

Penerapan Algoritma XGBoost untuk Klasifikasi Kualitas Air Minum

Tiara Permata Sari^{1*}, Faisal Muttaqin², Fetty Tri Anggraeny³

^{1,2,3}Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur

²faisalmuttaqin.if@upnjatim.ac.id

³fettyanggraeny.if@upnjatim.ac.id

*Corresponding author email: 22081010244@student.upnjatim.ac.id

Abstrak— Kualitas air minum merupakan salah satu faktor penting yang berpengaruh terhadap kesehatan manusia. Namun, metode konvensional dalam pengujian kualitas air cenderung memerlukan waktu yang lama serta biaya yang relatif tinggi. Oleh karena itu, diperlukan pendekatan yang lebih efisien untuk melakukan klasifikasi kualitas air secara otomatis. Penelitian ini bertujuan untuk menerapkan algoritma XGBoost dalam mengklasifikasikan kualitas air minum berdasarkan parameter fisik dan kimia. Tahapan penelitian meliputi pembersihan data melalui imputasi *missing value*, normalisasi menggunakan *Min-Max Scaling*, penyeimbangan data dengan metode *oversampling*, serta pembagian data menjadi data uji dan data latih. Model diproses menggunakan parameter *default* dengan menerapkan mekanisme *early stopping* untuk mencegah *overfitting*. Hasil pengujian menunjukkan bahwa model XGBoost mampu mencapai akurasi sebesar 81,62% dengan nilai *precision*, *recall*, dan *f1-score* yang seimbang pada kedua kelas. Hal ini menunjukkan bahwa XGBoost memiliki kinerja yang baik dalam menangani data kualitas air yang bersifat kompleks dan nonlinier. Dengan demikian, pendekatan ini dapat digunakan sebagai solusi alternatif dalam proses klasifikasi kualitas air secara cepat dan efisien.

Kata Kunci— Kualitas Air, Air Minum, Klasifikasi, *Machine Learning*, XGBoost

I. PENDAHULUAN

Air merupakan salah satu kebutuhan utama yang sangat esensial dalam kehidupan manusia, baik untuk konsumsi, kebersihan, maupun berbagai aktivitas ekonomi. Ketersediaan air bersih yang aman untuk dikonsumsi masih menjadi permasalahan global sampai sekarang. Menurut laporan World Health Organization (WHO), lebih dari dua miliar orang tinggal di negara yang mengalami tekanan air (*water stressed countries*), dan kondisi tersebut diperkirakan akan semakin memburuk akibat perubahan iklim serta meningkatnya pertumbuhan populasi [1]. Selain itu, diperkirakan sekitar 1,7 miliar penduduk dunia masih memanfaatkan sumber air minum yang tercemar oleh feses, sehingga menimbulkan risiko serius bagi kesehatan masyarakat [2]. Kondisi ini menunjukkan bahwa akses terhadap air minum yang aman dan layak konsumsi masih belum merata. Permasalahan tersebut terutama terjadi di negara-negara berkembang yang memiliki keterbatasan dalam infrastruktur pengolahan dan penyediaan air bersih [3].

Air yang tidak layak konsumsi dapat menjadi sumber penyebaran berbagai penyakit menular, antara lain diare,

disentri, kolera, polio, dan tifoid. WHO melaporkan bahwa setiap tahun diperkirakan sekitar 505.000 kematian akibat diare terjadi akibat konsumsi air minum yang terkontaminasi secara mikrobiologis [4]. Permasalahan ini tidak hanya berdampak pada aspek kesehatan, tetapi juga menimbulkan beban ekonomi dan sosial yang signifikan, terutama bagi kelompok masyarakat rentan, yaitu masyarakat berpenghasilan rendah dan anak-anak. Oleh karena itu, pemantauan dan penilaian kualitas air menjadi aspek penting dalam mendukung tercapainya Sustainable Development Goal (SDG) 6, yaitu menjamin ketersediaan serta pengelolaan air bersih yang berkelanjutan bagi seluruh masyarakat [1].

Secara umum, kualitas air dapat dinilai melalui berbagai parameter fisik, kimia, dan biologis seperti pH, total zat terlarut (TDS), kesadahan, sulfat, *chloramine*, *trihalomethanes*, dan tingkat kekeruhan [5]. Namun, metode konvensional dalam pengujian kualitas air yang dilakukan melalui proses laboratorium sering kali membutuhkan waktu yang lama serta biaya yang relatif tinggi. Selain itu, pendekatan tersebut belum mampu memberikan analisis secara cepat terhadap data kualitas air yang berjumlah besar [6].

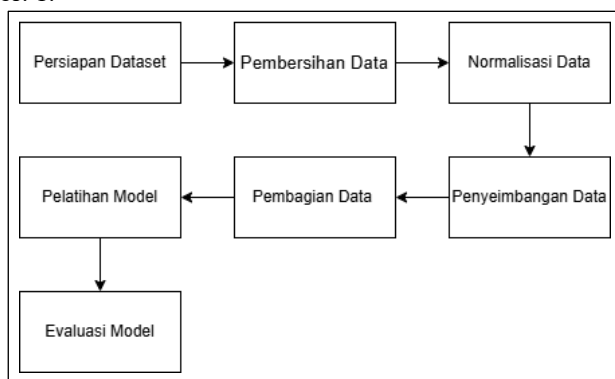
Seiring dengan perkembangan teknologi, berbagai penelitian mulai mengadopsi teknik kecerdasan buatan, terutama *machine learning*, untuk membantu proses analisis dan klasifikasi kualitas air [7]. *Machine learning* memungkinkan sistem untuk mempelajari pola dari data kualitas air sehingga dapat digunakan untuk memprediksi atau mengklasifikasikan tingkat kelayakan air secara otomatis. Pendekatan ini dinilai lebih efisien dalam mengolah data dalam jumlah besar serta mampu memberikan hasil prediksi dengan tingkat akurasi yang cukup tinggi [8]. Penelitian [9] menunjukkan bahwa penerapan model klasifikasi berbasis *machine learning* mampu mengenali pola kompleks pada data dengan baik. Selain itu, penelitian [10] menunjukkan bahwa pengolahan dan pemilihan fitur yang tepat dapat meningkatkan performa model klasifikasi secara signifikan. Di sisi lain, penelitian [11] menekankan pentingnya tahap *preprocessing* data untuk meningkatkan kualitas data sebelum dilakukan proses klasifikasi.

Penelitian yang dilakukan oleh Özsezer dan Mermer menunjukkan bahwa algoritma XGBoost memiliki performa yang baik dalam memprediksi kualitas air minum dengan memanfaatkan sembilan parameter fisik dan kimia. Dalam studi tersebut, XGBoost dibandingkan dengan beberapa algoritma lainnya dan berhasil memperoleh tingkat akurasi tertinggi sebesar 0,79 yang menunjukkan kemampuan

klasifikasi yang sangat optimal dalam membedakan air layak dan tidak layak konsumsi [12]. Hasil ini mengindikasikan bahwa XGBoost mampu menangani kompleksitas data kualitas air yang bersifat beragam dan nonlinier secara efektif. Secara umum, XGBoost merupakan algoritma berbasis *gradient boosting* yang dikenal memiliki efisiensi komputasi serta kinerja yang tinggi dalam berbagai permasalahan klasifikasi dan regresi. Berdasarkan keunggulan tersebut, penelitian ini berfokus pada penerapan XGBoost untuk mengklasifikasikan kualitas air minum serta mengevaluasi kinerja model dalam menghasilkan prediksi yang akurat dan andal.

II. METODOLOGI PENELITIAN

Metodologi penelitian dalam artikel ini dilakukan melalui beberapa tahapan yang disusun secara sistematis seperti pada Gbr. 1.



Gbr. 1 Diagram alur penelitian

A. Persiapan Dataset

Sumber data dalam penelitian ini diambil dari platform Kaggle dengan nama dataset “Water Quality & Potability”. Dataset tersebut terdiri dari 3.276 data dengan 9 fitur yang merepresentasikan parameter fisik dan kimia air serta 1 variabel target yang menunjukkan kelayakan air untuk dikonsumsi seperti pada Tabel I.

TABEL I
DESKRIPSI DATASET

Fitur	Tipe Data	Deskripsi
pH	float64	Menunjukkan tingkat keasaman atau kebasahan air (0–14).
Hardness (kesadahan)	float64	Menggambarkan kadar mineral terlarut dalam air.
Solids (padatan terlarut)	float64	Jumlah total padatan terlarut dalam air (ppm).
Chloramines (kloramin)	float64	Kadar kloramin yang digunakan sebagai disinfektan air.
Sulfate (sulfat)	float64	Konsentrasi ion sulfat dalam air.
Conductivity (konduktivitas)	float64	Kemampuan air menghantarkan listrik akibat kandungan ion.

Fitur	Tipe Data	Deskripsi
Organic_carbon (karbon organik)	float64	Jumlah karbon organik terlarut dalam air.
Trihalomethanes (trihalometana)	float64	Kandungan senyawa sampingan dari proses desinfeksi klorin.
Turbidity (kekeruhan)	float64	Tingkat kekeruhan atau kejernihan air.
Potability	int64	Label kelayakan air minum (1 = layak minum, 0 = tidak layak minum).

B. Pembersihan Data

Tahap *preprocessing* diawali dengan pembersihan data untuk menangani nilai yang hilang pada beberapa fitur, seperti pH, sulfate, dan trihalomethanes. Penanganan *missing value* dilakukan menggunakan teknik imputasi dengan nilai rata-rata (*mean*) pada masing-masing fitur, sehingga informasi data tetap terjaga tanpa mengurangi jumlah sampel.

C. Normalisasi Data

Selanjutnya dilakukan normalisasi menggunakan metode *min-max scaling* untuk mengubah rentang nilai fitur menjadi 0 hingga 1. Proses ini bertujuan untuk menyamakan skala antar variabel sehingga dapat meningkatkan kinerja model dalam proses pelatihan.

D. Penyeimbangan Data

Untuk mengatasi ketidakseimbangan distribusi kelas, dilakukan teknik *oversampling* pada kelas minoritas hingga jumlahnya seimbang dengan kelas mayoritas. Proses ini diikuti dengan pengacakan data guna menghindari pola tertentu yang dapat memengaruhi pembentukan model.

E. Pembagian Data

Dataset yang telah diproses kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan metode *stratified sampling*. Pendekatan ini memastikan distribusi kelas tetap seimbang pada kedua subset data.

F. Pelatihan Model

Pada tahap pelatihan model, digunakan algoritma XGBoost dengan terlebih dahulu mengonversi data latih dan data uji ke dalam bentuk DMatrix untuk meningkatkan efisiensi komputasi. Model dikonfigurasi menggunakan parameter seperti *objective* binary:logistic untuk klasifikasi biner dan *eval_metric* berupa logloss. Beberapa parameter lain seperti *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree* digunakan untuk mengatur kompleksitas model serta mencegah *overfitting*, sementara parameter regularisasi seperti *lambda*, *alpha*, dan *gamma* membantu meningkatkan stabilitas model. Proses pelatihan dilakukan menggunakan fungsi *xgb.train* dengan jumlah iterasi maksimum 5000 dan menerapkan mekanisme *early stopping* sebanyak 200 iterasi untuk

menghentikan pelatihan ketika tidak terjadi peningkatan performa. Setelah model terbentuk, dilakukan prediksi pada data uji dan hasil probabilitas dikonversi menjadi kelas biner menggunakan *threshold* 0.5.

G. Evaluasi Model

Kinerja model dievaluasi menggunakan data uji dilakukan dengan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Selain itu, *confusion matrix* berperan dalam memberikan gambaran lebih rinci terkait kemampuan model dalam mengklasifikasikan data.

III. HASIL DAN PEMBAHASAN

Pada tahap pembersihan data, dilakukan identifikasi terhadap keberadaan nilai yang hilang (*missing values*) pada setiap fitur dalam dataset. Hasil pemeriksaan menunjukkan bahwa terdapat beberapa fitur yang memiliki *missing value*, seperti pada Gbr. 2.

```
Jumlah missing value per kolom sebelum imputasi:
ph          491
Hardness    0
Solids       0
Chloramines 0
Sulfate     781
Conductivity 0
Organic_carbon 0
Trihalomethanes 162
Turbidity   0
Potability  0
dtype: int64

Jumlah missing value per kolom setelah Imputasi :
ph          0
Hardness    0
Solids       0
Chloramines 0
Sulfate     0
Conductivity 0
Organic_carbon 0
Trihalomethanes 0
Turbidity   0
Potability  0
dtype: int64
```

Gbr. 2 Penanganan *missing value*

Untuk mengatasi permasalahan tersebut, dilakukan proses imputasi menggunakan nilai rata-rata (*mean*) pada masing-masing fitur yang mengandung *missing value*. Pendekatan ini dipilih untuk mempertahankan jumlah data tanpa menghilangkan informasi penting yang terkandung dalam dataset. Setelah proses imputasi dilakukan, seluruh fitur tidak lagi memiliki nilai yang hilang, sehingga dataset menjadi lengkap dan siap digunakan pada tahap selanjutnya.

Pada tahap normalisasi data, dilakukan transformasi fitur menggunakan metode *min-max scaling* untuk mengubah seluruh nilai atribut ke dalam rentang 0 hingga 1. Proses ini diterapkan pada seluruh fitur input dengan memisahkan terlebih dahulu variabel target (*Potability*) dari fitur lainnya. Selanjutnya, fitur yang telah dinormalisasi digabungkan kembali dengan variabel target untuk membentuk dataset akhir yang siap digunakan seperti pada Gbr. 3.

Dataset setelah Scaling (5 data teratas):


	ph	Hardness	Solids	Chloramines	Sulfate	Conductivity
0	0.505771	0.571139	0.336096	0.543891	0.680385	0.669439
1	0.265434	0.297400	0.300611	0.491839	0.581699	0.719411
2	0.578509	0.641311	0.321619	0.698543	0.581699	0.414652
3	0.594055	0.605536	0.356244	0.603314	0.647347	0.317880
4	0.649445	0.484851	0.289922	0.484900	0.514545	0.379337
...
3271	0.333436	0.530482	0.775947	0.533436	0.656047	0.603192
3272	0.557775	0.530016	0.279263	0.603473	0.581699	0.368912
3273	0.672822	0.465486	0.539101	0.547807	0.581699	0.438152
3274	0.366197	0.664407	0.191490	0.465860	0.581699	0.387157
3275	0.562477	0.535635	0.280484	0.560259	0.581699	0.255266

	Organic_carbon	Trihalomethanes	Turbidity	Potability
0	0.313402	0.699753	0.286091	0.0
1	0.497319	0.450999	0.576793	0.0
2	0.562017	0.532866	0.303637	0.0
3	0.622089	0.808065	0.601015	0.0
4	0.358555	0.253606	0.496327	0.0
...
3271	0.448062	0.535037	0.564534	1.0
3272	0.678284	0.532673	0.254915	1.0
3273	0.338662	0.560655	0.349570	1.0
3274	0.343638	0.622659	0.616120	1.0
3275	0.534114	0.632478	0.162441	1.0


[3276 rows x 10 columns]

Gbr. 3 Hasil normalisasi data

Hasil normalisasi menunjukkan bahwa seluruh nilai fitur berhasil ditransformasikan ke dalam skala yang seragam tanpa mengubah distribusi data secara signifikan. Beberapa sampel awal dari dataset yang telah dinormalisasi juga menunjukkan bahwa setiap fitur kini berada dalam rentang yang sama, sehingga dapat membantu model dalam menganalisis pola data secara lebih optimal. Pada tahap penyeimbangan data, dilakukan analisis terhadap distribusi kelas untuk mengetahui apakah terdapat ketidakseimbangan antara jumlah data pada masing-masing kelas. Hasil awal menunjukkan bahwa dataset memiliki distribusi yang tidak seimbang, seperti pada Gbr. 4.



Gbr. 4 Distribusi kelas sebelum *oversampling*



Gbr. 5 Distribusi kelas setelah *oversampling*

Untuk mengatasi kondisi tersebut, diterapkan teknik *oversampling* pada kelas minoritas hingga jumlah sampelnya setara dengan kelas mayoritas. Setelah proses penyeimbangan dilakukan, distribusi data menjadi seimbang, seperti pada Gbr. 5. Pada tahap pembagian data, dataset yang telah melalui proses *preprocessing* dan penyeimbangan kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20. Proses pembagian dilakukan menggunakan metode *stratified sampling* untuk memastikan bahwa proporsi kelas tetap seimbang pada kedua subset data. Berdasarkan hasil pembagian, diperoleh sebanyak 3196 data sebagai data latih dan 800 data sebagai data uji seperti pada Gbr. 6. Data latih digunakan dalam proses pelatihan model untuk mempelajari pola hubungan antara fitur dan label, sedangkan data uji digunakan untuk mengevaluasi kinerja model terhadap data yang belum pernah dilihat sebelumnya.

```
Jumlah data latih: 3196
Jumlah data uji   : 800
```

Gbr. 6 Hasil pembagian data

Pembagian data yang proporsional ini bertujuan untuk menghasilkan model yang tidak hanya mampu belajar dengan baik, tetapi juga memiliki kemampuan generalisasi yang baik saat diterapkan pada data baru. Pada tahap pemodelan, digunakan algoritma XGBoost untuk melakukan klasifikasi kualitas air minum. Model diinisialisasi dengan parameter seperti *max_depth*, *learning_rate*, *subsample*, dan *regularization*, tanpa dilakukan proses optimasi lebih lanjut. Proses pelatihan model dilakukan menggunakan data latih dengan jumlah iterasi maksimum sebanyak 5000 dan menerapkan teknik *early stopping*. Pendekatan ini memungkinkan proses pelatihan berhenti secara otomatis apabila tidak terdapat peningkatan performa dalam sejumlah iterasi tertentu, sehingga dapat mengurangi risiko *overfitting*. Berdasarkan hasil pelatihan yang ditunjukkan pada Gbr. 7, model mampu mempelajari pola data dengan baik hingga mencapai kondisi optimal sebelum proses pelatihan dihentikan secara otomatis.

```
Akurasi XGBoost (early stopping): 81.62 %

Classification Report:
      precision    recall  f1-score   support

   0.0         0.86     0.75     0.80         400
   1.0         0.78     0.88     0.83         400

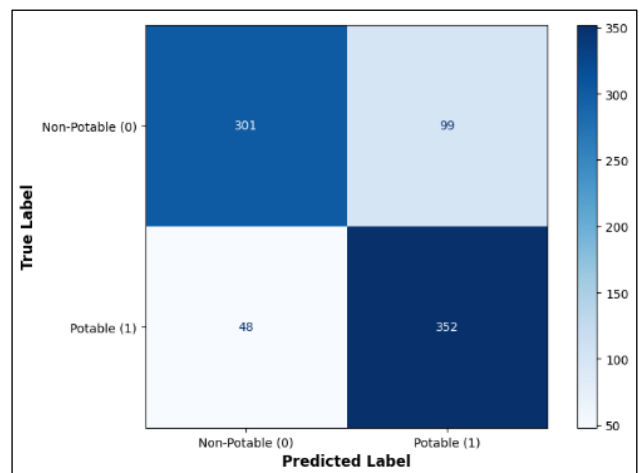
 accuracy          0.82
 macro avg         0.82     0.82     0.82         800
 weighted avg     0.82     0.82     0.82         800
```

Gbr. 7 Hasil pelatihan model

Setelah model selesai dibangun, dilakukan proses prediksi menggunakan data uji untuk mengevaluasi kinerjanya. Hasil pengujian menunjukkan bahwa model XGBoost memperoleh akurasi sebesar 81.62%, yang mengindikasikan bahwa

sebagian besar data berhasil diklasifikasikan dengan benar. Analisis lebih lanjut menggunakan *classification report* menunjukkan bahwa pada kelas tidak layak minum (0), model memperoleh *precision* sebesar 0.86 dan *recall* sebesar 0.75. Sementara itu, pada kelas layak minum (1), diperoleh *precision* sebesar 0.78 dan *recall* sebesar 0.88. Nilai *recall* yang lebih tinggi pada kelas layak menunjukkan bahwa model lebih efektif dalam mendeteksi air yang layak dibandingkan dalam mengidentifikasi air yang tidak layak. Selain itu, nilai *F1-score* pada kedua kelas berada pada kisaran 0.80 hingga 0.83, yang menunjukkan keseimbangan yang cukup baik antara *precision* dan *recall*. Secara keseluruhan, hasil ini mengindikasikan bahwa model memiliki performa yang cukup stabil dalam mengklasifikasikan kedua kelas.

Untuk memperoleh gambaran yang lebih rinci mengenai hasil klasifikasi, dilakukan analisis menggunakan *confusion matrix* seperti pada Gbr. 8. Berdasarkan hasil pengujian terhadap 800 data uji, model berhasil mengklasifikasikan 301 data tidak layak minum (*true negative*) dan 352 data layak minum (*true positive*) dengan benar. Namun, masih terdapat 99 data tidak layak yang diprediksi sebagai layak (*false positive*) dan 48 data layak yang diprediksi sebagai tidak layak (*false negative*).




Gbr. 8 Confusion matrix

Jumlah *false positive* yang relatif lebih tinggi menunjukkan bahwa model masih memiliki kecenderungan untuk mengklasifikasikan air yang tidak layak sebagai layak konsumsi. Kesalahan ini merupakan jenis kesalahan yang perlu mendapat perhatian khusus karena dapat menyebabkan air yang sebenarnya tidak memenuhi standar kualitas dikategorikan sebagai layak minum. Jika model digunakan sebagai sistem pendukung pengambilan keputusan, kondisi tersebut berpotensi menimbulkan risiko kesehatan bagi masyarakat akibat penggunaan air yang tidak aman untuk dikonsumsi.

Tingginya jumlah *false positive* dapat disebabkan oleh adanya kemiripan karakteristik antara beberapa sampel air layak dan tidak layak pada nilai fitur tertentu, sehingga model mengalami kesulitan dalam membedakan kedua kelas secara sempurna.

Selain itu, meskipun proses *oversampling* berhasil menyeimbangkan distribusi data, kemungkinan masih terdapat tumpang tindih pola data antar kelas yang memengaruhi proses klasifikasi. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penyesuaian *threshold* klasifikasi, optimasi *hyperparameter*, atau penerapan teknik seleksi fitur untuk mengurangi jumlah *false positive* dan meningkatkan keandalan model.

Untuk memahami faktor-faktor yang mungkin memengaruhi hasil klasifikasi tersebut, termasuk munculnya sejumlah *false positive*, dilakukan analisis *feature importance* guna mengetahui kontribusi masing-masing fitur terhadap proses pengambilan keputusan model. Hasil *feature importance* ditunjukkan pada Gbr. 9.



Gbr. 9 *Feature Importance*

Berdasarkan hasil *feature importance*, fitur *Sulfate* memiliki nilai *importance* tertinggi, diikuti oleh pH, *Hardness*, *Solids*, dan *Chloramines*. Hasil ini menunjukkan bahwa kelima parameter tersebut memberikan kontribusi paling besar dalam proses pengambilan keputusan model XGBoost untuk menentukan kelayakan air minum. Tingginya nilai *importance* pada fitur *Sulfate* dan pH menunjukkan bahwa kedua fitur tersebut paling sering digunakan model dalam proses pemisahan kelas air layak dan tidak layak konsumsi. Sementara itu, fitur *Organic_carbon*, *Turbidity*, *Conductivity*, dan *Trihalomethanes* memiliki nilai *importance* yang relatif lebih rendah dibandingkan fitur lainnya. Meskipun demikian, fitur-fitur tersebut tetap berkontribusi dalam proses klasifikasi karena XGBoost membangun keputusan berdasarkan kombinasi berbagai parameter kualitas air. Hasil analisis ini menunjukkan bahwa klasifikasi kualitas air minum tidak ditentukan oleh satu parameter saja, melainkan oleh interaksi beberapa karakteristik fisik dan kimia air secara simultan. Informasi *feature importance* ini juga meningkatkan interpretabilitas model dengan memberikan gambaran mengenai faktor-faktor yang paling berpengaruh terhadap hasil prediksi.

Temuan ini menunjukkan bahwa model tidak hanya mampu menghasilkan performa klasifikasi yang baik, tetapi juga memberikan informasi mengenai parameter kualitas air yang paling berpengaruh terhadap hasil prediksi. Informasi tersebut

dapat membantu proses pemantauan kualitas air dengan mengidentifikasi parameter yang perlu mendapatkan perhatian lebih dalam proses pengujian. Hasil penelitian ini menunjukkan bahwa pendekatan *machine learning* berpotensi digunakan sebagai sistem skrining awal kualitas air minum. Kemampuan model XGBoost dalam mencapai akurasi sebesar 81.62% menunjukkan bahwa model dapat membantu proses identifikasi awal terhadap sampel air yang berpotensi layak maupun tidak layak konsumsi. Dengan proses klasifikasi yang cepat, model dapat dimanfaatkan sebagai alat bantu bagi instansi pengelola air atau laboratorium dalam mendukung pemantauan kualitas air secara lebih efisien dan berkelanjutan. Meskipun demikian, hasil analisis *confusion matrix* menunjukkan masih terdapat sejumlah *false positive*, yaitu kondisi ketika air yang sebenarnya tidak layak diprediksi sebagai layak konsumsi. Dalam konteks kesehatan masyarakat, keberadaan *false positive* menunjukkan bahwa hasil prediksi model masih perlu diverifikasi melalui pengujian laboratorium sebelum digunakan sebagai dasar pengambilan keputusan. Langkah verifikasi tersebut penting untuk meminimalkan risiko paparan air yang tidak memenuhi standar kualitas bagi masyarakat. Oleh karena itu, model yang dikembangkan lebih tepat digunakan sebagai alat pendukung dalam proses pemantauan kualitas air daripada sebagai pengganti pengujian laboratorium secara langsung.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang diperoleh, dapat disimpulkan bahwa penggunaan algoritma XGBoost dengan parameter default mampu memberikan performa yang cukup baik dalam mengklasifikasikan kualitas air minum. Model yang dibangun menghasilkan akurasi sebesar 81.62% dengan nilai *precision*, *recall*, dan *F1-score* yang relatif seimbang pada kedua kelas, yaitu air layak dan tidak layak konsumsi. Hasil analisis *feature importance* menunjukkan bahwa fitur *Sulfate*, pH, *Hardness*, *Solids*, dan *Chloramines* merupakan parameter yang paling berpengaruh dalam proses klasifikasi kualitas air.

Berdasarkan hasil evaluasi, model menunjukkan kemampuan yang baik dalam mendeteksi air layak minum, yang ditunjukkan oleh nilai *recall* yang tinggi pada kelas tersebut. Namun hasil klasifikasi masih menunjukkan adanya kekeliruan, khususnya pada prediksi air tidak layak yang diklasifikasikan sebagai layak, sehingga perlu menjadi perhatian dalam penerapan di dunia nyata. Secara keseluruhan, pendekatan *machine learning* menggunakan XGBoost dapat berperan sebagai solusi yang efisien dalam membantu proses klasifikasi kualitas air secara cepat dan efisien. Untuk penelitian selanjutnya, performa model masih dapat ditingkatkan melalui pengembangan lebih lanjut, seperti penerapan teknik optimasi *hyperparameter* atau penggunaan metode lain untuk meningkatkan akurasi dan mengurangi kesalahan klasifikasi.

REFERENSI

- [1] United Nations Children's Fund (UNICEF) and World Health

- Organization (WHO), "Summary progress update 2021 : SDG 6 — water and sanitation for all," *UN-Water Integr. Monit. Initiat.*, pp. 1–58, 2021, [Online]. Available: <https://www.unwater.org/new-data-on-global-progress-towards-ensuring-water-and-sanitation-for-all-by-2030/>
- [2] WHO, *Global water, sanitation and hygiene Annual report 2022*. 2022.
- [3] S. Li, A. Gong, Y. Yin, and Q. Su, "Spatiotemporal characteristics and socioeconomic inequalities in water , sanitation , and hygiene access in China from 2000 to 2020 : analysis of data from three national censuses," *BMC Public Health*, 2024, doi: 10.1186/s12889-024-20739-8.
- [4] Q. Liu, M. Liu, and J. Liu, "Article Association of drinking water services with the disease burden of diarrhea in children under five in 200 countries from 2000 to 2021 ll Association of drinking water services with the disease burden of diarrhea in children under five in 200 countries from 2000 to 2021," *Cell Reports Sustain.*, vol. 1, no. 9, p. 100177, 2024, doi: 10.1016/j.crsus.2024.100177.
- [5] World Health Organization, *Guidelines for drinking-water quality: fourth edition incorporating the first addendum*. Geneva: World Health Organization, vol. 55. 2017. doi: 10.5005/jp/books/11431_8.
- [6] P. Vilasrao and Y. M. Patil, "Water Quality Monitoring Using Machine Learning Model," pp. 5686–5694, 2024.
- [7] M. Zhu *et al.*, "Eco-Environment & Health A review of the application of machine learning in water quality evaluation," *Eco-Environment Heal.*, vol. 1, no. 2, pp. 107–116, 2022, doi: 10.1016/j.eehl.2022.06.001.
- [8] N. T. Anh, L. D. Can, N. T. Nhan, B. Schmalz, and T. Le Luu, "Influences of key factors on river water quality in urban and rural areas: A review," *Case Stud. Chem. Environ. Eng.*, vol. 8, no. July, p. 100424, 2023, doi: 10.1016/j.cscee.2023.100424.
- [9] F. T. A. Alif Wildan Azzahra, Satria Farras Ayhallansyah, Moh. Angga Ardiansyah, Moh. Ayyuhan Fawwazansa, "Deteksi Gambar Palsu Menggunakan Deep Learning," vol. 19, 2024, doi: <https://doi.org/10.33005/scan.v19i3.5032>.
- [10] Ani Dijah Rahajoe; Agussalim; Emy Setyaningsih; Eka Prakarsa Mandyartha; Fawwaz Akbar; Faisal Muttaqin, "Comparison of Sequential Feature Selection Performance with Various Dimensional Data to Produce Optimal Classification," 2022, doi: <https://doi.org/10.1109/ITIS57155.2022.10009035>.
- [11] F. M. Eka Prakarsa Mandyartha, Fetty Tri Anggraeny and F. A. Akbar, "Global and Adaptive Thresholding Technique for White Blood Cell Image Segmentation", doi: 10.1088/1742-6596/1569/2/022054.
- [12] G. Özsezer and G. Mermer, "Prediction of drinking water quality with machine learning models: A public health nursing approach," *Public Health Nurs.*, vol. 41, no. 1, pp. 175–191, 2024, doi: 10.1111/phn.13264.