

PENERAPAN MODEL LONG SHORT-TERM MEMORY (LSTM) UNTUK PREDIKSI PEROLEHAN MEDALI PON

David^a, Ramalia Noratama Putri^b, Johan^c, Gusrianty^d

^aInstitut Bisnis dan Teknologi Pelita Indonesia, david2157@student.pelitaIndonesia.ac.id

^bInstitut Bisnis dan Teknologi Pelita Indonesia, ramalia.noratamaputri@lecturer.pelitaIndonesia.ac.id

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima Redaksi: 29 April 2025

Revisi Akhir: 29 April 2025

Diterbitkan Online: 29 April 2025

KATA KUNCI

Long Short-Term Memory (LSTM), Prediksi Perolehan Medali, PON, Data Historis, *Machine Learning*

KORESPONDENSI

E-mail: david2157@student.pelitaIndonesia.ac.id

ABSTRACT

Perolehan sebuah medali dalam pekan olahraga nasional (PON) sering kali menjadi sebuah acuan sebuah provinsi bahwa provinsi-provinsi tersebut memiliki kesuksesan dalam bidang olahraga. Oleh karena itu, melakukan prediksi yang akurat dapat membantu provinsi mendapatkan perolehan medali, agar provinsi provinsi yang ikut dalam PON dapat menyiapkan sebuah program Latihan, strategi yang akan digunakan saat berkompetisi. Penelitian ini bertujuan untuk mengembangkan sebuah model prediksi perolehan medali PON dengan metode *Long Short-Term Memory (LSTM)*, dimana merupakan metode yang baik dalam melakukan prediksi dengan basis analisis data historis. Dengan penelitian ini, data perolehan medali PON diolah dalam tahapan *preprocessing*. Model *LSTM* kemudian akan dikembangkan dan dievaluasi menggunakan metrik seperti *Mean Absolute Error (MAE)* dan *Root Mean Squared Error (RMSE)* untuk mengukur tingkat akurasi prediksi, sehingga model *LSTM* dapat memberikan prediksi dengan Tingkat akurasi yang tinggi dalam melakukan prediksi perolehan medali PON. Dengan penelitian ini dapat diharapkan memberikan kontribusi dalam dunia olahraga, terutama dalam membantu sebuah provinsi dalam menyiapkan program latihan dan strategi yang baik berdasarkan data prediksi yang telah dilakukan menggunakan data historis.

1. PENDAHULUAN

PON atau Pekan Olahraga Nasional adalah ajang olahraga berskala nasional yang diadakan setiap empat tahun sekali. Dan melibatkan atlet dari berbagai provinsi di Indonesia untuk memperebutkan medali dalam berbagai cabang olahraga dan untuk mempromosikan nilai-nilai solidaritas dan memperkuat integrasi budaya. PON diselenggarakan pada tahun 1948 disolo dan terus berkembang sebagai ajang olahraga terbesar di Indonesia, dimana pemilihan tuan rumah untuk melaksanakan PON dilakukan berdasarkan kebijakan Komite Olahraga Nasional Indonesia (KONI) [1]. PON diharapkan menjadi wadah pembinaan prestasi olahraga nasional. Sebagai contoh, PON Papua 2021 menjadi momen penting dalam implementasi kebijakan percepatan pembangunan kesejahteraan di Papua melalui Inpres Nomor 9 Tahun 2020, yang menekankan kolaborasi antar pemangku kepentingan untuk mendukung keberhasilan penyelenggaraan [2].

Dengan adanya perkembangan teknologi yang pesat maka dapat memungkinkan untuk melakukan prediksi perolehan medali PON dari berbagai provinsi, dimana dengan adanya penelitian ini dapat diharapkan memberikan kontribusi terhadap Lembaga olahraga dari berbagai provinsi peserta PON agar dapat memahami faktor-faktor apa saja yang dapat mempengaruhi perolehan medali. Melakukan prediksi dapat dilakukan dengan berbagai cara salah satunya adalah dengan mempelajari data historis, dimana data historis adalah kumpulan data-data yang dikumpulkan dari masa lalu dan digunakan untuk melakukan analisis atau prediksi terhadap pola masa depan. Adanya data historis mengenai hasil perolehan medali provinsi-provinsi peserta PON, data tersebut dapat digunakan untuk melakukan analisis yang bertujuan mengidentifikasi pola-pola tertentu. Pola ini berpotensi memberikan gambaran mengenai prediksi pemenang medali PON di masa depan seperti penelitian yang pernah dilakukan menggunakan data historis olimpiade dan algoritma *machine learning* untuk memprediksi perolehan medali [3]. Untuk mencapai tujuan penelitian ini maka metode *Long Short-Term*

Memory (LSTM) digunakan sebagai metode utama penelitian ini. *Long Short-Term Memory (LSTM)* adalah jaringan saraf tiruan berulang yang dirancang untuk mengatasi masalah *vanishing gradient* yang terjadi pada *Recurrent Neural Network (RNN)*, dimana pada metode *LSTM* ini memperkenalkan mekanisme “gate” yang memungkinkan jaringan untuk memilih informasi yang akan diteruskan dan yang akan diabaikan[4]. Metode *LSTM* dipilih karena memiliki kemampuan untuk menangani data *time series* seperti penelitian yang sudah pernah dilakukan dalam memprediksi harga saham dengan *RMSE* 27,310, sehingga metode ini terbukti efektif dan relevan untuk diaplikasikan untuk memprediksi dengan basis data historis [5].

2. TINJAUAN PUSTAKA

2.1. Pekan Olahraga Nasional (PON)

Pekan Olahraga Nasional (PON) adalah pesta olahraga terbesar yang diadakan setiap empat tahun sekali yang memiliki tujuan untuk melakukan promosi bahwa olahraga merupakan sebagian dari kehidupan masyarakat Indonesia dalam membangun persatuan bangsa dan meningkatkan kompetisi antar provinsi sekaligus menjadi jembatan untuk mengembangkan atlet yang berpotensi ke tingkat nasional dan internasional [6].

2.2. Machine Learning

Machine Learning merupakan sebuah studi ilmiah tentang suatu algoritma dan model statistik yang digunakan dalam sistem komputer untuk menjalankan tugas-tugas tertentu tanpa harus diprogram dulu secara eksplisit [7]. *Machine Learning* dibagi menjadi beberapa bagian kategori berdasarkan cara model dilatih dan jenis data yang akan digunakan, berikut jenis-jenis *machine learning*:

2.2.1. Supervised Learning

Supervised Learning adalah algoritma yang dilatih dengan data yang diberi label dengan tujuan memetakan *input* dan *output* yang sesuai [8].

2.2.2. Unsupervised Learning

Unsupervised Learning adalah algoritma yang dilatih dengan data yang tidak diberi label untuk menemukan sebuah pola atau struktur dalam sebuah data [8].

2.2.3. Reinforcement Learning

Reinforcement Learning adalah algoritma yang belajar dengan mendapatkan umpan balik berbasis *reward* dari lingkungan [8].

2.2.4. Semi-Supervised Learning

Semi-Supervised Learning adalah algoritma yang dilatih menggunakan kombinasi data berlabel dan tidak berlabel [8].

2.2.5. Self-Supervised Learning

Self-Supervised Learning adalah algoritma yang belajar dari data dengan cara menghasilkan label secara otomatis dari data itu sendiri, yang sering diterapkan pada pengenalan gambar [8].

2.3. Long Short-Term Memory

Long Short-Term Memory adalah jaringan saraf tiruan yang dirancang untuk mengenali pola dan ketergantungan waktu dalam data sekuensial, sehingga dapat mengatasi keterbatasan yang ditemukan dalam *recurrent neural network (RNN)* tradisional, dimana *LSTM* dapat memproses, menyimpan, dan mengingat informasi dalam urutan data yang panjang dan memungkinkan dalam menanganin tantangan seperti *vanishing gradient* yang sulit diatasi oleh *RNN* tradisional [9].

2.4. Arsitektur Long Short-Term Memory

Long Short-Term Memory adalah varian *recurrent neural network (RNN)* yang dirancang untuk mengatasi masalah yang sering terjadi dalam *RNN* yaitu untuk mempertahankan informasi data dalam jangka waktu yang panjang, sehingga *LSTM* memiliki arsitektur yang terdiri dari 3 *gates* utama, yaitu *forget gate*, *input gate*, dan *output gate* [10].

2.4.1. Forget Gate

Forget gate berfungsi untuk memutuskan sebuah informasi yang mana harus dilupakan [11].

$$f_t = \sigma(w_f \cdot x_t + b_f)$$

2.4.2. Input Gate

Input gate berfungsi untuk memperbarui informasi baru sehingga informasi yang ada masih relevan [11].

$$i_t = \sigma(w_i \cdot x_t + b_i)$$

2.4.3. Output Gate

Output gate berfungsi untuk memutuskan sebuah informasi yang akan digunakan sebagai keluaran [11].

$$o_t = \sigma(w_o \cdot x_t + b_o)$$

$$h_t = o_t \cdot \tanh(C_t)$$

2.5. Kelebihan Long Short-Term Memory

LSTM adalah model *deep learning* yang sudah dirancang untuk menangani data *time series* yang memiliki relasi temporal yang kuat, sehingga model *LSTM* ini mampu mengingat pola data jangka panjang yang dapat memberikan prediksi yang lebih akurat lagi dibandingkan dengan model *machine learning* yang lain. Selain itu, *LSTM* dapat disesuaikan untuk mencapai hasil yang lebih optimal dalam berbagai skenario skenario prediksi yang dapat menghasilkan error yang lebih rendah [12]. Berikut adalah kelebihan dari *LSTM*:

1. *LSTM* dirancang untuk mengatasi masalah ketergantungan jangka panjang pada data *time series* yang membuat *LSTM* dapat menangkap pola dari data historis.
2. *LSTM* mampu menyimpan informasi dalam jangka waktu yang panjang.

3. *LSTM* mampu bekerja baik dalam menangani *dataset* yang kompleks, seperti data *time series* yang memerlukan analisis yang mendalam terhadap pola pola historis.

2.6. Data Historis

Data historis dapat didefinisikan sebagai data data masa lalu yang memiliki fungsi sebagai informasi yang akan diinput dalam membuat prediksi. Data melibatkan rangkaian informasi informasi yang telah dikumpulkan dari waktu ke waktu, sehingga data data historis dapat digunakan untuk menganalisis sebuah pola, tren, dan perilaku yang mungkin tidak terlihat secara langsung. Secara umum data historis dapat berupa data kualitatif maupun kuantitatif yang dimana terdiri dari serangkaian observasi yang telah disusun secara berurutan sehingga setiap observasi dapat mewakili status pada titik waktu tertentu. Data historis memiliki manfaat untuk memahami hubungan antara variable, mengidentifikasi penyebab suatu kejadian, atau bahkan digunakan untuk melakukan prediksi [13]. Secara keseluruhan, data historis merupakan elemen utama dalam mengembangkan sebuah model prediksi yang akurat dan memiliki akurasi yang tinggi. Dengan adanya data historis maka model prediksi dapat memungkinkan pengambilan Keputusan yang lebih baik dan lebih terinformasi, karena model prediksi didasarkan oleh informasi historis yang sudah dikumpulkan dari waktu ke waktu dan sudah terbukti relevan di masa lalu [14].

3. METODOLOGI

Berikut merupakan beberapa tahapan yang dilakukan pada penelitian ini. Terdapat beberapa tahapan, antara lain:

3.1. Pengumpulan Data

Tahap awal yang sangat penting dalam penelitian ini adalah pengumpulan data yang memiliki tujuan untuk memperoleh informasi yang relevan dan akurat dari sumber-sumber data yang ada. Data yang digunakan dalam penelitian ini adalah dataset historis perolehan medali PON yang mencakup jumlah medali emas, perak, dan perunggu yang diperoleh masing-masing provinsi dari seri PON pada tahun 2000 hingga seri PON pada tahun 2024.

3.2. Preprocessing Data

Data yang sudah didapat akan dilanjutkan ke tahapan *preprocessing data* untuk memvalidasi perolehan medali, di mana data historis dikategorikan berdasarkan jumlah medali yang diperoleh dan data yang akan diproses adalah jumlah medali yang dimenangkan oleh setiap provinsi dalam setiap edisi PON. Setelah berhasil diverifikasi, karakter khusus, dan kata atau angka yang hilang. Proses ini dapat membantu menjamin data yang digunakan.

3.3. Penerapan Model Long Short-Term Memory

Setelah melakukan *preprocessing data*, selanjutnya model *LSTM* akan diterapkan untuk melakukan prediksi jumlah medali yang akan dimenangkan oleh setiap provinsi. *LSTM* dipilih karena kemampuannya dalam mengatasi masalah *vanishing gradient* yang sering terjadi pada *Recurrent Neural Network* konvensional, serta kemampuannya yang sangat baik dalam menangani data sekuensial. Dalam implementasi ini, *LSTM* akan dilatih

menggunakan data historis jumlah medali yang dimenangkan oleh setiap provinsi di setiap seri PON sebelumnya.

3.4. Evaluasi Model

Setelah melatih *LSTM* menggunakan data historis, hasilnya dievaluasi dengan memeriksa performa model. Evaluasi sangat penting dilakukan karena memberikan kebaikan model dalam prediksinya. Dua metrik utama yang diterapkan dalam mengevaluasi model *LSTM* adalah *Mean Absolute Error* dan *Root Mean Squared Error*.

Dimana dengan rumus *MAE* dan *RMSE* sebagai berikut [15]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

4. HASIL DAN PEMBAHASAN

Penelitian ini akan menghasilkan sebuah sistem berbasis *website* yang memiliki fungsi untuk melakukan prediksi perolehan medali emas, perak, dan perunggu dari setiap provinsi yang mengikuti PON. Pada sistem ini, menggunakan data yang sudah diolah dan sudah dibersihkan sehingga tidak ada proses *preprocessing data*.

4.1. Perhitungan Manual

Perhitungan manual pada penelitian akan menggunakan data dari provinsi jawa barat. Data dapat dilihat pada tabel di bawah ini.

Tabel 1 : Data Time Series Jawa Barat

Tahun	Emas	Perak	Perunggu
2004	76	79	94
2008	101	84	132
2012	99	79	101
2016	217	157	157
2021	133	105	115
2024	195	163	182

Tabel di atas merupakan data *time series* jawa yang diambil dari 6 edisi PON sebelumnya, setelah data diambil maka selanjutnya akan dilakukan normalisasi data. Data normalisasi dari data *time series* dapat dilihat pada tabel dibawah ini.

Tabel 2 : Normalisasi Data Time Series Jawa Barat

Tahun	Emas	Perak	Perunggu
2004	0.0	0.0	0.0
2008	0.177	0.06	0.34
2012	0.163	0.0	0.07
2016	1.0	0.93	0.63
2021	0.405	0.31	0.24
2024	0.843	1.0	1.0

Data dari tahun 2004 hingga tahun 2016 digunakan sebagai data latih, sementara data tahun 2021 hingga tahun 2024 digunakan sebagai data uji. Berikut merupakan hasil perhitungan medali

emas pada provinsi jawa barat dengan mengimplementasikan metode *LSTM*.

4.1.1. Perhitungan Forget Gate

$$\text{Rumus: } f_t = \sigma(w_f \cdot x_t + b_f)$$

Di mana:

$w_f = 0.5$: Bobot untuk forget gate.

$x_t = 0.843$: Nilai normalisasi jumlah medali emas

$b_f = 1$: Bias untuk forget gate.

Langkah perhitungan:

$$f_t = \sigma((0.5 \cdot 0.843) + 1)$$

$$= \sigma(0.4215 + 1)$$

$$= \sigma(1.4215)$$

Nilai sigmoid (σ) dari 1.4215 dapat dihitung:

$$f_t = \frac{1}{1 + e^{-1.4215}} = 0.806$$

Jadi, nilai $f_t = 0.806$, artinya 80.6% dari status sel sebelumnya akan dipertahankan.

4.1.2. Perhitungan Input Gate

$$\text{Rumus: } i_t = \sigma(w_i \cdot x_t + b_i)$$

Di mana:

$w_i = 0.5$: Bobot untuk input gate.

$x_t = 0.843$: Nilai normalisasi jumlah medali emas

$b_i = 0.5$: Bias untuk input gate.

Langkah perhitungan:

$$i_t = \sigma((0.5 \cdot 0.843) + 0.5)$$

$$= \sigma(0.4215 + 0.5)$$

$$= \sigma(0.9215)$$

Menghitung sigmoid:

$$i_t = \frac{1}{1 + e^{-0.9215}} = 0.715$$

Jadi, nilai $i_t = 0.715$, yang berarti 71,5% dari informasi baru akan dimasukkan.

4.1.3. Perhitungan Lapisan Tanh

$$\text{Rumus: } \tilde{C}_t = \tanh(w_C \cdot x_t)$$

Di mana:

$w_C = 0.5$: Bobot untuk lapisan tanh.

$x_t = 0.843$: Nilai normalisasi input saat ini.

Langkah perhitungan:

$$\tilde{C}_t = \tanh(0.5 \cdot 0.843)$$

$$= \tanh(0.4215)$$

Menghitung tanh:

$$\tilde{C}_t = \tanh(0.4215)$$

$$= 0.398$$

Jadi, $\tilde{C}_t = 0.398$, yaitu kandidat nilai baru untuk status sel.

4.1.4. Perhitungan Status Sel Yang Diperbarui

$$\text{Rumus: } C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t$$

Di mana:

$f_t = 0.806$: Nilai dari forget gate.

$C_{t-1} = 0$: Status sel sebelumnya.

$i_t = 0.715$: Nilai dari input gate.

$\tilde{C}_t = 0.398$: Nilai kandidat status sel.

Langkah perhitungan:

$$C_t = (0.806 \cdot 0) + (0.715 \cdot 0.398)$$

$$= 0 + 0.285$$

$$= 0.285$$

Jadi, $\tilde{C}_t = 0.285$, yaitu status sel yang baru.

4.1.5. Perhitungan Output Gate

$$\text{Rumus: } o_t = \sigma(w_o \cdot x_t + b_o)$$

Di mana:

$w_o = 0.5$: Bobot untuk output gate.

$x_t = 0.843$: Nilai input saat ini.

$b_o = 0.5$: Bias untuk output gate.

Langkah perhitungan:

$$o_t = \sigma((0.5 \cdot 0.843) + 0.5)$$

$$= \sigma(0.4215 + 0.5)$$

$$= \sigma(0.9215)$$

Menghitung sigmoid:

$$O_t = \frac{1}{1 + e^{-0.9215}} = 0.715$$

Jadi, $O_t = 0.715$.

4.1.6. Perhitungan Status Tersembunyi Yang Diperbarui

$$\text{Rumus: } h_t = O_t \cdot \tanh(C_t)$$

Di mana:

$O_t = 0.715$: Nilai dari output gate.

$C_t = 0.285$: Status sel yang diperbarui.

Langkah perhitungan:

$$h_t = 0.715 \cdot \tanh(0.285)$$

$$= 0.715 \cdot 0.277$$

$$= 0.198$$

Jadi, $h_t = 0.198$, yaitu status tersembunyi yang baru untuk langkah waktu ini.

4.2. Evaluasi Model Uji

Setelah melakukan perhitungan manual menggunakan metode *LSTM* dalam memprediksi medali emas yang akan diperoleh provinsi Jawa Barat, maka selanjutnya akan dilakukan evaluasi model uji menggunakan matriks *maen absolute error(MAE)* dan *root mean squared error(RMSE)*. Data data yang digunakan antara lain nilai aktual (y_i): 0.843 (nilai normalisasi jumlah medali emas yang sebenarnya) dan nilai prediksi ($\hat{y}_i$): 0.198 (nilai prediksi dari model *LSTM*).

4.2.1. Perhitungan Maen Absolute Error

Rumus MAE:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Langkah Perhitungan MAE:

Hitung kesalahan absolut untuk setiap data:

$$|y_i - \hat{y}_i| = |0.843 - 0.198| = 0,645$$

Jadi, kesalahan absolut untuk data ini adalah 0,645.

4.2.2. Perhitungan Root Maen Squared Error

Rumus RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Langkah Perhitungan RMSE:

Hitung kuadrat dari kesalahan untuk setiap data:

$$\begin{aligned} (y_i - \hat{y}_i)^2 &= (0.843 - 0.198)^2 \\ &= 0,645^2 \\ &= 0,416025 \end{aligned}$$

Hitung rata-rata dari kuadrat kesalahan: Karena hanya ada satu data, rata-rata dari kuadrat kesalahan adalah sama:

$$\frac{1}{1} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = 0,416025$$

Ambil akar kuadrat dari rata-rata kuadrat kesalahan:

$$RMSE = \sqrt{0,416025} = 0,645$$

Jadi, RMSE untuk data ini adalah 0,645.

Kedua metrik tersebut menunjukkan bahwa rata-rata kesalahan antara nilai prediksi dan nilai aktual adalah 0,645 dalam satuan data normalisasi (nilai medali). Dalam kasus ini, karena hanya ada satu data, hasil MAE dan RMSE sama. Jika Anda memiliki lebih banyak data, perhitungan ini bisa diterapkan pada seluruh dataset untuk mendapatkan evaluasi yang lebih akurat.


Tabel 3 : Uji Manual *LSTM* 12 Provinsi

Provinsi	Emas	Perak	Perunggu
Jawa Barat	172	135	169
DKI Jakarta	154	125	136
Jawa Timur	116	115	132
Papua	75	51	93
Kalimantan Timur	66	67	92
Sumatera Utara	66	46	106
Jawa Tengah	58	71	108
Aceh	53	36	72
Bali	27	28	53
Riau	26	26	44
Yogyakarta	24	29	48
Sumatera Selatan	19	25	34

Tabel di atas merupakan sebagian hasil uji manual menggunakan *LSTM* semua provinsi dimana penulis hanya memasukkan 12 provinsi dikarenakan terlalu banyaknya provinsi yang tidak dapat dimasukkan, dengan nilai MAE dan RMSE adalah 0.2563 dan 0.2893, atau dengan akurasi 74.37% dan 71.07%.

4.3. Diagram Aliran Sistem Informasi Berjalan


Berikut merupakan alur proses melakukan prediksi perolehan medali PON berdasarkan peran *stakeholders* yang sedang berjalan:



Gambar 1. Alur Proses Melakukan Prediksi Perolehan Medali PON

4.4. Use Case Diagram

Untuk menggambarkan interaksi antara aktor dengan sistem yang sedang dikembangkan perlu digambarkan dengan *use case*, berikut use case sistem yang dirancang.



Gambar 2. Use Case Diagram

Berikut penjabaran semua *use case* yang berkaitan dengan sistem yang dirancang seperti terlihat pada tabel di bawah ini:

Tabel 4 : Definisi Aktor Use Case Diagram


No	Nama Aktor	Deskripsi
1	Admin	Aktor yang mengelola website, dapat melakukan beberapa tugas utama yang ada pada website, yaitu melakukan prediksi perolehan medali PON
2	Pimpinan	Aktor yang menjadi atasan dari admin, dapat menerima laporan hasil prediksi dan menjadi pengambil Keputusan terhadap perkembangan dan kebijakan dibidang olahraga berdasarkan hasil prediksi.

Tabel 5 : Definisi Use Case Diagram

Kode	Use Case	Deskripsi
UC_1	Melakukan Login	Proses di mana admin akan melakukan proses masuk ke dalam halaman dashboard.
UC_2	Mengakses halaman prediksi LSTM	Halaman yang menjadi fungsi utama dari sistem. Untuk melakukan prediksi perolehan medali PON selanjutnya yang dilakukan oleh admin.
UC_3	Memasukkan dataset	Usecase yang dilakukan untuk memasukkan dataset untuk melakukan prediksi perolehan medali PON.
UC_4	Melakukan Prediksi	Usecase yang dilakukan untuk melakukan prediksi menggunakan algoritma LSTM.
UC_5	Menguji Performa Model	Usecase yang dilakukan untuk menguji performa model menggunakan matrik MAE dan RMSE.
UC_6	Melihat Laporan Prediksi	Usecase yang dilakukan untuk melihat data laporan hasil prediksi yang akan dicetak oleh admin dan akan diserahkan kepada pimpinan.


4.5. Implementasi Sistem

Dari sistem yang sudah dirancang, maka penulis membuat sistem sedemikian rupa sesuai dengan rancangan antarmuka yang sudah dijelaskan. Berikut merupakan implementasi sistem yang sudah diterapkan.




Gambar 3. Halaman Login

Gambar diatas ini merupakan tampilan dari halaman login untuk masuk ke website prediksi perolehan medali PON.



Gambar 4. Halaman Dashboard


Gambar diatas ini merupakan tampilan halaman utama atau dashboard dari sistem prediksi perolehan medali PON, dimana tampilan dashboard ini hanya memberikan informasi fitur fitur yang dapat digunakan oleh admin seperti upload data historis dalam format CSV, prediksi perolehan medali PON per provinsi, dan generate laporan prediksi dalam format PDF.



Gambar 5. Halaman Upload Dataset


Tampilan diatas merupakan tampilan dari menu upload data training, dimana sistem akan menampilkan form upload kepada admin agar admin dapat mengupload dataset yang sesuai dengan format yang sesuai dengan keterangan pada form upload. Pada form upload ini juga sistem akan melakukan training data

berdasarkan dataset yang sesuai dengan format sehingga sistem dapat melakukan fungsi utamanya.



Gambar 6. Halaman Prediksi Dan Status Sistem

Halaman ini merupakan tempat bagi admin untuk memilih provinsi yang akan di prediksi dan status sistem yang berisi informasi tentang jumlah provinsi, *MAE* dan *RMSE* yang sudah dibaca dan *ditraining* oleh sistem.



Gambar 7. Halaman Hasil Prediksi

Halaman ini merupakan tempat menampilkan hasil prediksi dari provinsi yang sudah dipilih oleh *admin* pada halaman sebelumnya, dimana pada halaman ini akan menampilkan jumlah prediksi medali emas, perak, dan perunggu dan juga sistem akan menampilkan tren historis dan prediksi medali dalam bentuk grafik.

Provinsi	Prediksi	Error	Perak	Perunggu
DKI Jakarta	145	100	100	100
Jawa Barat	100	100	100	100
Jawa Tengah	95	100	100	100
Kalimantan Utara	107	10	10	10
Riau	100	10	10	10
Jawa Tengah	102	10	10	10
Sumatera Utara	104	10	10	10
Aceh	104	10	10	10
Bali	107	10	10	10
Riau	100	10	10	10
Kepulauan Riau	100	10	10	10
Kalimantan	107	10	10	10

Gambar 8. Halaman Laporan Prediksi

Halaman ini akan menampilkan fungsi untuk mencetak laporan hasil prediksi yang sudah tersimpan di dalam *database*, pada halaman ini laporan pada sistem berisi semua prediksi perolehan medali PON dari seluruh provinsi.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Kesimpulan yang dapat diambil dari penelitian mengenai Penerapan model *long short-term memory (LSTM)* untuk Prediksi Perolehan Medali PON adalah Data historis PON dapat dimanfaatkan melalui berbagai tahapan *preprocessing data* seperti normalisasi data menggunakan *MinMaxScaler*, dengan pembagian data historis menjadi 70% data latih dan 30% data uji untuk diterapkan dalam metode *LSTM*, kemudian evaluasi hasil dari prediksi menggunakan metode *LSTM* memiliki akurasi yang baik dengan nilai *MAE* 0.2563 (akurasi 74.37%) dan *RMSE* 0.2893 (71.07%), dan terdapat *overfitting minor*, oleh karena itu metode *Long Short Term Memory (LSTM)* dalam melakukan prediksi perolehan medali PON yang akan datang dapat diimplementasikan dengan baik menggunakan sistem berbasis website.

5.2. Saran

Diharapkan akan ada pembaruan dataset secara berkala oleh dinas kepemudaan dan olahraga untuk meningkatkan akurasi prediksi sistem, melakukan optimalisasi pada aksesibilitas sistem sebagai platform terbuka agar informasi-informasi dapat diakses publik secara transparan, dan mengintegrasikan variabel tambahan seperti jumlah atlet, anggaran pelatihan, atau cabang olahraga untuk analisis yang lebih detail.

DAFTAR PUSTAKA

- [1] P. R. Putra, A. Ma'mun, and H. Firmansyah, "Indonesia National Sports Games (PON) Organizing in the Reform Era (2000-2020)," 2023. [Online]. Available: <https://ejournal.upi.edu/index.php/ajsdp/>
- [2] M. Kossay, "Analisis Terhadap Inpres Nomor 9 Tahun 2020 dalam," vol. volume 1, 2021.
- [3] P. Badoni, P. Choudhary, C. P. Rudesh, and N. T. Singh, "Predicting Medal Counts in Olympics Using Machine Learning Algorithms: A Comparative Analysis," in *Proceedings - 2023 International Conference on Advanced Computing and Communication Technologies, ICACCTech 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 116–121. doi: 10.1109/ICACCTech61146.2023.00027.
- [4] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network," Aug. 2020, doi: 10.1016/j.physd.2019.132306.
- [5] A. Agusta, I. Ernawati, and A. Muliawati, "Prediksi Pergerakan Harga Saham Pada Sektor Farmasi Menggunakan Algoritma Long Short-Term Memory," 2021.
- [6] I. Ayu and P. Aditria, "Status Kondisi Fisik Atlet Cabang Olahraga Renang Indah Tim Pelatihan Daerah Pekan Olahraga Nasional Provinsi Jawa Timur," 2022.
- [7] B. Mahesh, "Machine Learning Algorithms - A Review," *International Journal of Science and Research (IJSR)*, vol. 9, no. 1, pp. 381–386, Jan. 2020, doi: 10.21275/art20203995.
- [8] A. Darmawan Sidik, A. Ansawarman, K. Kunci, J. Kendaraan Bermotor, M. Regresi, and F. Jalan,

- “Prediksi Jumlah Kendaraan Bermotor Menggunakan Machine Learning,” *Formosa Journal of Multidisciplinary Research (FJMR)*, vol. 1, no. 3, pp. 559–568, 2022, doi: 10.55927.
- [9] M. Ghislieri, G. L. Cerone, M. Knaflitz, and V. Agostini, “Long short-term memory (LSTM) recurrent neural network for muscle activity detection,” *J Neuroeng Rehabil*, vol. 18, no. 1, Dec. 2021, doi: 10.1186/s12984-021-00945-w.
- [10] Y. Liu *et al.*, “A long short-term memory-based model for greenhouse climate prediction,” *International Journal of Intelligent Systems*, vol. 37, no. 1, pp. 135–151, Jan. 2022, doi: 10.1002/int.22620.
- [11] K. Avicenna, W. ; Endang, W. Pamungkas, S. Kom, and M. Kom, “Implementasi Algoritma LSTM Untuk Prediksi Harga Saham Pada Situs Yahoo Finance Dengan Menerapkan Microservice,” 2020.
- [12] S. Sautomo and H. F. Pardede, “Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM),” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 99–106, Feb. 2021, doi: 10.29207/resti.v5i1.2815.
- [13] P. H. Padhila, I. Cholissodin, and P. P. Adikara, “Prediksi Harga Bitcoin berdasarkan Data Historis Harian dan Google Trend Index menggunakan Algoritme Extreme Learning Machine,” 2022. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [14] M. Seyedan and F. Mafakheri, “Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities,” *J Big Data*, vol. 7, no. 1, Dec. 2020, doi: 10.1186/s40537-020-00329-2.
- [15] J. Qi, J. Du, S. M. Siniscalchi, X. Ma, and C.-H. Lee, “On Mean Absolute Error for Deep Neural Network Based Vector-to-Vector Regression,” Aug. 2020, doi: 10.1109/LSP.2020.3016837.