

Pengembangan Sensor Pengukuran pH Virtual untuk Sistem Hidroponik Biaya Rendah Berbasis IoT dengan KNN dan Moving Average

Pande Made Agung Dananjaya
Krisna Cakra
Fakultas Informatika
Universitas Telkom
Bandung
agungdanan@students.telkomuniversity.ac.id

Aji Gautama Putrada
Fakultas Informatika
Universitas Telkom
Bandung
ajigps@telkomuniversity.ac.id

Hassan Rizky Putra Sailallah
Fakultas Informatika
Universitas Telkom
Bandung
hassanrizkyhrs@telkomuniversity.ac.id

Apa permasalahan pada topik. Sistem hidroponik cerdas yang menggabungkan IoT dan *machine learning*, dapat menjadi solusi ranah pertanian.

Mengapa topik menarik atau penting. Penggunaan sensor pH fisik yang tergolong mahal, dan solusi berbiaya rendah dapat diusulkan dengan menggunakan sensor virtual.

Bagaimana solusinya. Penelitian ini mengusulkan sensor virtual pH pada IoT Hidroponik dengan memanfaatkan data sekunder dari Kaggle. Kami menggunakan algoritma regresi decision tree, Extreme Gradient Boosting (XGBoost), dan K-Nearest Neighbors (KNN) untuk prediksi dengan menggunakan data dari meter TDS dan sensor temperatur sebagai fitur input. Beberapa metrik pengujian yang digunakan adalah Root Mean Squared error (RMSE), Mean Absolute Error (MAE), dan R^2 score. Metode Moving Average digunakan untuk meningkatkan kinerja model dan validasi data menggunakan matriks Pearson Correlation Coefficient (PCC).

Hasil utama. Hasil pengujian menunjukkan bahwa Moving Average dengan jendela 181 mengurangi RMSE model KNN dari 0.98 menjadi 0.37. Hasil pengukuran menunjukkan bahwa KNN mencapai R^2 score yang lebih optimal (0.91), dibandingkan dengan decision tree (0.90) dan XGBoost (0.57). Sensor pH virtual dengan KNN adalah yang paling valid karena nilai korelasi pH dengan TDS dan temperatur air masing-masing yaitu -0.34 hingga -0.35 dan -0.44 hingga -0.31, dibandingkan dengan dataset sekunder. Sensor virtual ini dapat menjadi solusi biaya rendah dalam hidroponik IoT karena dapat mengurangi biaya produk dari 400 USD menjadi 10 USD.

Kata kunci: sensor virtual, sensor pH, biaya rendah,

internet of things, hidroponik Abstract

Intelligent hydroponics systems, incorporating IoT and machine learning, can become a precision agriculture solution. However, physical water pH sensors are expensive, and a low-cost solution can be proposed using virtual sensors. Our research propose a pH virtual sensor for Hydroponics IoT using secondary data from Kaggle. We employ decision tree, Extreme Gradient Boosting (XGBoost), and K-Nearest Neighbors (KNN) regression algorithms for prediction using data from the TDS meter and temperature sensor as input features. Some metrics for testing are Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and R^2 score. Moving average method to enhance the model performance and validate the data using Pearson correlation coefficient (PCC) matrix. Test results show that moving average with a window size of 181 reduces the RMSE of the KNN model from 0.98 to 0.30. KNN achieves a more optimal R^2 score (0.91) than the decision tree (0.90) and XGBoost (0.57). Virtual pH sensors with KNN are the most valid, as the correlation values of pH with TDS and water temperature are -0.34 to -0.35 and -0.44 to -0.31, compared to the secondary dataset. This virtual sensor can be a low-cost solution in IoT hydroponics because can reduce product costs from USD 400 to USD 10.

Keywords: virtual sensors, pH sensor, low-cost, Internet

of Things, hydroponic

1. Pendahuluan

Latar Belakang

Air merupakan sumber daya alam penting yang dibutuhkan untuk menunjang proses pertumbuhan dan perkembangan makhluk hidup [1]. Air dibutuhkan bagi setiap aspek kelangsungan hidup manusia serta ekosistem untuk aspek produksi pertanian, konservasi, dan kebutuhan lainnya [2]. Kondisi ini menyoroti pentingnya menjaga kualitas air optimal yang dipengaruhi parameter seperti pH, suhu, dan konsentrasi dalam mendukung kelangsungan hidup makhluk hidup dan ekosistem [3]. Dapat disimpulkan bahwa air merupakan sumber daya yang berharga bagi kehidupan makhluk hidup, sehingga diperlukan upaya yang tepat untuk mengelola kualitasnya. Hal ini terus mendorong penelitian tentang bagaimana mengatur kualitas air menggunakan teknologi modern.

Dalam penelitian Lakshmikanth *et al.* [4], penerapan alat pemantauan kualitas air menggunakan Internet of Things (IoT) berbasis Arduino mampu menganalisis beberapa parameter kualitas air seperti pH, suhu, kelembapan, dan karbon dioksida dalam air minum yang dikonsumsi setiap hari. Hal ini menunjukkan adanya perkembangan teknologi terkait pemantauan kualitas air, dengan semakin banyak penelitian yang bersaing untuk memanfaatkan metode paling efektif berdasarkan penelitian sebelumnya. Selain itu, dalam penelitian Hridoy *et al.* [5] menerapkan machine learning untuk memprediksi kualitas air di masa mendatang berdasarkan parameter pH, DO, kekeruhan, dan suhu menggunakan algoritma regresi linier yang berhasil menunjukkan performa metrik evaluasi secara baik.

Beberapa tantangan dalam penerapan sensor Internet of Things (IoT) antara lain biaya perangkat yang relatif mahal dan diperlukan kalibrasi rutin yang berpotensi menyebabkan penurunan akurasi seiring waktu [6]. Tantangan ini menjadi semakin penting ketika diterapkan pada sistem IoT, yang menuntut efisiensi biaya. Berdasarkan permasalahan ini, diperlukan inovasi berupa sensor virtual sebagai alternatif yang lebih ekonomis. Konsep ini juga diterapkan pada penelitian Khurshid *et al.* [7], yang memanfaatkan perhitungan machine learning untuk memprediksi BOD dan COD dalam air tanpa memerlukan implementasi sensor secara fisik.

Topik dan Batasannya

Penelitian ini berfokus pada pengembangan sensor pH Virtual berbasis Internet of Things (IoT) dengan memanfaatkan parameter TDS dan temperatur air dengan memanfaatkan model algoritma regresi seperti decision tree, Extreme Gradient Boosting (XGBoost), dan K-Nearest Neighbors (KNN) yang kemudian dievaluasi

menggunakan Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan R^2 score, serta validasi dengan Pearson Corelation Coeficient (PCC).

Penelitian ini dibatasi pada penggunaan dataset kaggle sebanyak 505.730 sampel sebagai pelatihan dan dataset primer sebanyak 600 sampel untuk pengujian. Variabel yang digunakan hanya mencakup TDS dan temperatur air sebagai input serta pH sebagai target prediksi. Evaluasi penelitian ini difokuskan pada performa model prediksi sensor virtual tanpa melibatkan implementasi sensor fisik pH dan sistem konrol hidroponik secara kompleks menggunakan metrik RMSE, MAE, R^2 score, dan PCC yang dilakukan berdasarkan asumsi bahwa korelasi TDS-temperatur-pH pada dataset aquaponik memiliki karakteristik serupa dengan sistem hidroponik yang diuji.

Tujuan

Berdasarkan topik yang diangkat, penelitian ini dilakukan untuk mengembangkan sensor pH virtual berbasis IoT sebagai solusi efisiensi biaya dengan cara membandingkan performa ketiga algoritma regresi seperti decision tree, XGBoost, dan KNN melalui data sensor TDS dan temperatur air, serta meningkatkan hasil prediksi menggunakan metode moving average dan kemudian divalidasi menggunakan PCC untuk mengetahui keterkaitan datanya. Demi memastikan ketercapaian tujuan penelitian, Tabel 1. akan menunjukan keterkaitan antara tujuan, pengujian dan kesimpulannya.

Tabel 1. Tabel keterkaitan antara tujuan, pengujian dan kesimpulan

No	Tujuan	Pengujian	Kesimpulan
1	Mengembangkan sensor pH virtual berbasis IoT sebagai solusi efisiensi biaya.	Implementasi model regresi menggunakan dataset kaggle dan dataset primer.	Sensor pH virtual berhasil dikembangkan menggunakan parameter TDS dan temperatur.
2	Membandingkan kinerja model decision tree, XGBoost, dan KNN dalam membangun model prediksi pH melalui data sensor	Perbandingan	KNN berhasil meraih performa terbaik dengan nilai RMSE sebesar 0.37 dan R^2 score sebesar 0.91.
	TDS dan temperatur.		

3	Meningkatkan hasil prediksi pH dengan metode moving average dan validasi menggunakan PCC.	Pengujian pengaruh window size terhadap RMSE dan MAE, serta analisis hubungan korelasinya menggunakan PCC.	Moving average berhasil menurunkan RMSE KNN dari 0.98 menjadi 0.37. Selain itu pola korelasi dari pH, TDS, dan temperatur mampu mencerminkan perilaku fisik nyata dari kualitas air yang diuji.
---	---	--	---

2. Studi Terkait

Beberapa penelitian telah menerapkan algoritma KNN dalam aplikasi prediksi sensor, seperti penelitian oleh Juna *et al.* [8], yang memanfaatkan KNN imputer untuk memprediksi kualitas air dengan jumlah missing values yang cukup tinggi serta mengurangi risiko overfitting. Selain itu, ada penelitian Wekalao *et al.* [9], yang memanfaatkan KNN dan mampu menunjukkan pengurangan 85% dalam sumber daya yang diperlukan selama simulasi untuk sensor biomedis.

Beberapa penelitian telah memanfaatkan moving average untuk meningkatkan kinerja performa regresi. Dinesh *et al.* [10] menunjukkan bahwa moving average mampu meningkatkan kemampuan prediktif dalam aspek perkiraan pasar saham dengan membantu model prediksi untuk lebih fokus pada pola tren. Vande Kamp *et al.* [11] melalui penelitiannya menyatakan bahwa moving average memiliki unsur autokorelasi yang dapat meningkatkan kinerja performa regresi. Pemanfaatan moving average dalam model regresi membuatnya lebih efisien dan konsisten. Berdasarkan hal tersebut, masih terdapat peluang penelitian untuk menerapkan moving average pada prediksi sensor virtual.

Beberapa penelitian telah memvalidasi keberadaan adanya data sintetis menggunakan analisis korelasi. Javergaard *et al.* [12] memanfaatkan PCC untuk mengamati bahwa hubungan korelasi antara fitur tidak berubah ketika sensor virtual atau data sintetis diterapkan. Endres *et al.* [13] juga memanfaatkan pendekatan analisis korelasi untuk mengamati konsistensi korelasi antara fitur saat menerapkan data sintetis. Penelitian ini memanfaatkan korelasi pasangan sebagai bahan analisa. Berdasarkan hal tersebut, masih terdapat peluang penelitian untuk menerapkan analisis korelasi sebagai salah satu metode validasi sensor

virtual. Tabel 2. akan menunjukkan perbandingan kesesuaian literatur yang digunakan.


Tabel 2. Perbandingan Literatur Terkait

Cite	Sensor Virtual	KNN	Moving Average	Analisis Korelasi
[8]	✓	✓	×	×
[9]	✓	✓	×	×
[10]	×	×	✓	×
[11]	×	×	✓	×
[12]	×	×	×	✓
[13]	×	×	×	✓
Literatur yang diajukan	✓	✓	✓	✓

3. Sistem yang Dibangun

3.1 Rancangan Sistem IoT Hidroponik


Arsitektur Internet of Things (IoT) yang dikembangkan dalam penelitian kami dirancang berdasarkan berdasarkan beberapa komponen utama. Salah satu komponen utamanya adalah NodeMCU ESP8266 yang berfungsi sebagai mikrokontroler utama, dilengkapi dengan modul Wi-Fi untuk mengelola pembacaan data dari dua sensor input yaitu sensor temperatur DS18B20 dan sensor TDS meter. Data dari hasil pengukuran sensor nantinya akan dikirim ke Google Spreadsheet menggunakan tools Google Script. Gambar 1. akan memberikan gambaran mengenai implementasi dalam memperoleh data primer.



Gambar 1 Arsitektur IoT Hidroponik

3.2 Diagram Alur Penelitian

Pada penelitian ini terdapat langkah-langka yang dilakukan untuk mencapai tujuan dalam bentuk satu diagram alur. Secara keseluruhan diagram ini memuat seluruh tahapan utama mulai dari perancangan hingga keluaran hasil. Gambar 2 akan memberikan gambaran mengenai alur penelitian yang dilakukan.



Gambar 2 Alur Kerja Penelitian

3.3 Algoritma Sensor pH Virtual Menggunakan KNN

KNN merupakan salah satu metode machine learning yang mengambil keputusan berdasarkan kedekatan data baru terhadap sejumlah tetangga terdekat. Pada penelitian ini, fitur yang digunakan meliputi nilai TDS dan nilai temperatur air. Gambar 3. akan menunjukkan ilustrasi penerapan KNN pada sensor virtual, dimana Xtrain berisi data pelatihan berupa TDS dan temperatur dari dataset sekunder, ytrain merupakan nilai pH sebagai output pelatihan, dan (TDSnew, Tempnew) merupakan data pada studi kasus aktual yang murni dari hasil algoritma KNN.

```

Algorithm 1 Sensor pH Virtual menggunakan KNN
Require:
  Xtrain
  ytrain
  (TDSnew, Tempnew)
  k
Ensure:
  pHvirtual
1: Initialize empty list Distances
2: for each training sample i do
3:   Compute Euclidean distance:

$$d^{(i)} = \sqrt{(TDS_{new} - TDS^{(i)})^2 + (Temp_{new} - Temp^{(i)})^2}$$

4:   Append (d(i), pH(i)) to Distances
5: end for
6: Sort Distances in ascending order by d(i)
7: Select the first k neighbors
8: Compute virtual pH:

$$pH_{virtual} = \frac{1}{k} \sum_{i=1}^k pH^{(i)}$$

9: return pHvirtual

```

Gambar 3 Algoritma KNN Sensor pH Virtual

3.4 Algoritma Validasi Sensor pH Virtual

Algoritma ini menjelaskan bahwa perhitungan jarak semua data dalam model dengan data baru dilakukan dengan jarak Euclidean [14]. Kemudian k jarak terkecil diambil dan nilai pH(i) dari jarak ini dirata-ratakan untuk mendapatkan nilai pH virtual sebagai output. Gambar 4. akan menunjukkan metode validasi sensor virtual dengan PCC. Input algoritma adalah Dsecondary = {(TDS_i, Temp_i, pH_i)}, yaitu dataset sekunder dengan pH nyata. Kemudian Dprimary = {(TDS_j, Temp_j, pH_j)}, yaitu dataset primer dengan pH virtual. Output dari algoritma ini adalah D, yaitu perbedaan antara dataset sekunder PCC psecondary dan dataset primer PCC pprimary.

```

Algorithm 2 Validasi Sensor pH Virtual Menggunakan PCC
Require:
  Dsecondary = {(TDSi, Tempi, pHi)}
  Dprimary = {(TDSj, Tempj, pHj)}
Ensure:
  D
1: Hitung PCC pada secondary dataset:
   Psecondary = PCC(TDS, pH)
   or
   Psecondary = PCC(Temp, pH)
2: Hitung PCC pada primary dataset:
   Pprimary = PCC(TDS, pHvirtual)
   or
   Pprimary = PCC(Temp, pHvirtual)
3: Bandingkan Pprimary dan Psecondary
4: if |Pprimary - Psecondary| lebih kecil than yang terlihat pada data nyata.
5:   D ← Sensor virtual mempertahankan hubungan fisik
6: else
7:   D ← Sensor virtual mungkin tidak mencerminkan pola fisik nyata dengan akurat.
8: end if

```


Gambar 4 Algoritma Validasi PCC

4. Evaluasi

4.1 Hasil Pengujian


Hasil pengujian menunjukkan bahwa penerapan moving average memberikan peningkatan performa yang signifikan pada model KNN. Sebelum preprocessing, model menghasilkan RMSE sebesar 0.98 yang menunjukkan tingkat kesalahan prediksi masih cukup tinggi. Setelah diterapkan moving average dengan window size sebesar 181, nilai

RMSE berhasil diturunkan menjadi 0.30 dan MAE menurun dari 0.74 menjadi 0.09. Gambar 5. akan menunjukkan bahwa smoothing data mampu membantu model menangkap tren utama dan mengurangi pengaruh noise.



Gambar 5 Analisis Moving Average Window Size


Hasil perbandingan performa model menunjukkan bahwa KNN memiliki performa terbaik dibandingkan decision tree dan XGBoost. Model KNN mampu menghasilkan nilai RMSE sebesar 0.37 dan R^2 score sebesar 0.91 sedangkan decision tree memiliki performa yang lebih mendekati KNN dengan nilai RMSE sebesar 0.38 dan R^2 score sebesar 0.90. Sementara itu XGBoost menunjukkan performa paling rendah diantara yang lain dengan nilai RMSE sebesar 0.81 dan R^2 score sebesar 0.57. Hal ini menunjukkan bahwa pendekatan pada KNN lebih sesuai dengan karakteristik data dibandingkan pendekatan boosting yang lebih kompleks. Gambar 6. akan menunjukkan perbandingan antara ketiga model regresi yang digunakan.



Gambar 6 Perbandingan Model Regresi (RMSE dan R^2 score)

Hasil validasi menggunakan PCC menunjukkan bahwa model KNN mampu mempertahankan pola korelasi antara pH, TDS, dan temperatur air mendekati dataset sekunder. Korelasi pH terhadap TDS berada pada rentang -0.34 hingga -0.35 sedangkan korelasi antara pH dan temperatur berada pada rentang

-0.44 hingga -0.31. Nilai ini paling mendekati korelasi asli dibandingkan dengan kedua model lainnya. Hal ini menunjukkan bahwa prediksi sensor virtual bukan hanya sekedar angka namun juga mencerminkan perilaku fisik nyata dari kualitas air yang diuji. Gambar 7. akan menunjukkan perbandingan matriks heatmaps menggunakan PCC.



Gambar 7. Perbandingan Matriks Heatmap PCC

4.2 Analisis Hasil Pengujian

Penerapan moving average dengan window size sebesar 181 berhasil menurunkan nilai RMSE dari 0.98 menjadi 0.30 yang menunjukkan bahwa proses smoothing mampu mengurangi noise dan membantu model KNN menangkap pola hubungan antara TDS, temperatur, dan pH secara lebih stabil. Hasil benchmarking model juga menunjukkan bahwa KNN memiliki performa terbaik dengan nilai RMSE sebesar 0.37 dan R^2 score sebesar 0.91 dibandingkan decision tree dan XGBoost sehingga menunjukkan bahwa karakteristik data lebih sesuai dengan pendekatan berbasis kedekatan jarak dibandingkan model boosting yang lebih kompleks. Selain itu, proses validasi menggunakan PCC menunjukkan bahwa hasil prediksi mampu mempertahankan pola korelasi negatif antara pH, TDS, dan temperatur yang konsisten dengan dataset sekunder sehingga menandakan bahwa model mampu menjaga hubungan antarparameter kualitas air pada implementasi nyata.

5. Kesimpulan

Tujuan dari penelitian ini adalah untuk mengembangkan sensor pH virtual berbasis IoT yang memanfaatkan kinerja model pembelajaran mesin regresi. Kami mengusulkan model regresi KNN, decision tree dan XGBoost sebagai model

tolak ukur. Kami juga menggunakan moving average untuk meningkatkan kemampuan prediktif model regresi. Akhirnya, kami menggunakan matriks PCC untuk memvalidasi hasil sensor virtual. Hasil pengujian menunjukkan bahwa moving average dengan window size sebesar 181 dapat mengurangi RMSE dan MAE dari model regresi KNN dari 0,98 dan 0,74 menjadi 0,30 dan 0,09, masing-masing. Hasil tolak ukur menunjukkan bahwa KNN mencapai R^2 score yang lebih optimal dibandingkan model decision tree dan XGBoost, dengan nilai masing-masing 0,91, 0,90, dan 0,57. Dengan demikian, sensor pH virtual dengan regresi KNN adalah sensor virtual yang paling valid dibandingkan dengan decision tree dan XGBoost karena nilai korelasi antara pH dan TDS, serta pH dan air, adalah -0,34 hingga -0,35 dan - 0,44 hingga -0,31, masing-masing, bila dibandingkan dengan dataset sekunder. Sensor virtual ini dapat menjadi solusi biaya rendah dalam hidroponik IoT karena dapat menurunkan biaya produk dari 400 USD menjadi 10 USD.

REFERENSI

- [1] Researcher Jizzakh State Pedagogical Institute Jizzakh, Uzbekistan, B. Y. Zikirov, I. Y. Zikirov, and Researcher Gulistan State University Gulistan, Uzbekistan, "WATER AS AN IMPORTANT NATURAL RESOURCE AND ECOLOGICAL FACTOR," *jgnr*, vol. 02, no. 01, pp. 10–16, Feb. 2022, doi: 10.37547/supsci-jgnr-02-01-02.
- [2] Mustaq Shaikh and Farjana Birajdar, "GROUNDWATER AND ECOSYSTEMS: UNDERSTANDING THE CRITICAL INTERPLAY FOR SUSTAINABILITY AND CONSERVATION," *EPRA*, pp. 181–186, Mar. 2024, doi: 10.36713/epra16111.
- [3] T. M. T. - and V. K. P. -, "A Review on Physico-chemical Parameters of the Quality of Water," *IJFMR*, vol. 5, no. 1, p. 1717, Feb. 2023, doi: 10.36948/ijfmr.2023.v05i01.1717.
- [4] V. Lakshmikantha, A. Hiriyanagowda, A. Manjunath, A. Patted, J. Basavaiah, and A. A. Anthony, "IoT based smart water quality monitoring system," *Global Transitions Proceedings*, vol. 2, no. 2, pp. 181–186, Nov. 2021, doi: 10.1016/j.gltp.2021.08.062.
- [5] Md. A. A. M. Hridoy, C. Bordin, A. Masood, and K. Masood, "Predictive modelling of aquaculture water quality using IoT and advanced machine learning algorithms," *Results in Chemistry*, vol. 16, p. 102456, Jul. 2025, doi: 10.1016/j.rechem.2025.102456.
- [6] M. Vermanen, J. Naskali, V. Harkke, and J. Koskinen, "PAPA for IoT - Role of Data Accuracy in IoT Deployment and Data-centric Decision-Making," in *2023 46th MIPRO ICT and Electronics Convention (MIPRO)*, Opatija, Croatia: IEEE, May 2023, pp. 500–505. doi: 10.23919/MIPRO57284.2023.10159749.
- [7] Aleefia .A. Khurshid, "IoT-Enabled Embedded Virtual Sensor for Energy-Efficient Scalable Online Water Quality Monitoring System," *jes*, vol. 20, no. 2, pp. 2458–2466, Apr. 2024, doi: 10.52783/jes.2019.
- [8] A. Juna *et al.*, "Water Quality Prediction Using KNN Imputer and Multilayer Perceptron," *Water*, vol. 14, no. 17, p. 2592, Aug. 2022, doi: 10.3390/w14172592.
- [9] J. Wekalao, A. Baz, and S. K. Patel, "Design and analysis of high-sensitivity hormone sensor with KNN behavior prediction for healthcare and biomedical applications," *Measurement*, vol. 242, p. 116172, Jan. 2025, doi: 10.1016/j.measurement.2024.116172.
- [10] S. Dinesh, N. R. R. S. P. Anusha, and S. R., "Prediction of Trends in Stock Market using Moving Averages and Machine Learning," in *2021 6th International Conference for Convergence in Technology (I2CT)*, Maharashtra, India: IEEE, Apr. 2021, pp. 1–5. doi: 10.1109/I2CT51068.2021.9418097.
- [11] G. N. Vande Kamp and S. Jordan, "The Necessity of Moving Averages in Dynamic Linear Regression Models," *American J Political Sci*, vol. 69, no. 1, pp. 176–193, Jan. 2025, doi: 10.1111/ajps.12825.
- [12] N. Jävergård, R. Lyons, A. Muntean, and J. Forsman, "Tunable correlation retention: A statistical method for generating synthetic data," 2024, *arXiv*. doi: 10.48550/ARXIV.2403.01471.
- [13] M. Endres, A. Mannarapotta Venugopal, and T. S. Tran, "Synthetic Data Generation: A Comparative Study," in *Proceedings of the 26th International Database Engineered Applications Symposium*, Budapest Hungary: ACM, Aug. 2022, pp. 94–102. doi: 10.1145/3548785.3548793.
- [14] P. Nando, A. G. Putrada, and M. Abdurrohmah, "Increasing The Precision Of Noise Source Detection System using KNN Method," *KINETIK*, pp. 157–168, May 2019, doi: 10.22219/kinetik.v4i2.757.