

Pemodelan Hybrid AI untuk Prediksi Nutrisi Pakan Berbasis Simulasi NIR

^{1*}Adinda Meylia Salsabila, ²Intan Nur Farida, ³Ardi Sanjaya

^{1,2,3}Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹adindameylia05@gmail.com, ²intannf@unpkediri.ac.id, ³dersky@gmail.com

Penulis Korespondens : Adinda Meylia Salsabila

Abstrak—Analisis kandungan nutrisi pakan ternak merupakan tahapan penting dalam menentukan kualitas dan efisiensi produksi peternakan. Penggunaan alat *Near Infrared Reflectance* (NIR) mampu memberikan hasil analisis yang cepat, namun biaya perangkat dan pengujiannya relatif tinggi. Penelitian ini bertujuan mengembangkan model *hybrid Artificial Intelligence* berbasis simulasi spektrum NIR untuk memprediksi kandungan nutrisi pakan secara digital. Dataset yang digunakan berupa data spektral dan data nutrisi beberapa jenis pakan ruminansia. Tahapan penelitian meliputi preprocessing data, normalisasi, pelatihan model Autoencoder sebagai pembangkit sinyal spektral tiruan, serta *Artificial Neural Network* sebagai model prediksi nutrisi. Evaluasi model dilakukan menggunakan MSE, RMSE, MAE, dan R^2 . Hasil penelitian menunjukkan model hybrid mampu menghasilkan prediksi dengan tingkat kesalahan rendah dan nilai koefisien determinasi tinggi. Sistem yang dikembangkan berpotensi menjadi alternatif simulasi analisis nutrisi pakan berbasis kecerdasan buatan dengan biaya lebih efisien.

Kata Kunci—*Artificial Intelligence, Hybrid Model, NIR, Nutrisi Pakan, Prediksi*

Abstract—*Feed nutrient analysis is an important process in determining livestock productivity and feed quality. Near Infrared Reflectance (NIR) technology can provide rapid analysis results, but the equipment and testing costs are relatively expensive. This study aims to develop a hybrid Artificial Intelligence model based on NIR spectrum simulation for digital feed nutrient prediction. The dataset consisted of spectral data and nutritional data from several ruminant feed ingredients. The research stages included preprocessing, normalization, Autoencoder training for synthetic spectral generation, and Artificial Neural Network training for nutrient prediction. Model performance was evaluated using MSE, RMSE, MAE, and R^2 metrics. The results showed that the hybrid model achieved low prediction errors and high coefficient of determination values. The developed system has potential as an alternative AI-based simulation approach for feed nutrient analysis with more efficient operational costs.*

Keywords—*Artificial Intelligence, Feed Nutrition, Hybrid Model, NIR, Prediction*

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Perkembangan teknologi *Artificial Intelligence* (AI) memberikan pengaruh besar terhadap berbagai sektor, termasuk bidang peternakan. Pemanfaatan AI pada sektor peternakan mulai diterapkan untuk meningkatkan produktivitas ternak, efisiensi pakan, serta mendukung pengambilan keputusan berbasis data [1]. Salah satu aspek penting dalam peternakan adalah analisis kandungan nutrisi pakan karena kualitas nutrisi sangat memengaruhi pertumbuhan dan produktivitas ternak ruminansia [2].

Analisis nutrisi pakan umumnya dilakukan melalui pengujian laboratorium menggunakan metode konvensional. Proses tersebut membutuhkan waktu yang cukup lama serta biaya operasional yang tinggi. Selain itu, penggunaan alat *Near Infrared Reflectance* (NIR) sebagai teknologi analisis cepat juga masih memiliki keterbatasan karena harga perangkat yang relatif

mahal [3]. Walaupun demikian, teknologi NIR memiliki berbagai keunggulan seperti pengujian non-destruktif, waktu analisis yang singkat, dan kemampuan mendeteksi karakteristik nutrisi melalui pola spektrum reflektansi [4].

Beberapa penelitian sebelumnya menunjukkan bahwa kombinasi teknologi NIR dengan *machine learning* mampu meningkatkan kualitas prediksi berbasis data spektral. Machine learning diketahui memiliki performa yang baik dalam pengolahan data *Near Infrared Reflectance* (NIR) serta mampu menghasilkan prediksi yang akurat pada berbagai bidang analisis berbasis spektrum [5]. Pendekatan *Generative Adversarial Network* (GAN) yang dikombinasikan dengan *Vis-NIR Spectroscopy* juga terbukti mampu meningkatkan kualitas prediksi nutrisi berbasis data spektral [6]. Selain itu, penerapan *Wasserstein GAN* pada data NIR telah berhasil digunakan untuk mendeteksi kualitas bahan baku secara cepat dan akurat [7]. Model berbasis *Artificial Intelligence* dan NIR juga dilaporkan mampu melakukan kuantifikasi kandungan anti nutrisi pada bahan pakan secara cepat dan efisien [8].

Penerapan NIR telah digunakan secara luas dalam analisis kualitas bahan pakan maupun produk pertanian lainnya. Teknologi ini dimanfaatkan untuk pengendalian kualitas dedak padi [9], serta prediksi kandungan protein dan kafein pada kopi arabika [10]. Berbagai hasil penelitian tersebut menunjukkan bahwa teknologi NIR memiliki potensi besar untuk dikembangkan dalam berbagai aplikasi analisis nutrisi berbasis data spektral.

Meskipun teknologi NIR telah banyak digunakan untuk analisis kualitas bahan pakan dan produk pertanian, sebagian besar penelitian masih berfokus pada prediksi parameter nutrisi tertentu atau pengendalian kualitas bahan menggunakan pendekatan model tunggal. Selain itu, implementasi pendekatan generatif berbasis hybrid *Artificial Intelligence* untuk simulasi spektrum NIR pada bidang nutrisi pakan ternak masih relatif terbatas. Sebagian besar penelitian terdahulu juga masih bergantung pada akuisisi data menggunakan perangkat NIR secara langsung sehingga memerlukan instrumen khusus dan proses kalibrasi yang relatif kompleks dalam implementasinya [11].


Berdasarkan kondisi tersebut, penelitian ini menawarkan pendekatan berbeda melalui kombinasi Autoencoder dan *Artificial Neural Network* (ANN) untuk menghasilkan simulasi spektrum NIR sekaligus melakukan prediksi kandungan nutrisi pakan secara digital. Pendekatan hybrid AI dipilih karena mampu meningkatkan representasi fitur spektral dan membantu model prediksi mempelajari pola data dengan lebih efektif. Dengan demikian, penelitian ini diharapkan dapat memberikan alternatif analisis nutrisi berbasis simulasi digital yang lebih efisien dan ekonomis dibandingkan metode konvensional.

Tujuan penelitian ini adalah mengembangkan model *hybrid Artificial Intelligence* berbasis Autoencoder dan ANN untuk melakukan simulasi spektrum NIR dan prediksi kandungan nutrisi pakan ternak. Evaluasi performa model dilakukan menggunakan metrik *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R^2) untuk mengetahui tingkat akurasi model yang dikembangkan.

II. METODE

Penelitian ini menggunakan pendekatan *hybrid Artificial Intelligence* untuk melakukan simulasi spektrum *Near Infrared Reflectance* (NIR) dan prediksi kandungan nutrisi pakan ternak ruminansia. Model yang digunakan merupakan kombinasi antara Autoencoder dan *Artificial Neural Network* (ANN). Pendekatan hybrid dipilih karena mampu meningkatkan kemampuan model dalam mempelajari pola data spektral dan menghasilkan prediksi nutrisi yang lebih stabil

[12]. Tahapan penelitian dimulai dari pengumpulan dataset, preprocessing data, pelatihan model Autoencoder, pelatihan model ANN, hingga evaluasi performa model yang ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian *Hybrid Artificial Intelligence*

A. Dataset Penelitian

Dataset penelitian berupa data spektral NIR dan data kandungan nutrisi dari beberapa jenis bahan pakan ternak ruminansia. Variabel nutrisi yang digunakan meliputi protein kasar, serat kasar, lemak kasar, kadar abu, dan bahan kering. Data spektral digunakan sebagai variabel input, sedangkan kandungan nutrisi digunakan sebagai target prediksi model.

Jenis bahan pakan yang digunakan dalam penelitian ini terdiri dari dedak halus, jagung, bungkil kedelai, ampas tahu, pollard, rumput gajah, dan jerami fermentasi. Pemilihan bahan pakan dilakukan karena bahan tersebut umum digunakan pada peternakan ruminansia dan memiliki karakteristik nutrisi yang berbeda-beda sehingga dapat membantu model mempelajari pola data secara lebih baik [13].

Total dataset yang digunakan sebanyak 180 data. Dataset kemudian dibagi menjadi data training sebesar 75% dan data testing sebesar 25%. Pembagian data dilakukan menggunakan metode train-test split secara acak agar distribusi data lebih merata dan model dapat melakukan generalisasi dengan lebih baik terhadap data baru.

Tabel 1. Pembagian Dataset Penelitian

Jenis Data	Jumlah
Data <i>Training</i>	135
Data <i>Testing</i>	45
Total Dataset	180

B. Preprocessing Data

Tahap preprocessing dilakukan sebelum proses pelatihan model untuk meningkatkan kualitas data dan mengurangi kemungkinan terjadinya *error* selama proses pembelajaran model. Proses *preprocessing* diawali dengan pemeriksaan data kosong (*missing value*) dan data duplikat. Data yang tidak valid kemudian dihapus agar tidak memengaruhi performa model.

Selanjutnya dilakukan proses normalisasi menggunakan metode *Min-Max Scaling*. Normalisasi bertujuan untuk menyamakan rentang nilai setiap fitur sehingga proses pembelajaran model menjadi lebih stabil dan mempercepat proses konvergensi [14]. Selain itu, beberapa data kategorikal pada jenis pakan diubah ke bentuk numerik menggunakan metode One-Hot Encoding agar dapat diproses oleh model *machine learning*.

C. Arsitektur *Hybrid Artificial Intelligence*

Model *hybrid Artificial Intelligence* yang digunakan pada penelitian ini terdiri dari dua tahapan utama, yaitu Autoencoder dan *Artificial Neural Network* (ANN). Autoencoder digunakan untuk mempelajari pola spektrum NIR dan menghasilkan representasi fitur laten dari data spektral.

Representasi fitur tersebut kemudian digunakan sebagai input pada model ANN untuk melakukan prediksi kandungan nutrisi pakan ternak [15].

Autoencoder terdiri dari encoder dan decoder. Encoder bertugas melakukan kompresi data input menjadi representasi fitur berdimensi lebih kecil, sedangkan decoder bertugas merekonstruksi data agar mendekati bentuk aslinya. Penggunaan Autoencoder pada penelitian ini bertujuan untuk membantu model mengenali pola spektral dengan lebih efektif dan mengurangi noise pada data [16].

Setelah proses ekstraksi fitur selesai, data hasil representasi Autoencoder digunakan pada model ANN. Model ANN terdiri dari input layer, dua hidden layer, dan output layer. Fungsi aktivasi yang digunakan pada hidden layer adalah ReLU karena mampu meningkatkan performa pembelajaran model pada data non-linear. Proses pelatihan model dilakukan menggunakan beberapa parameter seperti optimizer, learning rate, epoch, batch size, dan fungsi aktivasi. Parameter tersebut digunakan untuk menjaga stabilitas proses pembelajaran model dan meningkatkan performa prediksi [17]. Parameter pelatihan model yang digunakan dalam penelitian ini dapat dilihat pada Tabel 2.

Tabel 2. Parameter Pelatihan Model

Parameter	Nilai
<i>Learning Rate</i>	0.001
<i>Epoch</i>	30
<i>Batch Size</i>	16

D. Evaluasi Model

Evaluasi model dilakukan untuk mengetahui tingkat performa model *hybrid Artificial Intelligence* dalam memprediksi kandungan nutrisi pakan ternak berdasarkan data spektral NIR. Proses evaluasi dilakukan menggunakan data testing sebanyak 45 data yang sebelumnya tidak digunakan pada tahap pelatihan model. Penggunaan data testing bertujuan untuk mengetahui kemampuan model dalam melakukan generalisasi terhadap data baru sehingga hasil evaluasi dapat menggambarkan performa model secara lebih objektif.

Pada penelitian ini, evaluasi dilakukan menggunakan beberapa parameter regresi, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R^2). Penggunaan beberapa parameter evaluasi dilakukan agar performa model dapat dianalisis dari berbagai aspek, mulai dari tingkat kesalahan prediksi hingga kemampuan model dalam menjelaskan hubungan antara data aktual dan data hasil prediksi [18].

Mean Squared Error (MSE) digunakan untuk mengukur rata-rata kuadrat kesalahan antara nilai aktual dan hasil prediksi model. Semakin kecil nilai MSE menunjukkan bahwa hasil prediksi model semakin mendekati nilai sebenarnya. *Mean Squared Error* (MSE) digunakan untuk mengukur rata-rata kuadrat kesalahan antara nilai aktual dan hasil prediksi model. Semakin kecil nilai MSE menunjukkan bahwa hasil prediksi model semakin mendekati nilai sebenarnya. Rumusnya dapat dilihat pada persamaan (1).

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

Selain MSE, penelitian ini juga menggunakan *Root Mean Squared Error* (RMSE). RMSE digunakan untuk mengetahui tingkat kesalahan prediksi model dalam satuan yang sama dengan data asli sehingga lebih mudah diinterpretasikan. Nilai RMSE yang rendah menunjukkan bahwa model memiliki performa prediksi yang baik. Rumusnya ditunjukkan pada persamaan (2).

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

Mean Absolute Error (MAE) digunakan untuk menghitung rata-rata kesalahan absolut antara hasil prediksi dan nilai aktual. MAE membantu mengetahui seberapa besar rata-rata selisih prediksi model terhadap data sebenarnya tanpa memperhatikan arah kesalahan. Rumusnya dapat dilihat pada persamaan (3).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots \dots \dots (3)$$

Selanjutnya, koefisien determinasi atau R^2 digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual. Nilai R^2 berada pada rentang 0 hingga 1. Semakin mendekati 1 menunjukkan bahwa model memiliki kemampuan prediksi yang semakin baik. Rumusnya ditunjukkan pada persamaan (4).

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \dots \dots \dots (4)$$

Melalui parameter evaluasi tersebut, performa model *hybrid Artificial Intelligence* dapat dianalisis secara menyeluruh. Model dengan nilai MSE, RMSE, dan MAE yang rendah serta nilai R^2 yang tinggi menunjukkan bahwa model mampu melakukan prediksi kandungan nutrisi dengan tingkat akurasi yang baik. Hasil evaluasi ini kemudian digunakan sebagai dasar untuk menganalisis efektivitas kombinasi Autoencoder dan ANN dalam proses simulasi spektrum NIR dan prediksi nutrisi pakan ternak.

III. HASIL DAN PEMBAHASAN

Hasil penelitian diperoleh melalui proses pelatihan model *hybrid Artificial Intelligence* yang terdiri dari Autoencoder dan *Artificial Neural Network* (ANN) menggunakan data spektral *Near Infrared Reflectance* (NIR) dan data kandungan nutrisi pakan ternak. Model dilatih menggunakan 135 data training dan diuji menggunakan 45 data testing untuk mengetahui kemampuan model dalam melakukan prediksi kandungan nutrisi secara akurat. Evaluasi performa model dilakukan menggunakan parameter *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R^2).


Tabel 3. Hasil Evaluasi Model *Hybrid Artificial Intelligence*

Parameter	Nilai
MSE	0.082
RMSE	0.286
MAE	0.084
R ²	0.97

Berdasarkan hasil evaluasi pada Tabel 3, model menghasilkan nilai error yang relatif rendah dengan nilai MSE sebesar 0.082, RMSE sebesar 0.286, dan MAE sebesar 0.084. Nilai error yang rendah menunjukkan bahwa perbedaan antara hasil prediksi dan data aktual relatif kecil. Selain itu, nilai koefisien determinasi (R²) sebesar 0.97 menunjukkan bahwa model mampu menjelaskan 97% variasi data aktual. Hasil tersebut mengindikasikan bahwa kombinasi Autoencoder dan ANN mampu mempelajari hubungan antara data spektral NIR dan kandungan nutrisi pakan ternak secara efektif.

Tingginya performa model diduga dipengaruhi oleh kemampuan Autoencoder dalam mengekstraksi fitur-fitur penting dari data spektral NIR sebelum proses prediksi dilakukan oleh ANN. Proses ekstraksi fitur tersebut membantu mengurangi informasi yang tidak relevan serta meningkatkan representasi karakteristik spektral yang berkaitan dengan kandungan nutrisi pakan. Dengan representasi data yang lebih baik, model ANN dapat mempelajari hubungan antara data input dan target prediksi secara lebih efektif sehingga menghasilkan tingkat kesalahan yang rendah.


Selain itu, proses preprocessing berupa normalisasi data turut berkontribusi terhadap stabilitas proses pelatihan model. Normalisasi membantu menyamakan rentang nilai antar fitur sehingga proses optimasi dapat berjalan lebih baik dan mengurangi kemungkinan terjadinya ketidakseimbangan bobot selama pelatihan. Kondisi tersebut memungkinkan model mencapai konvergensi yang lebih cepat dan menghasilkan performa prediksi yang lebih optimal pada data pengujian.



Gambar 1. Rekonstruksi Loss (Autoencoder)

Gambar 1 menunjukkan perkembangan nilai training loss dan validation loss selama proses pelatihan Autoencoder. Terlihat bahwa kedua kurva mengalami penurunan secara konsisten hingga mencapai kondisi konvergen pada epoch akhir. Penurunan loss yang stabil menunjukkan bahwa model berhasil mempelajari representasi fitur laten dari data spektral NIR dengan baik.

Selain itu, jarak antara training loss dan validation loss relatif kecil sehingga menunjukkan bahwa model tidak mengalami overfitting yang signifikan. Kondisi ini mengindikasikan bahwa Autoencoder memiliki kemampuan generalisasi yang baik dalam mengekstraksi fitur penting dari data spektral. Hasil tersebut menunjukkan bahwa proses ekstraksi fitur berjalan secara optimal sehingga informasi penting pada data spektral dapat direpresentasikan dengan baik sebelum digunakan pada tahap prediksi.




Gambar 2. Training Loss dan Validation Loss ANN

Gambar 2 menunjukkan proses pelatihan model ANN menggunakan fitur hasil ekstraksi Autoencoder. Pola penurunan nilai loss yang terjadi selama pelatihan mengindikasikan bahwa model mampu mempelajari hubungan antara data spektral NIR dan kandungan nutrisi secara bertahap. Stabilitas proses pembelajaran menunjukkan bahwa parameter model yang digunakan mampu menghasilkan proses optimasi yang efektif tanpa menyebabkan fluktuasi yang berlebihan.

Selain itu, kecenderungan nilai validation loss yang mengikuti pola training loss menunjukkan bahwa model tidak hanya mampu menyesuaikan diri terhadap data pelatihan, tetapi juga memiliki kemampuan yang baik dalam menangani data yang belum pernah digunakan sebelumnya. Kondisi tersebut menjadi indikator bahwa model memiliki kemampuan generalisasi yang memadai sehingga hasil prediksi yang dihasilkan dapat merepresentasikan kondisi data secara lebih akurat.

Integrasi antara Autoencoder sebagai ekstraktor fitur dan ANN sebagai model prediksi memberikan kontribusi terhadap peningkatan performa model secara keseluruhan. Fitur laten yang dihasilkan Autoencoder membantu ANN dalam mempelajari pola hubungan antara data spektral dan kandungan nutrisi secara lebih efektif, sehingga menghasilkan prediksi dengan tingkat kesalahan yang rendah dan kemampuan prediksi yang tinggi.



Gambar 3. Perbandingan Nilai Aktual dan Hasil Prediksi

Gambar 3 menunjukkan tingkat kesesuaian antara nilai aktual dan nilai prediksi yang dihasilkan oleh model *hybrid Artificial Intelligence*. Sebaran titik yang mengikuti pola garis referensi mengindikasikan bahwa model mampu mempertahankan hubungan antara data input dan output dengan baik. Hal ini menunjukkan bahwa fitur-fitur penting yang terkandung dalam data spektral berhasil dipelajari dan dimanfaatkan oleh model untuk menghasilkan prediksi yang mendekati kondisi sebenarnya.

Hasil tersebut memperkuat temuan pada tahap evaluasi model yang menunjukkan nilai R^2 sebesar 0.97. Tingginya tingkat kesesuaian antara nilai aktual dan nilai prediksi menunjukkan bahwa pendekatan *hybrid* yang digunakan mampu mengurangi kesalahan prediksi serta meningkatkan ketepatan estimasi kandungan nutrisi pakan ternak. Temuan ini juga mengindikasikan bahwa metode yang dikembangkan memiliki potensi untuk digunakan sebagai alternatif analisis nutrisi berbasis kecerdasan buatan yang lebih cepat dan efisien dibandingkan metode konvensional yang memerlukan pengujian laboratorium secara langsung.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model *hybrid Artificial Intelligence* yang mengombinasikan Autoencoder dan *Artificial Neural Network* (ANN) untuk melakukan simulasi spektrum *Near Infrared Reflectance* (NIR) dan prediksi kandungan nutrisi pakan ternak. Pendekatan yang digunakan mampu mempelajari hubungan antara data spektral dan parameter nutrisi secara efektif sehingga dapat digunakan sebagai alternatif dalam proses analisis nutrisi berbasis data. Hasil penelitian menunjukkan bahwa integrasi Autoencoder sebagai metode ekstraksi fitur dan ANN sebagai model prediksi mampu meningkatkan kemampuan model dalam menghasilkan prediksi yang mendekati nilai aktual.

Pengembangan model ini memberikan kontribusi dalam pemanfaatan teknologi kecerdasan buatan pada bidang peternakan, khususnya untuk mendukung analisis nutrisi yang lebih cepat, efisien, dan mudah diakses dibandingkan metode konvensional yang memerlukan pengujian

laboratorium secara langsung. Dengan demikian, pendekatan yang diusulkan memiliki potensi untuk mendukung pengembangan sistem nutrisi digital dan penerapan *precision feeding* pada sektor peternakan. Penelitian selanjutnya dapat dilakukan dengan menambah jumlah dataset, memperluas variasi bahan pakan, serta mengembangkan model menggunakan pendekatan deep learning lainnya untuk meningkatkan kemampuan generalisasi dan akurasi prediksi.

DAFTAR PUSTAKA

- [1] N. Q. Aini and A. C. Septaningsih, "Artificial Intelligence untuk Peningkatan Produktivitas Ternak: Pendekatan Inovatif dalam Peternakan," *Jurnal Ilmiah Peternakan Halu Oleo*, vol. 7, no. 1, pp. 9–17, Jan. 2025, doi: 10.56625/jipho.v7i1.234.
- [2] R. A. Anggraeni Kamid, L. Khotijah, and N. R. Kumalasari, "Analisis Keragaman Kualitas Nutrien Berbagai Pakan Ruminansia di Wilayah Indonesia," *Jurnal Ilmu Nutrisi dan Teknologi Pakan*, vol. 22, no. 1, pp. 14–22, Apr. 2024, doi: 10.29244/jintp.22.1.14-22.
- [3] C. Maduro Dias, H. Nunes, and A. Borba, "Near-Infrared Spectroscopy in Animal Nutrition: Historical Insights, Technical Principles, and Practical Applications," 2024, Multidisciplinary Digital Publishing Institute (MDPI). doi: 10.3390/analytica5040033.
- [4] R. Zahera, L. A. Sari, I. G. Permana, and Despal, "The use of near-infrared reflectance spectroscopy (NIRS) to predict dairy fibre feeds in vitro digestibility," in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing Ltd, Jan. 2022. doi: 10.1088/1755-1315/951/1/012100.
- [5] W. Zhang, L. C. Kasun, Q. J. Wang, Y. Zheng, and Z. Lin, "A Review of Machine Learning for Near-Infrared Spectroscopy," Dec. 01, 2022, MDPI. doi: 10.3390/s22249764.
- [6] C. Jiang, J. Zhao, Y. Ding, and G. Li, "Vis–NIR Spectroscopy Combined with GAN Data Augmentation for Predicting Soil Nutrients in Degraded Alpine Meadows on the Qinghai–Tibet Plateau," *Sensors*, vol. 23, no. 7, Apr. 2023, doi: 10.3390/s23073686.
- [7] X. Xin et al., "Combination of near-infrared spectroscopy with Wasserstein generative adversarial networks for rapidly detecting raw material quality for formula products," *Opt. Express*, vol. 32, no. 4, p. 5529, Feb. 2024, doi: 10.1364/oe.516341.
- [8] N. J. Palange et al., "Artificial intelligence-driven near-infrared spectrophotometry model for rapid quantification of anti-nutritional factors in soybean (*Glycine max.*)," *Discover Applied Sciences*, vol. 7, no. 6, Jun. 2025, doi: 10.1007/s42452-025-07235-3.
- [9] S. Wulandari, M. Adhyatma, D. Pantaya, A. Jayanegara, and R. A. Nurfitriani, "Near infrared spectroscopy for the quality control of rice bran," *Livestock and Animal Research*, vol. 20, no. 2, p. 210, Jul. 2022, doi: 10.20961/lar.v20i2.54353.
- [10] F. Yuwita, I. Ifmalinda, and M. Makky, "Prediction of Caffeine and Protein of Arabica Coffee Beans Using Near Infrared Spectroscopy (NIRS)," *Jurnal Teknik Pertanian Lampung (Journal of Agricultural Engineering)*, vol. 12, no. 4, p. 852, Dec. 2023, doi: 10.23960/jtep-l.v12i4.852-862.
- [11] M. E. Hossain, M. A. Kabir, L. Zheng, D. L. Swain, S. McGrath, and J. Medway, "Near-infrared spectroscopy for analysing livestock diet quality: A systematic review," *Heliyon*, vol. 10, no. 22, Nov. 2024, doi: 10.1016/j.heliyon.2024.e40016.

- [12] S. Tkatek, S. Amassmir, A. Belmzoukia, and J. Abouchabaka, "Predictive fertilization models for potato crops using machine learning techniques in Moroccan Gharb region," *International Journal of Electrical and Computer Engineering*, vol. 13, no. 5, pp. 5942–5950, Oct. 2023, doi: 10.11591/ijece.v13i5.pp5942-5950.
- [13] Y. L. R. Tulung, A. F. Pendong, J. J. M. Londok, C. A. Rahasia, and S. A. E. Moningkey, "Ilmu Nutrisi Ternak dan Pengetahuan Bahan Pakan," pp. 1–69, 2022.
- [14] J. Ha, M. Kambe, and J. Pe, *Data Mining: Concepts and Techniques*. 2011. doi: 10.1016/C2009-0-61819-5.
- [15] A. Ashfahani, M. Pratama, E. Lughofer, and Y. S. Ong, "DEV DAN: Deep evolving denoising autoencoder," *Neurocomputing*, vol. 390, pp. 297–314, 2020, doi: 10.1016/j.neucom.2019.07.106.
- [16] A. Manconi, G. Armano, M. Gnocchi, and L. Milanesi, "A Soft-Voting Ensemble Classifier for Detecting Patients Affected by COVID-19," *Applied Sciences (Switzerland)*, vol. 12, no. 15, 2022, doi: 10.3390/app12157554.
- [17] S. Mehmood and U. M. Mataram, "Parameter Tuning in Backpropagation Neural Networks :," *JTIK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 11, no. 1, pp. 110–124, 2025, doi: 10.33480/jitk.v11i1.6484.
- [18] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput. Sci.*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.