

Prediksi Kadar Air Produk Pertanian Berbasis *Machine Learning*: Sebuah Tinjauan Sistematis

Bryan Anderson Napitupulu

Informatika, Universitas Jember, Jember
*232410103044@mail.unej.ac.id

Abstrak— Prediksi kadar kelembaban (*moisture content/MC*) pada produk pertanian merupakan aspek krusial dalam optimasi proses panen, pengeringan, dan penyimpanan untuk menjaga kualitas dan mengurangi kerugian pascapanen. Metode konvensional sering bersifat destruktif dan lambat, sehingga *machine learning* (ML) seperti *artificial neural network* (ANN) dan *support vector regression* (SVR) semakin banyak digunakan untuk prediksi non-destruktif. Dari 51 kandidat paper yang diidentifikasi melalui pencarian sistematis, *Systematic Literature Review* (SLR) ini meninjau 32 studi terkini (2017-2025) yang memanfaatkan ML untuk prediksi MC pada berbagai tanaman, termasuk gandum, kopi, apel, dan padi, sementara 19 paper dieksklusi karena tidak memenuhi kriteria. Mengikuti panduan PRISMA, paper-paper dipilih dari database seperti Scopus, IEEE Xplore, dan MDPI berdasarkan kriteria inklusi (studi ML untuk prediksi MC pada produk pertanian) dan eksklusi (non-ML atau non-pertanian). Hasil menunjukkan ANN mendominasi (12 paper), diikuti SVR (7) dan random forest (7), dengan input utama fitur gambar (13 paper) dan data sensor (10 paper). Performa umum mencapai $R^2 > 0.90$ dan RMSE $< 1\%$. Tren menunjukkan peningkatan penggunaan deep learning (LSTM, CNN) dan integrasi IoT untuk prediksi real-time, meskipun gap seperti kurangnya deployment lapangan dan validasi cross-varietas masih ada. SLR ini menyimpulkan bahwa ML efektif untuk prediksi MC, mendukung pertanian pintar dan mengurangi kerugian pascapanen global (14-30% menurut FAO), serta merekomendasikan penelitian lanjutan pada hybrid model dan skalabilitas untuk petani kecil di negara berkembang.

Kata Kunci— Deep Learning; Kadar Air; Machine Learning; Pengeringan; Prediksi; Produk Pertanian; Tinjauan Sistematis.

DOI: 10.22441/jitkom.v10i2.001

Article History:

Received: Jan 9, 2026

Revised: Mar 12, 2026

Accepted: Mar 16, 2026

Published: Jul 17, 2026

I. PENDAHULUAN

Kadar kelembaban (*moisture content/MC*) pada produk pertanian seperti biji-bijian, buah, dan sayuran memainkan peran vital dalam menentukan kualitas, umur simpan, dan nilai ekonomi [1][2][3][4]. MC yang tidak optimal dapat menyebabkan kerusakan mikrobiologis, penurunan nutrisi, atau kerugian pascapanen yang signifikan, terutama di negara-negara berkembang di mana pertanian menjadi tulang punggung ekonomi [5][6][7]. Menurut data FAO (2023), kerugian pascapanen global mencapai 14% untuk biji-bijian dan 20-30% untuk buah-buahan, sebagian besar karena pengendalian MC yang buruk selama pengeringan dan penyimpanan [8][9][10]. Metode tradisional seperti pengukuran gravimetri atau oven drying bersifat destruktif, memakan waktu, dan tidak cocok bagi pemantauan real-time di skala industri atau petani kecil [11][12][13].

Kemajuan teknologi *machine learning* (ML) menawarkan solusi non-destruktif dan akurat bagi prediksi MC, dengan memanfaatkan data sensor, gambar, atau spektrum guna membangun model prediktif [14][15][16]. Studi terkini menunjukkan ML seperti ANN dan SVR mampu mencapai akurasi tinggi ($R^2 > 0.95$) dalam memprediksi MC pada berbagai tanaman, sehingga mendukung pertanian presisi dan mengurangi limbah [17][18][19]. Namun, literatur yang ada masih terfragmentasi, dengan fokus pada tanaman spesifik atau metode tunggal, tanpa tinjauan sistematis yang komprehensif tentang tren, gap, dan aplikasi potensial [21].

Mengisi kekosongan tersebut, SLR ini difokuskan pada pertanyaan-pertanyaan penelitian utama, yaitu: Apa metode ML yang paling umum dan efektif bagi prediksi MC pada produk pertanian? Apa fitur input, performa, dan aplikasi utama dari studi-studi tersebut? Apa tren terkini, gap, dan rekomendasi bagi penelitian masa depan di bidang ini? Tujuan SLR ini adalah meringkas 32 studi terpilih (2017-2025) yang membahas prediksi MC menggunakan ML, mengidentifikasi tren seperti peningkatan deep learning dan integrasi IoT, serta mengusulkan arah penelitian guna meningkatkan skalabilitas di konteks pertanian tropis [21][22][23][24][25][26][27][28][29][30][31]. SLR ini diharapkan memberikan panduan bagi peneliti, petani, dan industri dalam mengadopsi teknologi ML pada pengelolaan MC, sehingga mendukung ketahanan pangan dan efisiensi produksi [32].

II. LITERATURE REVIEW

Perkembangan mutakhir dalam teknologi prediksi kadar air produk pertanian menunjukkan tren integrasi yang kuat antara IoT, pengolahan citra digital, dan algoritma kecerdasan buatan tingkat lanjut. Dalam optimasi pascapanen, implementasi sistem monitoring *real-time* berbasis IoT dan *machine learning* (ML) telah sukses diterapkan untuk mengoptimalkan proses pelayuan pada komoditas teh [21]. Pendekatan berbasis fitur visual juga berkembang pesat, salah satunya adalah penentuan kadar air jagung menggunakan transformasi ruang warna RGB ke HSV dengan dukungan *Artificial Neural Network* (ANN) [22].

Sementara itu, arsitektur *deep learning* yang lebih kompleks seperti *Long Short-Term Memory* (LSTM) dimanfaatkan untuk mendeteksi kadar air irisan kentang secara *real-time* selama proses pengeringan melalui parameter morfometri gambar [23]. Selain metode visual, pengujian non-destruktif cepat pada komoditas gandum juga dikembangkan dengan memanfaatkan karakteristik dielektrik yang dipadukan dengan ML [24].

Di sisi lain, aplikasi ML mencakup pemodelan prediktif untuk sistem pengeringan bertenaga surya pada tanaman bit [25], bahkan meluas hingga aspek manajemen peternakan seperti prediksi kelembaban pada kotoran ayam menggunakan data hiperspektral dan ML [26]. Untuk skala petani kecil, penggunaan analisis gambar dari *smartphone* yang diproses dengan ML terbukti efektif menilai kadar air biji-bijian guna menentukan waktu panen yang paling optimal [27]. Lebih lanjut, integrasi analisis citra dan ML digunakan untuk memprediksi kelembaban sekaligus mengevaluasi kualitas penampilan pada pra-perlakuan pengeringan buah kiwi [28]. Pada skala industri yang lebih masif, teknologi *Deep Learning* diterapkan untuk mengontrol proses pengeringan padi secara prediktif pada sistem *counter-flow* multistate [29]. Terakhir, akurasi prediksi ditingkatkan melalui model *stacking ensemble learning* untuk memantau kadar air daun cerutu selama proses *air-curing* [30], serta pengoptimalan model prediksi *online* berbasis ANN untuk pengeringan padi pada sistem pompa panas sirkulasi suhu rendah [31].

III. METODOLOGI PENELITIAN

Penelitian ini merupakan Systematic Literature Review (SLR) yang mengikuti panduan PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) guna menjamin transparansi dan reproduisibilitas proses seleksi literatur [20]. Pencarian literatur dilakukan secara sistematis pada database Scopus, IEEE Xplore, MDPI, dan Google Scholar. Proses tersebut mencakup strategi pencarian, kriteria inklusi serta eksklusi, dan tahapan seleksi data yang dirinci pada subbab berikut.

A. Strategi Pencarian

Pencarian literatur dilaksanakan secara sistematis melalui pangkalan data Scopus, IEEE Xplore, Google Scholar, dan ScienceDirect. Pemilihan keempat sumber tersebut didasarkan pada reputasi tinggi publikasi di bidang teknik pangan, instrumentasi, dan pembelajaran mesin (*machine learning*) untuk aplikasi pertanian. Penyusunan kata kunci mengacu pada tiga konsep utama yang dihubungkan menggunakan operator Boolean, yaitu:

((*"machine learning"* OR *"deep learning"* OR *"artificial neural network"* OR *"random forest"* OR *"SVM"* OR *"support vector machine"* OR *"neural network"* OR *"xgboost"* OR *"catboost"* OR *"lstm"* OR *"cnn"*) AND (*"moisture content"* OR *"moisture prediction"* OR *"water content"* OR *"moisture ratio"* OR *"drying kinetics"*) AND (*"agricultural product"* OR *"crop"* OR *"grain"* OR *"seed"* OR *"drying"* OR *"post-harvest"* OR *"coffee"* OR *"tea"* OR *"cocoa"* OR *"rice"* OR *"wheat"* OR *"corn"* OR *"apple"* OR *"fruit"*))

Batasan rentang waktu publikasi yang ditetapkan adalah mulai Januari 2015 hingga November 2025. Penentuan rentang waktu tersebut didasari oleh beberapa pertimbangan berikut:

- Tahun 2015 ditetapkan sebagai titik awal karena peningkatan signifikan jumlah publikasi *machine learning* pada bidang pertanian pascapanen terjadi pada tahun tersebut. Kondisi ini didorong oleh kemunculan kerangka kerja (*framework*) *deep learning* modern, seperti TensorFlow, Keras, dan PyTorch, yang mempermudah implementasi ANN, CNN, dan LSTM untuk pengolahan data sensor maupun citra.
- Periode 2015–2025 mencakup kurun waktu sepuluh tahun terakhir. Hal ini bertujuan agar hasil tinjauan tetap relevan dan mutakhir terhadap perkembangan teknologi, termasuk kemunculan XGBoost, LightGBM, *stacking ensemble*, serta integrasi Internet of Things (IoT) pada rentang tahun 2023–2025.
- Batas atas bulan November 2025 memungkinkan pencakupan publikasi terbaru yang sedang berkembang pesat, seperti *deep learning hybrid*, *multimodal fusion*, dan TinyML untuk perangkat edge. Pendekatan ini memastikan SLR mencerminkan teknologi terkini (*state-of-the-art*) hingga masa penulisan berlangsung.

Penerapan strategi pencarian tersebut menghasilkan total 51 kandidat artikel sebelum tahap penyaringan (*screening*) dilakukan.

B. Kriteria Inklusi dan Eksklusi

Penentuan kriteria inklusi dan eksklusi dilakukan untuk memastikan bahwa artikel yang dianalisis memiliki relevansi langsung dengan tujuan kajian, yaitu prediksi kadar air pada produk pertanian menggunakan metode *machine learning* atau *deep learning*. Kriteria inklusi digunakan untuk memilih artikel yang sesuai dengan ruang lingkup penelitian, sedangkan kriteria eksklusi digunakan untuk menyingkirkan artikel yang tidak memenuhi standar kelayakan. Rincian kedua kelompok kriteria tersebut ditampilkan pada Tabel 1.


Tabel 1. Kriteria Inklusi dan Eksklusi

Kategori	Kode	Kriteria
Inklusi	I1	Artikel merupakan studi penelitian primer (bukan review atau survei).
	I2	Artikel menerapkan metode <i>machine learning</i> (ML) atau <i>deep learning</i> (DL) untuk tujuan prediksi.
	I3	Artikel membahas prediksi kadar air (<i>moisture content</i>).
	I4	Objek penelitian merupakan produk pertanian atau hasil panen, seperti kopi, teh, padi, jagung, atau buah.

Kategori	Kode	Kriteria
	I5	Artikel tersedia dalam bentuk full-text dan dapat diakses dalam Bahasa Inggris atau Indonesia.
Eksklusi	E1	Artikel berupa review, survei, atau meta-analisis.
	E2	Artikel hanya membahas kontrol (misalnya fuzzy logic control), monitoring tanpa ML (misalnya IoT saja), atau klasifikasi (misalnya identifikasi jenis biji kopi).
	E3	Artikel membahas kadar air pada objek non-pertanian (misalnya beton) atau kelembapan tanah (soil moisture).
	E4	Artikel tidak tersedia dalam bentuk full paper, seperti hanya berupa abstrak atau presentasi.

C. Proses Seleksi dan Ekstraksi Data

Alur seleksi mengikuti PRISMA dalam dua tahap. Tahap 1 (Screening Judul & Abstrak): Jumlah total paper yang ditemukan dari database berjumlah 51. Paper yang ditolak (exclude) setelah membaca judul/abstrak (karena tidak relevan, review, dll.) berjumlah 7. Tahap 2 (Screening Full-Text): Jumlah paper yang lolos untuk dibaca full-text berjumlah 44. Paper yang ditolak (exclude) setelah membaca full-text (misal: ternyata sistem kontrol, kelembapan tanah, dll.) berjumlah 12. Hasil akhir: Jumlah paper final yang lolos dan dimasukkan ke dalam sintesis (analisis) berjumlah 32. Dari 32 paper tersebut, data diekstraksi secara sistematis. Informasi yang diekstrak yaitu penulis, tahun, objek penelitian, metode Machine Learning yang digunakan, jenis input data/sensor, dan hasil kinerja yang dilaporkan (R^2 , RMSE, MAE). Diagram alir PRISMA dapat dilihat pada Gambar 1.



Gambar 1. Diagram Alir PRISMA

D. Quality Assessment (QA)


Proses penilaian kualitas (Quality Assessment) diterapkan untuk memastikan bahwa seluruh studi yang dianalisis memiliki validitas metodologis yang memadai. Kriteria penilaian meliputi tiga aspek utama:

1. Kejelasan metode penelitian, mencakup deskripsi dataset, teknik praproses, dan algoritma ML yang digunakan.
2. Ketersediaan metrik evaluasi, sekurang-kurangnya R^2 , RMSE, MAE, atau korelasi.
3. Relevansi konteks, yakni kesesuaian antara objek penelitian dan topik prediksi kadar air pada produk pertanian.

Penilaian dilakukan secara biner (memenuhi/tidak memenuhi). Studi yang tidak memenuhi sedikitnya dua kriteria dieliminasi pada tahap seleksi lanjutan. Sebanyak 32 dari 44 studi memenuhi seluruh kriteria dan digunakan dalam sintesis akhir. Mekanisme QA ini memastikan bahwa analisis SLR berbasis pada penelitian dengan metodologi yang jelas dan pelaporan hasil yang transparan.

IV. HASIL DAN ANALISA

Analisis yang dilakukan terhadap 32 artikel terpilih (included) yang diterbitkan antara tahun 2017 hingga 2025 menunjukkan perkembangan yang signifikan dalam penerapan machine learning (ML) untuk memprediksi kadar kelembaban (moisture content/MC) pada produk pertanian. Jika melihat dari distribusi tahunan publikasi, terjadi peningkatan yang cukup tajam yaitu dari hanya 1 artikel pada tahun 2017 meningkat menjadi 10 artikel pada tahun 2025, dengan percepatan yang jelas terlihat sejak tahun 2023. Tren ini mencerminkan semakin tingginya minat terhadap integrasi teknologi digital dalam pengendalian kualitas pascapanen, sejalan dengan kebutuhan global untuk mengurangi kerugian akibat pengelolaan kelembaban yang tidak optimal. Diagram distribusi tahunan publikasi dapat dilihat pada Gambar 2.



Gambar 2. Distribusi Tahunan

A. Metode ML Paling Umum dan Efektif

Metode Artificial Neural Network (ANN) beserta turunannya seperti MLP, DNN, LSTM, dan CNN menjadi pendekatan paling dominan dengan digunakan pada 13 artikel atau 40,6% dari total studi. Posisi kedua ditempati Support Vector Regression (SVR) yang muncul pada 8 artikel (25%), diikuti Random Forest (RF) pada 7 artikel (21,9%). Pendekatan

ensemble seperti XGBoost, CatBoost, dan stacking mulai menonjol pada studi-studi terbaru antara tahun 2023 hingga 2025. ANN terbukti paling efektif dalam menangani data non-linear dan deret waktu, dengan rata-rata R^2 mencapai 0,96, sementara SVR unggul pada dataset kecil (kurang dari 500 sampel) dan RF konsisten pada analisis fitur citra. Tabel 2 di bawah ini merangkum distribusi metode ML secara lengkap.

Tabel 2. Distribusi Metode ML

Metode ML	Jumlah Artikel	Persentase (%)	Contoh Studi
ANN & turunan (MLP, DNN, LSTM, CNN)	14	43,75	Zuo et al. (2025)
SVR / GWO-SVM	8	25	Abdollahpour et al. (2020)
Random Forest	8	25	Keramat-Jahromi et al. (2021)
Ensemble (XGBoost, Stacking)	6	18,75	Xing et al. (2025)
PLS/PLSR	5	15,6	Lozano et al. (2025)

B. Fitur Input, Performa, dan Aplikasi Utama

Fitur input yang digunakan dalam studi-studi ini terbagi menjadi tiga kategori utama. Pertama, fitur berbasis citra seperti warna RGB, HSV, parameter morfometri, hingga data hiperspektral digunakan pada 15 artikel dan mendominasi pada komoditas buah dan biji kakao. Kedua, data sensor fisik seperti kelembapan relatif (RH), suhu, sifat dielektrik, dan gelombang mikro muncul pada 12 artikel, terutama untuk biji-bijian dan padi. Ketiga, data kinetika pengeringan meliputi waktu, suhu, dan laju penguapan ditemukan pada 8 artikel, umumnya terkait proses pengeringan kopi dan umbi-umbian. Pendekatan multimodal (gabungan citra dan sensor) yang diterapkan pada 5 studi terbaru menghasilkan performa terbaik dengan R^2 di atas 0,98. Performa model secara keseluruhan sangat baik, dengan rata-rata R^2 sebesar $0,94 \pm 0,04$, RMSE $0,88 \pm 0,52\%$, dan MAE $0,63 \pm 0,31\%$. Sebanyak 70% studi melaporkan RMSE di bawah 1% untuk MC di bawah 40% (basis kering). Tabel 3 di bawah menyajikan ringkasan performa model dari 32 studi.

Tabel 3. Ringkasan Performa Model

No	Tahun	Komoditas	Metode Utama	Input Utama	Performa Terbaik	Studi
1	2017	Biji kopi hijau	PLSR	Diffuse reflectance NIR (1155–2249 nm)	RMSEP = 0.57–0.80 %	Adnan et al., 2017
2	2018	Teh	ANN (NARX)	RH dan suhu inlet/outlet trough	Maximum mean error = –3.6 %	Das et al., 2018
3	2020	Gandum	MLP, SVR	Hari setelah tanam, suhu, RH, angin, curah hujan	$R^2 = 0.92$, RMSE = 2.09 % (MLP)	Abdollahpour et al., 2020
4	2020	Jagung manis	DNN	Swept microwave 2.6–3 GHz (21 frekuensi)	$R^2 = 0.980$, RMSE = 2.023 %, MAE = 1.556 %	Zhang et al., 2020
5	2021	Padi	Random Forest	RSSI ZigBee + UHF RFID	Akurasi > 98 % (2 fitur)	Azmi et al., 2021
6	2021	Padi	SVR	8 indeks warna dari citra smartphone + PCA	MAE = 1.23 %	Yang et al., 2021
7	2021	Kurma	Random Forest, kNN	Atribut warna online + kondisi lingkungan	$R^2 = 0.976$ (RF)	Keramat-Jahromi et al., 2021
8	2022	Jagung	ANN feedforward backpropagation	Fitur statistik HSV dari citra RGB	Max difference = 4.35 % vs oven	Rivero et al., 2022
9	2022	Nanas	ANN	Coating + suhu 50–80 °C	Topology 3-14-14-1 (MR), 3-7-7-1 (DR) – terbaik	Meerasri et al., 2022
10	2022	Apel	RF, MLP, kNN	Waktu, MC, Deff	$R > 0.8722$ (DR), $R > 0.8500$ (MR)	Çetin, 2022
11	2023	Bit	CatBoost	Suhu, ketebalan, waktu	$R^2 = 0.9999$, MSE = 3.15×10^{-6} , MAE = 0.02	Tagnamas et al., 2023
12	2023	Kentang	LSTM	Parameter morfometri citra	$R^2 = 0.977$, RMSE = 0.0461	Sabat et al., 2023


No	Tahun	Komoditas	Metode Utama	Input Utama	Performa Terbaik	Studi
13	2023	Apel (Pink Lady)	ANN	VIS-NIR HSI 386–1028 nm	R = 0.868, RMSE = 0.756 (MC)	Kavuncuoğlu et al., 2023
14	2023	Aprikot	MLP, RF	Data dryer CV/MW/IR/hybrid	R = 0.9985 (MR, MLP), R = 0.9912 (MC, RF)	Kaveh et al., 2023
15	2023	Tembakau	CNN	Warna, bentuk, tekstur citra	R ² = 0.9044, akurasi 87.34 %	Hao et al., 2023
16	2024	Kakao	SVR (RBF), Polynomial, DTR	Fitur warna RGB/HSV/Lab*/YCbCr	R ² = 0.94–0.96, RMSE = 3.85–4.81 %	Ako et al., 2024
17	2024	Gandum	GWO-SVM	Kapasitansi, konduktansi, suhu (1–10 MHz)	Rp ² = 0.998, RMSEP = 0.416 %, RPD = 20.4	Song, 2024
18	2024	Kuskus	ANN Levenberg-Marquardt	Waktu, RH, suhu	R ² = 0.99999, MSE = 8.2173×10^{-4}	Hmazi et al., 2024
19	2024	Teh	XGBoost	Data IoT (suhu, RH, MC)	MAE = 0.99, R ² = 0.92	Rajkumar et al., 2024
20	2024	Padi	LSTM-MPC	MC inlet/outlet, kecepatan alir	MAE = 0.190 % d.b.	Zhang et al., 2024
21	2024	Kiwi	PLS, RF	Fitur HSV + morfologi citra	Prediksi MR akurat (optimal 60 °C, 4 mm, ultrasonic)	Yu et al., 2024
22	2024	Kakao	MLPRegressor + Classifier	Model Adrover + Brusselator	Akurasi 78–82 %	Zárate-Montero et al., 2024
23	2025	Apel	Multi-modal fusion	Tabular + citra irisan	RMSE turun 15.2–24.2 %	Li et al., 2025
24	2025	Padi	ANN + RI/Sobol	Data multi-dimensi akuisisi	R ² = 0.969/0.966, MSE $\approx 6 \times 10^{-3}$	Zuo et al., 2025
25	2025	Kotoran ayam	XGBoost	Hiperspektral raw	R ² = 0.97, RMSE = 1.01	Tulsi et al., 2025
26	2025	Tomat hijau	Hybrid CNN-LSTM	Data pengeringan + model matematis	R ² > 0.998, RMSE = 0.01268–0.01345	Recio-Colmenares et al., 2025
27	2025	Berbagai biji-bijian	SVR	Dielektrik, frekuensi, density	MAE terendah 8–12 GHz	Leblanc et al., 2025
28	2025	Lemon Tahiti	ANN	Data kinetika endocarp/epicarp	R ² > 0.9979 (endocarp), > 0.9989 (epicarp)	Camilo et al., 2025
29	2025	Tembakau	Stacking ensemble	Warna + tekstur citra depan/belakang	R ² test = 0.989	Xing et al., 2025
30	2025	Kopi	PLS	Spektrum FT-NIR	R ² = 0.99, SEP = 0.34	Lozano et al., 2025
31	2025	Kopi	SVM	Data isotherms DDI 25–45 °C	MRE < 1 %, R ² > 99 %	Collazos-Escobar et al., 2025
32	2025	Jujube	MLP, RF	Vis-NIR + indeks vegetasi	R > 0.999 (MR)	Günaydın et al., 2025

Aplikasi utama meliputi prediksi real-time selama proses pengeringan (18 artikel), estimasi MC saat panen (9 artikel), serta pengendalian kualitas selama penyimpanan (5 artikel). Integrasi IoT pada 6 studi memungkinkan pemantauan jarak jauh, sementara penggunaan citra smartphone pada 4 artikel terbaru mendukung adopsi teknologi oleh petani kecil di daerah terpencil.

C. Tren Terkini, Gap, dan Rekomendasi

Berdasarkan analisis studi yang terpilih, metode Machine Learning Klasik (seperti ANN, RF, dan SVR) teridentifikasi

masih mendominasi dalam penelitian prediksi kadar air produk pertanian, dengan jumlah studi yang signifikan setiap tahunnya. Namun, di samping dominasi tersebut, beberapa tren teknologi terkini juga mulai menunjukkan peningkatan dan relevansi yang jelas. Grafik tren teknologi terkini ditunjukkan pada Gambar 3.



Gambar 3. Tren Teknologi

Pertama, penggunaan Deep Learning, khususnya LSTM dan CNN, semakin menonjol pada data deret waktu kinetika pengeringan, seringkali menghasilkan R^2 di atas 0,98. Meskipun secara absolut jumlahnya masih belum sebanyak ML Klasik, peningkatannya dalam beberapa tahun terakhir mengindikasikan adopsi yang meluas. Kedua, integrasi IoT dengan ML memungkinkan prediksi real-time dan pengambilan keputusan otomatis, terutama terlihat pada studi yang terkait dengan proses withering teh dan pengeringan padi. Ketiga, pendekatan multimodal yang menggabungkan citra dan data sensor menunjukkan potensi untuk menghasilkan akurasi tertinggi, meskipun saat ini jumlah studi yang mengadopsi pendekatan ini masih terbatas. Keempat, model hybrid yang mengintegrasikan persamaan fisik (seperti model Page atau Lewis) dengan ML mulai muncul, terutama untuk meningkatkan interpretabilitas hasil prediksi.

Meski demikian, terdapat beberapa celah penelitian yang signifikan. Hanya 8 dari 32 artikel yang melaporkan validasi di lapangan (kebun atau peternakan), sementara mayoritas masih berbasis eksperimen laboratorium. Studi pada tanaman tropis lokal seperti kelapa sawit, cengkeh, atau durian belum ditemukan sama sekali. Prediksi parameter tambahan seperti pH atau warna sering kali gagal ($R < 0,50$) ketika digabungkan dengan MC, menunjukkan keterbatasan fitur input. Selain itu, sebagian besar model masih terlalu berat untuk dijalankan pada perangkat edge, sehingga sulit diadopsi oleh petani kecil.

Berdasarkan temuan tersebut, beberapa rekomendasi disampaikan untuk penelitian mendatang. Pertama, kembangkan model ringan berbasis TinyML yang dapat dijalankan pada perangkat IoT berbiaya rendah. Kedua, lakukan validasi lintas musim, varietas, dan wilayah khususnya di Indonesia guna memastikan generalisasi model. Ketiga, integrasikan teknologi blockchain untuk menciptakan sistem *traceability* MC dari panen hingga pasar. Keempat, eksplorasi *federated learning* dapat menjadi solusi untuk melatih model secara kolaboratif tanpa melanggar privasi data petani.

V. KESIMPULAN

Systematic Literature Review (SLR) ini mengidentifikasi dan menganalisis 32 studi primer terkait prediksi kadar air (moisture content/MC) pada produk pertanian menggunakan metode machine learning (ML) dan deep learning (DL).

Berdasarkan sintesis yang dilakukan, dapat disimpulkan bahwa ML terbukti efektif sebagai pendekatan non-destruktif dalam memprediksi MC pada berbagai komoditas pertanian, dengan performa umum mencapai R^2 di atas 0,90 dan RMSE di bawah 1%. Metode yang paling dominan ialah ANN, diikuti SVR dan Random Forest, sementara pendekatan DL seperti LSTM dan CNN menunjukkan peningkatan signifikan dalam beberapa tahun terakhir terutama untuk data deret waktu dan citra.

Fitur input yang paling banyak digunakan mencakup citra warna dan spektral, data sensor fisik, serta parameter kinetika pengeringan. Pendekatan multimodal terbukti memberikan akurasi tertinggi, meskipun adopsinya masih terbatas. Selain itu, tren integrasi IoT pada beberapa studi menunjukkan potensi besar bagi implementasi sistem pemantauan dan prediksi MC secara real-time di lapangan.

Meskipun demikian, penelitian di bidang ini masih menghadapi sejumlah keterbatasan: validasi lapangan masih minim, studi pada komoditas tropis lokal relatif sedikit, serta kompleksitas model sering kali tidak sesuai untuk perangkat edge yang digunakan petani kecil. Oleh karena itu, penelitian selanjutnya direkomendasikan untuk mengembangkan model ringan berbasis TinyML, melakukan validasi lintas lokasi dan varietas, serta mengeksplorasi integrasi teknologi seperti federated learning dan blockchain guna meningkatkan generalisasi, keamanan, dan penerapan sistem prediksi MC secara luas.

DAFTAR PUSTAKA

- [1] Adnan, D. Von Hörsten, E. Pawelzik, and A. D. Mörlein, "Rapid prediction of moisture content in intact green coffee beans using near infrared spectroscopy," *Foods*, vol. 6, no. 5, p. 38, May 2017, doi: 10.3390/foods6050038.
- [2] S. Abdollahpour, A. Kosari-Moghaddam, and M. Bannayan, "Prediction of wheat moisture content at harvest time through ANN and SVR modeling techniques," *Information Processing in Agriculture*, vol. 7, no. 4, pp. 500–510, Jan. 2020, doi: 10.1016/j.inpa.2020.01.003.
- [3] F. A. Hmazi, H. Bagar, A. Madani, and I. Mrani, "A novel approach for modelling and predicting the drying kinetics of couscous grains using artificial neural networks," *Journal of Food Composition and Analysis*, vol. 132, p. 106301, May 2024, doi: 10.1016/j.jfca.2024.106301.
- [4] J. E. Ako, C. E. N'zi, and K. Kpalma, "Cocoa beans moisture content prediction using Machine Learning Model based on the color image features," *Computer Science Research Notes*, Jan. 2024, doi: 10.24132/csrn.3401.25.
- [5] N. Azmi *et al.*, "RF-Based moisture content determination in rice using machine learning techniques," *Sensors*, vol. 21, no. 5, p. 1875, Mar. 2021, doi: 10.3390/s21051875.
- [6] M. O. Camilo, R. F. Carvalho, A. B. S. Costa, E. FC Junior, A. O. S. Costa, and R. C. Sousa, "Drying kinetic for moisture content prediction of peels Tahiti lemon (*Citrus latifolia*): Approach by machine learning and optimization - genetic algorithms and nonlinear programming," *South African Journal of Chemical Engineering*, vol. 51, pp. 136–152, Nov. 2024, doi: 10.1016/j.sajce.2024.10.005.
- [7] N. Çetin, "Machine Learning Based Estimation Of Drying Characteristics Of Apple Slices," *CURRENT TRENDS IN NATURAL SCIENCES*, vol. 11, no. 22, pp. 44–52, Dec. 2022, doi: 10.47068/ctns.2022.v11i22.006.
- [8] G. A. Collazos-Escobar, N. Gutiérrez-Guzmán, H. A. Váquiro, J. V. García-Pérez, and J. A. Cárcel, "Analysis of machine learning algorithms for the computer simulation of moisture sorption isotherms of coffee beans," *Food and Bioprocess Technology*, vol. 18, no. 6, pp. 5419–5430, Feb. 2025, doi: 10.1007/s11947-025-03785-x.
- [9] N. Das, K. Kalita, P. K. Boruah, and U. Sarma, "Prediction of moisture loss in withering process of tea manufacturing using artificial neural

- network," *IEEE Transactions on Instrumentation and Measurement*, vol. 67, no. 1, pp. 175–184, Oct. 2017, doi: 10.1109/tim.2017.2754818.
- [10] J. Zhang, D. Du, Y. Bao, J. Wang, and Z. Wei, "Development of Multifrequency-Swept Microwave sensing system for moisture measurement of sweet corn with deep neural network," *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 9, pp. 6446–6454, Feb. 2020, doi: 10.1109/tim.2020.2972655.
- [11] S. Günaydin, N. Çetin, C. Sağlam, K. Sacilik, and A. Jahanbakhshi, "Comparative analysis of visible and near-infrared (Vis-NIR) spectroscopy and prediction of moisture ratio using machine learning algorithms for jujube dried under different conditions," *Applied Food Research*, vol. 5, no. 1, p. 100699, Jan. 2025, doi: 10.1016/j.afres.2025.100699.
- [12] Y. Hao et al., "Moisture content monitoring of cigar leaves during drying based on a Convolutional Neural Network," *International Agrophysics*, vol. 37, no. 3, pp. 225–234, Jun. 2023, doi: 10.31545/intagr/165775.
- [13] E. Kavuncuoğlu, N. Çetin, B. Yildirim, M. Nadimi, and J. Paliwal, "Exploration of machine learning algorithms for pH and moisture estimation in Apples using VIS-NIR Imaging," *Applied Sciences*, vol. 13, no. 14, p. 8391, Jul. 2023, doi: 10.3390/app13148391.
- [14] M. Kaveh, N. Çetin, E. Khalife, Y. Abbaspour-Gilandeh, M. Sabouri, and F. Sharifian, "Machine learning approaches for estimating apricot drying characteristics in various advanced and conventional dryers," *Journal of Food Process Engineering*, vol. 46, no. 12, Oct. 2023, doi: 10.1111/jfpe.14475.
- [15] M. Keramat-Jahromi, S. S. Mohtasebi, H. Mousazadeh, M. Ghasemi-Varnamkhasti, and M. Rahimi-Movassagh, "Real-time moisture ratio study of drying date fruit chips based on on-line image attributes using kNN and random forest regression methods," *Measurement*, vol. 172, p. 108899, Dec. 2020, doi: 10.1016/j.measurement.2020.108899.
- [16] A. P. LeBlanc, S. Trabelsi, K. Rasheed, and J. Miller, "Machine learning algorithms for nondestructive sensing of moisture content in grain and seed," *IEEE Open Journal of Instrumentation and Measurement*, vol. 4, pp. 1–14, Jan. 2025, doi: 10.1109/ojim.2025.3568080.
- [17] S. Li and C. Shao, "Multi-modal data fusion for moisture content prediction in apple drying," *Manufacturing Letters*, vol. 44, pp. 1316–1325, Aug. 2025, doi: 10.1016/j.mfglet.2025.06.151.
- [18] K. S. O. Lozano, A. F. B. Monje, and N. G. Guzman, "Predictive model of moisture content in dry parchment coffee beans using near-infrared spectroscopy (FT-NIR)," *Coffee Science*, vol. 20, pp. 1–9, Jan. 2025, doi: 10.25186/v20i.2289.
- [19] J. Meerasri and R. Sothornvit, "Artificial neural networks (ANNs) and multiple linear regression (MLR) for prediction of moisture content for coated pineapple cubes," *Case Studies in Thermal Engineering*, vol. 33, p. 101942, Mar. 2022, doi: 10.1016/j.csite.2022.101942.
- [20] M. J. Page et al., "The PRISMA 2020 statement: an updated guideline for reporting systematic reviews," *BMJ*, vol. 372, p. n71, Mar. 2021, doi: 10.1136/bmj.n71.
- [21] N. B. Rajkumar, "IOT-Enabled Real-Time Monitoring and Machine Learning-Based prediction system for optimizing tea withering process," *Communications on Applied Nonlinear Analysis*, vol. 31, no. 8s, pp. 56–86, Sep. 2024, doi: 10.52783/cana.v31.1457.
- [22] J. B. L. Rivero, R. D. C. Dela Cruz, M. F. M. Lomabao, N. B. Linsangan, J. R. Balbin and R. A. Juanatas, "Moisture Content Determination of Corn Using Red-Green-Blue to Hue-Saturation-Value Color Space with Artificial Neural Network," *2022 IEEE 14th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)*, Boracay Island, Philippines, 2022, pp. 1–5, doi: 10.1109/HNICEM57413.2022.10109463.
- [23] M. Sabat, N. Kotwaliwale, and P. S. Shelake, "Real-time determination of moisture content of potato slices during drying using long short-term memory from image morphometric parameters," *Food and Bioprocess Processing*, vol. 140, pp. 132–143, May 2023, doi: 10.1016/j.fbp.2023.05.006.
- [24] H. Song, "Rapid Non-destructive Testing of Wheat Moisture Content Based on Dielectric Characteristics and Machine Learning," *2024 7th International Conference on Electronics Technology (ICET)*, Chengdu, China, 2024, pp. 126–130, doi: 10.1109/ICET61945.2024.10673046.
- [25] Z. Tagnamas, A. Idlimam, and A. Lamharrar, "Predictive models of beetroot solar drying process through machine learning algorithms," *Renewable Energy*, vol. 219, p. 119522, Oct. 2023, doi: 10.1016/j.renene.2023.119522.
- [26] A. Tulsı, A. Momin, and V. Ayres, "Moisture prediction in chicken litter using hyperspectral data and machine learning," *Smart Agricultural Technology*, vol. 11, p. 101058, May 2025, doi: 10.1016/j.atech.2025.101058.
- [27] M.-D. Yang et al., "Assessment of grain harvest moisture content using machine learning on smartphone images for optimal harvest timing," *Sensors*, vol. 21, no. 17, p. 5875, Aug. 2021, doi: 10.3390/s21175875.
- [28] S. Yu, H. Zheng, D. I. Wilson, W. Yu, and B. R. Young, "Integrating image analysis and machine learning for moisture prediction and appearance quality Evaluation: A case study of kiwifruit drying pretreatment," *Foods*, vol. 13, no. 12, p. 1789, Jun. 2024, doi: 10.3390/foods13121789.
- [29] Y. Zhang, Z. Fang, C. Li, and C. Li, "Deep-Learning-Based model predictive control of an Industrial-Scale multistate Counter-Flow paddy drying process," *Foods*, vol. 13, no. 1, p. 43, Dec. 2023, doi: 10.3390/foods13010043.
- [30] Z. Xing, Y. Shi, K. Zhang, S. Ding, and X. Shi, "Moisture content prediction of cigar leaves air-curing process based on stacking ensemble learning model," *Frontiers in Plant Science*, vol. 16, p. 1553110, Mar. 2025, doi: 10.3389/fpls.2025.1553110.
- [31] Y. Zuo, A. N. Jibril, J. Yan, Y. Xia, R. Liu, and K. Chen, "Optimization of Online Moisture Prediction Model for Paddy in Low-Temperature Circulating Heat Pump Drying System with Artificial Neural Network," *Sensors*, vol. 25, no. 7, p. 2308, Apr. 2025, doi: 10.3390/s25072308.
- [32] G. Zárate-Montero, C. H. Aguirre, A. M. Guevara, G. T. Espinoza and L. Z. Montero, "Prediction of Internal Moisture in Post-Harvest Cocoa (Theobroma Cacao) Using a Machine Learning System, Applicable to Farms That Use Solar Drying," *2024 IEEE 6th International Conference on BioInspired Processing (BIP)*, Liberia, Guanacaste, Costa Rica, 2024, pp. 1–7, doi: 10.1109/BIP63158.2024.10885389.