


**PREDIKSI KINERJA *TIME SERIES WELL PERFORMANCE* BERDASARKAN  
*LONG SHORT-TERM MEMORY (LSTM)***



**AYUB**

**H011191031**



**PROGRAM STUDI MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS HASANUDDIN  
MAKASSAR**

**2024**

**PREDIKSI KINERJA *TIME SERIES WELL PERFORMANCE* BERDASARKAN  
*LONG SHORT-TERM MEMORY (LSTM)***

**AYUB**

**H011191031**



**PROGRAM STUDI MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS HASANUDDIN  
MAKASSAR  
2024**



**PREDIKSI KINERJA *TIME SERIES WELL PERFORMANCE* BERDASARKAN  
*LONG SHORT-TERM MEMORY (LSTM)***

AYUB

H011191031

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Sains

Program Studi Matematika

Pada

**PROGRAM STUDI MATEMATIKA  
DEPARTEMEN MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS HASANUDDIN  
MAKASSAR  
2024**



**SKRIPSI**

**PREDIKSI KINERJA *TIME SERIES WELL PERFORMANCE* BERDASARKAN  
*LONG SHORT-TERM MEMORY (LSTM)***

Disusun dan diajukan oleh

**AYUB**

**H011191031**

Skripsi,

Telah dipertahankan di depan Panitia Ujian yang dibentuk dalam rangka Penyelesaian Studi Program Sarjana Sains Program Studi Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin

Pada tanggal 8 Juli 2024

Dan dinyatakan telah memenuhi syarat kelulusan.

Mengesahkan:

Pembimbing Utama

Pembimbing Pertama

Prof. Dr. Jeffry Kusuma, Ph.D

Dr. Muh. Nur, S.Si., M.Si.

NIP. 19641112 198703 1 002

NIP. 19850529 200812 1 002

Menyetujui:

Ketua Departemen,

Dr. Firman, S.Si., M.Si.

NIP. 19680429 200212 1 001





**PERNYATAAN KEASLIAN SKRIPSI  
DAN PELIMPAHAN HAK CIPTA**

Yang bertanda tangan di bawah ini:

Nama : AYUB  
Nim : H011191031  
Program Studi : Matematika  
Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya yang berjudul:

**PREDIKSI KINERJA *TIME SERIES WELL PERFORMANCE* BERDASARKAN *LONG SHORT-TERM MEMORY (LSTM)***

Adalah karya tulisan saya sendiri dan bukan merupakan pengambilan alihan tulisan orang lain, bahwa tulisan skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka skripsi ini. Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Dengan ini saya melimpahkan hak cipta (hak ekonomis) dari karya tulis saya berupa skripsi ini kepada Universitas Hasanuddin.

Makassar, 8 Juli 2024

Yang menyatakan,



*Ayub*  
AYUB  
H011191031



## UCAPAN TERIMA KASIH

Puji Tuhan, penulis panjatkan puji syukur ke hadirat Tuhan yang Maha Esa atas segala limpahan rahmat, nikmat, dan karunia-Nya sehingga tugas akhir ini dapat terselesaikan dengan lancar yang berjudul **"Prediksi Kinerja *Time Series Well Performance* Berdasarkan *Long Short-Term Memory (LSTM)*"**. Dengan berbagai rintangan yang dihadapi saat menyelesaikan tugas ini, tidak lupa untuk penulis mengucapkan terima kasih atas kontribusi dan bantuannya kepada :

1. Bapak Prof. Dr. Ir. Jamaluddin Jompa, M.Sc. selaku Rektor Universitas Hasanuddin beserta seluruh jajarannya, serta Bapak Dr. Eng. Amiruddin selaku Dekan Fakultas Matematika Dan Ilmu Pengetahuan Alam beserta jajarannya.
2. Bapak Dr. Firman, S.Si., M.Si. selaku Ketua Departemen Matematika Fakultas Matematika Dan Ilmu Pengetahuan Alam Universitas Hasanuddin beserta Bapak dan Ibu Dosen Departemen Matematika yang telah membantu penulis.
3. Bapak Prof. Dr. Jeffry Kusuma, Ph.D dan Bapak Dr. Muh. Nur, S.Si., M.Si. selaku dosen pembimbing yang dengan sabar telah memberikan saran, kritik, dan masukan yang bermanfaat sehingga skripsi ini dapat tersusun dengan baik.
4. Bapak Dr. Khaeruddin, M.Sc dan Bapak Dr. Firman, S.Si., M.Si selaku dosen penguji I dan dosen penguji II yang telah memberikan saran yang membangun demi kesempurnaan skripsi yang telah disusun untuk menjadi lebih baik lagi.
5. Kedua orang tua penulis, Bapak Pamewa dan Ibu Arruan Langi' yang selalu memberikan doa dan dukungan selama ini dan juga terkhusus untuk bapak yang memberikan masukan seputar bagaimana dalam menyusun skripsi dengan baik.
6. Adik penulis, Yehezkiel dan Gideon dan keluarga besar yang telah memberikan dukungan dan doa sampai titik terselesaikannya penyusunan skripsi.
7. Tante Seti' dan om Roberth yang terus mendukung penulis dalam menyelesaikan skripsi ini dengan baik.
8. Teman-teman seperjuangan, Samuel, Edin, Heri, Fatha, Jeki, Ferdi, Ade, Rifqy, Kiply, Rozzaq, Ichsan, Resa, Wawan, Toni, Ilham, Hanif, Rais, Rabil, Zidan, Tasya, dan seluruh teman Prodi Matematika 2019 yang telah membantu dan memberi semangat dalam menyusun skripsi ini dan berjuang bersama-sama hingga saat ini.
9. Teman-teman KKNT Perhutanan Sosial Toraja Utara, terkhusus Wandu, Gilbert, Melki, Lopinta, Austin, dan Elma yang terus mendukung penulis sampai bisa menyelesaikan skripsi ini dengan baik.
10. Semua pihak yang terlibat dalam penulisan skripsi ini yang belum bisa disebutkan satu per satu yang telah mendukung dalam proses penulisan skripsi ini.

Semoga Tuhan Yesus memberkati dan memberikan rahmat dan berkat-Nya kepada semua pihak yang turut membantu menyelesaikan skripsi ini. Walaupun masih jauh dari kata sempurna, tetapi dengan tulisan ini semoga dapat bermanfaat bagi pembacanya.

Makassar, 8 Juli 2024

AYUB



## ABSTRAK

AYUB. *Prediksi Kinerja Time Series Well Performance Berdasarkan Long Short-Term Memory (LSTM)* (dibimbing oleh Jeffry Kusuma dan Muh. Nur).

**Latar Belakang.** Long Short Term Memory (LSTM), sebagai inovasi dari Recurrent Neural Network (RNN), mengatasi keterbatasan RNN dan ANN dalam memproses informasi jangka panjang. **Tujuan.** Dalam industri minyak dan gas, LSTM berperan penting dalam memprediksi hasil produksi sumur minyak, mendukung optimalisasi hasil, pengurangan risiko, dan peningkatan efisiensi operasional. **Metode.** Penelitian ini berfokus pada algoritma LSTM untuk memprediksi hasil produksi minyak mentah berdasarkan data historis. Masalahnya melibatkan evaluasi kemampuan LSTM dalam prediksi jangka panjang dan membandingkannya dengan algoritma lain. Tujuannya untuk memperoleh hasil dan keakuratan prediksi, serta menilai keunggulan LSTM dibandingkan alternatif lainnya. **Hasil.** Temuan penelitian menunjukkan bahwa LSTM memberikan prediksi yang memuaskan terhadap hasil produksi sumur minyak dengan tingkat akurasi yang tinggi. Perbandingan dengan algoritma lain menawarkan wawasan mendalam mengenai keunggulan LSTM dalam konteks industri minyak dan gas. Penelitian ini memberikan kontribusi signifikan terhadap pengembangan metode prediksi tingkat lanjut, yang meningkatkan keakuratan estimasi laju produksi minyak mentah. Selain itu, mengatasi masalah inisialisasi bobot dalam model jaringan saraf untuk menghindari hilangnya gradien juga dibahas. Metrik evaluasi performa model, seperti Mean Squared Error (MSE) dan Root Mean Square Error (RMSE), dijelaskan sebagai parameter penilaian akurasi. **Kesimpulan.** Dengan temuan tersebut, penelitian ini mendukung pengembangan solusi yang lebih andal dalam manajemen produksi minyak dan gas.

**Kata Kunci:** *Long Short Term Memory, Artificial Neural Network, Recurrent Neural Network*, Produksi sumur minyak, Inisialisasi bobot, MSE, RMSE.



## ABSTRACT

AYUB. *Prediksi Kinerja Time Series Well Performance Berdasarkan Long Short-Term Memory (LSTM)* (dibimbing oleh Jeffry Kusuma dan Muh. Nur).

**Background.** Long Short Term Memory (LSTM), as an innovation from Recurrent Neural Network (RNN), overcomes the limitations of both RNN and ANN in processing long-term information. **Aim.** In the oil and gas industry, LSTM plays a crucial role in predicting the production outcomes of oil wells, supporting result optimization, risk reduction, and operational efficiency enhancement. **Method.** This research focuses on the LSTM algorithm to predict the production outcomes of crude oil based on historical data. The problem involves evaluating LSTM's ability in long-term prediction and comparing it with other algorithms. The objectives are to obtain results and prediction accuracy, as well as to assess the superiority of LSTM compared to alternatives. **Results.** The research findings demonstrate that LSTM provides satisfactory predictions for oil well production outcomes with a high level of accuracy. Comparisons with other algorithms offer in-depth insights into LSTM's superiority in the context of the oil and gas industry. This research significantly contributes to the development of advanced prediction methods, enhancing the accuracy of crude oil production rate estimates. Additionally, addressing the issue of initializing weights in the neural network model to avoid vanishing gradients is discussed. Evaluation metrics for model performance, such as Mean Squared Error (MSE) and Root Mean Square Error (RMSE), are explained as parameters for accuracy assessment. **Conclusion.** With these findings, this research supports the development of more reliable solutions in oil and gas production management.

**Keywords:** Long Short Term Memory, Artificial Neural Network, Recurrent Neural Network, Oil Well Production, Weight Initialization, MSE, RMSE.



## DAFTAR ISI

	Halaman
HALAMAN JUDUL.....	i
PERNYATAAN PENGAJUAN.....	ii
HALAMAN PENGESAHAN.....	iii
PERNYATAAN KEASLIAN SKRIPSI DAN PELIMPAHAN HAK CIPTA.....	iv
UCAPAN TERIMA KASIH.....	v
ABSTRAK.....	vi
ABSTRACT.....	vii
DAFTAR ISI.....	viii
DAFTAR TABEL.....	x
DAFTAR GAMBAR.....	xi
DAFTAR PERSAMAAN.....	xii
DAFTAR LAMPIRAN.....	xiii
DAFTAR SINGKATAN DAN SIMBOL.....	xiv
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	2
1.3 Tujuan Penelitian.....	2
1.4 Batasan Masalah.....	2
1.5 Manfaat Penelitian.....	2
1.6 Sistematika Penulisan.....	3
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>4</b>
2.1 Minyak Bumi di Indonesia.....	4
2.2 Artificial Neural Network (ANN).....	4
2.3 Recurrent Neural Network (RNN).....	5
2.4 Long Short Term Memory(LSTM).....	6
2.5 Inisialisasi Bobot.....	8
2.6 Loss Function.....	9
<b>BAB III METODOLOGI PENELITIAN.....</b>	<b>23</b>
3.1 Metode Penelitian.....	23
3.2 Waktu dan Tempat Penelitian.....	23
3.3 Prosedur Penelitian.....	23
3.4 Alur Penelitian.....	25
<b>BAB IV HASIL DAN PEMBAHASAN.....</b>	<b>26</b>
4.1 PENDAHULUAN.....	26
4.2 Penerapan Algoritma Long Short-Term Memory (LSTM).....	27
4.2.1 Penerapan algoritma LSTM menggunakan inisialisasi bobot dengan menggunakan metode inisialisasi Nguyen-Windrow.....	27
4.2.2 Penerapan algoritma LSTM tanpa menggunakan Inisialisasi bobot dengan	



menggunakan metode inisialisasi Nguyen-Windrow.....	35
4.3 Perbandingan algoritma LSTM, RNN dengan algoritma ANN.....	41
BAB V PENUTUP.....	45
5.1 Kesimpulan.....	45
5.2 Saran.....	45
DAFTAR PUSTAKA.....	47
LAMPIRAN.....	48



## DAFTAR TABEL

Nomor Urut	Halaman
1. Nilai RMSE <i>training</i> LSTM menggunakan Inisialisasi Nguyen-Windraw.....	33
2. Nilai RMSE <i>training</i> LSTM tanpa Inisialisasi Nguyen-Windraw.....	40
3. Hasil Prediksi minyak mentah lima tahun yang akan datang.....	44



## DAFTAR GAMBAR

Nomor urut	Halaman
1. Jaringan saraf biologis otak manusia.....	5
2. Skema proses Recurrent Neural Network (RNN).....	6
3. Skema proses Long Short-Term Memory (LSTM).....	10
4. Fungsi aktivasi tan hiperbolik (tanh).....	11
5. Fungsi aktivasi sigmoid.....	12
6. Langkah forget gate.....	13
7. Langkah input gate.....	15
8. Langkah cell gate.....	19
9. Langkah output gate.....	20
10. <i>Flowchart</i> .....	25
11. Grafik Data Produksi Minyak Mentah di Indonesia.....	26
12. Grafik perubahan nilai RMSE terhadap banyaknya <i>epoch training</i> pada <i>epoch</i> ke-50, 500, dan 1000.....	34
13. Grafik Hasil Pradiksi produksi minyak mentah di Indonesia lima tahun yang akan datang menggunakan Nguyen-Windraw.....	35
14. Grafik perubahan nilai RMSE terhadap banyaknya <i>epoch training</i> pada <i>epoch</i> ke-50, 500, dan 1000.....	40
15. Grafik Hasil Prediksi produksi minyak mentah di Indonesia lima tahun yang akan datang tanpa menggunakan Nguyen-Windraw.....	41
16. Grafik Hasil nilai loss function pada epoch ke-100.....	42
17. Grafik Hasil Prediksi Produksi minyak bumi dengan menggunakan tiga Metode LSTM, RNN, dan ANN.....	43
18. Grafik Hasil Perbandingan Prediksi Produksi minyak bumi.....	44



## DAFTAR PERSAMAAN

Nomor urut	Halaman
1. Persamaan (1)	6
2. Persamaan (2)	6
3. Persamaan (3)	7
4. Persamaan (4)	7
5. Persamaan (5)	7
6. Persamaan (6)	7
7. Persamaan (7)	8
8. Persamaan (8)	8
9. Persamaan (9)	8
10. Persamaan (10)	8
11. Persamaan (11)	9
12. Persamaan (12)	9
13. Persamaan (13)	9
14. Persamaan (14)	11
15. Persamaan (15)	12



**DAFTAR LAMPIRAN**

Nomor urut	Halaman
1. Data Produksi Minyak Bumi di Indonesia dari Tahun 1973 sampai 2022.....	48
2. Grafik hasil training.....	49
3. Kode Program Python.....	55



## DAFTAR SINGKATAN DAN SIMBOL

LSTM	: <i>Long Short Term Memory.</i>
RNN	: <i>Recurrent Neural Network.</i>
ANN	: <i>Artificial Neural Network.</i>
MSE	: <i>Mean Square Error.</i>
RMSE	: <i>Root Mean Square Error</i>
$H_{t-1}$	: Hasil data asli.
$H_t$	: Hasil data Prediksi.
$f_t$	: <i>forget gate.</i>
$i_t$	: <i>input gate</i>
$\tilde{C}_t$	: sel kandidat memperbaiki $i_t$ .
$c_t$	: <i>call gate.</i>
$o_t$	: <i>output gate</i>
$b_i$	: Bias ke- $i$ .
$\ W_s\ $	: memperbaiki inisialisasi bobot.
$\phi$	: Fungsi aktivasi <i>sigmoid.</i>
$\tanh$	: Fungsi aktivasi <i>tan hiperbolik</i>
$W_s$	: inisialisasi bobot
$\beta$	: Skala Nguyen-Windrow ( $\beta=0,7(p)^{\frac{1}{n}}$ ), dengan $p$ adalah unit <i>hidden layer</i> , dan $n$ adalah jumlah unit <i>input layer</i> .
$n$	: Jumlah <i>input layer</i> .



# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

*Long Short-Term Memory* (LSTM) merupakan evolusi dari salah satu algoritma *deep learning* yaitu *Recurrent Neural Network* (RNN), mengatasi salah satu kekurangan RNN yaitu kemampuan memproses informasi dalam jangka waktu yang lama. LSTM sering dipilih orang untuk prediksi berbasis waktu atau deret waktu karena dikenal unggul dan andal dalam melakukan prediksi dalam jangka waktu lama dibandingkan algoritma lainnya. Topik inflasi menjadi topik perdebatan yang penting, karena merupakan salah satu faktor penentu keberhasilan pengelolaan perekonomian suatu negara dan merupakan faktor penentu dalam kebijakan perekonomian (Zahara, Sugianto, & limiddafid, 2019).

Industri minyak dan gas merupakan sektor yang penuh tantangan, dengan peningkatan kompleksitas dalam pengelolaan aset. Sumur minyak, sebagai komponen kunci dalam rantai produksi, memerlukan prediksi yang akurat untuk memaksimalkan hasil produksi, mengurangi risiko, dan meningkatkan efisiensi operasional. Minyak merupakan campuran yang sangat kompleks, terutama terdiri dari senyawa hidrokarbon, khususnya senyawa organik, masing-masing molekul hanya mengandung unsur karbon dan hidrogen. Minyak bumi banyak mengandung hidrokarbon, tetapi juga mengandung unsur belerang, vanadium, nikel, besi, dan tembaga. Air dan garam hampir selalu terdapat dalam minyak dalam keadaan terdispersi. Bahan non-hidrokarbon ini, sering dianggap sebagai pengotor, karena umumnya akan mengganggu selama pemrosesan minyak di kilang dan akan berdampak negatif (boros) pada produk (Bakhri, 2021).

*Time series well performance* sumur merupakan sumber informasi kritis dalam industri minyak. Prediksi yang akurat terhadap perilaku sumur di masa depan sangat penting untuk pengelolaan aset dan pengambilan keputusan strategi. Dalam menghadapi kompleksitas pola perilaku sumur, pendekatan berbasis jaringan saraf seperti *Long Short-Term Memory* (LSTM) muncul sebagai solusi yang efektif untuk menganalisis dan memprediksi data dari waktu ke waktu. LSTM adalah jenis jaringan saraf rekurensial (RNN) yang dirancang khusus untuk mengatasi masalah *vanishing gradien* yang sering terjadi pada RNN tradisional. LSTM memiliki unit memori internal yang memungkinkannya untuk "mengingat" informasi dari masa lalu dalam rentang waktu yang lama.

Memori jangka panjang (LSTM) adalah jaringan saraf berulang (RNN) yang dimodifikasi. LSTM dibuat untuk mengatasi masalah ketergantungan jangka panjang RNN yang tidak mengingat informasi dalam waktu lama, untuk membandingkan dengan informasi yang sedang diproses (Kumar, Md, Jeckson, & dkk, 2023).

Penelitian ini mengusulkan model berbasis jaringan saraf *Long Short-Term Memory* (LSTM) untuk peramalan produksi minyak pada sumur minyak yang ada di Indonesia. Model ini menangkap data urutan waktu laju minyak dan kendala produksi, dan dioptimalkan. Dua studi kasus dilakukan, membandingkan kinerja model dengan



jaringan saraf lainnya, pendekatan perkiraan deret waktu, dan kurva penurunan konvensional, yang menunjukkan keunggulannya.

Berdasarkan penelitian yang dilakukan oleh Xuanyi Song, dan kawan-kawan pada tahun 2019 tentang Peramalan produksi minyak merupakan salah satu isu terpenting dalam fase eksploitasi sumur minyak. Keterbatasan metode tradisional membuat peramalan rangkaian waktu produksi masih menjadi tantangan. Dengan berkembangnya kecerdasan buatan, algoritma yang canggih memungkinkan perkiraan produksi yang andal dari perspektif data. Studi ini mengusulkan model berbasis jaringan saraf memori jangka pendek (LSTM) untuk menyimpulkan pembentukan sumur horizontal yang retak di reservoir vulkanik, mengatasi keterbatasan metode tradisional dan memperkenalkan prediksi yang akurat. Berdasarkan penelitian tersebut yang telah diperoleh oleh peneliti sebelumnya, dan dituangkan dalam penelitian yang berjudul "*Prediksi Kinerja Time Series Well Performance Berdasarkan Long Short-Term Memory (LSTM)*".

## 1.2 Rumusan Masalah

Rumusan masalah berdasarkan latar belakang di atas adalah:

1. Bagaimana algoritma LSTM dapat memprediksi hasil produksi minyak dengan data hasil produksi minyak bumi sebelumnya?
2. Bagaimana hasil perbandingan algoritma LSTM dengan algoritma lainnya?

## 1.3 Tujuan Penelitian

Tujuan dalam penelitian ini adalah:

1. Memperoleh hasil dan tingkat keakuratan algoritma LSTM dalam memprediksi jangka panjang hasil produksi sumur minyak bumi.
2. Membandingkan algoritma LSTM dengan algoritma lainnya.

## 1.4 Batasan Masalah

Penelitian ini terbatas pada skala yang signifikan, dengan kompleksitas yang membutuhkan pendekatan Long-Short Term Memory (LSTM). Model-model lainnya, seperti arsitektur jaringan saraf tiruan lainnya, akan dibahas untuk membandingkan hasil prediksi.

## 1.5 Manfaat Penelitian

Penelitian ini bagaimana mengoptimalkan dan mengadaptasi model LSTM untuk prediksi minyak bumi, memberikan kontribusi pada pengembangan metode analisis deret waktu yang lebih efektif. Memungkinkan prediksi perilaku sistem pada titik waktu masa depan berdasarkan data masa lalu dan saat ini.



## 1.6 Sistematika Penulisan

Sistematika penulisan dalam penelitian ini adalah sebagai berikut.

### **BAB I PENDAHULUAN**

Dalam bab ini dipaparkan mengenai latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan sistematika penulisan.

### **BAB II TINJAUAN PUSTAKA**

Bab ini mencakup pemaparan secara singkat mengenai konsep dasar yang menunjang pembahasan masalah, yaitu definisi-definisi dan istilah-istilah yang berkaitan dengan algoritma *Long-Short Term Memory*(LSTM)

### **BAB III METODOLOGI PENELITIAN**

Dalam bab ini dijelaskan tentang metode penelitian, waktu dan tempat penelitian, prosedur penelitian, serta alur penelitian yang digunakan oleh penulis.

### **BAB IV PEMBAHASAN**

Pada bab ini disajikan pembahasan dari tugas akhir yakni menentukan Prediksi kinerja sumur deret waktu berdasarkan model jaringan saraf Long Short-Term Memory (LSTM) dengan model jaringan saraf lainnya.

### **BAB V PENUTUP**

Pada bab ini menyajikan kesimpulan hasil penelitian dan saran yang ditujukan bagi peneliti selanjutnya untuk mengembangkan penelitian yang telah dikaji dalam tugas akhir ini.



## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Minyak Bumi di Indonesia

Minyak bisa juga disebut minyak bumi, yang berasal dari bahasa Yunani, tepatnya dari kata petrus dan oleum dan juga oleus, petrus adalah batu, oleus adalah minyak. Minyak bumi adalah cairan kental berwarna coklat tua yang terdiri dari banyak senyawa hidrokarbon yang tersusun rumit. Sebagaimana kita ketahui, minyak bumi merupakan salah satu sumber energi yang sangat dibutuhkan dalam berbagai bidang tergantung dari kebutuhannya masing-masing, salah satu penerapannya pada industri, transportasi dan berbagai bidang kegiatan sehari-hari. Beberapa orang percaya bahwa mengubah energi cahaya dapat menghasilkan energi listrik, tanpa menimbulkan limbah seperti pembakaran bahan bakar atau menghasilkan banyak bahan bakar fosil lainnya (Wati, Erwan, & dkk, 2019).

Penemuan minyak bumi pertama kali dilaporkan di Indonesia pada tahun 1885 di Pangkalan Brandan, Sumatera Utara, oleh seorang ahli geologi Belanda, C.A.L Dummler. Penemuan ini menandai dimulainya eksplorasi lebih lanjut di daerah tersebut. Pada awal abad ke-20, perusahaan minyak dan gas asing mulai masuk dan beroperasi di Indonesia. Royal Dutch Shell mendirikan Bataafsche Petroleum Maatschappij (BPM) di Hindia Belanda pada tahun 1907. Perusahaan ini kemudian berkembang menjadi Royal Dutch Shell Group.

Setelah kemerdekaan Indonesia pada tahun 1945, pemerintah Indonesia mengambil alih sebagian besar industri minyak dan gas di wilayah tersebut. Pada tahun 1947, Pertamina didirikan sebagai perusahaan minyak nasional.

#### 2.2 Artificial Neural Network (ANN)

Artificial neural network (ANN) yang merupakan salah satu bentuk kecerdasan buatan telah banyak diaplikasikan dalam bidang computer, teknik listrik, fisika, financial, dan lain-lain.


Jaringan syaraf tiruan (ANN) adalah salah satu representasi tiruan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia. Otak manusia berisi berjuta-juta sel syaraf (neuron) yang bertugas untuk memproses informasi. Setiap sel saling berinteraksi untuk mendukung kemampuan kerja otak. Setiap sel saraf akan memiliki inti sel yang bertugas memproses informasi (Hadihardaja & Sutikno, 2005).

Perkembangan ilmu Neural network sudah ada sejak tahun 1943 ketika Warren McCulloch dan Walter Pitts memperkenalkan perhitungan model neural network yang pertama kalinya. Kemudian dilanjutkan oleh Rosenblatt pada tahun 1950, dimana dia berhasil menemukan sebuah two-layers network yang disebut sebagai perceptron. Perceptron memungkinkan untuk pekerjaan klasifikasi pembelajaran tertentu dengan penambahan bobot pada setiap koneksi antar-network. Keberhasilan perceptron dalam



pengklasifikasian pola tertentu ini tidak sepenuhnya sempurna, masih ditemukan juga beberapa keterbatasan didalamnya. Perceptron tidak mampu untuk menyelesaikan permasalahan XOR (exclusive-OR). Penilaian terhadap keterbatasan neural network ini membuat penelitian di bidang ini sempat mati selama kurang lebih 15 tahun. Namun demikian, perceptron berhasil menjadi sebuah dasar untuk penelitian-penelitian selanjutnya di bidang neural network (Abraham, 2002).

Jaringan saraf biologis Otak manusia terdiri atas sekitar  $10^{11}$  sel saraf (neuron) yang bertugas untuk memproses informasi yang masuk. Tiap sel saraf bekerja seperti prosesor dan dihubungkan dengan sel saraf lain hingga  $10^4$  sinapsis. Masing-masing sel saraf tersebut saling berinteraksi sehingga mendukung kemampuan kerja otak manusia. Berikut jaringan saraf pada manusia:



**Gambar 1.** Jaringan saraf biologis otak manusia

Komponen utama neuron dapat dikelompokkan menjadi 4 bagian:

1. Dendrit, bertugas menerima informasi dan jalur input bagi badan sel.
2. Badan sel (soma), berfungsi sebagai tempat pengolahan informasi.
3. Akson, bertugas mengirimkan impuls-impuls sinyal ke sel saraf lain dan jalur output bagi badan sel.
4. Sinaptik gap, berfungsi sebagai tempat menghubungkan ujung sel saraf dengan sel saraf lainnya.

Jaringan saraf tiruan atau Artificial Neural Network adalah sebuah cara pengolahan informasi yang terinspirasi dari sistem kerja saraf biologis, seperti kinerja otak yang memproses sesuai informasi. Metode ANN adalah suatu struktur baru dari sistem pengolahan informasi, yang terdiri dari sejumlah besar elemen-elemen pemrosesan yang saling berhubungan (neuron) dan saling bekerja sama untuk pemecahan masalah-masalah tertentu (Balaji & Baskaran, 2013).

### 2.3 Recurrent Neural Network (RNN)

Sejarah RNN dapat ditelusuri kembali ke awal tahun 1980-an. Salah satu model RNN pertama yang dikenal sebagai jaringan saraf rekurensial Elman diperkenalkan oleh Jeffrey Elman pada tahun 1990. Model ini memiliki struktur sederhana dan berhasil mengatasi beberapa masalah pembelajaran jarak jauh (long-term dependencies) yang sulit memecahkan jaringan saraf biasa pada saat itu.




Jaringan Saraf Rekuren (Recurrent Neural Network atau disingkat RNN) adalah jenis arsitektur jaringan saraf yang dirancang khusus untuk menangani data urutan atau data dengan dimensi waktu. RNN memiliki kemampuan untuk menyimpan informasi atau keadaan internal, sehingga dapat mengingat informasi dari masa lalu dan menggunakannya dalam pemrosesan informasi saat ini. Ini membuat RNN sangat berguna dalam tugas-tugas seperti pemrosesan bahasa alami, prediksi deret waktu, dan tugas lain yang melibatkan urutan data (Ivanedra & Mustikasari, 2019).

RNN memiliki koneksi berulang dimana keadaan tersembunyi terakhir merupakan masukan ke keadaan berikutnya. Pembaruan dapat digambarkan sebagai berikut:

$$h_t = \tanh(W_{xh} X_t + W_{hh} h_{t-1} + b_h) \quad (1)$$

$$= \tanh(W_{xhh} [X_t, h_{t-1}] + b_h).$$

$$y_t = g(WX_t h_t + b_h). \quad (2)$$



Gambar 2. Skema proses Recurrent Neural Network (RNN)

## 2.4 Long Short Term Memory (LSTM)

LSTM diperkenalkan oleh Sepp Hochreiter dan Jürgen Schmidhuber pada tahun 1997 dalam makalah berjudul "Long Short-Term Memory." LSTM dirancang untuk mengatasi kendala jarak jauh yang dihadapi oleh RNN konvensional. Salah satu inovasi utama dari LSTM adalah penggunaan "sel memori" yang memungkinkan informasi untuk dihapus atau disimpan dalam waktu yang lama (Arfan & ETP, 2020).

Peningkatan signifikan dalam penggunaan dan popularitas LSTM terjadi pada awal tahun 2010-an. Ini terkait dengan kemajuan lebih lanjut dalam teknik pelatihan jaringan saraf, peningkatan daya komputasi, dan keberhasilan aplikasi praktis di berbagai bidang seperti pemrosesan bahasa alami (NLP), pengenalan wicara, dan pemodelan deretan waktu.

LSTM (Long Short-Term Memory) pada kecerdasan buatan yang terinspirasi dari prinsip-prinsip dasar dalam sistem saraf biologi, terutama dalam hal bagaimana



otak manusia mengelola dan menyimpan informasi dalam jangka waktu yang lama. Namun perlu diingat bahwa LSTM dan jaringan saraf kecerdasan buatan lainnya hanya merupakan model kasar dari prinsip-prinsip yang kita temui dalam sistem saraf biologi. Beberapa persamaan konsep antara LSTM dan fungsi otak manusia meliputi:

1. **Memori Jangka Panjang dan Pendek:** Seperti otak manusia, LSTM memiliki mekanisme untuk menyimpan informasi dalam jangka waktu yang lama (memori jangka panjang) dan untuk mengakses informasi secara cepat dalam jangka waktu singkat (memori jangka pendek).
2. **Sel-sel Memori (Memory Cells):** Ide utama di balik LSTM adalah penggunaan sel-sel memori yang dapat menyimpan dan mengakses informasi dalam suatu urutan.
3. **Gerbang (Gates):** LSTM memiliki "gerbang" yang dapat mengontrol aliran informasi ke dalam dan keluar dari sel-sel memori. Ini mencerminkan cara otak manusia memutuskan untuk menyimpan atau mengabaikan informasi.

Long Short-Term Memory (LSTM) adalah tipe arsitektur dalam jaringan saraf tiruan (neural networks), khususnya dalam ranah deep learning. LSTM dirancang untuk menangani permasalahan ketidakmampuan model rekurrent (RNN) tradisional dalam mengatasi masalah vanishing gradient, yang terjadi saat pelatihan model dengan data urutan panjang.

Selama perhitungan LSTM, perhitungan dilakukan dengan rumus berikut:

- a. Putuskan informasi apa yang harus dibuang dari keadaan sel sebelumnya  $C_{t-1}$  di gerbang forget gate  $f_t$ .

$$f_t = \sigma(W_f [H_{t-1}, X_t] + b_f). \quad (3)$$

- b. Identifikasi informasi di  $X_t$  yang harus disimpan ke dalam keadaan sel  $C_t$ ,  $i_t$  input gate informasi dan keadaan sel kandidat  $\tilde{C}_t$  memperbaiki informasi.

$$i_t = \sigma(W_i [H_{t-1}, X_t] + b_i) \quad (4)$$

Dan

$$\tilde{C}_t = \tanh(W_c [H_{t-1}, X_t] + b_c). \quad (5)$$

- c. Memperbaiki status sel langkah waktu sekarang  $C_t$ , memori jangka panjang  $C_t$  dan memori jangka panjang  $C_{t-1}$ .

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t. \quad (6)$$

- d. Dimana digunakan output gate formasi  $o_t$  dan status sel  $C_t$  digunakan untuk konfirmasi hasil  $H_t$  di gerbang keluaran.



$$o_t = \sigma(W_o [H_{t-1}, X_t] + b_o) \quad (7)$$

Dan

$$H_t = o_t * \tanh(C_t). \quad (8)$$

Dimana  $X_t$  adalah vektor input pada waktu (t),  $h_t$  adalah vektor output,  $C_t$  adalah state sel memori,  $i_t$  adalah vektor input gate,  $f_t$  adalah vektor forget gate,  $o_t$  adalah vektor output gate,  $W$  dan  $U$  adalah bobot metrik,  $b$  adalah vektor bias, dan  $\sigma$  adalah fungsi aktivasi sigmoid (Rizkilloh & Widiyanesti, 2022).

## 2.5 Inisialisasi Bobot

Inisialisasi bobot dengan menggunakan metode inisialisasi Nguyen-Windrow. Algoritma inisialisasi bobot dengan menggunakan Nguyen-Widrow adalah sebagai berikut:

$$\beta = 0,7(p)^{\frac{1}{n}} \quad (9)$$

dengan  $\beta$  adalah skala Nguyen-Windrow,  $p$  jumlah hidden layer dan  $n$  adalah input layer.

Inisialisasi bobot  $W_{s,j}$  dimana  $j$  *hidden layer ke-j* dan  $W_{s,lama}$  diambil secara random dengan batasan -0,5 hingga 0,5, dengan nilai inialisasi  $W_s'$  adalah  $-0,5 \leq W_s' \leq 0,5$ . Inisialisasi bobot secara acak dari rentang -0,5 hingga 0,5 biasanya digunakan.

1. Inisialisasi bobot dengan nilai yang terlalu terlalu kecil, maka bisa terjadi *vanishing gradient* adalah hilangnya gradien pada proses *backpropagation*. Hal ini terjadi ketika gradien yang dihitung saat proses *backpropagation* menjadi sangat kecil sehingga tidak ada perubahan signifikan pada bobot saat pelatihan.
2. Inisialisasi bobot dengan nilai yang terlalu besar, maka akan terjadi *exploding gradient*. Hal terjadi ketika gradien yang dihitung saat proses *backpropagation* menjadi sangat besar dan terjadi meledaknya gradien pada saat perhitungan *backpropagation* (Novikaginanto, 2012).

Adapun untuk memperoleh besarnya *magnitude* bobot  $W_{s,baru}$

$$\|W_s'\| = \sqrt{\sum_{j=1}^n (W_{s,j}')^2}. \quad (10)$$

Akibatnya diperoleh

$$W_{s,baru} = \frac{\beta W_{s,j}'}{\|W_{s,j}'\|}. \quad (11)$$

Selanjutnya untuk menghitung nilai bias,  $-\beta \leq b_s \leq \beta$  atau  $-0,7 \leq b_s \leq 0,7$ .

Dimana diketahui  $W_{s,j}' = W_{f,j}'$ ,  $W_{s,j}' = W_{ij}'$ ,  $W_{s,j}' = W_{cj}'$  dan  $W_{s,j}' = W_{oj}'$  dan ada dua  $W_{s,lama}$  adalah nilai yang di ambil secara random dan  $W_{s,baru}$  adalah nilai perbaikan dari  $W_{s,lama}$ .



## 2.6 Loss Function

Dalam konteks jaringan saraf, termasuk Long Short-Term Memory (LSTM), nilai loss merupakan suatu ukuran yang menggambarkan seberapa baik model tersebut melakukan prediksi dibandingkan dengan nilai sebenarnya (ground truth). Fungsi kerugian mengukur perbedaan antara model prediksi dengan nilai sebenarnya, dan tujuan utama selama proses pelatihan adalah untuk meminimalkan nilai kerugian.

Untuk LSTM atau jaringan saraf lainnya, proses pelatihan melibatkan optimalisasi parameter-model berulang (bobot dan bias) sehingga nilai loss yang dihasilkan semakin kecil. Pada setiap iterasi (epoch) pelatihan, model memperbarui parameter berdasarkan gradien dari fungsi kerugian terhadap parameter tersebut.

### a. Mean Square Error (MSE)

MSE merupakan nilai rata-rata kuadrat dari error prediksi. Pada tiap data akan dihitung kuadrat perbedaan antar solusi analitik dengan solusi numerik. Semakin besar nilai MSE maka semakin buruk hasil numerik yang diperoleh (Indarwatin, 2019). MSE dapat dihitung dengan menggunakan persamaan:

$$\text{MSE} = \frac{1}{n} \sum_{t=1}^n (H_{t-1} - H_t)^2 \quad (12)$$

dengan,

- $H_{t-1}$  : hasil asli  $H_{t-1}$
- $H_t$  : hasil prediksi  $H_t$ .
- $n$  : jumlah *input*.

### b. Root Mean Square Error (RMSE)

RMSE merupakan nilai rata-rata kuadrat dari error prediksi yang diakarkan. Semakin besar nilai RMSE maka prediksi yang dihasilkan cukup buruk (Indarwatin, 2019). RMSE dapat dihitung menggunakan persamaan berikut.


$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (H_{t-1} - H_t)^2} \quad (13)$$

dengan,

- $H_{t-1}$  : hasil asli  $H_{t-1}$
- $H_t$  : hasil prediksi  $H_t$ .
- $n$  : jumlah *input*.



Skema proses Long Short-Term Memory (LSTM) dapat dilihat pada gambar berikut ini:



Gambar 3. Skema proses Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) dibagi dalam beberapa bagian, yaitu sebagai berikut

a. Input Layer

Input layer adalah bagian dari struktur jaringan saraf yang menerima data masukan dan mengirimkannya ke lapisan berikutnya dalam jaringan. Dalam konteks jaringan saraf buatan, lapisan masukan umumnya terdiri dari neuron-neuron atau unit-unit yang mewakili nilai-nilai masukan. *Layer* ini mewakili variabel *input* ditambah dengan *neuron bias*, *neuron bias* adalah parameter tambahan yang diterapkan ke input sebelumnya, sebelum fungsi aktivasi diterapkan. Penambahan neuron bias dapat membantu meningkatkan fleksibilitas dan kemampuan adaptasi jaringan saraf. Dengan memiliki bias, neuron dapat belajar untuk menghasilkan *output* yang sesuai dalam berbagai situasi. Tanpa *neuron bias*, *input* 0 untuk sebuah *network* pasti memberikan *output* 0 juga. Tentu suatu *network* dapat bekerja tanpa neuron bias, tetapi dengan menambahkan *neuron bias*, *network* yang digunakan dapat mempelajari fungsi yang lebih kompleks. Jika terdapat  $i$  variabel *input*, maka ukuran variabel *input* adalah  $i + b_s$ , dengan  $b_s$  adalah suku bias. Informasi dari *input layer* kemudian dibawa oleh koneksi *input* ke *hidden layer* dengan besaran kekuatan hubungan tertentu (bobot).

b. Kekuatan hubungan (bobot)

Dalam jaringan saraf memori jangka panjang (Long Short-Term Memory atau LSTM), kekuatan hubungan atau bobot (bobot) Merujuk pada parameter yang menentukan seberapa penting atau signifikan suatu input atau informasi dalam mempengaruhi keputusan yang dihasilkan oleh sel memori atau elemen-elemen lain di dalam LSTM. Setiap koneksi antara neuron atau elemen dalam LSTM memiliki bobot yang dapat diatur selama proses pelatihan untuk mengoptimalkan kinerja jaringan.

c. Hidden layer

Hidden layer dapat dianggap sebagai kumpulan sel-sel ini. Setiap sel memori memiliki kemampuan untuk menyimpan dan mengelola informasi dalam jangka panjang, dan selanjutnya, hasil dari setiap sel memori pada suatu waktu tertentu




dapat berkontribusi pada lapisan berikutnya atau menjadi output dari jaringan. Secara umum, sebuah model LSTM dapat memiliki satu atau beberapa lapisan LSTM. Setiap lapisan LSTM adalah suatu entitas yang terdiri dari beberapa sel memori (memory cells) dan masing-masing sel memori memiliki empat gerbang utama forget gate, input gate, cell gate dan output gate. Jika terlalu banyak *hidden layer* maupun *neuron* pada *hidden layer*, maka semakin banyak parameter pada model LSTM, hal ini dapat menyebabkan *overfitting* pada data *training*, akibatnya model dapat menghasilkan prediksi yang buruk. Dalam *hidden layer* terdapat empat dan dua fungsi aktivasi perhitungan matematis yang digunakan, yaitu sebagai berikut:

1. Fungsi aktivasi tan hiperbolik (tanh)

Fungsi tan hiperbolik (tanh) adalah fungsi matematika yang merupakan variasi dari fungsi tangen, dan sering digunakan sebagai fungsi aktivasi dalam jaringan saraf. Fungsi tanh mengkonversi input ke rentang nilai antara -1 dan 1.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (14)$$

Adapun grafik digambarkan sebagai berikut:



**Gambar 4.** Fungsi aktivasi tan hiperbolik (tanh)


2. Fungsi aktivasi sigmoid

Fungsi aktivasi sigmoid mengambil *input* bilangan riil dan menghasilkan *output* dalam rentang 0 hingga 1. Fungsi aktivasi *sigmoid* dirumuskan sebagai berikut:

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (15)$$



Adapun grafik digambarkan sebagai berikut:



Gambar 5. Fungsi aktivasi sigmoid

Fungsi aktivasi sigmoid dipilih dalam proses training pada kasus ini karena rentang nilainya berada diantara 0 hingga 1, hal ini dikaitkan pula dengan besar nilai input layer yang berada pada [0 1].


d. Output Layer

Lapisan keluaran (output layer) adalah lapisan terakhir dari arsitektur jaringan saraf, yang menghasilkan hasil atau prediksi model. Lapisan keluaran berperan penting dalam menentukan bagaimana hasil akhir jaringan saraf dihasilkan dan diinterpretasikan.

Terdapat empat gates yaitu forget gate, input gate, cell gate dan output gate. Proses pertama yang dilakukan oleh LSTM adalah menentukan nilai yang tidak digunakan (forget gate) dengan rumus sebagai berikut:

- **Langkah pertama** yang dilakukan adalah forget gate yaitu  $f_t = \sigma(W_f [H_{t-1}, X_t] + b_f)$  dimana dapat dilihat dalam skema gambar berikut:





Gambar 6. Langkah forget gate

Sebagai contoh diketahui sebagai berikut:

$$H_{t-1} = [1,2,3],$$

$$X_t = [4,5,6],$$

Akibatnya

$$[H_{t-1}, X_t] = [1,2,3,4,5,6].$$

Kemudian menentukan nilai skala Nguyen-Windrow

$$\beta = 0,7(p)^{\frac{1}{n}} = 0,7(1)^{\frac{1}{6}} = 0,7.$$

Selanjutnya menentukan nilai bobot ditentukan secara random

$$W_{f \text{ lama}} = \begin{bmatrix} -0,5 & -0,4 & -0,3 & -0,2 & -0,1 & 0 \\ 0,1 & 0,2 & 0,3 & 0,4 & 0,5 & 0,2 \\ 0,3 & 0,4 & 0,5 & 0,3 & 0,2 & 0,1 \end{bmatrix}.$$

Akan diperoleh nilai bobot yang lama

$$\begin{aligned} \|W_{f_j}\| &= \sqrt{\sum_{j=1}^n (W_{f_j})^2} \\ &= \sqrt{0,25+0,16+0,09+0,04+0,01+0+0,01+0,04+0,09+0,16} \\ &\quad +0,25+0,04+0,09+0,16+0,25+0,09+0,04+0,01 \\ &= \sqrt{1,73}. \end{aligned}$$

Jadi diperoleh nilai bobot barunya sebagai berikut:

$$W_{f \text{ baru}} = \frac{\beta W_{f_j}}{\|W_{f_j}\|}$$



$$= \begin{bmatrix} \frac{0,7(0,25)}{\sqrt{1,73}} & \frac{0,7(0,16)}{\sqrt{1,73}} & \frac{0,7(0,09)}{\sqrt{1,73}} & \frac{0,7(0,04)}{\sqrt{1,73}} & \frac{0,7(0,01)}{\sqrt{1,73}} & \frac{0,7(0)}{\sqrt{1,73}} \\ \frac{0,7(0,01)}{\sqrt{1,73}} & \frac{0,7(0,04)}{\sqrt{1,73}} & \frac{0,7(0,09)}{\sqrt{1,73}} & \frac{0,7(0,16)}{\sqrt{1,73}} & \frac{0,7(0,25)}{\sqrt{1,73}} & \frac{0,7(0,04)}{\sqrt{1,73}} \\ \frac{0,7(0,09)}{\sqrt{1,73}} & \frac{0,7(0,16)}{\sqrt{1,73}} & \frac{0,7(0,25)}{\sqrt{1,73}} & \frac{0,7(0,09)}{\sqrt{1,73}} & \frac{0,7(0,04)}{\sqrt{1,73}} & \frac{0,7(0,01)}{\sqrt{1,73}} \end{bmatrix}$$

$$= \begin{bmatrix} 0,133 & 0,085 & 0,047 & 0,021 & 0,005 & 0 \\ 0,005 & 0,021 & 0,047 & 0,085 & 0,133 & 0,021 \\ 0,047 & 0,085 & 0,133 & 0,047 & 0,021 & 0,005 \end{bmatrix}$$

Selanjutnya mengambil nilai biasnya secara random

$$b_f = [0,5 \ 0,1 \ 0,3]$$

Oleh karna itu nilai forget gatena adalah

$$f_t = \sigma(W_{f \text{ baru}} [H_{t-1}, X_t] + b_f)$$

$$= \begin{bmatrix} 0,133 & 0,085 & 0,047 & 0,021 & 0,005 & 0 \\ 0,005 & 0,021 & 0,047 & 0,085 & 0,133 & 0,021 \\ 0,047 & 0,085 & 0,133 & 0,047 & 0,021 & 0,005 \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \end{bmatrix}$$

$$= \begin{bmatrix} 0,553 \\ 1,319 \\ 0,939 \end{bmatrix}$$

$$\text{Diperoleh } W_{f \text{ baru}} [H_{t-1}, X_t] + b_f = \begin{bmatrix} 0,553 \\ 1,319 \\ 0,939 \end{bmatrix} + \begin{bmatrix} 0,5 \\ 0,1 \\ 0,3 \end{bmatrix} = \begin{bmatrix} 0,053 \\ 1,419 \\ 1,239 \end{bmatrix}$$

$$\text{Akibatnya } f_t = \sigma(W_{f \text{ baru}} [H_{t-1}, X_t] + b_f) = \sigma \begin{bmatrix} 0,053 \\ 1,419 \\ 1,239 \end{bmatrix}$$

$$\sigma[0,053] = \frac{1}{1+e^{-0,053}} = \frac{1}{1+0,948} = 0,513 \approx 0,5,$$

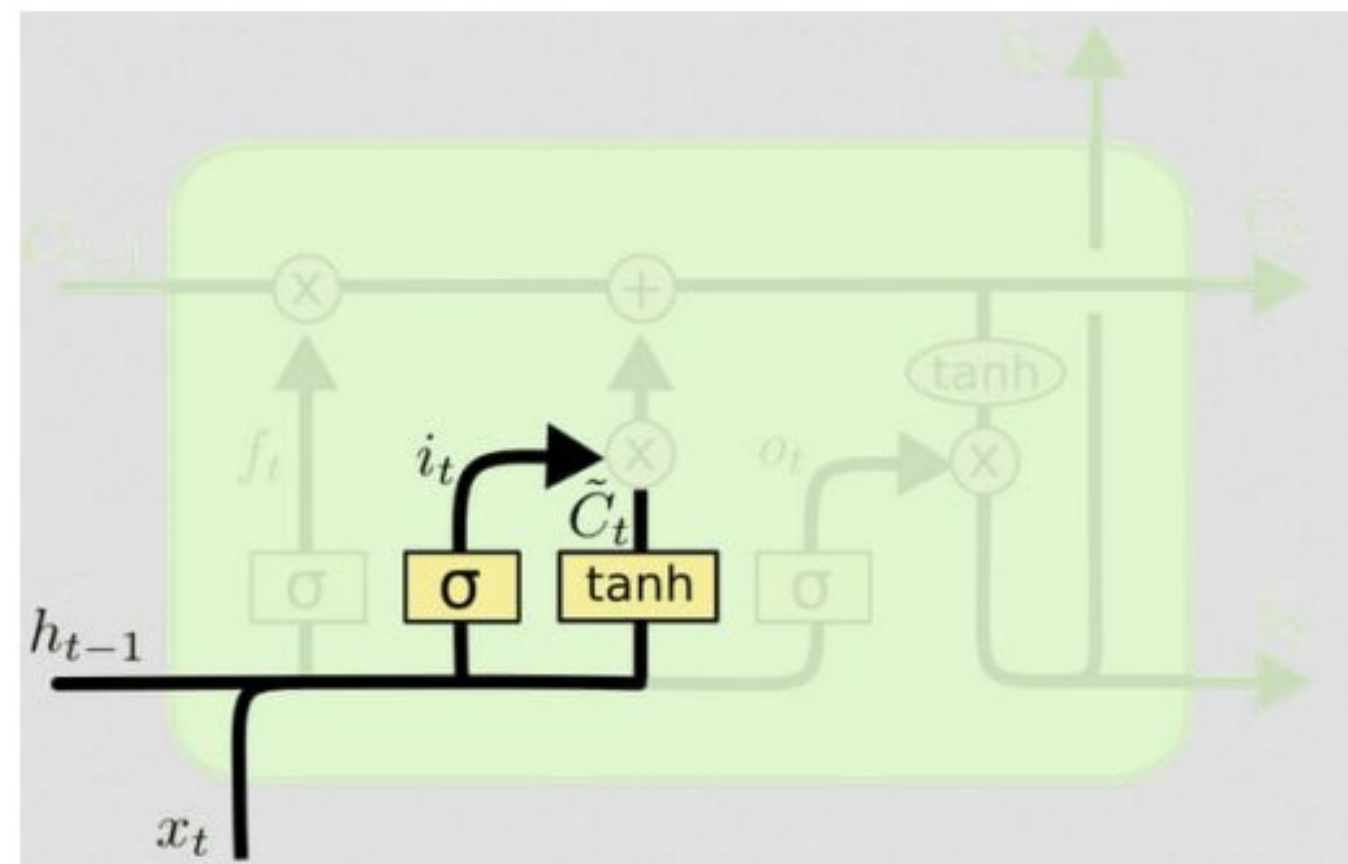
$$\sigma[1,419] = \frac{1}{1+e^{-1,419}} = \frac{1}{1+0,241} = 0,805 \approx 1 \text{ dan}$$

$$\sigma[1,239] = \frac{1}{1+e^{-1,239}} = \frac{1}{1+0,289} = 0,775 \approx 1.$$

$$\text{Jadi } f_t = \sigma(W_{f \text{ baru}} [H_{t-1}, X_t] + b_f) = \begin{bmatrix} 0,5 \\ 1 \\ 1 \end{bmatrix}$$

- Langkah kedua yang dilakukan adalah input gate yaitu  $i_t = \sigma(W_i [H_{t-1}, X_t] + b_i)$  dan  $C_t = \tanh [W_c [H_{t-1}, X_t] + b_c]$  dimana dapat dilihat dalam skema gambar berikut:





**Gambar 7.** Langkah input gate

Tahap input gate  $i_t = \sigma(W_i [H_{t-1}, X_t] + b_i)$

Sebagai contoh diketahui sebagai berikut:

$$H_{t-1} = [1, 2, 3],$$

$$X_t = [4, 5, 6],$$

Akibatnya

$$[H_{t-1}, X_t] = [1, 2, 3, 4, 5, 6].$$

Kemudian menentukan nilai skala Nguyen-Windrow

$$\beta = 0,7(p)^{\frac{1}{n}} = 0,7(1)^{\frac{1}{6}} = 0,7.$$

Selanjutnya menentukan nilai bobot ditentukan secara random

$$W_{i \text{ lama}} = \begin{bmatrix} 0,5 & 0,2 & 0,1 & 0,3 & 0,4 & 0,1 \\ 0,4 & 0,1 & 0 & 0 & 0,4 & 0,3 \\ 0,3 & 0 & 0,3 & 0,3 & 0,5 & 0,3 \end{bmatrix}.$$

Akan diperoleh nilai bobot yang lama

$$\begin{aligned} \|W_{ij}\| &= \sqrt{\sum_{j=1}^n (W_{ij})^2} \\ &= \sqrt{0,25+0,04+0,01+0,09+0,16+0,01+0,16+0,01+0+0 \\ &\quad +0,16+0,09+0,09+0+0,09+0,09+0,25+0,09} \\ &= \sqrt{1,59}. \end{aligned}$$

Jadi diperoleh nilai bobot barunya sebagai berikut:



$$\begin{aligned}
 W_{i \text{ baru}} &= \frac{\beta W_{ij}}{\|W_{ij}\|} \\
 &= \begin{bmatrix} \frac{0,7(0,25)}{\sqrt{1,59}} & \frac{0,7(0,04)}{\sqrt{1,59}} & \frac{0,7(0,01)}{\sqrt{1,59}} & \frac{0,7(0,09)}{\sqrt{1,59}} & \frac{0,7(0,16)}{\sqrt{1,59}} & \frac{0,7(0,01)}{\sqrt{1,73}} \\ \frac{0,7(0,16)}{\sqrt{1,59}} & \frac{0,7(0,01)}{\sqrt{1,59}} & \frac{0,7(0)}{\sqrt{1,59}} & \frac{0,7(0)}{\sqrt{1,59}} & \frac{0,7(0,16)}{\sqrt{1,59}} & \frac{0,7(0,09)}{\sqrt{1,59}} \\ \frac{0,7(0,09)}{\sqrt{1,59}} & \frac{0,7(0)}{\sqrt{1,59}} & \frac{0,7(0,09)}{\sqrt{1,59}} & \frac{0,7(0,09)}{\sqrt{1,59}} & \frac{0,7(0,25)}{\sqrt{1,59}} & \frac{0,7(0,09)}{\sqrt{1,59}} \end{bmatrix} \\
 &= \begin{bmatrix} 0,138 & 0,022 & 0,005 & 0,021 & 0,049 & 0,005 \\ 0,008 & 0,005 & 0 & 0 & 0,088 & 0,049 \\ 0,049 & 0 & 0,049 & 0,049 & 0,138 & 0,049 \end{bmatrix}
 \end{aligned}$$

Kemudian mengambil nilai biasnya secara random

$$b_i = [-0,5 \ 0,2 \ 0,3].$$

Oleh karena itu nilai input gatenya adalah

$$\begin{aligned}
 W_{i \text{ baru}} [H_{t-1}, X_t] &= \begin{bmatrix} 0,138 & 0,022 & 0,005 & 0,021 & 0,049 & 0,005 \\ 0,008 & 0,005 & 0 & 0 & 0,088 & 0,049 \\ 0,049 & 0 & 0,049 & 0,049 & 0,138 & 0,049 \end{bmatrix} \begin{bmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \end{bmatrix} \\
 &= \begin{bmatrix} 0,556 \\ 0,752 \\ 0,939 \end{bmatrix}
 \end{aligned}$$

Selanjutnya

$$W_{i \text{ baru}} [H_{t-1}, X_t] + b_i = \begin{bmatrix} 0,556 \\ 0,752 \\ 0,939 \end{bmatrix} + \begin{bmatrix} -0,5 \\ 0,2 \\ 0,3 \end{bmatrix} = \begin{bmatrix} 0,056 \\ 0,952 \\ 1,239 \end{bmatrix}$$

$$\text{Akibatnya } i_t = \sigma(W_{i \text{ baru}} [H_{t-1}, X_t] + b_i) = \sigma \begin{bmatrix} 0,056 \\ 0,952 \\ 1,239 \end{bmatrix}$$

$$\sigma[0,056] = \frac{1}{1+e^{-0,056}} = \frac{1}{1+0,945} = 0,514 \approx 0,5,$$

$$\sigma[0,952] = \frac{1}{1+e^{-0,952}} \approx \frac{1}{1+0} = 1 \text{ dan}$$

$$\sigma[1,239] = \frac{1}{1+e^{-1,239}} \approx \frac{1}{1+0} = 1.$$

$$\text{Jadi } i_t = \sigma(W_{i \text{ baru}} [H_{t-1}, X_t] + b_i) = \begin{bmatrix} 0,5 \\ 1 \\ 1 \end{bmatrix}.$$

Selanjutnya tahap cell gate  $C_t = \tanh(W_c [H_{t-1}, X_t] + b_c)$



Sebagai contoh diketahui sebagai berikut:

$$H_{t-1} = [1,2,3],$$

$$X_t = [4,5,6],$$

Akibatnya

$$[H_{t-1}, X_t] = [1,2,3,4,5,6].$$

Kemudian menentukan nilai skala Nguyen-Windrow

$$\beta = 0,7(p)^{\frac{1}{n}} = 0,7(1)^{\frac{1}{6}} = 0,7.$$

Selanjutnya menentukan nilai bobot ditentukan secara random

$$W_{c \text{ lama}} = \begin{bmatrix} 0,1 & 0,3 & 0 & 0 & 0,3 & 0,1 \\ 0,1 & 0,4 & 0,5 & 0,2 & 0,5 & 0,2 \\ -0,3 & -0,3 & -0,5 & -0,3 & -0,1 & -0,3 \end{bmatrix}.$$

Akan diperoleh nilai bobot yang lama

$$\begin{aligned} \|W_{c_j}\| &= \sqrt{\sum_{j=1}^n (W_{c_j})^2} \\ &= \sqrt{0,01+0,09+0+0+0,09+0,01+0,01+0,16+0,25+0,04} \\ &\quad +0,25+0,04+0,09+0,09+0,25+0,09+0,01+0,09 \\ &= \sqrt{0,33}. \end{aligned}$$

Jadi diperoleh nilai bobot barunya sebagai berikut:

$$\begin{aligned} W_{c \text{ baru}} &= \frac{\beta W_{c_j}}{\|W_{c_j}\|} \\ &= \begin{bmatrix} \frac{0,7(0,01)}{\sqrt{0,33}} & \frac{0,7(0,09)}{\sqrt{0,33}} & \frac{0,7(0)}{\sqrt{0,33}} & \frac{0,7(0)}{\sqrt{0,33}} & \frac{0,7(0,09)}{\sqrt{0,33}} & \frac{0,7(0,01)}{\sqrt{0,33}} \\ \frac{0,7(0,01)}{\sqrt{0,33}} & \frac{0,7(0,16)}{\sqrt{0,33}} & \frac{0,7(0,25)}{\sqrt{0,33}} & \frac{0,7(0,04)}{\sqrt{0,33}} & \frac{0,7(0,25)}{\sqrt{0,33}} & \frac{0,7(0,04)}{\sqrt{0,33}} \\ \frac{0,7(0,09)}{\sqrt{0,33}} & \frac{0,7(0,09)}{\sqrt{0,33}} & \frac{0,7(0,25)}{\sqrt{0,33}} & \frac{0,7(0,09)}{\sqrt{0,33}} & \frac{0,7(0,01)}{\sqrt{0,33}} & \frac{0,7(0,09)}{\sqrt{0,33}} \end{bmatrix} \end{aligned}$$

Kemudian mengambil nilai biasnya secara random

$$b_c = [0,7 \ 0,5 \ 0,1].$$

Oleh karena itu nilai cell gatenya adalah

$$W_{c \text{ baru}} = \begin{bmatrix} 0,012 & 0,109 & 0 & 0 & 0,109 & 0,012 \\ 0,012 & 0,194 & 0,304 & 0,048 & 0,304 & 0,048 \\ 0,109 & 0,109 & 0,304 & 0,109 & 0,012 & 0,109 \end{bmatrix}$$



$$W_{c \text{ baru}} [H_{t-1}, X_t] = \begin{bmatrix} 0,012 & 0,109 & 0 & 0 & 0,109 & 0,012 \\ 0,012 & 0,194 & 0,304 & 0,048 & 0,304 & 0,048 \\ 0,109 & 0,109 & 0,304 & 0,109 & 0,012 & 0,109 \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \end{bmatrix}$$

$$= \begin{bmatrix} 0,703 \\ 1,736 \\ 1,081 \end{bmatrix}$$

Selanjutnya

$$W_{c \text{ baru}} [H_{t-1}, X_t] + b_c = \begin{bmatrix} 0,703 \\ 1,736 \\ 1,081 \end{bmatrix} + \begin{bmatrix} 0,7 \\ 0,5 \\ 0,1 \end{bmatrix} = \begin{bmatrix} 1,403 \\ 2,236 \\ 1,181 \end{bmatrix}$$

$$\text{Akibatnya } \tilde{C}_t = \tanh [W_{c \text{ baru}} [H_{t-1}, X_t] + b_c] = \tanh \begin{bmatrix} 1,403 \\ 2,236 \\ 1,181 \end{bmatrix}$$


$$\tanh (1,403) = \frac{e^{1,403} - e^{-1,403}}{e^{1,403} + e^{-1,403}} = \frac{3,821}{4,313} = 0,882 \approx 1,$$

$$\tanh (2,236) = \frac{e^{2,236} - e^{-2,236}}{e^{2,236} + e^{-2,236}} = \frac{9,248}{9,462} = 0,977 \approx 1 \text{ dan}$$

$$\tanh (1,181) = \frac{e^{1,181} - e^{-1,181}}{e^{1,181} + e^{-1,181}} = \frac{2,950}{3,564} = 0,827 \approx 1.$$

$$\text{Jadi } \tilde{C}_t = \tanh [W_{c \text{ baru}} [H_{t-1}, X_t] + b_c] = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}.$$

- **Langkah ketiga** yang dilakukan adalah cell gate yaitu  $C_t = f_t * C_{t-1} + i * \tilde{C}_t$ . Dimana dapat dilihat dalam skema gambar dibawah sebagai berikut



Gambar 8. Langkah cell gate



Tahap cell gate  $C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$


Sebagai contoh diketahui sebagai berikut:

$$C_{t-1} = [5,5,5].$$

Jadi diperoleh nilai call gatenya adalah

$$C_t = \begin{bmatrix} 0,5 \\ 1 \\ 1 \end{bmatrix} * \begin{bmatrix} 5 \\ 5 \\ 5 \end{bmatrix} + \begin{bmatrix} 0,5 \\ 1 \\ 1 \end{bmatrix} * \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 3 \\ 6 \\ 5 \end{bmatrix}.$$

- Langkah keempat yang dilakukan adalah output gate yaitu  $o_t = \sigma(W_o [H_{t-1}, X_t] + b_o)$  dimana dapat dilihat dalam skema gambar dibawah sebagai berikut



Gambar 9. Langkah output gate

Tahap output gate  $o_t = \sigma(W_o [H_{t-1}, X_t] + b_o)$

Sebagai contoh diketahui sebagai berikut:

$$H_{t-1} = [1,2,3],$$

$$X_t = [4,5,6],$$

Akibatnya

$$[H_{t-1}, X_t] = [1,2,3,4,5,6].$$

Kemudian menentukan nilai skala Nguyen-Windrow

$$\beta = 0,7(p)^{\frac{1}{n}} = 0,7(1)^{\frac{1}{6}} = 0,7.$$

Selanjutnya menentukan nilai bobot ditentukan secara random

$$W_{o \text{ lama}} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & -0,1 \\ 0,1 & 0,1 & 0,1 & 0,3 & 0,3 & 0,3 \\ 0,2 & 0,2 & 0,2 & 0,2 & 0,2 & 0,2 \end{bmatrix}.$$

Akan diperoleh nilai bobot yang lama



$$\begin{aligned} \|W_{oj}'\| &= \sqrt{\sum_{j=1}^n (W_{oj}')^2} \\ &= \sqrt{0+0+0+0+0+0,01+0,01+0,01+0,01+0,09+0,09+0,09} \\ &\quad +0,04+0,04+0,04+0,04+0,04+0,04 \\ &= \sqrt{0,53}. \end{aligned}$$

Jadi diperoleh nilai bobot barunya sebagai berikut:

$$W_{o \text{ baru}} = \frac{\beta W_{oj}'}{\|W_{oj}'\|} = \begin{bmatrix} \frac{0,7(0)}{\sqrt{0,53}} & \frac{0,7(0)}{\sqrt{0,53}} & \frac{0,7(0)}{\sqrt{0,53}} & \frac{0,7(0)}{\sqrt{0,53}} & \frac{0,7(0)}{\sqrt{0,53}} & \frac{0,7(0,01)}{\sqrt{0,53}} \\ \frac{0,7(0,01)}{\sqrt{0,53}} & \frac{0,7(0,01)}{\sqrt{0,53}} & \frac{0,7(0,01)}{\sqrt{0,53}} & \frac{0,7(0,09)}{\sqrt{0,53}} & \frac{0,7(0,09)}{\sqrt{0,53}} & \frac{0,7(0,09)}{\sqrt{0,53}} \\ \frac{0,7(0,04)}{\sqrt{0,53}} & \frac{0,7(0,04)}{\sqrt{0,53}} & \frac{0,7(0,04)}{\sqrt{0,53}} & \frac{0,7(0,04)}{\sqrt{0,53}} & \frac{0,7(0,04)}{\sqrt{0,53}} & \frac{0,7(0,04)}{\sqrt{0,53}} \end{bmatrix}$$

Kemudian mengambil nilai biasnya secara random

$$b_o = [0,7 \ 0,5 \ 0,1].$$

Oleh karena itu nilai cell gatenya adalah

$$W_{o \text{ baru}} [H_{t-1}, X_t] = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0,009 \\ 0,009 & 0,009 & 0,009 & 0,009 & 0,009 & 0,009 \\ 0,038 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 \end{bmatrix} \begin{bmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \end{bmatrix}$$

$$= \begin{bmatrix} 0,054 \\ 0,189 \\ 0,798 \end{bmatrix}$$

$$\text{Akibatnya } o_t = \sigma(W_o [H_{t-1}, X_t] + b_o) = \sigma \begin{bmatrix} 0,054 \\ 0,189 \\ 0,798 \end{bmatrix}$$

$$\sigma[0,054] = \frac{1}{1+e^{-0,054}} \approx \frac{1}{1+0,947} = 0,5,$$

$$\sigma[0,189] = \frac{1}{1+e^{-0,189}} \approx \frac{1}{1+0} = 1 \text{ dan}$$

$$\sigma[0,798] = \frac{1}{1+e^{-0,798}} \approx \frac{1}{1+0} = 1.$$

$$\text{Jadi } o_t = \sigma(W_o [H_{t-1}, X_t] + b_o) = \begin{bmatrix} 0,5 \\ 1 \\ 1 \end{bmatrix}.$$

Selanjutnya mencari nilai  $H_t = o_t(\tanh(C_t))$

$$\text{Akibatnya } H_t = [(1(\tanh(3))), (1(\tanh(6))), (1(\tanh(5)))]$$



$$\tanh(3) = \frac{e^3 - e^{-3}}{e^3 + e^{-3}} = \frac{20,035}{20,135} = 0,9950,$$

$$\tanh(6) = \frac{e^6 - e^{-6}}{e^6 + e^{-6}} = \frac{403,426}{403,431} = 0,9999 \text{ dan}$$

$$\tanh(4) = \frac{e^5 - e^{-5}}{e^5 + e^{-5}} = \frac{148,406}{148,419} = 0,9999.$$

Diperoleh

$$H_t = [(0,5(0,9950)), (1(0,9999)), (1(0,9999))].$$

$$\text{Jadi } H_t = [(0,497), (0,9999), (0,9999)].$$

Selanjutnya proses menghitung nilai loss dengan persamaan sebagai berikut:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (H_{t-1} - H_t)^2}$$

$$\text{RMSE} = \sqrt{\frac{(1-0,497)^2 + (2-0,9999)^2 + (3-0,9999)^2}{3}}$$

$$\text{RMSE} = 1,323.$$

Hasil dari Program RMSE dari yang dibuat dengan data yang sama.

LSTM Epoch 1/3, Loss: 1.3187906742095947.