



Perbandingan Algoritma *Deep Q-Network* dan *Local Outlier Factor* Untuk Deteksi Anomali Konsumsi Air Minum Pelanggan PUDAM Kabupaten Banyuwangi

Andhika Ahnaf Daniswara

Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

ahnaf.andhika@gmail.com

Basuki Rahmat

Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

basukirahmat.if@upnjatim.ac.id

Eva Yulia Puspaningrum

Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

evapuspaningrum.if@upnjatim.ac.id

Alamat : Jl. Rungkut Madya No.1, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur 60294

Korespondensi penulis: basukirahmat.if@upnjatim.ac.id

Abstract. *Adequate provision of drinking water in quantity, quality, and continuity is needed to realize a healthy and productive society. A well-managed Drinking Water Supply System (SPAM) is essential to meet this need. Based on Government Regulation Number 122 of 2015, the implementation of SPAM involves the development and management of drinking water which is the responsibility of the local government and PUDAM as the implementer. The main challenges faced by PUDAM include the high level of water loss or Non-Revenue Water (NRW), which reaches 40% in Indonesia. One of the efforts to reduce the NRW level at PUDAM Banyuwangi Regency in the Kalipuro District area is to detect abnormal consumption in customer drinking water consumption. This study uses the Deep Q Network and Local Outlier Factor algorithms to detect anomalies in drinking water consumption, with the aim of comparing the performance of the two algorithms in identifying abnormal consumption patterns at PUDAM Banyuwangi Regency. The results of the study indicate that the Local Outlier Factor algorithm is more suitable for anomaly detection as evidenced by the absence of detection errors and an F1-Score value of 36%.*

Keywords: *Non-Revenue Water, Anomali, Deep Q-Network, Local Outlier Factor, IQR.*

Abstrak. Penyediaan air minum yang memadai dalam kuantitas, kualitas, dan kontinuitas diperlukan untuk mewujudkan masyarakat yang sehat dan produktif. Sistem Penyediaan Air Minum (SPAM) yang dikelola dengan baik sangat penting untuk memenuhi kebutuhan ini. Berdasarkan Peraturan Pemerintah Nomor 122 Tahun 2015, penyelenggaraan SPAM melibatkan pengembangan dan pengelolaan air minum yang menjadi tanggung jawab pemerintah daerah dan PUDAM sebagai pelaksana. Tantangan utama yang dihadapi PUDAM termasuk tingginya tingkat kehilangan air atau Non-Revenue Water (NRW), yang mencapai 40% di Indonesia. Salah satu upaya dalam menurunkan tingkat NRW pada PUDAM Kabupaten Banyuwangi di wilayah Kecamatan Kalipuro adalah dengan mendeteksi konsumsi tidak normal pada konsumsi air minum pelanggan. Penelitian ini menggunakan algoritma Deep Q Network dan Local Outlier Factor untuk deteksi anomali konsumsi air minum, dengan tujuan membandingkan performa kedua algoritma dalam mengidentifikasi pola konsumsi yang tidak normal di PUDAM Kabupaten Banyuwangi. Hasil penelitian menunjukkan bahwa algoritma Local Outlier Factor lebih cocok digunakan untuk deteksi anomali terbukti dengan tidak adanya kesalahan deteksi dan nilai F1-Score sebesar 36 %.

Kata kunci: Air Tak Berekening, Anomali, Deep Q-Network, Local Outlier Factor, IQR.

1. LATAR BELAKANG

Penyelenggaraan SPAM berdasarkan Peraturan Pemerintah Nomor 122 Tahun 2015 adalah meliputi kegiatan pengembangan dan pengelolaan SPAM yang dilaksanakan untuk

menjamin hak rakyat atas air minum, akses terhadap pelayanan air minum dan terpenuhinya kebutuhan pokok air minum sehari-hari. Penyelenggaraan SPAM di wilayah kabupaten/kota adalah menjadi tugas dan tanggung jawab Pemerintah Kabupaten/Kota, dengan Perusahaan Umum Daerah Air Minum (PUDAM/Perumdam) sebagai Badan Usaha Milik Daerah (BUMD) yang dibentuk khusus sebagai pelaksana kegiatan penyelenggaraan SPAM di wilayahnya.

Dalam melaksanakan kegiatan penyelenggaraan SPAM, PUDAM dituntut untuk dapat memberikan pelayanan air minum kepada masyarakat khususnya melalui jaringan perpipaan secara cukup dan memenuhi aspek kuantitas, kualitas, kontinuitas serta keterjangkauan (SHANTY & S DJ, 2020). Untuk memenuhi tuntutan pelayanan air minum tersebut, PUDAM secara umum akan dihadapkan pada berbagai persoalan dan tantangan baik bersifat teknis maupun non teknis, termasuk kebijakan. Salah satu persoalan klasik yang dihadapi oleh hampir seluruh PUDAM di Indonesia adalah permasalahan masih tingginya tingkat kehilangan air atau Air Tak Berekoning (ATR) / *Non-Revenue Water* (NRW). Dalam pembukaan Indonesia Water Forum 2022 yang digelar di Jakarta Convention Center pada tanggal 5 Oktober 2022, sebagaimana dilansir di <https://jabar.idntimes.com>, Menteri Pekerjaan Umum dan Perumahan Rakyat (PUPR) mengungkapkan bahwa angka kehilangan air minum di Indonesia, baik teknis maupun administrasi (non teknis), rata-rata masih sangat tinggi yaitu pada kisaran 40%. Padahal, Pemerintah menargetkan penurunan angka kehilangan air pada PUDAM ke level 25% pada tahun 2024.

Permasalahan tingginya angka kehilangan air ini juga dihadapi oleh PUDAM Kabupaten Banyuwangi. Meskipun data di beberapa sumber termasuk dari Buku Kinerja BUMD Air Minum Tahun 2021 dari Kementerian PUPR yang menyebutkan bahwa tingkat kehilangan air PUDAM Kabupaten Banyuwangi pada tahun 2018 adalah sebesar 25,23% dan pada tahun 2021 menurun menjadi 23,94%, namun angka ini adalah merupakan rata-rata tingkat kehilangan air di seluruh wilayah pelayanan PUDAM Kabupaten Banyuwangi yang terdiri dari 1 wilayah pelayanan pusat (Banyuwangi Kota) dan 5 cabang wilayah pelayanan (Kecamatan) dengan total pelanggan ±72.327 Sambungan Langganan (SL), serta angka kehilangan air ini masih dihitung berdasarkan angka volume air yang sifatnya prakiraan maupun menggunakan alat ukur konvensional yang kurang akurat.

Sejak tahun 2021, PUDAM Kabupaten Banyuwangi mengikuti Performance Based Grant (PBG) Programme atau Program Hibah Air Minum Berbasis Kinerja (HAMBK) dengan sumber dana hibah dari Pemerintah Australia dimana salah satu indikator kinerja yang diukur sebagai dasar perhitungan dan pemberian dana hibah adalah Air Tak Berekoning (ATR). Jika selama periode monitoring Program HAMBK, PUDAM Kabupaten Banyuwangi mampu

menurunkan angka ATR dari titik awal (baseline), maka penurunan volume ATR tersebut akan dikonversi menjadi dana hibah yang akan dibayarkan oleh Pemerintah Australia melalui Pemerintah Pusat dan Pemerintah Kabupaten Banyuwangi. Karena keterbatasan anggaran biaya dan kesiapan data jaringan perpipaan yang dimiliki oleh PUDAM Kabupaten Banyuwangi, maka ditetapkan Lokasi/Zona ATR sebagai Pilot Project pada Program HAMBK tersebut tidak mencakup keseluruhan wilayah pelayanan PUDAM Kabupaten Banyuwangi, melainkan hanya sebagian kecil wilayah pelayanan Banyuwangi Kota bagian utara yaitu di wilayah pelayanan Kecamatan Kalipuro dengan jumlah pelanggan ± 7.254 SL. Sesuai dengan ketentuan yang berlaku pada Program HAMBK, jaringan pipa distribusi di Zona ATR harus benar-benar terisolasi dan semua aliran air ke Zona ATR harus terukur melalui Meter Induk yang telah dikalibrasi dan dilengkapi dengan Data Logger yang dapat mencatat debit/volume air setiap jam serta semua pihak terkait dapat melakukan monitoring secara online. Pada bulan Januari 2022 disepakati menjadi bulan baseline indikator ATR sehingga dilakukan monitoring dan perhitungan ATR yaitu dengan membandingkan antara Total Volume Air yang Didistribusikan sebagaimana tercatat pada Meter Induk (Data Logger) vs Total Volume Air Terjual sebagaimana tercatat di seluruh meter pelanggan dan direkap dalam Data DRD (Daftar Rekening Ditagih). Selisih total volume air didistribusikan selama bulan Januari 2022 di Zona ATR dikurangi total volume air terjual (pemakaian air pelanggan selama bulan Januari 2022 di Zona ATR) merupakan volume air yang hilang (ATR) bulan Januari 2022. Hasil perhitungan menunjukkan bahwa tingkat ATR riil di lokasi Pilot Project ATR pada bulan Januari 2022 adalah 51,1% atau jumlah volume ATR sebesar 137.702 m³/bulan, yang selanjutnya angka ini digunakan sebagai angka baseline. Untuk menurunkan tingkat ATR yang masih sangat tinggi tersebut serta dalam rangka agar dapat memperoleh dana hibah dari Pemerintah Australia sebagai insentif atas peningkatan kinerja indikator ATR (penurunan tingkat ATR), maka PUDAM Kabupaten Banyuwangi melakukan identifikasi penyebab tingginya angka ATR baik fisik maupun non fisik (komersial) untuk selanjutnya dilakukan upaya penurunan.

Salah satu upaya dalam mengatasi permasalahan ATR non fisik adalah dengan melakukan deteksi anomali pada data konsumsi air minum pelanggan PUDAM Kabupaten Banyuwangi wilayah Kecamatan Kalipuro. Pendekatan yang dilakukan untuk deteksi anomali dapat dilakukan dengan teknologi machine learning. Penelitian ini bertujuan untuk mengetahui performa algoritma machine learning yaitu Deep Q-Network yang menggunakan teknik pembelajaran reinforcement learning dan Local Outlier Factor yang menggunakan teknik pembelajaran unsupervised learning.

2. KAJIAN TEORITIS

Deteksi Anomali

Anomaly berasal dari bahasa inggris yang berarti penyimpangan. Anomali merupakan sebuah penyimpangan yang terjadi pada model lingkungan. Penyimpangan ini dapat diakibatkan oleh factor dari dalam sistem itu sendiri maupun dari luar. Pendeteksian anomaly yang melibatkan manusia dapat sangat ampuh tetapi memerlukan waktu yang sangat lama dalam penggunaannya (Situmorang & Yahfizham, 2023).

Time Series

Time series atau data berkala adalah data yang dikumpulkan dari waktu ke waktu untuk menggambarkan perkembangan suatu kegiatan. Waktu yang digunakan dapat berupa minggu, bulan, tahun dan sebagainya (Nugroho, 2016). Dengan adanya data berkala, kita dapat mengamati atau mengetahui pola gerakan data atau nilai-nilai variabel, sehingga data berkala dapat digunakan sebagai dasar untuk :

1. Pembuatan keputusan saat ini
2. Peramalan keadaan perdagangan dan ekonomi yang akan datang
3. Perencanaan kegiatan di masa yang akan datang
4. Mencari pencilan data (anomali)

Reinforcement Learning

Reinforcement Learning merupakan kemajuan dari salah satu cabang kecerdasan buatan yang dapat diimplementasikan pada mesin atau robot untuk secara otomatis menentukan tindakan optimal dalam situasi tertentu dengan tujuan memaksimalkan kinerja mesin atau robot (Yu & Sun, 2020). Prinsip dasar pendekatan reinforcement learning memungkinkan mesin atau agen untuk memahami dan menyesuaikan tindakannya berdasarkan umpan balik dari lingkungan, sehingga dapat berubah dan beradaptasi seiring berjalannya waktu (Sutton & Barto, 2018). Harapannya, dengan kemampuan adaptasi ini, kinerja mesin atau agen dapat terus meningkat dan mencapai tingkat optimal.

Deep Q-Network

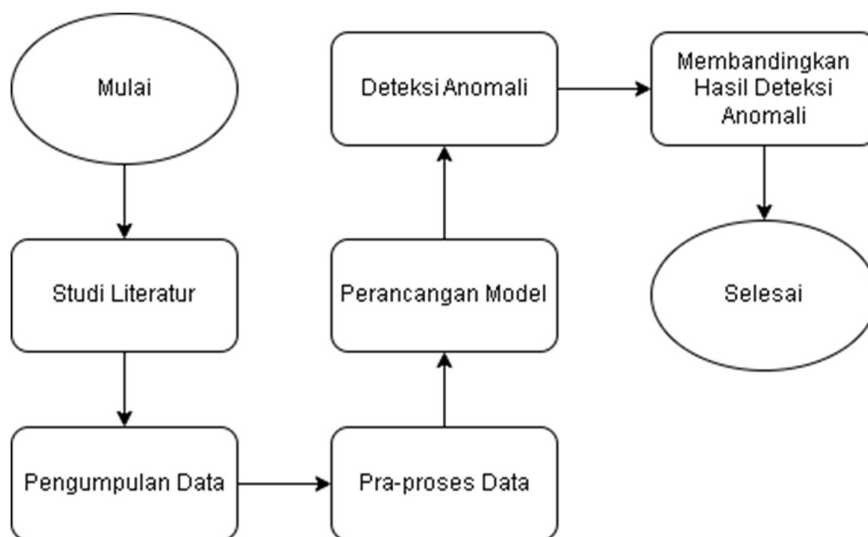
Deep Q Network (DQN) adalah jenis arsitektur dalam pembelajaran mesin yang dikembangkan untuk menangani permasalahan reinforcement learning (penguatan pembelajaran) dengan menggabungkan Deep Learning dan Q-Learning (Purba et al., 2022).

Local Outlier Factor

Local Outlier Factor (LOF) adalah algoritma unsupervised learning dalam pembelajaran mesin yang diusulkan pada tahun 2000 oleh Breunig, Kriegel, Ng, dan Sander. Tujuannya adalah mengidentifikasi pencilan dalam sebuah dataset dengan memeriksa seberapa jauh titik data tertentu dari tetangganya dalam hal kepadatan lokal (Dang et al., 2013). Pencilan dianggap sebagai titik data yang terisolasi dari lingkungan lokalnya. Jika sebuah titik memiliki sedikit tetangga dan terisolasi, itu kemungkinan besar menjadi pencilan. Sebaliknya, jika titik tersebut memiliki banyak tetangga dan termasuk dalam sebuah klaster, itu kemungkinan besar normal (Breunig et al., 2000). Metode ini terutama efektif dalam data berdimensi tinggi, di mana metode tradisional mungkin gagal.

3. METODE PENELITIAN

Dalam penelitian ini, diperlukan adanya perencanaan berdasarkan studi literatur yang telah dikumpulkan oleh peneliti, hal ini bertujuan untuk memastikan pelaksanaan penelitian ini sesuai dengan yang diharapkan, dan dapat menambahkan kontribusi baru untuk penelitian selanjutnya. Berikut ini adalah tahapan penelitian yang akan dilakukan agar mencapai hasil yang diinginkan.



Gambar 1. Tahapan Penelitian

1. Studi Literatur

Langkah awal yang dilakukan peneliti adalah mengumpulkan literatur atau referensi, yang didapat dari jurnal, artikel ilmiah, dan penelitian-penelitian terdahulu yang memiliki

relevansi dengan topik penelitian yang sedang dilakukan. Proses ini membantu peneliti untuk memahami konteks yang lebih luas dari topik yang diteliti, menemukan gap dalam pengetahuan yang ada, dan mengevaluasi metodologi serta temuan dari penelitian-penelitian sebelumnya.

2. Pengumpulan Data

Pada tahap ini, dilakukan pengumpulan data penggunaan air bulanan dari pelanggan PUDAM Kabupaten Banyuwangi. Data ini akan diproses menggunakan algoritma deteksi anomali. Data yang digunakan adalah data DRD (Daftar Rekening Ditagih) Zona ATR Program Hibah Air Minum Berbasis Kinerja (HAMBK) bantuan pemerintah Australia Tahun 2022. Sebagai tambahan, peneliti melakukan wawancara dengan narasumber yang relevan sebagai sumber informasi pendukung untuk menyelesaikan tugas akhir ini.

3. Praproses Data

Proses yang dilakukan pada dataset yang telah dikumpulkan adalah ekstraksi fitur yang akan digunakan pada algoritma DQN dan LOF, atribut yang digunakan hanya nomor pelanggan dan konsumsi air selama 12 bulan, setelah itu dilakukan penghilangan data pelanggan yang memiliki nilai konsumsi air nol dan kosong, karena agar penelitian menjadi seimbang semua nilai konsumsia air harus ada selama 12 bulan berturut-turut.

4. Perancangan Model

Perancangan model dimulai dengan menginputkan dataset yang telah di praproses untuk diproses pada algoritma Deep Q-Network dan Local Outlier Factor, hasil dari deteksi anomali kedua metode tersebut kemudian di analisa perbandingannya dengan perhitungan manual menggunakan Microsoft Excel dengan metode *interquartile range* (IQR).

5. Deteksi Anomali

Deteksi anomali dilakukan dengan menggunakan dua algoritma, yaitu Deep Q-Network dan Local Outlier Factor, untuk mengidentifikasi anomali dalam konsumsi air dengan periode 12 bulan.

6. Membandingkan Hasil Deteksi Anomali

Pada bagian ini, akan dijelaskan mengenai uji coba hasil deteksi dari algoritma DQN dan LOF. Tujuan utama dari membandingkan hasil deteksi anomali adalah untuk mengevaluasi dan menganalisa hasil dari deteksi anomali. Selain itu, perbandingan ini juga bertujuan untuk menilai akurasi perhitungan aplikasi jika dibandingkan dengan perhitungan manual menggunakan Microsoft Excel, yang menggunakan metode Interquartile Range (IQR).

Dengan membandingkan hasil dari algoritma Deep Q-Network dan Local Outlier Factor dengan metode IQR yang diterapkan di Excel, kita dapat memahami kelebihan dan kekurangan masing-masing pendekatan. Uji coba ini memberikan wawasan tentang efektivitas dan efisiensi model dalam mendeteksi anomali.

7. Skenario Pengujian

Skenario pengujian yang dibuat pada penelitian ini yakni bertujuan untuk menganalisa perbandingan kinerja model dari algoritma Deep Q-Network dan algoritma Local Outlier Factor. Dalam mencapai tujuan tersebut, akan dilakukan analisa dengan beberapa macam hyperparameter, pada algoritma Deep Q-Network hyperparameter yang digunakan adalah learning rate dan optimizer yang digunakan adalah adam, sedangkan pada algoritma Local Outlier Factor parameter yang digunakan adalah nilai k.

Tabel 1. Tabel Skenario Pengujian Algoritma DQN

Skenario	Optimizer	Hyperparameter
		Learning Rate
1	Adam	0,001
2		0,002
3		0,003
4		0,004
5		0,0001
6		0,0002
7		0,0003
8		0,0004

Tabel 2. Tabel Skenario Pengujian Algoritma LOF

Skenario	Hyperparameter
	K

PERBANDINGAN ALGORITMA DEEP Q-NETWORK DAN LOCAL OUTLIER FACTOR UNTUK DETEKSIANOMALI KONSUMSI AIR MINUM KONSUMEN PUDAM KABUPATEN BANYUWANGI

1	5
2	10
3	20
4	30
5	40

4. HASIL DAN PEMBAHASAN

Hasil Pengumpulan Data

A	B	C	D	E	F	G	H	I	J	K	L	M	N
NO	SP	NAMA	ALAMAT	RAYON	GOL	BULAN	TAHUN	STAND	PAKAI	ADM	BAYAR	JUMLAH	SUMBER
1893	1030766	sengaja dikosongkan	sengaja dikosongkan	B.33.10	R2	1	2022	2031.00	27	10000	77900	87900	KALIPURO2
566	1007962	sengaja dikosongkan	sengaja dikosongkan	B.33.02	R2	1	2022	3533.00	6	10000	21400	31400	KALIPURO2
2199	1014152	sengaja dikosongkan	sengaja dikosongkan	B.33.04	R3	1	2022	7414.00	36	11000	128160	139160	KALIPURO2
2225	1013262	sengaja dikosongkan	sengaja dikosongkan	B.37.02	R2	1	2022	4451.00	37	10000	115900	125900	KALIPURO2
2320	1013095	sengaja dikosongkan	sengaja dikosongkan	B.37.02	R3	1	2022	6461.00	42	11000	153120	164120	KALIPURO2
781	1013091	sengaja dikosongkan	sengaja dikosongkan	B.37.02	R3	1	2022	5290.00	10	11000	27300	38300	KALIPURO2
1146	1042822	sengaja dikosongkan	sengaja dikosongkan	B.33.10	R2	1	2022	228.00	16	10000	39340	49340	KALIPURO2
417	1014724	sengaja dikosongkan	sengaja dikosongkan	B.37.03	R2	1	2022	2962.00	3	10000	21400	31400	KALIPURO2
2161	1013632	sengaja dikosongkan	sengaja dikosongkan	B.37.02	R3	1	2022	7730.00	34	11000	119840	130840	KALIPURO2
819	1011267	sengaja dikosongkan	sengaja dikosongkan	B.37.01	R2	1	2022	606.00	11	10000	24390	34390	KALIPURO2
1233	1011143	sengaja dikosongkan	sengaja dikosongkan	B.36.03	R3	1	2022	3742.00	17	11000	51310	62310	KALIPURO2
46	1011161	sengaja dikosongkan	sengaja dikosongkan	B.36.03	R2	1	2022	3420.00	0	10000	21400	31400	KALIPURO2
2420	1007182	sengaja dikosongkan	sengaja dikosongkan	B.33.02	R2	1	2022	6881.00	54	10000	180500	190500	KALIPURO2
895	1016939	sengaja dikosongkan	sengaja dikosongkan	B.36.04	R2	1	2022	6451.00	12	10000	27380	37380	KALIPURO2
1565	1011358	sengaja dikosongkan	sengaja dikosongkan	B.36.02	R3	1	2022	2586.00	21	11000	65760	76760	KALIPURO2
1705	1025510	sengaja dikosongkan	sengaja dikosongkan	B.33.06	R2	1	2022	1902.00	23	10000	62700	72700	KALIPURO2
2265	1013913	sengaja dikosongkan	sengaja dikosongkan	B.33.04	R2	1	2022	7000.00	39	10000	123500	133500	KALIPURO2
1118	1011196	sengaja dikosongkan	sengaja dikosongkan	B.37.01	R2	1	2022	3375.00	15	10000	36350	46350	KALIPURO2
750	1011114	sengaja dikosongkan	sengaja dikosongkan	B.36.03	R3	1	2022	1687.00	10	11000	27300	38300	KALIPURO2
920	1024781	sengaja dikosongkan	sengaja dikosongkan	B.33.04	R2	1	2022	4589.00	12	10000	27380	37380	KALIPURO2
1211	1013298	sengaja dikosongkan	sengaja dikosongkan	B.37.02	R2	1	2022	7986.00	16	10000	39340	49340	KALIPURO2
1339	1042613	sengaja dikosongkan	sengaja dikosongkan	B.33.04	R2	1	2022	254.00	18	10000	45320	55320	KALIPURO2
839	1038179	sengaja dikosongkan	sengaja dikosongkan	B.33.03	R2	1	2022	106.00	11	10000	24390	34390	KALIPURO2

Gambar 2. Cuplikan Dataset

Gambar diatas menunjukkan cuplikan hasil pengumpulan data yang didapat dari PUDAM Kabupaten Banyuwangi yakni data DRD (Daftar Rekening Ditagih) Zona ATR Program Hibah Air Minum Berbasis Kinerja (HAMBK) bantuan pemerintah Australia Tahun 2022 di wilayah Kecamatan Kalipuro, Kabupaten Banyuwangi selama periode Januari hingga Desember dengan jumlah sebanyak 7018 data. Data tersebut masih belum dilakukan pemrosesan apapun, sehingga masih terdapat nilai konsumsi air yang kosong maupun nilai konsumsi nol, oleh karena itu perlu dilakukan praproses data yang akan dijelaskan pada sub bab berikutnya.

Praproses Data

Setelah memperoleh dataset mentah, langkah selanjutnya adalah melakukan praproses data. Proses ini dilakukan dengan tujuan untuk mempersiapkan dataset agar siap untuk digunakan sebagai input algoritma deteksi anomali. Untuk melakukan deteksi anomali, hanya diperlukan kolom nomor pelanggan dan data pemakaian air setiap bulannya. Oleh karena itu dilakukan pengeliminasian atribut yang tidak diperlukan dalam proses ini. Data tersebut melewati beberapa proses yang telah ditentukan, antara lain seleksi dan penggabungan atribut, eliminasi missing value, dan eliminasi nilai nol.

Hasil Percobaan


Nomor	SP	januari	februari	maret	april	mei	juni	juli	agustus	september	oktober	november	desember
1	1007595	208	200	67	212	213	230	287	305	302	257	243	237
2	1010568	28	27	45	59	97	82	88	48	52	52	44	42
3	1012551	101	128	90	98	100	84	63	64	60	71	122	126
4	1013005	98	40	38	37	56	46	46	46	47	46	50	55
5	1014139	35	32	40	81	187	65	30	31	36	38	33	35
6	1015083	63	57	54	54	67	52	57	58	55	59	63	59
7	1016054	76	64	68	77	87	78	76	89	80	48	52	52
8	1016951	63	53	43	62	67	56	55	48	56	59	61	60
9	1019359	33	30	24	29	44	40	31	38	58	68	69	66
10	1019382	66	65	57	65	63	64	78	68	74	64	78	80
...
170	1024134	60	50	38	56	66	55	58	58	52	56	60	32
171	1027408	19	17	2	24	21	18	46	40	78	98	97	62
172	1028820	67	59	40	78	72	64	73	77	71	48	38	45
173	1032915	89	73	49	71	94	75	76	83	79	70	67	67
174	1035645	147	114	77	109	133	104	92	111	82	115	120	110
175	1036489	44	43	30	61	50	31	55	50	76	59	72	114
176	1040199	16	17	26	39	88	61	98	193	84	23	7	9
177	1041257	25	20	20	42	52	73	108	194	20	11	12	13
178	1044050	65	60	41	67	76	60	62	59	66	59	64	65
179	1044837	3	2	6	7	11	8	13	10	63	1	19	188

Gambar 3. Pelanggan Anomali Skenario 5 DQN

Pada gambar terlihat hasil deteksi anomali dari skenario 5 dengan menggunakan nilai algoritma DQN dengan parameter learning rate sebesar 0,0001, jumlah pelanggan yang terdeteksi anomali sebanyak 179 pelanggan, hasil deteksi tersebut kemudian dibandingkan dengan menggunakan perhitungan excel, sehingga hasil F1-Score dari skenario 5 didapat sebesar 8%.

Tabel 3. Confussion Matriks Skenario 5 DQN

	Normal	Anomali
Normal	3546	113
Anomali	1379	66



Gambar 4. Heatmap Skenario 5 DQN

Berdasarkan gambar 4.17 ditunjukkan hasil confusion matrix dari skenario 5 dapat dijelaskan bahwa model tersebut dapat mendeteksi nilai TP atau model memprediksi anomali dan perhitungan manual menggunakan excel juga mendeteksi data tersebut anomali sejumlah 66 data, nilai FP atau model memprediksi anomali sedangkan pada perhitungan excel data tersebut merupakan normal sejumlah 113 data, dan nilai FN atau model memprediksi normal sedangkan pada perhitungan excel data tersebut merupakan anomali sejumlah 1379 data.

Setelah confusion matrix dilakukan, nilai yang dihasilkan dalam matriks tersebut akan diolah untuk menghasilkan matriks evaluasi pada skenario menggunakan learning rate 0,0001 yang ditunjukkan pada tabel dibawah.

Tabel 4. Matriks Evaluasi Skenario 5 DQN

Matriks Evaluasi		
Precision	Recall	F1-Score
0,36	0,04	0,08

Pada tabel diatas terdapat hasil matriks evaluasi yang menunjukkan bahwa hasil deteksi anomali menggunakan algoritma DQN dengan learning rate 0,0001 menunjukkan hasil yang kurang baik, dengan precision sebesar 0.36 dan recall sebesar 0,04 dengan nilai F1-Score sebesar 0.08. Dengan demikian hasil evaluasi kinerja model menunjukkan bahwa model memiliki performa yang kurang memuaskan dalam mendeteksi anomali.


Nomor	SP	januari	februari	maret	april	mei	juni	juli	agustus	september	oktober	november	desember
1	1006822	55	51	49	56	58	60	62	68	46	3	3	3
2	1007595	208	200	67	212	213	230	287	305	302	257	243	237
3	1008604	10	12	5	18	15	13	15	9	16	27	13	13
4	1008842	25	16	12	25	3	5	10	24	32	3	13	2
5	1009006	9	5	10	26	17	8	4	6	2	14	11	10
6	1009718	7	35	39	14	4	5	15	38	47	30	26	21
7	1010568	28	27	45	59	97	82	88	48	52	52	44	42
8	1012172	8	9	9	24	19	9	6	11	13	17	14	20
9	1012520	10	9	21	28	40	46	34	26	33	24	33	31
10	1012532	15	5	4	7	27	15	7	12	9	6	8	7
...
1127	1043224	21	24	1	3	3	1	2	5	20	21	19	20
1128	1044001	1	14	5	4	9	8	2	5	9	6	8	30
1129	1044014	5	10	57	16	15	15	13	14	12	10	5	6
1130	1044019	1	26	24	25	24	20	19	21	24	23	21	20
1131	1044020	3	3	3	16	23	23	14	20	21	24	24	9
1132	1044376	12	21	17	13	12	12	11	14	22	11	10	12
1133	1044523	59	8	8	8	9	7	9	6	8	7	8	8
1134	1044769	3	10	11	12	16	26	19	6	15	15	20	20
1135	1044837	3	2	6	7	11	8	13	10	63	1	19	188
1136	1044885	20	18	17	23	21	35	36	16	23	22	22	22

Gambar 5. Anomali Terdeteksi Skenario 5 LOF

Pada gambar 4.32 terlihat hasil deteksi anomali dari skenario 5 pada algoritma LOF dengan menggunakan parameter $K = 40$, jumlah pelanggan yang terdeteksi anomali sebanyak 1136 pelanggan, hasil deteksi tersebut kemudian dibandingkan dengan menggunakan perhitungan excel yang ditunjukkan pada tabel dibawah.

Tabel 5. Confusion Matriks Skenario 5 LOF

	Normal	Anomali
Normal	2988	671
Anomali	980	465



Gambar 6. Heatmap Skenario 5 LOF

Berdasarkan gambar diatas ditunjukkan hasil confusion matrix dari skenario 5, dapat dijelaskan bahwa model tersebut dapat mendeteksi nilai TP atau model memprediksi anomali dan perhitungan manual menggunakan excel juga mendeteksi data tersebut anomali sejumlah 465 pelanggan, nilai FP atau model memprediksi anomali sedangkan pada perhitungan excel data tersebut merupakan normal sejumlah 671 pelanggan, dan nilai FN atau model memprediksi normal sedangkan pada perhitungan excel data tersebut merupakan anomali sejumlah 980 pelanggan..

Setelah confusion matrix dilakukan, nilai yang dihasilkan dalam matriks tersebut akan diolah untuk menghasilkan matriks evaluasi pada skenario menggunakan parameter nilai $K=40$ yang ditunjukkan pada tabel dibawah.

Tabel 6. Matriks Evaluasi Skenario 5 LOF

Matriks Evaluasi		
Precision	Recall	F1-Score
0,41	0,32	0,36

Pada tabel diatas terdapat hasil matriks evaluasi yang menunjukkan bahwa hasil deteksi anomali menggunakan algoritma LOF dengan parameter nilai $K=30$ menunjukkan hasil dengan precision sebesar 0.41 dan recall sebesar 0,32 dengan nilai F1-Score sebesar 0.36. Hal ini bisa dikatakan cukup baik, jika dibandingkan dengan penggunaan algoritma DQN dengan hasil F1-Score yang lebih tinggi dibandingkan dengan semua pengujian pada algoritma DQN dan juga F1-Score meningkat dibandingkan dengan pengujian pada skenario sebelumnya yakni 0.36.

5. KESIMPULAN DAN SARAN

Algoritma Deep Q-Network (DQN) dengan lapisan pertama sebanyak 128 neuron, lapisan kedua sebanyak 64 neuron, dan fungsi aktivasi ReLU kurang cocok untuk deteksi anomali. Sebaliknya, algoritma Local Outlier Factor (LOF) dengan parameter k (jumlah tetangga terdekat) dapat melakukan deteksi anomali lebih akurat tanpa kesalahan hasil seperti pada DQN. Berdasarkan analisis hasil pengujian, algoritma LOF memberikan hasil terbaik dengan nilai F1-Score tertinggi sebesar 0,36 pada skenario ke-5, dibandingkan dengan perhitungan manual menggunakan Excel. Namun, pengujian kedua algoritma tersebut pada dataset tanpa label ground truth menghasilkan nilai precision, recall, dan F1-Score yang rendah,

karena perbedaan pendekatan antara kedua algoritma tersebut dengan perhitungan manual menggunakan Excel.

DAFTAR REFERENSI

- Asian Development Bank. (2023). *Buku Pegangan tentang Air Tak Berekening (NRW) untuk Manajer*. Diakses dari [Asian Development Bank](#).
- Breunig, M. M., Kriegel, H.-P., Ng, R. T., & Sander, J. (2000). LOF: identifying density-based local outliers. *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, 93–104. <https://doi.org/10.1145/342009.335388>
- Dang, X.-H., Micenková, B., Assent, I., & Ng, R. (2013). *Local Outlier Detection with Interpretation*. https://doi.org/10.1007/978-3-642-40994-3_20
- Infrastructure Asia. (2024). *3 Steps to the Sustainable Reduction of Non-Revenue Water in Indonesia*. Diakses dari [Infrastructure Asia](#).
- JDIH Kementerian PUPR. (2021). *Buku Kinerja BUMD Air Minum Tahun 2021*. Jakarta: Kementerian Pekerjaan Umum dan Perumahan Rakyat.
- Kementerian Pekerjaan Umum dan Perumahan Rakyat (PUPR). (2021). *Buku Kinerja BUMD Air Minum Tahun 2021*. Jakarta: Kementerian PUPR.
- Nugroho, K. (2016). Model Analisis Prediksi Menggunakan Metode Fuzzy Time Series. *Jurnal Ilmiah Infokam*, 12(1).
- Pasha, Y. (2022). *Tingkat Kebocoran Air Minum PDAM di Indonesia Capai 40 Persen*. IDN Times. Diakses dari [IDN Times](#).
- Purba, R., Lestari, W. S., & Ulina, M. (2022). Deteksi Serangan DDoS Menggunakan Deep Q-Network. *Teknik Informatika Dan Sistem Informasi*.
- Republik Indonesia. (2015). *Peraturan Pemerintah Nomor 122 Tahun 2015 tentang Sistem Penyediaan Air Minum*. Jakarta: Sekretariat Negara.
- SHANTY, D., & S DJ, R. (2020). Ketercapaian Sasaran 4K dalam Pelaksanaan Rencana Pengamanan Air Minum (RPAM) di PDAM Tirta Dharma Kota Malang. *Jurnal Reka Lingkungan*, 8(2), 112–120. <https://doi.org/10.26760/rekalingkungan.v8i2.112-120>
- Situmorang, S., & Yahfizham, Y. (2023). Analisis Kinerja Algoritma Machine Learning Dalam Deteksi Anomali Jaringan. *Konstanta: Jurnal Matematika Dan Ilmu Pengetahuan Alam*, 1(4), 258–269.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning, second edition: An Introduction*. MIT Press. <https://books.google.co.id/books?id=sWV0DwAAQBAJ>
- Wanginusantara. (2023). *PUDAM Banyuwangi Jadi Peserta Terbaik Indikator Kualitas Air Program Hibah Air Minum Berbasis Kinerja*. Diakses dari [Wanginusantara](#).
- Yu, M., & Sun, S. (2020). Policy-based reinforcement learning for time series anomaly detection. *Engineering Applications of Artificial Intelligence*, 95, 103919. <https://doi.org/10.1016/j.engappai.2020.103919>