

Implementasi Kontrol Nutrisi dan pH Pada Hidroponik Cerdas Berbasis Arduino dan JST

M Naufal Zul Hazmi^{*1}, Raden Sumiharto²

¹ Program Studi Elektronika dan Instrumentasi, DIKE, FMIPA, UGM, Yogyakarta, Indonesia

² Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: ^{*1}naufal.z.h@mail.ugm.ac.id, ²r_sumiharto@ugm.ac.id

Abstrak

Penelitian ini bertujuan untuk menerapkan sistem otomatisasi kontrol nutrisi dan pH pada sistem hidroponik NFT (Nutrient Film Technique) berbasis kendali JST (Jaringan Saraf Tiruan). Sistem Hidroponik NFT merupakan menanam tanaman tanpa media tanah. Tanaman hidroponik harus terus menerus dikontrol nutrisi dan pH-nya. Namun, kontrol manual yang dilakukan secara terus menerus oleh manusia tidak efisien dan memakan waktu..

JST digunakan untuk memodelkan dan memprediksi output aktuator berdasarkan input sensor pada sistem hidroponik NFT. JST melakukan pembelajaran dari dataset dan memprediksi output (pompaHUp, pompaHDown, pompaTDS) berdasarkan input (pH, TDS). Arsitektur JST ini memiliki jumlah neuron input layer: 2, hidden layers pertama: 128, hidden layers kedua: 64, output layers 3, dan model multipleoutputs. Pemodelan pelatihan JST digunakan untuk melakukan klasifikasi sampel data dengan variasi hyperparameter.

Hasil penelitian menunjukkan bahwa model klasifikasi JST berhasil diterapkan untuk mengontrol pH dan nutrisi dengan prediksi output aktuator. Aktuator pompa aktif sesuai dengan input yang diterima dari sensor TDS dan pH. Melalui variasi hyperparameter, ditemukan bahwa model klasifikasi dengan *test_size*: 0.3, *epoch*: 400, *batch_size*: 32, dan *random_state*: 42 memberikan performa terbaik dalam prediksi. Model klasifikasi JST ini mencapai hasil terbaik dalam pengujian model dengan tingkat akurasi sebesar 97.96% dari 49 data.

Kata kunci— Otomatisasi, Hidroponik NFT, Model klasifikasi, prediksi

Abstract

This research aims to implement an automated nutrition and pH control system in NFT hydroponic system based on ANN control. NFT hydroponics involves growing plants without soil as a medium. In hydroponics, it is essential to continuously control the nutrient levels and pH of the solution. However, manual control performed by humans continuously is inefficient and time-consuming.

The ANN method is used to model and predict the output actuators based on sensor input in the NFT hydroponic system. This ANN architecture consists of several layers with the following number of neurons: input layer 2, first hidden layer 128, second hidden layer 64, and output layer 3, representing multipleoutputs. The ANN training process involves classifying the data samples using various hyperparameters.

The research findings demonstrate the ANN classification model successfully applied to control pH and nutrient levels through the predicted output actuators. The pump actuators are activated according to input received from the TDS and pH sensors. Through the variation of hyperparameters, the classification model with a *test_size*: 0.3, *epoch*: 400, *batch_size*: 32, and *random_state*: 42 provided the best performance in prediction. This ANN classification model achieved the best results in model testing with an accuracy rate: 97.96% from 49 data.

Keywords— Automated nutrition control, NFT Hydroponics system, ANN Classification model, Prediction.

1. PENDAHULUAN

Setiap bertambahnya tahun, pertumbuhan penduduk di Indonesia akan semakin meningkat, sehingga kebutuhan bahan pangan juga akan berangsur naik. Salah satu cara menjaga ketahanan pangan di lahan yang terbatas ialah dengan bertani dengan menggunakan sistem hidroponik. Perkembangan sistem hidroponik di Indonesia dilatarbelakangi persoalan masyarakat yang ingin mengembangkan pertanian di lahan terbatas khususnya tanaman hortikultura meliputi tanaman sayuran, buah-buahan, hias dan biofarmaka [1].

Hidroponik merupakan sistem menanam tanaman hortikultura tanpa menggunakan media tanah. Tanaman hidroponik memperoleh sumber nutrisi melalui akarnya dengan cara dialiri air yang mengandung larutan nutrisi dengan sistem NFT (*Nutrient Film Technique*). NFT adalah metode bercocok tanam hidroponik di mana akar tanaman ditempatkan pada lapisan air yang tidak terlalu dalam [2]. Keunggulan hidroponik tanah antara lain pemeliharaan dan budidaya tanaman hidroponik lebih mudah karena tempatnya relatif bersih dan tanaman terlindung dari terpaan hujan, serangan hama penyakit relatif kecil, tanaman lebih sehat, Vigor, produktivitasnya tinggi, mutu hasil tanaman berkualitas tinggi dan tahan lama serta harga jualnya tinggi [3]. Tanpa media tanah, tanaman hidroponik memperoleh nutrisi melalui air yang dialirkan secara terus menerus melewati akar tanaman hidroponik. Selain itu, air yang dialirkan ke tanaman hidroponik juga akan ditampung kembali untuk dialirkan lagi ke media tanam hidroponik. Namun lama kelamaan nutrisi dalam bak penampungan air pun akan berkurang dan hilang bahkan akan menjadi keruh atau kotor akibat selalu dialirkan ke tanaman hidroponik.

Tanaman hidroponik memiliki kondisi lingkungan yang harus selalu dialiri dengan larutan nutrisi secara terus menerus. Tanaman menyerap ion dari larutan nutrisi yang diberikan secara terus menerus dalam tingkatan konsentrasi yang rendah [4]. Tanaman hidroponik harus selalu terkontrol kondisi dan keadaan lingkungannya baik dari pH cairan maupun kadar nutrisinya yang merupakan bagian terpenting dari tanaman hidroponik. Apabila proses kontrol tersebut dilakukan terus menerus secara manual oleh manusia, maka akan terasa berat dan sangat tidak efisien terhadap waktu. Sehingga diperlukan proses otomatisasi terhadap sistem kontrol nutrisi dan pH pada tanaman hidroponik. Dengan adanya proses otomatisasi ini diharapkan sistem tanaman hidroponik ini akan menghasilkan output yang terbaik dan maksimal untuk hasil panennya. Sistem otomatis ini akan berjalan secara terus menerus oleh sistem yang cerdas dengan menggunakan jaringan saraf tiruan sebagai kendali untuk parameter pengkondisian lingkungan pada tanaman hidroponik.

Jaringan saraf tiruan (JST) adalah jaringan komputasi yang mencoba untuk simulasi, proses pengambilan keputusan dalam jaringan sel saraf (neuron) dari sistem saraf pusat biologis (manusia atau hewan) [5]. JST ini dapat diterapkan sebagai kendali, di mana JST dapat mengambil keputusan layaknya saraf otak manusia. Jaringan saraf tiruan memiliki kemampuan untuk mengidentifikasi aktivitas berdasarkan data historis [6]. JST memiliki kemampuan yang lebih optimal ketika mengolah data dalam jumlah yang banyak atau besar dengan akurasi dan presisi yang tinggi. Dalam tanaman hidroponik konvensional, kontrol parameter kadar nutrisi dan pH dilakukan manual secara terus menerus oleh manusia, hal ini sangat tidak efisien dan hasil tanaman juga tidak maksimal. Sehingga dengan adanya JST ini diharapkan dapat diterapkan untuk proses otomatisasi kendali parameter yang ada pada tanaman hidroponik dan juga dapat bekerja memantau dan kontrol secara terus menerus oleh sistem kendali JST.

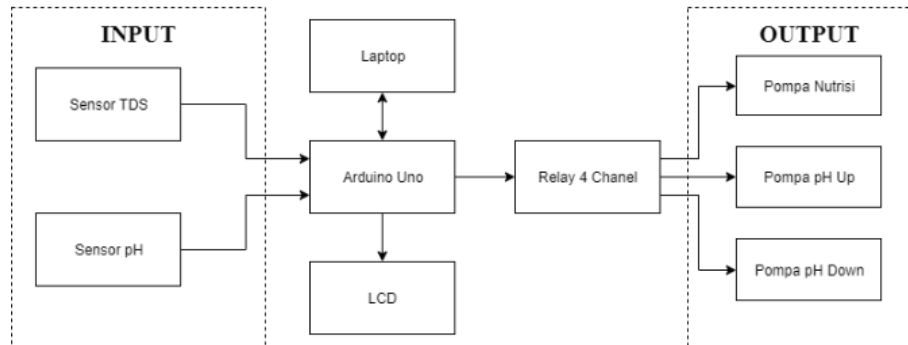
2. METODE PENELITIAN

2.1 Pembangunan Perangkat Keras

2.1.1 Perakitan Perangkat Keras

Penelitian ini menggunakan perangkat keras yang terdiri dari sensor pH, sensor TDS, Laptop, Arduino Uno, LCD, Relay 4 chanel, pompa pH Up, pompa pH Down, dan pompa Nutrisi. Berdasarkan dari komponen tersebut, maka dapat disusun blok diagram perangkat keras

sistem yang ditunjukkan pada Gambar 1. Keterkaitan antara perangkat keras tersebut yaitu data hasil bacaan input sensor baik dari sensor nutrisi maupun sensor pH akan diterima oleh Arduino UNO. Kemudian dari Arduino, data dari sensor-sensor tersebut akan ditampilkan di LCD dan dikirimkan ke Laptop, tempat terjadinya pemrosesan dan pengiriman data. Setelah data diproses oleh Laptop, data dikirimkan kembali ke Arduino, sehingga Arduino dapat mengoperasikan dan memanipulasi aktuator sesuai kebutuhan sistem yang sudah dibangun. Output aktuator ini meliputi dari pompa nutrisi, dan pompa pH up serta pompa pH down.

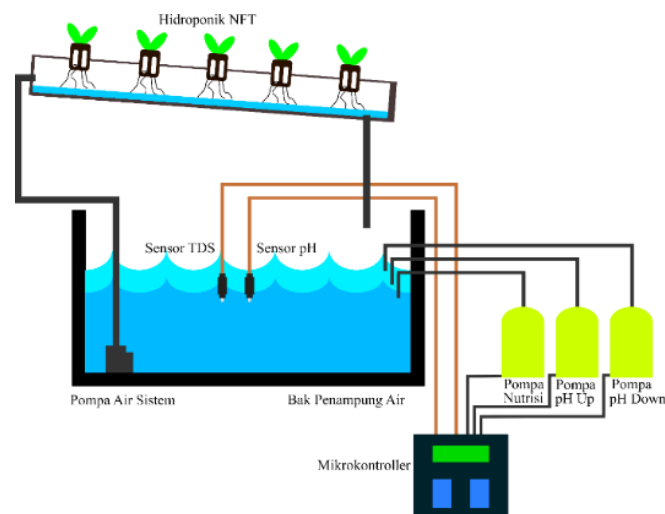


Gambar 1 Diagram Perangkat Keras

2.1.2 Desain Penempatan Perangkat Keras

Desain penempatan perangkat keras ada dua bagian yaitu bagian tanaman hidroponik dan reservoir (bak penampungan air). Pada area sistem tanaman hidroponik, susunan pipa cenderung dibuat miring, karena mengadopsi metode budidaya hidroponik NFT (*Nutrient Film Technique*). Ilustrasi penyusunan penempatan perangkat keras tersebut ditunjukkan pada Gambar 2.

Reservoir pada Gambar 2 dilengkapi dengan dua sensor, yaitu sensor TDS dan sensor pH, yang berfungsi untuk memantau nutrisi cairan dalam sistem hidroponik. Sensor-sensor ini digunakan untuk mengambil sampel cairan dan mendeteksi kadar nutrisi serta tingkat keasaman atau kebasahan. Bagian di luar reservoir, terdapat rangkaian elektronik dan tiga pompa (pompa pH Up, pH Down, TDS/nutrisi). Pompa nutrisi digunakan untuk memompa larutan nutrisi ke reservoir saat kadar nutrisi cairan menurun. Jika pH air terlalu tinggi, pompa pH down yang akan memompa cairan asam ke reservoir. Sebaliknya, jika pH air terlalu rendah, pompa pH up yang akan memompa cairan basa ke reservoir. Data dari sensor akan ditampilkan dan divisualisasikan melalui layar LCD untuk pemantauan data secara *real-time*.



Gambar 2 Desain Penempatan Perangkat Keras

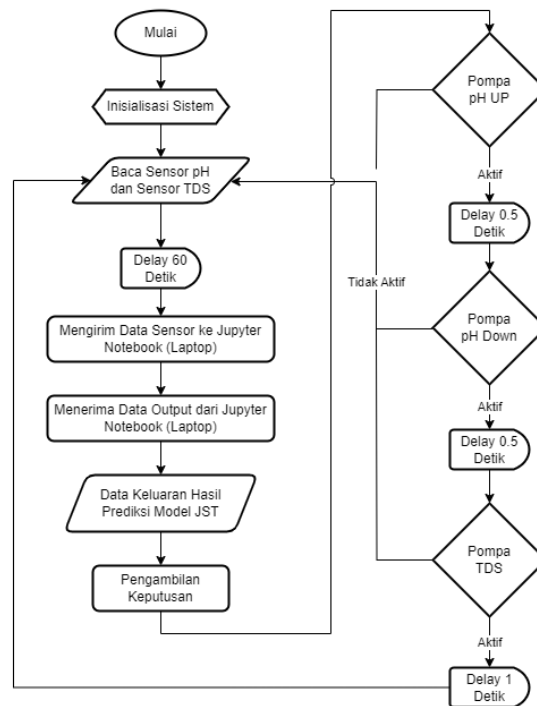
2.2 Pengembangan Perangkat Lunak

Pengembangan perangkat lunak dilakukan dalam dua bahasa pemrograman. Pertama, program Arduino IDE sebagai editor untuk input/output sensor dan aktuator. Kedua, program Python untuk pelatihan dan pengolahan data dengan menggunakan metode JST backpropagation. Data bacaan dari sensor TDS dan sensor pH digunakan sebagai input bagi JST backpropagation, dan keluarannya berupa kode biner 0 atau 1 untuk setiap label pompapHUp, pompapHDown, dan pompa TDS. Nilai 0 mengindikasikan pompa yang "tidak aktif", sedangkan nilai 1 mengindikasikan pompa yang "aktif".

2.2.1 Pengembangan Proses Kontrol pH dan TDS pada Arduino IDE

Batas nilai TDS dari tanaman selada adalah 560-840 ppm, namun dalam sistem ini diatur batas nilai pada nilai 640 – 860 ppm dengan maksud agar sistem tetap mempertahankan nilai TDS pada angka 640. Ketika nilai TDS kurang dari 640, maka pompaTDS akan aktif. Batas nilai untuk pH tanaman selada adalah 6.0 – 7.0, sehingga ketika nilai pH kurang dari 6.0 maka pompa yang aktif adalah pompapHUp, dan ketika nilai pH lebih dari 7.0 maka pompapHDown akan aktif, sedangkan ketika nilai pH pada rentang 6.0 – 7.0 maka baik pompapHUp maupun pompapHDown akan tidak aktif.

Pengembangan perangkat lunak meliputi dari tahapan deteksi parameter kadar nutrisi dan pH oleh sensor, dilanjutkan dengan pemrosesan atau pengolahan data menggunakan JST backpropagation. Output hasilnya meliputi aksi dari aktuator sebagai respons dari proses prediksi yang dilakukan oleh model JST. Pemberian delay pada bacaan sensor ini adalah sebesar 60 detik. Adapun delay pada pompa ini berguna untuk mengaktifkan seberapa lama pompa akan mengirimkan larutan ke dalam *chamber*.



Gambar 3 Flowchart Kontrol pH dan TDS pada Arduino IDE


2.3 Akuisisi Data

Sebelum proses pengambilan data, terlebih dahulu disiapkan sampel data untuk training model Neural Network untuk pertama kalinya. Sampel data yang digunakan merupakan dataset yang dibuat secara manual berupa "data dummy". Sampel data yang dibuat terdiri dari input (pH dan TDS) dan output (pompapHUp, pompapHDown, dan pompaTDS).

2.4 Pembangunan Arsitektur Artificial Neural Network

Arsitektur ANN pada kasus ini menggunakan jaringan *Feedforward Multilayer* [7]. Arsitektur ini terdiri dari, *Input Layer* mendapatkan input dari dataset. Input layer memiliki jumlah neuron 2 (pH dan TDS). Arsitektur ANN dapat dilihat pada

Gambar 4. Arsitektur ini memiliki dua *hidden layers* dengan menggunakan 'Dense' layer. Hidden layer pertama memiliki 128 neuron, sementara hidden layer kedua memiliki 64 neuron. Fungsi aktivasi pada setiap hidden layer adalah ReLu, yang memberikan sifat non-linearitas pada model. Untuk output, terdapat tiga Output Layers yang masing-masing digunakan untuk pompapHUp, pompapHDown, dan pompaTDS., menggunakan 'Dense' layer dengan 1 neuron dan fungsi aktivasi yang digunakan adalah sigmoid, yang menghasilkan probabilitas keluaran antara 0 dan 1 untuk klasifikasi biner. Input layer berperan sebagai input model, dan output layer dari setiap output berperan sebagai output model. Model multipleoutputs ini dapat memprediksi untuk setiap output secara terpisah.



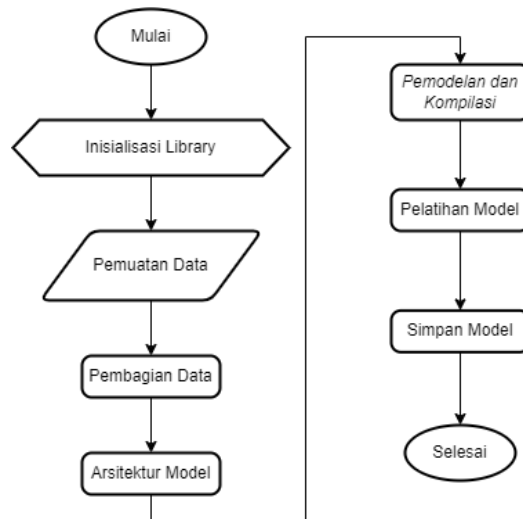
Gambar 4 Arsitektur Model ANN

2.5 Pemodelan Pelatihan JST Backpropagation

Backpropagation termasuk dalam jaringan multilayer karena memiliki tiga layer dalam proses pelatihannya [8]. Backpropagation adalah kemampuan jaringan untuk melatih dan mengenali pola yang digunakan selama pelatihan dan kemampuan jaringan untuk merespons dengan benar pola input yang serupa (tetapi tidak identik) dengan yang digunakan selama pelatihan [9]. Pelatihan JST backpropagation memiliki variasi parameter yang digunakan dalam sistem. Hyperparameter yang digunakan pada penelitian ini ditunjukkan pada Tabel 1. Sedangkan alur pemodelan pelatihan JST Backpropagation ditunjukkan pada Gambar 5.

Tabel 1 Setting Hyperparameter Pelatihan JST Backpropagation

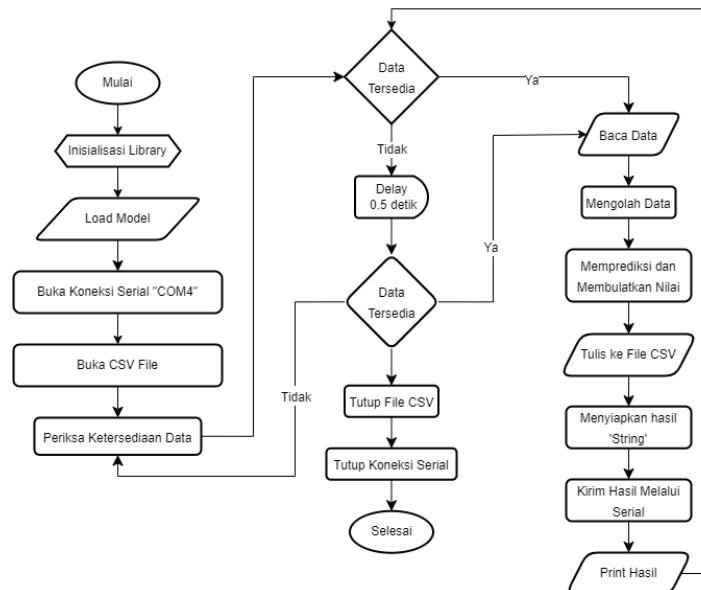
Test Size	Jumlah Epoch	Ukuran Batch	Random State	Optimizer	Loss Function	Metrik
0.2; 0.3; 0.4; 0.5	100, 200, 300, 400, 500	16, 32, 64, 128	0, 1, 42	adam	binary_crossentropy	accuracy



Gambar 5 Flowchart JST Backpropagation

2.5 Pengembangan Proses Pengambilan Data dengan Komunikasi Serial

Pengembangan proses pengambilan data ini bertujuan untuk menerima data melalui koneksi serial, melakukan prediksi menggunakan model yang telah dilatih, menyimpan hasil prediksi ke dalam file CSV, dan mengirim kembali hasil prediksi melalui koneksi serial. Tahapan alur pengambilan data dengan koneksi serial dapat dilihat pada Gambar 6.



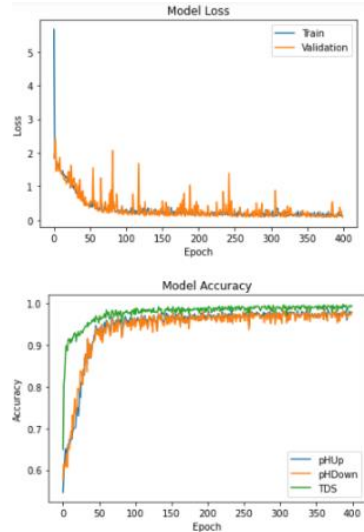
Gambar 6 Flowchart Pengambilan Data dengan Komunikasi Serial

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

Penelitian ini melakukan pelatihan model untuk mengamati kinerja model arsitektur dengan variasi jumlah nilai test size, epochs, ukuran batch, dan random state. Berdasarkan hasil akurasi dan loss, maka model dengan test size: 0.3; jumlah epoch: 400; ukuran batch: 32; dan random state: 42 termasuk model *good fit*. Pada Tabel 2 nilai akurasi dari setiap output dengan model variasi ini memiliki nilai yang tinggi dari pada model lainnya. Nilai loss juga rendah dari

lainnya, begitu juga nilai validation loss yang rendah disetiap outputnya. Jika dilihat pada Gambar 7 grafik accuracy dan loss pelatihan juga tidak terjadi fluktuasi yang signifikan dan cenderung stabil diakhir pelatihan. Sehingga model ini mampu menggeneralisasi dengan baik ke data baru, dan kinerja tinggi pada data yang belum pernah dilihat sebelumnya.



Gambar 7 Accuracy dan Loss 0.3;400;32;42

Tabel 2 Hasil Accuracy dan Loss Pelatihan Model

Test Size		0.3	0.4	0.2	0.2
Jumlah Epoch		400	500	400	500
Ukuran Batch		32	32	64	64
Random State		42	42	42	42
Loss		0.0864	0.0826	0.0989	0.0895
pHUp	Training Accuracy	0.9788	0.9518	0.9809	0.9663
	Validation Accuracy	0.989	0.9869	0.9862	0.9927
	Validation Loss	0.0352	0.0416	0.0348	0.0358
pHDown	Training Accuracy	0.9789	0.9413	0.9788	0.961
	Validation Accuracy	0.9855	0.9875	0.9836	0.9848
	Validation Loss	0.0402	0.0451	0.042	0.0467
TDS	Training Accuracy	0.9942	0.9752	0.9951	0.9885
	Validation Accuracy	0.9974	0.9961	0.9947	0.9993
	Validation Loss	0.011	0.0123	0.0126	0.008

3.2 Hasil Pengujian Model

Pengujian dilakukan terhadap pemodelan yang sudah dilatih menggunakan variasi parameter test size, epochs, ukuran batch, dan random state. Pada tahap pengujian, model diuji menggunakan dataset dengan format yang sama, namun berbeda data. Dataset ini diperoleh dari hasil pengambilan data dengan model yang telah dilatih sebelumnya. Hasil pengujian model dengan variasi parameter tersebut dapat dilihat pada Tabel 3.

Pada Tabel 3 terlihat bahwa Akurasi, Presisi, dan F1 Score umumnya memiliki nilai yang tinggi dan satu sama lain nilainya saling berdekatan atau tidak terlalu signifikan perbedaannya. Pengujian yang dilakukan dengan test size: 0.3; epoch 400; ukuran batch: 32; dan random state: 42 memiliki nilai akurasi, presisi, dan F1 score yang lebih tinggi, jika dibandingkan dengan variasi lainnya. Hal ini seperti pada proses pelatihan, di mana akurasi pelatihan dengan variasi ini lebih tinggi performanya dibandingkan pelatihan dengan variasi parameter lainnya yang memiliki beberapa fluktuasi pada modelnya. Pelatihan dan pengujian

model ini diambil model terbaik yaitu dengan variasi parameter test size: 0.3; epoch 400; ukuran batch: 32; dan random state: 42 yang termasuk kategori good fit.

Tabel 3 Hasil Pengujian Model

Test Size	0.3	0.4	0.2	0.2	Rerata(%)	
Jumlah Epoch	400	500	400	500		
Batch Size	32	32	64	64		
Random State	42	42	42	42		
pHUp	Akurasi (%)	97.72	96.55	95.81	97.28	96.68
	Presisi (%)	92.65	89.11	86.99	91.21	89.52
	F1 Score (%)	96.08	94.2	93.04	95.37	94.41
pHDown	Akurasi (%)	98.44	98.49	96.2	98.79	97.75
	Presisi (%)	99.59	99.52	100	99.46	99.83
	F1 Score (%)	97.62	97.69	93.97	98.17	96.51
TDS	Akurasi (%)	98.55	98.31	98.33	98.33	98.43
	Presisi (%)	99.84	99.38	99.19	98.48	99.22
	F1 Score (%)	98.73	98.52	98.55	98.57	98.63

3.3 Hasil Pengujian Sistem Kendali Model JST Backpropagation

Pengujian sistem kendali model JST Backpropagation berguna untuk melihat seberapa akurat model dalam melakukan pengujian dengan data real. Model yang digunakan merupakan model dengan test size: 0.3; epoch 400; ukuran batch: 32; dan random state: 42.

3.3.1 Hasil Pengujian Penaikan Nutrisi

Pengujian penaikan nutrisi dilakukan setiap 60 detik sampai nilai nutrisi mencapai titik di atas 640 ppm. Pompa TDS akan aktif secara terus menerus hingga mencapai rentang yang sudah ditentukan tersebut, dengan kata lain pengujian penaikan ini berjalan terus hingga pompa TDS tidak aktif yaitu saat TDS di atas 640 ppm. Hasil pengujian sistem kendali Model JST Backpropagation pada penaikan nutrisi (TDS) dapat dilihat pada Tabel 4.

Pada Tabel 4 pengujian penaikan nutrisi dari 10liter air baku dengan kadar nutrisi awal 196.47 ppm naik menjadi 654.56 ppm dengan memompa cairan nutrisi 2250 ppm selama 1 detik. Waktu yang dibutuhkan untuk mencapai kadar nutrisi 654.56 ppm adalah 1500 detik. Pengujian ini melibatkan pengaktifan pompa TDS (nutrisi) saat nilai 196.47 ppm, dengan pengecekan setiap 60 detik hingga mencapai 654.56 ppm. Terdapat kesalahan pada saat TDS bernilai 642.97, seharusnya pompa TDS tidak aktif. Sistem ini dapat menormalkan kadar nutrisi pada rentang 640-860 ppm. Jika nilai nutrisi di bawah normal, sistem akan mengaktifkan pompa TDS hingga nilai normal tercapai.

Tabel 4 Hasil Pengujian Penaikan Nutrisi

TDS	pompaTDS
196.47	1
208.81	1
222.08	1
240.93	1
258.14	1
280.57	1
...	...
586.63	1
605.15	1
619.54	1
642.97	1
654.56	0

3.3.2 Hasil Pengujian Peningkatan pH

Pengujian peningkatan pH dilakukan setiap 60 detik sampai nilai nutrisi mencapai titik rentang pH 6.0 – 7.0 pompa pHUp akan aktif secara terus menerus hingga mencapai rentang yang sudah ditentukan tersebut, dengan kata lain pengujian peningkatan ini berjalan terus hingga pompa pHUp tidak aktif yaitu saat pH di atas 6.0. Hasil pengujian sistem kendali Model JST Backpropagation pada peningkatan pH dapat dilihat pada Tabel 5.

Pada Tabel 5 pengujian peningkatan pH dari 10 liter air baku dengan kadar pH awal 4.9 naik menjadi 6.1 dengan memompa larutan air pH 8.5 secara bertahap menggunakan pompa pH selama 0.5 detik. Waktu yang dibutuhkan untuk mencapai kadar pH 6.1 adalah 720 detik. Pengujian ini melibatkan pengaktifan pompa pH Up saat nilai pH 4.06, dengan pengecekan setiap 60 detik hingga mencapai pH 6.1. Secara keseluruhan, model JST berhasil berjalan dengan baik dalam peningkatan nilai pH. Dapat disimpulkan bahwa parameter pH dalam sistem hidroponik ini sudah berada dalam kisaran normal 6.0-7.0. Jika nilai pH di bawah normal, sistem akan mengaktifkan pompa pH Up untuk mengembalikan nilai pH ke level normal.

Tabel 5 Hasil Pengujian Peningkatan pH

pH	pompapHUp
4.9	1
5.09	1
5.15	1
5.29	1
5.31	1
5.49	1
5.58	1
5.64	1
5.7	1
5.84	1
5.92	1
6.1	0

3.3.3 Hasil Pengujian Penurunan pH

Pengujian penurunan pH dilakukan setiap 60 detik sampai nilai nutrisi mencapai titik rentang pH 6.0 – 7.0 pompa pHDown akan aktif secara terus menerus hingga mencapai rentang yang sudah ditentukan tersebut, dengan kata lain pengujian peningkatan ini berjalan terus hingga pompa pHDown tidak aktif yaitu saat pH di bawah 7.0. Hasil pengujian sistem kendali Model JST Backpropagation pada penurunan pH dapat dilihat pada **Error! Reference source not found.**

Tabel 6 Hasil Pengujian Penurunan pH

pH	pompapHDown
8.0	1
7.9	1
7.82	1
7.75	1
7.62	1
7.53	1
7.46	1
7.35	1
7.26	1
7.16	1
7.06	1

6.93	0
------	---

Pada **Error! Reference source not found.** pengujian penurunan pH dari 10liter air baku dengan kadar pH awal 8.0 turun menjadi 6.93 dengan memompa larutan air pH 5.5 secara bertahap menggunakan pompa pHDown selama 0.5 detik. Waktu yang dibutuhkan untuk mencapai kadar pH 6.93 adalah 720 detik. Pengujian ini melibatkan pengaktifan pompa pH Down saat nilai pH 8.0, dengan pengecekan setiap 60 detik hingga mencapai pH 6.93. Secara keseluruhan, model JST Backpropagation berhasil berjalan dengan baik dalam penurunan nilai pH. Dapat disimpulkan bahwa parameter pH dalam sistem hidroponik ini sudah berada dalam kisaran normal 6.0-7.0.

3.3.4 Hasil Analisis Model JST

Berdasarkan hasil pengujian yang diperoleh, performa sistem kendali dengan model JST Backpropagation terhadap pengujian 3 kasus mengenai penaikan TDS, penaikan pH, dan penurunan pH dengan 49 data memiliki akurasi model sebesar 97.96%. Nilai akurasi diperoleh dengan metode *Confusion Matrix*, yaitu menghitung jumlah prediksi yang benar (*true positive* dan *true negative*) dibagi dengan jumlah keseluruhan data [10].

Tabel 7 Akurasi Pengujian Model JST

Model JST		Kelas Prediksi (<i>Target Class</i>)	
		Actual 1	Actual 0
Kelas Utama (<i>Output Class</i>)	Predicted 1	TP (48 data)	FP (0)
	Predicted 0	FN (0)	TN (1)

Hasil pengujian model terhadap 49 data ditunjukkan pada Tabel 7. Berdasarkan pengujian model JST ada 1 error prediksi yaitu saat TDS bernilai 642.97 seharusnya pompaTDS 0. pompaTDS dengan nilai sebenarnya 0 terprediksi sebagai 1, sehingga dapat dihitung akurasi dengan Persamaan (1)

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} = \frac{48 + 0}{48 + 0 + 0 + 1} = \frac{48}{49} = 0.9796 \quad (1)$$

Jadi, akurasi model pengujian model JST adalah 0.9796 atau 97.96%.


3.4 Analisis Pertumbuhan Tanaman Hidroponik

Hasil pertumbuhan tanaman ditunjukkan pada Gambar 8 dan

Gambar 9 dapat dilihat tanaman selada hidroponik dengan sistem kendali dapat tumbuh dengan cukup baik selama 30 hari daripada dengan selada hidroponik tanpa sistem kendali. Daun pada tanaman selada hidroponik dengan sistem kendali tumbuh subur sampai lebih 5 helai daun. Kekurangan tanaman selada ini terletak pada batangnya yang tumbuh tinggi terlalu cepat sebelum memperbesar diameter batangnya, hal ini menyebabkan batang pada ujung daun melengkung karena harus menopang daun yang tumbuh cukup subur. Hal itu memungkinkan terjadi dikarenakan faktor intensitas cahaya di tempat pertumbuhan hidroponik. Namun, pada penelitian ini faktor pertumbuhan yang dikendalikan hanya terbatas pada kadar nutrisi dan pH sehingga faktor lain seperti intensitas cahaya, kelembaban, dan suhu tidak diperhitungkan.



Gambar 8 Hidroponik dengan Sistem Kendali



Gambar 9 Hidroponik tanpa Sistem Kendali

4. KESIMPULAN

Berdasarkan hasil penelitian, implementasi dan pengujian sistem yang telah dilakukan dapat disimpulkan bahwa, sistem kendali model JST dapat dibuat untuk melakukan otomatisasi pengambilan data dan melakukan prediksi parameter pH dan TDS, secara koneksi serial terhadap tanaman hidroponik. Model ini dapat digunakan untuk mengimplementasikan kontrol pH dan nutrisi (TDS), dan prediksi untuk mengaktifkan pompa pH dan TDS secara otomatis, terhadap sistem hidroponik berbasis Arduino. Implementasi model JST terhadap sistem kontrol pH dan nutrisi yang dilakukan dalam pengujian kenaikan TDS, kenaikan pH, dan penurunan pH memiliki tingkat akurasi dengan nilai sebesar 97.96% dari 49 data.

5. SARAN

Penelitian ini masih perlu disempurnakan kembali untuk penelitian selanjutnya, beberapa saran yang perlu diperhatikan yaitu mengganti sensor TDS dan pH dengan kualitas yang lebih baik dari segi akurasi dan kestabilannya. Menambahkan sistem IoT untuk memudahkan monitoring tanaman dan sistem secara daring. Memperhatikan faktor lingkungan lain yang dapat mempengaruhi proses pertumbuhan tanaman.

DAFTAR PUSTAKA

- [1] Susilawati, *Dasar – Dasar Bertanam Secara Hidroponik*. Unstri Press, 2019.
- [2] S. Wibowo and A. Asriyanti, "Aplikasi Hidroponik NFT pada Budidaya Pakcoy (Brassica rapa chinensis)," *J. Penelit. Pertan. Terap.*, vol. 13, no. 3, pp. 159–167, 2013, [Online]. Available:

- <https://jurnal.polinela.ac.id/index.php/JPPT/article/viewFile/180/149>
- [3] T. E. Tallei, I. F. M. Rumengan, and A. A. Adam, *Hidroponik untuk Pemula*. LPPM UNSRAT, 2017.
- [4] S. Swastika, A. Yulfida, and Y. Sumitro, *Budidaya Sayuran Hidroponik*. Balai Pengkajian Teknologi Pertanian, 2017. [Online]. Available: <http://riau.litbang.pertanian.go.id/kopitani/images/pdf/juknis/juknishidroponik.pdf>
- [5] D. Graupe, *Principles of Artificial Neural Networks*, 3rd ed. World Scientific Publishing Company, 2013.
- [6] D. Kartini, “Penerapan Data Mining dengan Algoritma Neural Network (Backpropagation) Untuk Prediksi Lama Studi Mahasiswa,” *Pros. Semin. Nas. SISFOTEK*, vol. 3584, pp. 235–241, 2017, [Online]. Available: www.seminar.iaii.or.id
- [7] S. Haykin, *Neural Networks and Learning Machines*, vol. 3. Prentice Hall, 2009. doi: 978-0131471399.
- [8] F. Laurene, *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. 1994. doi: 10.1109/T-C.1969.222718.
- [9] J. J. Siang, *Jaringan Syaraf Tiruan dan Pemograman Menggunakan Matlab*. Yogyakarta: Andi, 2005.
- [10] J. Heaton, *Artificial Intelligence for Humans Volume 3: Deep Learning and Neural Networks*, 1st ed. CreateSpace Independent Publishing Platform, 2015. doi: 10.1007/978-1-4842-3450-1_5.