

## Prediksi Kadar Air *Greenbeans* Kopi Pra-Roasting Menggunakan Metode ANFIS

DOI: <http://dx.doi.org/10.35889/jutisi.v15i2.3568>

Creative Commons License 4.0 (CC BY – NC) 

**Muchammad Fadika Naddiyanto<sup>1</sup>, Mohammad Idhom<sup>2\*</sup>, Hendra Maulana<sup>3</sup>**

<sup>1</sup>Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur, Surabaya, Indonesia

<sup>2</sup>Sains Data, Universitas Pembangunan Nasional Veteran Jawa Timur, Surabaya, Indonesia

<sup>3</sup>Bisnis Digital, Universitas Pembangunan Nasional Veteran Jawa Timur, Surabaya, Indonesia

\*e-mail *Corresponding Author*: idhom@upnjatim.ac.id

### Abstract

*Moisture content of green coffee beans is a critical parameter that determines quality stability during storage and the pre-roasting stage; however, conventional measurement methods are destructive and unsuitable for continuous monitoring. This study aims to develop an Internet of Things (IoT)-based moisture content prediction system using the Adaptive Neuro-Fuzzy Inference System (ANFIS). Input variables include temperature, relative humidity (RH), and capacitive sensor ADC signals, while moisture content is used as the target variable. A dataset consisting of 1032 observations was divided into training and testing sets with an 80:20 ratio. The ANFIS model employed Gaussian membership functions and an early stopping mechanism, and its performance was evaluated using MAE, RMSE, MAPE, and the coefficient of determination ( $R^2$ ). Experimental results achieved MAE of 0.2648, RMSE of 0.4187, MAPE of 2.077%, and  $R^2$  of 0.8109 with an accuracy of 97.923%. The proposed system enables accurate, non-destructive, and real-time moisture content prediction.*

**Keywords:** *Moisture content; Green beans; Coffee; ANFIS; Prediction.*

### Abstrak

Kadar air biji kopi hijau merupakan parameter penting yang menentukan stabilitas mutu selama penyimpanan hingga tahap *pra-roasting*, namun metode pengukuran konvensional bersifat destruktif dan tidak mendukung monitoring berkelanjutan. Penelitian ini bertujuan mengembangkan sistem prediksi kadar air berbasis *Internet of Things* (IoT) menggunakan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Variabel input meliputi suhu, kelembaban relatif (RH), dan sinyal ADC sensor, dengan kadar air sebagai variabel target. Dataset sebanyak 1032 data dibagi menjadi data latih dan data uji dengan rasio 80:20. Model ANFIS menggunakan fungsi keanggotaan Gaussian dan mekanisme *early stopping*, serta dievaluasi menggunakan MAE, RMSE, MAPE, dan koefisien determinasi ( $R^2$ ). Hasil pengujian menunjukkan MAE 0,2648, RMSE 0,4187, MAPE 2,077%, dan  $R^2$  sebesar 0,8109 dengan akurasi 97,923%. Sistem yang diusulkan mampu melakukan prediksi kadar air secara akurat, non-destruktif, dan *real-time*.

**Kata kunci:** *Kadar air; Greenbeans; Kopi; ANFIS; Prediksi.*

### 1. Pendahuluan

Kadar air pada biji kopi hijau merupakan parameter utama yang menentukan stabilitas mutu selama proses pasca panen hingga tahap *pra-roasting*. Nilai kadar air berpengaruh langsung terhadap perubahan karakteristik sensori, stabilitas kimia selama penyimpanan, serta risiko pertumbuhan mikroorganisme dan jamur yang dapat menurunkan kualitas produk kopi [1], [2]. Berbagai penelitian menunjukkan bahwa kadar air optimal untuk menjaga kestabilan penyimpanan berada pada kisaran 10-12%, di mana penyimpangan dari rentang tersebut dapat mempercepat degradasi mutu dan meningkatkan potensi kerusakan biji kopi selama penyimpanan [3], [4]. Oleh karena itu, pengendalian dan pemantauan kadar air secara akurat menjadi aspek krusial dalam menjaga konsistensi kualitas *green beans* sebelum proses roasting.

Metode konvensional dalam pengukuran kadar air biji kopi hijau umumnya dilakukan menggunakan teknik oven yang memiliki tingkat akurasi tinggi sebagai metode referensi standar [5]. Namun, metode oven memiliki beberapa keterbatasan, antara lain membutuhkan waktu pengujian yang relatif lama serta bersifat destruktif sehingga sampel tidak dapat digunakan kembali untuk proses selanjutnya [6], [7]. Selain itu, metode ini tidak memungkinkan monitoring kadar air secara berkala dan kontinu. Kondisi tersebut menyebabkan metode oven kurang efektif untuk kebutuhan monitoring berkelanjutan, khususnya pada skala industri dan penyimpanan modern yang memerlukan pengambilan keputusan secara cepat dan non-destruktif guna menjaga stabilitas kualitas biji kopi [8], [9].

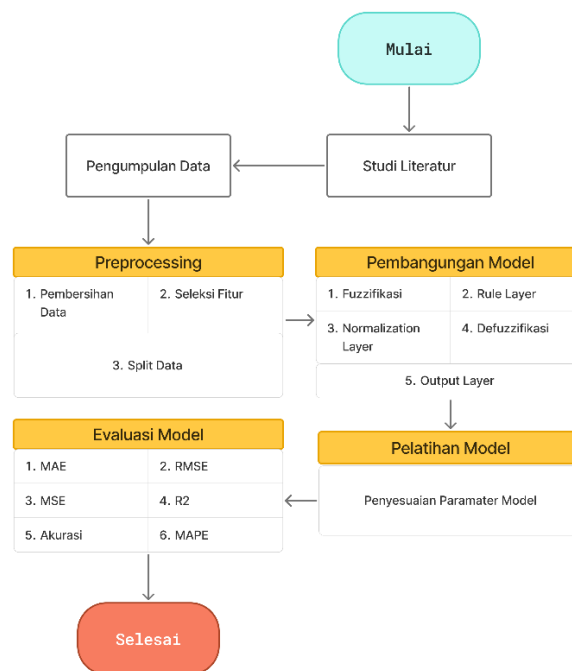
Berbagai penelitian telah dilakukan untuk mengatasi keterbatasan metode konvensional melalui pendekatan berbasis sensor non-destruktif dan kecerdasan buatan. Penelitian Lozano menggunakan pendekatan *Near Infrared Spectroscopy* (NIRS) untuk memprediksi kadar air biji kopi secara non-destruktif dan menunjukkan adanya hubungan nonlinier antara parameter fisik dan kadar air [10]. Studi lain oleh Ordoñez-Lozano mengembangkan model prediksi kadar air berbasis data spektral menggunakan pendekatan pembelajaran mesin untuk meningkatkan akurasi estimasi kadar air selama proses pengeringan [11]. Selain itu, penelitian Collazos-Escobar [12] menunjukkan bahwa algoritma machine learning mampu memodelkan karakteristik kadar air kopi secara lebih akurat dibandingkan metode statistik konvensional [12]. Meskipun demikian, sebagian besar penelitian tersebut masih dilakukan pada kondisi laboratorium atau menggunakan dataset statis sehingga belum mampu merepresentasikan dinamika lingkungan penyimpanan secara *real-time*. Integrasi langsung antara sistem *Internet of Things* (IoT) dan model prediksi adaptif berbasis *neuro-fuzzy* pada monitoring kadar air kopi masih terbatas, sehingga masih terdapat celah penelitian dalam pengembangan sistem monitoring yang adaptif dan berkelanjutan [13].

Berdasarkan gap tersebut, penelitian ini mengusulkan sistem prediksi kadar air biji kopi hijau berbasis *Internet of Things* (IoT) menggunakan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Metode ANFIS dipilih karena mampu memodelkan hubungan nonlinier yang kompleks melalui kombinasi kemampuan pembelajaran jaringan saraf tiruan dan representasi pengetahuan berbasis logika *fuzzy* [14], [15]. Integrasi ANFIS dengan data sensor lingkungan secara *real-time* memungkinkan sistem melakukan estimasi kadar air secara adaptif dan non-destruktif berdasarkan kondisi penyimpanan aktual. Kebaruan penelitian ini terletak pada integrasi langsung sistem IoT dengan model ANFIS untuk prediksi kadar air *green beans* secara *real-time* menggunakan data lingkungan nyata, sehingga tidak hanya meningkatkan akurasi prediksi tetapi juga mendukung sistem monitoring mutu yang berkelanjutan dan aplikatif pada industri kopi.

## 2. Metodologi

Penelitian ini menggunakan pendekatan kuantitatif, karena seluruh proses analisis didasarkan pada pengolahan data numerik berupa parameter lingkungan (seperti suhu, kelembaban relatif dan Signal ADC Sensor *Soil Moisture*) serta nilai kadar air (*Moisture Content*) sebagai variabel target. Pendekatan kuantitatif memungkinkan hubungan antar variabel dianalisis secara objektif melalui pemodelan matematis dan evaluasi statistik, sehingga kinerja model dapat diukur secara terukur menggunakan metrik kesalahan seperti MAE, MSE, dan RMSE.

Secara metodologis, pendekatan kuantitatif ini yang ditunjukkan pada Gambar 1. Alur Penelitian. Proses diawali dengan pengumpulan dataset sebagai sumber data utama. Data yang diperoleh kemudian akan masuk pada pra-pemrosesan, yang mencakup pembersihan data untuk menghilangkan noise atau nilai tidak valid, seleksi fitur untuk menentukan variabel input yang paling relevan terhadap kadar air, serta pembagian data (*split data*) menjadi data latih dan data uji. Tahapan ini bertujuan memastikan kualitas data dan meningkatkan kemampuan generalisasi model.



**Gambar 1.** Alur Penelitian

Setelah dataset telah dikumpulkan maka dilakukan pembangunan model ANFIS dengan merancang struktur *fuzzy* dan jaringan saraf yang sesuai. Model tersebut kemudian dilatih pada tahap training ANFIS menggunakan data latih agar mampu mempelajari pola hubungan nonlinier antara parameter lingkungan dan nilai MC. Tahap akhir adalah evaluasi model, di mana hasil prediksi dikomparasikan dengan nilai aktual sebagai menilai tingkat akurasi dan keandalan sistem. Dengan alur seperti yang ditunjukkan pada gambar, pendekatan kuantitatif tidak hanya model prediksi, tetapi juga memberikan kerangka evaluasi yang sistematis dan terukur dalam menilai performa ANFIS untuk prediksi kadar air biji kopi hijau.

### 2.1. Dataset

Dataset yang digunakan dalam penelitian ini merupakan data primer yang diperoleh melalui proses pengambilan data secara langsung di lapangan, dengan pendampingan dan validasi dari ahli kopi di PT. Bontugu Jaya Makmur sebagai mitra industri. Proses akuisisi data dilakukan pada lokasi penyimpanan dan pengolahan *green beans*, sehingga kondisi yang terekam mencerminkan keadaan lingkungan nyata yang mempengaruhi kadar air biji kopi. Data dikumpulkan menggunakan sistem sensor berbasis *Internet of Things* (IoT) yang dirancang dan dikembangkan oleh peneliti, sehingga setiap parameter lingkungan dapat direkam secara otomatis, kontinu, dan terintegrasi.

### 2.2. Pengumpulan Data

Dataset pada penelitian ini diperoleh dari data primer hasil pengukuran langsung di lapangan menggunakan sistem sensor berbasis IoT yang dirancang oleh peneliti, dengan pendampingan ahli kopi dari PT. Bontugu Jaya Makmur. Sampel *green beans* dipilih dari satu lot yang sama untuk menjaga konsistensi karakteristik, dengan melakukan beberapa Langkah - Langkah yang telah disusun.

#### 1) Persiapan Sampel Biji Kopi Hijau

Sampel biji kopi hijau (*green beans*) dipilih dari satu lot yang sama untuk menjaga keseragaman karakteristik fisik dan kimia, kemudian dibagi menjadi beberapa batch dengan berat  $\pm 50$  gram. Setiap batch dirancang memiliki variasi kadar air pada rentang sekitar 9%-15% agar merepresentasikan kondisi kadar air rendah, normal, dan tinggi sesuai standar mutu.

Sampel disimpan dalam wadah tertutup sebelum pengukuran untuk mencegah perubahan kelembaban yang tidak terkontrol.

## 2) Pengaturan dan Kalibrasi Chamber IoT

Mini-chamber tertutup digunakan sebagai ruang pengukuran dan dilengkapi sensor SHT31 (suhu dan kelembaban), serta sensor kapasitif untuk kelembaban biji, yang seluruhnya terhubung ke mikrokontroler ESP32. Sebelum pengambilan data, dilakukan pengecekan dan kalibrasi awal guna memastikan kestabilan pembacaan sensor, kemudian chamber dibiarkan selama  $\pm 5$ -10 menit agar kondisi lingkungan mencapai keadaan stabil.

## 3) Pengumpulan Data Sensor IoT

Setelah kondisi stabil, data suhu, kelembaban relatif, konsentrasi CO<sub>2</sub>, dan nilai kapasitif direkam secara periodik dengan interval 10-30 detik untuk setiap *batch*, dengan jumlah data yang cukup merepresentasikan tiap kondisi kadar air. Selama proses akuisisi, dilakukan pemantauan untuk mendeteksi anomali atau *noise*, dan data yang tidak realistis diulang agar kualitas dataset tetap terjaga.

## 4) Penentuan Kadar Air

Nilai kadar air aktual setiap *batch* ditentukan menggunakan metode oven sesuai standar SNI 01-2907-2008 dengan menimbang sampel sebelum (*W<sub>1</sub>*) dan sesudah (*W<sub>2</sub>*) pengeringan pada suhu 105°C selama 16 jam, kemudian dihitung menggunakan perhitungan. Nilai ini digunakan sebagai label (*ground truth*) untuk seluruh data sensor yang berasal dari *batch* yang sama.

## 5) Penyusunan Dataset

Data sensor dan hasil oven kemudian disinkronkan berdasarkan identitas *batch*, kemudian di susun pada sebuah tabel excel. Dataset akhir yang berjumlah 1054 data selanjutnya digunakan sebagai masukan pada proses pelatihan dan evaluasi model ANFIS.

### 2.3. Pra-processing

Pada *pra-processing* dilakukannya sebuah mengolah data yang telah dikumpulkan. Data ini akan disesuaikan dengan kebutuhan penelitian dari fitur dan juga apa saja yang perlu dihapus dalam data primer ini. Dengan tujuan adanya tahapan ini agar bisa menopang akurasi dan juga mendapatkan model yang optimal dan maksimal. Oleh karena itu, tahapan ini Adalah hal yang penting dan juga menjadi tolak ukur yang berpengaruh dengan performa model yang akan dibangun.

#### 1) Pembersihan Data

Tahap pembersihan data dilakukan sebagai kualitas dataset sebelum digunakan dalam proses pelatihan model ANFIS. Proses ini meliputi identifikasi dan penanganan data yang tidak lengkap (*missing values*), data duplikat, serta nilai ekstrem atau tidak realistis yang dapat muncul akibat gangguan sensor atau *noise* selama proses pengukuran. Data yang tidak valid dihapus atau diperbaiki agar tidak mempengaruhi proses pembelajaran model dan hasil prediksi.

#### 2) Seleksi Fitur

Seleksi fitur dilakukan sebagai penentuan variabel input yang paling relevan terhadap kadar air (*Moisture Content*). Pada tahap ini dipilih parameter lingkungan yang secara teoritis dan empiris memiliki pengaruh signifikan, seperti suhu, kelembaban relatif, dan nilai kapasitif sensor. Tujuan seleksi fitur adalah mengurangi redundansi data, menyederhanakan struktur model, serta meningkatkan akurasi dan efisiensi komputasi pada proses pelatihan ANFIS.

#### 3) Split Data

Setelah dilakukan proses pembersihan dan pemilihan data, dataset kemudian dipisahkan ke dalam dua kelompok, yaitu data latih dan data uji. Data latih digunakan dalam tahap pembelajaran model ANFIS agar sistem dapat mengenali keterkaitan antara variabel masukan dengan kadar air. Sementara itu, data uji berfungsi untuk mengukur kemampuan model dalam melakukan prediksi pada data baru yang tidak termasuk dalam proses pelatihan. Pembagian data dilakukan dengan komposisi 80% sebagai data latih dan 20% sebagai data uji. Pendekatan

ini bertujuan untuk menghasilkan penilaian performa model yang lebih akurat serta mencegah model mengalami overfitting.

#### 2.4. Pembangunan Model ANFIS

*Adaptive Neuro-Fuzzy Inference System* (ANFIS) merupakan metode komputasi cerdas yang menggabungkan keunggulan jaringan saraf tiruan (*Artificial Neural Network*) dalam proses pembelajaran adaptif dengan kemampuan logika *fuzzy* dalam merepresentasikan ketidakpastian melalui aturan linguistik. Dalam lima tahun terakhir, ANFIS banyak digunakan pada pemodelan sistem nonlinier di bidang pertanian dan pengolahan hasil, khususnya untuk prediksi parameter fisik yang dipengaruhi oleh kondisi lingkungan, seperti suhu, kelembaban relatif, dan kadar air bahan [15]. ANFIS tipe Sugeno orde pertama dipilih karena memiliki struktur konsekuen berupa fungsi linear sehingga mampu memberikan akurasi tinggi sekaligus stabil dalam proses komputasi.

Tahap awal dalam ANFIS adalah proses *fuzzifikasi*, yaitu pemetaan setiap variabel input ke dalam derajat keanggotaan menggunakan fungsi keanggotaan. Fungsi keanggotaan Gaussian banyak digunakan pada penelitian terkini karena memiliki bentuk kurva yang halus, kontinu, dan mampu merepresentasikan variasi data sensor secara realistis [16]. Secara matematis, fungsi keanggotaan Gaussian dirumuskan sebagai :

$$\mu_{ij} = (x_i) = \exp\left(-\frac{1}{2} \left(\frac{x_i - c_{ij}}{\sigma_{ij}}\right)^2\right) \quad (1)$$

dengan  $c_{ij}$  sebagai pusat dan  $\sigma_{ij}$  sebagai lebar sebaran fungsi keanggotaan [4].

Nilai derajat keanggotaan tersebut kemudian dikombinasikan untuk membentuk aturan *fuzzy*. Kekuatan setiap aturan (*firing strength*) diperoleh dari hasil perkalian derajat keanggotaan seluruh input, yang dirumuskan sebagai

$$w_r = \prod_{i=1}^n u_{i,r}(x_i) \quad (2)$$

Nilai ini selanjutnya dinormalisasi untuk memperoleh bobot relatif masing-masing aturan, yaitu

$$\bar{w}_r = \frac{w_r}{\sum_{k=1}^R w_k} \quad (3)$$

dengan  $R$  menyatakan jumlah aturan *fuzzy* yang terbentuk.

Pada lapisan konsekuen, setiap aturan memiliki fungsi *output* berbentuk persamaan linear sebagai berikut:

$$f_r(x) = a_{r1}x_1 + a_{r2}x_2 + \dots + a_{rn}x_n + b \quad (4)$$

*Output* akhir sistem ANFIS diperoleh melalui metode rata-rata berbobot (*weighted average*), yaitu

$$\hat{y} = \sum_{r=1}^R \bar{w}_r f_r(x) \quad (5)$$

Dalam proses pelatihan, parameter fungsi keanggotaan dan koefisien konsekuen dioptimasi menggunakan algoritma pembelajaran berbasis *gradien* dengan fungsi objektif berupa *Mean Squared Error* (MSE), yang dinyatakan sebagai

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (6)$$

Penggunaan optimizer adaptif seperti Adam terbukti mampu mempercepat konvergensi dan meningkatkan stabilitas pelatihan model ANFIS pada data yang bersifat nonlinier dan berisik.

#### 2.5. Training Model ANFIS

Pada tahap training, model ANFIS dibangun berdasarkan jumlah variabel input pada data latih dan jumlah *membership function* (MF) yang ditetapkan sebanyak tiga untuk setiap variabel, sehingga terbentuk aturan *fuzzy* yang merepresentasikan kondisi rendah, sedang, dan tinggi. Parameter-parameter ANFIS kemudian dioptimasi menggunakan optimasi Adam dengan

learning rate 0,001 dan fungsi kerugian *Mean Squared Error* (MSE) karena target yang diprediksi bersifat kontinu. Proses pelatihan dilakukan menggunakan batch size 64 dan maksimum 500 epoch.

Untuk mencegah terjadinya overfitting, digunakan mekanisme Early Stopping yang memantau nilai loss pada data validasi. Pelatihan akan dihentikan secara otomatis apabila nilai validasi tidak mengalami perbaikan selama 30 epoch berturut-turut, dan bobot model akan dikembalikan ke kondisi terbaik saat error validasi paling rendah. Dengan strategi ini, model ANFIS yang dihasilkan tidak hanya mampu mempelajari pola data secara optimal, tetapi juga memiliki kemampuan generalisasi yang lebih baik terhadap data baru.

## 2.6. Evaluasi Model ANFIS

Tahap evaluasi model dilakukan untuk menilai kinerja ANFIS dalam memprediksi nilai keluaran berdasarkan data uji yang tidak terlibat pada proses training. Evaluasi ini menggunakan beberapa metrik kesalahan seperti *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), koefisien determinasi ( $R^2$ ), serta MAPE untuk melihat tingkat akurasi dan kestabilan prediksi. Perbandingan antara nilai aktual dan nilai hasil prediksi dianalisis untuk mengetahui seberapa baik model mampu merepresentasikan hubungan nonlinier antar variabel input. Hasil evaluasi ini menjadi dasar untuk menilai apakah model ANFIS telah memenuhi kriteria akurasi yang diharapkan dan layak digunakan sebagai sistem prediksi pada aplikasi monitoring yang dikembangkan.

## 3. Hasil dan Pembahasan

### 3.1. Hasil

#### 1) Hasil Pengumpulan Dataset

Hasil pengumpulan data atau akuisisi data yang telah dijelaskan pada bagian metodologi menghasilkan total 1054 data pengamatan. Dataset ini terdiri atas beberapa parameter utama, yaitu waktu pengukuran (*timestamp*), suhu udara ( $^{\circ}\text{C}$ ), kelembaban relatif (RH, %), nilai sinyal sensor kelembaban berbasis ADC, serta kadar air biji kopi (MC, %). Data diperoleh secara periodik dari sistem monitoring yang terintegrasi dengan sensor lingkungan dan sensor kelembaban, sehingga setiap baris data merepresentasikan kondisi aktual lingkungan penyimpanan biji kopi hijau pada waktu tertentu.

Tabel 1. Sample Dataset

<i>Timestamp</i>	<i>Suhu (<math>^{\circ}\text{C}</math>)</i>	<i>RH (%)</i>	<i>ADC</i>	<i>MC (%)</i>
2026-01-12	25.61	84.91	3205.0	13.7
2026-01-12	25.59	84.91	3173.0	13.7
2026-01-12	24.76	82.79	3205.0	14.1
2026-01-12	24.9	82.55	3226.0	14.3
2026-01-12	24.98	82.43	3189.0	14
2026-01-12	25.53	75.38	3200	11.5

Contoh sebagian data yang didapatkan dari penelitian ini ditampilkan pada Tabel 1. Tabel tersebut menunjukkan variasi nilai suhu, RH, sinyal ADC, dan kadar air yang terjadi selama proses pengamatan. Variasi ini menggambarkan adanya perubahan kondisi lingkungan yang berpotensi memengaruhi kadar air *green beans*. Seluruh dataset tersebut selanjutnya digunakan dalam proses pra-processing data.

#### 2) Hasil Pra-processing

*Pra-processing* data dilakukan melalui beberapa tahapan, diawali dengan proses pembersihan data untuk menghilangkan nilai *missing value* dan data yang tidak akurat (*inaccurate data*). Pada tahap ini ditemukan sebanyak 22 data yang memiliki nilai kosong atau tidak sesuai dengan kebutuhan penelitian, sehingga data tersebut dihapus dari dataset. Setelah proses pembersihan dilakukan, jumlah data yang tersisa sebanyak 1032 data pengamatan yang selanjutnya digunakan pada tahap seleksi fitur.

Tahap berikutnya adalah seleksi fitur yang dilakukan berdasarkan relevansi parameter lingkungan terhadap kadar air biji kopi. Variabel yang dipertahankan sebagai input model meliputi

suhu ( $^{\circ}\text{C}$ ), kelembaban relatif (RH, %), dan nilai sinyal ADC, sedangkan kadar digunakan sebagai variabel target. Contoh data hasil seleksi fitur ditunjukkan pada Tabel 2.

**Tabel 2.** Data Hasil Seleksi Fitur

Suhu ( $^{\circ}\text{C}$ )	RH (%)	ADC	MC (%)
25.61	84.91	3205.0	13.7
24.76	82.79	3205.0	14.1
24.9	82.55	3226.0	14.3
24.98	82.43	3189.0	14
25.53	75.38	3200	11.5

Selanjutnya dilakukan proses pembagian dataset (*data splitting*) dengan rasio 80% sebagai data latih dan 20% sebagai data uji. Dari total 1032 data, diperoleh sebanyak 825 data latih dan 211 data uji yang digunakan untuk mengevaluasi kemampuan generalisasi model.

Tahap terakhir pada *pra-processing* adalah normalisasi data menggunakan metode *Min-Max Scaling*, yang bertujuan mengubah rentang nilai setiap variabel ke interval 0-1 sehingga meningkatkan stabilitas proses pelatihan model ANFIS berbasis optimasi *gradien*. Contoh data hasil normalisasi ditunjukkan pada Tabel 3.

**Tabel 3.** Data Hasil Normalisasi

Suhu ( $^{\circ}\text{C}$ )	RH (%)	ADC	MC (%)
0.8268161	0.28115654	0.35448587	0.21875
0.86033535	0.4232304	0.33916855	0.1875
0.84078217	0.31206393	0.34792125	0.25
0.83519554	0.3459623	0.32822764	0.25
0.8491621	0.4007976	0.2954049	0.25

### 3) Hasil Train Model ANFIS

Proses pelatihan model *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dilakukan menggunakan dataset hasil *pra-processing* yang telah dinormalisasi. Model diimplementasikan menggunakan TensorFlow dengan fungsi *Mean Squared Error* (MSE) dan optimizer Adam untuk mengoptimasi parameter fungsi keanggotaan Gaussian serta parameter konsekuen model. Proses pelatihan ditetapkan hingga maksimum 500 *epoch* dengan penerapan mekanisme *early stopping* untuk mencegah terjadinya *overfitting*.

Berdasarkan hasil pelatihan yang ditunjukkan pada Gambar 2, proses *training* dihentikan secara otomatis pada *epoch* ke-456 ketika nilai *validation loss* tidak lagi mengalami perbaikan yang signifikan. Nilai *best validation loss* yang diperoleh sebesar 0,01099, yang menunjukkan bahwa model telah mencapai kondisi konvergen dengan tingkat kesalahan yang rendah. Bobot model pada *epoch* tersebut kemudian dipilih sebagai parameter terbaik karena memberikan performa validasi paling optimal terhadap data yang tidak dilibatkan dalam proses pelatihan.

```

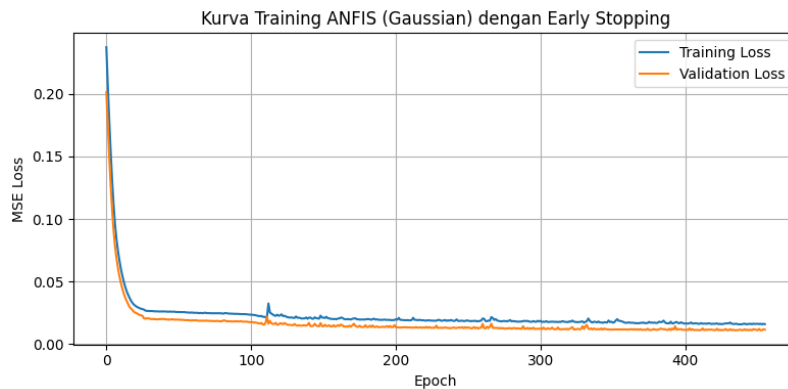
11/11 ----- 0s 8ms/step - loss: 0.0162 - val_loss: 0.0110
Epoch 452/500
11/11 ----- 0s 8ms/step - loss: 0.0159 - val_loss: 0.0121
Epoch 453/500
11/11 ----- 0s 8ms/step - loss: 0.0163 - val_loss: 0.0110
Epoch 454/500
11/11 ----- 0s 8ms/step - loss: 0.0157 - val_loss: 0.0111
Epoch 455/500
11/11 ----- 0s 9ms/step - loss: 0.0162 - val_loss: 0.0118
Epoch 456/500
11/11 ----- 0s 10ms/step - loss: 0.0159 - val_loss: 0.0115
Epoch berhenti di: 456
Best val_loss: 0.010988228023052216

```

**Gambar 2.** Training Model

Gambar 3 menampilkan kurva *training loss* dan *validation loss* yang dihasilkan selama proses pelatihan model. Pada tahap awal pelatihan terlihat penurunan nilai MSE yang sangat tajam, yang menunjukkan bahwa model ANFIS mampu dengan cepat menyesuaikan parameter terhadap pola dasar hubungan antara suhu, kelembaban relatif, dan sinyal ADC sensor terhadap

kadar air. Setelah sekitar *epoch* ke-50 hingga ke-100, laju penurunan loss menjadi lebih landai dan stabil, menandakan proses pembelajaran memasuki fase penyempurnaan parameter.

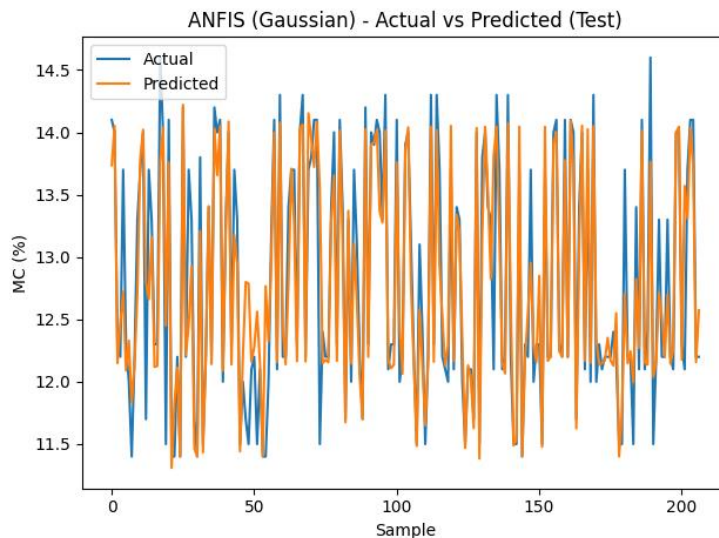


**Gambar 3.** Kurva Training Model

Kedekatan pola antara kurva *training loss* dan *validation loss* sepanjang proses pelatihan menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan. Stabilitasnya nilai *loss* hingga akhir pelatihan mengindikasikan bahwa kombinasi normalisasi data, fungsi keanggotaan Gaussian, serta mekanisme *early stopping* mampu menghasilkan proses optimasi yang stabil dan memiliki kemampuan generalisasi yang baik. Implementasi ANFIS dalam framework TensorFlow memungkinkan proses optimasi parameter dilakukan secara *end-to-end* menggunakan algoritma berbasis *gradien*, sehingga meningkatkan stabilitas konvergensi dibandingkan pendekatan ANFIS konvensional. *Output* dari tahap pelatihan ini berupa model ANFIS terlatih beserta kurva konvergensi *loss*, yang selanjutnya digunakan pada tahap evaluasi untuk menguji kemampuan prediksi kadar air *green beans* kopi pada kondisi *pra-roasting*.

**4) Hasil Evaluasi Model ANFIS**

Kinerja model ANFIS dievaluasi menggunakan data uji yang tidak dilibatkan selama proses pelatihan untuk menilai kemampuan generalisasi model terhadap data baru. Hasil pengujian ditunjukkan pada Gambar 4, yang memperlihatkan perbandingan antara nilai kadar air aktual (*Actual*) dan hasil prediksi model (*Predicted*). Secara visual, kurva prediksi mampu mengikuti pola perubahan nilai aktual dengan baik pada rentang kadar air sekitar 11,5% hingga 14,5%. Kedekatan kedua kurva menunjukkan bahwa model ANFIS mampu merepresentasikan hubungan nonlinier antara parameter lingkungan, yaitu suhu, kelembaban relatif (RH), dan sinyal ADC sensor kelembaban terhadap kadar air *green beans* secara konsisten.



**Gambar 4.** Hasil Test Model

Untuk memperjelas asal perhitungan metrik evaluasi, contoh data historis hasil prediksi model pada data uji disajikan pada Tabel 4. Data Hasil Prediksi tersebut menunjukkan perbandingan langsung antara nilai kadar air aktual dan hasil prediksi model pada setiap sampel, beserta nilai error absolut yang menjadi dasar perhitungan metrik evaluasi.

**Tabel 4.** Data Hasil Prediksi

Sampel	MC Aktual (%)	MC Prediksi (%)	Error Absolut
1	14.10	13.43	0.67
2	14.00	13.77	0.23
3	12.30	12.21	0.09
4	12.20	12.38	0.18
5	13.70	12.74	0.96
6	12.30	12.46	0.16
7	12.00	12.29	0.29
8	11.40	12.43	1.03
9	12.20	12.21	0.01
10	13.30	12.73	0.57

Evaluasi kuantitatif dilakukan menggunakan beberapa metrik performa, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), serta koefisien determinasi ( $R^2$ ). Perhitungan metrik evaluasi dilakukan berdasarkan selisih antara nilai kadar air aktual dan hasil prediksi model sebagaimana ditunjukkan pada Tabel 4.

Hasil pengujian menunjukkan nilai MAE sebesar 0,2648, MSE sebesar 0,1753, dan RMSE sebesar 0,4187. Nilai RMSE yang relatif kecil menunjukkan bahwa deviasi antara nilai prediksi dan nilai aktual berada pada kisaran rendah, sehingga kesalahan prediksi model dapat dikategorikan kecil dan stabil. Selain itu, nilai MAPE sebesar 2,077% menunjukkan bahwa rata-rata kesalahan prediksi relatif terhadap nilai aktual berada di bawah 3%, yang mengindikasikan tingkat akurasi prediksi yang sangat baik untuk sistem estimasi kadar air berbasis data sensor lingkungan.

Berdasarkan nilai koefisien determinasi ( $R^2$ ) sebesar 0,8109, dapat disimpulkan bahwa sekitar 81,09% variasi kadar air aktual dapat dijelaskan oleh model ANFIS, yang menunjukkan kemampuan model dalam menangkap hubungan nonlinier antara parameter lingkungan dan kadar air secara signifikan. Sementara itu, nilai akurasi sebesar 97,923% menunjukkan performa prediksi yang tinggi pada data uji.

Konsistensi antara kesesuaian pola kurva pada Gambar 4 dan hasil evaluasi numerik menunjukkan bahwa model ANFIS dengan fungsi keanggotaan Gaussian memiliki stabilitas prediksi dan kemampuan generalisasi yang baik. Hal ini mengindikasikan bahwa perubahan parameter lingkungan yang direpresentasikan melalui sistem sensor IoT memiliki korelasi yang kuat terhadap perubahan kadar air biji kopi dan dapat dimodelkan secara efektif menggunakan pendekatan *neuro-fuzzy*. Dengan demikian, model yang dihasilkan dinilai layak digunakan sebagai sistem prediksi kadar air biji kopi *pra-roasting* secara non-destruktif dan *real-time*.

### 3.2. Pembahasan

Hasil penelitian menunjukkan bahwa model *Adaptive Neuro-Fuzzy Inference System* (ANFIS) mampu memprediksi kadar air biji kopi hijau dengan tingkat akurasi yang tinggi berdasarkan parameter lingkungan yang diperoleh dari sistem sensor berbasis *Internet of Things* (IoT). Nilai evaluasi yang diperoleh, yaitu MAE sebesar 0,2648, RMSE sebesar 0,4187, dan MAPE sebesar 2,077%, menunjukkan bahwa kesalahan prediksi berada pada tingkat rendah dan stabil. Temuan ini memperkuat penelitian sebelumnya yang menyatakan bahwa pendekatan berbasis kecerdasan buatan efektif digunakan untuk memodelkan hubungan nonlinier antara parameter lingkungan dan kadar air komoditas pertanian.

Penelitian Lozano [10] menggunakan pendekatan *Near Infrared Spectroscopy* (NIRS) untuk memprediksi kadar air biji kopi secara non-destruktif dan menunjukkan bahwa perubahan kadar air memiliki hubungan kompleks terhadap kondisi lingkungan penyimpanan. Namun, pendekatan

tersebut masih bergantung pada perangkat laboratorium khusus dan belum mendukung monitoring secara real-time. Sementara itu, penelitian Ordoñez-Lozano [11] mengembangkan model berbasis *Artificial Neural Network* (ANN) yang mampu menghasilkan akurasi tinggi dalam prediksi kadar air, tetapi model ANN memiliki keterbatasan dalam interpretabilitas hubungan antar variabel karena bersifat black-box. Hasil penelitian ini menunjukkan bahwa ANFIS mampu menjadi alternatif yang efektif karena menggabungkan kemampuan pembelajaran adaptif jaringan saraf dengan representasi aturan fuzzy yang lebih interpretatif.

Selain itu, penelitian Collazos-Escobar [17] menunjukkan bahwa algoritma machine learning mampu meningkatkan akurasi pemodelan parameter fisik bahan pertanian dibandingkan metode statistik konvensional. Temuan pada penelitian ini memperkuat hasil tersebut dengan menunjukkan bahwa integrasi ANFIS dengan data sensor lingkungan nyata dapat menghasilkan performa prediksi yang stabil pada kondisi operasional sebenarnya. Hal ini menunjukkan bahwa pendekatan *neuro-fuzzy* tidak hanya efektif pada data eksperimen laboratorium, tetapi juga dapat diterapkan pada sistem monitoring berbasis IoT secara kontinu.

Kontribusi utama penelitian ini terletak pada integrasi langsung antara sistem IoT dan model ANFIS untuk melakukan prediksi kadar air secara real-time menggunakan data lingkungan aktual. Berbeda dengan penelitian [18] menggunakan dataset statis atau pengukuran laboratorium, penelitian ini memanfaatkan data sensor secara kontinu sehingga model mampu merepresentasikan dinamika kondisi penyimpanan secara lebih realistis. Integrasi ini memperluas penerapan ANFIS dari sekadar model prediksi menjadi bagian dari sistem monitoring mutu berbasis kecerdasan buatan yang adaptif dan non-destruktif.

Secara konseptual, temuan penelitian ini memperkuat paradigma bahwa kombinasi teknologi IoT dan metode komputasi cerdas dapat digunakan sebagai pendekatan baru dalam pengendalian mutu komoditas pertanian. Kemampuan model dalam mempertahankan stabilitas prediksi serta menunjukkan kemampuan generalisasi yang baik mengindikasikan bahwa parameter lingkungan seperti suhu, kelembaban relatif, dan sinyal sensor kelembaban memiliki keterkaitan yang signifikan terhadap perubahan kadar air biji kopi. Dengan demikian, penelitian ini tidak hanya memberikan kontribusi pada pengembangan model prediksi berbasis ANFIS, tetapi juga memperkaya konsep sistem monitoring mutu berbasis data real-time pada bidang pertanian presisi (*precision agriculture*).

#### 4. Simpulan

Penelitian ini berhasil mengembangkan sistem prediksi kadar air biji kopi hijau berbasis *Internet of Things* (IoT) menggunakan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) sebagai pendekatan non-destruktif untuk monitoring mutu pada tahap pra-roasting. Model ANFIS mampu memodelkan hubungan nonlinier antara parameter lingkungan, yaitu suhu, kelembaban relatif, dan sinyal ADC sensor kelembaban terhadap kadar air biji kopi secara efektif.

Hasil evaluasi menunjukkan performa model yang baik dengan nilai MAE sebesar 0,2648, RMSE sebesar 0,4187, MAPE sebesar 2,077%, serta koefisien determinasi ( $R^2$ ) sebesar 0,8109. Nilai akurasi yang mencapai 97,923% menunjukkan bahwa model memiliki kemampuan prediksi yang tinggi dan stabil terhadap data uji yang tidak dilibatkan dalam proses pelatihan. Selain itu, kesesuaian antara nilai aktual dan hasil prediksi menunjukkan bahwa pendekatan ANFIS mampu menghasilkan kemampuan generalisasi yang baik dalam merepresentasikan dinamika perubahan kadar air berdasarkan kondisi lingkungan penyimpanan.

Kontribusi utama penelitian ini terletak pada integrasi langsung model ANFIS dengan sistem sensor berbasis IoT untuk menghasilkan sistem monitoring kadar air secara real-time, adaptif, dan non-destruktif. Pendekatan ini memberikan alternatif yang lebih efisien dibandingkan metode konvensional berbasis oven yang bersifat destruktif dan tidak mendukung pemantauan kontinu. Secara praktis, sistem yang diusulkan berpotensi diterapkan sebagai pendukung pengambilan keputusan dalam pengelolaan penyimpanan biji kopi guna menjaga stabilitas mutu dan mengurangi risiko penurunan kualitas selama proses pra-roasting.

Untuk penelitian selanjutnya, pengembangan dapat diarahkan pada penambahan variabel lingkungan lain, integrasi sistem kendali otomatis berbasis prediksi, serta pengujian pada skala industri untuk meningkatkan robustnes dan validitas implementasi sistem pada kondisi operasional nyata.

**Daftar Referensi**

- [1] C. P. Gallego, J. Pabón, R. D. Medina, and V. Osorio, "Maintenance of the Quality of Coffee (*Coffea arabica* L.) in Different Packaging and Storage Locations," *Int. J. Food Sci.*, vol. 2025, no. 1, p. 5049217, 2025, doi: <https://doi.org/10.1155/ijfo/5049217>.
- [2] J. Błaszkiwicz *et al.*, "Effect of green and roasted coffee storage conditions on selected characteristic quality parameters," *Sci. Rep.*, vol. 13, no. 1, p. 6447, Dec. 2023, doi: [10.1038/s41598-023-33609-x](https://doi.org/10.1038/s41598-023-33609-x).
- [3] A. Adnan, D. von Hörsten, E. Pawelzik, and D. Mörlein, "Rapid prediction of moisture content in intact green coffee beans using near infrared spectroscopy," *Foods*, vol. 6, no. 5, pp. 1–11, May 2017, doi: [10.3390/foods6050038](https://doi.org/10.3390/foods6050038).
- [4] L. Anokye-Bempah, J. Han, K. Kornbluth, W. Ristenpart, and I. R. Donis-González, "The use of desiccants for proper moisture preservation in green coffee during storage and transportation," *J. Agric. Food Res.*, vol. 11, p. 100478, Mar. 2023, doi: [10.1016/j.jafr.2022.100478](https://doi.org/10.1016/j.jafr.2022.100478).
- [5] L. Anokye-Bempah, K. Phetpan, D. Slaughter, and I. R. Donis-González, "Design, calibration, and validation of an inline green coffee moisture estimation system using time-domain reflectometry," *J. Food Eng.*, vol. 341, p. 111342, Mar. 2023, doi: [10.1016/j.jfoodeng.2022.111342](https://doi.org/10.1016/j.jfoodeng.2022.111342).
- [6] R. Moulana, S. Zakaria, and A. A. Munawar, "Rapid and non-destructive prediction of moisture content on intact gayo coffee beans using near infrared spectroscopy," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 1356, no. 1, p. 012041, 2024, doi: [10.1088/1755-1315/1356/1/012041](https://doi.org/10.1088/1755-1315/1356/1/012041).
- [7] L. Wulandari, G. Indrayanto, and M. Yuwono, "Determination of Moisture Content in Ground Coffee Using Near-Infrared Spectroscopy and Chemometrics," *Asian Journal of Green Chemistry*, vol. 10, no. 1, pp. 101–113, Jan. 2026, doi: [10.48309/AJGC.2026.535228.1775](https://doi.org/10.48309/AJGC.2026.535228.1775).
- [8] J. Błaszkiwicz and others, "Effect of Green and Roasted Coffee Storage Conditions on Selected Characteristic Quality Parameters," *Sci. Rep.*, vol. 13, no. 1, p. 6380, 2023, doi: [10.1038/s41598-023-33609-x](https://doi.org/10.1038/s41598-023-33609-x).
- [9] S. Alyammahi, A. Alhמודi, M. Alawadhi, and F. Alqaydi, "Low-Cost IoT-Based Smart Grain Monitoring System for Sustainable Storage Management," in *The 12th International Electronic Conference on Sensors and Applications*, Basel Switzerland: MDPI, Nov. 2025, p. 90. doi: [10.3390/ECSA-12-26545](https://doi.org/10.3390/ECSA-12-26545).
- [10] 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 Sci.*, vol. 20, pp. e202289-e202289, Feb. 2025, doi: [10.25186/v20i.2289](https://doi.org/10.25186/v20i.2289).
- [11] S. Ordoñez-Lozano, G. A. Collazos-Escobar, A. F. Bahamón-Monje, and N. Gutiérrez-Guzmán, "Monitoring moisture content in parchment coffee beans during drying using Fourier Transform near infrared (FT-NIR) spectroscopy: A dataset for calibrating chemometric-based models for moisture prediction," *Data Brief*, vol. 59, p. 111436, Apr. 2025, doi: [10.1016/j.dib.2025.111436](https://doi.org/10.1016/j.dib.2025.111436).
- [12] 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 Bioproc. Tech.*, vol. 18, no. 6, pp. 5419–5430, Jun. 2025, doi: [10.1007/s11947-025-03785-x](https://doi.org/10.1007/s11947-025-03785-x).
- [13] W. Ruiz Martinez and R. Ferro Escobar, "Internet of Things (IoT) System to Monitor Environmental Variables in a Coffee Crop Review Article," *Journal of agriculture and horticulture research*, vol. 3, no. 1, pp. 10–12, 2020, [Online]. Available: [www.opastonline.com](http://www.opastonline.com)
- [14] M. Esmaili *et al.*, "Assessment of adaptive neuro-fuzzy inference system (ANFIS) to predict production and water productivity of lettuce in response to different light intensities and CO2 concentrations," *Agric. Water Manag.*, vol. 258, p. 107201, Dec. 2021, doi: [10.1016/j.agwat.2021.107201](https://doi.org/10.1016/j.agwat.2021.107201).
- [15] A. Abdurohman, M. Siregar, C. Olivia Sereati, S. Windasari, and MM. L. W. Pandjaitan, "Implementation and Analysis of Fuzzy Inference System (FIS) and Adaptive Neuro-Fuzzy Inference System (ANFIS) for Irrigation," *International Journal of Engineering Continuity*, vol. 4, no. 1, pp. 210–231, Aug. 2025, doi: [10.58291/ijec.v4i1.399](https://doi.org/10.58291/ijec.v4i1.399).
- [16] O. Taylan, A. E. M. Al-Juaidi, and B. Guloglu, "Novel Machine Learning Approaches for Predicting Soil Moisture Content Using Hydrological and Soil Characteristics: A

- Comparative Analysis of ANN, SVM, and ANFIS Models,” Dec. 05, 2024. doi: 10.21203/rs.3.rs-5404605/v1.
- [17] G. A. Collazos-Escobar, V. Hurtado-Cortés, A. F. Bahamón-Monje, and N. Gutiérrez-Guzmán, “Mathematical modeling of water sorption isotherms in specialty coffee beans processed by wet and semidry postharvest methods,” *Sci. Rep.*, vol. 15, p. 3898, 2025, doi: 10.1038/s41598-024-83702-y.
- [18] J. Seyedmohammadi and M. N. Navidi, “Optimizing soil water retention predictions using a subtractive clustering-based ANFIS model,” *Cogent Food Agric.*, vol. 12, no. 1, p. 2612450 2026, doi: 10.1080/23311932.2025.2612450.