

IMPLEMENTASI ALGORITMA LONG SHORT TERM MEMORY (LSTM) UNTUK MEMPEREDIKSI VOLUME SAMPAH

Salsa Loni Manikari¹, Rini Astuti², Fadhil Muhammad Basysyar³, Agusbaciari⁴

^{1,4} Teknik Informatika, STMIK IKMI Cirebon

² Sistem Informasi, STMIK LIKMI Bandung

³ Sistem Informasi, STMIK IKMI Cirebon

Jalan Perjuangan No.10B, Karyamulya, Kec. Kesambi, Kota Cirebon, Jawa Barat 45135

Lonimanikari06@gmail.com

ABSTRAK

Permasalahan sampah telah menjadi isu penting di berbagai kota dan kabupaten di Indonesia, termasuk di kabupaten Cirebon. Pertumbuhan penduduk dan gaya hidup masyarakat menjadi faktor utama dalam meningkatkan volume sampah. Pada tahun 2022, volume sampah di Provinsi Jawa Barat meningkat 5,4%, menyebabkan masalah ketersediaan Tempat Pembuangan Akhir (TPA) yang hampir overload. Hal ini dapat mengakibatkan berkurangnya lahan tempat pembuangan sampah akhir. Oleh karena itu dibutuhkan prediksi volume sampah adalah cara untuk mengantisipasi lonjakan volume sampah yang berlebihan di lokasi pembuangan sampah akhir. Data yang digunakan dalam penelitian ini meliputi data time series yang terdiri dari tanggal dan jumlah volume sampah dari tahun 2021-2023 dengan metode Long Short Term Memory (LSTM). Penelitian ini menggunakan algoritma LSTM dengan jumlah neuron sebanyak 128, input layer sebanyak 30, dan pelatihan model sebanyak 500 epoch berhasil memberikan tingkat akurasi yang cukup baik dengan nilai MSE 0.02207 dalam memprediksi volume sampah.

Kata Kunci : *Prediksi, Volume sampah, TPAS, LSTM*

1. PENDAHULUAN

Sampah merupakan salah satu permasalahan kompleks yang harus dihadapi baik negara maju maupun negara berkembang. Pada daerah-daerah di Indonesia, permasalahan sampah kini telah menjadi sebuah fenomena penting bahkan menjadi fenomena social, hal ini terjadi karena banyak permasalahan sampah yang harus segera ditangani [1], termasuk daerah kab. Cirebon. Faktor mempengaruhi volume sampah yaitu meningkatnya jumlah penduduk, tingginya tingkat konsumsi dan perubahan gaya hidup masyarakat menjadi penyebab meningkatnya volume sampah [2]. Jika jumlah sampah terus meningkat setiap tahun, maka lahan TPA akan semakin berkurang. Perbandingan jumlah sampah yang dihasilkan dengan jumlah sampah yang diolah tidak sebanding [3]. Sampah yang tidak dikelola dengan benar akan merusak lingkungan, menimbulkan bau dan resiko penyakit disekitar TPAS.

TPAS adalah bagian yang sangat penting dari sistem pengelolaan sampah. Pemerintah kabupaten Cirebon memiliki salah satu tempat pembuangan akhir. TPAS Gunung santri terletak di desa kepek, kecamatan Palimanan, dengan luas lahan 47.000 m³. Untuk menangani masalah sampah, dinas lingkungan hidup (DLH) kabupaten Cirebon mengumpulkan sampah, menampungnya di tempat pembuangan sampah sementara yang disediakan oleh DLH, dan kemudian membawanya ke TPAS Gunung Santri. Hal ini dapat mengakibatkan berkurangnya lahan tempat pembuangan sampah akhir. Jika terus dibiarkan maka masa umur pakai TPAS akan berakhir dalam beberapa tahun ke depan. Oleh karena

itu dibutuhkan prediksi volume sampah adalah cara untuk mengantisipasi lonjakan volume sampah yang berlebihan di lokasi pembuangan sampah akhir. Langkah awal yang sangat penting dalam membuat strategi pengelolaan sampah adalah memprediksi atau meramalkan jumlah sampah yang masuk ke tpas gunung santri.

Studi terkait prediksi deret waktu dalam bidang data mining dan kecerdasan buatan telah dilakukan secara luas menggunakan metode regresi linier untuk prediksi volume dan ritasi sampah [4], penelitian selanjutnya menerapkan metode backpropagation untuk memprediksi volume sampah [5]. Meskipun demikian, metode regresi linier cenderung kurang efektif dalam menangkap pola non-linear dalam deret waktu. Di sisi lain, metode backpropagation sering mengalami kesulitan dalam menangkap pola jangka panjang karena masalah hilangnya gradien. Oleh karena itu, peneliti bertujuan untuk menggunakan metode Long Short Term Memory (LSTM) dalam menangani masalah ini. Penelitian ini bertujuan untuk memprediksi volume sampah yang akan masuk ke Tempat Pemrosesan Akhir Sampah (TPAS) Gunung Santri setiap harinya, serta menganalisis kinerja model LSTM untuk menemukan pola tersembunyi dalam data volume sampah. Fokus penelitian ini adalah pada evaluasi kinerja model LSTM, yang diukur menggunakan Mean Squared Error (MSE), dengan variasi parameter seperti jumlah epoch dan lapisan LSTM. Hasil dari penelitian ini berupa prediksi volume sampah yang akan masuk ke TPAS pada hari berikutnya.

Penelitian ini menerapkan pendekatan eksperimen dengan metode kuantitatif. Data yang

diperlukan diambil dari instansi terkait seperti dinas lingkungan hidup dan TPAS Gunung Santri. Proses pengolahan data meliputi tahapan pengumpulan data, prediksi, dan evaluasi hasil prediksi. Data volume sampah yang diperoleh dari TPAS Gunung Santri dan Dinas Lingkungan Hidup mencakup informasi tanggal dan volume sampah yang dibuang ke TPAS Gunung Santri. Proses pengolahan data melibatkan normalisasi dan pembagian data untuk uji dan pengujian. Langkah selanjutnya melibatkan proses prediksi menggunakan metode LSTM untuk menguji keefektifan metode tersebut. Hasil penelitian ini mencakup prediksi volume sampah yang diperkirakan akan dihasilkan pada hari berikutnya. Analisis data dilakukan dengan menerapkan teknik Proses *Knowledge Discovery in Databases* (KDD).

2. TINJAUAN PUSTAKA

Algoritma *Long Short-Term Memory* (LSTM) adalah sebuah jenis arsitektur jaringan neural yang dirancang khusus untuk menangani masalah pembelajaran berbasis urutan (*sequential learning*) dalam domain seperti pemrosesan bahasa alami, pemodelan waktuan, dan prediksi deret waktu. LSTM dirancang untuk mengatasi masalah memori jangka panjang (*long-term memory*) dan pendek (*short-term memory*) dalam pembelajaran urutan, sehingga memungkinkan model untuk menjaga informasi yang relevan dari masa lalu dan mengabaikan informasi yang tidak perlu.

Mean Squared Error (MSE) adalah nilai rata-rata dari kuadrat kesalahan (*error*) yang digunakan untuk mengukur tingkat kesalahan antara nilai yang diprediksi oleh model dan nilai yang sebenarnya dalam sampel data[6].

Knowledge Discovery in Databases(KDD) adalah Proses KDD merupakan sebuah elemen utama dalam domain ilmu data yang bertujuan untuk mengeksplorasi, menggali, dan menemukan pola atau pengetahuan yang bermanfaat dari kumpulan data yang besar dan kompleks. Proses KDD melibatkan langkah-langkah seperti pemahaman terhadap masalah yang dihadapi, persiapan dan pembersihan data, serta tahap penambangan data untuk mengidentifikasi pola atau informasi yang bermanfaat. Seiring dengan itu, KDD Cup menambah dimensi kompetitif ke dalam ranah penambangan data dengan menyelenggarakan serangkaian kompetisi tahunan di mana para peserta diberikan kumpulan data untuk menyelesaikan tantangan spesifik. Di sisi lain, dalam konteks sistem operasi Windows, istilah KDD juga merujuk pada Kernel Data Deduplication, sebuah fitur yang dirancang untuk mengurangi penggunaan ruang penyimpanan dengan menghapus salinan data identik pada tingkat blok. Oleh karena itu, KDD mencakup spektrum konsep yang luas, mencakup dari metode analisis data hingga kompetisi dalam ilmu data dan teknologi penyimpanan data dalam konteks perangkat lunak sistem operasi.

Paper [7] membahas mengenai prediksi volume pengangkutan sampah di sungai DKI Jakarta menggunakan metode Long Short Term Memory (LSTM). Dalam penelitian tersebut, terdapat dua tahap yang dilakukan, yaitu tahap pelatihan (*training*) dan pengujian (*testing*) untuk mengembangkan dan mengevaluasi model. Hasil penelitian menunjukkan bahwa Root Mean Squared Error (RMSE) memiliki nilai sebesar 54,711 untuk rata-rata volume sampah yang dapat diangkut setiap bulannya. Data yang digunakan dalam penelitian ini terdiri dari 43 sampel.

Paper [8] membahas mengenai prediksi tingkat tempelatur kota. Dalam penelitian tersebut, digunakan data iklim yang meliputi periode tahun 2019 hingga 2021 dengan total 1096 data. Data tersebut dibagi menjadi data latih sebanyak 70% dan data uji sebanyak 30%. Parameter yang dievaluasi meliputi learning rate, jumlah unit LSTM, epoch, dan ukuran batch. Hasil penelitian menunjukkan bahwa konfigurasi terbaik, dengan learning rate sebesar 0,009, 128 unit LSTM, ukuran batch 16, dan 100 epoch, menghasilkan prediksi paling akurat dengan nilai Mean Absolute Percentage Error (MAPE) terendah sebesar 1,896016% dan Root Mean Squared Error (RMSE) sebesar 0,725.

Paper [9] membahas mengenai memprediksi harga bahan pokok nasional. Dalam penelitian tersebut, dilakukan segmentasi atau pembagian jendela dengan jumlah timestep sebanyak 7. Proses ini dilakukan untuk membagi data input dan target berdasarkan jumlah timestep yang ditetapkan. Data awal dari timestep 1 hingga 6 digunakan sebagai data input, sedangkan timestep ke-7 dijadikan target.

Paper[10] membahas mengenai prediksi harga komoditas pangan. Dalam penelitian tersebut, dilakukan prediksi harga komoditas di Banyumas menggunakan data time series. Proses penelitian terdiri dari beberapa tahap, yaitu (1) pengumpulan data, (2) pra-pemrosesan data, (3) pelatihan dan pengujian, (4) pengembangan model LSTM, (5) evaluasi model, dan (6) visualisasi.

Paper[11] membahas mengenai prediksi curah hujan di KAB.Magelang. Dalam penelitian ini, diperoleh nilai Mean Absolute Error (MAE) sebesar 7.90, Root Mean Squared Error (RMSE) sebesar 10.16, dan Mean Squared Error (MSE) sebesar 103.37. Penelitian ini menguji dua skenario berbeda: skenario pertama menggunakan 4 lapisan LSTM, sedangkan skenario kedua menggunakan 2 lapisan LSTM dengan masing-masing memiliki 50-100 neuron.

Paper[12] membahas mengenai Studi ini menggambarkan upaya untuk meramalkan penjualan obat "X" dari PT. Metiska Farma menggunakan data penjualan harian selama tiga tahun (2017, 2018, dan 2019), yang terdiri dari 603 entri. Data ini mencatat tanggal penjualan dan nilai dalam jumlah rupiah. Tujuan penelitian ini adalah untuk mengembangkan model prediksi menggunakan teknik Machine Learning dan metode Regresi Long Short Term

Memory (LSTM). Dalam eksperimen ke-15, model terbaik menghasilkan nilai RMSE sebesar 286.465.424 untuk data latih dan 187.013.430 untuk data uji. Metode ini juga memberikan MAPE sebesar 787% untuk data latih dan 309% untuk data uji, menunjukkan tingkat akurasi yang baik dalam memprediksi penjualan. Dataset asli terdiri dari 603 entri, yang kemudian dibagi menjadi data latih (90%) dan data uji (10%).

Paper [13] membahas mengenai Langkah-langkah dalam penelitian ini mencakup pengumpulan data saham BBCA dari tahun 2011 hingga 2022, pra-pemrosesan data untuk memisahkan data latih dan data uji, serta penerapan teknik data mining menggunakan algoritma LSTM. Evaluasi dilakukan menggunakan metode Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE) untuk menentukan model yang paling optimal dalam memprediksi harga saham. Hasil penelitian menunjukkan bahwa kombinasi parameter terbaik adalah dengan jumlah epoch 5, batch size 1, dan jumlah unit 50 yang dioptimalkan menggunakan adam optimizer. Model ini menghasilkan MAE sebesar 96.924, MSE sebesar 16185.226, dan RMSE sebesar 127.221. Meskipun model ini mampu mengikuti tren harga saham aktual, terdapat perbedaan yang cukup signifikan antara harga aktual dan harga yang diprediksi pada beberapa parameter epoch.

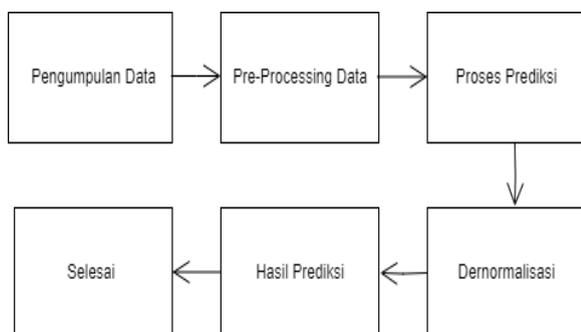
3. METODE PENELITIAN

Pendekatan metodologi yang digunakan adalah eksperimental dengan pendekatan kuantitatif. Langkah-langkah penelitian akan meliputi pengumpulan data, pra-pemrosesan data, proses prediksi, normalisasi, dan analisis hasil prediksi.

3.1. Pengumpulan Data

Pengumpulan data ini diperoleh melalui petugas yang bertanggung dalam menginput data volume sampah. Data volume yang diunduh dalam format xlsx mencakup periode dari Januari 2021-November 2023. Dengan jumlah data sebanyak 1065 data.

3.2. Normalisasi Data



Gambar 1. Metode Penelitian

Normalisasi data adalah sebuah proses yang dimanfaatkan untuk mengubah nilai-nilai dalam suatu kumpulan data yang secara relatif memiliki rentang nilai yang sangat berbeda menjadi rentang nilai yang seragam atau seimbang.[14] pada tahapan ini bertujuan untuk menghilangkan otensi bias yang akan ditimbulkan oleh perbedaan skala rentang nialai 0 dan 1.

Rumus Min-max :

$$X' = \frac{X - \text{Nilai Min}}{\text{Nilai Max} - \text{Nilai Min}} \quad (1)$$

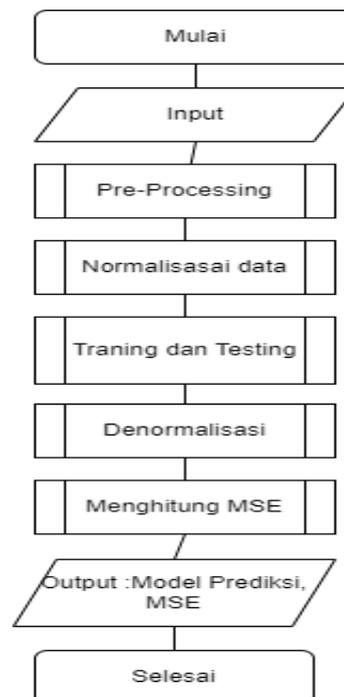
Pada tahapan ini juga akan dilakukan input windows size yang akan diterapkan sebanyak 30.

3.3. Pembagian Data

Pada penelitian ini akan dilakukan pembagian data menjadai data testing dan traning dengan rasio 70% dan 30%. Data pelatihan digunakan untuk mengajar dan merancang model atau membangun analisis di mana model akan belajar pola dari data pelatihan. Data pengujian digunakan untuk mengukur kinerja model atau mengevaluasi hasil analisis.

3.4. Proses Prediksi

Pada proses ini akan menggunakan algoritma Dalam proses analisis data ini, akan diterapkan algoritma Long Short Term Memory (LSTM). LSTM merupakan sebuah metode pengembangan dari jaringan saraf tiruan. Dalam LSTM, terdapat suatu keadaan yang disebut sebagai cell state yang mampu menyimpan informasi baik dalam jangka waktu yang pendek maupun panjang.



Gambar 2. Alur Algoritma LSTM

Parameter yang digunakan dalam penelitian ini:

Tabel 1. Parameter

| Parameter | |
|---------------|---------------------|
| Input Layer | 30,1 |
| LSTM | 8,16,32,64,128 |
| Dense | 8 |
| Output Layer | 1 |
| Optimizer | Adam |
| Epoch | 100,300,500,700,900 |
| Learning Rate | 0,01 |

3.5. Algoritma Long Short Memory

LSTM memiliki struktur utama yang terdiri dari empat bagian, yaitu Forget Gate (Ft), Input Gate (It), Hidden State (Hi), dan Output Gate (Ot), di mana setiap bagian memiliki fungsinya masing-masing. Penelitian ini akan memilih model yang cocok dan mengestimasi parameter yang akan digunakan, kemudian melatih model yang telah dibuat untuk melakukan prediksi.

a. *Input gate*

$$it = \sigma(Wi \times Xi + Ui \times ht - 1 + bi) \tag{3}$$

b. *Forget gate*

$$ft = \sigma(Wf \times Xt + Uf \times ht - 1 + bf) \tag{4}$$

c. *Hidden State*

$$ht = ot \odot \sigma(ct) \tag{5}$$

d. *Output gate*

$$ot = \sigma(Wo \times Xi + Uo \times ht - 1 + bo) \tag{6}$$

3.6. Denormalisasi

Proses denormalisasi dilakukan untuk mengubah data prediksi yang masih terkandung dalam interval 1 dan 0 menjadi nilai prediksi semula.

$$d = y(Max - Min) + min \tag{7}$$

Keterangan :

d = hasil nilai denormalisasi

y = hasil nilai prediksi sebelum denormalisasi

Min = nilai minimal

Max = nilai maksimal

3.7. Hasil Prediksi

Pada langkah ini, model yang telah dibuat akan disusun dan dinilai untuk mengevaluasi tingkat kesalahan rata-rata antara nilai sebenarnya dan nilai prediksi. Metode evaluasi yang digunakan adalah Mean Squared Error (MSE), yang umumnya dipakai untuk mengevaluasi ketepatan prediksi kesalahan dalam suatu proses prediksi. Nilai MSE yang kecil atau mendekati nol menunjukkan bahwa model memiliki kemampuan untuk menghasilkan prediksi yang akurat berdasarkan data aktual, yang berguna untuk peramalan masa depan[14].

$$MSE = \frac{1}{n} \sum_{k=0}^n (y_1 - y_t)^2 \tag{8}$$

Keterangan :

y = Nilai Aktual

Y_t = Nilai Prediksi

n = Jumlah Data

4. HASIL DAN PEMBAHASAN

4.1. Pengumpulan Data

Penelitian ini menggunakan data sekunder yang terdiri dari catatan historis tentang pengangkutan sampah ke Tempat Pembuangan Akhir Sampah (TPAS) Gunung Santri di Kabupaten Cirebon. Pengumpulan data dilakukan secara langsung melalui komunikasi dengan petugas yang bertanggung jawab atas pencatatan data pengangkutan sampah, yaitu petugas pengawas lingkungan hidup di Dinas Lingkungan Hidup. Data yang diperoleh mencakup volume sampah yang masuk ke TPAS Gunung Santri pada periode Januari 2021 hingga November 2023 dalam format file xlsx, dengan total 1065 rekaman data.

Tabel 2. Data Volume Sampah

| No. | Tanggal | Jumlah Volume Sampah (ton) |
|-----|------------|----------------------------|
| 1 | 01/01/2021 | 321 |
| 2 | 02/01/2021 | 366 |
| 3 | 03/01/2021 | 286 |
| 4 | 04/01/2021 | 362 |
| 5 | 05/01/2021 | 367 |
| 6 | 06/01/2021 | 353 |
| 7 | 07/01/2021 | 322 |
| 8 | 08/01/2021 | 315 |
| ... | | |
| 753 | 22/01/2023 | 367 |
| 754 | 23/01/2023 | 489 |

4.2. Pre-processing

Berdasarkan hasil analisis, diketahui bahwa rentang nilai minimum dan maksimum pada jumlah volume sampah memiliki perbedaan yang signifikan, yaitu antara 245 hingga 512. Oleh karena itu, normalisasi data diperlukan untuk menyatukan rentang nilai. Dalam penelitian ini, dilakukan feature scaling dengan rentang nilai antara 0 dan 1, sehingga semua data akan disesuaikan ke dalam rentang 0 hingga 1.

DataFrame Sebelum Normalisasi:

| | Tanggal | Volume sampah |
|------|------------|---------------|
| 0 | 2021-01-01 | 321 |
| 1 | 2021-01-02 | 366 |
| 2 | 2021-01-03 | 286 |
| 3 | 2021-01-04 | 362 |
| 4 | 2021-01-05 | 367 |
| ... | ... | ... |
| 1059 | 2023-11-26 | 295 |
| 1060 | 2023-11-27 | 487 |
| 1061 | 2023-11-28 | 368 |
| 1062 | 2023-11-29 | 379 |
| 1063 | 2023-11-30 | 344 |

Gambar 3. Sebelum Normalisasi

DataFrame Setelah Normalisasi:

| | Tanggal | Volume sampah |
|------|------------|---------------|
| 0 | 2021-01-01 | 0.284644 |
| 1 | 2021-01-02 | 0.453184 |
| 2 | 2021-01-03 | 0.153558 |
| 3 | 2021-01-04 | 0.438202 |
| 4 | 2021-01-05 | 0.456929 |
| ... | ... | ... |
| 1059 | 2023-11-26 | 0.187266 |
| 1060 | 2023-11-27 | 0.906367 |
| 1061 | 2023-11-28 | 0.460674 |
| 1062 | 2023-11-29 | 0.501873 |
| 1063 | 2023-11-30 | 0.370787 |

Gambar 4. Sesudah Normalisasi

Berikut ini perhitungan Normalisasi :

Nilai Min = 245
 Nilai Max = 512
 $X1 = (X - X_{min}) / (X_{max} - X_{min})$
 $= (321 - 245) / (512 - 245) = 76 / 267 = 0.284644$
 $X2 = (X - X_{min}) / (X_{max} - X_{min})$
 $= (366 - 245) / (512 - 245) = 121 / 267 = 0.453184$
 $X3 = (X - X_{min}) / (X_{max} - X_{min})$
 $= (286 - 245) / (512 - 245) = 41 / 267 = 0.153558$
 $X4 = (X - X_{min}) / (X_{max} - X_{min})$
 $= (362 - 245) / (512 - 245) = 117 / 267 = 0.438202$

Setelah normalisasi dilakukan, untuk mendapatkan hasil yang optimal, digunakan metode jendela geser (sliding windows) dengan ukuran jendela sebesar 30. Langkah ini bertujuan untuk memfasilitasi model dalam mengakses informasi historis dalam periode waktu tertentu, yang penting untuk analisis data deret waktu. Dan kemudian data akan dibagi menjadi 70% untuk data training dan 30% untuk data testing.

Tabel 3. Setelah Seading Windows

| X1 | X2 | ... | X30 | T |
|--------|--------|------|--------|--------|
| 0.2719 | 0.5526 | | 0.4517 | 0.4912 |
| 0.5526 | 0.3201 | | 0.4912 | 0.4517 |
| 0.3201 | 0.5214 | | 0.4517 | 0.6798 |
| | | | | |
| 0.1000 | 0.4912 | | 0.6359 | 0.5482 |
| 0.4912 | 0.6315 | | 0.5482 | 0.4912 |

4.3. Prediksi

Selanjutnya akan dilakukan pengujian pada data testing, model yang sudah dibuat sebelumnya akan di uji dengan dataset yang tidak pernah dilihat sebelumnya oleh model selama proses pelatihan. Pengujian ini bertujuan untuk mengevaluasi kinerja model dalam menggeneralisasi dan memberikan prediksi yang lebih akurat pada data baru. Hasil pengujian ini akan membantu menilai sejauh mana model dapat diandalkan dan efektif dalam memprediksi volume sampah berdasarkan pola pola yang telah dipelajari selama pelatihan.

Berdasarkan percobaan yang telah dilakukan menggunakan berbagai parameter. Berikut ini merupakan hasil dari uji coba hidden layer LSTM dan epoch hasil dapat dilihat dalam Tabel 4.

Tabel 4. Hasil Pengujian Parameter

| Unit LSTM | Epoch | Traning MSE | Testing MSE |
|-----------|-------|-------------|-------------|
| 128 | 100 | 0.040273 | 0.065360 |
| | 300 | 0.032474 | 0.073107 |
| | 500 | 0.010641 | 0.220207 |
| | 700 | 0.045155 | 0.067466 |
| 64 | 900 | 0.036070 | 0.079930 |
| | 100 | 0.019537 | 0.056968 |
| | 300 | 0.031394 | 0.081822 |
| 32 | 500 | 0.048721 | 0.069821 |
| | 700 | 0.043739 | 0.066524 |
| | 900 | 0.039238 | 0.077878 |
| | 100 | 0.022680 | 0.063652 |
| 16 | 300 | 0.040173 | 0.064401 |
| | 500 | 0.037127 | 0.074858 |
| | 700 | 0.033158 | 0.086420 |
| | 900 | 0.039973 | 0.074740 |
| 8 | 100 | 0.040053 | 0.056968 |
| | 300 | 0.029446 | 0.063829 |
| | 500 | 0.032466 | 0.077328 |
| | 700 | 0.050230 | 0.093856 |
| 4 | 900 | 0.032860 | 0.079285 |
| | 100 | 0.020249 | 0.060255 |
| | 300 | 0.025993 | 0.065560 |
| | 500 | 0.033460 | 0.059739 |
| 2 | 700 | 0.017513 | 0.060101 |
| | 900 | 0.034725 | 0.071883 |

Berdasarkan hasil pengujian pada nilai epoch 500 seperti yang tercatat dalam tabel 4, dapat disimpulkan bahwa arsitektur terbaik adalah menggunakan satu lapisan tersembunyi dan 128 lapisan LSTM. Model ini menghasilkan MSE pelatihan sebesar 0.010641 dan MSE pengujian sebesar 0.220207. Di sisi lain, pada nilai epoch 100, arsitektur terbaik kedua adalah dengan konfigurasi 30-64-1, yang memberikan MSE pelatihan sebesar 0.019537 dan MSE pengujian sebesar 0.056968. Selain mempertimbangkan nilai MSE, evaluasi model juga harus memperhatikan jumlah epoch, yang memberikan informasi tentang seberapa baik model LSTM dibangun selama proses pelatihan.

Dari Tabel 4 hasil eksperimen, menggunakan parameter yang telah ditentukan menghasilkan MSE terkecil sebesar 0.220207 dengan menggunakan model arsitektur 30-128-1 dengan epoch 500. Arsitektur ini terdiri dari 30 lapisan masukan, 1 lapisan tersembunyi dengan 128 lapisan LSTM, dan 1 lapisan keluaran. Hasil perbandingan ini akan digunakan untuk memprediksi volume sampah. Walaupun hasil pemodelan berada dalam rentang 0,1-1, namun perlu dilakukan denormalisasi pada data tersebut.

4.4. Denormalisasi

Setelah model LSTM memberikan prediksi volume sampah dalam bentuk data yang dinormalisasi, langkah selanjutnya adalah melakukan proses denormalisasi untuk mengembalikan hasil prediksi ke dalam skala nilai sebenarnya.

$$X = X (X_{max} - X_{min}) + X_{min}$$

$$X = 0,4972419 (512 - 245) + 245$$

$$X = 0,4972419 (267) + 245$$

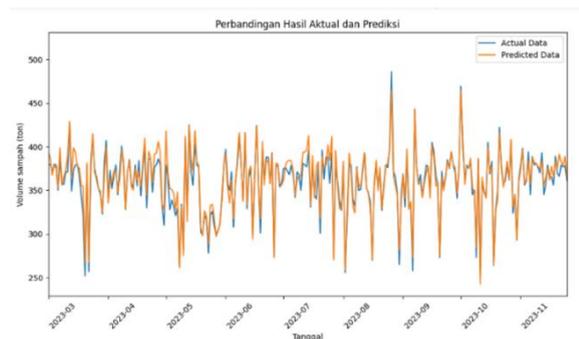
$$X = 132,76358 + 245 = 377,7636$$

Pada tabel 3 dibawah ini menunjukkan hasil dari data prediksi yang didapatkan dari model pelatihan terbaik.

Tabel 5. Hasil Denormalisasi data

| Sebelum Denormalisasi | Sesudah Denormalisasi |
|-----------------------|-----------------------|
| 0,4972419 | 377,7636 |
| 0,4841313 | 374,2631 |
| 0,4712943 | 370,8356 |
| | |
| 0,3297196 | 333,03515 |
| 0,6211281 | 410,84121 |
| 0,3947958 | 350,41049 |
| | |
| 0,6211219 | 410,83956 |
| 0,0915504 | 269,44396 |

Pada tabel 5 menunjukkan hasil prediksi menggunakan data training dan testing dan telah dilakukan proses denormalisasi. Plot data prediksi menggunakan parameter tersebut dapat dilihat pada gambar 8. pada plot tersebut dapat dilihat bahwa nilai prediksi mendekati nilai actual.



Gambar 8. hasil perbandingan data

Dari plot data tersebut, terlihat bahwa hasil prediksi tidak memiliki perbedaan yang signifikan terhadap data actual. Terlihat pada rentang waktu antara bulan juli 2023 hingga November 2023, model lstm menunjukkan kinerja yang baik dengan grafik yg relative stabil. Meskipun demikian, setelah rentang waktu tersebut. teramati pola berulang dalam model.

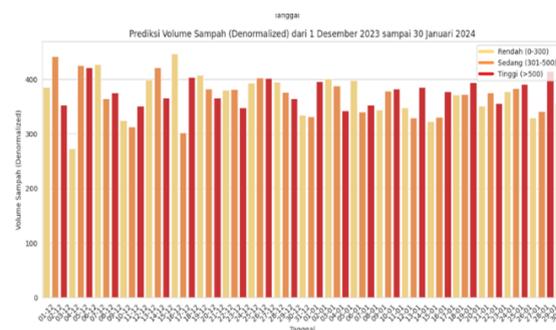
4.5. Hasil Prediksi

Hasil penelitian menunjukkan bahwa variasi jumlah LSTM mempengaruhi tingkat kemampuan model dalam menangkap pola pada data volume sampah. Dapat dilihat pada gambar 8 menunjukkan bahwa model yang menggunakan layer LSTM 128 dengan epoch memiliki nilai MSE yang cukup rendah dengan nilai rata-rata 0.01 pada data training dan data aktual 0.2.

| Tanggal | Data Aktual | Data Prediksi | Loss |
|------------|-------------|---------------|-----------|
| 20-Feb-23 | 379 | 377,7636 | 0,004631 |
| 21-Feb-23 | 380 | 374,2631 | 0,021486 |
| 21-Feb-23 | 371 | 370,8356 | 0,000616 |
| | | | |
| 16-Juni-23 | 338 | 333,03515 | 0,018594 |
| 17-Juni-23 | 413 | 410,84121 | 0,008085 |
| 18-Juni-23 | 329 | 350,41049 | 0,080189 |
| | | | |
| 29-Nov-23 | 405 | 410,8395691 | 0,0218710 |
| 30-Nov-23 | 276 | 269,4439697 | 0,0245543 |

Gambar 9. hasil nilai data actual dan prediksi

Hasil pengujian tersebut akan diterapkan pada data pengujian untuk memprediksi volume sampah dari bulan Desember 2023 hingga bulan Januari 2024. Dengan menggunakan parameter input layer sejumlah 30, hidden layer berjumlah 1 dengan 128 layer LSTM, dan output layer sejumlah 1 dengan epoch 500. Pada Gambar 10 berikut, terdapat hasil prediksi volume sampah yang diantisipasi untuk periode Desember 2023 hingga Januari 2024.



Gambar 10. hasil prediksi sampah bulan januarai 2024

Berdasarkan hasil tersebut, dapat dilihat bahwa pada tanggal 26 Desember 2023, terjadi peningkatan sekitar 432 ton sampah dalam satu hari, sementara pada tanggal 25 Desember terjadi penurunan volume sampah sekitar 350 ton per hari. Rata-rata jumlah sampah yang masuk ke TPAS Gunung Santri mencapai 354 ton per hari pada bulan Desember 2023. Prediksi untuk bulan Januari 2024 menunjukkan peningkatan pada tanggal 4 Januari 2024, dengan jumlah sampah sebanyak 386 ton per hari. Sementara itu, rata-rata prediksi sampah yang masuk ke TPAS pada tahun 2024 diperkirakan mencapai 355 ton.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian prediksi volume sampah menggunakan algoritma LSTM dengan konfigurasi parameter yang telah ditentukan, dapat diambil beberapa kesimpulan penting sebagai berikut : Penggunaan algoritma LSTM dengan jumlah neuron sebanyak 128, input layer sebanyak 30, dan pelatihan model sebanyak 500 epoch berhasil memberikan tingkat akurasi yang cukup baik dengan nilai MSE 0.02207 dalam memprediksi volume sampah. Berdasarkan hasil uji yang telah dilakukan oleh

peneliti yang menggunakan epoch 500 dan menambahkan parameter adam sangat mempengaruhi pada tingkat loss. Loss yang dihasilkan pada epoch memberikan nilai MSE terbaik yaitu 0.02207. Berdasarkan hasil pengujian dilakukan volume sampah bulan desember 2023- januari 2024. Hasil prediksi menunjukkan volume sampah pada tanggal 26 desember 2023 mengalami kenaikan sampah tertinggi di bulan desember. Memuat kesimpulan yang diperoleh dan saran-saran untuk penelitian selanjutnya (jika ada). Tuliskan Kesimpulan dan saran dalam 1 paragraf.

DAFTAR PUSTAKA

- [1] I. Kristanti, "Hubungan Pengetahuan Dan Sikap Tentang Pengelolaan Sampah Dengan Perilaku Pembuangan Sampah," *J. Kesehatan.*, vol. 8, no. 2, pp. 991–997, 2020, doi: 10.38165/jk.v8i2.108.
- [2] S. Hardiatmi, "The supporting factors of city waste management," *INNOFARM J. Inov. Pertan.*, vol. 10, no. 1, pp. 50–66, 2019.
- [3] R. Arisandi, H. Nariyah, and N. Nursahidin, "IMPLEMENTASI KEBIJAKAN PENGELOLAAN SAMPAH DI DINAS LINGKUNGAN HIDUP KABUPATEN CIREBON (Studi Kasus Tempat Penampungan Sampah Sementara Terminal Weru)," *J. Ilm. Publika*, vol. 7, no. 2, pp. 107–113, 2020, doi: 10.33603/publika.v7i2.4030.
- [4] . G., R. H. Laluma, and A. Prasetya, "Prediksi Volume Dan Ritasi Pengelolaan Sampah Di Kota Bandung Dengan Metode Regresi Linear," *Techno-Socio Ekon.*, vol. 15, no. 1, p. 49, 2022, doi: 10.32897/techno.2022.15.1.1195.
- [5] I. S. Purba *et al.*, "Implementasi Algoritma Backpropagation dalam Memprediksi Jumlah Mahasiswa Baru pada AMIK-STIKOM Tunas Bangsa Pematangsiantar," *Ilm. Ilmu Komput.*, vol. 2, no. 1, pp. 46–50, 2019, doi: 10.30645/senaris.v1i0.86.
- [6] A. S. B. Karno, "Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory)," *J. Inform. Inf. Secur.*, vol. 1, no. 1, pp. 1–8, 2020, doi: 10.31599/jiforty.v1i1.133.
- [7] G. W. Apandi Agung Ikbali, "PREDIKSI VOLUME PENGANGKUTAN SAMPAH DI SUNGAI DKI JAKARTA MENGGUNAKAN METODE LSTM," *repository.mercubuana.ac.id*, 2023, [Online]. Available: <https://repository.mercubuana.ac.id/76326/2/02/ABSTRAK.pdf>
- [8] R. Akbar, R. Santoso, and B. Warsito, "Prediksi Tingkat Temperatur Kota Semarang Menggunakan Metode Long Short-Term Memory (Lstm)," *J. Gaussian*, vol. 11, no. 4, pp. 572–579, 2023, doi: 10.14710/j.gauss.11.4.572-579.
- [9] J. Cahyani, S. Mujahidin, and T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *J. Sist. dan Teknol. Inf.*, vol. 11, no. 2, p. 346, 2023, doi: 10.26418/justin.v11i2.57395.
- [10] R. M. S. Adi and S. Sudiarto, "Prediksi Harga Komoditas Pangan Menggunakan Algoritma Long Short-Term Memory (LSTM)," *Build. Informatics, Technol. Sci.*, vol. 4, no. 2, pp. 1137–1145, 2022, doi: 10.47065/bits.v4i2.2229.
- [11] H. F. Freecenta, E. Yulia Puspaningrum, and H. Maulan, "Prediksi Curah Hujan Di Kab. Malang Menggunakan LSTM (Long Short Term Memory)," *J. Inform. dan Sist. Inf.*, vol. 3, no. 1, pp. 51–55, 2022, doi: 10.33005/jifosi.v3i1.448.
- [12] M. L. Ashari and M. Sadikin, "Prediksi Data Transaksi Penjualan Time Series Menggunakan Regresi Lstm," *J. Nas. Pendidik. Tek. Inform.*, vol. 9, no. 1, p. 1, 2020, doi: 10.23887/janapati.v9i1.19140.
- [13] M. N. Wathani, K. Kusriani, and K. Kusnawi, "Prediksi Tren Pergerakan Harga Saham PT Bank Central Asia Tbk, Dengan Menggunakan Algoritma Long Shot Term Memory (LSTM)," *Infotek J. Inform. dan Teknol.*, vol. 6, no. 2, pp. 502–512, 2023, doi: 10.29408/jit.v6i2.19824.
- [14] T. B. Sianturi, I. Cholissodin, and N. Yudistira, "Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 1101–1107, 2023, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/12384%0Ahttps://j-ptiik.ub.ac.id/index.php/j-ptiik/article/download/12384/5640>
- [15] G. Budiprasetyo, M. Hani'ah, and D. Z. Aflah, "Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM)," *J. Nas. Teknol. dan Sist. Inf.*, vol. 8, no. 3, pp. 164–172, 2023, doi: 10.25077/teknosi.v8i3.2022.164-172.