


BAB III

METODE PENELITIAN

3.1 *Flowchart* Penelitian



Gambar 3. 1 *Flowchart* Penelitian


Berdasarkan Gambar 3.1, terdapat tahapan-tahapan yang harus dilakukan dalam melaksanakan penelitian. Dari setiap tahapannya, tentu terdapat metode operasi, metode validasi dan metode bagaimana mendapatkan hasil penelitian.

3.2 Studi Literatur

Pada tahap ini, dilakukan studi untuk mencari referensi sebagai dasar teori serta mempelajari konsep yang berhubungan dengan pengendalian *Artificial Neural Network* (ANN), Sistem dan *Internet of Things* (IoT). Referensi yang digunakan meliputi artikel ilmiah, baik dari jurnal nasional maupun internasional, serta buku elektronik.

3.3 Perancangan Sistem

Pada tahap ini, dilakukan perancangan sistem untuk menjalankan *plant* dengan baik. Tahapan perancangan sistem ditunjukkan pada Gambar 3.2.




Gambar 3. 2 Diagram Blok Perancangan Sistem

Pada Gambar 3.2, proses perancangan dimulai dengan pengumpulan data input dan data target yang diperlukan untuk pelatihan model *Artificial Neural Network* (ANN). Data input terdiri dari parameter pH dan ppm pada tanaman hidroponik, sedangkan data target adalah nilai pH dan ppm yang ideal untuk tanaman, yang berfungsi sebagai output untuk durasi pompa nutrisi beroperasi. Model ANN dilatih dengan data input dan data target yang telah dikumpulkan menggunakan *software* MATLAB. Proses pelatihan ini melibatkan proses penyesuaian parameter-parameter ANN dengan metode *backpropogation*. Model JST yang telah dilatih diuji dengan data input yang baru untuk memastikan keakuratan model. Data yang diuji berupa nilai Error MSE dan R. Model JST yang telah terlatih diimplementasikan ke dalam

hardware yang akan digunakan untuk mengendalikan sistem nutrisi hidroponik. Data kontrol nutrisi diintegrasikan dengan *platform* IoT agar pembacaan parameter dapat *realtime* dan dapat disimpan di *database*.

3.3.1. Diagram Blok Sistem




Gambar 3. 3 Diagram Blok Sistem

Pada Gambar 3.3 menunjukkan sistem pengendalian pH dan nutrisi dengan ANN yang terdiri dari dua komponen utama yaitu *node* sensor dan Internet. *Node* berfungsi mengukur data air menggunakan sensor pH dan PPM, sensor suhu digunakan sebagai kalibrasi sensor PPM serta sensor jarak ultrasonik HCSR-04 digunakan sebagai mengukur ketersediaan air di bak penampungan nutrisi air. Sistem ini diproses oleh Portenta H7 dengan algoritma *Artificial Neural Network* (ANN) untuk mengendalikan *relay* pompa peristaltik. Pompa ini menambahkan larutan alkali (pH up), asam (pH down), atau nutrisi AB Mix sesuai kebutuhan. Pompa air baku bekerja apabila ketersediaan air nutrisi tidak sesuai dengan *setpoint* (air nutrisi berkurang di bak penampungan) serta air menguap yang menyebabkan kadar PPM AB Mix

meningkat secara drastis. Selain itu portenta H7 menampilkan data hasil pengukuran ke LCD TFT untuk tampilan *real-time local*. Pada bagian Internet, data diteruskan ke Node-RED untuk pemrosesan, visualisasi, dan kendali otomatis serta disimpan di *database* MySQL untuk analisis historis. Komunikasi antarperangkat menggunakan protokol MQTT melalui MQTT broker.

3.3.2. Flowchart Sistem



Gambar 3. 4 Flowchart Sistem

Pada Gambar 3.4 diatas menggambarkan alur kerja sistem pengendalian pH dan nutrisi dengan ANN. Sistem dimulai dengan menyalakan sistem. Sensor membaca kadar pH dan PPM nutrisi air, kemudian data tersebut diproses oleh Portenta H7 menggunakan algoritma *Artificial Neural Network*

(ANN). Jika kadar pH dan PPM tidak sesuai, pompa peristaltik diaktifkan berdasarkan prediksi durasi dari model ANN untuk menyesuaikan kadar nutrisi. Setelah kadar nutrisi sesuai, Portenta H7 memproses data dan menampilkannya di layar LCD TFT. Jika tampilan data berhasil, Portenta H7 menghubungkan sistem ke jaringan Wi-Fi. Selanjutnya, data dikirim ke Node-RED untuk visualisasi dan disimpan di *database*.

3.4 Pembangunan Sistem

3.4.1. Perancangan Sistem *Software*

Perancangan sistem *software* dirancang untuk mengontrol tingkat pH dan ppm nutrisi dalam air hidroponik secara otomatis menggunakan algoritma *Artificial Neural Network* (ANN). Tahapan perancangan *software* ini mencakup:

3.4.1.1. Uji Validitas Data Sensor

Pengujian validitas data sensor dilakukan dengan membandingkan hasil pengukuran sensor terhadap data referensi dari alat ukur standar menggunakan metode korelasi Pearson. Metode ini dipilih untuk mengevaluasi kekuatan dan arah hubungan linear antara kedua data berdasarkan rumus 2.5. Data sensor dianggap valid jika nilai koefisien korelasi signifikan dan mendekati 1 sesuai dengan Tabel 2.1, sehingga dapat digunakan sebagai dataset untuk pengembangan model *Artificial Neural Network* (ANN). Proses ini memastikan kualitas data yang digunakan mendukung keakuratan prediksi model.

Tabel 3. 1 Uji Validitas Data Sensor

No	Data Sensor (x)	Data Alat Ukur (y)	Galat (%)	Nilai Korelasi Pearson (R)	Keterangan
1.	x_1	y_1	Err_1	r_1	
2.	x_2	y_2	Err_2	r_2	
3.	x_3	y_3	Err_3	r_3	
4.	X_n	Y_n	Err_n	R_n	

3.4.1.2. Akuisisi Data

Tahap ini bertujuan mengumpulkan data untuk melatih model ANN. Data pH dan ppm diperoleh secara *real-time* dari sensor yang terhubung dengan mikrokontroler, kemudian disimpan bersama parameter referensi untuk tanaman hidroponik selada pH (6–7) dan ppm (560–840). Dataset juga mencakup respons sistem, yaitu durasi aktif pompa pH up, pH down, dan pompa nutrisi.

Tabel 3. 2 Dataset akuisisi

No.	Kondisi Awal		pH up (ms)	pH down (ms)	AB Mix (ms)	Kondisi Akhir	
	pH	PPM				pH	PPM
1.							
2.							
3.							
...							
dst.							

Dataset ini digunakan untuk melatih model ANN agar mampu mengontrol pH dan ppm air hidroponik secara otomatis berdasarkan kondisi aktual. Dataset yang diperoleh dari tahap akuisisi data mencakup nilai pH dan ppm dari sensor sebagai input, serta durasi aktivasi pompa (pH up, pH down,


dan pompa nutrisi) sebagai output. Sebelum digunakan untuk pelatihan, data *input* (pH dan ppm) dan *output* (durasi pompa) dinormalisasi ke dalam rentang (-1) sampai 1 menggunakan metode *min-max normalization*. Normalisasi untuk meningkatkan efisiensi proses pelatihan model, memastikan semua data berada pada skala yang sama, sehingga jaringan lebih stabil dan mampu mempelajari pola dengan lebih cepat.

3.4.1.3. Perancangan *Artificial Neural Network* (ANN)

Pada tahap ini, dilakukan perancangan *Artificial Neural Network* (ANN) untuk mengontrol pH dan ppm pada sistem hidroponik. *Artificial Neural Network* (ANN) dirancang untuk memproses data dari sensor pH dan sensor ppm sebagai input, lalu memberikan keluaran berupa waktu aktivasi tiga aktuator yaitu pompa pH up, pompa pH down, dan pompa nutrisi. Pelatihan model *Artificial Neural Network* (ANN) dilakukan dengan *software* MATLAB menggunakan fitur *Neural Network Toolbox* dengan parameter awal sebagai berikut:

Tabel 3. 3 Parameter Pelatihan

Parameter	Nilai
<i>Input Neuron</i>	2 sensor (pH dan PPM)
<i>Output Neuron</i>	3 <i>relay</i> (pompa pH up, pH down pompa nutrisi A dan pompa nutrisi B)
<i>Hidden layer</i>	Konfigurasi jumlah neuron dan layer ditentukan berdasarkan eksperimen untuk mendapatkan hasil yang optimal.



Gambar 3. 5 Inisialisasi Bobot dan Bias

Setelah proses akuisisi data, berdasarkan Gambar 3.5 dilakukan inisialisasi bobot dan bias dengan algoritma Nguyen Widrow. Bobot ini digunakan pada proses pengolahan data. Algoritma tersebut dilakukan dua kali untuk menginisialisasi bobot V dan bias V_0 , yaitu bobot di antara input layer dan *hidden layer*, dan bobot W dan bias W_0 , yaitu bobot di antara *hidden layer* dan *output layer*.


3.4.1.4. Permodelan Training Data *BackProporgation*

Metode *backpropagation* digunakan untuk melatih *Artificial Neural Network* (ANN) dalam sistem kontrol nutrisi hidroponik. Teknik ini digunakan untuk mempelajari pola hubungan antara *input* (nilai pH dan ppm) dan output (durasi aktivasi pompa pH up, pH down, dan pompa nutrisi). *Backpropagation* bekerja dengan menghitung selisih antara prediksi model dengan target (*error*), kemudian memperbarui bobot pada jaringan untuk meminimalkan error

tersebut.

Model dilatih menggunakan metode *Backpropagation*. Proses pelatihan melibatkan pembagian dataset menjadi tiga bagian:

1. Data pelatihan (70%): Digunakan untuk melatih model.
2. Data validasi (15%): Untuk memantau performa model selama pelatihan dan mencegah overfitting.
3. Data uji (15%): Untuk mengevaluasi kemampuan generalisasi model pada data baru.



Gambar 3. 6 Algoritma Artificial Neural Network (ANN) Backpropagation

Berdasarkan Gambar 3.6 Proses pertama dalam *backpropagation* adalah membaca parameter utama yang diperlukan, termasuk jumlah data yang akan diolah, jumlah variabel input (n), jumlah unit pada *hidden layer* (m), serta jumlah output (o). Selain itu, juga ditentukan nilai *learning rate* (α), batas maksimum *error* yang diperbolehkan (err_max), serta jumlah iterasi maksimum atau *epoch* ($epoch_max$). Setelah parameter ini ditentukan, inisialisasi bobot menggunakan metode Nguyen-Widrow. Selanjutnya, matriks untuk penyimpanan bobot dan bias diinisialisasi sebelum proses utama dimulai.

Tahap berikutnya adalah menjalankan *feed forward*. Program memasuki perulangan (*looping*) yang akan terus berjalan selama *error* masih lebih besar dari err_max dan jumlah epoch masih di bawah $epoch_max$. Karena data yang digunakan berbentuk matriks, setiap iterasi akan memproses setiap kolom data secara berurutan, mulai dari kolom pertama hingga kolom terakhir. Pada *hidden layer*, setiap *neuron* menghitung jumlah sinyal *input* yang telah dikalikan dengan bobot masing-masing.

Setelah itu, nilai Z_{inj} yang dihasilkan akan diterapkan pada fungsi aktivasi untuk memperoleh nilai Z_j , yang kemudian diteruskan ke *output layer*. Di sini, setiap neuron pada *output layer* kembali menghitung jumlah sinyal input yang telah dikalikan dengan bobotnya, lalu menerapkan fungsi aktivasi untuk menghasilkan output akhir. Setelah memperoleh hasil dari proses *feed forward*, metode *backpropagation* digunakan untuk memperbarui bobot sehingga output semakin mendekati target, dengan tujuan untuk mengurangi *error*.

Langkah pertama dalam *backpropagation* adalah menghitung nilai *error*

menggunakan metode *error* kuadratis. Kemudian, sinyal *error* δ_k dihitung untuk setiap *neuron* pada *output layer* dengan membandingkan hasil terhadap target. Selanjutnya, bobot antara *output layer* dan *hidden layer* diperbarui menggunakan nilai *learning rate* α , dan bias pada lapisan tersebut juga diperbarui. Setelah itu, proses *backpropagation* dilanjutkan ke hubungan antara *hidden layer* dan *input layer*. Sinyal *error* δ_j dihitung untuk setiap *neuron* di *hidden layer*, diikuti dengan pembaruan bobot antara *hidden layer* dan *input layer*. Selain bobot, bias pada lapisan ini juga diperhitungkan dan diperbarui.

Setelah semua bobot dan bias diperbarui, langkah selanjutnya adalah melakukan *update* dengan menambahkan nilai bobot dan bias lama dengan perubahan yang telah dihitung sebelumnya. Setelah *error* dihitung, nilainya disimpan dalam matriks *error* pada kolom pertama. Proses *feed forward* dan *backpropagation* kemudian kembali dilakukan pada kolom data berikutnya hingga semua data diproses. Setiap kali seluruh data telah diproses dalam satu iterasi, nilai epoch akan bertambah satu. Perulangan ini akan terus berjalan hingga *error* lebih kecil dari *err_max* atau jumlah epoch telah mencapai *epoch_max*. Jika salah satu kondisi ini tidak terpenuhi, program akan keluar dari perulangan.

Setelah iterasi selesai, dilakukan perhitungan *Recognition Rate*, yaitu tingkat akurasi hasil yang diperoleh dengan membandingkan setiap elemen dalam matriks *output* terhadap nilai referensi tertentu. Program akan melakukan iterasi pada setiap kolom data, dengan indeks *j* dari 1 hingga jumlah total data. Fungsi mod digunakan untuk menentukan kelas dari setiap data berdasarkan indeksnya dalam matriks output. Jika hasil mod adalah 1, maka

output pada kolom *j* dibandingkan dengan vektor referensi. *Recognition Rate* akan meningkat jika kondisi terpenuhi. Proses ini dilakukan untuk setiap kelas hingga semua data selesai diproses. Langkah terakhir adalah menghitung jumlah epoch, total *error* yang diperoleh, serta *Recognition Rate* untuk menentukan hasil akhir dari proses pembelajaran.

3.4.1.5. Implementasi ke *Hardware*


Tahap implementasi ke *hardware* bertujuan untuk merealisasikan sistem kendali nutrisi hidroponik yang telah dirancang menggunakan model *Artificial Neural Network* (ANN). Pada tahap ini, model yang telah dilatih di MATLAB diintegrasikan dengan perangkat keras untuk mengontrol durasi pompa pH dan pompa nutrisi berdasarkan pembacaan sensor pH dan ppm secara *real-time*.

3.4.1.6. Pembangunan Integrasi *IoT*

Pembangunan integrasi *IoT* dalam sistem kontrol nutrisi hidroponik bertujuan untuk pemantauan, pengendalian, serta penyimpanan data secara *real-time* dan terstruktur. Sistem ini memanfaatkan *Node-Red* sebagai antarmuka visual (*interface*) untuk pemantauan dan kontrol serta basis data untuk menyimpan data historis.

3.4.2. Perancangan Sistem *Hardware*

3.4.2.1. *Design* Skematik Sistem



Gambar 3. 7 Skematik Sistem


Gambar 3.7 menunjukkan desain skematik sistem pengendalian pH dan nutrisi berbasis IoT. Sistem terdiri dari beberapa komponen utama, yaitu modul *input* daya, *Node* Sensor Portenta H7, sensor pH dan ppm, modul *relay*, pompa peristaltik dan tampilan LCD TFT. Sistem ini dirancang dengan konfigurasi pin sebagai berikut:

Tabel 3. 4 Konfigurasi Pin Portenta H7

Komponen	Fungsi	Pin pada Portenta H7	Deskripsi
Sensor pH	<i>Input analog</i>	A1	Mengukur tingkat keasaman/alkalinitas larutan.
Sensor TDS	<i>Input analog</i>	A0	Mengukur konsentrasi <i>Total Dissolved Solids</i> (TDS) dalam larutan.
Sensor DS18B20	<i>Input analog</i>	A2	Mengukur suhu air
Sensor HCSR-04	<i>Input analog</i>	PWM 6 (Trig), PWM7 (Echo).	Mengukur ketinggian bak penampungan nutrisi air
LCD TFT	<i>Interface</i>	CS: D8, SCK: D13, MOSI: D11, MISO: D12, DC: D9, RESET: D10	Untuk menampilkan data pH, TDS, dan status sistem.
Relay 1 (pH)	Kontrol pompa	PWM 2	Mengaktifkan pompa

Komponen	Fungsi	Pin pada Portenta H7	Deskripsi
Up)	pH Up		untuk menambahkan larutan pH meningkat.
Relay 2 (pH Down)	Kontrol pompa pH Down	PWM 3	Mengaktifkan pompa untuk menambahkan larutan pH menurun.
Relay 3 (Nutrisi)	Kontrol pompa nutrisi A dan pompa nutrisi B	PWM 4	Mengaktifkan pompa untuk menambahkan nutrisi ke larutan.
Relay 4 (Air Baku)	Kontrol pompa Air Baku	PWM 5	Mengaktifkan pompa untuk menambahkan air baku sebagai netralisir kondisi
Pompa Peristaltik (3 unit)	Aktuator cairan	Terhubung ke relay	Mengatur sirkulasi cairan sesuai kebutuhan pH dan nutrisi.
Pompa Air	Aktuator air	Terhubung ke relay	Mengatur volume air baku dengan menambahkan air baku.
Power Supply	5V DC	VIN dan GND	Menyediakan daya untuk seluruh sistem.


3.4.2.2. Design Case Sistem



Gambar 3. 8 *Design Case & Layout* Komponen Sistem

Berdasarkan Gambar 3.8 case ini dirancang menggunakan box dengan dimensi 220 mm × 150 mm × 75 mm untuk menampung komponen sistem. Case dilengkapi display LCD TFT di bagian atas untuk visualisasi data dan

konektor depan untuk power, sensor TDS, sensor pH, dan pompa peristaltik. Material yang digunakan adalah PLA. Desain ini dirancang agar *compact*, *portabel*, dan memudahkan akses koneksi.



Gambar 3. 9 *Design Case & Layout Peristaltic Pump*

Berdasarkan Gambar 3.9 case ini dirancang untuk menempatkan empat pompa peristaltik berfungsi dalam pengaturan pH dan nutrisi otomatis dengan dimensi 220 mm × 150 mm x 75 mm. Pompa terdiri atas pH Up Pump, AB Mix Nutrisi Pump, dan pH Down Pump, yang disusun simetris untuk kemudahan pemasangan dan perawatan. Dibuat menggunakan Fusion 360, materialnya menggunakan PLA dan dicetak menggunakan *3D Printer*.

3.5 Pengumpulan Alat dan Bahan

Pada tahap ini, dilakukan pengumpulan alat dan bahan untuk dilakukan perakitan dan pengujian agar sistem dapat berjalan dengan baik.

3.5.1. Alat Perancangan

Alat yang digunakan pada penelitian ini, yaitu alat permodelan dan program serta alat perancangan. Alat permodelan dan program ditunjukkan dalam Tabel 3.5

Tabel 3. 5 Alat Permodelan dan Program

No.	Nama Alat	Keterangan
1.	Laptop	OS Windows 11, Prosesor Intel Core i5, RAM 8 GB
2.	<i>Software</i> Matlab 2024a	Versi a tahun 2024 (Permodelan <i>plant</i> Algoritma <i>Artificial Neural Network</i> (ANN))
3.	<i>Software Autodesk Fusion</i>	Versi 2021 (Pembuatan Layout Design Hardware)
4.	Arduino IDE	Versi 1.8.12 2019 (Program Kontroler)
5.	Easy EDA	Versi 2024 (Design PCB)
6.	Node Red	Versi 2024 (Design Platform IoT)
7.	My SQL	Versi 8.20.40 (Menyimpan data monitoring)

Alat yang digunakan untuk kebutuhan perancangan diantaranya, obeng, tang kombinasi, penggaris, multimeter, *caliper* dan lain-lain.

3.5.2. Bahan Perancangan

Bahan Perancangan meliputi bahan perangkat keras (*hardware*) dan bahan perangkat lunak (*software*). Bahan hardware meliputi sebagai berikut seperti yang ditunjukkan pada Tabel 3.6.

Tabel 3. 6 Bahan *hardware*

No.	Nama Bahan	Keterangan
1.	Portenta	Portenta Breakout H7
2.	Sensor PH	Df Robot Analog pH meter V1.1
3.	Sensor PPM	Df Robot Analog Tds meter V1.0
4.	Sensor Suhu	Type DS18B20
5.	Sensor Jarak	HCSR-04
6.	Pompa Peristaltik	Peristaltik pump dosing kamoer pompa peristaltik 12V dc laboratorium
7.	Pompa Air	<i>MiniPump</i> (Mengalirkan air ke gully dan bak penampungan)


6.	Relay	Relay 5V DC 10A
----	-------	-----------------

Bahan *Software* meliputi *wiring* diagram, program Matlab Simulink, program C++, program *Javascript Node-Red* dan *design layout*.

3.6 Pengujian Unit

Dalam tahap ini dilakukan pengujian terhadap beberapa unit, diantaranya Sensor PH, Sensor PPM, Sensor Suhu, Sensor Jarak, Relay dan Lcd Tft. Jika unit tersebut sudah teruji, maka dapat dilakukan proses selanjutnya dan bisa dijadikan sebagai bahan penelitian.


3.6.1. Pengujian Unit Sensor pH



Gambar 3. 10 Pengujian Unit Sensor pH

Gambar 3.10 menunjukkan tahapan pengujian sensor pH untuk memastikan akurasi pembacaan setelah kalibrasi. Pengujian diawali dengan menyambungkan sensor pH ke Portenta H7, dilanjutkan dengan kalibrasi menggunakan larutan *pH buffer* sebagai referensi. Program disesuaikan dengan hasil kalibrasi untuk memastikan pembacaan sesuai standar. Data pH ditampilkan melalui *serial monitor* dan dibandingkan dengan alat ukur pH meter. Tahap akhir mengevaluasi kesesuaian pembacaan sensor dengan alat referensi, menghasilkan tingkat akurasi sensor pH.


3.6.2. Pengujian unit sensor *Total Dissolved Solids* (TDS)



Gambar 3. 11 Pengujian Unit Sensor TDS

Gambar 3.11 menggambarkan pengujian sensor TDS untuk memastikan akurasi pembacaan setelah kalibrasi. Sensor TDS disambungkan ke Portenta H7 Breakout, kemudian dikalibrasi menggunakan ppm meter sebagai referensi. Program disesuaikan berdasarkan hasil kalibrasi untuk memastikan pembacaan data sesuai. Data sensor ditampilkan melalui *serial monitor* dan dibandingkan dengan hasil ppm meter. Tahap akhir mengevaluasi kesesuaian pembacaan sensor dengan alat referensi, menghasilkan akurasi sensor TDS.


3.6.3. Pengujian unit sensor Suhu DS18B20



Gambar 3. 12 Pengujian Unit Sensor Suhu

Gambar 3.12 menunjukkan proses pengujian sensor suhu untuk memastikan tingkat akurasi setelah dilakukan kalibrasi. Sensor suhu dihubungkan dengan *Portenta H7 Breakout* dan dikalibrasi menggunakan *Thermometer* sebagai alat referensi. Program dikonfigurasi berdasarkan hasil kalibrasi untuk memastikan data yang terbaca sesuai dengan standar. Hasil pengukuran suhu ditampilkan melalui *serial monitor* dan dibandingkan dengan pembacaan dari *thermometer*. Langkah terakhir adalah mengevaluasi tingkat kesesuaian pembacaan sensor dengan alat referensi untuk menentukan akurasi sensor suhu.


3.6.4. Pengujian unit sensor Ultrasonik HCSR-04



Gambar 3. 13 Pengujian Unit HCSR-04

Gambar 3.13 menunjukkan proses pengujian sensor jarak untuk memastikan tingkat akurasi setelah dilakukan kalibrasi. Sensor jarak HCSR-04 dihubungkan dengan Portenta H7 *Breakout* dan dikalibrasi menggunakan alat ukur jarak sebagai alat referensi. Program dikonfigurasi berdasarkan hasil kalibrasi untuk memastikan data yang terbaca sesuai dengan standar. Hasil pengukuran jarak pada sensor ultrasonik ditampilkan melalui *serial monitor* dan dibandingkan dengan pembacaan dari alat ukur jarak. Langkah terakhir adalah mengevaluasi tingkat kesesuaian pembacaan sensor dengan alat referensi untuk menentukan akurasi sensor jarak.

3.6.5. Pengujian Model *Artificial Neural Network (ANN) Backpropagation*



Gambar 3. 14 Pengujian Unit Model

Pada Gambar 3.14 proses pengujian unit model *Artificial Neural*


Network (ANN) dimulai dengan menyiapkan dataset pengujian yang terdiri atas data input, seperti nilai pH dan PPM, serta target output berupa durasi pompa. Dataset ini kemudian dimasukkan ke dalam sistem untuk diuji. Parameter model *Artificial Neural Network* (ANN), seperti bobot dan bias yang telah dilatih sebelumnya, juga dimuat ke dalam sistem untuk menghasilkan prediksi. Hasil prediksi dari model dibandingkan dengan target output, dan kinerjanya dievaluasi menggunakan metrik *Mean Squared Error* (MSE). Jika hasil evaluasi menunjukkan bahwa kinerja model sudah optimal, memiliki nilai MSE mendekati 0 dan nilai korelasi pearson (R) mendekati 1 maka pengujian dianggap selesai. Namun, jika tidak optimal, model dapat diperbaiki atau dilatih ulang sebelum dilakukan pengujian ulang.

3.7 Perakitan Sistem

Apabila komponen yang telah diuji bekerja dengan baik, maka pada tahap ini akan digabungkan menjadi satu sistem sesuai dengan perencanaan. Sehingga akan membentuk *Artificial Neural Network* (ANN) dalam sistem kendali nutrisi hidroponik dan bisa dilanjutkan ke tahap pengujian sistem.

3.8 Pengujian Sistem


Pengujian dilakukan dengan melakukan pengujian stabilitas model *Artificial Neural Network* (ANN) terhadap perubahan parameter lingkungan serta pengujian konektivitas *Internet of Things* (IoT).



Gambar 3. 15 Pengujian Akurasi, Korelasi dan Kestabilan Model ANN

Berdasarkan Gambar 3.15 pengujian dimulai dengan menyiapkan sistem yang sudah terintegrasi dengan model *Artificial Neural Network* (ANN) dan *Internet of Things* (IoT). Data sensor (seperti pH dan PPM) diambil dan diproses oleh model *Artificial Neural Network* (ANN) untuk memprediksi durasi operasional pompa. Selanjutnya, hasil akhir prediksi nilai pH dan PPM dianalisis untuk mengetahui kesesuaiannya dengan nilai target yang telah ditetapkan. Jika hasilnya akurat, sistem dianggap berfungsi dengan baik. Jika

tidak, perbaikan dilakukan baik pada model *Artificial Neural Network* (ANN) maupun sensor untuk meningkatkan akurasi prediksi durasi pompa. Untuk mengetahui hubungan antara durasi kerja pompa terhadap hasil akhir parameter lingkungan, dilakukan uji korelasi Pearson (R). Uji ini bertujuan untuk mengetahui kekuatan dan arah hubungan antara variabel independen (durasi pompa) terhadap variabel dependen (nilai akhir pH dan PPM). Selanjutnya, dilakukan analisis keberartian korelasi, guna menentukan apakah hubungan yang terdeteksi secara statistik signifikan atau tidak. Secara paralel, dilakukan pula uji kestabilan sistem melalui analisis standar deviasi terhadap data hasil prediksi. Tujuannya adalah untuk melihat seberapa konsisten hasil prediksi ANN terhadap target prediksi. Nilai standar deviasi yang rendah menunjukkan bahwa sistem memiliki prediksi yang stabil dan akurat. Tahapan akhir adalah analisis hasil kestabilan sistem, yang menjadi tolok ukur penting dalam menilai keandalan sistem kendali berbasis ANN yang dirancang. Dengan demikian, penelitian ini tidak hanya mengevaluasi akurasi hasil prediksi terhadap target, tetapi juga mengukur hubungan kausal (melalui korelasi) dan kestabilan performa (melalui standar deviasi) dari sistem kendali otomatis. Setelah evaluasi selesai, pengujian dinyatakan selesai.



Gambar 3. 16 Pengujian Konektivitas IoT

Berdasarkan Gambar 3.16 pengujian dimulai dengan memantau data sensor (pH dan PPM) melalui *Node-RED*. Data tersebut kemudian dikirim dan disimpan ke *database MySQL*. Hasilnya diverifikasi untuk memastikan data masuk dengan benar dan koneksi IoT stabil. Setelah seluruh proses pengiriman dan penyimpanan data berhasil, dilakukan analisis terhadap kinerja komunikasi data menggunakan parameter *Quality of Service (QoS)*. Parameter QoS yang dievaluasi meliputi *latency*, yaitu waktu tunda dalam pengiriman data dari sensor ke server, *throughput*, yaitu jumlah data yang berhasil dikirim dalam satuan waktu tertentu, *packet loss*, yaitu jumlah data yang hilang selama proses transmisi dan *reliability*, yang menunjukkan tingkat keandalan sistem dalam mengirim dan menyimpan data secara konsisten. Analisis parameter QoS ini bertujuan untuk mengukur seberapa efektif sistem komunikasi dalam

mentransmisikan data sensor secara *real-time*. Pengujian selesai setelah data tercatat dengan akurat di MySQL.

3.9 Pengumpulan Data dan Validasi Data

Pada tahap ini, data dari setiap pengujian dikumpulkan, yaitu hasil percobaan permodelan yang dilakukan dengan berbagai parameter. Data yang dihasilkan dari MATLAB, kemudian data tersebut di implementasikan di hardware. Kemudian dilakukan validasi menggunakan standar deviasi, korelasi pearson sebagai pengujian hasil serta data uji konektivitas IoT.

3.9.1. Pengumpulan Data Akurasi Model

Pengujian model *Artificial Neural Network* (ANN) dilakukan untuk mengevaluasi kemampuan model dalam melakukan prediksi. Pengujian dilakukan dengan 9 skema percobaan variasi nilai awal pH dan PPM dengan melibatkan perbandingan antara hasil prediksi durasi operasional pompa yang dihasilkan oleh model dengan target akhir sistem.

Tabel 3. 7 Pengumpulan Data Akurasi Model ANN

No.	pH Awal	PPM Awal	Durasi (ms)			pH Akhir	PPM Akhir	Δ pH	Δ PPM
			pH Up	pH Down	AB Mix				
1									
2									
3									
...									
dst									
Rata-rata									

3.9.2. Pengumpulan Data Uji Keberartian Korelasi Pearson Model ANN

Pengumpulan data dilakukan untuk mengevaluasi hubungan antara durasi kerja pompa (pH up, pH down, dan AB mix) dengan nilai akhir pH dan PPM yang dihasilkan oleh sistem ANN berbasis IoT. Data diambil dari hasil

output sistem setelah penyetelan parameter lingkungan berdasarkan beberapa skema. Seluruh data kemudian dianalisis menggunakan korelasi Pearson untuk mengetahui kekuatan dan arah hubungan linier antar variabel. Uji keberartian dilakukan guna memastikan hubungan tersebut signifikan secara statistik dan mencerminkan kinerja prediktif model ANN dalam mengontrol pH dan PPM.

Tabel 3. 8 Pengumpulan Data Korelasi Pearson Model ANN

Skema	Korelasi Pearson			Tingkat Korelasi
	pH Up	pH Down	AB Mix	
1				
2				
3				
4				
5				
6				
7				
8				
9				

3.9.3. Pengumpulan Data Stabilitas Model ANN

Pengujian stabilitas model *Artificial Neural Network* (ANN) dilakukan untuk mengevaluasi kestabilan hasil prediksi pada berbagai skema. Pengujian menyajikan hasil analisis statistik deskriptif berupa nilai rata-rata, standar deviasi, dan koefisien variasi untuk parameter pH dan konsentrasi PPM pada masing-masing skema pengujian. Penyajian data ini bertujuan untuk mengevaluasi tingkat penyebaran (dispersi) dan kestabilan data yang diperoleh, sehingga dapat memberikan gambaran kuantitatif mengenai konsistensi, kestabilan dan reliabilitas sistem terintegrasi model ANN pada setiap skema.

Tabel 3. 9 Pengumpulan Data Stabilitas ANN

Skema	Rata-rata		Standar Deviasi		Koefisien Variansi (%)	
	pH	PPM	pH	PPM	pH	PPM
1						
2						
3						
4						
5						
6						
7						
8						
9						

3.9.4. Pengumpulan Data Konektivitas IoT

Pengujian konektivitas IoT dilakukan untuk mengevaluasi kehandalan sistem dalam mengirim dan menerima data melalui jaringan. Dalam pengujian ini, menggunakan evaluasi terhadap parameter *Quality of Service* (QoS) yang meliputi *latency*, *jitter*, *throughput* dan *packet loss*.


Tabel 3. 10 Pengumpulan Data Konektivitas IoT

No.	Waktu Pengamatan	<i>Latency</i>	<i>Jitter</i>	<i>Througput</i>	<i>Packet Loss</i>	<i>Indeks Tiphon</i>	Keterangan
1.							
2.							
...							
dst.							

3.10 Analisa

Pada tahap ini dilakukan analisis terhadap hasil permodelan meliputi serta dilakukan analisa data pada akurasi sensor dan implementasi hardware berdasarkan respon durasi pompa setelah ditanamkan kendali ANN, uji keberartian, stabilitas model dan analisa konektivitas IoT.

3.11 Subjek dan Objek Penelitian



Gambar 3. 17 Subjek dan Objek Penelitian

Berdasarkan Gambar 3.17 ini menunjukkan *design prototipe* sistem hidroponik NFT (*Nutrient Film Technique*) dengan tanaman selada sebagai objek pengujian. Sistem menggunakan sensor pH dan TDS untuk memantau kualitas larutan nutrisi, pompa peristaltik untuk menyesuaikan kadar pH dan TDS, serta kontroler Portenta H7 yang terhubung ke Node-RED dan database MySQL untuk pemantauan dan pengelolaan data secara *real-time*. Subjek penelitian adalah pengelolaan otomatis larutan nutrisi hidroponik dengan metode ANN, sedangkan objek penelitian adalah prototipe NFT dengan tanaman selada.

3.12 Waktu dan Tempat Pelaksanaan Penelitian

Proses pelaksanaan penelitian dan penyusunan laporan tugas akhir ini dimulai pada bulan September tahun 2024 sampai dengan selesai yang bertempat di Laboratorium Teknik Elektro Fakultas Teknik Kampus 2 Universitas Siliwangi, Kota Tasikmalaya. Waktu penelitian dilakukan

