

ALGORITMA DEEP LEARNING-LSTM UNTUK MEMPREDIKSI UMUR TRANSFORMATOR

Ayu Ahadi Ningrum^{*1}, Iwan Syarif², Agus Indra Gunawan³, Edi Satriyanto⁴, Rosmaliati Muchtar⁵

^{1,2,3,4}Departemen Teknik Informatika dan Komputer, Politeknik Elektronika Negeri Surabaya

⁵Departemen Teknik Elektro, Institut Teknologi Sepuluh Nopember Surabaya

Email: : ¹ayuahadinn@gmail.com, ²iwanarif@pens.ac.id, ³agus_ig@pens.ac.id, ⁴edi@pens.ac.id,

⁵rosmaliati14@mhs.ee.its.ac.id

*Penulis Korespondensi

(Naskah masuk: 11 Januari 2021, diterima untuk diterbitkan: 09 Juni 2021)

Abstrak

Kualitas dan ketersediaan pasokan listrik menjadi hal yang sangat penting. Kegagalan pada transformator menyebabkan pemadaman listrik yang dapat menurunkan kualitas layanan kepada pelanggan. Oleh karena itu, pengetahuan tentang umur transformator sangat penting untuk menghindari terjadinya kerusakan transformator secara mendadak yang dapat mengurangi kualitas layanan pada pelanggan. Penelitian ini bertujuan untuk mengembangkan aplikasi yang dapat memprediksi umur transformator secara akurat menggunakan metode *Deep Learning-LSTM*. *LSTM* adalah metode yang dapat digunakan untuk mempelajari suatu pola pada data deret waktu. Data yang digunakan dalam penelitian ini bersumber dari 25 unit transformator yang meliputi data dari sensor arus, tegangan, dan suhu. Analisis performa yang digunakan untuk mengukur kinerja LSTM adalah *Root Mean Squared Error* (RMSE) dan *Squared Correlation* (SC). Selain LSTM, penelitian ini juga menerapkan algoritma *Multilayer Perceptron*, *Linear Regression*, dan *Gradient Boosting Regressor* sebagai algoritma pembandingan. Hasil eksperimen menunjukkan bahwa LSTM mempunyai kinerja yang sangat bagus setelah dilakukan pencarian komposisi data, seleksi fitur menggunakan algoritma KBest dan melakukan percobaan beberapa variasi parameter. Hasil penelitian menunjukkan bahwa metode *Deep Learning-LSTM* mempunyai kinerja yang lebih baik daripada 3 algoritma lain yaitu nilai RMSE= 0,0004 dan nilai *Squared Correlation*= 0,9690.

Kata kunci: Prediksi, Transformator, Deep Learning, LSTM

DEEP LEARNING-LSTM ALGORITHM FOR POWER TRANSFORMER LIFETIME PREDICTION

Abstract

The quality and availability of the electricity supply is very important. Failures in the transformer cause power outages which can reduce the quality of service to customers. Therefore, knowledge of transformer life is very important to avoid sudden transformer damage which can reduce the quality of service to customers. This study aims to develop applications that can predict transformer life accurately using the Deep Learning-LSTM method. LSTM is a method that can be used to study a pattern in time series data. The data used in this research comes from 25 transformer units which include data from current, voltage, and temperature sensors. The performance analysis used to measure LSTM performance is Root Mean Squared Error (RMSE) and Squared Correlation (SC). Apart from LSTM, this research also applies the Multilayer Perceptron algorithm, Linear Regression, and Gradient Boosting Regressor as a comparison algorithm. The experimental results show that LSTM has a very good performance after searching for the composition of the data, selecting features using the KBest algorithm and experimenting with several parameter variations. The results showed that the Deep Learning-LSTM method had better performance than the other 3 algorithms, namely the value of RMSE = 0.0004 and the value of Squared Correlation = 0.9690.

Keywords: Prediction, Power Transformer, Deep Learning, LSTM.

1. PENDAHULUAN

Perkembangan teknologi informasi saat ini sangat berguna untuk semua aspek bidang pekerjaan.

Terutama teknologi AI telah banyak diterapkan dalam kehidupan sehari-hari seperti adanya *smart home*, sistem pendukung keputusan, pembacaan sensor. Tanpa disadari teknologi informasi menjadi

salah satu kebutuhan utama dalam pengembangan bisnis (Jahromi and R. Piercy, 2019). Sensor, *wireless* dan teknologi persuasif menjadi sebuah inovasi model bisnis yang telah berkembang pesat dan sangat potensial (Valter et al., 2017). Jaminan kualitas penyaluran energi kepada pelanggan menjadi sangat penting bagi penyedia energi listrik. Ini harus mencakup kesehatan peralatan yang digunakan untuk menyediakan energi kepada pelanggan. Transformator distribusi adalah peralatan yang paling dekat dengan beban listrik (Tjahjono et al., 2019).

Strategi pemeliharaan peralatan saat ini terbagi menjadi tiga kategori utama. Yang pertama adalah 'run-to-failure'. Dalam kategori ini, intervensi terjadi hanya setelah transformator gagal. Kategori kedua adalah pemeliharaan preventif. Pada tahap ini, tindakan pemeliharaan dilakukan sesuai dengan yang direncanakan. Kategori terakhir, pemeliharaan prediktif adalah paling hemat biaya. Upaya pemeliharaan prediktif untuk menilai kondisi kesehatan setiap perangkat. Ini memungkinkan untuk deteksi lanjutan dari kegagalan yang tertunda (Gultom et al., 2017).

Sistem pemantauan pada transformator dapat memudahkan pengguna dalam mendeteksi peristiwa atau mengembangkan kesalahan pada transformator yang dapat mengganggu pengoperasiannya. Ini mengarah pada manajemen aset yang lebih efisien (Ceferin et al., 2017). Prediksi umur selalu menjadi tugas yang menantang karena beberapa alasan, misalnya representasi fitur yang tidak akurat yang disebabkan oleh *noise*, variasi akhir masa pakai dan ketidakpastian prediksi lainnya (Ma & Mao, 2019).

Deep Learning merupakan sebuah teknologi yang digadang-gadang menjadi salah satu teknologi terpenting setelah internet dan sering digambarkan sebagai teknologi yang akan menggantikan posisi manusia di lapangan pekerjaan (Lecun et al., 2015). LSTM merupakan salah satu jenis *Recurrent Neural Network*. LSTM dapat memiliki kemampuan mempelajari data di mana dalam setiap *neuron* LSTM memiliki beberapa gerbang yang mengatur memori dari setiap neuron itu sendiri (Sakinah et al., 2019). Dengan menggunakan hasil prediksi umur trafo diharapkan dapat membuat keputusan lebih cerdas terkait kapan dan di mana perbaikan akan dilakukan. Keputusan cerdas tersebut dapat mengurangi biaya operasional dikarenakan akan dapat disusun rencana perbaikan yang lebih baik (Diwyacitta et al., 2017).

Pada penelitian ini dijabarkan mengenai penggunaan algoritma *Deep Learning* dalam melakukan prediksi umur transformator. *Deep Learning* yang digunakan pada penelitian ini menggunakan *Long Short Term Memory Neural Network* (LSTM). LSTM banyak digunakan untuk mengolah teks, video, dan data deret waktu (Azzouni and Pujolle, 2018). Parameter pada penelitian ini menggunakan tegangan, arus dan suhu pada trafo. Analisis performa yang digunakan menggunakan nilai *Root Mean Squared Error* (RMSE) yang

merupakan tingkat kesalahan hasil prediksi dan nilai *Squared Correlation* (SC) yang menggambarkan nilai proporsi variasi dalam atribut yang dikaitkan dengan hasil prediksi.


2. METODE PENELITIAN

Proses penelitian dibagi menjadi beberapa fase utama. Fase pertama adalah pengumpulan teori terkait transformator serta algoritma yang digunakan. Tahapan selanjutnya pengumpulan dataset yang digunakan dalam penelitian. Mendapatkan fitur terbaik dan nilai parameter optimal data kemudian digunakan untuk pelatihan dan pengujian. Tahapan terakhir mencari penelitian terkait dengan topik penelitian.

2.1 Transformator

Transformator merupakan alat yang berfungsi untuk dapat memindahkan energi listrik arus bolak-balik dari suatu rangkaian ke rangkaian yang lain. Tegangan yang dihasilkan dapat lebih besar atau lebih kecil.

Transformator beroperasi berdasarkan rangkaian magnetik dan belitan yang terdiri beberapa belitan (Gambar 1), secara induksi elektromagnetik, mentransformasikan daya (arus dan tegangan) sistem AC ke sistem arus dan tegangan lain pada frekuensi yang sama (Jahromi, et al., 2019).



Gambar 1. Rangkaian Transformator[4]

2.2 Selisih Suhu Hotspot dengan Suhu Top Oil

$\Delta\theta_c$ (Delta Suhu *Hotspot Top Oil*) adalah selisih antara suhu *hotspot* dengan suhu *top oil*, dapat dihitung dengan persamaan 1 (Gultom, 2017).

$$\Delta\theta_c = (\Delta\theta_{cr} - \Delta\theta_{br}) K^{2y} \quad (1)$$

Dengan

$$\Delta\theta_{cr} = 78^\circ\text{C}$$

$$y = \text{konstanta}$$

$$y = 0,8 \text{ (ONAN dan ONAF)}$$

$$y = 0,9 \text{ (OFAF dan OF WF)}$$

$$\Delta\theta_{br} = \text{suhu}$$

Untuk $\Delta\theta_{br} = 55^\circ\text{C}$ untuk ON, $\Delta\theta_{br} = 40^\circ\text{C}$ untuk OF

2.3 Nilai Relatif dari Umur Pemakaian

Nilai relative dapat dihitung dengan menggunakan rumusan dari *Montsinger* pada suhu $\Delta\theta_c$, lalu dibanding dengan nilai normal dari umur pemakaian pada suhu $\Delta\theta_{cr}$. Detil rumusan yang digunakan terdapat pada persamaan 2 dan 3 (Gultom, 2017).

$$V = \left\lceil \frac{\text{Laju penggunaan umur saat } \Delta\theta_c}{\text{Laju penggunaan umur saat } \Delta\theta_{cr}} \right\rceil \quad (2)$$

$$V = 2^{(\Delta\theta_c - \Delta\theta_{cr}) / 6} \quad (3)$$

Dengan :

V = nilai relative dari umur pakai

$\Delta\theta_{cr}$ = 98°C menurut publikasi IEC 76(1967).

2.4 Pengurangan Umur Transformator

Besarnya susut umur dari sebuah transformator dapat dihitung dengan menggunakan persamaan 4 (Gultom, 2017).

$$L = \sum_{n=1}^N V_n \quad (4)$$

Di mana :

L = *loss of life calculation*

V_n = nilai dari umur pemakaian pada waktu n

n = waktu ke(jam)

2.5 Perkiraan Umur Transformator

Nilai pembebanan berubah-ubah setiap hari menyebabkan kesulitan dalam menentukan pola pembebanan hariannya. Maka diasumsikan setiap hari merupakan pembebanan harian. Sehingga didapatkan rumus untuk menentukan perkiraan sisa umur transformator terdapat pada persamaan 5.

$$\text{Sisa waktu pakai} = \left[\frac{8760 - (L \times 365)}{8760} \right] \times \text{umur dasar} \quad (5)$$

Di mana :

Umur dasar = 30 tahun

8760 = Jam (1 tahun)

365 = Hari (1 tahun)

2.6 Linear Regression

Regresi adalah metode analisis statistik untuk mengidentifikasi hubungan antar variabel. Hubungannya dapat dikenali antara variabel dependen dan independen. Itu dapat dijelaskan menggunakan fungsi distribusi probabilitas (S, et al., 2016) digambarkan pada gambar 2. *Linear Regression* (Montgomery, et al., 2016) adalah prediksi yang paling umum model untuk mengidentifikasi hubungan antar variabel. Selain dari tipe data *univariate* atau *multivariate* dari konsep linier.

$$Y = a + b \cdot X \quad (6)$$

Di mana:

Y = variable bebas

X = variable independen


a = *intercept*

b = *slope* (koefisien dari regresi)

2.7 Multilayer Perceptron

Multilayer Perceptron adalah jaringan *neuron* sederhana yang disebut *perceptrons*. Konsep dasar dari *perceptron* tunggal diperkenalkan oleh


Rosenblatt pada tahun 1958. *Perceptron* menghitung *output* tunggal dari beberapa *input* bernilai nyata dengan membentuk kombinasi linear sesuai dengan bobot inputnya dan kemudian mungkin menempatkan *output* melalui beberapa fungsi aktivasi nonlinier (Jitendra, et al., 2017). Secara matematis ini dapat ditulis pada persamaan 7.



Gambar 2. Metode *Linear Regression*¹

$$y = \varphi \left(\sum_{i=1}^n w_i \cdot x_i + b \right) = \varphi(w^T x + b) \quad (7)$$

di mana w menunjukkan vektor bobot, x adalah vektor input, b adalah bias dan φ adalah fungsi aktivasi. Grafik aliran sinyal dari operasi ini ditunjukkan pada gambar 3. *Perceptron* Rosenblatt asli menggunakan fungsi langkah *Heaviside* sebagai fungsi aktivasi φ . Saat ini, dan terutama di jaringan *multilayer*, fungsi aktivasi sering dipilih sebagai *sigmoid logistic* atau garis singgung hiperbolik. Fungsi-fungsi ini digunakan karena mereka secara matematis nyaman dan dekat dengan linier dekat asal sementara menjenuhkan agak cepat ketika menjauh dari asal. Hal ini memungkinkan jaringan MLP untuk memodelkan pemetaan yang baik secara kuat dan agak *nonlinier*.



Gambar 3. Struktur MLP (Jitendra, et al., 2017)


2.8 Long Short Term Memory

Deep Learning atau pembelajaran terstruktur mendalam dapat didefinisikan sebagai jenis jaringan saraf khusus yang terdiri dari beberapa lapisan. Jaringan ini lebih baik daripada jaringan saraf tradisional dalam menyimpan informasi dari acara sebelumnya (Hochreiter & Schmidhuber, 2017). Jaringan saraf berulang (RNN) adalah salah satu mesin yang memiliki kombinasi jaringan dalam loop. Jaringan *loop* memungkinkan informasi tetap ada.

Setiap jaringan dalam *loop* tersebut mengambil masukan dan informasi dari jaringan sebelumnya, melakukan operasi yang ditentukan dan menghasilkan keluaran bersama dengan meneruskan informasi ke jaringan berikutnya (Hochreiter & Schmidhuber, 2017).

Long Short Term Memory Neural Network (LSTM) merupakan salah satu jenis RNN. LSTM memiliki kemampuan untuk mempelajari data yang harus digunakan atau diabaikan, proses ini terjadi pada setiap *neuron* (Sakinah, et al., 2019). LSTM banyak digunakan untuk mengolah teks, video, dan data deret waktu (Azzouni & Pujolle, 2017). Hal ini berdasarkan lebih banyak informasi sebelumnya dapat mempengaruhi akurasi model, LSTM menjadi pilihan penggunaan yang wajar. Modul LSTM yang disebut modul berulang memiliki empat modul lapisan jaringan saraf yang saling berinteraksi ditunjukkan pada gambar 4.

Simbol π dan Σ mewakili elemen perkalian bijak dan penjumlahan masing-masing. Operasi penggabungan diwakili oleh simbol (\bullet) poin. Itu komponen dasar LSTM adalah status sel, sebuah baris yang berjalan dari memori dari blok sebelumnya (S_{t-1}) ke memori blok saat ini (S_t). Ini memungkinkan informasi mengalir lurus ke bawah. Jaringan dapat menentukan jumlah informasi sebelumnya mengalir. Itu dikendalikan melalui lapisan pertama (σ_1). Operasi yang dilakukan oleh lapisan ini diberikan (Jitendra, et al., 2017).



Gambar 4. Perulangan Modul LSTM[7]


2.9 Deep Learning

Deep Learning merupakan suatu algoritma yang pada proses pengolahannya menggunakan sejumlah *hidden layer*, lalu pada proses perhitungan nilai *output* menggunakan transformasi linier. Pada Deep Learning terdapat sebuah fitur yang mampu bekerja secara otomatis dalam mengekstraksi data. Dapat dikatakan algoritma ini dapat mengolah fitur secara baik dalam memecahkan suatu masalah. Di dalam dunia kecerdasan buatan hal tersebut menjadi hal yang sangat penting dalam proses mengurangi beban pemrograman. Algoritma ini dapat digunakan untuk memecahkan dengan metode *supervised*, *unsupervised*, dan *supervised* (Dong & Grumbach, 2018; E. B., & M. M., 2015).

Deep Learning memiliki kemampuan untuk menemukan struktur rumit dari sebuah data yang

besar dengan metode *backpropagation* (Leecun, et al., 2015). Ilustrasi terdapat pada gambar 5. *Deep Learning* memiliki beberapa properti yang mengukuhkan statusnya sebagai revolusi AI. Kita mungkin tidak menggunakan *Neural Network* dua dekade dari sekarang, namun apapun yang kita gunakan akan secara langsung mewarisi dari pembelajaran mendalam modern dan konsep intinya. Properti penting ini secara luas dapat diurutkan menjadi tiga kategori:

- Kesederhanaan
Deep Learning menghilangkan kebutuhan akan rekayasa fitur, menggantikan *pipeline* yang rumit, rapuh, dan banyak rekayasa dengan model sederhana yang dapat dilatih secara menyeluruh yang biasanya dibuat hanya menggunakan lima atau enam operasi *tensor* yang berbeda.
- Skalabilitas
Deep learning sangat cocok untuk paralelisasi pada GPU atau TPU, sehingga dapat memanfaatkan sepenuhnya hukum *Moore*.
- Kecerbagaan dan kegunaan kembali
Tidak seperti banyak pendekatan pembelajaran mesin sebelumnya, model *Deep Learning* dapat dilatih pada data tambahan tanpa memulai ulang dari awal, membuatnya layak untuk pembelajaran online berkelanjutan (Chollet, 2018).



Gambar 5. Ilustrasi Deep Learning[8]

2.10 Dataset

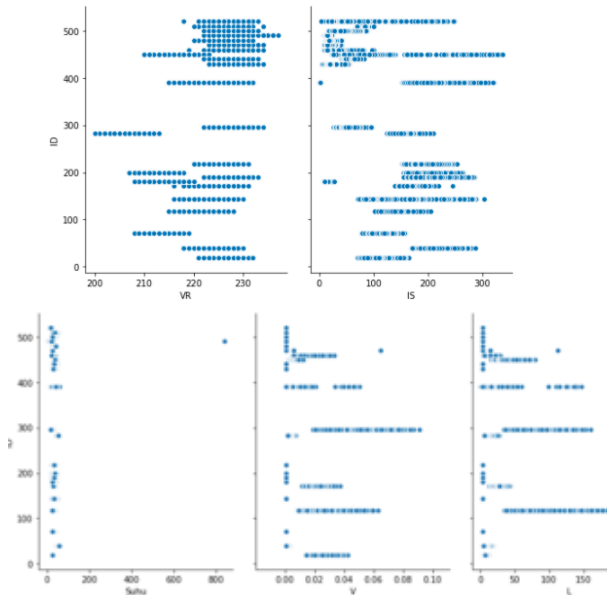
Pada tahap implementasi ini menggunakan dataset transformator distribusi di mana dataset ini bersifat deret waktu. Data didapatkan berdasarkan historis dari 25 unit transformator, di mana dataset akan diselesaikan dengan pendekatan regresi.

Dataset Transformator ini terdiri dari 24 kolom dan 12480 data. Setiap baris adalah sebuah data yang diambil selama satu siklus operasional tunggal, setiap kolom adalah variabel yang berbeda. Kolom tersebut terdiri dari Kode trafo, Tanggal, Tegangan pada R(VR), Tegangan pada S (VS), Arus pada R(IR), Arus pada S(IS), Arus pada T(IT), PF-R, PF-S, PF-T, *Load Factor*, Energi, *Unbalanced Load*, Suhu, d, Pendingin_x, Pendingin_y, Delta_b, Delta_cr, Delta_c, n, V, L, Umur Dasar, Prediksi_umur. Tabel 1 menampilkan contoh dari dataset yang digunakan.

Table 1. Dataset Transformer

ID	Tgl	VR	...	V	L	Umur dasar	Umur
282	01/0	...	0.0	5.2			
	5/17	211	...	014	1	30	23
	02/0	...	0.0	5.3			
282	5/17	211	...	015	3	30	23
...
	01/0	...	0.0	34.			
450	5/17	221	...	058	22	30	24

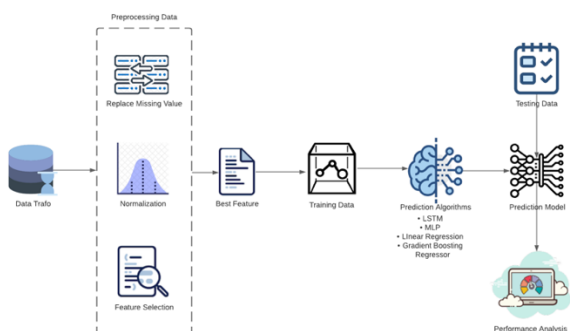
Visualisasi sebaran data yang terdapat pada Gambar 6.



Gambar 6. Visualisasi data attribute

2.11 Desain Perangkat Lunak

Pada pengujian kali ini akan dilakukan dengan menggunakan *Deep Learning* dengan menggunakan model LSTM serta MLP, *Linear Regression* dan *Gradient Boosting Regressor* sebagai algoritma pembandingan. Adapun untuk desain sistem dari penelitian ini terdapat pada Gambar .



Gambar 7. Desain Sistem

Sebelum masuk ke proses pengujian. Data transformator terlebih dahulu harus dilakukan pemrosesan data di mana langkah ini sangat berguna untuk pembersihan data sebelum dilanjutkan ke proses *training* data. Selain itu diadakan juga proses seleksi fitur di mana proses ini berfungsi untuk

mendeteksi atribut yang sangat berpengaruh dalam proses prediksi kedepannya.

Pengujian akan dilakukan dengan beberapa algoritma dan pada proses validasi dataset menggunakan metode *k-fold cross validation*, di mana fungsi ini memiliki dua subproses. Subproses *train* data digunakan untuk mempelajari atau membangun model. Model yang dilatih kemudian diterapkan dalam subproses *test-data*. Performa model juga diukur selama tahap pengujian.

2.12 Ujicoba Dataset dan Algoritma

Penelitian menggunakan nilai RMSE sebagai indikator keberhasilan dalam proses pengujian hasil penelitian. Dimana *Root Mean Squared Error* (RMSE) adalah salah satu metode pengukuran dengan cara menghitung perbedaan nilai prediksi sebuah model sebagai estimasi atas nilai data yang diobservasi. Persentase dari akar kesalahan kuadrat rata-rata (%RMSE) dapat mengatasi hal ini, dan didefinisikan pada persamaan 7 dan 8.

$$\%RSME = \frac{RSME}{T_1} \times 100\% \quad (7)$$

Di mana:

$$T_1 = \frac{1}{N.(N-1)} \sum_i \sum_d T_u \text{ untuk } i \neq d \quad (8)$$

Nilai RSME dan %RSME merepresentasikan hasil estimasi model yang dihasilkan. Semakin kecil nilai RMSE, maka semakin akurat pula hasil prediksi yang dihasilkan.

2.12.1 Pengujian Komposisi Dataset

Penelitian ini akan menggunakan teknik *K-Fold-Cross Validation* dalam proses menentukan komposisi data yang berfungsi untuk menguji keakuratan sebuah model yang dihasilkan. Proses ini melibatkan fold 6 s.d 10. Di mana setiap proses *training*, *testing* dan validasi dilakukan sebanyak 6 s/d 10 lipatan secara terus menerus. Adapun pada proses pengujian komposisi dataset ini masih menggunakan parameter standart dari *Deep Learning-LSTM*.

2.12.2 Seleksi fitur

Seleksi fitur adalah masalah krusial dalam pembelajaran mesin yang efisien, dan juga berkontribusi besar pada kemampuan menjelaskan keputusan yang dihasilkan mesin (Wang, et al., 2020). Seleksi fitur merupakan proses memilih fitur yang tepat untuk digunakan. Proses ini bertujuan untuk menyederhanakan proses, meningkatkan akurasi dari sebuah algoritma, serta dapat mengetahui fitur yang paling berpengaruh dalam meningkatkan hasil akurasi. Pemilihan metode *Select KBest* pada penelitian ini bertujuan menyederhanakan banyaknya

attribut yang ada pada dataset transformator. Adapun *pseudocode* dari proses ini terdapat pada Tabel 2.

Tabel 2. *Pseudocode* Proses Seleksi Fitur dengan KBest

Urutan	Proses
Step-1	Panggil dataset trafo.
Step-2	Bagi data menjadi data pelatihan dan pengujian.
Step-3	Panggil fungsi library <i>SelectKBest</i> , panggil <i>f_regression</i> untuk bagian skor dan masukkan nilai K. Disini kita masukkan seluruh fitur.
Step-4	Buat perulangan sebanyak nilai k yang sudah dimasukkan.
Step-5	Cetak hasil dari setiap fitur.

2.12.3 Skenario Pengujian Algoritma

Adapun untuk skema pengujiannya terdapat 4 skenario pengujian yaitu algoritma *Multilayer Perceptron*(MLP), *Deep Learning*(LSTM), *Linear Regression*(LR), Gradient Boosting Regressor(GBR) seperti pada Tabel 3.

Tabel 3. Skenario Pengujian Algoritma

MLP	LSTM	LR	GBR
Activation = ReLu	Activation = linear	Random_state=4 s/d 6	Alpha = 0.9
Epoch = 200	Epoch = 50	-	n_estimator = 500
Batch_size = 1	Batch_size = 64	-	Learning_rate = 0.005 s/d 0.01
Verbose = 0	Verbose = 2	-	Verbose = 1
Optimizer = Adam	Optimizer = Adam	-	max_dept = 6
Hidden layer = 50	Hidden layer = 2	-	-
Learning rate = 0 s.d 1	Learning rate = 0 s.d 0.2	-	-

Pada penelitian kali ini akan difokuskan pada algoritma *Deep Learning*. Adapun untuk *pseudocode* dari Algoritma ini terdapat pada Tabel 4.

Tabel 4. *Pseudocode* Algoritma *Deep Learning*

Urutan	Proses
Step-1	Panggil dataset trafo.
Step-2	Lakukan normalisasi dan <i>scaling feature</i>
Step-3	Replace missing value
Step-4	Buat sebuah sequence sebesar 100
Step-5	Masukkan metode validasi pada dataset
Step-6	Gunakan window size = seq_len - 1
Step-7	Masukkan parameter sesuai dengan scenario.
Step-8	Compile model dengan tipe loss= <i>mean_squared_error</i> dan <i>optimizer</i> = adam
Step-9	Buat prediksi berdasarkan test data dan cetak hasil

2.13 Penelitian Terkait

Penelitian mengenai prediksi umur transformator telah dilakukan dengan berbagai macam metode dan

parameter. Nuno pada penelitiannya mengestimasi sisa umur dari transformator menggunakan model indeks kesehatan dengan *paper insulation* (De and Do, 2018). Alhaytham melakukan penelitian dengan menggunakan sampel minyak dan *load factor* sebagai parameter dalam memprediksi tingkat kesehatan suatu transformator, dan *Machine Learning* dipilih dalam metode penelitiannya (Alqudsi and El-Hag, 2019). Yolla menggunakan suhu, load factor, dan bahan isolasi belitan sebagai parameter dalam memperkirakan umur transformator. Analisa tren linear digunakan dalam metode penelitian tersebut (Rizki and Ervianto, 2019).

Deep Learning pun juga banyak diterapkan dalam berbagai kasus prediksi yang memiliki jumlah data yang besar. Khususnya untuk LSTM, memiliki kemampuan untuk menangani data besar bertipe deret waktu. G. Sateesh menggunakan *Deep Learning* berbasis CNN dalam memecahkan kasus prediksi sisa umur dari sebuah mesin pesawat (Babu et al., 2016). Xinjuan melakukan prediksi kualitas udara pada suatu daerah dengan menggunakan algoritma LSTM-Kalman model (Song et al., 2019). Md. Arif melakukan prediksi harga saham dengan menggunakan LSTM kemudian dibandingkan dengan metode LSTM model *Bi-Directional* (Istiaque Sunny et al., 2020).

3 HASIL PEMBAHASAN

Penelitian dilakukan pada perangkat computer i5 dengan kecepatan 1600 Mhz dengan kapasitas Memory 4GB. Python dengan Keras *Library* dipilih sebagai alat untuk mengimplementasi. Dataset yang digunakan adalah dataset transformator distribusi. Hal pertama yang dilakukan pada dataset transformator adalah melakukan menentukan komposisi data yang akan digunakan, lalu dilanjutkan proses seleksi fitur, di mana fitur tersebut ternyata menjadi fitur yang berpengaruh dalam proses prediksi umur dari transformator. Selanjutnya dilakukan proses pembelajaran menggunakan 4 jenis algoritma yaitu *Deep Learning-LSTM*, *Multilayer Perceptron*, *Linear Regression* dan *Gradient Boosting Regressor* sebagai algoritma pembandingan. Hasil percobaan menggunakan 4 jenis algoritma tersebut dijelaskan pada bagian berikut ini.

3.1 Hasil Pengujian Komposisi Dataset

Deep Learning dapat menghasilkan nilai prediksi yang memuaskan jika data yang digunakan untuk proses *training* (pembelajaran) berjumlah banyak dan parameter yang digunakan tepat. Sebelum menetapkan parameter untuk LSTM, dilakukan proses pengujian komposisi data. Tabel 5 berikut ini menjelaskan proses pembentukan model menggunakan *k-fold cross validation* di mana nilai k bervariasi dari 6-10.

Table 5. Komposisi Dataset Fold 6 s.d 10

<i>Fold</i>	<i>Hidden Layer</i>	<i>Epoch</i>	<i>Training Error</i>	<i>Testing Error</i>
6	2	10	0,0235	0,0192
7	2	10	0,0277	0,0166
8	2	10	0,0251	0,210
9	2	10	0,0155	0,0250
10	2	10	0,0137	0,0219

Dari 5 kombinasi *fold* yang ditunjukkan pada tabel 5 hasil terbaik didapatkan pada saat menggunakan fold bernilai 10 yang menghasilkan nilai eror 0,0137 pada *training data* dan 0,0219 pada *testing data*. Oleh karena itu, semua percobaan berikutnya akan menggunakan $k=10$.


3.2 Hasil Seleksi Fitur

Dataset transformator memiliki 24 atribut kemudian dilakukan proses seleksi fitur dengan metode *KBest*. Di mana proses *KBest* untuk mengoptimalkan kinerja suatu model dengan memilih fitur-fitur yang memiliki skor signifikan. Berdasarkan tabel 2 maka proses seleksi fitur menghasilkan *output* seperti pada Tabel 6.

Tabel 6. Hasil Skor Seleksi Fitur

No	Fitur	Nilai Skor
1	0	0.0388
2	1	98.5349
3	2	55.4718
4	3	40.6785
5	4	23.9592
6	5	70.5893
7	6	41.8381
8	7	34.4428
9	8	0.1485
10	9	41.5037
11	10	9.0395
12	11	461.5626
13	12	257.6368
14	13	200.1730
15	14	0.0000
16	15	nan
17	16	0.0000
18	17	48.4563
19	18	nan
20	19	48.8796
21	20	40.4754
22	21	200.0300
23	22	329.5501
24	23	Nan

Mengacu hasil dari table 6 terlihat bahwa dari 24 atribut menghasilkan skor yang beragam. Adapaun detil fitur dari Tabel 6 adalah fitur 1(Tanggal), fitur 2(VR), fitur 3(VS), fitur 4(IR), fitur 5(IS), fitur 6(IT), fitur 7(PF-R), fitur 8(PF-R), fitur 9(PF-T), fitur 10(Load Factor), fitur 11(Energi), fitur 12(Unbalanced Load), fitur 13(Suhu), fitur 14(d), fitur15(Pendingin_x), fitur 16(Pendingin_y), fitur 17(Delta b), fitur 18(Delta cr), fitur 19(Delta_c), fitur 20(n), fitur 21(V), fitur 22(L), fitur 23(Umur dasar). Pada Gambar 8 ditampilkan grafik hasil seleksi fitur yang telah dilakukan.



Gambar 8. Hasil Seleksi Fitur

Dari gambar 3 menunjukkan ada 5 fitur bernilai sangat kuat dalam mempengaruhi hasil prediksi umur dari transformator. Namun pada penelitian ini diputuskan untuk menambahkan 2 fitur yaitu fitur 1(Tanggal) dan fitur 5(IS). Hal ini dikarenakan dalam menggunakan algoritma *Deep Learning-LSTM* atribut tanggal dan arus pada S(IS) sangat diperlukan. Sehingga dalam penelitian ini diputuskan menggunakan 7 fitur tertinggi. Adapun ketujuh fitur itu yaitu: fitur 1(Tanggal), fitur 5(IS), fitur 11(Energi), fitur 12(Unbalanced Load), fitur 13(Suhu), fitur 21(V), fitur 22(L). Energi merupakan kekuatan dari transformator, suhu merupakan keadaan suhu dari transformator, V merupakan nilai relative pemakaian, dan L merupakan pengurangan umur pada transformator.

3.3 Keluaran Performa Algoritma

Implementasi algoritma untuk memprediksi umur transformator menggunakan algoritma *Deep Learning-LSTM*, *Multilayer Perceptron*, *Linear Regression*, dan *Gradient Boosting Regressor* sebagai pembandingan. Berikut merupakan keluaran dari hasil penelitian.


3.3.1 Deep Learning-LSTM

Algoritma *Deep Learning-LSTM* merupakan algoritma utama yang dilakukan pada penelitian ini. Skenario pengerjaan algoritma ini terdapat pada Tabel 4. Analisis performa yang dihasilkan pada penelitian ini menggunakan RMSE dan SC. Nilai RSME yang merupakan representasi nilai tingkat kesalahan prediksi pada metode LSTM menghasilkan 1,1823 dan $SC = 0,4218$. Nilai-nilai tersebut dihasilkan pada saat sebelum dilakukan proses seleksi fitur. Hasil dari proses seleksi fitur dengan metode *KBest* merujuk pada skenario pengujian pada Tabel 2 dan untuk hasilnya dilihat pada Tabel 11. Di mana hasil paling baik pada saat menggunakan nilai *learning rate* = 0,1 . Hasil pengujian beberapa *learning rate* dapat dilihat pada Tabel 7. Nilai RSME 0,0004 dan nilai SC 0,9690. Hasil tersebut menunjukkan bahwa algoritma *Deep Learning-LSTM* menghasilkan nilai tingkat kesalahan prediksi (RMSE) yang lebih kecil dan nilai SC yang lebih besar setelah dilakukan proses seleksi fitur dan melakukan pengaturan pada nilai *learning rate*.

Tabel 7. Hasil Algoritma *Deep Learning-LSTM*

Learning Rate	RMSE	SC
0	0,0010	0,9313
0,1	0,0004	0,9690
0,2	0,0006	0,9595

Adapun *Output* historis *loss* yang dihasilkan selama proses pembelajaran model yang dilakukan pada *train* dan *test* data pada saat menggunakan skenario dari Tabel 3 dan nilai *learning rate* 0,1 dapat dilihat pada gambar 9.



Gambar 9. Historis Loss Model

3.3.2 Algoritma Pembandingan

Penelitian ini juga melakukan proses perbandingan dengan beberapa algoritma prediksi lainnya seperti: algoritma *Multilayer Perceptron*, *Linear Regression* dan *Gradient Boosting Regressor*. Hal ini dimaksudkan untuk mengetahui sejauh mana performa algoritma *Deep Learning-LSTM* dibandingkan dengan algoritma prediksi lainnya.

a. *Multilayer Perceptron*(MLP)

Mengacu pada skenario pengujian pada Tabel 3. Tabel 8 menunjukkan hasil pengujian menggunakan *learning rate* dari 0 s/d 1 dengan algoritma *Multilayer Perceptron*. Hasil RMSE dan SC terbaik pada saat menggunakan *learning rate* 1 dengan nilai RMSE 3,144 dan SC 0,681.

Tabel 8. Pengujian Algoritma MLP

Learning Rate	RMSE	SC
0	4,291	0,407
0,5	3,772	0,542
1	3,144	0,681

b. *Linear Regression*

Mengacu pada skenario pengujian pada Tabel 3. Tabel 9 menunjukkan hasil pengujian menggunakan *random state* dari 2 s/d 6 dengan algoritma *Linear Regression*. Hasil RMSE dan SC terbaik pada saat menggunakan *random state* 6 yaitu RMSE=1,0305 dan SC=0,703.

Tabel 9. Pengujian Algoritma *Linear Regression*

Random State	RMSE	SC
2	8,1530	0,627
4	4,6346	0,599
6	1,0305	0,703

c. *Gradient Boosting Regressor*

Mengacu pada skenario pengujian pada Tabel 3. Tabel 10 menunjukkan hasil pengujian menggunakan *learning rate* dari 0,005 s/d 0,1 dengan algoritma *Gradient Boosting Regressor*. Hasil RMSE dan SC terbaik pada saat menggunakan *learning rate* 0,1 dengan nilai RMSE=0,0414 dan SC=0,9348.

Tabel 10. Pengujian Algoritma GBR


Learning Rate	RMSE	SC
0,005	1,2072	0,8992
0,05	0,9371	0,9208
0,1	0,0414	0,9348

Berdasarkan hasil pengujian yang dilakukan pada tabel 7, tabel 8, tabel 9 dan tabel 10. Hasil terbaik dari setiap algoritma kemudian diteruskan proses perbandingan antar algoritma yang terdapat pada tabel 11.

Table 11. Hasil *Deep Learning* dengan Algoritma Pembandingan

Algoritma	Sebelum FS		Setelah FS	
	RMSE	SC	RMSE	SC
<i>Deep Learning-LSTM</i>	1,1823	0,421	0,0004	0,9690
<i>MLP</i>	5,5306	0,3960	3,144	0,681
<i>Linear Regresion</i>	8,7330	0,3625	1,0305	0,703
<i>Gradient Boosting Regressor</i>	2,3483	0,6329	0,0414	0,9348

Tabel 11 tentang perbandingan antar algoritma menunjukkan *Deep Learning-LSTM* menghasilkan kinerja yang signifikan dalam menghasilkan nilai RMSE yang paling kecil dan nilai kolerasi (SC) yang lebih besar. Parameter yang digunakan adalah activation = linear, epoch = 50, batch_size = 64, verbose = 2, optimizer = Adam, hidden layer = 2 dan learning rate = 0,1. Nilai dari RMSE=0,0004 dan SC=0,9690. Visualisasi prediksi dari algoritma *Deep Learning-LSTM* terdapat pada gambar 10.



Gambar 10. Hasil Aktual vs Prediksi Umur Trafo-LSTM

4 KESIMPULAN

Perangkat lunak yang diteliti pada penelitian ini menghasilkan hasil yang memuaskan pada dataset yang berasal dari rekaman dari 25 transformator. Metode *KBest* digunakan untuk proses seleksi fitur berhasil mengurangi jumlah fitur dari 24 menjadi 7 fitur yang paling penting dan relevan untuk

memprediksi umur trafo yaitu tanggal, IS, energi, *unbalanced load*, suhu, V, dan L. Fitur-fitur ini kemudian diproses dengan empat algoritma mesin pembelajaran yaitu *Multilayer Perceptron*, *Deep Learning-LSTM*, *Linear Regression* dan *Gradient Boosting Regressor*. Hasil penelitian menunjukkan algoritma *Deep Learning-LSTM* dengan menggunakan parameter yaitu *activation = linear*, *epoch = 50*, *batch_size = 64*, *verbose = 2*, *optimizer = Adam*, *hidden_layer = 2* dan *learning rate = 0,1* mempunyai kinerja yang lebih baik daripada 3 algoritma lain nilai RMSE = 0,0004 dan nilai Squared Correlation = 0,9690.

Pada penelitian selanjutnya perangkat lunak ini akan dilengkapi dengan IoT sehingga sistem dapat melakukan prediksi umur dari transformator secara *realtime* dan dapat mendeteksi secara dini jika terjadi kegagalan fungsi pada transformator. Hal ini tentu akan membantu dalam proses jaminan mutu penyaluran listrik kepada pelanggan.

DAFTAR PUSTAKA

- JAHROMI AND PIERCY, R. (2019). An Approach to Power Trabsformer Asset Management. *IEEE*.
- ALQUDSI, A., AND EL-HAG, A. (2019). Application of Machine Learning in Transformer Health Index Prediction. *Energies*, 12(14), 1–13. <https://doi.org/10.3390/en12142694>
- AZZOUNI, A., AND PUJOLLE, G (2017). *NeuTM : A Neural Network-based Framework for Traffic Matrix Prediction in NeuTM : A Neural Network-based Framework for Traffic Matrix Prediction in SDN*. October.
- BABU, G. S., ZHAO, P., AND LI, X. L. (2016). Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9642, 214–228. https://doi.org/10.1007/978-3-319-32025-0_14
- CEFERIN, S., JANC, G., TOROS, Z., KASTELIC, T., AND PRASNIKAR, B. (2017). Power Transformer Monitoring Systems for Better Asset Management. *CIGRE - Open Access Proceedings Journal*, 2017(1), 395–399. <https://doi.org/10.1049/oap-cired.2017.1262>
- DE, A., AND DO, N. (2018). *Estimating the Remaining Lifetime of Power Transformers Using Paper Insulation Degradation*.
- DIWYACITTA, K., PRASOJO, R. A., SUWARNO, S., AND GUMILANG, H. (2017). Effects of Lifetime and Loading Factor on Dissolved Gases in power transformers. *ICECOS 2017 - Proceeding of 2017 International Conference on Electrical Engineering and Computer Science: Sustaining the Cultural Heritage Toward the Smart Environment for Better Future*, 243–247. <https://doi.org/10.1109/ICECOS.2017.8167142>
- DONG, M., AND GRUMBACH, L. S. (2019). Combining Unsupervised and Supervised Learning for Asset Class Failure Prediction in Power Systems. *ArXiv*.
- GULTOM, P., DANIAL, I, AND RAJAGUKGUK, M. (2017). Studi Susut Umur Transformator Distribusi 20 KV Akibat Pembebanan Lebih. *Jurnal Teknik Elektro Universitas Tanjungpura*, 2.
- ISTIAKE SUNNY, M. A., MASWOOD, M.M.S, AND ALHARBI, A. G. (2020). Deep Learning-Based Stock Price Prediction Using LSTM and Bi-Directional LSTM Model. *NILES* 2020, 87–92. <https://doi.org/10.1109/NILES50944.2020.9257950>
- KAVITHA, VARUNA AND RAMYA. (2016). A Comparative Analysis on Linear Regression and Support Vector Regression. *IC-GET*.
- KUMAR, J., GOOMER, R., AND SINGH, A. K. (2018). Long Short Term Memory Recurrent Neural Network (LSTM-RNN) Based Workload Forecasting Model for Cloud Datacenters. *Procedia Computer Science*, 125, 676–682. <https://doi.org/10.1016/j.procs.2017.12.087>
- LEECUN, Y., BENGIO, Y., AND HINTON, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- MA, M., & MAO, Z. (2019). Deep recurrent convolutional neural network for remaining useful life prediction. *2019 IEEE International Conference on Prognostics and Health Management, ICPHM 2019*, 1–4. <https://doi.org/10.1109/ICPHM.2019.8819440>
- MICELI, P. A., BLAIR, W. D., ANF BROWN, M. M. (2018). Deep Learning with Python. In *2018 21st International Conference on Information Fusion, FUSION 2018*. <https://doi.org/10.23919/ICIF.2018.8455530>
- Rizki, Y. Y., & Ervianto, E. (2019). Perkiraan umur

transformator berdasarkan pengaruh pembebanan dan temperatur lingkungan menggunakan metode trend linear. *Jom Fteknik*, 6(2), 1–8.

SAKINAH, N., TAHIR, M., BADRIYAH, T., AND SYARIF, I (2019). LSTM with Adam Optimization-Powered High Accuracy Preeclampsia Classification. *IES 2019 - International Electronics Symposium: The Role of Techno-Intelligence in Creating an Open Energy System Towards Energy Democracy, Proceedings*, 314–319. <https://doi.org/10.1109/ELECSYM.2019.8901536>

SCHMIDHUBER, S. H. J. (2017). LSTM. *Neural Comp*, 9(8).

SONG, X., HUANG, J., AND SONG, D. (2019). Air quality prediction based on LSTM-kalman model. *Proceedings of 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference, ITAIC 2019, Itaic*, 695–699. <https://doi.org/10.1109/ITAIC.2019.8785751>

TJAHJONO, A., SEPTIAN, W. A., ROSMALIATI, RIKA, N. W., & TAUFIK, T. (2019). Modeling the Temperature of the Distribution Transformer Oil Using Transformer Body Temperature and Power Quality Parameters Based on Artificial Neural Network. *2019 International Conference on Technologies and Policies in Electric Power and Energy, TPEPE 2019*, 7–12. <https://doi.org/10.1109/IEEECONF48524.2019.9102485>

VALTER, P., LINDGREN, P., & PRASAD, R. (2017). Artificial Intelligence and Deep Learning in a world of humans and persuasive business models. *IEEE*.