



Integration of a Long Short-Term Memory (LSTM)-Based Neural Network Model into a Smart Aquaponics System for Optimizing Catfish Feeding (Clarias gariepinus)

Integrasi Model Neural Network Berbasis Long Short-Term Memory (LSTM) Pada Sistem Smart Akuaponik Untuk Optimasi Pemberian Pakan Ikan Lele (Clarias Gariepinus)

Faqihuddin Arrasyid^{1*}, Hendra², Amrizal³

^{1,2,3}Program Studi Teknologi Rekayasa Komputer, Politeknik Pertanian Negeri Payakumbuh, Indonesia
E-mail: faqihuddin68@gmail.com^{1*}, amrizal.ch@gmail.com², hendra.bgd@gmail.com³

Abstract

Feeding is one of the key factors determining the success of catfish farming, as it directly affects fish growth, feed utilization efficiency, and the quality of the culture environment. This study aims to develop a Long Short-Term Memory (LSTM)-based feed requirement prediction model integrated into an Internet of Things (IoT)-based smart aquaponics system. The study adopts the CRISP-DM methodology, which consists of the stages of business understanding, data understanding, data preparation, modeling, evaluation, and implementation. Two models were developed: GrowthLSTM, which predicts the average fish weight, and PakanLSTM, which predicts feed requirements based on fish age, the number of fish, and the predicted fish weight. The evaluation results show that GrowthLSTM achieved an MAE of 2.3959 g, an RMSE of 3.4898 g, a MAPE of 3.19%, and an R^2 of 0.9962, while PakanLSTM achieved an MAE of 1.1034 g, an RMSE of 3.1447 g, a MAPE of 20.57%, and an R^2 of 0.9674. Both models were successfully integrated with an ESP32 through a REST API, enabling the system to perform automated feed prediction and dispensing to support more adaptive and efficient catfish farming.

Article Information

Article History:

Received: 18/07/2026
First Revised: 26/08/2026
Accepted: 27/09/2026
Publication Date: 29/09/2026

Keywords:

Internet of Things (IoT), Long Short-Term Memory (LSTM), Feed Prediction, Smart Aquaponics, Time Series



Copyright (c) 2026 Faqihuddin Arrasyid, Hendra, Amrizal

Abstrak

Pemberian pakan merupakan salah satu faktor utama yang menentukan keberhasilan budidaya ikan lele karena berpengaruh langsung terhadap pertumbuhan ikan, efisiensi penggunaan pakan, dan kualitas media budidaya. Penelitian ini bertujuan mengembangkan model prediksi kebutuhan pakan berbasis *Long Short-Term Memory* (LSTM) yang terintegrasi dengan sistem smart aquaponic berbasis *Internet of Things* (IoT). Penelitian menggunakan metodologi CRISP-DM yang meliputi tahapan *bussiness understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *implementation*. Dua buah model dikembangkan, yaitu GrowthLSTM untuk memprediksi berat rata-rata ikan dan PakanLSTM untuk memprediksi kebutuhan pakan berdasarkan umur ikan, jumlah ikan, dan hasil prediksi berat ikan. Hasil evaluasi menunjukkan bahwa GrowthLSTM memperoleh MAE sebesar 2,3959 g, RMSE 3,4898 g, MAPE 3,19%, dan R^2 0,9962, sedangkan PakanLSTM memperoleh MAE 1,1034 g, RMSE 3,1447 g, MAPE 20,57%, dan R^2 0,9674. Kedua model berhasil diintegrasikan dengan ESP32 melalui layanan REST API, sehingga sistem mampu melakukan prediksi dan pemberian pakan secara otomatis untuk mendukung budidaya ikan lele yang lebih adaptif dan efisien.



Copyright (c) 2026 Faqihuddin Arrasyid, Hendra, Amrizal

Artikel Info

Riwayat Artikel:

Diterima: 18/07/2026

Direvisi: 26/08/2026

Disetujui: 27/09/2026

Dipublikasikan: 29/09/2026

Kata Kunci:

Internet of Things, Long Short-Term Memory, Prediksi Pakan, Smart Aquaponic, Time Series

1. Pendahuluan

Budidaya ikan lele (*Clarias gariepinus*) merupakan salah satu sektor akuakultur yang memiliki peran penting dalam mendukung ketahanan pangan serta peningkatan ekonomi masyarakat. Seiring berkembangnya konsep pertanian berkelanjutan, sistem akuaponik menjadi salah satu inovasi budidaya yang mengintegrasikan akuakultur dan hidroponik dalam satu ekosistem yang saling mendukung. Pada sistem ini, limbah metabolisme ikan dimanfaatkan sebagai sumber nutrisi bagi tanaman, sedangkan tanaman berperan menjaga kualitas air sehingga penggunaan air menjadi lebih efisien dan produktivitas budidaya dapat ditingkatkan (Shobihah *et al.*, 2022). Pendekatan tersebut juga mendukung pemanfaatan sumber daya secara lebih efektif sehingga menjadi salah satu solusi budidaya yang ramah lingkungan (Kadarini *et al.*, 2022).

Di dalam sistem budidaya tersebut, pemberian pakan merupakan faktor yang sangat menentukan keberhasilan produksi. Pakan menjadi komponen biaya operasional terbesar sehingga ketepatan dalam menentukan jumlah pakan berpengaruh langsung terhadap efisiensi budidaya (Assan *et al.*, 2021). Dalam praktik budidaya, kebutuhan pakan ditentukan berdasarkan biomassa ikan yang dipengaruhi oleh umur ikan, berat rata-rata ikan, dan jumlah ikan dalam kolam (Mahendra *et al.*, 2022). Ketidaktepatan dalam menentukan kebutuhan pakan dapat menyebabkan *overfeeding* maupun *underfeeding*, yang berdampak pada meningkatnya nilai *Feed Conversion Ratio* (FCR), penurunan kualitas air, serta terhambatnya pertumbuhan ikan (Fitriyanto *et al.*, 2020). Selain itu, kepadatan populasi ikan turut memengaruhi tingkat kompetisi dalam memperoleh pakan sehingga kebutuhan pakan setiap populasi dapat berbeda meskipun berada pada fase pertumbuhan yang sama (Kurniaji *et al.*, 2021). Kondisi tersebut menunjukkan bahwa penentuan kebutuhan pakan tidak dapat dilakukan hanya berdasarkan tabel pemberian pakan secara umum, tetapi perlu mempertimbangkan karakteristik biologis ikan yang berubah selama masa pemeliharaan.

Perkembangan *Artificial Intelligence* (AI) telah membuka peluang baru dalam pengembangan sistem pendukung keputusan pada sektor akuakultur. Salah satu pendekatan yang banyak digunakan adalah *Artificial Neural Network* karena mampu memodelkan hubungan nonlinier antarvariabel melalui proses pembelajaran berbasis data (Riani *et al.*, 2021). Untuk data yang memiliki karakteristik deret waktu (*time-series*), arsitektur *Long Short-Term Memory* (LSTM) menjadi salah satu metode *deep learning* yang banyak digunakan karena mampu mempertahankan informasi historis dalam jangka panjang sehingga menghasilkan performa prediksi yang lebih baik dibandingkan arsitektur *Recurrent Neural Network* konvensional (Alkahfi *et al.*, 2024). Kemampuan tersebut menjadikan LSTM sesuai untuk memodelkan perubahan kebutuhan pakan yang dipengaruhi oleh dinamika pertumbuhan ikan sepanjang siklus budidaya (Cahyani *et al.*, 2023).

Beberapa penelitian telah menerapkan pendekatan kecerdasan buatan pada bidang akuakultur. Adriono *et al.* (2022) mengembangkan model prediksi jumlah pakan pada budidaya udang menggunakan jaringan saraf tiruan dan menunjukkan bahwa pendekatan berbasis AI mampu meningkatkan ketepatan estimasi kebutuhan pakan. Son & Jeong (2024) mengembangkan sistem pemberian pakan otomatis menggunakan kombinasi *Convolutional Neural Network* (CNN) dan *Gated Recurrent Unit* (GRU) untuk mendeteksi perilaku makan ikan secara otomatis. Pramana *et al.* (2025) menerapkan *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dalam menentukan intensitas makan ikan pada sistem akuaponik. Selain itu, Sitompul *et al.* (2025) menunjukkan bahwa arsitektur LSTM memiliki kemampuan yang baik dalam mempelajari pola temporal sehingga menghasilkan performa prediksi yang tinggi pada data deret waktu.

Meskipun demikian, penelitian-penelitian tersebut masih memiliki beberapa keterbatasan. Penelitian Adriono *et al.* (2022) berfokus pada estimasi jumlah pakan tanpa memanfaatkan hubungan temporal antarparameter biologis ikan. Penelitian Son & Jeong (2024) lebih menitikberatkan pada otomatisasi proses pemberian pakan melalui analisis perilaku makan dibandingkan pengembangan model prediksi kebutuhan pakan. Sementara itu, penelitian Pramana *et al.* (2025) menggunakan ANFIS untuk mengidentifikasi intensitas makan ikan, namun belum memanfaatkan kombinasi umur ikan, jumlah ikan, dan berat rata-rata ikan sebagai variabel utama dalam memprediksi kebutuhan pakan. Dengan demikian, masih terdapat *research gap* berupa belum tersedianya model prediksi berbasis LSTM yang secara khusus memanfaatkan parameter biologis ikan secara multivariat untuk menghasilkan estimasi kebutuhan pakan yang adaptif pada sistem budidaya ikan lele.

Berdasarkan *research gap* tersebut, penelitian ini menawarkan kebaruan (*novelty*) berupa pengembangan model prediksi kebutuhan pakan ikan lele menggunakan algoritma *Long Short-Term Memory* (LSTM) dengan tiga variabel biologis utama, yaitu umur ikan, jumlah ikan, dan berat rata-rata ikan. Ketiga variabel tersebut dipilih karena secara langsung merepresentasikan kondisi biomassa ikan yang menjadi dasar dalam penentuan kebutuhan pakan. Model yang dikembangkan dirancang untuk mempelajari hubungan temporal antarvariabel sehingga mampu menghasilkan estimasi kebutuhan pakan yang lebih adaptif dibandingkan pendekatan konvensional. Selain itu, model diintegrasikan ke dalam sistem smart aquaponik sebagai modul pendukung pengambilan keputusan sehingga hasil prediksi dapat dimanfaatkan sebagai dasar penentuan takaran pakan secara otomatis.

Penelitian ini bertujuan mengembangkan model prediksi kebutuhan pakan ikan lele menggunakan algoritma *Long Short-Term Memory* (LSTM), mengevaluasi kinerja model berdasarkan metrik evaluasi regresi, serta mengintegrasikan model ke dalam sistem smart aquaponic sebagai pendukung pengambilan keputusan pemberian pakan yang lebih adaptif, efisien, dan berbasis data.

2. Metodologi

Penelitian ini menggunakan metode penelitian eksperimental dengan pendekatan *Cross Industry Standard Process for Data Mining* (CRISP-DM). CRISP-DM merupakan metodologi standar yang banyak digunakan dalam penelitian berbasis data mining dan kecerdasan buatan


karena menyediakan tahapan kerja yang sistematis dan terstruktur, mulai dari pemahaman permasalahan hingga implementasi model. Metode ini dipilih karena penelitian berfokus pada pengembangan dan evaluasi model prediksi berbasis *Neural Network* dengan arsitektur *Long Short-Term Memory* (LSTM) yang memanfaatkan data deret waktu (*time-series*) untuk mengestimasi kebutuhan pakan ikan lele (*Clarias gariepinus*) pada sistem smart akuaponik. Penggunaan CRISP-DM memungkinkan setiap tahapan penelitian dilakukan secara terkontrol, terukur, dan dapat dipertanggungjawabkan secara ilmiah (Hasanah *et al.*, 2021).

2.1 Waktu dan Lokasi Penelitian

Penelitian ini dilaksanakan pada periode Januari hingga Juni 2026 di Program Studi Teknologi Rekayasa Komputer, Politeknik Pertanian Negeri Payakumbuh. Penelitian menggunakan pendekatan eksperimen komputasional yang meliputi pembangunan dataset, prapemrosesan data, pengembangan model *Long Short-Term Memory* (LSTM), evaluasi model, serta implementasi model pada sistem smart akuaponik berbasis *Internet of Things* (IoT). Seluruh tahapan penelitian dilakukan menggunakan lingkungan komputasi berbasis Python dan diimplementasikan pada prototipe sistem IoT untuk menguji penerapan model dalam proses prediksi kebutuhan pakan ikan lele.

2.2 Alur Penelitian

Metode penelitian CRISP-DM terdiri dari beberapa tahapan, diantaranya *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Tahapan penelitian menggunakan metode ini digambarkan dalam bentuk flowchart yang diawali dengan simbol Mulai dan diakhiri dengan simbol selesai. Flowchart dari tahapan penelitian ini dapat dilihat pada gambar berikut:



Gambar 1. Flowchart Tahapan Penelitian

1. Mulai

Tahap awal dari proses penelitian.

2. *Bussiness Understanding*

Tahap *Business Understanding* bertujuan mengidentifikasi permasalahan utama dalam budidaya ikan lele yang berkaitan dengan penentuan kebutuhan pakan. Pada praktik budidaya, pemberian pakan umumnya masih dilakukan berdasarkan pengalaman pembudidaya atau tabel *feeding rate* yang bersifat umum sehingga belum mampu menyesuaikan perubahan biomassa ikan selama masa pemeliharaan. Kondisi tersebut berpotensi menyebabkan overfeeding maupun underfeeding yang berdampak pada efisiensi penggunaan pakan dan kualitas media budidaya.

Berdasarkan permasalahan tersebut, penelitian ini menetapkan tujuan untuk mengembangkan sistem prediksi pertumbuhan berat dan kebutuhan pakan menggunakan algoritma LSTM. Model yang dikembangkan diharapkan mampu memberikan rekomendasi kebutuhan pakan berdasarkan karakteristik biologis ikan serta dapat diimplementasikan pada sistem smart aquaponic berbasis IoT.

3. *Data Understanding*

Tahap *Data Understanding* dilakukan untuk memahami karakteristik data yang digunakan sebagai dasar pengembangan model. Penelitian ini menggunakan dua dataset simulasi yang dikembangkan berdasarkan referensi biologis pertumbuhan ikan lele dan kebutuhan pakan pada setiap fase pemeliharaan. Dataset pertama digunakan untuk membangun model GrowthLSTM yang berfungsi memprediksi pertumbuhan berat ikan, sedangkan dataset kedua digunakan untuk membangun model PakanLSTM yang berfungsi memprediksi kebutuhan pakan.

Tabel 1. Karakteristik Dataset Penelitian

Dataset	Jumlah Data	Variabel Masukan	Variabel Keluaran
GrowthLSTM	24.000	Umur, Berat Rata-Rata Ikan	Berat Rata-Rata Ikan Periode Berikutnya
PakanLSTM	30.000	Umur, Jumlah Ikan, Berat Rata-Rata Ikan	Kebutuhan Pakan

Setelah dataset disusun, dilakukan proses eksplorasi data untuk memastikan konsistensi setiap variabel, kesesuaian rentang nilai, serta hubungan antarvariabel sebelum memasuki tahap prapemrosesan. Tahap ini bertujuan memastikan bahwa data yang digunakan telah memenuhi kebutuhan proses pelatihan model.

4. *Data Preparation*

Tahap *Data Preparation* bertujuan mempersiapkan dataset agar sesuai dengan kebutuhan algoritma LSTM. Tahapan yang dilakukan meliputi seleksi variabel, normalisasi menggunakan metode *Min-Max Scaling*, pembentukan data berurutan (*sequence*) berdasarkan nilai *time step*, serta pembagian dataset menjadi data pelatihan, validasi, dan pengujian.

Seleksi Variabel

Seleksi variabel dilakukan untuk menentukan atribut yang digunakan sebagai variabel masukan (*input feature*) dan variabel keluaran (*output*) pada masing-masing model. Pemilihan variabel disesuaikan dengan tujuan pengembangan setiap model agar proses pembelajaran mampu merepresentasikan hubungan biologis yang berkaitan dengan pertumbuhan ikan dan kebutuhan pakan.

Pada model GrowthLSTM, variabel umur ikan dan berat rata-rata ikan digunakan sebagai variabel masukan untuk memprediksi berat rata-rata ikan pada periode berikutnya. Sementara itu, pada model PakanLSTM, variabel umur ikan, jumlah ikan, dan berat rata-rata ikan

digunakan sebagai variabel masukan untuk memprediksi kebutuhan pakan sekali pemberian. Variabel yang digunakan pada masing-masing dataset telah dijelaskan pada Tabel 1.

Normalisasi Data

Data yang telah melalui proses seleksi variabel kemudian dinormalisasi menggunakan metode *Min-Max Scaling*. Normalisasi dilakukan untuk mengubah rentang nilai setiap variabel menjadi interval $[0, 1]$ sehingga mengurangi perbedaan skala antarvariabel. Proses ini bertujuan meningkatkan stabilitas pelatihan model serta mempercepat proses konvergensi selama optimasi. Rumus normalisasi yang digunakan:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

dengan:

- X' = nilai hasil normalisasi
- X = nilai asli data
- X_{min} = nilai minimum data
- X_{max} = nilai maksimum data

Pembentukan Sequence

Setelah proses transformasi dan normalisasi selesai dilakukan, data diubah menjadi bentuk deret waktu (*sequence*) menggunakan pendekatan *sliding window*. Tahap ini bertujuan mengubah data tabular menjadi urutan data historis yang dapat diproses oleh model *Long Short-Term Memory* (LSTM). Pada model LSTM, setiap prediksi tidak hanya dipengaruhi oleh kondisi pada satu waktu tertentu, tetapi juga oleh informasi dari beberapa periode sebelumnya sehingga model mampu mempelajari hubungan temporal antar data.

Pada penelitian ini diterapkan dua skema pembentukan *sequence* yang berbeda sesuai dengan karakteristik masing-masing model. Model GrowthLSTM menggunakan pendekatan *adaptive lookback*, yaitu panjang *sequence* disesuaikan dengan fase pertumbuhan ikan. Fase larva menggunakan *lookback* selama 4 hari, sedangkan fase juvenil, pembesaran, dan dewasa menggunakan *lookback* selama 7 hari. Untuk menjaga keseragaman dimensi masukan pada model, *sequence* fase larva yang terdiri atas empat langkah waktu dilakukan *padding* hingga memiliki panjang tujuh *time step*. Contoh pembentukan *sequence* pada model GrowthLSTM ditunjukkan pada Tabel 2.

Tabel 2. Contoh Pembentukan Sequence pada Model GrowthLSTM

Fase	Lookback	Bentuk Sequence	Target
Larva	4 hari	Berat ₁ , Berat ₂ , Berat ₃ , Berat ₄	Berat ₅
Juvenil–Dewasa	7 hari	Berat ₁ , Berat ₂ , Berat ₃ , Berat ₄ , Berat ₅ , Berat ₆ , Berat ₇	Berat ₈

Sementara itu, model PakanLSTM menggunakan pendekatan *fixed lookback* dengan panjang *sequence* tetap sebanyak 7 hari. Setiap *sequence* terdiri atas data historis umur ikan, jumlah ikan, dan berat rata-rata ikan selama tujuh hari berturut-turut, sedangkan kebutuhan pakan pada hari berikutnya digunakan sebagai target prediksi. Contoh pembentukan *sequence* pada model PakanLSTM ditunjukkan pada Tabel 3.

Tabel 3. Contoh Pembentukan Sequence pada Model PakanLSTM

Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7	Target
X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	Y ₈

Melalui proses pembentukan *sequence* tersebut, kedua model memperoleh masukan dalam bentuk data berurutan yang memungkinkan LSTM mempelajari pola temporal pertumbuhan ikan dan perubahan kebutuhan pakan berdasarkan informasi historis yang tersedia.

Pembagian Dataset

Setelah proses pembentukan *sequence* selesai dilakukan, data dibagi menjadi data pelatihan (*training*), validasi (*validation*), dan pengujian (*testing*). Pembagian dataset bertujuan memastikan model dilatih dan dievaluasi menggunakan data yang berbeda sehingga mampu mengukur kemampuan generalisasi model terhadap data yang belum pernah digunakan selama proses pelatihan.

Strategi pembagian dataset disesuaikan dengan karakteristik masing-masing model. Pada GrowthLSTM, pembagian data dilakukan berdasarkan kelompok simulasi (*simulation-based split*) untuk mencegah terjadinya data *leakage* antar kelompok data. Sebanyak 70% data digunakan sebagai data pelatihan, 15% sebagai data validasi, dan 15% sebagai data pengujian. Sementara itu, pada PakanLSTM, pembagian data dilakukan menggunakan pendekatan random split setelah seluruh *sequence* terbentuk, dengan komposisi 80% data pelatihan, 10% data validasi, dan 10% data pengujian.


Tabel 4. Distribusi Dataset Setelah Pembentukan Sequence

Model	Metode Pembagian	Training	Validation	Testing	Total Sequence
GrowthLSTM	<i>Simulation-based split</i>	15.820 (70%)	3.390 (15%)	3.390 (15%)	22.600
PakanLSTM	<i>Random split</i>	23.994 (80%)	2.999 (10%)	3.000 (10%)	29.993

Data pelatihan digunakan untuk membangun model, data validasi digunakan untuk memantau proses pelatihan dan membantu pemilihan model terbaik, sedangkan data pengujian digunakan untuk mengevaluasi performa akhir model terhadap data yang belum pernah digunakan selama proses pelatihan.

5. Modeling

Tahap Modeling merupakan proses pengembangan dua model Long Short-Term Memory (LSTM), yaitu GrowthLSTM dan PakanLSTM, yang terintegrasi untuk memprediksi pertumbuhan dan kebutuhan pakan ikan lele. GrowthLSTM memprediksi berat rata-rata ikan berdasarkan data historis pertumbuhan, sedangkan PakanLSTM memprediksi kebutuhan pakan berdasarkan umur, jumlah ikan, dan berat rata-rata hasil prediksi GrowthLSTM. Arsitektur kedua model ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur Model GrowthLSTM dan PakanLSTM yang Terintegrasi

Berdasarkan Gambar 2, model GrowthLSTM menerima masukan berupa umur ikan dan berat rata-rata ikan, kemudian menghasilkan prediksi berat rata-rata ikan pada periode berikutnya. Selanjutnya, hasil prediksi tersebut digunakan sebagai salah satu variabel masukan pada model PakanLSTM bersama dengan umur ikan dan jumlah ikan untuk menghasilkan prediksi kebutuhan pakan. Integrasi kedua model memungkinkan sistem melakukan estimasi kebutuhan pakan secara berkelanjutan tanpa memerlukan pengukuran berat ikan setiap hari.

Model GrowthLSTM

Model GrowthLSTM dikembangkan menggunakan arsitektur LSTM yang terdiri atas dua lapisan LSTM, satu lapisan *dropout*, satu *dense layer*, dan satu *output layer*. Model ini dirancang untuk mempelajari pola pertumbuhan berat ikan berdasarkan data historis sehingga mampu menghasilkan prediksi berat rata-rata ikan pada periode berikutnya. Selain itu, model menerapkan pendekatan *adaptive lookback*, yaitu panjang *sequence* disesuaikan dengan fase pertumbuhan ikan. Fase larva menggunakan *lookback* selama 4 hari, sedangkan fase juvenil hingga dewasa menggunakan *lookback* selama 7 hari. Untuk menjaga keseragaman dimensi masukan, *sequence* pada fase larva dilakukan *padding* hingga memiliki panjang 7 *time step*. Konfigurasi pelatihan model GrowthLSTM disajikan pada Tabel 5.

Tabel 5. Konfigurasi Training Model GrowthLSTM

Parameter	Nilai
Input Shape	(7, 2)
Optimizer	Adam
Loss Function	Mean Squared Error (MSE)
Batch Size	256
Epoch	100
Learning Rate	0,001
Early Stopping	Tidak
Total Parameter	30.113

Model PakanLSTM

Model PakanLSTM dikembangkan menggunakan arsitektur LSTM yang terdiri atas dua lapisan LSTM, satu lapisan *dropout*, satu *dense layer*, dan satu *output layer*. Model menerima masukan berupa umur ikan, jumlah ikan, dan berat rata-rata ikan yang berasal dari hasil prediksi GrowthLSTM. Berbeda dengan GrowthLSTM, model ini menggunakan pendekatan *fixed lookback* dengan panjang *sequence* tetap selama 7 hari untuk seluruh data pelatihan. Pendekatan tersebut dipilih karena perubahan kebutuhan pakan dipengaruhi oleh kondisi historis yang relatif konsisten selama periode pengamatan. Konfigurasi pelatihan model PakanLSTM disajikan pada Tabel 6.

Tabel 6. Konfigurasi Training Model PakanLSTM

Parameter	Nilai
Input Shape	(7, 3)
Optimizer	Adam
Loss Function	Mean Squared Error (MSE)
Batch Size	256
Epoch	100
Learning Rate	0,001
Early Stopping	Tidak
Total Parameter	30.369

6. Evaluation

Model yang telah dikembangkan selanjutnya dievaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *Coefficient of Determination* (R^2).

Mean Absolute Error (MAE)

Mean Absolute Error digunakan untuk menghitung rata-rata selisih absolut antara nilai prediksi dan nilai aktual tanpa memperhatikan arah kesalahan, sehingga memberikan gambaran langsung mengenai besar kesalahan prediksi model (Chicco *et al.*, 2021). Perhitungan MAE dinyatakan dengan persamaan:

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

Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur tingkat kesalahan prediksi dalam bentuk persentase terhadap nilai aktual. Semakin kecil nilai MAPE yang diperoleh, maka semakin tinggi tingkat akurasi model (Chicco *et al.*, 2021). Perhitungan MAPE dirumuskan dengan persamaan:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Root Mean Squared Error (RMSE)

RMSE merupakan akar kuadrat dari MSE dan sering digunakan sebagai indikator akurasi model karena sensitif terhadap kesalahan prediksi berskala besar (Chicco *et al.*, 2021). Perhitungan RMSE dirumuskan dengan persamaan:

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

Coefficient of Determination (R^2)

Coefficient of Determination (R^2) digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual. Persamaan R^2 dirumuskan dengan:

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

di mana:

- y_i adalah nilai aktual kebutuhan pakan
- $\hat{y}_i$ adalah nilai hasil prediksi model
- $\bar{y}$ adalah rata-rata nilai aktual
- n adalah jumlah data pengujian

7. Deployment

Tahap *Deployment* merupakan proses implementasi model GrowthLSTM dan PakanLSTM ke dalam sistem smart aquaponik berbasis *Internet of Things* (IoT). Kedua model diimplementasikan pada server berbasis Flask yang menyediakan layanan REST API, sedangkan perangkat ESP32 berperan sebagai *edge device* yang menerima masukan pengguna berupa umur ikan dan jumlah ikan melalui keypad, kemudian mengirimkan data tersebut ke server melalui jaringan internet. Model GrowthLSTM terlebih dahulu memprediksi berat rata-rata ikan pada periode berikutnya, kemudian hasil prediksi tersebut digunakan sebagai salah satu masukan bagi model PakanLSTM untuk menghasilkan estimasi kebutuhan pakan. Selanjutnya, hasil prediksi dikirimkan kembali ke ESP32 dalam format JSON sebagai dasar pengendalian aktuator servo MG996R sehingga proses pemberian pakan dapat dilakukan


secara otomatis sesuai dengan hasil prediksi tanpa memerlukan perhitungan manual oleh pembudidaya.

3. Hasil dan Pembahasan

3.1 Hasil Pengembangan Model GrowthLSTM

Model GrowthLSTM dikembangkan untuk memprediksi pertumbuhan berat rata-rata ikan lele berdasarkan data historis. Model ini berperan sebagai model pendukung yang menghasilkan estimasi berat ikan pada periode berikutnya, yang selanjutnya digunakan sebagai salah satu variabel masukan bagi model PakanLSTM. Dengan demikian, proses prediksi kebutuhan pakan dapat dilakukan secara berkelanjutan tanpa memerlukan pengukuran berat ikan setiap hari.


Proses pelatihan menggunakan dataset yang telah melalui normalisasi, pembentukan sequence, dan pembagian dataset. Performa model dipantau melalui training loss dan validation loss untuk memastikan model mampu mempelajari pola pertumbuhan ikan secara optimal.



Gambar 3. Kurva Training GrowthLSTM

Berdasarkan Gambar 3, training loss dan validation loss cenderung menurun seiring bertambahnya epoch, menunjukkan bahwa model mampu mempelajari pola pertumbuhan ikan dengan baik. Pola kedua kurva yang relatif sejalan juga menunjukkan kemampuan generalisasi yang baik dan tidak terdapat overfitting yang signifikan.

Setelah proses pelatihan selesai, model digunakan untuk memprediksi berat rata-rata ikan pada data pengujian. Perbandingan antara nilai aktual dan hasil prediksi model ditunjukkan pada Gambar 4.



Gambar 4. Perbandingan Nilai Aktual dan Prediksi GrowthLSTM

Gambar 4 menunjukkan bahwa hasil prediksi model mengikuti pola pertumbuhan berat ikan yang relatif konsisten dengan data aktual. Kedekatan antara kurva prediksi dan kurva

aktual menunjukkan bahwa model mampu mempelajari hubungan temporal pada data pertumbuhan ikan dengan baik. Meskipun masih terdapat sedikit perbedaan pada beberapa titik pengamatan, penyimpangan tersebut tidak mengubah tren pertumbuhan secara keseluruhan sehingga model tetap mampu menghasilkan estimasi berat ikan yang representatif. Untuk mengetahui performa model secara kuantitatif, dilakukan evaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *Coefficient of Determination* (R^2). Hasil evaluasi disajikan pada Tabel 7.


Tabel 7. Hasil Evaluasi GrowthLSTM

Metrik	Nilai
MAE	2,3959 g
MAPE	3,19%
R^2	0,9962
RMSE	3,4898 g

Berdasarkan Tabel 7, model GrowthLSTM mampu menghasilkan tingkat kesalahan prediksi yang rendah serta nilai koefisien determinasi yang tinggi. Nilai tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam mempelajari pola pertumbuhan berat ikan sehingga layak digunakan sebagai model pendukung pada sistem prediksi kebutuhan pakan. Hasil ini juga menunjukkan bahwa pendekatan *adaptive lookback* yang diterapkan pada penelitian mampu mengakomodasi perbedaan karakteristik data pada setiap fase pertumbuhan ikan, sehingga model dapat menghasilkan prediksi yang stabil pada seluruh fase budidaya.

3.2 Hasil Pengembangan Model PakanLSTM

Model PakanLSTM dikembangkan untuk memprediksi kebutuhan pakan ikan lele berdasarkan umur, jumlah ikan, dan berat rata-rata hasil prediksi GrowthLSTM. Model dilatih menggunakan dataset yang telah melalui normalisasi, pembentukan sequence, serta pembagian data pelatihan, validasi, dan pengujian. Performa model dipantau melalui training loss dan validation loss untuk memastikan kemampuannya mempelajari hubungan antara parameter pertumbuhan dan kebutuhan pakan.




Gambar 5. Kurva Training PakanLSTM

Berdasarkan Gambar 5, nilai *training loss* dan *validation loss* mengalami penurunan secara bertahap selama proses pelatihan hingga mencapai kondisi yang relatif stabil. Pola tersebut menunjukkan bahwa model berhasil mempelajari hubungan antarvariabel tanpa mengalami fluktuasi yang signifikan. Selain itu, kedekatan antara kedua kurva menunjukkan bahwa

model memiliki kemampuan generalisasi yang baik sehingga mampu mempertahankan performa pada data validasi.

Setelah proses pelatihan selesai, model digunakan untuk memprediksi kebutuhan pakan pada data pengujian. Perbandingan antara nilai aktual dan hasil prediksi model ditunjukkan pada Gambar 6.



Gambar 6. Perbandingan Nilai Aktual dan Prediksi PakanLSTM

Berdasarkan Gambar 6, hasil prediksi model menunjukkan pola yang mengikuti perubahan nilai aktual dengan tingkat kesesuaian yang tinggi. Perbedaan antara nilai prediksi dan nilai aktual hanya terjadi pada beberapa titik pengamatan dan tidak memengaruhi kecenderungan perubahan kebutuhan pakan secara keseluruhan. Hal ini menunjukkan bahwa model mampu menangkap hubungan nonlinier antara umur ikan, jumlah ikan, dan berat rata-rata ikan terhadap kebutuhan pakan.

Selanjutnya dilakukan evaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *Coefficient of Determination* (R^2). Hasil evaluasi model disajikan pada Tabel 8. Hasil Evaluasi PakanLSTM


Tabel 8. Hasil Evaluasi PakanLSTM

Metrik	Nilai
MAE	1,1034 g
MAPE	20.57%
R^2	0.9674
RMSE	3.1447 g

Berdasarkan Tabel 8, model PakanLSTM mampu menghasilkan tingkat kesalahan prediksi yang rendah dengan nilai koefisien determinasi yang tinggi. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam memprediksi kebutuhan pakan berdasarkan informasi umur ikan, jumlah ikan, dan berat rata-rata ikan. Integrasi hasil prediksi GrowthLSTM sebagai salah satu variabel masukan juga memungkinkan sistem menghasilkan estimasi kebutuhan pakan secara berkelanjutan tanpa memerlukan pengukuran berat ikan secara langsung pada setiap periode pemberian pakan.

3.3 Implementasi Model ke Sistem Smart Aquaponik

Model GrowthLSTM dan PakanLSTM yang telah dikembangkan selanjutnya diimplementasikan pada sistem smart aquaponic berbasis *Internet of Things* (IoT). Implementasi dilakukan menggunakan arsitektur *client-server*, di mana kedua model dijalankan pada server berbasis Flask sebagai REST API, sedangkan perangkat ESP32 berfungsi sebagai client yang bertugas mengirimkan data masukan dan menerima hasil prediksi. Arsitektur implementasi sistem ditunjukkan pada Gambar 7.



Gambar 7. Arsitektur Implementasi Sistem Smart Aquaponic

Berdasarkan Gambar 7, pengguna memasukkan data umur ikan, jumlah ikan, berat rata-rata ikan melalui keypad yang terhubung dengan ESP32. Selanjutnya, data dikirimkan ke server melalui jaringan internet menggunakan protokol HTTP. Server kemudian menjalankan model GrowthLSTM untuk memprediksi berat rata-rata ikan untuk hari berikutnya, dilanjutkan dengan model PakanLSTM untuk menentukan kebutuhan pakan berdasarkan umur ikan, jumlah ikan, dan hasil prediksi berat ikan. Hasil prediksi dikembalikan ke ESP32 dalam format JSON dan ditampilkan pada LCD sebagai informasi bagi pengguna.

Selain menampilkan hasil prediksi, ESP32 juga memanfaatkan data kebutuhan pakan sebagai dasar pengendalian aktuator servo MG996R. Servo akan bergerak sesuai jadwal pemberian pakan yang telah ditentukan untuk membuka mekanisme penyaluran pakan secara otomatis. Dengan pendekatan ini, proses pemberian pakan tidak lagi bergantung pada perhitungan manual, tetapi dilakukan berdasarkan hasil prediksi yang dihasilkan oleh kedua model LSTM.

Integrasi model kecerdasan buatan dengan perangkat IoT memungkinkan proses prediksi dan pengendalian aktuator berlangsung secara otomatis dalam satu alur kerja. Pendekatan ini tidak hanya mempermudah proses pemberian pakan, tetapi juga mendukung penerapan sistem budidaya ikan yang lebih adaptif, efisien, dan mudah dioperasikan oleh pembudidaya.

3.4 Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa seluruh komponen pada sistem smart aquaponik dapat bekerja secara terintegrasi mulai dari proses pengiriman data oleh ESP32, pemrosesan prediksi pada server, hingga pengendalian aktuator servo sebagai mekanisme pemberian pakan otomatis. Pengujian dilakukan terhadap komunikasi data, proses prediksi, serta respons aktuator untuk mengetahui keberhasilan implementasi model pada sistem IoT.

Pengujian Komunikasi ESP32 dan Server

Pengujian komunikasi dilakukan untuk memastikan bahwa perangkat ESP32 mampu mengirimkan data masukan berupa umur ikan, jumlah ikan, berat rata-rata ikan ke server serta menerima hasil prediksi dalam format JSON melalui layanan REST API. Selama pengujian, setiap permintaan (*request*) yang dikirimkan oleh ESP32 berhasil diproses oleh server dan menghasilkan respons sesuai dengan data masukan yang diberikan.

Tabel 9. Hasil Pengujian Komunikasi ESP32 dengan Server

No	Umur (hari)	Jumlah Ikan	HTTP Code	Response JSON	Status
1	30	100	200	Berhasil diterima	Berhasil
2	45	100	200	Berhasil diterima	Berhasil
3	60	80	200	Berhasil diterima	Berhasil

4	75	75	200	Berhasil diterima	Berhasil
5	90	60	200	Berhasil diterima	Berhasil

Berdasarkan hasil pengujian, komunikasi antara ESP32 dan server berjalan dengan baik tanpa mengalami kegagalan pengiriman maupun kesalahan pembacaan data. Hal ini menunjukkan bahwa mekanisme komunikasi menggunakan protokol HTTP dan format JSON mampu mendukung pertukaran data secara andal selama proses prediksi berlangsung.

Pengujian Hasil Prediksi

Pengujian ini dilakukan untuk memastikan bahwa server mampu menjalankan model GrowthLSTM dan PakanLSTM secara berurutan serta menghasilkan keluaran sesuai dengan data masukan yang diberikan. Hasil prediksi yang dihasilkan server kemudian dikirimkan kembali ke ESP32 sebagai dasar pengendalian sistem pemberian pakan.

```
{
  "status": "success",
  "umur": 60,
  "jumlah_ikan": 100,
  "berat_prediksi": 152.34,
  "pakan_prediksi": 25.61,
  "jadwal": "07:00"
}
```

Gambar 8. Respons JSON dari Server

Berdasarkan hasil pengujian, server berhasil menghasilkan respons dalam format JSON yang berisi informasi berat rata-rata ikan hasil prediksi GrowthLSTM dan kebutuhan pakan hasil prediksi PakanLSTM. Data tersebut diterima dan diproses oleh ESP32 tanpa mengalami kesalahan sehingga dapat digunakan sebagai dasar pengendalian aktuator.

Pengujian Aktuator Servo

Pengujian aktuator dilakukan untuk memastikan bahwa servo MG996R dapat bergerak sesuai hasil prediksi kebutuhan pakan yang diterima dari server. Setelah menerima data prediksi, ESP32 mengaktifkan servo sesuai jadwal pemberian pakan yang telah ditentukan sehingga mekanisme penyaluran pakan berlangsung secara otomatis.

Tabel 10. Hasil Pengujian Servo

No	Jadwal	Pakan Prediksi (gram)	Servo	Hasil
1	07.00	25,6	Aktif	Berhasil
2	12.00	28,4	Aktif	Berhasil
3	17.00	27,1	Aktif	Berhasil
4	07.00	30,3	Aktif	Berhasil
5	12.00	31,7	Aktif	Berhasil

Hasil pengujian menunjukkan bahwa servo mampu bekerja sesuai perintah yang dikirimkan oleh ESP32 dan berhasil melakukan proses penyaluran pakan pada setiap skenario pengujian. Integrasi antara model prediksi, server, ESP32, dan aktuator menunjukkan bahwa sistem dapat beroperasi secara otomatis sesuai dengan alur kerja yang telah dirancang.

Secara keseluruhan, hasil pengujian menunjukkan bahwa sistem smart aquaponik berhasil mengintegrasikan model kecerdasan buatan dengan perangkat IoT. Seluruh tahapan mulai dari pengiriman data, proses prediksi, penerimaan respons, hingga pengendalian aktuator berjalan sesuai rancangan, sehingga sistem mampu melakukan pemberian pakan ikan secara otomatis berdasarkan hasil prediksi yang dihasilkan oleh model LSTM.

4. Simpulan

Penelitian ini berhasil mengembangkan dua model LSTM yang terintegrasi, yaitu GrowthLSTM untuk memprediksi berat rata-rata ikan dan PakanLSTM untuk memprediksi kebutuhan pakan ikan lele. Hasil evaluasi menunjukkan kedua model memiliki performa prediksi yang baik dan mampu diimplementasikan pada sistem smart aquaponik berbasis IoT menggunakan ESP32 dan Flask REST API. Integrasi model dengan sistem menghasilkan proses prediksi dan pemberian pakan yang berlangsung secara otomatis, sehingga dapat mendukung pengambilan keputusan pemberian pakan yang lebih adaptif, efisien, dan berbasis data pada budidaya ikan lele.

5. Daftar Pustaka

- Adriono, E., Somantri, M., & Suryono, C. A. (2022). Model Prediksi Jumlah Pakan menggunakan Algoritma Evolusi Pikiran - Jaringan Syaraf Tiruan Rambatan Balik untuk Budidaya Udang. *Jurnal Kelautan Tropis*, 25(2), 266–278. <https://doi.org/10.14710/jkt.v25i2.14256>
- Alkahfi, C., Kurnia, A., & Saefuddin, A. (2024). Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(4), 1235–1243. <https://doi.org/10.57152/malcom.v4i4.1415>
- Assan, D., Huang, Y., Mustapha, U. F., Addah, M. N., Li, G., & Chen, H. (2021). Fish Feed Intake, Feeding Behavior, and the Physiological Response of Apelin to Fasting and Refeeding. *Frontiers in Endocrinology*, 12, 798903. <https://doi.org/10.3389/fendo.2021.798903>
- Cahyani, J., Mujahidin, S., & Fiqar, T. P. (2023). Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *Jurnal Sistem Dan Teknologi Informasi (JustIN)*, 11(2), 346–357. <https://doi.org/10.26418/justin.v11i2.57395>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Fitriyanto, A. N., Ediyanto, & Gultom, V. D. N. (2020). Efektifitas Penambahan Probiotik Terhadap Pertumbuhan, FCR dan Sintasan Ikan Lele Sangkuriang (*Clarias gariepinus*). *Jurnal Ilmiah Satya Minabahari*, 5(2), 73–84. <https://doi.org/10.53676/jism.v5i2.81>
- Hasanah, M. A., Soim, S., & Handayani, A. S. (2021). Implementasi CRISP-DM Model Menggunakan Metode Decision Tree dengan Algoritma CART untuk Prediksi Curah Hujan Berpotensi Banjir. *Journal of Applied Informatics and Computing*, 5(2), 103–108. <https://doi.org/10.30871/jaic.v5i2.3200>
- Kadarini, T., Yamin, M., Nurhidayat, N., & Sholichah, L. (2022). Pertumbuhan Ikan Mas Koki, *Carrasius Auratus* Pada Sistem Akuaponik Dengan Tanaman Air Yang Berbeda. *Jurnal Riset Akuakultur*, 16(3), 167–176. <https://doi.org/10.15578/jra.16.3.2021.167-176>
- Kurniaji, A., Yunarty, Y., Anton, A., Usman, Z., Wahid, E., & Rama, K. (2021). Pertumbuhan dan konsumsi pakan ikan nila (*Oreochromis niloticus*) yang dipelihara dengan sistem bioflok. *Sains Akuakultur Tropis*, 5(2), 197–203. <https://doi.org/10.14710/sat.v5i2.11824>
- Mahendra, I. P. E., Arthana, I. W., & Dewi, A. P. W. K. (2022). Pengaruh Pemberian Pakan Berbeda Pada Laju Pertumbuhan Ikan Lele Dumbo (*Clarias gariepinus*). *Bumi Lestari Journal of Environment*, 22(1), 12. <https://doi.org/10.24843/blje.2022.v22.i01.p02>
- Pramana, A., Rizki Dalimunthe, E., & Styawati, S. (2025). Teknologi Pemberian Nutrisi Ikan Lele dan Tanaman Kangkung pada Sistem Aquaponik Menggunakan Teknologi IoT. *Jurnal Pendidikan Dan Teknologi Indonesia*, 5(3), 813–829. <https://doi.org/10.52436/1.jpti.708>

- Riani, N. A., Andreswari, R., & Fauzi, R. (2021). Implementasi Algoritma Artificial Neural Network Pada Proses Seleksi Pilih Peminatan. *Journal of Science and Social Research*, 4(3), 241–247. <https://doi.org/10.54314/jssr.v4i3.651>
- Shobihah, H. N., Yustiati, A., & Andriani, Y. (2022). Produktivitas Budidaya Ikan dalam Berbagai Konstruksi Sistem Akuaponik (Review). *Akuatika Indonesia*, 7(1), 34–41. <https://doi.org/10.24198/jaki.v7i1.39441>
- Sitompul, P. A. U., Sujaini, H., Yacoub, R. R., & Ananda, N. (2025). Penerapan Model Long Short-Term Memory (LSTM) Untuk Prediksi Kualitas Udara dan Analisis Korelasi Terhadap Unsur Cuaca di Jongkat Kabupaten Mempawah. *Jurnal Sains & Teknologi Modifikasi Cuaca*, 25(1), 33–42. <https://ejournal.brin.go.id/JSTMC/article/view/4990>
- Son, S., & Jeong, Y. (2024). An Automated Fish-Feeding System Based on CNN and GRU Neural Networks. *Sustainability*, 16(9), 3675. <https://doi.org/10.3390/su16093675>