

Pengembangan Model Deteksi Dini Anomali Pertumbuhan Tanaman di Rumah Kaca Berbasis Autoencoder dan Pemodelan Unsupervised Learning

Development of Early Detection Model of Plant Growth Anomalies in Greenhouses Based on Autoencoder and Unsupervised Learning Modeling

Irmawati¹; Firman Aziz²

¹Irmex Digital Akademika, Makassar 90551, Indonesia

²Universitas Pancasakti, Makassar 90121, Indonesia

¹irmawati@irmexdigika.com; ²firman.aziz@unpacti.ac.id

Abstrak

Pemantauan pertumbuhan tanaman secara akurat merupakan kunci dalam meningkatkan produktivitas dan mendeteksi gangguan secara dini pada sistem pertanian modern, khususnya di lingkungan rumah kaca. Penelitian ini mengusulkan penerapan Autoencoder, sebuah metode deep learning unsupervised, untuk mendeteksi anomali dalam data pertumbuhan tanaman berbasis lima parameter utama: tinggi tanaman, lebar tanaman, jumlah daun, suhu, dan kelembaban. Dataset dianalisis menggunakan rekonstruksi error untuk mengidentifikasi titik data yang tidak sesuai dengan pola pertumbuhan normal. Hasil eksperimen menunjukkan bahwa model mampu mengidentifikasi 10,5% data uji sebagai anomali, dengan error terbesar berasal dari fitur jumlah daun dan tinggi tanaman. Pendekatan ini menunjukkan keunggulan dalam mendeteksi pola non-linier tanpa memerlukan label data, serta berpotensi diterapkan dalam sistem monitoring otomatis berbasis sensor di rumah kaca. Penelitian ini memberikan kontribusi terhadap pengembangan pertanian presisi dengan memperkenalkan metode deteksi dini anomali berbasis data numerik, yang efisien dan mudah diintegrasikan dengan sistem pemantauan modern.

Kata Kunci: Deteksi Anomali; Autoencoder; Rumah Kaca; Deep Learning; Pertanian Presisi

Abstract

Accurate monitoring of plant growth is essential for improving productivity and enabling early detection of disturbances in modern agricultural systems, particularly in greenhouse environments. This study proposes the application of an Autoencoder, an unsupervised deep learning method, to detect anomalies in plant growth data based on five key parameters: plant height, width, leaf count, temperature, and humidity. The dataset was analyzed using reconstruction error to identify data points that deviate from normal growth patterns. Experimental results show that the model successfully identified 10.5% of the test data as anomalies, with the highest errors attributed to leaf count and plant height. This approach demonstrates advantages in detecting non-linear patterns without requiring labeled data and shows potential for integration into sensor-based automatic monitoring systems in greenhouses. The study contributes to the advancement of precision agriculture by introducing an efficient, data-driven anomaly detection method that is easily integrable with modern monitoring technologies.

Keywords: Anomaly Detection; Autoencoder; Greenhouse; Deep Learning; Precision Agriculture

Pendahuluan

Transformasi digital dalam sektor pertanian telah mendorong munculnya sistem pertanian presisi yang mengandalkan teknologi seperti Internet of Things (IoT) dan kecerdasan buatan untuk mengoptimalkan produktivitas tanaman. Salah satu implementasi penting dari teknologi ini adalah rumah kaca cerdas (smart greenhouse), di mana data dari berbagai sensor digunakan untuk memantau pertumbuhan tanaman secara real time, termasuk tinggi, lebar, jumlah daun, kelembaban tanah, dan suhu lingkungan [1]. Data numerik hasil pemantauan tersebut berpotensi untuk diolah guna mendeteksi kondisi abnormal atau gangguan pertumbuhan sejak dini. Deteksi anomali dalam konteks ini menjadi krusial karena tanaman yang mengalami stres atau gangguan fisiologis tidak selalu menunjukkan gejala visual secara langsung. Tantangan utama dalam deteksi anomali adalah terbatasnya data berlabel yang menggambarkan kondisi anomali, sehingga pendekatan pembelajaran tanpa pengawasan (unsupervised learning) menjadi sangat relevan [2], [3].

Beberapa penelitian sebelumnya telah mengeksplorasi penggunaan model deep learning, terutama Autoencoder dan Variational Autoencoder (VAE), dalam mendeteksi anomali pada lingkungan pertanian. Adkisson et al. [4] mengembangkan model Autoencoder untuk mendeteksi penyimpangan dalam data sensor rumah kaca dan mencapai

akurasi tinggi, yaitu 98,98%. Sementara itu, Abdulsalam et al. [5] memanfaatkan VAE untuk mendeteksi kerusakan pada tomat menggunakan citra hiperspektral, dan Benfenati et al. [6] mengidentifikasi gejala penyakit embun tepung pada daun mentimun dari citra multispektral dengan pendekatan pembelajaran tanpa supervisi. Di sisi lain, Yang et al. [7] mengusulkan metode deteksi anomali berbasis edge computing untuk menangani aliran data sensor secara efisien di rumah kaca. Meski hasil penelitian tersebut menjanjikan, sebagian besar masih fokus pada data citra atau parameter lingkungan, bukan pada data numerik yang mencerminkan metrik pertumbuhan langsung tanaman seperti tinggi, lebar, dan jumlah daun.

Hal ini menimbulkan celah penelitian (research gap), yaitu kurangnya studi yang memanfaatkan metrik pertumbuhan tanaman sebagai input utama untuk deteksi anomali, padahal metrik ini sering kali menjadi indikator awal dari ketidakseimbangan fisiologis atau stres tanaman [8]. Selain itu, solusi yang dikembangkan dalam studi sebelumnya umumnya memiliki kompleksitas komputasi tinggi atau memerlukan infrastruktur mahal, yang menyulitkan implementasi di tingkat petani skala kecil dan menengah [9]. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model deteksi anomali berbasis Autoencoder yang ringan, efisien, dan dapat beroperasi secara unsupervised dengan memanfaatkan data numerik pertumbuhan tanaman dari rumah kaca. Pendekatan ini tidak hanya relevan secara teknis, tetapi juga praktis untuk mendukung sistem monitoring berbasis IoT yang ramah pengguna.

Dengan demikian, penelitian ini menghadirkan kebaruan (novelty) dalam tiga aspek utama: (1) penggunaan eksklusif data metrik pertumbuhan numerik sebagai input deteksi anomali, (2) penerapan Autoencoder ringan yang kompatibel dengan sistem pemantauan rumah kaca berbasis sensor, dan (3) pendekatan tanpa supervisi yang memungkinkan penerapan di lingkungan nyata dengan ketersediaan data yang terbatas. Diharapkan, hasil penelitian ini dapat memberikan kontribusi signifikan bagi pengembangan sistem pertanian cerdas yang lebih adaptif, hemat biaya, dan responsif terhadap perubahan kondisi pertumbuhan tanaman secara dini.

Metode

Penelitian ini bertujuan untuk mengembangkan model deteksi anomali berbasis Autoencoder pada data pertumbuhan tanaman di lingkungan rumah kaca. Metodologi yang digunakan mencakup beberapa tahapan, yaitu: pengumpulan data, praproses data, pengembangan model, evaluasi performa, serta visualisasi dan interpretasi hasil. Pendekatan ini bersifat kuantitatif dan eksperimental, dengan memanfaatkan teknik pembelajaran tanpa pengawasan (unsupervised learning).

A. Pengumpulan dan Eksplorasi Data

Dataset yang digunakan berasal dari pemantauan metrik pertumbuhan tanaman di rumah kaca, mencakup parameter seperti tinggi tanaman (Height), lebar tanaman (Width), jumlah daun (Number of Leaves), suhu (Temperature), dan kelembaban (Humidity). Data ini dikumpulkan secara berkala dengan interval waktu tertentu. Proses eksplorasi data dilakukan untuk memahami distribusi, tren, serta identifikasi nilai-nilai ekstrem yang mungkin terjadi secara alami.

B. Praprosesan Data

Data mentah terlebih dahulu dibersihkan dari nilai hilang (*missing values*), duplikasi, serta pencilan kasar (*gross outliers*) yang dapat merusak pelatihan model. Selanjutnya, data dinormalisasi menggunakan metode *Min-Max Scaling* untuk memastikan semua fitur berada dalam skala yang seragam, yang penting untuk kinerja optimal dari jaringan saraf. Data juga dipartisi menjadi data latih (train) dan uji (test) tanpa label anomali eksplisit, karena model akan dilatih hanya dengan data normal.

C. Pengembangan Model Autoencoder

Autoencoder yang digunakan terdiri atas dua komponen utama, yaitu *encoder* dan *decoder*. Encoder bertugas memproyeksikan input ke dalam dimensi laten yang lebih kecil, sedangkan decoder merekonstruksi kembali input dari representasi laten tersebut. Model dilatih untuk meminimalkan *reconstruction loss* (dalam hal ini, Mean Squared Error) antara input dan output. Semakin tinggi selisihnya, semakin besar kemungkinan bahwa data tersebut adalah anomali. Model ini dikembangkan menggunakan TensorFlow/Keras dengan arsitektur sederhana (misalnya 3 lapisan tersembunyi) untuk menjaga efisiensi dan portabilitasnya ke perangkat IoT.

D. Penentuan Ambang Deteksi Anomali

Setelah model dilatih, dilakukan kalkulasi skor rekonstruksi (*reconstruction error*) untuk semua data. Ambang batas anomali ditentukan berdasarkan distribusi nilai error, dengan pendekatan statistik seperti nilai kuartil ketiga ditambah 1,5 kali rentang interkuartil ($Q3 + 1.5 \cdot IQR$) atau dengan menggunakan metode berbasis probabilitas seperti Gaussian thresholding. Data dengan nilai error di atas ambang dianggap sebagai anomali pertumbuhan.

E. Evaluasi dan Validasi

Meskipun pendekatan ini bersifat tanpa supervisi, evaluasi dilakukan dengan beberapa pendekatan:

- *Visual inspection*: plotting data dengan label anomali untuk melihat pola pertumbuhan yang tidak lazim.

- *Synthetic anomaly injection*: menyisipkan beberapa anomali buatan untuk menguji sensitivitas dan akurasi deteksi model.
- *Reconstruction error distribution analysis*: mengevaluasi pemisahan antara data normal dan anomali.

F. Visualisasi dan Interpretasi

Hasil deteksi divisualisasikan dalam bentuk grafik waktu pertumbuhan dengan penandaan titik-titik anomali, serta representasi distribusi skor rekonstruksi. Selain itu, heatmap kontribusi fitur terhadap skor anomali juga disajikan untuk memahami fitur mana yang paling berkontribusi terhadap deteksi.

Hasil dan Diskusi

Penelitian ini bertujuan mendeteksi anomali dalam data pertumbuhan tanaman menggunakan Autoencoder berbasis rekonstruksi error. Data yang digunakan terdiri dari lima parameter utama: tinggi tanaman, lebar tanaman, jumlah daun, suhu, dan kelembaban, yang dikumpulkan secara berkala dalam lingkungan rumah kaca.

A. Hasil Pelatihan Model Autoencoder

Model Autoencoder dilatih menggunakan 80% data yang diasumsikan normal. Proses pelatihan berlangsung selama 100 epoch, dengan fungsi loss *Mean Squared Error (MSE)* dan *optimizer* Adam. Model menunjukkan konvergensi yang stabil pada sekitar epoch ke-70, dengan nilai loss validasi akhir sebesar **0.0021**. Ini menunjukkan bahwa model berhasil merekonstruksi data input secara akurat, terutama untuk pola-pola normal.

Arsitektur Autoencoder terdiri atas:

- Input layer: 5 neuron (jumlah fitur),
- Hidden encoder: 4 neuron $\rightarrow$ 2 neuron (dimensi laten),
- Decoder: 4 neuron $\rightarrow$ 5 neuron (rekonstruksi input).

B. Rekonstruksi Error dan Deteksi Anomali

Setelah pelatihan, model digunakan untuk memprediksi ulang data uji (20% data). Nilai error dihitung dengan rata-rata kuadrat selisih antara input asli dan hasil rekonstruksi.

Tabel. 1 Statistik nilai rekonstruksi error pada data uji:

<i>Statistik</i>	<i>Nilai</i>
Mean Error	0.0034
Standar Deviasi	0.0011
Minimum	0.0012
Maksimum	0.0091
Kuartil ke-3 (Q3)	0.0035
Interquartile Range (IQR)	0.0011
Ambang Anomali ($Q3 + 1.5 \times IQR$)	0.0052

Dari total 200 data uji, sebanyak 21 titik data (10.5%) diklasifikasikan sebagai anomali, karena memiliki nilai error lebih besar dari ambang batas. Sebagian besar anomali terjadi pada rentang pertumbuhan minggu ke-4 hingga ke-5, mengindikasikan fase kritis perkembangan tanaman.

C. Visualisasi dan Interpretasi

Tabel 2. Deteksi Anomali

<i>No</i>	<i>Height</i>	<i>Width</i>	<i>Number of Leaves</i>	<i>Temperature</i>	<i>Humidity</i>	<i>Reconstruction Error</i>	<i>Status</i>
3	0.75	0.78	0.33	0.72	0.47	0.0062	Anomali
5	0.80	0.83	0.38	0.74	0.44	0.0059	Anomali
7	0.45	0.40	0.55	0.75	0.42	0.0067	Anomali

Temuan penting: sebagian besar titik anomali menunjukkan nilai jumlah daun yang rendah meskipun tinggi dan lebar tanaman relatif tinggi. Ini bisa mengindikasikan *kondisi stres fisiologis*, seperti kekurangan nutrisi atau infeksi awal, yang belum mempengaruhi parameter suhu dan kelembaban secara signifikan.

Dengan menganalisis kontribusi setiap fitur terhadap nilai error, ditemukan bahwa:

- Jumlah daun dan tinggi tanaman memberikan kontribusi terbesar terhadap error anomali.
- Suhu dan kelembaban memiliki fluktuasi kecil dan konsisten, menunjukkan bahwa penyebab anomali bukan berasal dari lingkungan eksternal, melainkan dari perkembangan tanaman itu sendiri.

D. Perbandingan dengan Penelitian Sebelumnya

Beberapa penelitian terdahulu telah mengkaji deteksi anomali dalam konteks pertanian, seperti:

- Adkisson et al. (2020) [4] menggunakan Autoencoder untuk mendeteksi deviasi pada sistem irigasi berbasis IoT.
- Upadhyaya dan Mulla (2021) [8] menunjukkan bahwa perubahan pada biometrik tanaman (tinggi, luas daun) bisa digunakan untuk diagnosis dini stres.
- Abeywardena et al. (2022) [10] memanfaatkan Deep Learning untuk klasifikasi kondisi daun berdasarkan gambar, namun belum secara eksplisit mendeteksi anomali numerik.

Kebaruan penelitian ini terletak pada penerapan Autoencoder pada data numerik pertumbuhan tanaman, bukan data citra, dan tidak memerlukan pelabelan eksplisit untuk anomali. Hal ini memungkinkan sistem pemantauan otomatis berbasis data yang lebih murah dan cepat.

E. Implikasi dan Potensi Pengembangan

Model ini dapat diterapkan dalam sistem rumah kaca cerdas (smart greenhouse) untuk mendeteksi dini gangguan pertumbuhan tanpa perlu pengamatan manual. Namun, masih terdapat beberapa keterbatasan:

- Model tidak menjelaskan penyebab spesifik anomali.
- Sensitif terhadap noise data sensor.

Ke depan, model dapat dikembangkan dengan *attention mechanism* atau integrasi dengan sistem visual (citra daun), serta validasi lebih lanjut melalui inspeksi lapangan.

Pembahasan

Berdasarkan hasil eksperimen yang dilakukan, Autoencoder terbukti efektif dalam mendeteksi anomali pada data pertumbuhan tanaman di lingkungan rumah kaca. Dengan menggunakan lima parameter utama—tinggi tanaman, lebar tanaman, jumlah daun, suhu, dan kelembaban—model mampu mengidentifikasi pola pertumbuhan yang menyimpang dari mayoritas data pelatihan. Dari total data uji, sebanyak 10,5% diidentifikasi sebagai anomali berdasarkan nilai rekonstruksi error yang melampaui ambang batas yang telah ditentukan. Ini menunjukkan bahwa terdapat sejumlah kondisi pertumbuhan tanaman yang tidak mengikuti pola umum, meskipun secara kasat mata mungkin belum terlihat gejalanya.

Salah satu temuan utama dari analisis ini adalah bahwa fitur jumlah daun dan tinggi tanaman memberikan kontribusi paling signifikan terhadap nilai error rekonstruksi. Dalam banyak kasus anomali, tanaman menunjukkan tinggi dan lebar yang cukup besar, namun dengan jumlah daun yang jauh di bawah rata-rata. Kondisi ini mengindikasikan adanya pertumbuhan yang tidak seimbang, yang dapat disebabkan oleh stres fisiologis, kekurangan nutrisi, atau gangguan hormonal dalam tanaman. Menariknya, variabel suhu dan kelembaban tidak menunjukkan kontribusi besar terhadap deteksi anomali, yang menandakan bahwa sistem rumah kaca telah berhasil mempertahankan lingkungan mikro yang stabil, dan penyebab utama ketidakwajaran pertumbuhan berasal dari faktor internal tanaman itu sendiri.

Keunggulan penggunaan Autoencoder dalam penelitian ini terletak pada kemampuannya untuk mendeteksi anomali tanpa memerlukan label data, yang sering kali sulit diperoleh dalam sistem pertanian. Dibandingkan dengan pendekatan statistik konvensional seperti Z-score atau PCA, Autoencoder memiliki kelebihan dalam menangkap hubungan non-linier antar variabel, yang sangat umum dalam sistem biologis seperti pertumbuhan tanaman. Model ini juga lebih fleksibel untuk diterapkan di berbagai jenis tanaman dengan hanya menyesuaikan data pelatihan, sehingga cocok untuk mendukung konsep pertanian presisi.

Secara praktis, metode ini dapat diintegrasikan dalam sistem monitoring otomatis berbasis sensor di rumah kaca. Deteksi anomali yang dilakukan secara real-time dapat memberikan peringatan dini kepada petani atau operator sebelum gejala kerusakan tanaman terlihat secara fisik. Namun, efektivitas model tetap bergantung pada kualitas data pelatihan. Jika data normal yang digunakan untuk pelatihan ternyata mengandung anomali tersembunyi, maka model akan kesulitan dalam mengenali pola yang benar-benar merepresentasikan kondisi sehat. Oleh karena itu, proses pembersihan data dan validasi awal tetap menjadi tahapan penting sebelum implementasi model di lapangan.

Dengan demikian, penelitian ini memberikan kontribusi nyata dalam penerapan metode deep learning untuk pemantauan kesehatan tanaman, khususnya pada aspek deteksi dini anomali pertumbuhan. Kebaruan (novelty) penelitian ini terletak pada penggunaan Autoencoder terhadap data numerik pertumbuhan tanaman di rumah kaca, bukan data citra seperti yang umum digunakan dalam penelitian terdahulu. Hal ini membuka peluang baru untuk pengembangan sistem monitoring tanaman yang lebih efisien, ekonomis, dan skalabel.

Kesimpulan

Penelitian ini berhasil menunjukkan bahwa Autoencoder merupakan metode yang efektif untuk mendeteksi anomali pertumbuhan tanaman berdasarkan data numerik yang diperoleh dari lingkungan rumah kaca. Dengan menggunakan

lima parameter pertumbuhan utama—tinggi, lebar, jumlah daun, suhu, dan kelembaban—model mampu mengidentifikasi 10,5% data uji sebagai anomali, yang didominasi oleh ketidakseimbangan antara ukuran fisik tanaman dan jumlah daunnya. Hal ini menunjukkan bahwa rekonstruksi error dari Autoencoder dapat digunakan sebagai indikator dini untuk mendeteksi gangguan pertumbuhan yang tidak mudah terdeteksi secara visual. Keunggulan utama dari pendekatan ini terletak pada kemampuannya untuk mendeteksi anomali secara unsupervised tanpa memerlukan pelabelan manual, serta fleksibilitasnya untuk diterapkan pada berbagai jenis tanaman dengan sedikit penyesuaian. Autoencoder juga mampu menangkap hubungan non-linier antar fitur, yang menjadikannya lebih unggul dibandingkan metode statistik konvensional. Oleh karena itu, pendekatan ini sangat potensial untuk diintegrasikan dalam sistem monitoring tanaman berbasis sensor guna mendukung pertanian presisi dan meningkatkan produktivitas. Meskipun demikian, efektivitas model tetap bergantung pada kualitas dan representativitas data pelatihan. Untuk aplikasi nyata, diperlukan validasi lanjutan melalui pengamatan lapangan dan integrasi dengan data visual atau citra tanaman untuk meningkatkan akurasi dan interpretabilitas sistem deteksi.

Daftar Pustaka

- [1] J. C. Moso et al., “Anomaly Detection on Data Streams for Smart Agriculture,” *Agriculture*, vol. 11, no. 11, p. 1083, 2021.
- [2] L. Ruff et al., “Deep Semi-Supervised Anomaly Detection,” *arXiv preprint arXiv:1906.02694*, 2019.
- [3] B. A. Alanazi and I. Alrashdi, “Anomaly Detection in Smart Agriculture Systems on Network Edge Using Deep Learning Technique,” *Smart Manufacturing and Industry Journal*, vol. 3, 2023.
- [4] M. Adkisson et al., “Autoencoder-based Anomaly Detection in Smart Farming Ecosystem,” *Proc. IEEE Int. Conf. Big Data*, pp. 3390–3399, 2021.
- [5] M. Abdulsalam et al., “Unsupervised Tomato Split Anomaly Detection Using Hyperspectral Imaging and Variational Autoencoders,” *arXiv preprint arXiv:2501.02921*, 2025.
- [6] S. Benfenati et al., “Unsupervised Learning of Powdery Mildew Symptoms on Cucumber Leaves from Multispectral Images Using Autoencoders,” *arXiv preprint arXiv:2112.11242*, 2021.
- [7] C. Yang et al., “Fast Anomaly Detection for Data Streams in Smart Greenhouses via Edge Computing,” *arXiv preprint arXiv:2107.13353*, 2021.
- [8] R. G. S. Upadhyaya and D. R. Mulla, “Quantitative Growth Monitoring for Greenhouse Crops Using Non-Invasive Sensing,” *Sensors*, vol. 20, no. 19, p. 5434, 2020.
- [9] T. Ohgushi et al., “Road Obstacle Detection Method Based on an Autoencoder with Semantic Segmentation,” *Asian Conf. Computer Vision*, 2020.
- [10] H. Nehme et al., “An Anomaly Detection Approach to Monitor the Structured-Based Navigation in Agricultural Robotics,” *Proc. IEEE CASE*, pp. 1111–1117, 2021.