol dan B. Br. Bakara, serta semua Tulang, Nantulang, Tante, Uda, Lae, yang tidak bisa saya sebut satu per satu.
11. Kepada sahabat baik Sri Adelina Situmorang, , terimakasih senantiasa menemani penulis pada proses penulisan skripsi ini. Terimakasih senantiasa memberikan dukungan sehingga penulis mampu menyelesaikan skripsi ini dengan baik.
12. Seluruh teman-teman yang sudah memberikan dukungannya selama penulisan skripsi ini, khususnya teman-teman Teknik Informatika angkatan 2019.

13. Teman-teman alumni SMK N 2 Doloksanggul Lestari Indah Florentina Purba, Lasdiarta Sihite, Lista Simatupang, Santa Maria Simbolon, Ninik Hotmauli Hutasoit, Purnama Simamora, Dewi Sitorus, Elisabeth Lumban Batu, Rosianna Ayu Aritonang, Putri Kim Sihotang dan saudara yang tak bisa kusebut satu per satu.
14. Semua anggota PMDH yang tidak bisa saya sebutkan namanya satu per satu yang pernah berperan di dalam mengurangi sedikit banyaknya beban yang dihadapi oleh penulis.
15. Almamater tercinta Fakultas Teknik Universitas Medan tempatku menimba ilmu, pengalaman, teman dan semoga kelak dapat membanggakanmu.
16. Semoga Tuhan Yesus Kristus menyertai kita semua dan memberi kasih karunia pribadi lepas pribadi. Akhir kata, penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan, akan tetapi semoga skripsi ini dapat bermanfaat untuk menambah wawasan keilmuan bagi pembaca pada umumnya dan bagi penulis khususnya.

Medan, 2024

Penulis,

Tita Larose Togatorop

## RIWAYAT PENULIS

Nama lengkap penulis adalah Tita Larose Togatorop, dilahirkan di Pollung Kabupaten Humbang Hasundutan, 20 Desember 2000, anak ketiga dari empat bersaudara dari Bapak Barisan Togatorop dan Ibu Lasmawarni Lumban Gaol. Penulis menempuh Pendidikan di Sekolah Dasar 175782 Pollung dan selesai pada tahun 2013, Sekolah Menengah Pertama Negeri 4 Pollung yang selesai pada tahun 2016, dan Sekolah Menengah Kejuruan Negeri 2 Doloksanggul yang diselesaikan pada tahun 2019.

Pada tahun 2019 hingga saat ini, penulis terdaftar sebagai mahasiswa Jurusan Teknik Informatika Universitas Medan Area. Penulis juga melaksanakan program Kerja Praktek (KP) di Dinas Komunikasi dan Informatika (KOMINFO) Kabupaten Dairi, Kecamatan Sidikalang, selama 30 hari pada bulan agustus. Penulis aktif berpartisipasi dalam berbagai kegiatan kepemudaan di Gereja.

## DAFTAR ISI

<b>HALAMAN PENGESAHAN SKRIPSI</b> .....	<b>iii</b>
<b>HALAMAN PERNYATAAN</b> .....	<b>iv</b>
<b>HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI</b> .....	<b>v</b>
<b>ABSTRAK</b> .....	<b>vi</b>
<b>ABSTRACT</b> .....	<b>vii</b>
<b>KATA PENGANTAR</b> .....	<b>viii</b>
<b>RIWAYAT PENULIS</b> .....	<b>xi</b>
<b>DAFTAR ISI</b> .....	<b>xii</b>
<b>DAFTAR TABEL</b> .....	<b>xiv</b>
<b>DAFTAR GAMBAR</b> .....	<b>xv</b>
<b>BAB I PENDAHULUAN</b> .....	<b>1</b>
1.1    Latar Belakang .....	1
1.2    Rumusan Masalah .....	4
1.3    Batasan Masalah .....	4
1.4    Tujuan Penelitian .....	4
1.5    Manfaat Penelitian .....	5
1.6    Sistematika Penulisan.....	5
<b>BAB II TINJAUAN PUSTAKA</b> .....	<b>7</b>
2.1 <i>Learning Rate</i> .....	7
2.2 <i>Mean Square Error (MSE)</i> .....	7
2.3 <i>Neural Network (NN)</i> .....	8
2.4 <i>Reccurent Neural Network (RNN)</i> .....	9
2.5 <i>Long Short Term Memory (LSTM)</i> .....	10
2.6 <i>Flowchart</i> .....	14
2.7 <i>Python</i> .....	16
2.8 <i>Google Colab</i> .....	17
2.9    Penelitian Terdahulu .....	18
<b>BAB III METODE PENELITIAN</b> .....	<b>22</b>

3.1	Tahapan Penelitian .....	22
3.1.1	Studi Literatur .....	23
3.1.2	Pengumpulan Data.....	23
3.1.3	Pengolahan Data.....	24
<b>BAB IV HASIL DAN PEMBAHASAN.....</b>		<b>25</b>
4.1	Hasil .....	25
4.1.1	Pengujian dengan <i>Learning Rate</i> 0,1.....	25
4.1.2	Pengujian dengan <i>Learning Rate</i> 0, 01.....	26
4.1.3	Pengujian dengan <i>Learning Rate</i> 0, 001.....	27
4.2	Pembahasan .....	32
<b>BAB V KESIMPULAN DAN SARAN.....</b>		<b>39</b>
5.1	Kesimpulan.....	39
5.2	Saran.....	40
<b>DAFTAR PUSTAKA.....</b>		<b>41</b>
<b>LAMPIRAN .....</b>		<b>46</b>
Lampiran I : Source Code.....		46
Lampiran II : Hasil Pengujian.....		49


## DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu.....	19
Tabel 3. 1 Data Akses Penggunaan Aplikasi di Koinfo.....	23
Tabel 4. 1 Pengujian <i>Learning rate</i> 0.1 .....	25
Tabel 4. 2 Pengujian <i>Learning Rate</i> 0.01.....	26
Tabel 4. 3 pengujian Learning Rate 0.001 .....	27



## DAFTAR GAMBAR

Gambar 2. 1 <i>Neuron LSTM</i> (Qotrunnada, 2022).....	11
Gambar 2. 2 Simbol <i>Flowchart</i> (Fauzi, 2020) .....	16
Gambar 4. 1 Pengujian dengan 150 Epoch .....	31
Gambar 4. 2 <i>Import &amp; Read Dataset</i> .....	33
Gambar 4. 3 <i>Preprocessing Data</i> .....	34
Gambar 4. 4 Model LSTM.....	35
Gambar 4. 5 <i>Learning Rate</i> .....	37
Gambar 4. 6 Membuat <i>Line Chart</i> .....	37



# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

*Machine Learning* adalah salah satu teknologi baru yang paling kuat dalam kecerdasan buatan dan interaksi manusia, menjadikannya terobosan baru dalam Pendidikan. *Machine Learning* berpotensi berdampak pada banyak bidang, termasuk statistic, matematika, dan banyak bidang teori ilmu komputer (Fathurohman, 2021). *Machine Learning (ML)* adalah aplikasi *Artificial Inteligent (AI)* yang berfokus pada pengembangan sistem yang dapat belajar sendiri tanpa memerlukan pemrograman berulang-ulang. ML memerlukan pelatihan data sebagai proses pembelajaran sebelum menghasilkan *output*. Jadi, secara sederhana, ML adalah pemrograman komputer yang menggunakan sekumpulan data *training* atau pengalaman sebelumnya (*past experience*) untuk mencapai standar atau kinerja tertentu. (Chazar & Erawan, 2020). Intinya, tujuan ML adalah mengembangkan algoritma yang dapat menjalankan system pembelajaran otonom dengan banyak usaha dan sedikit masukan dari manusia (Fathurohman, 2021).

*Long Short Term Memory (LSTM)* adalah algoritma ML berdasarkan pendekatan *Recurent Neural Network (RNN)*. LSTM memiliki empat lapisan neuron yang biasa disebut gerbang, yang dapat mengatur memori setiap *neuron* untuk mendeteksi data mana yang sebaiknya digunakan dan tidak digunakan (Lattifia dkk, 2022). LSTM

merupakan salah satu metode RNN yang terbukti berhasil dalam memprediksi data *time series* (Ashari & Sadikin, 2020). RNN mempunyai masalah gradien hilang, sehingga RNN dapat menggunakan informasi yang sebelumnya direkam pada periode waktu yang berbeda. Sistem ini dibuat dengan menggunakan metode regresi LSTM (Ashari & Sadikin, 2020). Kelebihan metode LSTM dibandingkan metode RNN lainnya adalah LSTM dapat menyimpan data time-series atau data dengan informasi jangka panjang, dan sel-sel yang termasuk dalam LSTM mempunyai kemampuan untuk menyimpan informasi sebelumnya (Lattifia dkk, 2022).

Pengukuran kinerja LSTM dilakukan melalui *Mean Square Error (MSE)* (Novian dkk, 2023). Salah satu komponen utama yang digunakan LSTM untuk menentukan nilai MSE adalah *Learning rate*. *Learning rate* memegang peranan yang sangat penting dalam perhitungan koreksi bobot selama proses *training*. Memilih *learning rate* itu sendiri merupakan hal yang sulit, karena nilai yang terlalu kecil akan membutuhkan waktu yang lama untuk dipelajari, dan nilai yang terlalu besar akan menyebabkan pembelajaran menjadi terlalu cepat sehingga membuat proses pembelajaran menjadi tidak stabil. Tingkat *learning rate* yang dimasukkan pasti mempengaruhi hasil proses ML (Rochmawati dkk, 2021). *Learning rate* berperan sebagai parameter *training* dan menghitung jumlah langkah pada setiap iterasi untuk mendapatkan nilai minimum pada *loss function*. Hal ini didasarkan pada upaya untuk mencapai *learning rate* yang diwakili oleh vektor gradien dengan nilai negatif, dan nilai *learning rate* terbaik berusaha mencapai nilai minimum, yaitu *output* memiliki nilai dengan bobot yang stabil yang menunjukkan memiliki nilai rata-rata (Sukmana dkk, 2023). Lebih lanjut, fungsi *learning rate* adalah untuk meningkatkan komponen penting yang ada dalam

data masukan dan mengurangi keterlibatan varian yang tidak relevan selama pemrosesan data (Sukmana dkk, 2023).

Terdapat beberapa penelitian terdahulu yang sudah meneliti tentang *learning rate* menggunakan jaringan saraf tiruan. Dalam penelitian yang dilakukan oleh (Susilawati dkk, 2019) tentang Analisis Pengaruh Fungsi Aktivasi, *Learning Rate* Dan Momentum Dalam Menentukan *Mean Square Error (MSE)* Pada Jaringan Saraf *Restricted Boltzmann Machines (RBM)*. Kinerja RBM sangat dipengaruhi oleh pemilihan nilai parameter *Learning rate*, momentum, dan fungsi aktivasi yang sesuai, terutama saat menentukan *Mean Squared Error (MSE)* dan persentase akurasi pengenalan untuk *dataset*.

Penelitian yang dilakukan oleh (Supriyanto dkk, 2022) tentang Pengaruh Nilai *Hidden Layer* dan *Learning Rate* Terhadap Kecepatan Pelatihan Jaringan Syaraf Tiruan *Backpropagation*. Pelatihan jaringan menghasilkan parameter *hidden layer* sebanyak 12 *neuron* selama waktu pelatihan 3 menit 44 detik dengan *error MSE* sebesar 1.654151. Jumlah iterasi yang diperlukan pada arsitektur *hidden layer* 12 *neuron* adalah 100.000 iterasi dengan waktu *training* 21 menit 52 detik. Sedangkan parameter *learning rate* menggunakan 12 *neuron* dan 100.000 iterasi, nilai *learning rate* yang benar untuk pelatihan adalah 0,5, waktu yang diperlukan untuk pelatihan adalah 18 menit 35 detik, dan *MSE error* adalah 0,302868.

Berdasarkan penelitian terdahulu yang sudah dilakukan, Penelitian ini bertujuan untuk menganalisis pengaruh *learning rate* dalam menentukan *Mean Square Error (MSE)* pada algoritma *Long Short Term Memory (LSTM)* dimana setiap perubahan bobot yang terjadi selama siklus pola pembelajaran diharapkan dapat mengurangi

besarnya nilai kesalahan MSE, sampai diperoleh tingkat kesalahan yang paling minimum dengan bobot yang stabil.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang yang sudah dijelaskan di atas, maka masalah yang akan dibahas yaitu Bagaimana menganalisis pengaruh learning rate dalam menentukan MSE pada algoritma LSTM?

## 1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah :

1. Data yang digunakan dalam proses penelitian ini berupa historis akses penggunaan aplikasi di Kominfo.
2. Data historis yang digunakan adalah data satu tahun terakhir.
3. Learning rate yang digunakan yaitu 0.1, 0.01, dan 0,001
4. Output yang dihasilkan dari penelitian ini adalah untuk menganalisis besarnya nilai kesalahan MSE sampai diperoleh tingkat kesalahan yang paling minimum dengan bobot yang stabil.

## 1.4 Tujuan Penelitian

Agar penelitian yang dilakukan ini sesuai dengan permasalahan yang dibahas, maka tujuan penelitian ini adalah untuk menganalisis besarnya nilai kesalahan MSE sampai diperoleh tingkat kesalahan yang paling minimum dengan bobot yang stabil.

## 1.5 Manfaat Penelitian

Adapun manfaat yang dapat diperoleh dari penelitian ini yaitu menambah wawasan dan pengetahuan bagi penulis dalam menganalisis nilai learning rate yang paling efektif dalam memproses MSE pada model LSTM.

## 1.6 Sistematika Penulisan

Skema penulisan penelitian ini disajikan untuk memudahkan pembaca memahami isi penelitian ini. Berikut adalah gambaran metodologi penulisan penelitian ini:

### **BAB I : PENDAHULUAN**

Bab ini berisi tentang latar belakang, rumusan masalah, tujuan penelitian, Batasan masalah, manfaat penelitian dan sistematika penulisan.

### **BAB II : TINJAUAN PUSTAKA**

Bab ini menjelaskan berbagai teori dasar yang memiliki hubungan dengan judul penelitian, metode yang digunakan serta aplikasi pendukung pembuatan program.

### **BAB III : METODE PENELITIAN**

Bab ini menerangkan tentang system berjalan, metode pengembangan system dan perancangan system.

### **BAB IV : HASIL DAN PEMBAHASAN**

Bab ini menjelaskan hasil dan pembahasan yang berhubungan dengan data yang digunakan dalam penelitian.

## **BAB V : KESIMPULAN DAN SARAN**

Bab ini menjelaskan kesimpulan dan saran dari penelitian yang telah dilakukan.



## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Learning Rate

*Learning rate* memegang peranan yang sangat penting dalam perhitungan koreksi bobot selama proses *training*. Memilih *learning rate* itu sendiri merupakan hal yang sulit, karena nilai yang terlalu kecil akan membutuhkan waktu yang lama untuk dipelajari, dan nilai yang terlalu besar akan menyebabkan pembelajaran menjadi terlalu cepat sehingga membuat proses pembelajaran menjadi tidak stabil. Tingkat *input learning rate* pasti mempengaruhi hasil proses ML (Rochmawati dkk, 2021). *Learning rate* berperan sebagai parameter *training* dan penghitung jumlah langkah pada setiap iterasi untuk mendapatkan nilai minimum pada *loss function*. Hal ini didasarkan pada upaya untuk mencapai *learning rate* yang diwakili oleh vektor gradien dengan nilai negatif, dan nilai *learning rate* terbaik berusaha mencapai nilai minimum, yaitu output memiliki nilai dengan bobot yang stabil yang menunjukkan memiliki nilai rata-rata (Sukmana dkk, 2023). Lebih lanjut, fungsi *learning rate* adalah untuk meningkatkan komponen penting yang ada dalam data masukan dan mengurangi keterlibatan varian yang tidak relevan selama pemrosesan data (Sukmana dkk, 2023).

#### 2.2 Mean Square Error (MSE)

MSE adalah metrik referensi komprehensif yang paling banyak digunakan dan paling sederhana, dihitung dari perbedaan intensitas kuadrat piksel gambar yang

terdistorsi dan dirata-ratakan dari jumlah rasio *signal-to-noise (PSNR)* puncak yang sesuai. MSE digunakan karena komputasinya sederhana, tidak ambigu secara fisik, dan mudah diterapkan secara matematis dalam konteks optimasi. MSE tidak cocok untuk kualitas visual dan tidak dinormalisasi dalam representasi. MSE adalah penaksir metrik pengukuran kualitas gambar yang paling umum. Ini adalah indikator referensi yang sempurna, semakin dekat nilainya dengan nol semakin baik.

MSE adalah varians dari penaksir dalam kasus yang jarang terjadi dimana penaksir memiliki satuan pengukuran yang sama dengan kuadrat kuantitas yang dihitung sebagai varians. MSE memperkenalkan *root mean square error (RMSE)* atau *root mean square deviasi (RMSD)*, sering disebut sebagai deviasi standar varians. Berikut merupakan rumus dari MSE :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.1)$$

Di mana :

- $n$  adalah jumlah data.
- $y_i$  adalah nilai aktual dari data ke- $i$ .
- $\hat{y}_i$  adalah nilai prediksi dari data ke- $i$ .

### 2.3 Neural Network (NN)

NN merupakan model nonparametrik dengan bentuk fungsional fleksibel yang memuat beberapa parameter yang tidak dapat diinterpretasikan oleh model parametrik. NN telah muncul sebagai model kuantitatif yang penting untuk prediksi karena mereka mampu mendeteksi nonlinier dalam masalah serta memodelkan proses linier.

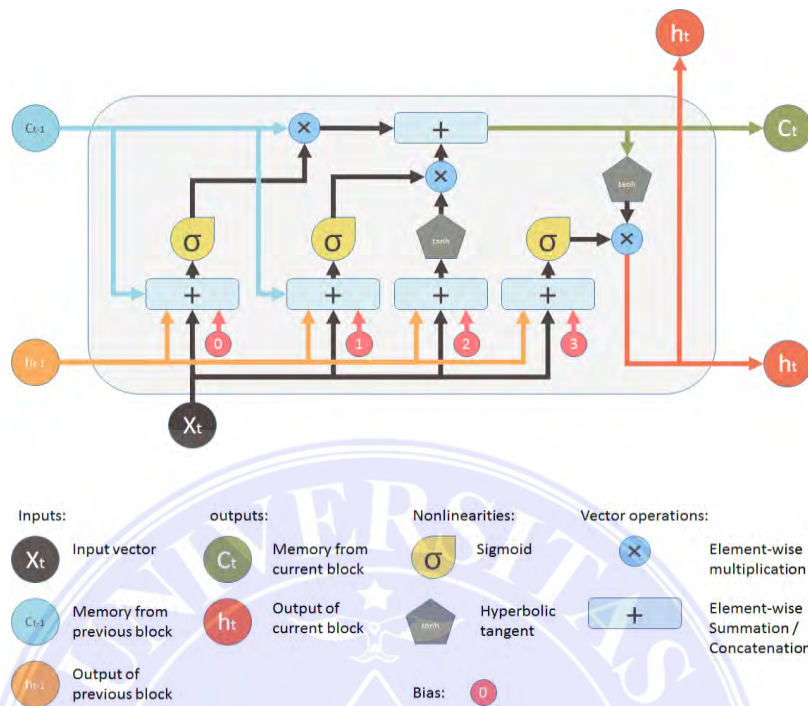
Berdasarkan kemampuan belajarnya, NN dapat dilatih untuk mempelajari dan menganalisis pola data masa lalu dan mencoba menemukan ekspresi atau fungsi yang menghubungkan pola data masa lalu dengan *output* yang diinginkan saat ini (Fany Achmalia dkk., 2020). NN adalah Teknik *Deep Learning* yang memiliki banyak variasi, RNN merupakan salah satu variasinya (Amrustian dkk., 2022).

#### **2.4 Recurrent Neural Network (RNN)**

RNN adalah jenis arsitektur jaringan saraf tiruan yang operasinya dipanggil berulang kali untuk memproses masukan data yang berurutan. RNN termasuk dalam kategori *Deep Learning* karena memproses data di banyak lapisan. RNN telah membuat kemajuan pesat dan merevolusi bidang-bidang seperti *Natural Language Processing NLP* (Firmansyah dkk., 2020). RNN adalah salah satu arsitektur NLP yang paling populer karena struktur rekursifnya sangat cocok untuk pemrosesan teks. Salah satu metode *deep learning* yang diusulkan dalam penelitian ini adalah RNN yang menerapkan arsitektur LSTM (Lestandy dkk., 2021). RNN adalah jaringan pemodelan jaringan saraf. Selain RNN, jenis pemodelan jaringan saraf lainnya mencakup *multilayer perceptron (MPL)* dan jaringan saraf *feedforward (FNN)*. RNN juga dikenal sebagai jaringan umpan balik, karena jenis jaringan saraf di mana *loop* ada sebagai koneksi umpan balik dalam jaringan. Jaringan RNN adalah jaringan yang mengambil *output* jaringan sebagai *input* ke jaringan dan digunakan untuk menghasilkan *output* baru (Tarkus dkk., 2020).

## 2.5 Long Short Term Memory (LSTM)

Model LSTM merupakan pengembangan lebih lanjut dari model RNN. LSTM dirancang untuk memproses data urutan seperti kata dan kalimat tanpa menyebabkan masalah gradien hilang di RNN. Masalah gradien hilang mencegah RNN menangkap ketergantungan jangka panjang, sehingga mengurangi akurasi yang dihasilkan oleh RNN (Nilsen, 2022). LSTM memiliki tiga jenis *gate*: *forget gate*, *input gate* dan *output gate*. *Forget gate* adalah gerbang yang menentukan bagaimana informasi dihapus dari sel. *Input gate* adalah gerbang yang menentukan nilai masukan yang diperbarui dalam keadaan memori. *Output gate* merupakan gerbang yang menentukan bagaimana keluaran dihasilkan setelah memasuki sel memori. Terdapat empat proses fungsi aktivasi pada setiap masukan pada *neurons* yang selanjutnya disebut sebagai *gates units*. *Gates units* tersebut ialah *forget gates*, *input gates*, *cell gates*, dan *output gates*. *forget gates* memproses informasi tentang setiap data masukan dan memilih data mana yang akan disimpan atau dibuang di sel memori. Fungsi aktivasi yang digunakan pada *forget gates* adalah fungsi aktivasi *sigmoid*. Hasil keluarannya antara 0 dan 1. Jika *outputnya* 1 maka semua data akan disimpan dan sebaliknya jika *outputnya* 0 maka semua data akan dibuang (Qotrunnada, 2022). Pada Gambar 2.1 dapat dilihat neuron pada LSTM (Andiyantama dkk., 2021).



Gambar 2. 1 Neuron LSTM (Qotrunnada, 2022)

Berikut rumus dan penjelasan proses LSTM :

a. *Forget gate* / Gate Pelupa ( $f_t$ )

Proses ini menggunakan fungsi *sigmoid* untuk menghapus informasi yang tidak perlu. Fungsi *sigmoid* dimaksudkan untuk mengubah nilai antara -1 dan 1 menjadi nilai 0 dan 1.

$$\text{sigmoid}(x_i) = \sigma(x_i) = \frac{1}{1 + e^{-x_i}} \quad (2.2)$$

Di sini, nilai 1 berarti elemen ini dipertahankan secara permanen dan nilai 0 berarti elemen ini dihapus secara permanen. Selanjutnya gunakan rumus untuk menghitung forget gate sebagai berikut :

$$f_t = \sigma(w_{fx} \cdot x_t + w_{fh} \cdot h_{t-1} + b_f) \quad (2.3)$$

Keterangan :

$w_{fx}$  : Output dari *forget gate* pada waktu  $t$

$\sigma$  : Fungsi aktivasi *sigmoid*

$w_{fh}$  : Bobot untuk *forget gate*

$h_{t-1}$  : *Hidden state* dari waktu sebelumnya

$x_t$  : *Input* pada waktu  $t$

$b_f$  : Bias untuk *forget gate*

b. *Input gate* / Gate Masukan (it)

Pada langkah selanjutnya, informasi diproses oleh komponen (it) untuk menentukan informasi yang diperbarui. Pada langkah ini juga dibentuk kandidat vektor baru menggunakan fungsi aktivasi Tanh. Kemudian gabungkan keduanya dan gunakan rumus untuk mengupgrade ke level berikutnya.

*Update gate:*

$$i_t = \sigma(w_{ix} \cdot x_t + w_{ih} \cdot h_{t-1} + b_i) \quad (2.4)$$

*Input Modulation Gate :*

$$c_t = \tanh(w_{cx} \cdot x_t + w_{ch} \cdot h_{t-1} + b_c) \quad (2.5)$$

Keterangan :

$i_t$  : Output dari *input gate* pada waktu  $t$

$c_t$  : Kandidat nilai *cell state* yang baru

Tanh : Fungsi aktivasi tanh

$w_{ix}$  : Bobot untuk *input gate*

$w_{cx}$  : Bobot untuk *input modulation gate*

$b_i, b_c$  : Bias untuk masing-masing *gate*

c. *Cell state* / Pembaruan State Sel ( $c_t$ )

Pada tahap ini nilai *memory cell* sebelumnya ( $c_{t-1}$ ) diperbarui dengan nilai *memory cell* baru ( $c_t$ ) dengan persamaan :

$$c_t = f_t \cdot c_{t-1} + i_t \cdot c_t \quad (2.6)$$

Keterangan :

$c_t$  : *Cell state* pada waktu  $t$

$c_{t-1}$  : *Cell state* dari waktu sebelumnya

$i_t \cdot c_t$  : Operasi perkalian elemen (*element-wise multiplication*)

d. *Output gate* / *Gate* Keluaran ( $o_t$ )

Tahap akhir dari *output gate* melakukan sigmoid untuk menghasilkan nilai *output* pada *hidden state* dan memperbaiki status sel ke *ground* dan menghasilkan nilai antara -1 dan 1. Nilai keluaran *sigmoid* kemudian dikalikan dengan fungsi Tan untuk memperoleh nilai yang dipilih. Hal ini dirumuskan sebagai berikut :

$$o_t = \sigma (w_{ox} \cdot x_t + w_{oh} \cdot h_{t-1} + b_o) \quad (2.7)$$

Keterangan :

$o_t$  : *output gate* pada waktu  $t$

$w_{ox}, w_{oh}$  : bobot untuk *output gate*

$b_o$  : vektor bias

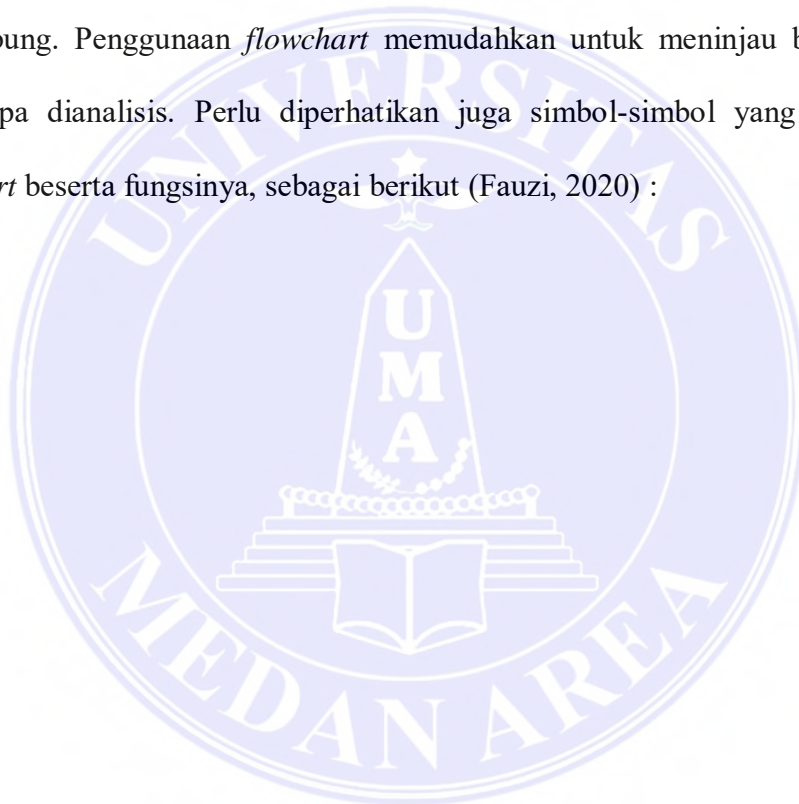
Proses pertama adalah menyaring informasi yang perlu dibuang. *Forget Gate* yang merupakan fungsi *sigmoid* dan dilambangkan dengan  $f_t$ , membaca nilai  $h_{t-1}$  dan  $x_t$  dan

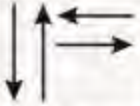
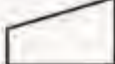






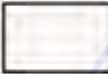




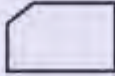


menghasilkan nilai 0 atau 1 untuk setiap elemen  $C_{t-1}$ . Nilai 0 menunjukkan bahwa elemen (informasi) tersebut harus dibuang. Sebaliknya, nilai 1 berarti elemen (informasi) tersebut harus dipertahankan. Proses berikut memiliki *input gate* dan *Tanh*. *Input gate* juga merupakan fungsi *sigmoid*. *Input gate* menentukan informasi yang akan diperbarui, dan fungsi *Tanh* membuat vektor  $\tilde{C}_t$  baru. Operasi selanjutnya adalah memperbarui sel memori dari  $C_{t-1}$  ke  $C_t$ . Untuk mendapatkan  $C_t$ , kita perlu mengalikan  $f_t$  dengan  $C_{t-1}$  atau  $\tilde{C}_t$ . Hasil dari kedua operasi perkalian tersebut kemudian dijumlahkan. Proses terakhir menentukan *output* dari proses ini. Jalankan fungsi *sigmoid* (*output*,  $o_t$ ) untuk mendapatkan bagian *memory cell* dan proses  $C_t$  dengan *tanh* untuk mendapatkan nilai dari 1 hingga -1. Untuk menentukan *output*, kalikan hasil *output gate* dengan *tanh*. Perbedaan antara LSTM dan RNN biasa adalah LSTM dapat mempelajari informasi mana yang harus dibuang dan informasi mana yang disimpan dalam sel memori.

## 2.6 Flowchart

*Flowchart* adalah representasi grafis dari langkah-langkah dan proses dalam suatu program. *Flowchart* membantu analis dan pemrogram memecah masalah menjadi segmen yang lebih kecil dan menganalisis alternatif lain dalam operasi (Zalukhu dkk., 2023). *Flowchart* adalah gambar grafis yang berisi proses sistematis atau urutan langkah-langkah untuk menjalankan suatu program. *Flowchart* memberikan gambaran proses analisis, perancangan, dan pengkodean ketika memecahkan masalah yang lebih rinci dalam alur operasional kegiatan (Kus Indrani Listyoningrum dkk., 2023). Dalam

arti lain, *Flowchart* adalah representasi grafis dari langkah-langkah dan proses dalam suatu program (Tuasamu dkk., 2023). *Flowchart* adalah cara untuk menggambarkan suatu algoritma menggunakan notasi grafis. *Flowchart* adalah gambar atau diagram yang menunjukkan urutan atau langkah-langkah suatu program dan hubungan antara suatu proses dan instruksi instruksinya. Gambaran ini dinyatakan dengan simbol. Oleh karena itu, setiap simbol menggambarkan proses tertentu. Proses diwakili oleh garis penghubung. Penggunaan *flowchart* memudahkan untuk meninjau bagian masalah yang lupa dianalisis. Perlu diperhatikan juga simbol-simbol yang ada di dalam *flowchart* beserta fungsinya, sebagai berikut (Fauzi, 2020) :



	<b>Flow Direction symbol</b> Yaitu simbol yang digunakan untuk menghubungkan antara simbol yang satu dengan simbol yang lain. Simbol ini disebut juga connecting line.		<b>Simbol Manual Input</b> Simbol untuk pemasukan data secara manual on-line keyboard
	<b>Terminator Symbol</b> Yaitu simbol untuk permulaan (start) atau akhir (stop) dari suatu kegiatan		<b>Simbol Preparation</b> Simbol untuk mempersiapkan penyimpanan yang akan digunakan sebagai tempat pengolahan di dalam storage.
	<b>Connector Symbol</b> Yaitu simbol untuk keluar - masuk atau penyambungan proses dalam lembar / halaman yang sama.		<b>Simbol Predefine Proses</b> Simbol untuk pelaksanaan suatu bagian (sub-program)/prosedure
	<b>Connector Symbol</b> Yaitu simbol untuk keluar - masuk atau penyambungan proses pada lembar / halaman yang berbeda.		<b>Simbol Display</b> Simbol yang menyatakan peralatan output yang digunakan yaitu layar, plotter, printer dan sebagainya.
	<b>Processing Symbol</b> Simbol yang menunjukkan pengolahan yang dilakukan oleh komputer		<b>Simbol disk and On-line Storage</b> Simbol yang menyatakan input yang berasal dari disk atau disimpan ke disk.
	<b>Simbol Manual Operation</b> Simbol yang menunjukkan pengolahan yang tidak dilakukan oleh computer		<b>Simbol magnetik tape Unit</b> Simbol yang menyatakan input berasal dari pita magnetik atau output disimpan ke pita magnetik.
	<b>Simbol Decision</b> Simbol pemilihan proses berdasarkan kondisi yang ada.		<b>Simbol Punch Card</b> Simbol yang menyatakan bahwa input berasal dari kartu atau output ditulis ke kartu
	<b>Simbol Input-Output</b> Simbol yang menyatakan proses input dan output tanpa tergantung dengan jenis peralatannya		<b>Simbol Dokumen</b> Simbol yang menyatakan input berasal dari dokumen dalam bentuk kertas atau output dicetak ke kertas.

Gambar 2. 2 Simbol *Flowchart* (Fauzi, 2020)

## 2.7 Python

*Python* adalah bahasa pemrograman tingkat tinggi yang dikembangkan oleh Guido Van Rossum dan dirilis pada tahun 1991. *Python* juga merupakan bahasa yang sangat populer saat ini. Selain itu, *Python* juga merupakan bahasa pemrograman serbaguna; misalnya, *Python* dapat digunakan untuk ML dan *Deep Larning*. *Python* dipilih untuk

penelitian ini karena sintaksisnya yang mudah ditulis. Selain itu, *Python* memiliki *library* yang lengkap dan *Python* bersifat *open source*, karena mendapat dukungan komunitas yang kuat (Alfarizi dkk., 2023).

Bahasa pemrograman *Python* merupakan bahasa pemrograman yang populer di bidang analisis data. Hal ini karena *Python* mudah dipelajari dan digunakan untuk segala usia. Selain itu, bahasa pemrograman *Python* memiliki beragam *Library* yang memiliki kegunaan unik dan dapat digunakan oleh siapa saja di sistem operasi berbeda. dengan kata lain bersifat *open source*. Contoh *Library Python* termasuk *NumPy*, *Pandas*, *Matplotlib*, dan *Scikit-learn* yang berguna untuk analisis data, pemodelan statistik, visualisasi data, dan ML. Selain itu, *Python* juga dapat dengan mudah diintegrasikan dengan teknologi lain yang terkait dengan analisis data, seperti *database*, *big data tools*, *framework web*, untuk tujuan mengakses dan mengelola data dari berbagai sumber (Angelina M. T. I. Sambu Ua dkk., 2023).

## 2.8 Google Colab

*Google Colab* adalah IDE untuk pemrograman *Python* yang pemrosesannya dilakukan oleh *server Google* dengan perangkat keras dengan performa yang tinggi. Terkait *software*, *Google Colab* menyediakan hampir semua *library* yang dibutuhkan (Gelar Guntara, 2023). *Google Colab* (kependekan dari *Google Colaboratory*) adalah *platform cloud* yang disediakan oleh *Google* untuk menjalankan dan menulis kode *Python* dari *browser* tanpa memerlukan konfigurasi tambahan apa pun. Ini memanfaatkan infrastruktur *cloud Google* dan menyediakan lingkungan

pengembangan yang kuat dengan akses gratis ke GPU dan TPU (*Tensor Processing Unit*) (Nazar, 2024). *Google Colab* adalah layanan *cloud computing* yang disediakan oleh *Google* untuk mendukung pengembangan ilmu pengetahuan dan penelitian. *Colaboratory* atau "*Colab*" adalah produk *Google Research*. *Colab* memungkinkan untuk menulis dan menjalankan kode *Python* *arbitrer* dari *browser*, sehingga ideal untuk ML, analisis data, dan pendidikan. Selain itu, *Google Colab* dapat dibagikan antar pengembang aplikasi, mendukung kebutuhan kolaborasi antar anggota tim. *Google Colab* masih relatif belum dikenal oleh masyarakat umum, karena hanya digunakan oleh orang-orang yang membutuhkan lingkungan *coding environment*, seperti para *developer* atau *programmer* (Wilyani dkk., 2024).

## 2.9 Penelitian Terdahulu


Hasil penelitian sebelumnya menjadi salah satu acuan dasar penelitian. Karena tugas penelitian sebelumnya adalah memperluas dan memperdalam teori yang digunakan dalam penelitian ini. Biasanya, penelitian sebelumnya adalah sumber penelitian yang kemudian peneliti coba bandingkan dengan penelitian saat ini. Hasil penelitian sebelumnya juga menjadi sumber inspirasi yang sangat membantu selama penelitian. Selain itu, peneliti dapat mengidentifikasi kekuatan dan kelemahan yang dapat dikembangkan. Adapun penelitian terdahulu dalam penelitian ini dapat dilihat pada Tabel 2. 1 sebagai berikut :

Tabel 2. 1 Penelitian Terdahulu

No	Nama Peneliti dan Tahun	Judul	Hasil Penelitian
1	Susilawati dkk, (2019)	Analisis Pengaruh Fungsi Aktivasi, <i>Learning Rate</i> Dan Momentum Dalam Menentukan <i>Mean Square Error (MSE)</i> Pada Jaringan Saraf <i>Restricted Boltzmann Machines (RBM)</i> .	Kinerja RBM sangat dipengaruhi oleh pemilihan nilai parameter <i>Learning rate</i> , momentum, dan fungsi aktivasi yang sesuai, terutama saat menentukan <i>Mean Squared Error (MSE)</i> dan persentase akurasi pengenalan untuk dataset .
2	Supriyanto dkk, (2022)	Pengaruh Nilai <i>Hidden Layer</i> dan <i>Learning Rate</i> Terhadap Kecepatan Pelatihan Jaringan <i>Syaraf Tiruan Backpropagation</i> .	Pelatihan jaringan menghasilkan parameter <i>hidden layer</i> sebanyak 12 <i>neuron</i> selama waktu pelatihan 3 menit 44 detik dengan <i>error MSE</i> sebesar 1.654151. Jumlah iterasi yang diperlukan pada arsitektur <i>hidden layer 12 neuron</i> adalah 100.000 iterasi dengan waktu <i>training</i> 21 menit 52 detik. Sedangkan parameter <i>learning rate</i> menggunakan 12 <i>neuron</i> dan 100.000 iterasi, nilai <i>learning rate</i> yang benar untuk pelatihan adalah 0,5, waktu yang diperlukan untuk pelatihan adalah 18 menit 35 detik, dan <i>MSE error</i> adalah 0,302868.
3	Saputra, (2020)	Penentuan Parameter <i>Learning Rate</i> Selama Pembelajaran Jaringan <i>Syaraf Tiruan Backpropagation</i> Menggunakan Algoritma Genetika	Berdasarkan hasil percobaan yang didapatkan dengan membandingkan kedua metode, metode penggantian nilai <i>learning rate</i> menggunakan algoritma genetika menghasilkan pembelajaran yang lebih baik dibandingkan dengan pembelajaran JST <i>backpropagation</i> tanpa modifikasi. Kecepatan pembelajaran selain bergantung

			pada <i>learning rate</i> bergantung pula pada pemilihan arsitektur JST.
4	Johny & Madhusoodanan, (2021)	<i>Dynamic Learning Rate in Deep CNN Model for Metastasis Detection and Classification of Histopathology Image</i>	Prediksi metastasis dalam gambar medis dilakukan dengan mengurangi tingkat <i>false - positive</i> . Melatih model CNN dengan variabel <i>learning rate</i> mencapai akurasi validasi 91,84% dengan <i>epoch</i> yang lebih rendah. <i>Learning rate</i> dinamis menghasilkan akurasi klasifikasi yang unggul dalam mendeteksi sel metastasis dan jinak dalam gambar <i>histopatologi</i> .
5	Ismail et al., (2019)	<i>Improving Convolutional Neural Network (CNN) Architecture (miniVGGNet) with Batch Normalization and Learning Rate Decay Factor for Image Classification</i>	Berdasarkan hasil eksperimen, penambahan lapisan <i>batch normalisasi</i> memungkinkan jaringan untuk meningkatkan akurasi klasifikasi dari 80% menjadi 82%. Menerapkan faktor <i>learning rate</i> akan meningkatkan akurasi klasifikasi hingga 83% dan mengurangi efek <i>overfitting</i> pada <i>learning plot</i> .
6	Smaida et al., (2021)	<i>Learning Rate Optimization in CNN for Accurate Ophthalmic Classification</i>	<i>learning rate adaptif Adam</i> telah mengungguli teknik optimasi lainnya dan mencapai akurasi model terbaik 92,58% untuk <i>training</i> dan masing-masing 80,49% untuk himpunan data validasi. Untuk Penelitian lebih lanjut dapat menggunakan jaringan yang berbeda untuk Tingkatkan akurasi
7	Zhu et al., (2023)	<i>Learning To Schedule Learning Rate With Graph Neural Networks</i>	Penjadwal yang diusulkan dapat menangkap informasi lapisan menengah sambil menggeneralisasi masalah dari berbagai skala. Selain itu, supaya lebih efisien Prosedur pengumpulan dimanfaatkan untuk mempercepat pelatihan. kerangka

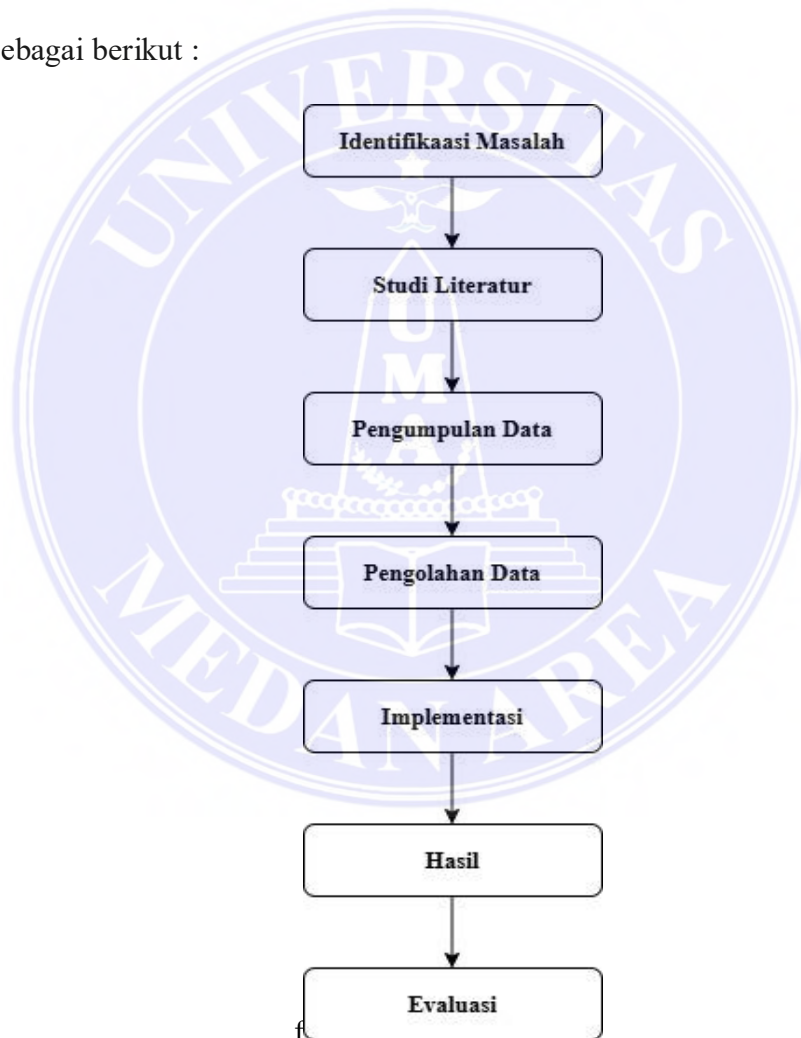
		<p>kerja yang digunakan untuk mengevaluasi diambil dari <i>dataset benchmarking, Fashion-MNIST</i> dan <i>CIFAR10</i> untuk klasifikasi gambar, dan <i>GLUE</i> untuk pemahaman bahasa. GNS menunjukkan peningkatan yang konsisten atas <i>baseline</i> populer saat melatih model CNN dan <i>Transformer</i>. Selain itu, GNS menunjukkan generalisasi yang bagus untuk kumpulan data dan struktur jaringan yang berbeda.</p>
--	--	--



## BAB III METODE PENELITIAN

### 3.1 Tahapan Penelitian

Berikut ini merupakan tahapan penelitian penerapan metode LSTM dalam merekomendasikan manajemen bandwidth pada penggunaan aplikasi di Kominfo adalah sebagai berikut :



Gambar 3. 1 Tahapan Penelitian

### 3.1.1 Studi Literatur

Dengan mengumpulkan referensi dari penelitian terdahulu yang menggunakan metode yang sama maupun berbeda. Study literatur dari jurnal - jurnal terpercaya yang telah terindeks seperti; *IEEE*, *ScienceDirect*, *SINTA*, maupun yang lainnya. Kemudian dilakukan *review* pada literatur tersebut untuk menemukan topik penelitian.

### 3.1.2 Pengumpulan Data

Adapun yang dibahas pada sub bab ini adalah mengenai sumber dan jenis data serta metode pengumpulan data yang digunakan. Pada penelitian ini jenis data yang digunakan adalah data primer yang diperoleh langsung dari kantor dinas Kominfo. Adapun sampel data yang diperoleh dapat dilihat pada table berikut :

Tabel 3. 1 Data Akses Penggunaan Aplikasi di Kominfo

No	Nama Pengguna	Aplikasi	Tanggal Akses	Bandwidth
1	Ri	Web Humbang	21-Jan-23	1.02
2	Do	FFLAJ	9-Jan-23	2.23
3	Ba	E-Kinerja	13-Jan-23	1.03
4	Ma	ID-Card	8-Jan-23	2.46
5	Sa	Simpuskes	10-Jan-23	1,98
6	Da	Simluhtan	6-Jan-23	1.23
...	....	...	...	...
6196	Mak	Simluhtan	1-Nov-23	1.86

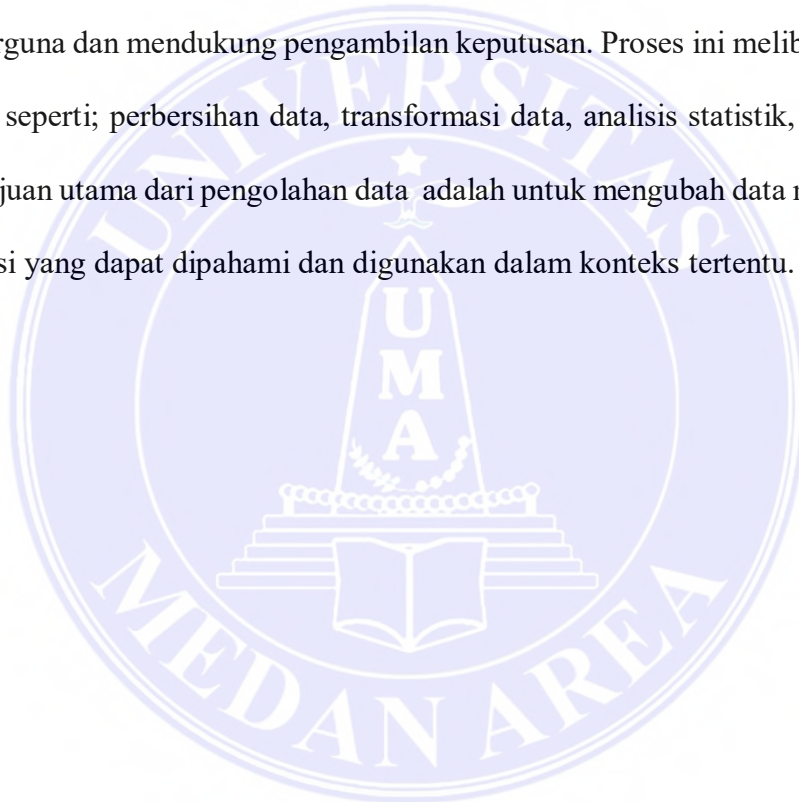
Sumber : Kominfo Humbang Hasundutan

Table 3.1 merupakan sampel data akses penggunaan aplikasi di kantor Kominfo. Adapun atribut meliputi nama pengguna, aplikasi, tanggal akses, dan bandwidth digunakan (GB). Data aplikasi yang diperoleh sebanyak 6 jenis, yaitu ; Web Humbang

(946), FFLAJ (746), E-Kinerja (4072), ID Card (241), Simpuskes (584), dan Simluhtan (354) dengan jumlah data keseluruhan 6.196. Sampel aplikasi yang diambil termasuk aplikasi yang paling sering diakses.

### 3.1.3 Pengolahan Data

Sub bab ini merupakan proses menyajikan data untuk mendapatkan informasi yang berguna dan mendukung pengambilan keputusan. Proses ini melibatkan beberapa langkah seperti; perbersihan data, transformasi data, analisis statistik, dan visualisasi data. Tujuan utama dari pengolahan data adalah untuk mengubah data mentah menjadi informasi yang dapat dipahami dan digunakan dalam konteks tertentu.



## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

*Long Short Term Memory (LSTM)* merupakan salah satu algoritma *machine learning (ML)* berbasis pendekatan *Reccurent Neural Network (RNN)*. LSTM memiliki empat lapisan *neuron* yang biasa disebut gerbang untuk mengatur memori setiap *neuron*, sehingga dapat mendeteksi data mana yang perlu dan tidak perlu digunakan. Salah satu komponen penting yang digunakan LSTM untuk menentukan nilai MSE adalah *learning rate*. *Learning rate* sangat berperan dalam menghitung koreksi bobot pada waktu proses *training*. Memilih *learning rate* memang merupakan tantangan tersendiri karena jika nilai terlalu kecil maka *training* akan membutuhkan waktu yang lama sebaliknya jika terlalu besar maka pembelajaran akan menjadi kurang optimal karena terlalu cepat dan proses *training* menjadi tidak stabil. Besarnya *learning rate* yang dimasukkan tentu akan berdampak pada hasil proses ML. Dengan menggunakan *dataset* akses penggunaan aplikasi di Kominfo. Dalam penelitian ini, peneliti telah menguji pengaruh berbagai nilai *learning rate* terhadap performa model LSTM dalam menganalisis nilai *learning rate* yang paling efektif dalam memproses MSE pada model LSTM. Tiga nilai *learning rate* yang diuji adalah 0.1, 0.01, dan 0.001. Hasilnya menunjukkan bahwa *learning rate* 0.001 memberikan performa terbaik dengan menunjukkan hasil yang cenderung stabil dengan *fluktuasi* yang minimal dan nilai MSE yang konsisten lebih rendah pada *epoch* 100 dan *epoch* 150. Hasilnya

menunjukkan bahwa learning rate 0.001 memberikan performa terbaik dengan menunjukkan hasil yang cenderung stabil dengan fluktuasi yang minimal dan nilai MSE yang konsisten lebih rendah pada *epoch* 115 yaitu MSE 0,083705828. Hasil penelitian ini menunjukkan bahwa pemilihan learning rate yang tepat sangat penting untuk optimisasi model LSTM. Learning rate 0.001 menunjukkan hasil terbaik dalam konteks penelitian ini, sehingga dapat direkomendasikan untuk penelitian selanjutnya.

## 5.2 Saran

1. Melakukan penelitian lebih lanjut yang bertujuan untuk menganalisis kinerja LSTM dengan menggunakan parameter lain seperti fungsi aktivasi dan momentum.
2. Penelitian selanjutnya bisa menggunakan *dataset* lain seperti citra gambar.

## DAFTAR PUSTAKA

- Alfarizi, M. R. S., Al-farish, M. Z., Taufiqurrahman, M., Ardiansah, G., & Elgar, M. (2023). Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning. *Karya Ilmiah Mahasiswa Bertauhid (KARIMAH TAUHID)*, 2(1), 1–6.
- Amrustian, M. A., Widayat, W., & Wirawan, A. M. (2022). Analisis Sentimen Evaluasi Terhadap Pengajaran Dosen di Perguruan Tinggi Menggunakan Metode LSTM. *Jurnal Media Informatika Budidarma*, 6(1), 535. <https://doi.org/10.30865/mib.v6i1.3527>
- Andiyantama, M. Q., Zahira, I., & Irawan, A. (2021). Prediksi Energi Listrik Kincir Angin Berdasarkan Data Kecepatan Angin Menggunakan LSTM. *JITCE (Journal of Information Technology and Computer Engineering)*, 5(01), 1–7. <https://doi.org/10.25077/jitce.5.01.1-7.2021>
- Angelina M. T. I. Sambi Ua, Diandra Lestriani H, Elizabeth Sonia Kristanty Marpaung, Jesslyn Ong, Michelle Savinka, Putri Nurhaliza, & Rahmi Yulia Ningsih. (2023). Penggunaan Bahasa Pemrograman Python Dalam Analisis Faktor Penyebab Kanker Paru-Paru. *Jurnal Publikasi Teknik Informatika*, 2(2), 88–99. <https://doi.org/10.55606/jupti.v2i2.1742>
- Ashari, M. L., & Sadikin, M. (2020). Prediksi Data Transaksi Penjualan Time Series Menggunakan Regresi Lstm. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 9(1), 1. <https://doi.org/10.23887/janapati.v9i1.19140>

- Chazar, C., & Erawan, B. (2020). Machine Learning Diagnosis Kanker Payudara Menggunakan Algoritma Support Vector Machine. *INFORMASI (Jurnal Informatika Dan Sistem Informasi)*, 12(1), 67–80.  
<https://doi.org/10.37424/informasi.v12i1.48>
- Fany Achmalia, A., Walid, S., Artikel, I., & Artikel, S. (2020). Peramalan Penjualan Semen Menggunakan Backpropagation Neural Network Dan Recurrent Neural Network. *UNNES Journal of Mathematics*, 9(1), 6–21.  
<http://journal.unnes.ac.id/sju/index.php/ujm>
- Fathurohman, A. (2021). Machine Learning Untuk Pendidikan: Mengapa Dan Bagaimana. *Jurnal Informatika Dan Teknologi Komputer (JITEK)*, 1(3), 57–62.  
<https://journal.amikveteran.ac.id/index.php/jitek/article/view/306>
- Fauzi, J. R. (2020). Algoritma Dan Flowchart Dalam Menyelesaikan Suatu Masalah Disusun Oleh Universitas Janabadra Yogyakarta 2020. *Jurnal Teknik Informatika*, 20330044, 4–6.
- Firmansyah, M. R., Ilyas, R., & Kasyidi, F. (2020). Klasifikasi Kalimat Ilmiah Menggunakan Recurrent Neural Network. *Prosiding The 11th Industrial Research Workshop and National Seminar*, 11(1), 488–495.
- Gelar Guntara, R. (2023). Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7. *Jurnal Teknologi Dan Sistem Informasi Bisnis*, 5(1), 55–60.  
<https://doi.org/10.47233/jteksis.v5i1.750>
- Ismail, A., Ahmad, S. A., Soh, A. C., Hassan, K., & Harith, H. H. (2019). Improving Convolutional Neural Network (CNN) architecture (miniVGGNet) with batch

normalization and learning rate decay factor for image classification. *International Journal of Integrated Engineering*, 11(4), 51–59. <https://doi.org/10.30880/ijie.2019.11.04.006>

Johney, A., & Madhusoodanan, K. N. (2021). Dynamic Learning Rate in Deep CNN Model for Metastasis Detection and Classification of Histopathology Images. *Computational and Mathematical Methods in Medicine*, 2021. <https://doi.org/10.1155/2021/5557168>

Kus Indrani Listyoningrum, Danise Yunaini Fenida, & Nurhasan Hamidi. (2023). Inovasi Berkelanjutan dalam Bisnis: Manfaatkan Flowchart untuk Mengoptimalkan Nilai Limbah Perusahaan. *Jurnal Informasi Pengabdian Masyarakat*, 1(4), 100–112. <https://doi.org/10.47861/jipm-nalanda.v1i4.552>

Lattifia, T., Wira Buana, P., & Rusjayanthi, N. K. D. (2022). Model Prediksi Cuaca Menggunakan Metode LSTM. *JITTER Jurnal Ilmiah Teknologi Dan Komputer*, 3(1), 994–1000. <https://ojs.unud.ac.id/index.php/jitter/article/view/85000/43781>

Lestandy, M., Abdurrahim, A., & Syafa'ah, L. (2021). Analisis Sentimen Tweet Vaksin COVID-19 Menggunakan Recurrent. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(10), 802–808.

Nazar, R. (2024). Implementasi Pemrograman Python Menggunakan Google Colab. *Jurnal Informatika Dan Komputer (JIK)*, 15(1), 50–56.

Nilsen, A. (2022). Perbandingan Model RNN, Model LSTM, dan Model GRU dalam Memprediksi Harga Saham-Saham LQ45. *Jurnal Statistika Dan Aplikasinya*, 6(1), 137–147. <https://doi.org/10.21009/jsa.06113>

Novian, A., & Kartini, U. T. (2023). Peramalan Loss Of Life Tranformator

- Berdasarkan Loading dan Temperature Menggunakan LSTM di Gardu Induk 150KV Buduran. *Jurnal Teknik Elektro*, 12(1), 81–86.  
<https://doi.org/10.26740/jte.v12n1.p81-86>
- Qotrunnada, F. (2022). *Implementasi Long Short Term Memory Pada Optimalisasi Prediksi Harga Saham Menggunakan Parameter Analisis Teknikal*. 1–20.
- Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtjas, H. P. A., Yustanti, W., & Prihanto, A. (2021). Analisa Learning Rate dan Batch Size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer Adam. *Journal of Information Engineering and Educational Technology*, 5(2), 44–48.  
<https://doi.org/10.26740/jieet.v5n2.p44-48>
- Saputra, A. chandra. (2020). Penentuan Parameter Learning Rate Selama Pembelajaran Jaringan Syaraf Tiruan Backpropagation Menggunakan Algoritma Genetika. *Jurnal Teknologi Informasi: Jurnal Keilmuan Dan Aplikasi Bidang Teknik Informatika*, 14(2), 202–212. <https://doi.org/10.47111/jti.v14i2.1141>
- Smaida, M., Yaroshchak, S., & Ben Sasi, A. Y. (2021). Learning Rate Optimization in CNN for Accurate Ophthalmic Classification. *International Journal of Innovative Technology and Exploring Engineering*, 10(4), 211–216.  
<https://doi.org/10.35940/ijitee.b8259.0210421>
- Sukmana, S. E., Ikawati, D. S. E., Dien, H. E., & Dianta, A. F. (2023). Penentuan Learning Rate Terbaik CNN Pada Pengenalan Individu Berbasis Analisis Gait. *JOINS (Journal of Information System)*, 8(1), 90–96.  
<https://doi.org/10.33633/joins.v8i1.7806>
- Susilawati, S., & Muhathir, M. (2019). Analisis Pengaruh Fungsi Aktivasi, Learning

- Rate Dan Momentum Dalam Menentukan Mean Square Error (MSE) Pada Jaringan Saraf Restricted Boltzmann Machines (RBM). *Journal of Informatics and Telecommunication Engineering*, 2(2), 77.  
<https://doi.org/10.31289/jite.v2i2.2162>
- Syaraf, J., Backpropagation, T., & Riadi, I. (2022). *508-1250-2-Pb*. 6(1), 27–33.
- Tarkus, defrisco excelSompie, Sompie, sherwin R. U. ., & Jacobus, agustinus. (2020). Implementasi metode recurrent neural network pada pengklasifikasian kualitas telur puyuh. *Jurnal Teknik Informatika*, 15(02), 137–144.
- Tuasamu, Z., M. Lewaru, N. A. I., Idris, M. R., Syafaat, A. B. N., Faradilla, F., Fadlan, M., Nadiva, P., & Efendi, R. (2023). Analisis Sistem Informasi Akuntansi Siklus Pendapatan Menggunakan DFD Dan Flowchart Pada Bisnis Porobico. *Jurnal Bisnis Manajemen*, 1(2), 495–510.
- Wilyani, F., Nuryan Arif, Q., & Aslimar, F. (2024). Pengenalan Dasar Pemrograman Python Dengan Google Colaboratory. *Jurnal Pengabdian Pada Masyarakat Indonesia*, 3(1), 08–14. <https://doi.org/10.55606/jppmi.v3i1.1087>
- Zalukhu, A., Purba, S., & Darma, D. (2023). Perangkat lunak aplikasi pembelajaran flowchart. *Jurnal Teknologi Informasi Dan Industri*, 4(1), 61–70.
- Zhu, H., Liu, L., & Hassoun, S. (2023). *U Sing G Raph N Eural N Etworks for*. 1–19.

## LAMPIRAN

### Lampiran I : Source Code

```
import pandas as pd

df = pd.read_csv('/content/DATA SKRIPSI.csv', encoding='windows-1252')
df
```

	Nama Pengguna	Aplikasi	Tanggal Akses	Bandwidth Digunakan (GB)
0	rianti zega	WEB HUMBANG	21-Jan-23	1.02
1	Yonepta Habeahan, SP, MM	WEB HUMBANG	22-Jan-23	1.75
2	Rickson Marojahan Tambunan, SP,MSI	WEB HUMBANG	23-Jan-23	1.75
3	Kartini Herawaty Sihombing, SE	WEB HUMBANG	24-Jan-23	1.36
4	Ir. Happy Silitonga	WEB HUMBANG	25-Jan-23	1.13
...	...	...	...	...
6192	Sipariama	SIMLUHTAN	1-Nov-23	1.34
6193	Bona Pasogit	SIMLUHTAN	1-Nov-23	1.21
6194	Alam Semesta Lestari	SIMLUHTAN	1-Nov-23	1.80
6195	Siboan Tua	SIMLUHTAN	1-Nov-23	0.93
6196	Makmur	SIMLUHTAN	1-Nov-23	1.86

```
import numpy as np
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split

# Mengambil kolom "Bandwidth Digunakan (GB)" sebagai target
data_values = df['Bandwidth Digunakan (GB)'].values

# Normalisasi data
scaler = MinMaxScaler()
data_scaled = scaler.fit_transform(data_values.reshape(-1, 1))

# Membuat sequences untuk LSTM
timesteps = 3 # jumlah timestep untuk input sequence
X, y = [], []
for i in range(len(data_scaled) - timesteps):
    X.append(data_scaled[i:i+timesteps])
    y.append(data_scaled[i+timesteps])
X, y = np.array(X), np.array(y)

# Membagi data menjadi training dan testing set
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42, shuffle=False)
```

```
# Definisikan model LSTM
from keras.models import Sequential
from keras.layers import LSTM, Dense
from keras.optimizers import Adam
from keras.losses import MeanSquaredError

def create_model():
    model = Sequential()
    model.add(LSTM(units=50, return_sequences=True, input_shape=(timesteps, 1)))
    model.add(LSTM(units=50))
    model.add(Dense(1))
    return model
```

```
learning_rates = [0.1, 0.01, 0.001]
results = []

for lr in learning_rates:
    model = create_model()
    optimizer = Adam(learning_rate=lr)
    model.compile(optimizer=optimizer, loss=MeanSquaredError())


    # Callback untuk menyimpan nilai MSE setelah setiap epoch
    mse_callback = LambdaCallback(
        on_epoch_end=lambda epoch, logs: results.append([
            lr,
            epoch + 1,
            logs['loss'],
            logs['val_loss'],
            model.evaluate(X_test, y_test, verbose=0)
        ])
    )

    history = model.fit(
        X_train, y_train,
        epochs=150,
        batch_size=32,
        validation_split=0.2,
        verbose=0,
        callbacks=[mse_callback]
    )

    print(f"Finished training with learning rate: {lr}")
    for result in results:
        if result[0] == lr:
            print(f"Epoch {result[1]}: Training Loss = {result[2]}, Validation Loss = {result[3]}, MSE = {result[4]}")
    print()
```

```
# Plotting hasilnya
import matplotlib.pyplot as plt

plt.figure(figsize=(12, 8))
for lr in learning_rates:
    lr_results = results_df[results_df['Learning Rate'] == lr]
    plt.plot(lr_results['Epoch'], lr_results['Validation Loss'], label=f'LR={lr}')
plt.title('Validation Loss per Epoch')
plt.xlabel('Epoch')
plt.ylabel('Validation Loss')
plt.legend()
plt.show()
```



## Lampiran II : Hasil Pengujian

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,1	1	0,21072	0,085805	0,087113
0,1	2	0,085073	0,083671	0,08491
0,1	3	0,085175	0,091152	0,092092
0,1	4	0,083552	0,082953	0,083794
0,1	5	0,085434	0,084841	0,085735
0,1	6	0,084451	0,083043	0,083848
0,1	7	0,084139	0,087348	0,088192
0,1	8	0,084461	0,088622	0,089526
0,1	9	0,084377	0,084406	0,085328
0,1	10	0,084288	0,083447	0,084164
0,1	11	0,083814	0,083264	0,084164
0,1	12	0,084358	0,082946	0,08377
0,1	13	0,084684	0,087349	0,088193
0,1	14	0,08502	0,084236	0,085017
0,1	15	0,083567	0,088822	0,089691
0,1	16	0,085153	0,088083	0,088755
0,1	17	0,086364	0,083005	0,083749
0,1	18	0,083179	0,082989	0,083673
0,1	19	0,083538	0,083031	0,083837
0,1	20	0,084454	0,085612	0,086427
0,1	21	0,083989	0,084018	0,084598
0,1	22	0,083501	0,083524	0,08402
0,1	23	0,084081	0,085208	0,08604
0,1	24	0,084709	0,092439	0,093183
0,1	25	0,085347	0,087204	0,087896
0,1	26	0,083022	0,083048	0,083824
0,1	27	0,086004	0,083239	0,084024
0,1	28	0,083455	0,087023	0,087725
0,1	29	0,083635	0,083147	0,083877
0,1	30	0,083561	0,084257	0,084942
0,1	31	0,08395	0,095969	0,096553
0,1	32	0,083159	0,084382	0,085195
0,1	33	0,083707	0,082997	0,083712
0,1	34	0,084386	0,083897	0,084641
0,1	35	0,083387	0,084325	0,085123
0,1	36	0,084273	0,083102	0,083806

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,1	37	0,083494	0,082939	0,083738
0,1	38	0,084205	0,086287	0,087121
0,1	39	0,083451	0,088701	0,089504
0,1	40	0,084967	0,087742	0,088548
0,1	41	0,083418	0,084242	0,084918
0,1	42	0,083498	0,084452	0,085157
0,1	43	0,083199	0,092579	0,093458
0,1	44	0,083945	0,083243	0,083991
0,1	45	0,08401	0,087448	0,088224
0,1	46	0,084699	0,084209	0,084876
0,1	47	0,084662	0,083379	0,084194
0,1	48	0,083405	0,083095	0,083846
0,1	49	0,08308	0,085671	0,08629
0,1	50	0,08305	0,08362	0,084358
0,1	51	0,083592	0,084262	0,08499
0,1	52	0,08457	0,085432	0,086388
0,1	53	0,085126	0,082978	0,083794
0,1	54	0,083479	0,083318	0,084132
0,1	55	0,083247	0,083797	0,084662
0,1	56	0,083466	0,085337	0,086197
0,1	57	0,083626	0,083324	0,084269
0,1	58	0,083241	0,09217	0,093116
0,1	59	0,084041	0,090516	0,091376
0,1	60	0,084497	0,08348	0,084317
0,1	61	0,083676	0,082919	0,083802
0,1	62	0,082829	0,083566	0,084353
0,1	63	0,084142	0,084183	0,084964
0,1	64	0,083521	0,083976	0,08483
0,1	65	0,084092	0,084561	0,085419
0,1	66	0,082912	0,083595	0,084515
0,1	67	0,084733	0,083378	0,084136
0,1	68	0,084265	0,085056	0,085902
0,1	69	0,083416	0,083519	0,084318
0,1	70	0,084417	0,083837	0,084729
0,1	71	0,083595	0,083179	0,084053
0,1	72	0,084162	0,083268	0,084357
0,1	73	0,083258	0,082882	0,083845
0,1	74	0,085856	0,083052	0,083928
0,1	75	0,083681	0,084018	0,08498

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,1	76	0,083642	0,082826	0,083793
0,1	77	0,083378	0,090748	0,091539
0,1	78	0,083785	0,083993	0,084909
0,1	79	0,08361	0,082941	0,083855
0,1	80	0,083431	0,082992	0,083956
0,1	81	0,084359	0,083466	0,084458
0,1	82	0,083715	0,086865	0,087725
0,1	83	0,083623	0,093182	0,094006
0,1	84	0,083586	0,083122	0,083982
0,1	85	0,082821	0,083844	0,084878
0,1	86	0,083963	0,082994	0,083929
0,1	87	0,085331	0,086133	0,087256
0,1	88	0,083996	0,084965	0,086141
0,1	89	0,083519	0,085278	0,0861
0,1	90	0,084508	0,083125	0,083978
0,1	91	0,083408	0,082935	0,083911
0,1	92	0,08374	0,083018	0,083872
0,1	93	0,085644	0,083345	0,084304
0,1	94	0,083869	0,083239	0,084302
0,1	95	0,08344	0,091009	0,09199
0,1	96	0,084997	0,083736	0,084662
0,1	97	0,083509	0,086096	0,08706
0,1	98	0,08431	0,083637	0,084602
0,1	99	0,082499	0,0833	0,084255
0,1	100	0,085731	0,083938	0,084936
0,1	101	0,082793	0,083329	0,084271
0,1	102	0,083516	0,083466	0,084297
0,1	103	0,083917	0,083857	0,084894
0,1	104	0,08325	0,085873	0,08675
0,1	105	0,083798	0,090702	0,091624
0,1	106	0,085476	0,083829	0,084722
0,1	107	0,083018	0,083397	0,084405
0,1	108	0,083329	0,084267	0,085171
0,1	109	0,085187	0,082949	0,083782
0,1	110	0,083377	0,084161	0,085237
0,1	111	0,083742	0,084541	0,085309
0,1	112	0,085131	0,101299	0,102087
0,1	113	0,084151	0,082796	0,083777
0,1	114	0,082878	0,08328	0,084251

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,1	115	0,083823	0,083592	0,084342
0,1	116	0,083674	0,083209	0,083995
0,1	117	0,084561	0,085029	0,085842
0,1	118	0,084786	0,083563	0,084357
0,1	119	0,084303	0,083067	0,083847
0,1	120	0,084479	0,085133	0,085947
0,1	121	0,085352	0,083407	0,084198
0,1	122	0,083634	0,083761	0,084509
0,1	123	0,085744	0,09223	0,092915
0,1	124	0,084548	0,083144	0,083928
0,1	125	0,085731	0,084644	0,085453
0,1	126	0,084173	0,084633	0,085369
0,1	127	0,084708	0,083649	0,084399
0,1	128	0,083379	0,083031	0,083809
0,1	129	0,082999	0,084547	0,085284
0,1	130	0,083627	0,085134	0,085943
0,1	131	0,08427	0,083328	0,084084
0,1	132	0,085741	0,083818	0,084616
0,1	133	0,083263	0,08328	0,084037
0,1	134	0,08361	0,092231	0,09309
0,1	135	0,086222	0,083931	0,084731
0,1	136	0,085089	0,08703	0,087744
0,1	137	0,085452	0,083755	0,084552
0,1	138	0,084613	0,083186	0,083946
0,1	139	0,084399	0,083788	0,084535
0,1	140	0,084926	0,083121	0,083903
0,1	141	0,083554	0,083002	0,083776
0,1	142	0,084073	0,088794	0,089636
0,1	143	0,084006	0,089511	0,090357
0,1	144	0,084081	0,083969	0,084713
0,1	145	0,083547	0,085936	0,086759
0,1	146	0,083985	0,084348	0,085153
0,1	147	0,084845	0,086489	0,087207
0,1	148	0,085156	0,08336	0,084149
0,1	149	0,083304	0,083107	0,08387
0,1	150	0,08382	0,091058	0,091912

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,01	1	0,089017	0,094125	0,095157
0,01	2	0,083385	0,084456	0,085336
0,01	3	0,082783	0,082971	0,08378
0,01	4	0,083065	0,084597	0,085326
0,01	5	0,083453	0,083023	0,083742
0,01	6	0,082538	0,083402	0,084136
0,01	7	0,082768	0,082968	0,083697
0,01	8	0,082923	0,082961	0,083686
0,01	9	0,082274	0,083477	0,084109
0,01	10	0,082641	0,082926	0,083712
0,01	11	0,082697	0,083127	0,083888
0,01	12	0,082556	0,083503	0,084229
0,01	13	0,082618	0,083038	0,083808
0,01	14	0,08241	0,083201	0,083947
0,01	15	0,082697	0,08414	0,084865
0,01	16	0,082595	0,08437	0,085147
0,01	17	0,082339	0,082954	0,083683
0,01	18	0,082494	0,083148	0,08392
0,01	19	0,082994	0,083719	0,08445
0,01	20	0,082455	0,083387	0,084142
0,01	21	0,082168	0,084251	0,084882
0,01	22	0,08237	0,083	0,083666
0,01	23	0,082222	0,083736	0,084442
0,01	24	0,082087	0,083352	0,084052
0,01	25	0,082082	0,083079	0,083696
0,01	26	0,082353	0,083017	0,083867
0,01	27	0,08228	0,083457	0,084302
0,01	28	0,082526	0,08321	0,083994
0,01	29	0,082286	0,08303	0,083824
0,01	30	0,082084	0,083107	0,084082
0,01	31	0,082209	0,082989	0,083814
0,01	32	0,082099	0,083152	0,083957
0,01	33	0,08224	0,083181	0,083791
0,01	34	0,082299	0,083054	0,083743
0,01	35	0,082024	0,083075	0,083811
0,01	36	0,082229	0,083217	0,08413
0,01	37	0,082355	0,083395	0,084148
0,01	38	0,082447	0,082919	0,08374
0,01	39	0,082117	0,083805	0,084559

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,01	40	0,082224	0,083218	0,083896
0,01	41	0,081981	0,083464	0,084353
0,01	42	0,082041	0,084611	0,085447
0,01	43	0,082134	0,083077	0,083852
0,01	44	0,082224	0,083215	0,08404
0,01	45	0,082111	0,083512	0,084385
0,01	46	0,081963	0,083981	0,08484
0,01	47	0,082068	0,084451	0,084838
0,01	48	0,082409	0,08324	0,08415
0,01	49	0,082206	0,08331	0,084279
0,01	50	0,082004	0,083786	0,08481
0,01	51	0,082014	0,083587	0,084448
0,01	52	0,082002	0,083151	0,083921
0,01	53	0,08199	0,083656	0,084542
0,01	54	0,082208	0,083383	0,084263
0,01	55	0,0817	0,084014	0,084772
0,01	56	0,081871	0,083977	0,084918
0,01	57	0,081776	0,083183	0,083997
0,01	58	0,081861	0,08344	0,084388
0,01	59	0,081805	0,083892	0,084684
0,01	60	0,082021	0,083447	0,084399
0,01	61	0,0817	0,084311	0,084867
0,01	62	0,081708	0,084149	0,085127
0,01	63	0,081769	0,083636	0,084468
0,01	64	0,081711	0,083409	0,084203
0,01	65	0,081498	0,083705	0,084688
0,01	66	0,0816	0,084329	0,084972
0,01	67	0,081512	0,084267	0,085094
0,01	68	0,081538	0,083721	0,084555
0,01	69	0,081503	0,083596	0,084598
0,01	70	0,081488	0,08416	0,084913
0,01	71	0,081542	0,083521	0,084316
0,01	72	0,08149	0,083537	0,084335
0,01	73	0,081665	0,083709	0,084582
0,01	74	0,081907	0,083346	0,083978
0,01	75	0,081463	0,084436	0,085193
0,01	76	0,081594	0,084016	0,084786
0,01	77	0,081382	0,084214	0,084559
0,01	78	0,08153	0,088203	0,088473

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,01	79	0,0816	0,085869	0,086599
0,01	80	0,081457	0,083429	0,084624
0,01	81	0,081385	0,084829	0,085974
0,01	82	0,081146	0,083943	0,084813
0,01	83	0,081278	0,083568	0,084855
0,01	84	0,081252	0,085371	0,086401
0,01	85	0,081262	0,084649	0,085025
0,01	86	0,08123	0,085484	0,085901
0,01	87	0,081609	0,083448	0,084523
0,01	88	0,081154	0,083872	0,085206
0,01	89	0,08092	0,084593	0,085734
0,01	90	0,081334	0,083985	0,085276
0,01	91	0,081083	0,085759	0,086226
0,01	92	0,081251	0,085635	0,086332
0,01	93	0,081181	0,084362	0,085157
0,01	94	0,081029	0,084397	0,085474
0,01	95	0,081133	0,083487	0,084406
0,01	96	0,081114	0,084825	0,085844
0,01	97	0,081049	0,085083	0,086116
0,01	98	0,080961	0,08564	0,086953
0,01	99	0,081222	0,084131	0,085269
0,01	100	0,08124	0,084725	0,086208
0,01	101	0,081154	0,084522	0,08471
0,01	102	0,081023	0,084446	0,084787
0,01	103	0,081052	0,08442	0,085218
0,01	104	0,081038	0,085273	0,085959
0,01	105	0,081015	0,083628	0,084474
0,01	106	0,080962	0,085379	0,086205
0,01	107	0,08114	0,083349	0,084416
0,01	108	0,081204	0,08439	0,084856
0,01	109	0,081079	0,084624	0,086146
0,01	110	0,080709	0,084727	0,085382
0,01	111	0,081134	0,084047	0,085034
0,01	112	0,081035	0,084862	0,085832
0,01	113	0,080868	0,083956	0,0852
0,01	114	0,080901	0,084215	0,0854
0,01	115	0,080881	0,084715	0,085852
0,01	116	0,081187	0,084548	0,085379
0,01	117	0,080894	0,084807	0,08583

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,01	118	0,080843	0,084483	0,085272
0,01	119	0,081011	0,086768	0,087646
0,01	120	0,080868	0,083644	0,08486
0,01	121	0,0811	0,084679	0,085898
0,01	122	0,080797	0,084202	0,085119
0,01	123	0,08092	0,084768	0,085401
0,01	124	0,081197	0,084032	0,085053
0,01	125	0,080711	0,08438	0,085744
0,01	126	0,080659	0,084145	0,085232
0,01	127	0,080856	0,084164	0,084586
0,01	128	0,080748	0,084644	0,085669
0,01	129	0,080553	0,086099	0,086956
0,01	130	0,080494	0,084169	0,085459
0,01	131	0,080561	0,08375	0,084736
0,01	132	0,080664	0,083791	0,08509
0,01	133	0,080593	0,084882	0,086327
0,01	134	0,080652	0,084573	0,08509
0,01	135	0,080696	0,084201	0,085241
0,01	136	0,080468	0,08518	0,086742
0,01	137	0,080535	0,084003	0,085387
0,01	138	0,080417	0,085268	0,086276
0,01	139	0,080672	0,085028	0,086532
0,01	140	0,080497	0,084771	0,085335
0,01	141	0,080907	0,084353	0,085481
0,01	142	0,080412	0,084304	0,086041
0,01	143	0,08084	0,084581	0,086635
0,01	144	0,0806	0,084148	0,085659
0,01	145	0,080428	0,08531	0,086247
0,01	146	0,080126	0,084631	0,086647
0,01	147	0,080723	0,085968	0,087476
0,01	148	0,08033	0,08452	0,085948
0,01	149	0,080328	0,084847	0,08632
0,01	150	0,08027	0,084085	0,085766

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,001	1	0,105694	0,085528	0,087256
0,001	2	0,083321	0,083279	0,084527
0,001	3	0,082751	0,082998	0,084089
0,001	4	0,082535	0,084031	0,085085
0,001	5	0,082666	0,084808	0,085714
0,001	6	0,082944	0,0837	0,084701
0,001	7	0,082867	0,083913	0,084914
0,001	8	0,082955	0,082904	0,083842
0,001	9	0,08277	0,082943	0,083917
0,001	10	0,082458	0,08295	0,083908
0,001	11	0,082448	0,08513	0,086015
0,001	12	0,082605	0,08426	0,085218
0,001	13	0,082227	0,08308	0,084022
0,001	14	0,082359	0,08319	0,084115
0,001	15	0,082206	0,082931	0,083846
0,001	16	0,082167	0,082931	0,083848
0,001	17	0,082492	0,084124	0,08507
0,001	18	0,08246	0,083086	0,083985
0,001	19	0,082472	0,083172	0,084079
0,001	20	0,08245	0,083273	0,084133
0,001	21	0,082354	0,083225	0,084129
0,001	22	0,082577	0,083371	0,084272
0,001	23	0,082312	0,082922	0,083792
0,001	24	0,082223	0,083319	0,084193
0,001	25	0,08245	0,083238	0,084092
0,001	26	0,082429	0,085105	0,08598
0,001	27	0,082821	0,084573	0,085432
0,001	28	0,082317	0,08419	0,084952
0,001	29	0,08239	0,082951	0,083738
0,001	30	0,082389	0,083127	0,083904
0,001	31	0,082208	0,08329	0,084053
0,001	32	0,082509	0,083139	0,083882
0,001	33	0,08218	0,083188	0,08391
0,001	34	0,082273	0,084091	0,084864
0,001	35	0,082253	0,083287	0,084005
0,001	36	0,082353	0,083775	0,0845
0,001	37	0,08274	0,084597	0,08532
0,001	38	0,082172	0,083342	0,084079
0,001	39	0,082313	0,083373	0,084125

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,001	40	0,082155	0,083175	0,083904
0,001	41	0,082231	0,084333	0,085046
0,001	42	0,082896	0,083361	0,084073
0,001	43	0,082122	0,083043	0,083722
0,001	44	0,082124	0,083163	0,083878
0,001	45	0,08215	0,08332	0,084039
0,001	46	0,082341	0,08405	0,084774
0,001	47	0,082523	0,083086	0,083819
0,001	48	0,082206	0,083604	0,08434
0,001	49	0,082121	0,083216	0,083924
0,001	50	0,08238	0,083568	0,084297
0,001	51	0,082098	0,082971	0,083731
0,001	52	0,082109	0,084103	0,084823
0,001	53	0,082259	0,083009	0,083749
0,001	54	0,082283	0,084391	0,085127
0,001	55	0,082099	0,083057	0,083775
0,001	56	0,08232	0,08305	0,083758
0,001	57	0,082275	0,085116	0,085866
0,001	58	0,082269	0,084125	0,084863
0,001	59	0,08214	0,083124	0,083839
0,001	60	0,082081	0,08318	0,083933
0,001	61	0,082072	0,083129	0,083863
0,001	62	0,082372	0,083184	0,083922
0,001	63	0,082178	0,083385	0,084145
0,001	64	0,082034	0,083684	0,084423
0,001	65	0,082153	0,083012	0,083721
0,001	66	0,082108	0,083082	0,083821
0,001	67	0,082167	0,082997	0,083736
0,001	68	0,082251	0,083097	0,083842
0,001	69	0,082136	0,083305	0,084044
0,001	70	0,08211	0,083046	0,08379
0,001	71	0,082165	0,084461	0,085186
0,001	72	0,082095	0,083177	0,083913
0,001	73	0,082036	0,08346	0,084195
0,001	74	0,08207	0,085258	0,085992
0,001	75	0,082122	0,082988	0,083753
0,001	76	0,082003	0,084227	0,085
0,001	77	0,082007	0,083671	0,084432
0,001	78	0,082362	0,084261	0,085023

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,001	79	0,082045	0,083816	0,084561
0,001	80	0,082256	0,083582	0,084316
0,001	81	0,082245	0,083012	0,083744
0,001	82	0,082039	0,083083	0,083843
0,001	83	0,08215	0,083038	0,083817
0,001	84	0,08217	0,083097	0,083846
0,001	85	0,081988	0,082955	0,083708
0,001	86	0,082231	0,083166	0,083881
0,001	87	0,082115	0,083	0,083747
0,001	88	0,082073	0,083321	0,084065
0,001	89	0,082157	0,083065	0,083811
0,001	90	0,082058	0,08318	0,083917
0,001	91	0,082123	0,083219	0,083992
0,001	92	0,082191	0,083999	0,084751
0,001	93	0,082149	0,082991	0,083763
0,001	94	0,082068	0,083046	0,083829
0,001	95	0,081977	0,083141	0,083916
0,001	96	0,082015	0,083089	0,083839
0,001	97	0,081996	0,083212	0,083978
0,001	98	0,082293	0,083012	0,083762
0,001	99	0,082222	0,083133	0,083878
0,001	100	0,082127	0,083174	0,083944
0,001	101	0,08208	0,083005	0,083746
0,001	102	0,082144	0,083254	0,084004
0,001	103	0,082049	0,084079	0,084865
0,001	104	0,08226	0,083007	0,083807
0,001	105	0,082104	0,08324	0,084079
0,001	106	0,082071	0,083236	0,084035
0,001	107	0,082117	0,083014	0,08379
0,001	108	0,08213	0,083067	0,083825
0,001	109	0,082144	0,082978	0,083732
0,001	110	0,081837	0,083526	0,084318
0,001	111	0,082104	0,084925	0,085676
0,001	112	0,08221	0,083207	0,083965
0,001	113	0,082028	0,082973	0,083727
0,001	114	0,082156	0,082953	0,083741
0,001	115	0,082218	0,082991	0,083706
0,001	116	0,082005	0,083108	0,083909
0,001	117	0,082209	0,083437	0,084229

<i>Learning Rate</i>	<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>MSE</i>
0,001	118	0,082066	0,083065	0,083873
0,001	119	0,082102	0,082999	0,083811
0,001	120	0,082025	0,083001	0,083825
0,001	121	0,082032	0,083951	0,084747
0,001	122	0,082058	0,083149	0,083951
0,001	123	0,082064	0,083001	0,083834
0,001	124	0,082034	0,08382	0,084627
0,001	125	0,082162	0,083333	0,084136
0,001	126	0,082098	0,083189	0,083961
0,001	127	0,08202	0,083035	0,08387
0,001	128	0,081933	0,08438	0,085204
0,001	129	0,082136	0,083158	0,083941
0,001	130	0,082183	0,082966	0,083751
0,001	131	0,082157	0,083006	0,083829
0,001	132	0,08206	0,083287	0,08404
0,001	133	0,08196	0,083433	0,084241
0,001	134	0,0821	0,083579	0,084326
0,001	135	0,08209	0,083065	0,083853
0,001	136	0,082047	0,08312	0,083951
0,001	137	0,08199	0,083021	0,083811
0,001	138	0,081918	0,083992	0,084785
0,001	139	0,082027	0,083057	0,083884
0,001	140	0,082102	0,083276	0,084045
0,001	141	0,081966	0,083065	0,083842
0,001	142	0,082075	0,082967	0,083824
0,001	143	0,081974	0,082999	0,083832
0,001	144	0,082131	0,083104	0,083985
0,001	145	0,082077	0,083537	0,084371
0,001	146	0,082034	0,084913	0,08575
0,001	147	0,081916	0,083087	0,083943
0,001	148	0,082025	0,083836	0,084592
0,001	149	0,081967	0,084154	0,084927
0,001	150	0,082307	0,083136	0,083987



# UNIVERSITAS MEDAN AREA

## FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estasi/Jalan PBSI Nomor 1 ☎(061) 7366878, 7360168, 7364348, 7366781, Fax (061) 7366998 Medan 20223  
Kampus II : Jalan Setia Budi Nomor 79 / Jalan Sei Serayu Nomor 70 A, ☎ (061) 8225602, Fax. (061) 8226331 Medan 20122  
Website: [www.teknik.uma.ac.id](http://www.teknik.uma.ac.id) E-mail: [univ\\_medanarea@uma.ac.id](mailto:univ_medanarea@uma.ac.id)

Nomor : 363/FT.6/01.10/VII/2024  
Lamp : -  
Hal : **Perubahan Judul Tugas Akhir**

30 Juli 2024

Yth, Pembimbing Tugas Akhir  
**Susilawati, S. Kom, M. Kom**  
di  
Tempat

Dengan hormat, Sehubungan dengan adanya perubahan judul tugas akhir maka perlu diterbitkan kembali SK Pembimbing Skripsi baru atas nama mahasiswa tersebut :

N a m a : Tita Larose Togatorop  
N P M : 198160081  
Jurusan : Teknik Informatika

Maka dengan hormat kami mengharapkan kesediaan saudara :

**Susilawati, S. Kom, M. Kom** (Sebagai Pembimbing)

Adapun Tugas Akhir Skripsi berjudul :

**"Analisis Pengaruh *Learning Rate* dalam Menentukan *Mean Square Error (MSE)* pada Algoritma *Long Short Term Memory (LSTM)*".**

SK Pembimbing ini berlaku selama enam bulan terhitung sejak SK ini diterbitkan. Jika proses pembimbing melebihi batas waktu yang telah ditetapkan, SK ini dapat ditinjau ulang.

Demikian kami sampaikan, atas kesediaan saudara diucapkan terima kasih.

An. Dekan,  
Wakil Bid. Penjaminan Mutu  
Akademik

  
**Susilawati, S. Kom, M. Kom**



# UNIVERSITAS MEDAN AREA FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estetis/Jalan PGSI Nomor 1 8225602, 7360168, 7364348, 7366781, Fax (061) 7366098 Medan 20223

Kampus II : Jalan Setiabudi Nomor 79 / Jalan Sei Serayu Nomor 70 A, 8225602, Fax (061) 8226331 Medan 20122

Website: www.teknik.uma.ac.id E-mail: univ\_medanarea@uma.ac.id

Nomor : 682 /FT.6/01.10/IX/2023  
Lamp : -  
Hal : Penelitian Dan Pengambilan Data Tugas Akhir

20 September 2023

Yth. Kepala Dinas Komunikasi dan Informatika Kabupaten Humbang Hasudutan  
Komplek Perkantoran Tano Tubu, Pasaribu, Doloksanggul  
Di  
Humbang Hasudutan

Dengan hormat,  
Kami mohon kesediaan Bapak/Ibu berkenan untuk memberikan izin dan kesempatan kepada mahasiswa kami tersebut dibawah ini :

NO	NAMA	NPM	PRODI
1	Tita Larose Togatorop	198160081	Teknik Informatika

Untuk melaksanakan Penelitian dan Pengambilan Data Tugas Akhir pada perusahaan/Instansi yang Bapak/Ibu Pimpin.

Perlu kami jelaskan bahwa Pengambilan Data tersebut adalah semata-mata untuk tujuan ilmiah dan Skripsi yang merupakan salah satu syarat bagi mahasiswa tersebut untuk mengikuti ujian sarjana pada Fakultas Teknik Universitas Medan Area dan tidak untuk dipublikasikan, dengan judul penelitian :

**Sistem Rekomendasi Bandwith Penggunaan Aplikasi di Dinas Komunikasi dan Informatika Kabupaten Humbang Hasudutan menggunakan Algoritma Long Short Term Memory (LSTM)**

Atas perhatian dan kerja sama yang baik diucapkan terima kasih.



Tembusan :  
1. Ka. BAMAI  
2. Mahasiswa  
3. File



PEMERINTAH KABUPATEN HUMBANG HASUNDUTAN  
DINAS KOMUNIKASI DAN INFORMATIKA  
Kompleks Perkantoran Tano Tubu Jl. Sisingamangaraja km. 2,2 Doloksanggul  
Telp./ Fax: (0633) 311555 kode pos 22457  
e\_mail : [diskominfo@humbanghasundutankab.go.id](mailto:diskominfo@humbanghasundutankab.go.id)

**SURAT KETERANGAN SELESAI MELAKSANAKAN PENELITIAN**  
Nomor: 555/275/Diskominfo/XI/2023

Yang bertandatangan dibawah ini:

NAMA : BATARA FRANZ SIREGAR, SE  
NIP : 19781101 200312 1 003  
PANGKAT/GOL : PEMBINA Tk. I, IV/b  
JABATAN : KEPALA DINAS

Dengan ini menyatakan bahwa:

NAMA : TITA LAROSE TOGATOROP  
NPM : 198160081  
PRODI : TEKNIK INFORMATIKA  
FAKULTAS : TEKNIK  
UNIVERSITAS : MEDAN AREA

Yang bersangkutan telah selesai melaksanakan penelitian di Dinas Komunikasi dan Informatika Kabupaten Humbang Hasundutan pada tanggal 23 Oktober 2023 dengan topik penelitian Sistem Rekomendasi Manajemen Bandwidth pada Penggunaan Aplikasi di Dinas Komunikasi dan Informatika dengan Menggunakan Algoritma Long Short Term Memory (LSTM) untuk penyusunan tugas akhir.

Surat keterangan ini diberikan agar dapat dipergunakan sebagaimana mestinya.

Doloksanggul 24 Oktober 2023

Kepala Dinas Komunikasi dan Informatika  
Kabupaten Humbang Hasundutan  
  
Batara Franz Siregar, SE  
NIP. 19781101 200312 1 003



Similarity Report ID: oid:29477:673995:

PAPER NAME

**TITA LAROSE TOGATOROP.pdf**

AUTHOR

**TITA LAROSE TOGATOROP**

WORD COUNT

**6534 Words**

CHARACTER COUNT

**35907 Characters**

PAGE COUNT

**37 Pages**

FILE SIZE

**1.3MB**

SUBMISSION DATE

**Sep 23, 2024 2:48 PM GMT+7**

REPORT DATE

**Sep 23, 2024 2:48 PM GMT+7**

● **21% Overall Similarity**

The combined total of all matches, including overlapping sources, for each database.

- 17% Internet database
- 4% Publications database
- Crossref database
- Crossref Posted Content database
- 14% Submitted Works database

● **Excluded from Similarity Report**

- Bibliographic material
- Cited material
- Abstract
- Small Matches (Less than 15 words)





