

Analisis Deret Waktu untuk *Forecasting* Populasi Ternak di Indonesia dengan Model LSTM

¹Tito Prabowo, ²Lestariningsih, ³Abd. Charis Fauzan, ⁴Veradella Yuelisa Mafula

Universitas Nahdlatul Ulama Blitar, Indonesia

titoprabowo@unublitar.ac.id; lestariningsih@unublitar.ac.id; abdcharis@unublitar.ac.id;

veradella@unublitar.ac.id

Article Info

Article history:

Received, 2024-12-27

Revised, 2025-01-07

Accepted, 2025-01-09

Kata Kunci:

Deret Waktu
Forecasting
Populasi ternak
Model LSTM

Keywords:

Livestock population
LSTM Models
Forecasting
Time series

ABSTRAK

Populasi ternak di Indonesia merupakan salah satu indikator utama dalam mendukung ketahanan pangan nasional, khususnya untuk memenuhi kebutuhan protein hewani. Namun, pemanfaatan data populasi ternak untuk perencanaan strategis kurang optimal, sehingga menghambat pengambilan keputusan berbasis data. Masalah utama yang dihadapi adalah keterbatasan dalam memprediksi tren populasi ternak di masa depan. Penelitian ini bertujuan untuk memprediksi populasi ternak di Indonesia menggunakan metode *Long Short-Term Memory* (LSTM), salah satu varian *Recurrent Neural Network* (RNN) yang dirancang untuk analisis data deret waktu. Data populasi ternak yang digunakan diperoleh dari Badan Pusat Statistik (BPS) untuk periode 2006 hingga tahun 2022. Model LSTM dilatih menggunakan 80% data untuk pelatihan dan 20% untuk pengujian, dengan evaluasi menggunakan *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE). Hasil penelitian menunjukkan bahwa model LSTM mampu melakukan *forecasting* populasi ternak nasional hingga tahun 2033, dengan tingkat akurasi yang baik, terutama pada ternak seperti kambing (MAPE 5.47%) dan sapi potong (MAPE 5.64%). Namun, tingkat kesalahan lebih tinggi pada kerbau (MAPE 16.57%). Prediksi ini menunjukkan tren pertumbuhan populasi yang signifikan pada unggas seperti ayam pedaging dan ayam petelur. Kesimpulannya, model ini dapat mendukung pengambilan keputusan berbasis data untuk memastikan ketersediaan protein hewani yang stabil dan berkelanjutan, mendukung ketahanan pangan nasional.

ABSTRACT

The livestock population in Indonesia is one of the key indicators in supporting national food security, particularly in meeting the demand for animal protein. However, the utilization of livestock population data for strategic planning remains suboptimal, hindering data-driven decision-making processes. The primary issue lies in the limitations of predicting future trends in livestock population accurately. This study aims to forecast the livestock population in Indonesia using the *Long Short-Term Memory* (LSTM) method, a variant of *Recurrent Neural Networks* (RNN) designed for time-series data analysis. The livestock population data used were obtained from the Indonesian Central Bureau of Statistics (BPS) for the period of 2006 to 2022. The LSTM model was trained using 80% of the data for training and 20% for testing, with evaluation metrics including *Mean Absolute Error* (MAE) and *Root Mean Squared Error* (RMSE). The study results demonstrate that the LSTM model is capable of forecasting the national livestock population up to 2033 with high accuracy, particularly for livestock such as goats (MAPE 5.47%) and beef cattle (MAPE 5.64%). However, the error rate is higher for buffaloes (MAPE 16.57%). The predictions indicate a significant population growth trend in poultry, such as broilers and laying hens. In conclusion, this model can support data-driven decision-making to ensure stable and sustainable animal protein availability, thus contributing to national food security.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by/4.0/) license.

**Penulis Korespondensi:**

Tito Prabowo

Program Studi Ilmu Komputer

Universitas Nahdlatul Ulama Blitar,

Email: titoprabowo@unublitar.ac.id**1. PENDAHULUAN**

Pada saat ini, jumlah populasi ternak di Indonesia telah terdokumentasi dengan baik melalui kegiatan sensus ternak yang kemudian diintegrasikan ke dalam data yang dikelola oleh Badan Pusat Statistik (BPS). Data populasi ternak yang diterbitkan oleh BPS telah dipetakan secara terperinci berdasarkan provinsi, memberikan gambaran yang jelas mengenai distribusi ternak di berbagai wilayah. Informasi ini mencakup berbagai jenis ternak, seperti sapi, kambing, ayam, itik, dan babi, yang merupakan komponen utama dalam mendukung ketahanan pangan nasional. Dengan terus meningkatnya populasi penduduk di Indonesia, kebutuhan akan protein hewani juga semakin tinggi [1]. Kondisi ini mendorong pemerintah untuk mengambil langkah strategis guna memastikan ketersediaan protein hewani, termasuk melalui kebijakan distribusi dan peningkatan produksi ternak. Namun, masih banyak potensi yang belum dimanfaatkan secara optimal dalam sektor peternakan. Salah satunya adalah penggunaan data populasi ternak untuk mendukung pengambilan keputusan berbasis bukti yang lebih akurat dan berkelanjutan [2].

Sebagai negara agraris dengan sumber daya alam yang melimpah, Indonesia memiliki peluang besar untuk mengembangkan sektor peternakan yang lebih modern dan efisien. Namun, salah satu permasalahan utama dalam sektor ini adalah kurang optimalnya pemanfaatan data populasi ternak dalam proses perencanaan dan pengambilan kebijakan [3]. Data yang ada sering kali tidak terintegrasi secara menyeluruh, sehingga menghambat analisis yang akurat terhadap kebutuhan konsumsi protein hewani dan potensi produksi ternak. Hal ini berdampak pada kurang efektifnya strategi distribusi, peningkatan produksi, dan pengelolaan sumber daya yang tersedia [4]. Oleh karena itu, keberadaan data yang terstruktur dan terintegrasi dapat menjadi solusi utama untuk mendukung penentuan kebijakan yang berkelanjutan dalam bidang peternakan [5].

Data populasi ternak yang dikelola dengan baik memiliki banyak manfaat. Tidak hanya membantu dalam memetakan kebutuhan konsumsi protein hewani berdasarkan wilayah, tetapi juga memungkinkan pemerintah untuk merancang kebijakan distribusi yang lebih efisien [6]. Selain itu, dengan adanya data populasi ternak yang terintegrasi, evaluasi terhadap kebijakan sebelumnya dapat dilakukan secara lebih akurat, sehingga perencanaan untuk masa depan dapat disusun dengan lebih baik. Dalam konteks ini, teknologi berbasis kecerdasan buatan (*artificial intelligence*) menawarkan solusi yang signifikan, khususnya dalam bidang prediksi dan analisis data yang kompleks.

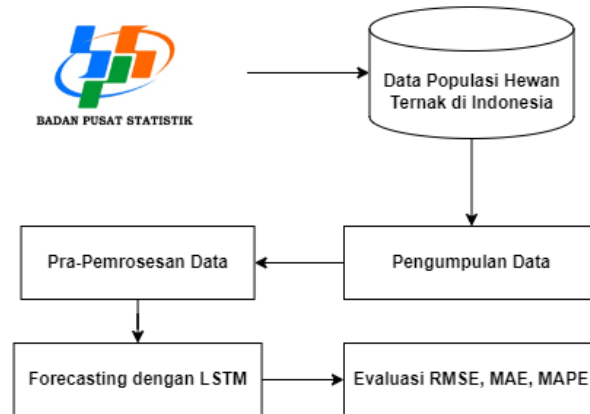
Pendekatan berbasis *Long Short-Term Memory* (LSTM) telah terbukti sebagai salah satu metode yang efektif dalam analisis data deret waktu [7]. LSTM merupakan varian dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi masalah ketergantungan jangka panjang pada data sekuensial [8]. Pada penelitian sebelumnya, metode ini telah berhasil digunakan dalam berbagai bidang. Misalnya, LSTM telah digunakan untuk memprediksi hasil panen berdasarkan data cuaca [9], memperkirakan kebutuhan pangan berdasarkan data historis [10], serta mengestimasi pola distribusi komoditas pertanian [11] serta husbandry [12] lalu ternak di India [13]. Dengan kemampuan untuk menangkap pola temporal dalam data, LSTM menjadi metode yang menjanjikan untuk diterapkan dalam peramalan populasi ternak.

Dalam penelitian ini, data populasi ternak yang diterbitkan oleh BPS digunakan sebagai acuan utama. Penerapan metode LSTM diharapkan dapat membantu dalam memprediksi tren populasi ternak di masa depan berdasarkan data historis populasi per provinsi. Hasil prediksi ini diharapkan mampu memberikan panduan yang lebih baik untuk perencanaan kebijakan di sektor peternakan, seperti penyusunan strategi distribusi ternak, pengelolaan sumber daya pakan, hingga estimasi kebutuhan ekspor dan impor. Selain itu, penelitian ini bertujuan untuk mendukung pengembangan sistem pemetaan populasi ternak yang lebih efisien dan terintegrasi, sehingga mampu memenuhi kebutuhan protein hewani masyarakat secara berkelanjutan. Dengan pendekatan ini, diharapkan kontribusi sektor peternakan terhadap ketahanan pangan nasional dapat ditingkatkan secara signifikan.

2. METODE PENELITIAN

Metode yang digunakan adalah *Recurrent Neural Network* (RNN) dengan pendekatan *Long-Short Term Memory* (LSTM) pada data populasi ternak di Indonesia. Tahapan penelitian dirancang mulai dari

pengumpulan data, preprocessing dataset; pemodelan LSTM; hingga evaluasi kinerja sistem sebagaimana disajikan pada Gambar 1.



Gambar 1. Alur Penelitian


Pengumpulan data

Pengumpulan data dilakukan dengan menghimpun data yang terdapat dari Badan Pusat Statistik. Adapun data populasi ternak yang dihimpun yakni data selama 16 tahun yang dimulai pada tahun 2006 hingga tahun 2022 meliputi data populasi 9 jenis ternak, antara lain: sapi potong, sapi perah, kambing, kerbau, ayam kampung, ayam pedaging, ayam petelur, itik dan babi.

Pre-processing data set

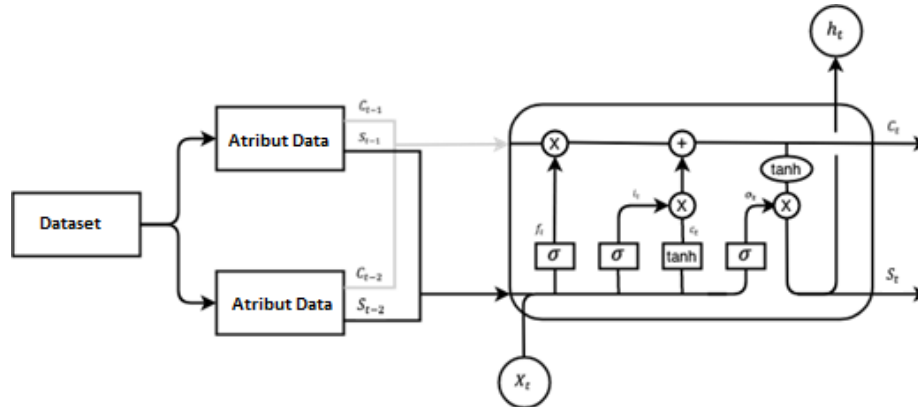
Preprocessing adalah tahapan untuk menghilangkan beberapa permasalahan yang dapat mengganggu pemrosesan pada data sebelum melakukan *Forecasting* dengan model RNN berbasis LSTM. Pada tahap ini terdapat dua proses yang dilakukan, yakni *data cleaning* dan *data selection*. *Data cleaning* merupakan proses pembersihan pada data yang akan dipakai untuk penghapusan data, dan memeriksa inkonsistensi data dan memperbaiki kesalahan pada data. *Data selection* merupakan proses pemilihan data dari sekumpulan data operasional yang ada sebelum masuk ke tahap data maupun informasi. Pada proses ini dilakukan pemilihan atribut atau variable yang akan digunakan dalam *Forecasting*, karena tidak semua atribut akan digunakan. Untuk melakukan *Forecasting*, atribut yang tidak akan terpakai akan dihilangkan.

Pemodelan LSTM



Gambar 2. Arsitektur LSTM

Pemodelan LSTM adalah sebuah pendekatan dalam jaringan saraf yang dirancang khusus untuk menangani masalah sequential data, di mana informasi dari input sebelumnya harus dipertahankan dalam memahami input berikutnya. LSTM adalah sebuah jenis unit memori dalam RNN yang dirancang untuk mengatasi masalah *vanishing gradient* dan *exploding gradient* yang sering terjadi dalam RNN biasa [14]. Secara umum, arsitektur RNN berbasis LSTM disajikan dalam Gambar 2.



Gambar 3. Arsitektur RNN berbasis LSTM untuk *Forecasting* dataset

Gambar 3 menyajikan arsitektur LSTM dalam memodelkan dan meramalkan populasi ternak di Indonesia. Populasi ternak dipengaruhi oleh data deret waktu, di mana populasi pada setiap waktu t akan dipengaruhi oleh populasi pada waktu sebelumnya dan faktor-faktor lainnya, misalnya seperti pertumbuhan, kematian, dan faktor lingkungan. Persamaan umum LSTM [15] untuk *forecasting* populasi ternak:

Forget Gate

Forget Gate bertanggung jawab untuk menentukan seberapa banyak informasi dari sel memori sebelumnya harus dilupakan atau diabaikan dalam memutuskan informasi baru apa yang akan dimasukkan ke dalam memori pada langkah waktu berikutnya. Hal ini memungkinkan model untuk mempertahankan atau mengabaikan informasi yang tidak relevan atau tidak penting dalam konteks prediksi atau pemodelan yang sedang dilakukan. Dirumuskan berdasarkan Persamaan (1).

$$f_t = \sigma(W_f \cdot h_{t-1} + b_f) \quad (1)$$

Input Gate

Input Gate digunakan untuk menentukan seberapa banyak informasi baru yang akan dimasukkan ke dalam sel memori pada waktu saat ini. *Input Gate* memutuskan nilai mana dari kandidat sel memori yang akan diupdate. Ini memungkinkan model untuk menyesuaikan informasi baru dengan lebih baik dengan kondisi saat ini. *Input Gate* dirumuskan dengan Persamaan (2).

$$\begin{aligned} i_t &= \sigma(W_i \cdot h_{t-1} + b_i) \\ \tilde{C}_t &= \tanh(W_C \cdot h_{t-1} + b_C) \end{aligned} \quad (2)$$

Update Cell State

Update Cell State mengacu pada proses memperbarui nilai sel memori berdasarkan informasi dari *Forget Gate* dan *Input Gate*. Ini menggabungkan informasi yang harus diingat dari waktu sebelumnya dengan informasi baru yang dipilih untuk dimasukkan. Ini memungkinkan model untuk menyimpan informasi jangka panjang yang relevan dari berbagai titik dalam sejarah data. Dirumuskan dengan Persamaan (3).

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (3)$$

Output Gate

Output Gate menentukan seberapa banyak informasi dari sel memori saat ini harus disertakan dalam output pada langkah waktu saat ini. Ini memungkinkan model untuk memutuskan informasi mana yang paling relevan

untuk diteruskan ke langkah berikutnya dalam jaringan atau ke output model. Dirumuskan dalam Persamaan (4).

$$\begin{aligned} o_t &= \sigma(W_o \cdot h_{t-1} + b_o) \\ h_t &= o_t \cdot \tanh(C_t) \end{aligned} \tag{4}$$

Dalam Persamaan (4), h_t akan menjadi prediksi populasi ternak pada waktu t .

Pengembangan aplikasi

Pengembangan aplikasi dilakukan menggunakan Bahasa pemrograman python berbasis *web-based*. Pemrograman python dipilih karena menyediakan *library artificial intelligent* untuk digunakan, antara lain: TensorFlow, NumPy, Keras, SciPy, Seaborn, Scikit-learn. *Library-library* tersebut digunakan untuk implementasi RNN berbasis LSTM

Evaluasi kinerja sistem.

Untuk mengevaluasi kinerja *Forecasting*, digunakan *Root Mean Square Error (RMSE)* dan *Mean Absolute Percentage Error (MAPE)*. *Root Mean Square Error (RMSE)* yaitu metode alternatif untuk mengevaluasi teknik peramalan yang digunakan untuk mengukur tingkat akurasi hasil perkiraan suatu model. Nilai yang dihasilkan RMSE merupakan nilai rata – rata kuadrat dari jumlah kesalahan pada model prediksi. *Root Mean Square Error (RMSE)* adalah teknik yang mudah diimplementasikan dan telah sering digunakan dalam berbagai studi yang berkaitan dengan peramalan. RMSE digunakan melalui Persamaan (5).

$$\sqrt{\frac{1}{n} \sum_i^n (\tilde{y}_i - y_i)^2} \tag{5}$$

Keterangan:

\tilde{y}_i = Nilai hasil peramalan

y_i = Nilai aktual / Nilai sebenarnya

n = Jumlah data

Sedangkan, *Mean Absolute Percentage Error (MAPE)* merupakan rata – rata diferensiasi absolut antara nilai peramalan dan aktual, yang dinyatakan sebagai persentase nilai aktual. MAPE digunakan untuk menghitung persentase kesalahan antara nilai aktual dan nilai prediksi. MAPE dihitung menggunakan Persamaan (6).

$$100 \times \frac{1}{n} \sum_{i=1}^n \left| \frac{\tilde{y}_i - y_i}{y_i} \right| \tag{6}$$

Keterangan:

\tilde{y}_i = Nilai hasil peramalan

y_i = Nilai aktual / Nilai sebenarnya

n = Jumlah data

3. HASIL DAN ANALISIS

Dalam penelitian ini, model yang diusulkan diimplementasikan menggunakan bahasa pemrograman Python dan *library* TensorFlow-Keras. Eksperimen dilakukan menggunakan GPU NVIDIA GeForce RTX 3060 dan RAM 32 GB 3600 MHz DDR4. Penelitian mengenai penerapan metode *Recurrent Neural Network (RNN)* dengan pendekatan *Long Short-Term Memory (LSTM)* untuk *Forecasting* populasi ternak di Indonesia

bertujuan untuk memprediksi tren populasi ternak di masa mendatang. LSTM, sebagai salah satu varian dari RNN, memiliki kemampuan yang unggul dalam menangani data berurutan dan mengatasi masalah long-term dependencies, sehingga cocok untuk prediksi berbasis deret waktu seperti populasi ternak. Data populasi ternak yang diambil dari beberapa tahun sebelumnya diolah menggunakan model LSTM untuk menghasilkan prediksi yang lebih akurat. Langkah-langkah melakukan penelitian tentang penerapan metode *Recurrent Neural Network* (RNN) dengan pendekatan *Long Short-Term Memory* (LSTM) untuk *Forecasting* populasi ternak, antar lain:

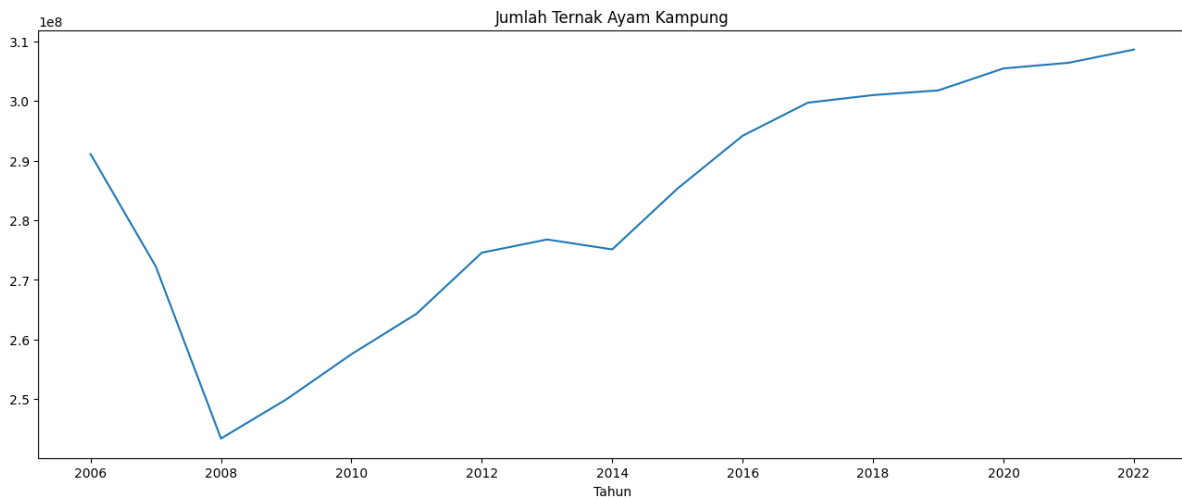
Pengumpulan Dataset

Dataset sebagaimana Gambar 4 berisi informasi historis tentang populasi berbagai jenis hewan ternak dari tahun 2006 hingga 2022. Setiap baris dalam tabel merepresentasikan data untuk satu tahun tertentu, sementara kolom-kolomnya mencakup kategori hewan ternak, seperti sapi potong, sapi perah, kambing, kerbau, ayam kampung, ayam pedaging, ayam petelur, itik, dan babi. Nilai-nilai dalam tabel menunjukkan jumlah populasi masing-masing jenis ternak, yang tampaknya diukur dalam satuan ekor. Secara keseluruhan, dataset ini menggambarkan pola temporal populasi ternak selama 17 tahun, dengan beberapa jenis ternak menunjukkan pertumbuhan yang signifikan, seperti ayam pedaging dan ayam petelur, sementara jenis lainnya, seperti kerbau, menunjukkan populasi yang relatif stabil atau menurun. Dataset ini menyediakan landasan yang kuat untuk analisis tren historis dan prediksi populasi di masa depan menggunakan model LSTM.


Tahun	Sapi Potong	Sapi Perah	Kambing	Kerbau	Ayam Kampung	Ayam Pedaging	Ayam Petelur	Itik	Babi
2006	10875125	369008	13789955	2166606	291085191	797527446	100201556	32480718	6218202
2007	11514871	374067	14470214	2085779	272251141	891659346	111488878	35866833	6710757
2008	12256604	457577	15147432	1930716	243423389	902052418	107955170	39839520	6837528
2009	12759838	474701	15815317	1932927	249963499	1026378580	111417637	40675995	6974732
2010	13581571	488488	16619599	1999604	257544104	986871711	105210062	44301804	7476665
2011	14824373	597213	16946187	1305078	264339634	1177990869	124635794	43487519	7524788
2012	15980696	611940	17905862	1438295	274564427	1244402017	138717751	49295007	7900362
2013	12686239	444266	18500321	1109636	276776576	1344191104	146621514	51355088	7598694
2014	14726875	502516	18639532	1335147	275116120	1443349117	146660415	52682954	7694131
2015	15419719	518649	19012794	1346917	285304304	1528329183	155007388	45321957	7808086
2016	16004097	533933	17847197	1355124	294161691	1632567839	161349806	47424151	7903450
2017	16429102	540441	18208017	1321904	299701400	2922636196	258843681	57557451	8260995
2018	16432945	581522	18306476	894278	300977882	3137707479	261932627	59551713	8254108
2019	16930025	565001	18463115	1133815	301761386	3169805127	263918004	57229088	8520947
2020	17440393	568000	18689711	1154226	305444937	2919516243	345181214	56569977	7622724
2021	17977214	582169	18904347	1143189	306391596	2889207954	386125709	56569983	7178088
2022	17602539	507075	18560835	1088483	308601685	3168325176	378590549	56728470	6748614

Gambar 4. Dataset Populasi Ternak Tahun 2006-2022

Visualisasi Data berperan untuk melihat tren historis populasi ternak. Cara ini dapat melihat pola musiman, tren naik atau turun, atau lonjakan tiba-tiba yang dapat mempengaruhi model prediksi. Jika terdapat pola yang konsisten, model LSTM lebih mudah untuk dilatih karena LSTM dirancang untuk menangani data yang bersifat time series. Setelah model LSTM dibangun, visualisasi data serupa dibuat kembali untuk membandingkan hasil prediksi dengan data historis, hal ini membantu dalam mengevaluasi performa model. Contoh visualisasi data ternak untuk tren ternak ayam kampung disajikan pada Gambar 5.




Gambar 5. Visualisasi Data Jumlah Ternak Ayam Kampung Tahun 2006-2022



Gambar 6. Tren populasi kerbau tiap provinsi dibandingkan dengan rata-rata nasional

Grafik pada Gambar 6 menunjukkan tren populasi kerbau di lima provinsi dengan populasi terbesar di Indonesia, yaitu Aceh, Nusa Tenggara Timur, Sumatera Barat, Sumatera Utara, dan Nusa Tenggara Barat, dibandingkan dengan rata-rata nasional dari tahun 2006 hingga 2022. Garis putus-putus mewakili rata-rata nasional, yang konsisten berada di bawah populasi masing-masing provinsi, menunjukkan bahwa populasi kerbau secara nasional tersebar lebih merata dengan jumlah yang lebih kecil di banyak provinsi lain. Tren populasi di provinsi-provinsi besar ini menunjukkan pola fluktuasi yang signifikan, terutama Aceh, yang mengalami penurunan tajam di awal periode, diikuti oleh penurunan yang lebih stabil setelahnya. Nusa Tenggara Timur menunjukkan peningkatan yang stabil sejak tahun 2016, sedangkan Sumatera Barat, Sumatera Utara, dan Nusa Tenggara Barat cenderung menunjukkan pola fluktuasi yang serupa tanpa perubahan drastis. Grafik ini memberikan wawasan tentang bagaimana tren populasi di tingkat provinsi berkontribusi terhadap rata-rata nasional, sekaligus menyoroti pola-pola unik di setiap wilayah.

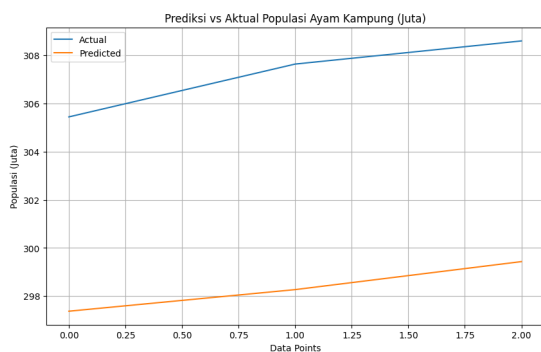


Gambar 7. Populasi sapi potong secara nasional

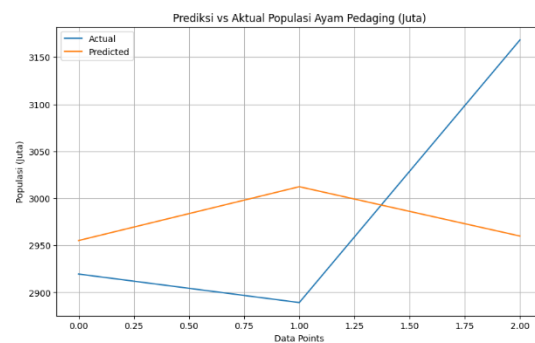
Diagram pada Gambar 7 menunjukkan jumlah populasi sapi potong secara nasional dari tahun 2006 hingga 2022, yang digunakan sebagai acuan untuk melakukan *forecasting* populasi ternak di masa depan. Data historis ini memperlihatkan tren populasi sapi potong yang mengalami peningkatan signifikan dari tahun 2006 hingga 2012, diikuti oleh penurunan tajam pada tahun 2014, dan kemudian kembali meningkat secara stabil hingga mencapai puncaknya pada tahun 2021 sebelum sedikit menurun pada tahun 2022. Pendekatan *forecasting* ini didasarkan pada total jumlah nasional untuk setiap jenis ternak, seperti yang terlihat pada diagram ini, sehingga memberikan gambaran yang holistik tentang perubahan populasi dari waktu ke waktu. Dengan menggunakan data nasional ini, model dapat mempelajari pola historis yang lebih representatif dan membuat prediksi yang lebih akurat mengenai tren populasi ternak di masa depan.

Forecasting Populasi Ternak dengan LSTM

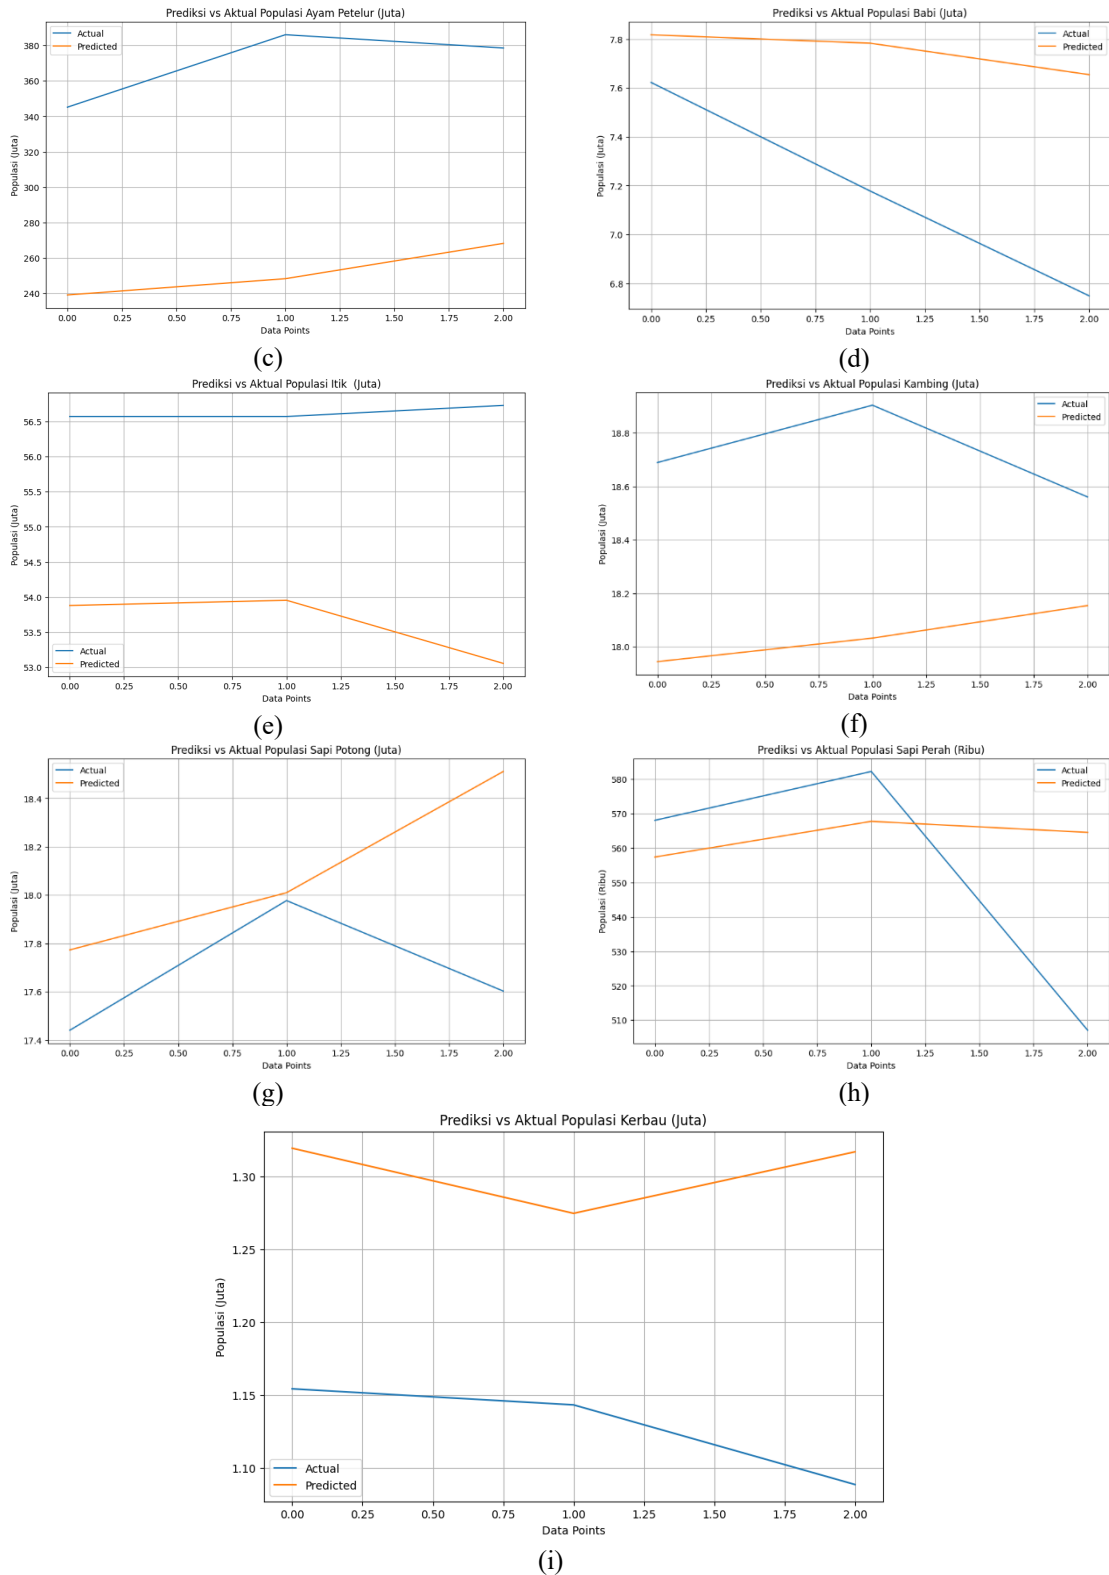
Penerapan *Long Short-Term Memory* (LSTM) dilakukan untuk menganalisis dan memprediksi populasi ternak nasional berdasarkan data historis yang diambil dari dataset. Prosesnya dimulai dengan memuat dan memproses setiap sheet data, di mana populasi dari berbagai provinsi dijumlahkan untuk mendapatkan total populasi secara nasional. Data ini kemudian diskalakan menggunakan Min-Max Scaling ke rentang [0, 1], sehingga lebih cocok untuk digunakan oleh model LSTM. Model LSTM dirancang untuk menangkap pola temporal dari data, dengan mempertimbangkan hubungan antar tahun dalam urutan tertentu. LSTM digunakan karena kemampuannya untuk menangani urutan data dengan memori jangka panjang dan pendek, yang penting untuk memahami tren populasi dari tahun ke tahun. Input model diatur dalam bentuk sequence yang digunakan untuk memprediksi populasi tahun berikutnya. Model LSTM ini memiliki dua lapisan LSTM dengan 50 unit masing-masing dan satu lapisan dense untuk menghasilkan prediksi akhir. Aktivasi "relu" memastikan model dapat menangkap pola non-linear dalam data.



(a)




(b)




Gambar 8. Prediksi LSTM dibandingkan dengan data aktual untuk populasi tiap hewan ternak

Grafik (a) hingga (i) pada Gambar 8 ini menunjukkan hasil penerapan LSTM untuk memprediksi populasi berbagai jenis ternak. Grafik ini membandingkan data aktual (berbasis observasi atau historis) dengan prediksi yang dihasilkan oleh model LSTM pada data uji. Secara keseluruhan, terdapat kesenjangan yang bervariasi antara kurva "Actual" dan "Predicted" untuk masing-masing ternak, yang menunjukkan seberapa baik LSTM berhasil memahami pola data historis. Kinerja model dapat dievaluasi dari keselarasan antara kurva aktual dan prediksi, di mana grafik yang lebih dekat menunjukkan performa yang lebih baik.

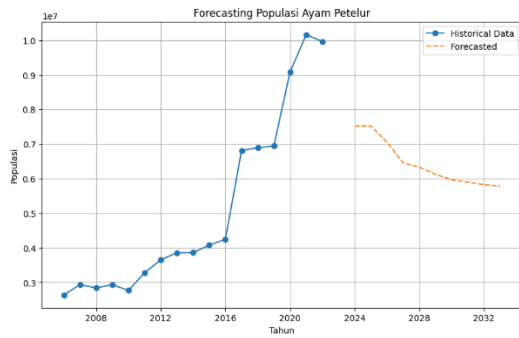
Model LSTM menunjukkan variasi akurasi yang signifikan dalam memprediksi populasi berbagai jenis ternak. Untuk ayam kampung, model gagal mengikuti tren kenaikan populasi secara akurat, dengan hasil prediksi yang jauh lebih rendah dibandingkan data aktual. Pada ayam pedaging, prediksi LSTM stabil meskipun data aktual menunjukkan fluktuasi tajam, mengindikasikan kurangnya kemampuan model menangkap perubahan besar. Ayam petelur mengalami hasil prediksi yang terlalu linier dibandingkan pola kenaikan melandai yang terlihat dalam data aktual. Untuk babi, prediksi model tidak mencerminkan penurunan tajam dalam data historis, menghasilkan tren yang lebih ringan. Populasi itik yang stabil dengan sedikit kenaikan tidak sepenuhnya ditangkap oleh model, yang justru memprediksi tren menurun. Pada kambing, data aktual menunjukkan fluktuasi tajam yang tidak dapat diikuti oleh model, yang cenderung memberikan pola peningkatan konsisten. Untuk kerbau, yang memiliki tren menurun, model menghasilkan prediksi yang lebih stabil dengan sedikit peningkatan, menunjukkan kesulitan dalam menangkap penurunan tajam. Sapi perah menunjukkan pola yang kompleks dengan peningkatan tajam dan penurunan berikutnya, tetapi model memberikan hasil prediksi yang datar, kurang mencerminkan perubahan drastis. Pada sapi potong, model memberikan prediksi yang stabil dan meningkat, sementara data aktual menunjukkan fluktuasi yang lebih dinamis. Secara keseluruhan, model LSTM lebih cocok untuk menangani pola yang stabil atau linier, tetapi kurang efektif dalam menangkap fluktuasi atau perubahan kompleks. Hal ini menunjukkan perlunya peningkatan model melalui penyesuaian *hyperparameter* atau penggunaan dataset yang lebih besar dan beragam untuk melatih model.




(a)



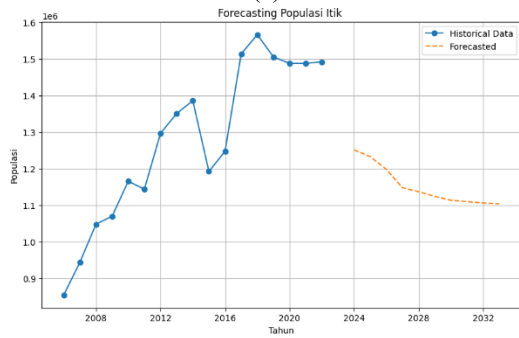
(b)



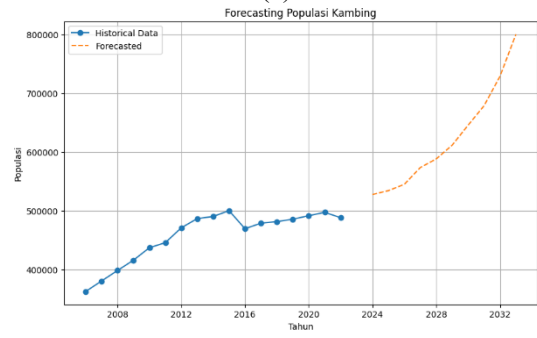
(c)



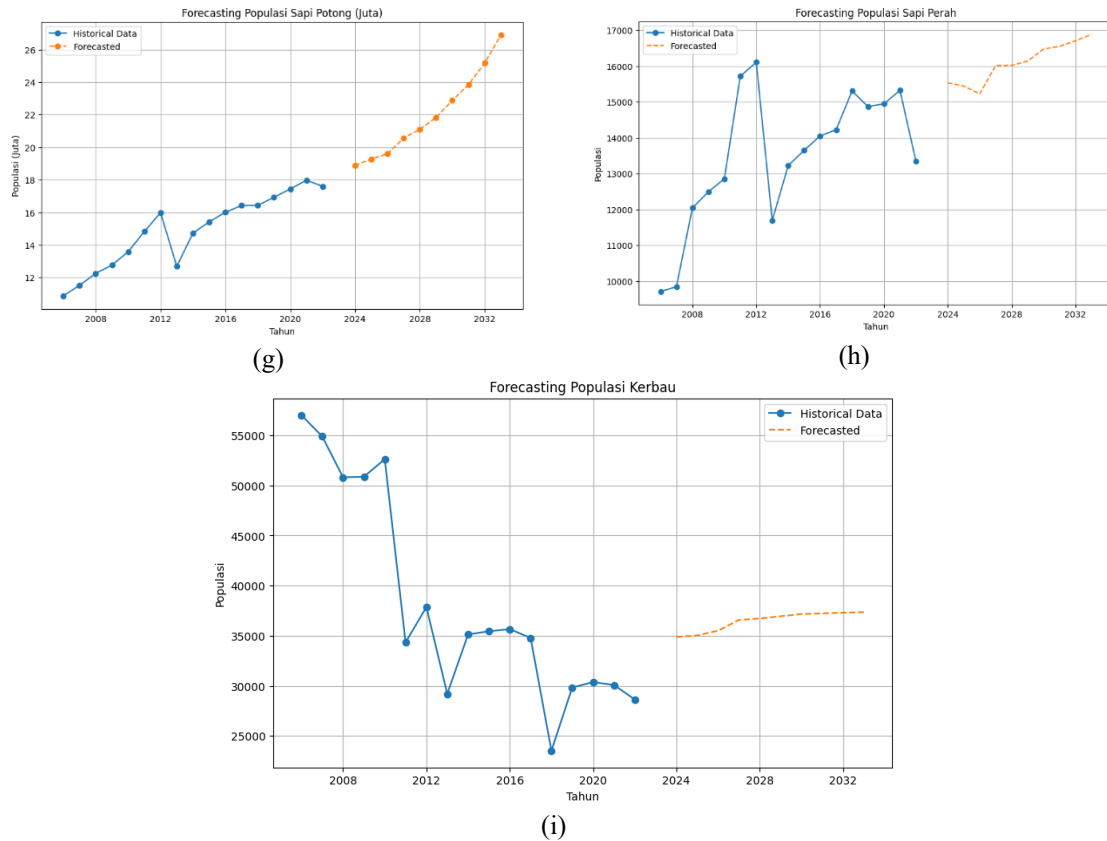
(d)



(e)



(f)



Gambar 9. Hasil forecasting populasi tiap hewan

Grafik (a) hingga (i) pada Gambar 9 menunjukkan hasil penerapan model LSTM untuk memprediksi populasi hewan ternak berdasarkan data historis hingga tahun tertentu, dengan peramalan untuk sekitar 10 tahun ke depan. Secara umum, grafik-grafik ini menggambarkan bagaimana model menangkap tren historis, baik yang menunjukkan peningkatan, penurunan, atau fluktuasi, kemudian melanjutkan pola tersebut dalam bentuk prediksi. Namun, perbedaan antara data historis dan prediksi di masa depan menunjukkan bahwa model LSTM mungkin tidak sepenuhnya akurat dalam menangkap pola tertentu, terutama jika data memiliki fluktuasi besar atau perubahan drastis.

Analisis spesifik pada tiap jenis hewan menunjukkan bahwa model LSTM memiliki keterbatasan dalam menangkap pola historis yang kompleks dan fluktuatif. Untuk ayam kampung, meskipun tren historis menunjukkan peningkatan stabil setelah penurunan tajam, prediksi masa depan justru menunjukkan penurunan populasi, menandakan kurangnya kemampuan model dalam memahami tren positif tersebut. Pada ayam pedaging, model memprediksi penurunan bertahap meskipun data historis menunjukkan peningkatan tajam diikuti fluktuasi kecil, yang mengindikasikan bias terhadap pola menurun. Hal serupa terlihat pada ayam petelur, di mana tren kenaikan tajam diikuti fluktuasi diabaikan oleh model yang malah memprediksi penurunan perlahan. Untuk babi, meskipun data historis menunjukkan peningkatan dan penurunan signifikan, model hanya memprediksi sedikit kenaikan populasi yang tidak mencerminkan pola penurunan tajam sebelumnya. Pada itik, populasi stabil dengan sedikit kenaikan dalam data historis justru diprediksi menurun secara perlahan oleh model. Populasi kambing yang stabil setelah peningkatan awal diprediksi mengalami kenaikan signifikan, yang tampak terlalu optimis. Tren menurun populasi kerbau dalam data historis diprediksi stabil hingga sedikit meningkat, menunjukkan ketidaksesuaian antara prediksi dan tren historis. Untuk sapi potong, tren peningkatan stabil dengan sedikit penurunan pada akhir data diprediksi meningkat secara signifikan, yang mungkin mencerminkan optimisme model. Sementara itu, sapi perah dengan pola fluktuasi signifikan diprediksi mengalami peningkatan perlahan, mengabaikan dinamika kompleks pada data historis. Secara keseluruhan, model LSTM cenderung memberikan prediksi yang lebih halus dan linier, yang kurang mencerminkan pola fluktuasi tajam atau perubahan kompleks pada data historis. Hal ini menunjukkan kebutuhan untuk penyesuaian parameter model atau perbaikan data historis agar menghasilkan prediksi yang lebih akurat dan realistis.

Evaluasi Forecasting

<input type="checkbox"/>	Hewan	RMSE	MAE	MAPE (%)
1	Sapi Potong	27342.104	26312.66	5.644
2	Sapi Perah	13767.62	10676.15	7.734
3	Kambing	27646.56	26921.33	5.474
4	Kerbau	49973.25	48937.76	16.567
5	Ayam Kampung	738062.1	737772.66	9.124
6	Ayam Pedaging	1170028.07	1111696.07	13.954
7	Ayam Petelur	3278556.06	3257610.06	13.387
8	Itik	2243584.45	2214158.05	15.043
9	Babi	2606380.0	2504922.06	13.472

Gambar 10. Hasil evaluasi RMSE, MAE dan MAPE untuk tiap hewan ternak

Gambar 10 menunjukkan evaluasi model LSTM dalam memprediksi populasi ternak utama di Indonesia, yang berkontribusi langsung terhadap ketahanan pangan nasional melalui pemenuhan kebutuhan protein hewani. Sapi Potong sebagai salah satu sumber utama daging merah menunjukkan performa prediksi yang cukup baik, dengan RMSE sebesar 27,342.10 dan MAPE sebesar 5.64%, yang mengindikasikan bahwa populasi sapi potong memiliki pola pertumbuhan yang relatif stabil. Hal ini penting untuk memastikan pasokan daging merah yang memadai dalam mendukung kebutuhan protein masyarakat. Sapi Perah, yang menjadi sumber utama susu sebagai protein hewani cair, memiliki tingkat kesalahan prediksi yang sedikit lebih tinggi dengan MAPE sebesar 7.73%, tetapi masih dalam batas akurasi yang baik, sehingga model ini dapat digunakan untuk merencanakan produksi susu nasional secara lebih strategis.

Kambing, dengan MAPE terendah sebesar 5.47%, menunjukkan pola populasi yang konsisten dan mudah diprediksi, mendukung pasokan daging kambing sebagai salah satu sumber protein hewani alternatif. Sebaliknya, Kerbau memiliki tingkat kesalahan tertinggi dengan MAPE sebesar 16.57%, yang menunjukkan bahwa populasi kerbau lebih sulit diprediksi. Hal ini dapat berdampak pada pasokan daging kerbau yang menjadi alternatif penting, terutama di wilayah tertentu yang mengandalkan kerbau sebagai sumber utama protein hewani.

Di sektor unggas, Ayam Kampung menunjukkan hasil yang cukup baik dengan MAPE sebesar 9.12%, mendukung kestabilan pasokan daging ayam kampung yang sangat digemari masyarakat. Namun, Ayam Pedaging dan Ayam Petelur, yang merupakan tulang punggung utama dalam penyediaan daging ayam dan telur, memiliki tingkat kesalahan prediksi yang lebih tinggi dengan MAPE masing-masing sebesar 13.95% dan 13.39%. Variasi dalam populasi unggas ini mungkin disebabkan oleh faktor pasar dan kebijakan produksi, yang memengaruhi kapasitas model untuk memberikan prediksi yang lebih akurat. Itik, dengan MAPE sebesar 15.04%, juga menunjukkan tantangan dalam prediksi populasi, meskipun daging itik dan telur asin merupakan sumber protein yang signifikan di beberapa daerah. Sementara itu, Babi, yang menjadi sumber protein penting di wilayah tertentu, memiliki MAPE sebesar 13.47%, mencerminkan fluktuasi populasi yang juga dipengaruhi oleh permintaan pasar dan kondisi sosial-ekonomi. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa model LSTM dapat menjadi alat yang efektif untuk mendukung perencanaan strategis dalam pemenuhan kebutuhan protein hewani di Indonesia. Dengan akurasi yang baik pada ternak seperti sapi, kambing, dan ayam kampung, model ini dapat membantu pemerintah dan pemangku kepentingan dalam memastikan ketersediaan protein hewani yang stabil dan memadai. Namun, untuk ternak dengan MAPE lebih

tinggi seperti kerbau, ayam pedaging, dan itik, diperlukan data tambahan dan pendekatan yang lebih holistik untuk meningkatkan akurasi prediksi, sehingga dapat lebih mendukung ketahanan pangan nasional.

4. KESIMPULAN

Penelitian ini mengevaluasi model LSTM untuk memprediksi populasi ternak utama di Indonesia, yang mendukung ketahanan pangan nasional melalui pemenuhan kebutuhan protein hewani. Hasil penelitian menunjukkan bahwa model LSTM memiliki akurasi yang baik untuk ternak dengan pola populasi stabil, seperti Sapi Potong, Sapi Perah, dan Kambing, dengan MAPE masing-masing sebesar 5.64%, 7.73%, dan 5.47%. Hal ini menunjukkan bahwa model mampu menangkap tren pertumbuhan populasi ternak yang signifikan sebagai sumber utama daging merah, susu, dan protein alternatif. Namun, tingkat kesalahan prediksi lebih tinggi pada ternak seperti Kerbau, Ayam Pedaging, dan Itik, dengan MAPE masing-masing sebesar 16.57%, 13.95%, dan 15.04%. Fluktuasi dalam data populasi ini kemungkinan dipengaruhi oleh faktor pasar, kebijakan, dan variasi musiman, sehingga memerlukan pendekatan tambahan untuk meningkatkan akurasi prediksi. Kesimpulannya, model LSTM adalah alat yang efektif untuk perencanaan strategis dalam pemenuhan kebutuhan protein hewani, terutama untuk jenis ternak dengan pola populasi yang konsisten. Namun, penelitian lebih lanjut diperlukan untuk memperbaiki prediksi pada ternak dengan pola populasi yang lebih kompleks. Hasil ini memberikan wawasan bagi pemerintah dan pemangku kepentingan untuk memastikan pasokan protein hewani yang stabil guna mendukung ketahanan pangan nasional.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia serta Universitas Nahdlatul Ulama Blitar yang telah mendukung pendanaan untuk penelitian ini.

REFERENSI

- [1] A. A. H. Tobong and A. Zubair, "Analisa Perbandingan Metode Peramalan Jumlah Populasi Sapi di Wilayah Nusa Tenggara Timur," *Semin. Nas. Sist. Inf.*, vol. 6, no. September, pp. 3282–3292, 2022.
- [2] N. Rahmi, M. Ridwan, and S. Nurlaelah, "Proyeksi populasi ternak sapi potong di Kabupaten Bone dalam pencapaian target RPJMD Kabupaten Bone," *J. Agrisistem*, vol. 13, no. 2, pp. 101–108, 2017.
- [3] Y. Yurike, "Forecasting Produksi dan Analisis Trend Harga Daging Ayam Broiler di Provinsi Bengkulu," *Bul. Peternak. Trop.*, vol. 4, no. 1, pp. 18–25, 2023, doi: 10.31186/bpt.4.1.18-25.
- [4] F. Zuhdi, Y. Zurriyati, and E. Novriandeni, "Peramalan Populasi Sapi di Provinsi Riau dan Indonesia Menggunakan Pendekatan ARIMA (Autoregressive Integrated Moving Average)," *J. Peternak.*, vol. 18, no. 2, p. 87, 2021, doi: 10.24014/jupet.v18i2.11558.
- [5] D. Julia, S. Siregar, and S. Setyaningrum, "Analisis Forecasting Ketersediaan Dan Konsumsi Daging Sapi 2025 Di Sumatera Utara (Prediction analysis of production and consumption of beef in North Sumatra 2025)," *Semin. Nas. LPPM Univ. Jambi Tahun 2015*, pp. 293–300, 2025.
- [6] G. A. Ryu, T. Chuluunsaikhan, A. Nasridinov, H. C. Rah, and K. H. Yoo, "SCE-LSTM: Sparse Critical Event-Driven LSTM Model with Selective Memorization for Agricultural Time-Series Prediction," *Agric.*, vol. 13, no. 11, 2023, doi: 10.3390/agriculture13112044.
- [7] D. O. Sunday, "Application of Long Short-Term Memory (LSTM) in Stock Price Prediction," *Int. J. Dev. Econ. Sustain.*, vol. 12, no. 3, pp. 36–45, 2024, doi: 10.37745/ijdes.13/vol12n33645.
- [8] T. W. Yoo and I. S. Oh, "Time series forecasting of agricultural products' sales volumes based on seasonal Long Short-Term Memory," *Appl. Sci.*, vol. 10, no. 22, pp. 1–15, 2020, doi: 10.3390/app10228169.
- [9] A. W. Saputra, A. P. Wibawa, U. Pujiyanto, A. B. Putra Utama, and A. Nafalski, "LSTM-based Multivariate Time-Series Analysis: A Case of Journal Visitors Forecasting," *Ilk. J. Ilm.*, vol. 14, no. 1, pp. 57–62, 2022, doi: 10.33096/ilkom.v14i1.1106.57-62.
- [10] J. G. Kim, S. Y. Lee, and I. B. Lee, "The Development of an LSTM Model to Predict Time Series Missing Data of Air Temperature inside Fattening Pig Houses," *Agric.*, vol. 13, no. 4, pp. 1–18, 2023, doi: 10.3390/agriculture13040795.
- [11] K. Albeladi, B. Zafar, and A. Mueen, "Time Series Forecasting using LSTM and ARIMA," *Int. J. Adv.*

- Comput. Sci. Appl.*, vol. 14, no. 1, pp. 313–320, 2023, doi: 10.14569/IJACSA.2023.0140133.
- [12] A. Kulyk, K. Fokina-Mezentseva, O. Piankova, L. Sierova, and M. Slokva, “Forecasting husbandry development using time series,” *Sci. Horizons*, vol. 26, no. 11, pp. 166–174, 2023, doi: 10.48077/scihor11.2023.166.
- [13] A. S. Nair, M. Thirunavukkarasu, A. Serma Saravana Pandian, G. Senthilkumar, and C. Balan, “Forecasting cattle and buffalo population in India – A time series analysis,” *Indian J. Dairy Sci.*, vol. 73, no. 3, pp. 268–273, 2020, doi: 10.33785/ijds.2020.v73i03.013.
- [14] R. Prater, T. Hanne, and R. Dornberger, “Generalized Performance of LSTM in Time-Series Forecasting,” *Appl. Artif. Intell.*, vol. 38, no. 1, 2024, doi: 10.1080/08839514.2024.2377510.
- [15] Stavelin Abhinandithe K, Madhu B, Somanathan Balasubramanian, and Sridhar Ramachandran, “Forecasting Multivariate time-series data using LSTM Neural Network in Mysore district, Karnataka,” *Indian J. Public Heal. Res. Dev.*, vol. 13, no. 4, pp. 284–289, 2022, doi: 10.37506/ijphrd.v14i4.18631.