



Analisis Performa Choke Dalam Prediksi Well Testing Menggunakan Algoritma Long-Short Term Memory

Rendi Cahya Saputra¹, Fetty Tri Anggraeny², Agung Mustika Rizki³

^{1,2,3}Informatika, Fakultas Ilmu Komputer, UPN Veteran Jawa Timur, Surabaya, Indonesia

Email: reindes@gmail.com¹; fettyanggraeny.if@upnjatim.ac.id²; agung.mustika.if@upnjatim.ac.id³

Saputra, R. C., Anggraeny, F. T., & Rizki, A. M. (2025). Analisis Performa Choke Dalam Prediksi Well Testing Menggunakan Algoritma Long-Short Term Memory. *Journal Cerita: Creative Education of Research in Information Technology and Artificial Informatics*, 11(2), 184-191

DOI: <https://doi.org/10.33050/cerita.v11i2.3575>

ABSTRAK

Well testing adalah proses yang penting dalam industri perminyakan hal ini karena *well testing* berfungsi untuk memprediksi produksi minyak dan gas, yang memungkinkan perusahaan membuat keputusan strategis mengenai optimasi produksi dan alokasi sumber daya. Metode konvensional untuk *well testing* membutuhkan waktu dan biaya yang besar. LSTM, jenis *Recurrent Neural Network* (RNN) dengan penambahan *memory cell* agar dapat menyimpan informasi jangka panjang, diharapkan dapat mengatasi kelemahan ini. penelitian ini menggunakan data *time series*, yang digunakan untuk mempelajari pola produksi. Hasil penelitian menunjukkan bahwa model LSTM dengan skenario terbaik pada *choke* 38 didapatkan pada pembagian data 90%, *hidden size* 150 dan 250, dengan nilai MSE 0.001 dan nilai RMSE 0.044, untuk *choke* 40 didapatkan pada pembagian data 90%, *hidden size* 150, dengan nilai MSE 0.006 dan nilai RMSE 0.078, dan untuk *choke* 42 didapatkan pada pembagian data 90%, *hidden size* 150, dengan nilai MSE 0.007 dan nilai RMSE 0.086, hasil penelitian juga menunjukkan bahwa hasil produksi menggunakan *choke* 42 menunjukkan performa terbaik dibandingkan dengan kedua *choke* lainnya. Penelitian ini menunjukkan bahwa LSTM adalah metode yang efektif untuk prediksi *well testing* dan dapat menjadi alternatif bagi perusahaan minyak dalam mengoptimalkan produksi dan pengambilan keputusan dalam melakukan produksi sumur.

Kata kunci: Prediksi, *Time Series*, LSTM, Perminyakan

ABSTRACT

Well testing is an important process in the petroleum industry because well testing serves to predict oil and gas production, which allows companies to make strategic decisions regarding production optimization and resource allocation. Conventional methods for well testing are time-consuming and costly. LSTM, a type of Recurrent Neural Network (RNN) with the addition of memory cells in order to store long-term information, is expected to overcome this weakness. This research uses time series data, which is used to study production patterns. The results showed that the LSTM model with the best scenario at choke 38 was obtained at 90% data split, hidden size 150 and 250, with MSE value 0.001 and RMSE value 0.044, for choke 40 was obtained at 90% data split, hidden size 150, with MSE value 0.006 and RMSE value 0.078, and for choke 42 obtained at 90% data split, hidden size 150, with MSE value 0.007 and RMSE value 0.086, the results also show that the production results using choke 42 show the best performance compared to the other two chokes. This research shows that LSTM is an effective method for predicting well testing and can be an alternative for oil companies in optimizing production and making decisions on well production.

Keywords: Prediction, Time Series, LSTM, Petroleum

I. PENDAHULUAN

Industri minyak dan gas memegang peranan yang penting dalam memenuhi kebutuhan energi global (Vasudevan et al., 2023). Dimana minyak dan gas merupakan sumber daya utama untuk menghasilkan energi dalam berbagai bentuk, seperti bahan bakar transportasi, pembangkit listrik, dan bahan baku industri kimia. Produksi minyak dan gas memiliki kontribusi besar terhadap perekonomian berbagai negara mulai dari menciptakan lapangan kerja dan mendukung infrastruktur ekonomi.

Forecasting, atau biasa disebut prediksi, adalah sebuah teknik yang menggabungkan seni dan ilmu. Teknik ini digunakan untuk memperkirakan apa yang akan terjadi di masa depan dengan mengolah data masa lalu dan memproyeksikannya menjadi data masa depan dengan model matematika (Nasution, 2019).

Dalam industri migas, prediksi produksi minyak dan gas atau biasa disebut well testing memiliki peran yang sangat penting. Menurut (Ibrahim et al., 2022) prediksi produksi migas merupakan elemen kunci dalam pengambilan keputusan perusahaan minyak. Saat ini, prediksi ini menjadi faktor utama dalam menentukan strategi perusahaan dalam memproduksi sumur. Proses ini memainkan peran penting dalam strategi perusahaan, membantu mereka mengoptimalkan produksi, alokasi sumber daya, dan membuat keputusan yang tepat terhadap investasi dan operasional.

Dalam prediksi produksi sumur terdapat beberapa metode yang umum digunakan untuk memprediksi performa sumur minyak. Simulasi numerik reservoir, meskipun umum digunakan,

proses ini membutuhkan waktu dan sumber daya yang besar, karena melibatkan pembuatan model geologis, model numerik, dan pencocokan historis data formasi, data batuan-fluida, dan lainnya (Jin et al., 2020). *Distributed Acoustic Sensor (DAS)* metode ini menawarkan akurasi tinggi, tetapi membutuhkan biaya yang signifikan karena penggunaan alat berat (Ekechukwu & Sharma, 2021). Selain itu, analisis dari reservoir ke model fisik dan matematis memerlukan asumsi tentang kondisi batas, kekompakan, gaya kapiler, dan efek termal. Metode Analitis, metode ini bergantung pada pengukuran dan analisis fluida yang diproduksi dari sumur secara *real-time*. Operator berperan penting dalam mencatat dan menganalisis kadar air, minyak, dan gas, yang kemudian dianalisis dan diprediksi secara manual. Ketiga metode prediksi konvensional ini memiliki kelemahan yang perlu diperhatikan, yaitu membutuhkan waktu yang lama, sumber daya komputasi yang besar, biaya yang besar dan proses yang melelahkan. Hal ini dapat menghambat pengambilan keputusan yang cepat dan efisien. Penelitian ini bertujuan untuk memprediksi produksi sumur dengan menggunakan pendekatan deep learning, khususnya menggunakan algoritma *Long Short-Term Memory (LSTM)*. Dimana dengan pendekatan ini diharapkan dapat mengurangi biaya operasional sekaligus meningkatkan efisiensi dalam proses prediksi sumur.


Long Short-Term Memory (LSTM) adalah salah satu jenis model pengembangan *Recurrent Neural Network (RNN)* dengan penambahan *memory cell* yang berfungsi menyimpan informasi untuk jangka waktu lama, LSTM juga memiliki fungsi *gates* untuk mempelajari data

yang perlu disimpan dan data yang perlu dilupakan (Sherstinsky, 2020). LSTM sendiri cocok digunakan pada teknologi pemrosesan video maupun teks, dan data *time series*, pada penelitian ini sendiri data yang akan digunakan adalah data *time series*.

Data *Time series* merupakan salah satu tipe data yang digunakan dalam metode prediksi kualitatif. *Time series* adalah kumpulan data yang terdiri dari pengamatan atau catatan kejadian yang terjadi dan memiliki interval waktu yang dapat terjadi secara konsisten atau tidak konsisten. Waktu dalam data *time series* sendiri dapat berupa hari, bulan, dan tahun (Pandji et al., 2019). Pada penelitian ini dataset yang akan digunakan didapatkan dari eksplorasi *well testing* PT. Elnusa Tbk, dalam terdapat tiga variasi *choke* (38, 40, 42) yang nanti akan diprediksi menggunakan model LSTM yang dibuat

II. METODE PENELITIAN

Tahapan penelitian untuk prediksi *well testing Long Short-Term Memory* (LSTM) dibagi menjadi beberapa tahapan. Berikut adalah tahapan-tahapan penelitian yang digunakan.



Gambar 1. Tahapan Penelitian

A. Pengumpulan Data

Penelitian ini dilakukan dengan dataset yang diperoleh dari hasil eksplorasi *well testing* PT. Elnusa Tbk yang digunakan untuk memprediksi dan menganalisa produksi minyak berdasarkan *choke*, dataset diambil setiap 15 menit dan berjumlah sebesar 1878 dataset pada sumur West Pangkah yang diambil pada 15 Mei 2021 - 6 Juni 2021 dengan varian *choke* 38, 40, dan 42.

Tabel 1. Jumlah Dataset

Choke	Jumlah
38	854
40	645
42	379
Total	1,878

B. Pre-processing

Tahap selanjutnya setelah melakukan pengumpulan data adalah *pre-processing*, yaitu tahap dimana dataset akan diolah terlebih dahulu sebelum dilakukan pelatihan menggunakan model LSTM. Tujuan dari *pre-processing* adalah untuk menyesuaikan data dengan model sehingga model dapat membuat prediksi yang akurat dan menghasilkan hasil terbaik (Çetin & Yıldız, 2022).

Pada tahapan pertama yang dilakukan adalah merubah format dataset menjadi CSV (*Comma-Separated Values*), yang umum digunakan untuk menyimpan data dalam bentuk tabel dengan baris dan kolom yang mudah diakses. Dataset ini mencakup fitur-fitur penting seperti BOPD (*Barrels of Oil per Day*), Psig (tekanan sumur), apsig, (tekanan sumur setelah *choke*), BWPD (*Barrels of Water per Day*), MMSCFD (*Million Standard Cubic Feet per Day*), dan BLPD (*Barrels of Liquid per Day*). Fitur-fitur tersebut memberikan informasi krusial terkait performa dan kondisi sumur, yang digunakan sebagai input dalam proses pelatihan model LSTM.

Proses selanjutnya adalah melakukan normalisasi data, Pada proses ini metode normalisasi yang akan digunakan adalah *Min-Max Normalization* metode ini berfungsi untuk menormalisasi data aktual menjadi nilai dengan range interval (0,1) (Islam et al., 2022). Proses ini digunakan untuk mempermudah dalam melakukan pelatihan.

Pada proses selanjutnya adalah proses transformasi data, proses ini dilakukan untuk mengubah data dari *time series* menjadi *supervised*, langkah bertujuan untuk membuat data *time series* dapat digunakan untuk pelatihan model dengan struktur input-output yang jelas. Pada data *time series*, data umumnya tersusun dalam urutan waktu tanpa pasangannya input dan output, sehingga tidak langsung cocok untuk model *supervised* seperti LSTM yang memerlukan data dalam bentuk pasangan fitur dan target.

Proses selanjutnya adalah *split data*, proses ini sangatlah penting dalam machine learning untuk membangun model yang akurat. Pemilihan rasio split data yang tepat berpengaruh besar pada performa model dalam memprediksi data baru yang belum pernah dilihat sebelumnya (Nguyen et al., 2021). pada proses ini data akan dibagi menjadi 2 bagian, yaitu data latih (Train Data) dan data uji (Test Data). Dalam Penelitian ini pembagian data menjadi salah satu faktor dalam pengujian. Pada proses ini terdapat beberapa pembagian sampel data dengan menggunakan pembagian 3 pembagian data yaitu 90% data *train* dan 10% data *test*, 80% data *train* dan 20% data *test*, dan 70% data *train* dan 30% data *test*.

C. Skenario Pengujian

Skenario pengujian dibuat sebelum melakukan pembuatan model LSTM karena skenario pengujian ini akan menggunakan variasi dari *hidden size* dan *split data* yang berbeda. Hal ini dilakukan untuk mencari performa konfigurasi parameter terbaik yang mampu menghasilkan performa prediksi optimal, dengan dibuatnya skenario penelitian ini diharapkan menghasilkan hasil prediksi yang akurat.

Tabel 2. Skenario Pengujian


Split Data	Hidden Size
70%	50
	100
	150
	200
	250
	300
	350

Split Data	Hidden Size
80%	400
	50
	100
	150
	200
	250
	300
90%	350
	400
	50
	100
	150
	200
	250
300	
350	
400	

Tabel 2 diatas menampilkan skenario pengujian yang akan dilakukan, terdapat 24 skenario pengujian yang akan dilakukan pada setiap *choke* dimana terdapat 3 *choke* yaitu *choke* 38, 40, dan 42 untuk *epoch* dan *learning rate* yang digunakan bersifat tetap dengan nilai *epoch* 100 dan *learning rate* 0.001.

D. Pembuatan Model LSTM

Pada thapan ini model LSTM dibuat sesuai skenario yang telah dibuat, pada pembuatan model LSTM sendiri terdapat beberapa tahapan seperti gambar dibawah ini.



Gambar 1. Arsitektur LSTM

Sumber :

<https://medium.com/@daksha.uchagaonkar/lstm-a-detailed-explanation-3dcafa1312e0>

Proses tahapan LSTM dimulai dengan *Input Layer* (x_t), yang menerima dan menginterpretasikan data sebelum diteruskan ke jaringan. Selanjutnya, *Forget Gate* menentukan informasi mana yang perlu dibuang atau disimpan dalam *cell state* berdasarkan nilai antara 0 dan 1. Tahapan *Cell State* berfungsi sebagai memori utama, di mana nilai dari memori sebelumnya diperbarui berdasarkan output dari *Forget Gate*. Akhirnya, *Output Gate* menentukan informasi yang dihasilkan berdasarkan kombinasi nilai input dan kondisi *cell state*. Seluruh proses ini memungkinkan LSTM agar dapat menangkap pola jangka panjang dalam data berurutan dengan efisiensi tinggi.

E. Pelatihan Model

Setelah melakukan pemodelan LSTM langkah selanjutnya adalah melakukan pelatihan terhadap dataset yang telah disiapkan, pelatihan ini dilakukan sesuai skenario pengujian yang telah dibuat, dimana terdapat 24 skenario pengujian yang akan dilakukan pada ketiga *choke*.

Setelah dilakukan pelatihan model akan dievaluasi menggunakan *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE) untuk menilai seberapa akurat model yang telah dibuat untuk memprediksi nilai produksi pada ketiga *Choke*.

F. Pengujian dan Evaluasi Hasil

Setelah dilakukan pelatihan, maka tahapan selanjutnya yang akan dilakukan adalah pengujian dan evaluasi pada pengujian hasil prediksi akan ditampilkan dengan plot grafik, pengujian akan dilakukan sesuai skenario yang telah dibuat, pada evaluasi metode yang digunakan adalah *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE), evaluasi akan dilakukan pada setiap skenario yang telah dibuat untuk menilai skenario mana yang menghasilkan hasil prediksi yang paling akurat.

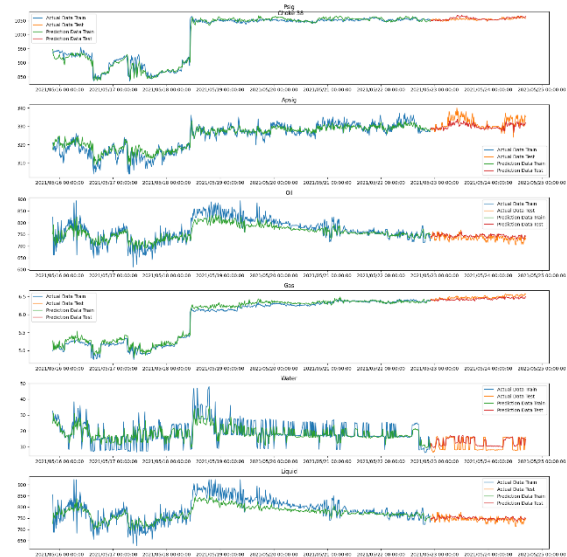
III. HASIL DAN PEMBAHASAN

Hasil dan pembahasan pada penelitian ini akan memberikan hasil dari prediksi yang telah dilakukan.

A. Visualisasi Hasil Prediksi

Pada tahap ini hasil prediksi pada ketiga *choke* akan ditampilkan dengan plotting untuk mengukur akurasi hasil prediksi dengan data

aktual. Gambar berikut ini merupakan hasil prediksi yang telah dilakukan :



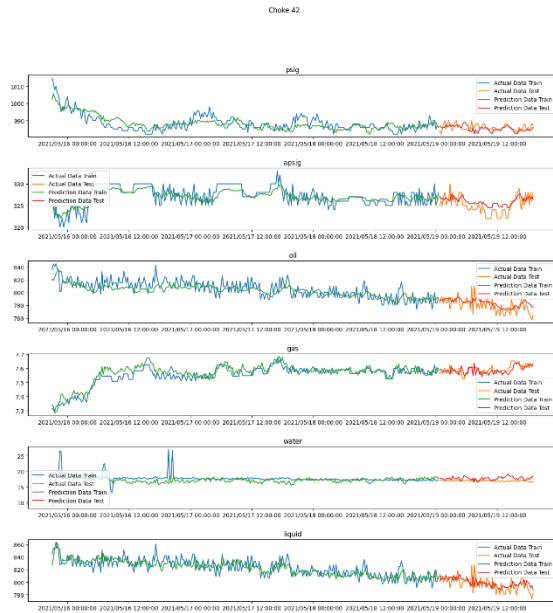
Gambar 2. Hasil Prediksi Choke 38

Pada gambar 2 menampilkan hasil prediksi terhadap *choke 38* hasil prediksi menunjukkan bahwa prediksi memiliki hasil yang hampir mirip dengan data aktual, dimana hanya terdapat perbedaan yang minor dalam beberapa parameter.




Gambar 3. Hasil Prediksi Choke 40

Pada gambar 3 menampilkan hasil prediksi terhadap *choke 40* hasil prediksi menunjukkan bahwa prediksi memiliki hasil yang hampir mirip dengan data aktual, Dimana hanya terdapat perbedaan yang minor dalam beberapa parameter



Gambar 4. Hasil Prediksi Choke 42

Pada gambar 3 menampilkan hasil prediksi terhadap *choke* 42 hasil prediksi menunjukkan bahwa prediksi memiliki hasil yang cukup baik pada parameter gas, psig, air, dan liquid. Sedangkan pada parameter apsig dan minyak terdapat perbedaan terhadap data aktual



Gambar 5. Rata-rata hasil Produksi pada setiap Choke

Gambar 5 merupakan hasil perbandingan rata-rata hasil prediksi produksi pada setiap *choke* gambar menunjukkan bahwa *choke* 42 memiliki rata-rata produksi terbaik dibandingkan kedua *choke* lainnya. Hal ini menunjukkan bahwa *choke* 42 memiliki keunggulan dalam tingkat produksi dibandingkan dengan *choke* 38 dan *choke* 40.

B. Analisis Evaluasi Prediksi

Pada tahapan ini akan dilakukan evaluasi terhadap seluruh konfigurasi yang telah dilakukan hal ini dilakukan untuk mengetahui konfigurasi *split* data dan *hidden size* mana yang menghasilkan hasil terbaik, evaluasi ini akan dilakukan dengan menghitung rata-rata hasil

MSE dan RMSE terhadap seluruh konfigurasi yang dilakukan

Tabel 3. Hasil Evaluasi Prediksi Choke 38

Split Data	Hidden Size	MSE	RMSE
70%	50	0.005	0.077
	100	0.004	0.066
	150	0.003	0.06
	200	0.003	0.06
	250	0.004	0.068
	300	0.003	0.062
80%	50	0.002	0.054
	100	0.002	0.05
	150	0.002	0.053
	200	0.002	0.054
	250	0.003	0.056
	300	0.002	0.052
90%	50	0.002	0.049
	100	0.002	0.049
	150	0.001	0.044
	200	0.002	0.045
	250	0.001	0.044
	300	0.002	0.046
	350	0.002	0.051
	400	0.002	0.045

Pada tabel 3 hasil prediksi menunjukkan bahwa hasil nilai skenario terbaik terdapat pada skenario dengan pembagian data 90%, hidden size 150 dan 250, dengan nilai MSE 0.001 dan nilai RMSE 0.044, sedangkan untuk skenario terburuk terdapat pada pembagian data 70%, *hidden size* 50, dengan nilai MSE 0.005 dan nilai RMSE 0.077.

Tabel 4. Hasil Evaluasi Prediksi Choke 40

Split Data	Hidden Size	MSE	RMSE
70%	50	0.03	0.176
	100	0.009	0.094
	150	0.011	0.105
	200	0.008	0.094
	250	0.009	0.095
	300	0.01	0.102
	350	0.008	0.093
	400	0.009	0.096
80%	50	0.055	0.234
	100	0.007	0.084
	150	0.007	0.085
	200	0.007	0.087
	250	0.009	0.097
	300	0.007	0.088
	350	0.01	0.1
	400	0.01	0.104
90%	50	0.03	0.173
	100	0.007	0.085
	150	0.006	0.078
	200	0.006	0.079
	250	0.006	0.08
	300	0.008	0.09
	350	0.008	0.089
	400	0.009	0.099

Pada tabel 4 nilai skenario terbaik terdapat pada skenario dengan pembagian data 90%, *hidden size* 150, dengan nilai MSE 0.006 dan nilai RMSE 0.078, sedangkan untuk skenario terburuk terdapat pada skenario dengan pembagian data 80%, *hidden size* 50, dengan nilai MSE 0.055 dan nilai RMSE 0.234.

Tabel 5. Hasil Evaluasi Prediksi Choke 42

Split Data	Hidden Size	MSE	RMSE
70%	50	0.014	0.12
	100	0.024	0.155
	150	0.017	0.133
	200	0.014	0.119
	250	0.019	0.137
	300	0.011	0.106
	350	0.01	0.103
	400	0.106	0.327
80%	50	0.022	0.149
	100	0.013	0.11
	150	0.011	0.107
	200	0.009	0.099
	250	0.011	0.105
	300	0.012	0.11
	350	0.014	0.12
	400	0.01	0.101
90%	50	0.261	0.511
	100	0.016	0.128
	150	0.007	0.086
	200	0.007	0.087
	250	0.008	0.093
	300	0.009	0.098
	350	0.011	0.106
	400	0.011	0.105

Pada tabel 5 hasil prediksi menunjukkan bahwa skenario terbaik terdapat pada skenario dengan pembagian data 90%, *hidden size* 150, dengan nilai MSE 0.007 dan nilai RMSE 0.086, sedangkan untuk skenario terburuk terdapat pada skenario pembagian data 90%, *hidden size* 50, dengan nilai MSE 0.261 dan nilai RMSE 0.511.

Tabel 6. Evaluasi Rata-rata Split Data

Split Data	MSE	RMSE
90%	0.0170	0.085
80%	0.0089	0.084
70%	0.0128	0.101

Berdasarkan table 6 menampilkan rata-rata konfigurasi terhadap *split* data yang dilakukan, berdasarkan hasil didapatkan menunjukkan bahwa *split* data 80% data *train* dan 20% data *test* mendapatkan hasil terbaik dengan nilai MSE 0.0089 dan nilai RMSE 0.084.

Tabel 7. Evaluasi Rata-rata Hidden Size

Hidden Size	MSE	RMSE
50	0.047	0.171
100	0.0093	0.091
150	0.0072	0.083
200	0.0064	0.08
250	0.0078	0.086
300	0.0071	0.084
350	0.008	0.095
400	0.0182	0.123
50	0.047	0.171

Pada tabel 7 menampilkan hasil evaluasi rata-rata konfigurasi terhadap *hidden size*, berdasarkan hasil yang didapatkan menunjukkan bahwa konfigurasi *hidden size* dengan nilai 200 menghasilkan nilai terbaik dengan nilai MSE 0.0064 dan nilai RMSE 0.08.

IV. KESIMPULAN

Setelah melakukan penelitian ini, telah diperoleh beberapa kesimpulan sebagai berikut :

1. Pada proses penelitian yang dilakukan, penelitian berlangsung dengan cukup baik dan menghasilkan hasil sesuai dengan

- harapan. Pada penelitian ini menunjukkan bahwa konfigurasi parameter LSTM mempengaruhi hasil yang didapatkan dalam melakukan pelatihan dan prediksi sumur.
2. Untuk konfigurasi terbaik pada *split* data didapatkan pada pembagian 80% data *train* dan 20% data *test* dengan nilai MSE 0.0089 dan nilai RMSE 0.084. Pada konfigurasi *hidden size*, konfigurasi *hidden size* dengan nilai 200 menghasilkan nilai terbaik dengan nilai MSE 0.0064 dan nilai RMSE 0.08.
 3. Hasil prediksi menunjukkan bahwa hasil produksi menggunakan *choke* 42 menghasilkan hasil produksi terbaik dibandingkan dengan kedua *choke* lainnya.
 4. Dari hasil pengujian skenario hasil prediksi terbaik pada *choke* 38 didapatkan pada pembagian data 90%, *hidden size* 150 dan 250, dengan nilai MSE 0.001 dan nilai RMSE 0.044, untuk *choke* 40 didapatkan pada pembagian data 90%, *hidden size* 150, dengan nilai MSE 0.006 dan nilai RMSE 0.078, dan untuk *choke* 42 didapatkan pada pembagian data 90%, *hidden size* 150, dengan nilai MSE 0.007 dan nilai RMSE 0.086.
- #### DAFTAR PUSTAKA
- [1]. Çetin, V., & Yıldız, O. (2022). A comprehensive review on data preprocessing techniques in data analysis. *Pamukkale University Journal of Engineering Sciences*, 28(2), 299–312. <https://doi.org/10.5505/pajes.2021.62687>
 - [2]. Ekechukwu, G. K., & Sharma, J. (2021). Well-scale demonstration of distributed pressure sensing using fiber-optic DAS and DTS. *Scientific Reports*, 11(1), 1–18. <https://doi.org/10.1038/s41598-021-91916-7>
 - [3]. Ibrahim, N. M., Alharbi, A. A., Alzahrani, T. A., Abdulkarim, A. M., Alessa, I. A., Hameed, A. M., Albabtain, A. S., Alqahtani, D. A., Alsawwaf, M. K., & Almuqhim, A. A. (2022). Well Performance Classification and Prediction: Deep Learning and Machine Learning Long Term Regression Experiments on Oil, Gas, and Water Production. *Sensors*, 22(14). <https://doi.org/10.3390/s22145326>
 - [4]. Islam, M. J., Ahmad, S., Haque, F., Reaz, M. B. I., Bhuiyan, M. A. S., & Islam, M. R. (2022). Application of Min-Max Normalization on Subject-Invariant EMG Pattern Recognition. *IEEE Transactions on Instrumentation and Measurement*, 71, 1–12. <https://doi.org/10.1109/TIM.2022.3220286>
 - [5]. Jin, Z. L., Liu, Y., & Durlofsky, L. J. (2020). Deep-learning-based surrogate model for reservoir simulation with time-varying well controls. *Journal of Petroleum Science and Engineering*, 192(April), 107273. <https://doi.org/10.1016/j.petrol.2020.107273>
 - [6]. Nasution, A. (2019). Metode Weighted Moving Average Dalam M-Forecasting. *JURTEKSI (Jurnal Teknologi Dan Sistem Informasi)*, 5(2), 119–124. <https://doi.org/10.33330/jurteksi.v5i2.355>
 - [7]. Nguyen, Q. H., Ly, H. B., Ho, L. S., Al-Ansari, N., Van Le, H., Tran, V. Q., Prakash, I., & Pham, B. T. (2021). Influence of data splitting on performance of machine learning models in prediction of shear strength of soil. *Mathematical Problems in Engineering*, 2021. <https://doi.org/10.1155/2021/4832864>
 - [8]. Pandji, B. yafitra, Indwiarti, & Rohmawati, A. A. (2019). Perbandingan Prediksi Harga Saham Dengan Model Arima Dan Artificial Neural Network. *Ind. on Computing*, 4(2), 189–198. <https://doi.org/10.21108/indojc.2019.4.2.344>
 - [9]. Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404(March), 1–43. <https://doi.org/10.1016/j.physd.2019.132306>
 - [10]. Vasudevan, H., Zolghadri, S., & Makarem, M. A. (2023). 2 - Introduction to oil, gas, and petrochemical industries: importance to the current world. In M. R. Rahimpour, B. Omidvar, N. A. Shirazi, & M. A. Makarem (Eds.), *Crises in Oil, Gas and Petrochemical Industries* (pp. 25–46). Elsevier. <https://doi.org/https://doi.org/10.1016/B978-0-323-95154-8.00003-7>