



## SISTEM OTOMASI PENGENDALIAN NUTRISI HIDROPONIK BERBASIS IOT DENGAN ALGORITMA K-NEAREST NEIGHBORS

Lili Wulandari<sup>1</sup>, Muhammad Fakhri<sup>2</sup>

<sup>1,2</sup>Ilmu Komputer, Fakultas Sains dan Teknologi,  
Universitas Islam Negeri Sumatera Utara, Medan

<sup>1,2</sup>Jl. Lapangan Golf, Kecamatan Pancur Batu, Kabupaten Deli Serdang, Sumatera Utara 20353

E-mail : [liliwulandari2207@gmail.com](mailto:liliwulandari2207@gmail.com)<sup>1</sup>, [fakhri@uisu.ac.id](mailto:fakhri@uisu.ac.id)<sup>2</sup>

### ABSTRAK

Penelitian ini mengembangkan sistem otomasi nutrisi hidroponik berbasis Internet of Things (IoT) dengan penerapan algoritma K-Nearest Neighbors (KNN) untuk mengklasifikasikan kondisi nutrisi berdasarkan nilai Electrical Conductivity (EC) dan suhu. Data pelatihan dibagi ke dalam tiga kelas, yaitu low, optimal, dan high, kemudian diproses menggunakan perhitungan jarak Euclidean. Sensor TDS dan sensor suhu terintegrasi dengan platform IoT untuk pemantauan dan pengendalian jarak jauh. Hasil pengujian menunjukkan sensor TDS memiliki rata-rata error sebesar 0,22%, sedangkan sensor suhu menghasilkan error sebesar 0,40%. Pengujian algoritma KNN pada sepuluh skenario menunjukkan tingkat akurasi sebesar 90% dalam mengklasifikasikan kondisi nutrisi. Implementasi ini membuktikan bahwa integrasi IoT dan KNN mampu meningkatkan ketepatan dan efisiensi pengelolaan nutrisi hidroponik secara real-time.

**Kata kunci** : Hidroponik, Iot, Otomasi Nutrisi, K-Nearest Neighbors, Klasifikasi.

### ABSTRACT

This study develops an Internet of Things (IoT)-based hydroponic nutrient automation system using the K-Nearest Neighbors (KNN) algorithm to classify nutrient conditions based on Electrical Conductivity (EC) and temperature values. The training data were categorized into low, optimal, and high classes and processed using Euclidean distance calculations. TDS and temperature sensors were integrated with an IoT platform for real-time monitoring and remote control. Experimental results indicate that the TDS sensor achieved an average error of 0.22%, while the temperature sensor produced an error of 0.40%. KNN testing across ten scenarios achieved an accuracy of 90% in classifying nutrient conditions. These findings demonstrate that the integration of IoT and KNN enhances the accuracy and efficiency of nutrient management in hydroponic cultivation in real-time.

**Keywords** : Hydroponics, Iot, Nutrient Automation, K-Nearest Neighbors, Classification.

### 1. PENDAHULUAN

Budidaya hidroponik menjadi salah satu solusi pertanian modern yang menawarkan efisiensi penggunaan lahan, air, dan waktu. Metode ini semakin populer terutama di wilayah urban karena mampu menghasilkan tanaman secara konsisten tanpa ketergantungan pada kualitas tanah. Namun, keberhasilan hidroponik sangat dipengaruhi oleh kestabilan nutrisi dan kondisi lingkungan larutan, sehingga pemantauan yang presisi menjadi faktor penting dalam menjaga kualitas dan kuantitas hasil panen

(Abdullah & Jena, 2021).

Pada praktiknya, pengelolaan nutrisi hidroponik masih banyak dilakukan secara manual. Proses pengecekan konsentrasi larutan, suhu, dan parameter lain membutuhkan ketelitian tinggi dan dilakukan secara berkala (Dzi et al., 2024). Ketergantungan pada intervensi manual ini berpotensi menimbulkan kesalahan pengukuran maupun keterlambatan penanganan, yang pada akhirnya dapat memengaruhi pertumbuhan tanaman. Oleh karena itu, diperlukan sistem yang mampu melakukan monitoring dan pengendalian secara otomatis, cepat, dan lebih akurat (Erlangga et al.,



2024).

Perkembangan teknologi Internet of Things (IoT) memberikan peluang besar dalam otomatisasi hidroponik. Dengan integrasi sensor dan perangkat komunikasi, kondisi larutan dapat dipantau secara real-time, dan tindakan korektif dapat dilakukan tanpa perlu kehadiran fisik pengguna (Agus et al., 2022). Sistem otomatis berbasis IoT memungkinkan proses pengelolaan nutrisi menjadi lebih efisien, responsif, dan terstruktur. Namun, pemanfaatan IoT dalam hidroponik masih membutuhkan pendekatan yang mampu menginterpretasikan data sensor secara cerdas untuk menentukan tindakan yang tepat (Romagusta & Sonalitha, 2024).

Dalam konteks tersebut, teknik klasifikasi berbasis machine learning dapat digunakan untuk membantu menentukan kondisi nutrisi berdasarkan data yang diterima dari sensor. Salah satu metode yang cocok untuk sistem embedded dan IoT adalah algoritma K-Nearest Neighbors (KNN) karena sederhana, mudah diimplementasikan, dan efektif pada dataset berukuran kecil (Fatori, 2022). Dengan menggunakan fitur Electrical Conductivity (EC) dan suhu, sistem dapat mengidentifikasi apakah kondisi larutan termasuk kategori low, optimal, atau high, sehingga proses penyesuaian nutrisi dapat dilakukan secara otomatis dengan tingkat kesalahan yang rendah (Bimanta et al., 2022).

Sistem otomatis yang dilengkapi dengan kemampuan klasifikasi berbasis data akan memberikan keputusan yang lebih objektif dibandingkan pendekatan konvensional yang hanya bergantung pada threshold tetap (Erlangga et al., 2024). Selain itu, metode klasifikasi seperti KNN dapat menyesuaikan kategori berdasarkan pola data dan rentang kondisi aktual di lapangan. Hal ini memberikan fleksibilitas lebih besar dalam pengelolaan nutrisi dibandingkan pendekatan manual atau sistem otomatis yang hanya menggunakan batasan statis (Maysandra & Ikhsan, 2025).

Di sisi lain, penggunaan sensor TDS dan sensor suhu dalam sistem hidroponik telah berkembang menjadi standar umum karena kedua parameter tersebut sangat berpengaruh terhadap penyerapan nutrisi oleh tanaman. EC menggambarkan tingkat konsentrasi nutrisi dalam larutan, sedangkan suhu larutan mempengaruhi kelarutan oksigen dan metabolisme tanaman. Oleh karena itu, integrasi kedua sensor ini dalam sistem IoT memungkinkan pemantauan nutrisi yang lebih komprehensif dan relevan terhadap kondisi pertumbuhan tanaman (Ariyo et al., 2024).

Selain pemantauan, salah satu tantangan dalam otomatisasi hidroponik adalah memastikan

bahwa sistem mampu memberikan respons yang tepat dan cepat terhadap perubahan kondisi nutrisi. Keterlambatan dalam memberikan larutan tambahan atau pengenceran dapat menyebabkan tanaman mengalami stres, terutama pada fase pertumbuhan yang sensitif. Dengan penerapan klasifikasi KNN, sistem dapat mengenali kondisi larutan secara real-time dan memberikan tindakan korektif otomatis tanpa menunggu campur tangan manusia (Hafizhiadi, 2024).

Manfaat lain dari penerapan IoT dan klasifikasi data adalah tersedianya rekam jejak digital terhadap seluruh kondisi lingkungan dan tindakan otomatis yang dilakukan sistem. Data historis ini dapat digunakan untuk analisis lanjutan, seperti prediksi kebutuhan nutrisi, pola konsumsi larutan, hingga anomali pada sensor. Hal ini membuka peluang bagi petani atau pelaku urban farming untuk merancang strategi pemeliharaan tanaman yang lebih efisien dan berbasis data (Wiranti, 2021).

Selain itu, integrasi IoT dengan pendekatan klasifikasi memungkinkan sistem tidak hanya memantau kondisi nutrisi, tetapi juga memberikan rekomendasi atau keputusan otomatis berdasarkan pola data yang telah dipelajari (Priatno & Muniroh, 2022). Sistem yang berbasis data-driven seperti ini menawarkan tingkat akurasi yang lebih tinggi dibandingkan pendekatan rule-based yang statis. Dengan demikian, pengelolaan nutrisi dapat dilakukan secara adaptif terhadap kondisi lingkungan yang berubah, sehingga kualitas pertumbuhan tanaman tetap terjaga pada level optimal (Leonard et al., 2021).

Beberapa penelitian nasional dalam lima tahun terakhir menunjukkan peningkatan pemanfaatan IoT dan klasifikasi data dalam sistem hidroponik. Penelitian oleh Yunita Fifi Rahmawati dkk. (2025) berjudul "Sistem Pengontrol Nutrisi Otomatis Tanaman Hidroponik Berbasis IoT" mengembangkan sistem kontrol nutrisi menggunakan sensor TDS dan suhu untuk mempertahankan stabilitas larutan. Hasil penelitian menunjukkan bahwa sistem mampu menjaga rentang EC sesuai standar dan menurunkan potensi kesalahan pengukuran dengan error sensor di bawah 2% (Rahmawati et al., 2025). Selain itu, penelitian oleh I Gusti Made Arya Dipayasa (2025) berjudul "Smart Hidroponik dengan IoT Menggunakan KNN untuk Monitoring Nutrisi Tanaman" menerapkan algoritma K-Nearest Neighbors dalam sistem IoT untuk mengklasifikasikan kondisi nutrisi. Peneliti melaporkan bahwa KNN mampu mengelompokkan kondisi nutrisi dengan akurasi yang baik dan respons yang cepat dalam sistem monitoring real-time. Kedua penelitian ini menunjukkan adanya tren penggunaan IoT dan metode klasifikasi dalam meningkatkan efisiensi pengelolaan hidroponik



(Made et al., 2025).


Meskipun demikian, penelitian-penelitian sebelumnya masih memiliki sejumlah keterbatasan, seperti fokus yang lebih dominan pada monitoring tanpa otomasi aksi korektif, belum adanya integrasi klasifikasi nutrisi secara eksplisit, serta kurangnya evaluasi kuantitatif terkait performa sensor maupun akurasi algoritma. Selain itu, dokumentasi dataset dan proses evaluasi yang komprehensif masih jarang ditemukan, sehingga analisis performa sistem kurang terukur. Oleh karena itu, diperlukan penelitian yang tidak hanya mengklasifikasikan kondisi nutrisi, tetapi juga menghubungkannya secara langsung dengan mekanisme otomasi berbasis IoT.

Penelitian ini hadir untuk mengisi gap tersebut dengan mengembangkan sistem otomasi nutrisi hidroponik berbasis IoT yang memanfaatkan algoritma KNN untuk mengklasifikasikan kondisi larutan secara real-time. Sistem ini dirancang untuk mengukur EC dan suhu, kemudian menentukan kategori nutrisi sebagai dasar pengendalian otomatis. Artikel ini membahas perancangan sistem, proses pengumpulan data, penerapan algoritma, serta evaluasi performa baik dari sisi sensor maupun akurasi klasifikasi. Hasil penelitian diharapkan dapat memberikan kontribusi nyata dalam pengembangan teknologi hidroponik cerdas yang aplikatif dan mudah diimplementasikan.

Struktur artikel ini disusun dimulai dari pendahuluan, kemudian metode penelitian yang mencakup arsitektur sistem dan prosedur klasifikasi, dilanjutkan dengan hasil dan pembahasan yang memuat performa sensor dan akurasi algoritma, serta diakhiri dengan kesimpulan penelitian. Dengan penyusunan tersebut, artikel ini diharapkan mampu memberikan gambaran menyeluruh mengenai sistem otomasi nutrisi hidroponik berbasis IoT yang dirancang.

## 2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan rekayasa sistem yang disusun secara terstruktur melalui beberapa tahapan, mulai dari identifikasi masalah hingga proses pengujian. Setiap tahapan dirancang untuk memastikan bahwa sistem otomasi nutrisi hidroponik berbasis IoT dengan klasifikasi K-Nearest Neighbors (KNN) dibangun secara sistematis, terukur, dan sesuai dengan kebutuhan penelitian. Alur penelitian yang digunakan dapat dilihat pada kerangka penelitian berikut.



**Gambar 1. Kerangka Penelitian**

- a) **Mengidentifikasi Masalah**  
Tahap pertama adalah mengidentifikasi masalah yang berkaitan dengan ketidakstabilan nutrisi pada sistem hidroponik yang selama ini banyak dikelola secara manual. Pada tahap ini dilakukan observasi dan analisis terhadap proses pemantauan EC dan suhu larutan yang memerlukan ketelitian tinggi serta rawan terjadi keterlambatan dalam penanganan. Melalui identifikasi tersebut, ditemukan kebutuhan akan sistem otomatis yang mampu memberikan klasifikasi kondisi nutrisi secara real-time sehingga tindakan korektif dapat dilakukan tanpa campur tangan manusia.
- b) **Pengumpulan Data**  
Tahap berikutnya adalah pengumpulan data, yang dilakukan dengan mengambil serangkaian pengukuran terhadap nilai EC dan suhu larutan nutrisi menggunakan sensor TDS dan sensor suhu. Data dikumpulkan dalam berbagai kondisi untuk memperoleh representasi tiga kategori nutrisi, yaitu low, optimal, dan high. Seluruh data kemudian dicatat, diseleksi, dan disesuaikan dengan standar nutrisi hidroponik berdasarkan literatur agar dataset siap digunakan pada proses klasifikasi.
- c) **Analisis Data**  
Data yang telah terkumpul selanjutnya dianalisis untuk melihat pola hubungan antara nilai EC, suhu, dan kategori nutrisi. Proses analisis mencakup pembersihan data, pemilihan fitur yang relevan, serta penentuan parameter awal untuk algoritma KNN, termasuk penentuan nilai K dan metode penghitungan jarak. Tahap ini memastikan bahwa data yang digunakan benar-benar valid dan representatif untuk menghasilkan model klasifikasi yang akurat.
- d) **Perancangan Sistem**  
Setelah analisis dilakukan, tahap perancangan sistem dimulai dengan menyusun arsitektur IoT



- yang menghubungkan sensor, mikrokontroler, dan platform monitoring. Pada tahap ini disusun pula diagram alir proses, diagram blok sistem, serta rancangan kerja algoritma KNN untuk mengklasifikasikan kondisi nutrisi. Desain perangkat keras dan perangkat lunak dipadukan untuk membentuk sistem yang dapat membaca data sensor, memproses klasifikasi, dan menjalankan kontrol otomatis.
- e) Implementasi  
Tahap implementasi dilakukan dengan merakit perangkat keras yang terdiri dari sensor nilai EC, sensor suhu, mikrokontroler, serta modul komunikasi. Perangkat lunak diimplementasikan untuk menjalankan pembacaan data sensor, pengiriman data ke server atau dashboard IoT, serta penerapan algoritma KNN dalam menentukan kategori nutrisi. Selain itu, dashboard dirancang untuk menampilkan data secara real-time dan mengaktifkan tindakan korektif otomatis berdasarkan hasil klasifikasi.
  - f) Pengujian  
Tahap terakhir adalah pengujian, yang dilakukan untuk mengevaluasi performa sensor, akurasi sistem, dan keandalan klasifikasi. Sensor TDS dan suhu diuji dengan cara membandingkan hasil pembacaan dengan alat ukur standar untuk memperoleh nilai error. Algoritma KNN diuji menggunakan dataset uji untuk memperoleh nilai akurasi dalam menentukan kelas nutrisi. Pengujian sistem secara keseluruhan dilakukan untuk menilai kestabilan proses otomasi dan kualitas komunikasi IoT dalam kondisi operasional.

**2.1 Pengumpulan Data**

Pengumpulan data dilakukan dengan melakukan serangkaian pengukuran terhadap nilai Electrical Conductivity (EC) dan suhu larutan nutrisi menggunakan sensor TDS serta sensor suhu yang terintegrasi dengan sistem IoT. Data diambil dalam berbagai kondisi larutan untuk merepresentasikan tiga kategori nutrisi, yaitu low, optimal, dan high. Setiap pengukuran dicatat secara berurutan untuk memastikan konsistensi dan validitas dataset, kemudian dilakukan verifikasi terhadap standar nilai nutrisi hidroponik berdasarkan literatur. Seluruh data yang terkumpul digunakan sebagai dasar pembelajaran dan pengujian algoritma K-Nearest Neighbors (KNN) dalam proses klasifikasi kondisi nutrisi pada tahap selanjutnya.

**2.2 Teknik Pengumpulan Data**

Teknik pengumpulan data pada penelitian ini dilakukan melalui pengukuran langsung menggunakan sensor TDS dan sensor suhu yang dipasang pada instalasi hidroponik. Sensor membaca nilai EC dan suhu secara real-time, kemudian data dikirimkan ke sistem IoT untuk dicatat dan disimpan. Pengukuran dilakukan secara berulang pada berbagai kondisi larutan, mulai dari konsentrasi rendah hingga tinggi, guna memperoleh dataset yang representatif bagi tiga kategori nutrisi. Setiap data yang diperoleh diverifikasi melalui perbandingan dengan standar pengukuran manual untuk memastikan keakuratan nilai, sehingga data yang digunakan dalam proses analisis dan klasifikasi memiliki reliabilitas yang baik.

**2.3 Analisis Data**

Analisis data dilakukan dengan menyeleksi, membersihkan, dan mengelompokkan hasil pengukuran EC dan suhu ke dalam tiga kategori nutrisi, yaitu low, optimal, dan high. Data yang sudah siap kemudian diproses menggunakan perhitungan jarak Euclidean sebagai dasar penerapan algoritma K-Nearest Neighbors (KNN), sehingga model klasifikasi dapat dibangun secara akurat untuk digunakan pada tahap berikutnya.

**2.4 Perancangan Sistem**

Perancangan sistem dilakukan untuk menentukan alur kerja otomasi nutrisi hidroponik mulai dari pembacaan sensor hingga proses klasifikasi dan pengendalian. Tahap ini menggambarkan bagaimana data EC dan suhu diproses oleh sistem IoT dan digunakan sebagai dasar penentuan tindakan otomatis. Alur lengkap proses kerja sistem disajikan pada flowchart berikut.



**Gambar 2. Flowchart Sistem Otomasi**


Setelah alur dirancang, setiap proses pada flowchart diimplementasikan melalui integrasi sensor, mikrokontroler, dan algoritma KNN. Sistem



kemudian menjalankan pembacaan sensor secara berkala, mengklasifikasikan kondisi nutrisi, serta mengaktifkan aksi otomatis sesuai kategori yang terdeteksi. Perancangan ini memastikan bahwa sistem mampu bekerja secara terstruktur, responsif, dan berfungsi secara real-time.

**2.5 Cara Kerja Sistem**

Cara kerja sistem dirancang untuk menggambarkan bagaimana sensor, mikrokontroler, dan algoritma klasifikasi berinteraksi dalam menentukan kondisi nutrisi hidroponik. Alur kerja ini menunjukkan proses mulai dari pembacaan data hingga keluaran sistem berupa tindakan otomatis. Rancangan lengkap cara kerja sistem ditunjukkan pada gambar berikut.



**Gambar 3. Rancangan Cara Kerja Sistem**

Setelah alur kerja disusun, setiap proses dijalankan secara berurutan, dimulai dari pembacaan EC dan suhu, pengiriman data ke sistem pemrosesan, klasifikasi kondisi menggunakan KNN, hingga pemberian tindakan otomatis seperti penambahan atau pengenceran larutan. Rancangan ini memastikan seluruh komponen bekerja terintegrasi sehingga sistem mampu merespons kondisi nutrisi secara real-time.

**3. HASIL DAN PEMBAHASAN**

**3.1 Hasil Pengukuran Sensor**

Pengukuran sensor dilakukan untuk memastikan bahwa nilai EC dan suhu yang digunakan sebagai input klasifikasi memiliki akurasi yang baik. Pengujian dilakukan dengan membandingkan pembacaan sensor terhadap alat ukur standar untuk mengetahui tingkat kesalahan dari masing-masing sensor.

**Tabel 1. Pengujian Sensor TDS**

No	Kondisi Tangki	Pembacaan Sensor (mS/cm)	Nilai Avg. (mS/cm)	Error (%)
1	Low	0.79, 0.81, 0.78, 0.82, 0.79	0.798	0.25%
2	Optimal	1.62, 1.59, 1.61, 1.60, 1.61	1.606	0.38%
3	High	2.98, 3.03, 3.01, 2.99, 3.04	3.010	0.33%

Persentase error absolut pada Sensor Electrical Conductivity (EC) dihitung menggunakan Formula 5 dengan membandingkan selisih mutlak antara nilai rata-rata pembacaan sensor dan nilai referensi larutan uji. Berdasarkan hasil pengujian pada Tabel 4.3, sensor menunjukkan akurasi yang baik dengan nilai error tertinggi hanya sebesar 0,38% pada titik klasifikasi Optimal, sehingga dapat disimpulkan bahwa Sensor EC memiliki tingkat ketelitian yang layak digunakan dalam proses klasifikasi nutrisi.

**Tabel 2. Pengujian Suhu DHT-11**

No	Suhu Referensi (C)	Suhu DS18B20 (C)	Nilai Avg. (C)	Error (%)
1	21.0	20.8, 21.1, 20.9, 21.0, 20.9	20.94	0.29
2	26.0	25.9, 26.1, 25.7, 26.0, 26.2	25.98	0.08
3	31.0	30.8, 31.1, 30.7, 31.0, 31.2	30.96	0.13

Berdasarkan hasil pengujian suhu menggunakan sensor DS18B20, sensor menunjukkan tingkat akurasi yang baik dengan error absolut di bawah 1%. Nilai error tertinggi tercatat sebesar 0,29% pada titik suhu kategori Rendah, sehingga sensor ini dinilai cukup stabil dan layak digunakan sebagai parameter pendukung dalam proses klasifikasi kondisi nutrisi.

**3.2 Penerapan KNN**

Penerapan algoritma K-Nearest Neighbors (KNN) dilakukan untuk mengklasifikasikan kondisi nutrisi berdasarkan dua parameter utama, yaitu nilai EC dan suhu larutan. Pada tahap ini, data hasil



pengukuran yang telah dikumpulkan sebelumnya diolah dan dikelompokkan untuk membentuk dataset pelatihan. Setiap data diberi label kategori nutrisi Low, Optimal, atau High sesuai rentang standar hidroponik, sehingga model KNN dapat mengenali pola kedekatan antar data berdasarkan fitur yang digunakan.

**Tabel 3. Dataset Training**

No	EC (mS/cm)	Suhu Larutan	Label
1	0.49	21.3	Low
2	0.52	23.1	Low
3	0.61	22.7	Low
4	0.82	24.0	Low
5	0.76	20.9	Low
6	0.98	23.5	Low
7	1.08	24.8	Low
8	0.63	21.0	Low
9	1.16	23.9	Low
10	0.84	20.5	Low
11	1.30	25.4	Optimal
12	1.44	26.1	Optimal
13	1.76	24.5	Optimal
14	1.99	27.8	Optimal
15	1.22	24.0	Optimal
16	1.46	26.7	Optimal
17	2.04	25.2	Optimal
18	1.69	26.0	Optimal
19	1.38	24.9	Optimal
20	1.56	27.1	Optimal
21	2.30	28.3	High
22	2.60	29.0	High
23	3.01	30.2	High
24	2.84	27.6	High
25	3.40	31.1	High
26	2.51	28.9	High
27	3.78	32.0	High
28	3.20	29.7	High
29	2.25	27.4	High
30	2.76	28.0	High

No	EC (mS/cm)	Suhu Larutan	Label
----	------------	--------------	-------

Penerapan algoritma K-Nearest Neighbors (KNN) dimulai ketika sistem menerima data baru berupa nilai EC dan suhu hasil pembacaan sensor. Data baru ini menjadi input utama untuk menentukan kategori nutrisi. Setelah data diterima, tahap selanjutnya adalah menghitung jarak antara data uji dan seluruh data pelatihan menggunakan rumus Euclidean Distance. Perhitungan jarak dilakukan secara individual terhadap setiap record pada dataset training, sehingga diperoleh daftar nilai jarak yang menggambarkan tingkat kedekatan data uji dengan data pelatihan.

**Tabel 4. Nilai Euclidean Distance**

Data	Label	Jarak Euclidean
D1	Low	5.572
D2	Low	3.838
D3	Low	4.177
D4	Low	2.848
D5	Low	5.884
D6	Low	3.271
D7	Low	1.974
D8	Low	5.820
D9	Low	2.832
D10	Low	6.262
D11	Optimal	1.319
D12	Optimal	0.601
D13	Optimal	2.241
D14	Optimal	1.331
D15	Optimal	2.721
D16	Optimal	0.000
D17	Optimal	1.710
D18	Optimal	0.772
D19	Optimal	1.804
D20	Optimal	0.424
D21	High	1.993
D22	High	2.825
D23	High	4.130
D24	High	2.149
D25	High	5.183



D26	High	2.654
D27	High	6.233
D28	High	3.880
D29	High	1.318
D30	High	2.252

Setelah seluruh nilai jarak diperoleh, langkah berikutnya adalah mengurutkan jarak tersebut dari yang paling kecil hingga paling besar. Pengurutan ini diperlukan untuk menentukan K tetangga terdekat sesuai nilai K yang digunakan pada penelitian. Proses sorting menghasilkan daftar jarak dengan urutan prioritas, yang kemudian disajikan dalam tabel khusus untuk mempermudah identifikasi tetangga terdekat.

**Tabel 5. Hasil Sorting Euclidean Distance**

Data	Label	Jarak Euclidean
D16	Optimal	0.000
D20	Optimal	0.424
D12	Optimal	0.601
D18	Optimal	0.772
D29	High	1.318
D11	Optimal	1.319
D14	Optimal	1.331
D17	Optimal	1.710
D19	Optimal	1.804
D7	Low	1.974
D21	High	1.993
D24	High	2.149
D13	Optimal	2.241
D30	High	2.252
D15	Optimal	2.721
D22	High	2.825
D9	Low	2.832
D4	Low	2.848
D6	Low	3.271
D26	High	2.654
D8	Low	3.820
D2	Low	3.838
D28	High	3.880

D23	High	4.130
D3	Low	4.177
D25	High	5.183
D1	Low	5.572
D5	Low	5.884
D27	High	6.233
D10	Low	6.262

Berdasarkan hasil perhitungan Jarak Euclidean yang telah diurutkan pada Tabel, penentuan kelas untuk Data Uji T1 (EC=1.46 mS/cm, TR=26.7 C) dilakukan melalui mekanisme voting mayoritas dari K=5 tetangga terdekat.

Dari 5 data terdekat tersebut, diperoleh hasil perolehan suara (vote) sebagai berikut:

- a. Kelas Optimal: 4 suara (D16, D20, D12, D18)
- b. Kelas High: 1 suara (D29)
- c. Kelas Low: 0 suara

Oleh karena itu, karena kelas Optimal memiliki suara mayoritas terbanyak (4 dari 5), sistem memutuskan bahwa data baru tersebut diklasifikasikan ke dalam kategori Optimal.

**3.3 Hasil Dan Pengujian**

Pengujian akurasi dilakukan untuk menilai kemampuan algoritma K-Nearest Neighbors (KNN) dalam mengklasifikasikan kondisi nutrisi berdasarkan kombinasi nilai EC dan suhu. Proses pengujian dilakukan dengan membandingkan hasil klasifikasi KNN terhadap kategori nutrisi aktual pada setiap data uji. Dengan demikian, dapat diketahui sejauh mana model mampu menghasilkan prediksi yang tepat sesuai pola data yang telah dipelajari pada tahap pelatihan.

**Tabel 6. Skenario Pengujian**

No	EC (mS/cm)	Suhu (°C)	Label Aktual	Label Prediksi (K=5)	Status
1	0.98	23.5	Low	Low	Benar
2	1.16	23.9	Low	Optimal	Salah
3	1.44	26.1	Optimal	Optimal	Benar
4	1.99	27.8	Optimal	Optimal	Benar



5	1.56	27.1	Optima 1	Optima 1	Benar
6	2.60	29.0	High	High	Benar
7	2.84	27.6	High	High	Benar
8	3.20	29.7	High	High	Benar
9	2.76	28.0	High	High	Benar
10	0.82	24.0	Low	Low	Benar

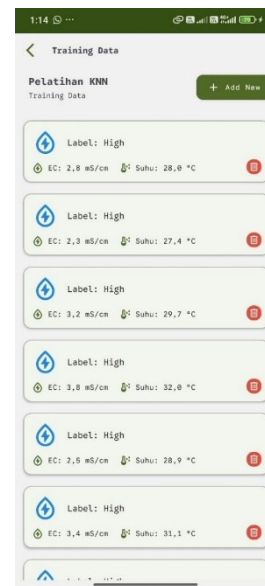
Dari total 10 kali percobaan pengujian, model KNN berhasil memprediksi label dengan benar sebanyak 9 kali, sementara 1 percobaan diprediksi salah. Hasil akurasi sebesar 90% menunjukkan bahwa model KNN yang diimplementasikan memiliki tingkat keandalan yang tinggi. Kesalahan tunggal terjadi pada Percobaan No. 2, di mana label aktualnya adalah Low namun model memprediksinya sebagai Optimal.

Antarmuka sistem dirancang untuk memudahkan pengguna dalam melakukan pemantauan, pengelolaan data, serta proses klasifikasi kondisi nutrisi. Setiap tampilan dibuat sederhana, responsif, dan fokus pada penyajian informasi utama agar pengguna dapat memahami status nutrisi hidroponik secara real-time tanpa kesulitan. Berikut adalah tampilan antarmuka yang telah dikembangkan pada sistem.



**Gambar 3. Antarmuka Beranda**

Antarmuka beranda menampilkan informasi umum sistem, termasuk akses menuju menu utama seperti halaman training, klasifikasi, dan monitoring data. Tampilan ini memberikan navigasi awal bagi pengguna untuk memilih fungsi yang ingin digunakan.



**Gambar 4. Antarmuka Training**

Halaman training digunakan untuk mengelola dataset yang akan dijadikan data pelatihan bagi algoritma KNN. Pada tampilan ini, pengguna dapat melihat, menambah, atau memperbarui data EC dan suhu beserta label kategorinya. Antarmuka dibuat sederhana agar proses pengolahan data training dapat dilakukan dengan cepat.



**Gambar 5. Antarmuka Klasifikasi**

Antarmuka klasifikasi menampilkan proses dan hasil klasifikasi kondisi nutrisi secara real-time berdasarkan data yang diterima dari sensor. Pengguna dapat melihat nilai EC, suhu, jarak perhitungan, serta kategori nutrisi yang ditentukan oleh algoritma KNN. Tampilan ini menjadi bagian



utama sistem karena menjadi dasar pengambilan keputusan otomatis.

Secara keseluruhan, antarmuka yang dikembangkan memberikan kemudahan dalam penggunaan sistem dan memastikan setiap proses mulai dari pengelolaan data hingga klasifikasi dapat dilakukan secara efisien dan mudah dipahami oleh pengguna.

#### 4. KESIMPULAN

Penelitian ini menghasilkan sistem otomasi nutrisi hidroponik berbasis IoT yang mampu mengukur nilai EC dan suhu secara real-time serta melakukan klasifikasi kondisi nutrisi menggunakan algoritma K-Nearest Neighbors (KNN). Berdasarkan hasil pengujian sensor, Sensor EC menunjukkan tingkat akurasi tinggi dengan error absolut rata-rata sangat kecil, sedangkan sensor suhu memiliki error yang masih berada dalam batas toleransi sehingga keduanya layak digunakan sebagai input sistem. Pengujian terhadap algoritma KNN menunjukkan bahwa model mampu melakukan klasifikasi kondisi nutrisi dengan akurasi mencapai 90%, yang berarti sebagian besar prediksi sesuai dengan kondisi aktual lapangan. Hasil ini membuktikan bahwa kombinasi antara sensor, IoT, dan metode klasifikasi berbasis data dapat digunakan untuk mendukung otomasi nutrisi hidroponik secara efektif. Secara keseluruhan, sistem yang dikembangkan telah dapat bekerja dengan baik dan memberikan hasil yang stabil dalam menentukan kategori nutrisi sebagai dasar pengambilan keputusan otomatis.

#### 5. REFERENSI

- Abdullah, A., & Jena, A. (2021). Pengaruh Pemberian Pupuk Organik Cair Terhadap Pertumbuhan Tanaman Selada (*Lactuca Sativa L*) Secara Hidroponik. *3*(1), 21–27.
- Agus, Hermala, I., Hendrasto, N., & Daulay, S. (2022). Sistem Pintar IoT Berbasis Arduino dan Android untuk Pengontrolan Kondisi pH dan TDS pada Pengairan Hidroponik Smart IoT System of Arduino and Android Based for pH and TDS in Hydroponic Irrigation. *6*(1), 101–108.
- Ariyo Banjardana, Titi Andriani, Paris Ali Topan, N. A. (2024). *Prototipe Sistem Monitoring Dan Kontrol Ph Serta Nutrisi Tanaman Hidroponik Berbasis Iot Untuk Pertanian*. 455–464.
- Bimanta, G. A., Prisca, C., Larasati, T., & Pradana, I. M. (2022). *Sistem Pengendali Suhu Ruang berbasis IoT Pada Gudang dengan Metode KNN*. *4*(1), 9–16.
- Dzi, M., Hasin, W., Sukoco, D., & Munadhif, I. (2024). *Penerapan Neural Network sebagai Klasifikasi Kualitas Air Hasil Filtrasi Reverse Osmosis*. *11*(September), 668–679.
- Erlangga, F., Nur, A., Utami, L., & Khadijah, S. (2024). *Pengembangan Prototype Smart Sistem Penyiraman Dan Pemupukan Tanaman Secara Otomatis Dengan Sistem Monitoring Berbasis IoT*. *16*, 1–6.
- Fatori, M. M. F. (2022). *Aplikasi IoT Pada Sistem Kontrol dan Monitoring Tanaman Hidroponik*. *2*(2), 350–356.
- Hafizhiadi Rizki Cahyaputra, R. R. (2024). *Klasifikasi tingkat kematangan buah paprika menggunakan metode k-nearest neighbor berdasarkan warna rgb melalui aplikasi matlab*. *9*(1), 242–249.
- Leonard, B. P., Azzizah, E., & Sugiartini, E. (2021). *Uji Efektivitas Budidaya Sistem Hidroponik dan Akuaponik pada Tiga Varietas Bawang Merah ( Allium ascalonicum L .) Hydroponics and Aquaponics System Cultivation Effectiveness Test on Three Varieties of Shallots ( Allium ascalonicum L .)*. *12*(200), 204–210.
- Made, I. G., Dipayasa, A., Aurelius, R., Diaz, N., Ayu, I. G., & Upadani, W. (2025). *Smart Hidroponik Dengan IoT Menggunakan KNN Untuk Monitoring Nutrisi Tanaman Bayam*. *2*(1), 157–162.
- Maysandra, A., & Ikhsan, M. (2025). *Sistem Irigasi Otomatis Budidaya Anggrek Menggunakan Metode Fuzzy K-Nearest Neighbor ( FK-NN ) Berbasis Internet of Things*. 2021. <https://doi.org/10.33364/algorithm/v.22-1.2335>
- Priatno, E. A., & Muniroh, N. (2022). *Penerapan Algoritma K-Nn Pada Machine Learning Untuk Klasifikasi Kualitas Air Budidaya Akuaponik Berbasis IoT*. *4*(2), 73–86.
- Rahmawati, Y. F., Wirman, S. P., & Fitrya, N. (2025). *Sistem Pengontrol Nutrisi Otomatis Tanaman Hidroponik Berbasis IoT IoT-based Hydroponic Plant Automatic Nutrient Control System*. *11*(2), 262–273.
- Romagusta, I. G., & Sonalitha, E. (2024). *Prediksi Kematangan Tomat Menggunakan Sensor Warna dengan Metode KNN*.
- Wiranti, D. yu. (2021). *Implementasi Sistem Pengukuran Ph Dan Suhu Pada Tanaman Aquaponik Berbasis Internet Of Things Menggunakan K-Nearest Neighbour*.