

Komparasi Algoritma Machine Learning dalam Identifikasi Kualitas Air

Dwi Hartanti^{a,*}, Afu Ichsan Pradana^b

^{ab} Universitas Duta Bangsa Surakarta

*correspondence email : dwihartanti@udb.ac.id

Abstract—Water is a very important part of life because it is the source of human life and living things and about 71% of the earth's area is water. Every human being has the human right to clean water which is a basis for the realization of a decent and dignified life for humans. Machine learning is a branch of artificial intelligence that focuses on using data and algorithms to mimic the way humans learn, gradually increasing accuracy and intelligence. This study uses water quality data using four algorithmic methods, namely Decision Tree, Logistic Regression, SVM, and ANN. The objective of this research is to compare which method has the maximum accuracy for water quality identification. The accuracy results obtained are the Decision Tree method of 60.19%, the Logistic Regression method of 62.80%, the SVM method of 68.59%, and the ANN method of 69.54%.

Index Terms—Water Quality; Decision Tree; Logistics Regression; SVM; ANN

Abstrak—Air menjadi bagian sangat penting untuk kehidupan karena merupakan sumber kehidupan manusia serta makhluk hidup dan sekitar 71% wilayah bumi merupakan air. Setiap manusia memiliki Hak asasi manusia atas air yang bersih yang merupakan sebuah dasar untuk terwujudnya kehidupan yang layak dan bermatrabat bagi manusia. *Machine learning* merupakan cabang dari kecerdasan buatan yang berfokus penggunaan data dan algoritma untuk meniru cara manusia belajar secara bertahap dapat meningkatkan akurasi dan kecerdasan. Penelitian ini menggunakan data kualitas air menggunakan empat metode algoritma yaitu Decision Tree, Logistic Regression, SVM, dan ANN. Tujuan penelitian adalah untuk membandingkan metode mana yang memiliki nilai akurasi paling maksimum untuk identifikasi kualitas air. Hasil akurasi yang diperoleh adalah dengan metode *Decision Tree* sebesar 60,19%, metode *Logistic Regression* sebesar 62,80%, metode *SVM* sebesar 68,59%, dan metode *ANN* sebesar 69,54%.

Kata Kunci—Kualitas Air; Decision Tree; Logistic Regression; SVM; ANN

I. PENDAHULUAN

Air menjadi bagian sangat penting untuk kehidupan karena merupakan sumber dari kehidupan manusia serta makhluk hidup dan sekitar 71% wilayah bumi merupakan air dan memiliki senyawa kompleks[1][2][3]. Setiap manusia memiliki Hak asasi manusia atas air yang bersih yang merupakan sebuah dasar untuk terwujudnya kehidupan yang layak dan bermatrabat bagi manusia[4]. Maka dari itu pentingnya untuk menjaga demi keberlangsungan kehidupan manusia. Suatu ukuran kondisi air dilihat dari berbagai karakteristik fisik, kimiawi, dan biologis[2]. Banyaknya pembagunan yang semakin pesat mengakibatkan banyak wilayah memiliki kualitas air yang kurang baik. Hal tersebut dibuktikan dengan banyaknya sungai-sungai yang berubah fungsi perubahan ini dikhawatirkan akan menurunnya kualitas air yang berada di sepanjang sungai-sungai di berbagai lingkungan sekitar.

Banyak upaya untuk menjaga kualitas air yaitu dengan melakukan kegiatan pengecekan apakah air tersebut terdapat penyakit atau bakteri sehingga akan dilakukan sebuah tindakan untuk melakukan pencegahan jika terjadi penurunan sebuah kualitas air[5]. Kualitas air memiliki banyak parameter meliputi mikrobiologi, kimia anorganik, parameter fisik, serta parameter kimia. Parameter kualitas air diketahui karena air mengganggu zat mineral yang terlarut dalam air[2].

Kecerdasan buatan memiliki cabang keilmuan yaitu *Machine learning*. *Machine Learning* memiliki fokus dalam penggunaan data serta algoritma yang digunakan untuk meniru cara manusia belajar secara bertahap dapat meningkatkan akurasi dan kecerdasannya[6][7]. *Machine Learning* digunakan untuk memecahkan berbagai masalah dan mempelajari data yang ada dan bisa melakukan tugas tertentu [8][9]. Penelitian ini menggunakan algoritma Decision Tree, Logistic Regression, SVM, dan ANN. Metode Algoritma tersebut banyak di implementasikan untuk sebuah permasalahan dengan banyak kasus dan cocok untuk kasus kualitas air[10].

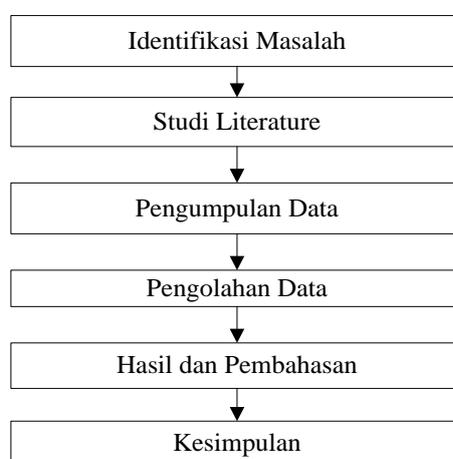
Penelitian yang dilakukan Weiskhy dkk menyimpulkan bahwa nilai Accuracy 84.81% dan nilai AUCnya 0.898 dengan menggunakan algoritma SVM-PSO dan nilai Accuracy 80.00% dan nilai AUCnya

0.787 dengan menggunakan Algoritma C4.5-PSO[11]. Penelitian yang dilakukan oleh Icha Gusti Vidiastanta dkk menyimpulkan bahwa hasil yang didapat yaitu Akurasi rata – rata yang didapatkan dengan metode K-Nearest Neighbors dan Support Vector Machine adalah sebesar 88.94% dan 87.71%. Hasilnya K-Nearest Neighbors (KNN) dengan nilai rata-rata lebih tinggi menjadi metode yang lebih baik untuk klasifikasi status air dibandingkan dengan metode Support Vector Machine (SVM)[12]. Penelitian yang dilakukan Priscolius Evrolino Jennes dkk menyimpulkan bahwa sebuah akurasi kelayakan sumber air dimana hasil akurasi adalah 71% untuk SVM, 61% untuk decision tree, 67% untuk random forest berdasarkan akurasi diatas dapat membantu analisis dan klasifikasi kelayakan air di Indonesia[13].

Tujuan dari penelitian yang dilakukan adalah untuk membandingkan Decision Tree, Logistic Regression, SVM, dan ANN dalam kasus identifikasi kualitas air. Maka dengan empat metode algoritma tersebut dapat di ketahui metode algoritma yang paling baik digunakan dalam identifikasi kualitas air dengan hasil akurasi yang paling maksimal.

II. METODE PENELITIAN

Penelitian yang dilakukan memiliki alur penelitian yang digunakan untuk melakukan komparasi metode Decision Tree, Logistic Regression, SVM, dan ANN untuk kualitas air terlihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

1. Tahap pertama dalam penelitian dimulai dengan mengidentifikasi masalah terkait pentingnya air bagi kehidupan manusia dengan masalah kualitas air untuk di konsumsi.
2. Tahap kedua merupakan studi literatur sebagai pengumpulan informasi yang terkait kualitas air. Cara yang dilakukan dengan melakukan pengumpulan berupa artikel ilmiah, buku dan sumber-sumber untuk menjadi informasi terkait penelitian.
3. Tahap pengumpulan data dilakukan dengan teknik pengumpulan data yang menggunakan data dari *kaggle* tentang *Water Quality*.
4. Proses pengolahan data mencakup beberapa langkah, dimulai dari dataset, *Preparation, preprocessing, Visualisai Data, Training* dan *result*. Penogolahan data menggunakan menggunakan bahasa pemrograman Python dengan Alat Jupyter Notebook. Proses pengolahan data yang dilakukan akan menghasilkan sebuah *result* atau hasil yang akan dibahas dan menghasilkan sebuah kesimpulan dalam proses penelitian yang dilakukan.

III. HASIL

1. Dataset

Dataset yang digunakan untuk data latih dalam program ini berjumlah 3276 baris, yang memiliki 9 Fitur atau Atribut (*PH, Hardness, Solids, Chloramines, Sulfate, Conductivity, Organic Carbon, Trihalomethanes, Turbidity*) dan 1 Atribut Labelling (*Potability*). Dataset yang digunakan dalam penelitian ini dataset yang digunakan adalah kualitas air dengan tipe data *csv* untuk proses identifikasi dalam membandingkan hasil akurasi dari ketiga metode yang digunakan yaitu Decision Tree, Logistic Regression, SVM, dan ANN. Hasil data dapat dilihat pada Gambar 2 Data Kualitas Air

	ph	Hardness	Solids	Chloramines	Sulfate	Conductivity	Organic_carbon	Trihalomethanes	Turbidity	Pot
0	NaN	204.890455	20791.318981	7.300212	368.516441	564.308654	10.379783	86.990970	2.963135	
1	3.716080	129.422921	18630.057858	6.635246	NaN	592.885359	15.180013	56.329076	4.500656	
2	8.099124	224.236259	19909.541732	9.275884	NaN	418.606213	16.868637	66.420093	3.055934	
3	8.316766	214.373394	22018.417441	8.059332	356.886136	363.266516	18.436524	100.341674	4.628771	
4	9.092223	181.101509	17978.986339	6.546600	310.135738	398.410813	11.558279	31.997993	4.075075	

Gambar 2. Data Kualitas Air

2. Data Preparation

Data Preparation adalah suatu proses/langkah yang dilakukan untuk membuat data mentah menjadi data yang berkualitas. Dalam penelitian ini melakukan persiapan data yang akan digunakan. Hasil dari data preparation terlihat pada Gambar 3.

	ph	Hardness	Solids	Chloramines	Sulfate
count	2785.000000	3276.000000	3276.000000	3276.000000	2495.000000
mean	7.080795	196.369496	22014.092526	7.122277	333.775777
std	1.594320	32.879761	8768.570828	1.583085	41.416840
min	0.000000	47.432000	320.942611	0.352000	129.000000
25%	6.093092	176.850538	15666.690297	6.127421	307.699498
50%	7.036752	196.967627	20927.833607	7.130299	333.073546
75%	8.062066	216.667456	27332.762127	8.114887	359.950170
max	14.000000	323.124000	61227.196008	13.127000	481.030642

	Conductivity	Organic_carbon	Trihalomethanes	Turbidity	Potability
count	3276.000000	3276.000000	3114.000000	3276.000000	3276.000000
mean	426.205111	14.284970	66.396293	3.966786	0.390110
std	80.824064	3.308162	16.175008	0.780382	0.487849
min	181.483754	2.200000	0.738000	1.450000	0.000000
25%	365.734414	12.065801	55.844536	3.439711	0.000000
50%	421.884968	14.218338	66.622485	3.955028	0.000000
75%	481.792304	16.557652	77.337473	4.500320	1.000000
max	753.342620	28.300000	124.000000	6.739000	1.000000

Gambar 3. Hasil Data Preparation

3. Data Preprocessing

Pada tahap data preproesing dilakukan proses analisa data dengan value kosong atau null dan melakukan pengisian data yang kosong atau null tersebut dengan rata-rata disetiap atribut. Gambar 4 untuk menampilkan data kosong atau null dan Gambar 5 Mengisi data yang kosong dengan nilai rata-rata disetiap atribut

```

ph          491
Hardness    0
Solids      0
Chloramines 0
Sulfate     781
Conductivity 0
Organic_carbon 0
Trihalomethanes 162
Turbidity   0
Potability  0
dtype: int64
    
```

Gambar 4. Menampilkan data null

```

dataset["ph"].mean()
7.080794504276819

dataset["ph"]=dataset["ph"].fillna(7.080794504276819)

dataset["Sulfate"].mean()
333.7757766108134

dataset["Sulfate"]=dataset["Sulfate"].fillna(333.7757766108134)

dataset["Trihalomethanes"].mean()
66.39629294676803

dataset["Trihalomethanes"]=dataset["Trihalomethanes"].fillna(66.39629294676803)
    
```

Gambar 5. Mengisi data yang kosong dengan nilai rata-rata

4. Data Training dan Data Testing

Dalam tahap ini melakukan pembagian data training dan data testing. Penelitian membagi data menjadi data training sebanyak 80% dan data testing 20%. Data training akan digunakan untuk melatih model yang di bangun dan data testing unnt menguji dan mengetahui performance model yang didapatkan pada tahapan testing.

5. Implementasi Metode Algoritma

a. Menerapkan Metode Decission Tree

Dalam penerapan menggunakan Metode Decission Tree. Pada implementasi menggunakan Decission Tree diperoleh nilai akurasi modelnya sebesar 60,19%. Hasil akurasi pada Gambar 6.

```
# DecisionTreeClassifier

from sklearn.tree import DecisionTreeClassifier

tree_model = DecisionTreeClassifier()
tree_model = tree_model.fit(x_train, y_train)

from sklearn.metrics import accuracy_score

y_pred = tree_model.predict(x_test)
acc_score= round(accuracy_score(y_pred, y_test), 3)
print('The accuracy for Decision Tree is : ', acc_score*100,'%')

The accuracy for Decision Tree is : 60.199999999999996 %
```

Gambar 6. Hasil akurasi metode Decission Tree

b. Menerapkan Metode Logistic Regression

Dalam penerapan menggunakan Metode Logistic Regression. Pada implementasi menggunakan Metode Logistic Regression diperoleh nilai akurasi modelnya sebesar 62,80%. Hasil akurasi pada Gambar 7.

```
#LogisticRegression

from sklearn.linear_model import LogisticRegression
lr = LogisticRegression()
lr.fit(x_train, y_train)
y_predlr = lr.predict(x_test)
acc_lr = lr.score(x_test, y_test)
print('The accuracy for Logistic Regression is : ', acc_lr*100, '%')

The accuracy for Logistic Regression is : 62.80487804878049 %
```

Gambar 7. Hasil akurasi metode Logistic Regression

c. Menerapkan Metode Support Vector Machine (SVM)

Dalam penerapan menggunakan Metode Logistic Regression. Pada implementasi menggunakan Metode Support Vector Machine (SVM) diperoleh nilai akurasi modelnya sebesar 68,59%. Hasil akurasi pada Gambar 8.

```
: from sklearn.svm import SVC
from sklearn.metrics import accuracy_score

svm = SVC()
svm.fit(x_train, y_train)
y_predsvm = svm.predict(x_test)

acc_svm= accuracy_score(y_predsvm, y_test)
print('The accuracy for SVM is : ', acc_svm*100, '%')

The accuracy for SVM is : 68.59756097560977 %
```

Gambar 8. Hasil akurasi metode SVM

d. Menerapkan Metode Artificial Neural Network (ANN)

Dalam penerapan menggunakan Metode Artificial Neural Network (ANN). Pada implementasi menggunakan Metode Artificial Neural Network (ANN) diperoleh nilai akurasi modelnya sebesar 69,54%. Hasil akurasi pada Gambar 9.

```

1: from sklearn.neural_network import MLPClassifier
   clf = MLPClassifier(activation='relu', solver='lbfgs', max_iter=500, alpha=1e-5,
   →hidden_layer_sizes=(5,3))
   clf.fit(x_train, y_train)

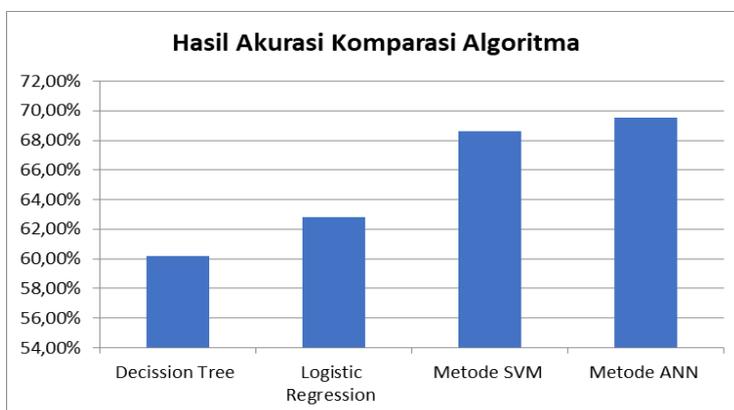
from sklearn.metrics import accuracy_score
y_model = clf.predict(x_train)
print('The accuracy Neural Network is : ', accuracy_score(y_train, y_model)*100,
   →'%')

```

The accuracy Neural Network is : 69.54198473282443 %

Gambar 9. Hasil akurasi metode ANN

Dari hasil komparasi metode didapatkan hasil seperti Gambar 10.



Gambar 10. Hasil Akurasi Komparasi Algoritma

Hasil dari perbandingan yang telah dilakukan didapatkan nilai akurasi metode *Decision Tree* sebesar 60,19%, metode *Logistic Regression* sebesar 62,80%, metode Support Vector Machine (SVM) sebesar 68,59%, dan metode Artificial Neural Network (ANN) sebesar 69,54%. Nilai tertinggi nilai akurasi untuk kualitas air pada metode Artificial Neural Network (ANN).

IV. KESIMPULAN

Tujuan dilakukan penelitian yang dilakukan untuk perbandingan tingkat keakuratan dari metode penelitian *Decision Tree*, *Logistic Regression*, SVM, dan ANN. Hasil dari program ini berupa Akurasi dalam identifikasi kualitas air layak di konsumsi atau tidak. Masing-masing akurasi yang diperoleh adalah dengan metode *Decision Tree* sebesar 60,19%, metode *Logistic Regression* sebesar 62,80%, metode SVM sebesar 68,59%, dan metode ANN sebesar 69,54%.

V. REFERENCE AND CITATION

[1] E. De Buck, V. Borra, E. De Weerd, A. Vande Veegaete, and P. Vandekerckhove, "A systematic review of the amount of water per person per day needed to prevent morbidity and mortality in (post-)disaster settings," *PLoS One*, vol. 10, no. 5, pp. 1–14, 2015, doi: 10.1371/journal.pone.0126395.

[2] F. Y. Rahman, I. I. Purnomo, and N. Hijriana, "Penerapan Algoritma Data Mining Untuk Klasifikasi Kualitas Air," *Technol. J. Ilm.*, vol. 13, no. 3, p. 228, 2022, doi: 10.31602/tji.v13i3.7070.

[3] M. A. Rahman, N. Hidayat, and A. Afif Supianto, "Komparasi Metode Data Mining K-Nearest

- Neighbor Dengan Naïve Bayes Untuk Klasifikasi Kualitas Air Bersih (Studi Kasus PDAM Tirta Kencana Kabupaten Jombang),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Vol. 2, No. 12, Desember 2018, hlm. 6346-6353 e-ISSN*, vol. 2, no. 12, pp. 925–928, 2018, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [4] Generosa Lukhayu Pritalia, “Analisis Komparatif Algoritme Machine Learning dan Penanganan Imbalanced Data pada Klasifikasi Kualitas Air Layak Minum,” *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 2, no. 1, pp. 43–55, 2022, doi: 10.24002/konstelasi.v2i1.5630.
- [5] Y. T. K. Yuniar and K. Kusriani, “Sistem Monitoring Kualitas Air Pada Budidaya Perikanan Berbasis IoT dan Manajemen Data,” *Creat. Inf. Technol. J.*, vol. 6, no. 2, p. 153, 2021, doi: 10.24076/citec.2019v6i2.251.
- [6] N. Muniroh and E. Agus Priatno, “PENERAPAN ALGORITMA K-NN PADA MACHINE LEARNING UNTUK KLASIFIKASI KUALITAS AIR BUDIDAYA AKUAPONIK BERBASIS IoT,” *J. Teknol. dan Bisnis*, vol. 4, no. 2, pp. 73–86, 2022, doi: 10.37087/jtb.v4i2.87.
- [7] I. M. Faiza and W. Andriani, “Tinjauan Pustaka Sistematis: Penerapan Metode Machine Learning untuk Deteksi Bencana Banjir,” vol. 11, no. September, pp. 59–63, 2022.
- [8] A. Roihan, P. A. Sunarya, and A. S. Rafika, “Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper,” *IJCIT (Indonesian J. Comput. Inf. Technol.)*, vol. 5, no. 1, pp. 75–82, 2020, doi: 10.31294/ijcit.v5i1.7951.
- [9] Y. Herdiana, “Penerapan Machine Learning Dengan Model Linear Regression Terhadap Analisis Kualitas Hasil Petik the Di Pt. Perkebunan ...,” *Comput. J. Inform.*, vol. 09, pp. 1–9, 2022, [Online]. Available: <https://unibba.ac.id/ejournal/index.php/computing/article/view/855%0Ahttps://unibba.ac.id/ejournal/index.php/computing/article/download/855/710>
- [10] M. M. Mutoffar and A. Fadillah, “KLASIFIKASI KUALITAS AIR SUMUR MENGGUNAKAN ALGORITMA RANDOM FOREST,” vol. 04, no. 02, pp. 138–146, 2022.
- [11] W. S. Dharmawan, “Komparasi Algoritma Klasifikasi Svm-Pso Dan C4.5-Pso Dalam Prediksi Penyakit Jantung,” *I N F O R M a T I K a*, vol. 13, no. 2, p. 31, 2022, doi: 10.36723/juri.v13i2.301.
- [12] N. Anggraeni, G. Arifiana, and A. M. Abadi, “Klasifikasi Kualitas Air Sungai Winongo Menggunakan Fuzzy Inference System (FIS) Metode Mamdani,” *Progr. Stud. Mat. FMIPA UNY*, no. 2014, pp. 161–170, 2017.
- [13] P. E. J. Y. W. A. D. N. Fadlilah, “Prediksi Kelayakan Sumber Air Minum Menggunakan Algoritma Support Vector Machine (SVM),” vol. 3, p. 4865, 2022.

Dwi Hartanti, Meraih gelar Sarjana Teknik Informatika (S.Kom) dari Sekolah Tinggi Ilmu Manajemen Informatika Komputer Sinar Nusantara Surakarta pada tahun 2017. Kemudian gelar Master (M.Kom) dari Unoversitas Amikom Yogyakarta pada tahun 2019. Saat ini penulis menjadi Tenaga Pengajar di Universitas Duta Bangsa Surakarta.