


4. PEMBAHASAN


4.1 General Model

Untuk memahami proses *Machine Learning* (ML), maka perlu mengetahui general model yang dimiliki. General model biasanya terdiri 3 proses yakni input, analisa model dengan *Machine Learning* (ML), dan output.



Gambar 4. 1 General model dengan fitur 1


Gambar 4.1 merupakan general model dengan menggunakan input variabel indeks harga angkutan, kondisi pasang surut, rute kapal, dan kapasitas. Selain itu, pada model ini juga ditambahkan input analisa pra-proses, yang selanjutnya dilakukan pada proses pemodelan. Hasil dari pemodelan tersebut bertujuan mendapatkan model *Machine Learning* (ML) terbaik untuk prediksi jumlah muatan di hari ke-0.



Gambar 4. 2 General model dengan fitur 2


Gambar 4.2 merupakan general model dengan menggunakan input variabel indeks harga angkutan, kondisi pasang surut, rute kapal, dan kapasitas dan ditambahkan variabel lain yakni jumlah muatan dengan status FTL pada hari ke -9,-8,-7,-6,-5. Selain itu, pada model ini juga ditambahkan input analisa pra-proses, yang selanjutnya dilakukan pada proses pemodelan. Hasil dari pemodelan tersebut bertujuan mendapatkan model *Machine Learning* (ML) terbaik untuk prediksi jumlah muatan di hari ke-0.

4.2 Analisa Tren




Gambar 4. 3 Tren Muatan FTL Hari Ke -9 sampai dengan Hari Ke 0

Untuk tren muatan FTL pada hari ke -9 hingga hari ke 0, yang ditunjukkan pada Gambar 4.3 cenderung memiliki pola yang sama. Disisi lain jika diperhatikan bahwa muatan di hari berikutnya cenderung meningkat, hal ini disebabkan karena muatan pada hari sebelumnya akan mengisi muatan di hari berikutnya, sehingga muatan di hari berikutnya akan bertambah. Tren juga menggambarkan bahwa muatan berikutnya juga bisa tetap/ turun, dikarenakan tidak adanya penambahan muatan di hari sebelumnya, sehingga pola peningkatannya juga berbeda-beda. Kondisi muatan yang bertambah/turun/ tetap/ disebabkan oleh beberapa faktor seperti kapal rusak, ada *exception* lain dari pihak internal, muatan *overload*.




Gambar 4. 4 Tren Kapasitas Kapal

Gambar 4.4 menunjukkan bahwa kapasitas kapal yang paling besar berada di kisaran 4.000 hingga 4.500, sedangkan untuk kapasitas kapal yang paling kecil di kisaran 200, terdapat beberapa waktu data tersebut linear naik dan turun, hal ini disebabkan pada dataset terdiri dari beberapa tanggal yang sama, namun memiliki waktu yang berbeda. Kapasitas dari suatu kapal perlu diketahui untuk dapat melakukan prediksi jumlah muatan yang akan dimuat di atas kapal. Sehingga, kapasitas kapal yang ada dapat dimaksimalkan dengan baik.



Gambar 4. 5 Frekuensi Kapasitas Kapal

Frekuensi kapasitas kapal ditunjukkan pada Gambar 4.5 frekuensi kapasitas kapal ini




menunjukkan bahwa jumlah frekuensi kapasitas kapal 288 itu lebih banyak dibanding kapasitas kapal yang lain.


Gambar 4. 6 Tren Indeks harga Angkutan Peti Kemas (CFI)

Indeks harga angkutan peti kemas, terlihat pada Gambar 4.6, pada tahun 2021 hingga tahun 2022 nilai CFI cenderung meningkat. Di sisi lain pada tahun 2022, nilai CFI juga mengalami penurunan hingga tahun 2023. Dan Kembali meningkat pada tahun 2024. Di tahun 2021-2022

dan juga 2022-2023 ada grafik yang ditunjukkan dengan garis linear naik dan linear turun, hal ini disebabkan pada dataset terdiri dari beberapa tanggal yang sama, namun memiliki waktu yang berbeda. Berdasarkan data pada indeks harga angkutan peti kemas, menunjukkan bahwa dibandingkan dengan tahun 2021, tren nilai CFI ditahun 2020 cenderung turun dan stabil.




Gambar 4. 7 Frekuensi Rute Kapal




Gambar 4. 8 10 besar Frekuensi Rute Kapal

Pada Gambar 4.7 dan 4.8 menunjukkan untuk tren 3 rute kapal terbanyak yaitu IDJKT-IDPNK-IDJKT; IDSUB-ISBDJ-IDSUB; IDSUB-IDSRI_IDSUB.


4.3 Analisa Skewness





Gambar 4. 9 Gambar Data Sebelum *Log Transformation*

Gambar 4.9 merupakan gambar data sebelum *Log Transformation*. Metode ini sering digunakan untuk mengatasi *skewness* pada data time series. *Skewness* yang tinggi menunjukkan distribusi data yang tidak simetris, dengan ekor panjang di salah satu sisi. Ketika log transformasi diterapkan, distribusi data biasanya menjadi lebih simetris dan mendekati distribusi normal, yang sering mempermudah analisis dan pemodelan. Pada data di atas menggambarkan bahwa pada dataset untuk kolom kapasitas kapal, jumlah muatan FTL di hari ke-9,-8,-7,-6,-5 memiliki *skewness* ke arah kanan, namun untuk indeks harga angkutan peti kemas (CFI) memiliki distribusi yang normal, meskipun terdapat kenaikan di sisi kiri.



Gambar 4. 10 Gambar Data Setelah Log Transformation

Setelah dilakukan *Log Transformation* yang ditunjukkan pada Gambar 4.10 dataset untuk kolom kapasitas kapal, jumlah muatan FTL di hari ke-9,-8,-7,-6,-5 memiliki *skewness* yang lebih baik, dan berdistribusi normal, sedangkan untuk indeks harga angkutan peti kemas (CFI) memiliki *skewness* tetap, baik sebelum dan setelah dilakukan *Log Transformation* yakni berdistribusi normal, meskipun terdapat kenaikan di sisi kiri. Selanjutnya peneliti melakukan analisa statistik deskriptif untuk memahami distribusi data yang ditunjukkan pada Gambar 4.11:


Statistik Deskriptif Sebelum Log Transformasi:			
	Mean	Median	Standard Deviation
CAPACITY	784.343679	538.0	687.462473
9	5.441146	4.0	8.506097
8	10.364646	8.0	15.301523
7	18.161615	14.0	24.314941
6	29.306311	22.0	34.400269
5	44.437824	34.0	47.548880
CFI	3663.458817	2885.0	1139.460114

Statistik Deskriptif Setelah Log Transformasi:			
	Mean	Median	Standard Deviation
CAPACITY	6.411736	6.289716	0.661211
9	1.563360	1.609438	0.754420
8	2.116396	2.197225	0.768973
7	2.650388	2.708050	0.756707
6	3.132385	3.135494	0.732210
5	3.554223	3.555348	0.713006
CFI	8.156828	7.967627	0.317949

Gambar 4. 11 Gambar Analisa Deskriptif

Dari Gambar 4.11 tersebut disimpulkan bahwa *Log transformasi* berhasil memperbaiki distribusi data yang tidak simetris dengan mengurangi *skewness* dan mendekatkan distribusi data ke normalitas. Penurunan standar deviasi juga mengindikasikan bahwa transformasi ini membuat variasi data menjadi lebih konsisten dan lebih mudah untuk dianalisis.

4.4 Analisa Korelasi




Gambar 4. 12 Hubungan korelasi antar data numerik

Gambar 4.12 menunjukkan, dalam analisa hubungan korelasi antar data numerik ini, penulis menggunakan *heatmap* sebagai alat visualisasi untuk menganalisis pola dan hubungan antara variabel dalam dataset yang telah di pra-proses. *Heatmap* digunakan untuk secara intuitif menggambarkan korelasi antara fitur-fitur utama yang mempengaruhi hasil prediksi pada dataset, terlihat berkorelasi positif dengan muatan *full to load* pada hari ke -9,-8,-7,-6,-dan -5 yang ditunjukkan dengan nilai yang cukup besar secara berturut-turut yakni 0,87; 0,94; 0,95; 0,97. Indeks harga angkutan peti kemas (CFI) tidak berkorelasi baik dengan kapasitas dan kapasitas memiliki korelasi dengan bahwa muatan *full to load* (FTL) di hari ke -9,-8,-7,-6,-dan -5.

4.5 Pelatihan dan Pengujian

Pelatihan dan pengujian dilakukan dengan menggunakan 2 fitur dan 3 mekanisme pembagian data pelatihan dan pengujian. Masing-masing fitur memiliki variabel yang berbeda-beda, untuk fitur 1 menggunakan variabel indeks harga angkutan peti kemas (CFI), kondisi pasang surut, rute kapal, dan kapasitas, sedangkan fitur 2 menggunakan variabel variabel indeks harga angkutan peti kemas (CFI), kondisi pasang surut, rute kapal, kapasitas, dan jumlah muatan dengan status FTL hari ke -9, -8, -7, -6, -5. Untuk mekanisme yang digunakan, pertama ada 2021-2022 sebagai data pelatihan dan 2023 sebagai data pengujian, kedua ada *rolling horizon* , di mana 4 bulan data sebagai pelatihan, dan 2 bulan data sebagai pengujian, dan ketiga ada 80% data sebagai pelatihan, dan 20% data sebagai pengujian.


4.5.1 Pelatihan dan Pengujian Menggunakan 2021-2022 Pelatihan, 2023 Pengujian dengan Menggunakan Fitur 1




Gambar 4. 13 Hasil Aktual VS Prediksi dari 4 Model *Machine Learning* dengan Fitur 1

Gambar 4.13 adalah prediksi 4 model *machine learning* menggunakan fitur 1. Gambar 4.13 menunjukkan analisa setiap model memiliki *Mean Absolute Percentage Error* (MAPE) yakni model *Random Forest* (RF) (MAPE : 49%), model *XGBoost* (MAPE : 74%), *LSTM* (MAPE : 43,09%), dan *Ensemble Learning* (*Random Forest* dan *XGBoost*) (MAPE : 58,71%). Dari analisa diatas, model *machine learning* terbaik ditunjukkan oleh LSTM.

4.5.2 Pelatihan dan Pengujian Menggunakan 2021-2022 Pelatihan, 2023 Pengujian dengan Menggunakan Fitur 2







Gambar 4. 14 Hasil Aktual VS Prediksi dari 4 Model *Machine Learning* dengan Fitur 2

Gambar 4.14 menunjukkan analisa di atas setiap model memiliki *Mean Absolute Percentage Error* (MAPE) yakni model *Random Forest* (RF) (MAPE : 12,83%), model *XGBoost* (MAPE : 18,35%), *LSTM* (MAPE : 16,82%), dan *Ensemble Learning* (*Random Forest* dan *XGBoost*) (MAPE : 14,34%). Dari analisa data di atas berdasarkan *Mean Absolute Percentage Error* (MAPE) model *machine learning* terbaik adalah model *Random Forest*, yang ditunjukkan dengan nilai 12,83%. Gambar 4.14 juga dapat dilihat bahwa terdapat 1 data yang jauh dari garis prediksi, hal ini menunjukkan kemungkinan adanya anomali atau ketidaksesuaian dalam model yang digunakan atau adanya kesalahan penginputan data.


4.5.3 Pelatihan dan Pengujian Menggunakan 4 Bulan Pelatihan, 2 Bulan Pengujian dengan Menggunakan Fitur 1






Gambar 4. 15 Hasil Aktual VS Prediksi Model *Machine Learning Random Forest* dengan Fitur 1


Hasil plot aktual dan prediksi model *Machine Learning Random Forest* dengan menggunakan fitur 1 ditunjukkan Gambar 4.15, dari gambar tersebut terlihat bahwa nilai aktual dan prediksi dengan menggunakan model *Random Forest* dengan periode pelatihan selama 4 bulan dan periode pengujian selama 2 bulan. Pendekatan ini diuji beberapa kali, misalnya pelatihan dilakukan pada bulan Januari hingga bulan April, dan pengujian dilakukan pada bulan Mei, selanjutnya pelatihan akan dilakukan pada bulan Februari hingga bulan Mei, dan pengujian dilakukan pada bulan Juni, hal ini dilakukan untuk mengevaluasi konsistensi dan kinerja model menunjukkan nilai MAPE berturut – turut yakni 44,62%, dan 38,82%.





Gambar 4. 16 Hasil Aktual VS Prediksi Model *Machine Learning XGBoost* dengan Fitur 1


Hasil plot aktual dan prediksi model *Machine Learning XGBoost* menggunakan fitur 1 ditunjukkan Gambar 4.16, dari gambar tersebut terlihat bahwa nilai aktual dan prediksi dengan menggunakan model *XGBoost* dengan periode pelatihan selama 4 bulan dan periode pengujian selama 2 bulan. Pendekatan ini diuji beberapa kali dan model menunjukkan nilai MAPE berturut – turut yakni 42,48%, dan 40,47%.



Gambar 4. 17 Hasil Aktual VS Prediksi Model *Machine Learning LSTM* dengan Fitur 1

Hasil plot aktual dan prediksi model *Machine Learning LSTM* menggunakan fitur 1 ditunjukkan pada Gambar 4.17, dari gambar tersebut terlihat bahwa nilai aktual dan prediksi dengan menggunakan model *LSTM* dengan periode pelatihan selama 4 bulan dan periode pengujian selama 2 bulan, ketika dilakukan *running* , hanya menghasilkan 1 model, hal ini


disebabkan, dengan pendekatan *rolling horizon*, di mana pelatihan dan pengujian bergeser maju satu bulan setiap kali, model terus-menerus dihadapkan pada data baru yang mungkin memiliki karakteristik yang berbeda, yang menambah kompleksitas dalam menghasilkan prediksi yang akurat. Model LSTM menghasilkan nilai MAPE yang cukup tinggi 83,29%.



Gambar 4. 18 Hasil Aktual VS Prediksi Model *Machine Learning Ensemble Learning* dengan Fitur 1


Gambar 4.18 terlihat bahwa nilai aktual dan prediksi dengan menggunakan model *Ensemble Learning* dengan periode pelatihan selama 4 bulan dan periode pengujian selama 2 bulan. Pendekatan ini diuji beberapa kali dan model menunjukkan nilai MAPE berturut – turut yakni 41,98%, dan 38,69%.

4.5.4 Pelatihan dan Pengujian Menggunakan 4 Bulan Pelatihan, 2 Bulan Pengujian dengan Menggunakan Fitur 2




Gambar 4. 19 Hasil Aktual VS Prediksi Model *Machine Learning Random Forest* dengan Fitur 2

Gambar 4.19 menunjukkan bahwa nilai aktual dan prediksi dengan menggunakan model *Random Forest* dengan periode pelatihan selama 4 bulan dan periode pengujian selama 2 bulan. Pendekatan ini diuji beberapa kali dan model menunjukkan nilai MAPE berturut – turut yakni 15,14%, dan 15,35%.




Gambar 4. 20 Hasil Aktual VS Prediksi Model *Machine Learning XGBoost* dengan Fitur 2

Hasil plot aktual dan prediksi model *Machine Learning XGBoost* menggunakan fitur 1 ditunjukkan Gambar 4.20, dari gambar tersebut terlihat bahwa nilai aktual dan prediksi dengan menggunakan model *XGBoost* dengan periode pelatihan selama 4 bulan dan periode pengujian selama 2 bulan. Pendekatan ini diuji beberapa kali dengan waktu yang maju satu bulan setiap kali pengujian untuk mengevaluasi konsistensi dan kinerja model menunjukkan nilai MAPE berturut – turut yakni 14,83%, dan 15,40%, dan terlihat adanya kenaikan nilai MAPE.



Gambar 4. 21 Hasil Aktual VS Prediksi Model *Machine Learning LSTM* dengan Fitur 2

Hasil plot aktual dan prediksi model *Machine Learning LSTM* menggunakan fitur 2 ditunjukkan Gambar 4.21, dari gambar tersebut terlihat bahwa nilai aktual dan prediksi dengan menggunakan model *LSTM* dengan periode pelatihan selama 4 bulan dan periode pengujian selama 2 bulan. Pendekatan ini diuji beberapa kali dengan waktu yang maju satu bulan setiap kali pengujian untuk mengevaluasi konsistensi dan kinerja model menunjukkan nilai MAPE berturut – turut yakni 42,68%, dan 66,12%. Terlihat adanya peningkatan nilai MAPE pada pelatihan dan pengujian kedua, selain itu, Gambar 4.21 terlihat bahwa hasil prediksi dengan aktual sangat berbeda jauh, hal ini disebabkan dengan pendekatan *rolling horizon* model terus-menerus dihadapkan pada data baru yang mungkin memiliki karakteristik yang berbeda, yang menambah kompleksitas dalam menghasilkan prediksi yang akurat.



Gambar 4. 22 Hasil Aktual VS Prediksi Model *Machine Learning Ensemble Learning* dengan Fitur 2


Hasil plot aktual dan prediksi model *Machine Learning Ensemble Learning* menggunakan fitur 2 ditunjukkan Gambar 4.22, dari gambar tersebut terlihat bahwa nilai aktual dan prediksi dengan menggunakan model *Ensemble Learning* dengan periode pelatihan selama 4 bulan dan periode pengujian selama 2 bulan. Pendekatan ini diuji beberapa kali dengan waktu yang maju satu bulan setiap kali pengujian untuk mengevaluasi konsistensi dan kinerja model menunjukkan nilai MAPE berturut – turut yakni 14,13%, dan 14,91%.

Tabel 4. 1 Hasil Model *Machine Learning* dengan Mekanisme 4 Bulan Pelatihan, dan 1 Bulan Pengujian

Mekanisme	Model <i>Machine Learning</i>	Fitur 1		Fitur 2	
4 bulan Pelatihan 1 bulan Pengujian	<i>Random Forest</i>	44,62%	38,82%	15,14%	15,35%
	<i>XGBoost</i>	42,48%	40,47%	14,83%	15,40%
	<i>LSTM</i>	83,29%	-	42,68%	66,12%
	<i>Ensemble Learning</i>	41,98%	38,69%	14,13%	14,91%

Tabel 4.1 menunjukkan bahwa dengan melakukan pelatihan dan pengujian menggunakan 4 bulan pelatihan, 2 bulan pengujian dengan menggunakan fitur 1 dan 2 nilai yang baik ditunjukkan oleh *Random Forest*, *XGBoost*, dan *Ensemble Learning*. Namun, apabila di telaah lebih dalam pada fitur 1 model terbaik ditunjukkan oleh *Random Forest* dan *Ensemble Learning*, karena memiliki nilai MAPE yang turun berturut-turut untuk *Random Forest* ditunjukkan dengan nilai MAPE 44,62% menjadi 38,82% dan *Ensemble Learning* ditunjukkan dengan nilai 41,98% menjadi 38,69%.


4.5.5 Pelatihan dan Pengujian Menggunakan 80% dan 20% Data, Pengujian dengan Menggunakan Fitur 1



Gambar 4. 23 Hasil Plot Aktual VS Prediksi 4 Model *Machine Learning* dengan Fitur 1

Gambar 4.23 menunjukkan bahwa setiap model memiliki *Mean Absolute Percentage Error* (MAPE) yang berbeda, yakni model *Random Forest* (RF) (MAPE: 47,55%), model *XGBoost* (MAPE: 43,96%), *LSTM* (MAPE: 58,07%), dan *Ensemble Learning* (*Random Forest* dan *XGBoost*) (MAPE: 44,63%). Maka model *machine learning* terbaik adalah *XGBoost*. Perbedaan ini menegaskan keunggulan *XGBoost* dalam memprediksi nilai target dengan tingkat kesalahan yang lebih rendah dibandingkan model lainnya.

4.5.6 Pelatihan dan Pengujian Menggunakan 80% dan 20% Data, Pengujian dengan Menggunakan Fitur 2



Gambar 4. 24 Hasil Plot Aktual VS Prediksi 4 Model *Machine* dengan Fitur 2

Gambar 4.24, setiap model memiliki *Mean Absolute Percentage Error* (MAPE) yang berbeda, yakni model *Random Forest* (RF) (MAPE: 16,19%), model *XGBoost* (MAPE: 20,39%), *LSTM* (MAPE: 20,35%), dan *Ensemble Learning* (*Random Forest* dan *XGBoost*) (MAPE: 17,63%). Hal ini menunjukkan bahwa *Random Forest* memiliki kemampuan prediksi lebih unggul dari model yang lain.

Tabel 4. 2 Hasil Model *Machine Learning*

Mekanisme	Model <i>Machine Learning</i>	Fitur 1		Fitur 2	
2021-2022 Pelatihan 2023 Pengujian	<i>Random Forest</i>	49,00%		12,83%	
	<i>XGBoost</i>	74,00%		18,35%	
	<i>LSTM</i>	43,09%		16,82%	
	<i>Ensemble Learning</i>	58,71%		14,34%	
4 bulan Pelatihan 1 bulan Pengujian	<i>Random Forest</i>	44,62%	38,82%	15,14%	15,35%
	<i>XGBoost</i>	42,48%	40,47%	14,83%	15,40%
	<i>LSTM</i>	83,29%	-	42,68%	66,12%
	<i>Ensemble Learning</i>	41,98%	38,69%	14,13%	14,91%
80% Pelatihan 20% Pengujian	<i>Random Forest</i>	47,55%		16,19%	
	<i>XGBoost</i>	43,96%		20,39%	
	<i>LSTM</i>	58,07%		20,35%	
	<i>Ensemble Learning</i>	44,63%		17,63%	

Tabel 4.2 menunjukkan perbandingan hasil analisa *model Machine Learning* (ML) dengan menggunakan tiga mekanisme dan dua fitur. Dari data analisa di atas dengan menggunakan 3 mekanisme pelatihan dan pengujian, dapat dilihat jika menggunakan cara pelatihan dan pengujian berdasarkan tahun 2021-2022 pelatihan, dan 2023 bulan pengujian, maka *Random Forest* (RF) juga menjadi model terbaik jika prediksi dilakukan dengan menggunakan fitur. Namun, jika menggunakan mekanisme pelatihan dan pengujian berdasarkan 4 bulan pelatihan, dan 2 bulan pengujian, maka *Ensemble Learning* dan *XGBoost* menjadi model terbaik, baik prediksi dilakukan dengan menggunakan menggunakan fitur 2. Begitu juga, jika menggunakan mekanisme pelatihan dan pengujian berdasarkan pembagian dari dataset 80% untuk pelatihan dan 20% untuk pengujian, maka *Random Forest* (RF) menjadi model terbaik jika prediksi dilakukan dengan menggunakan fitur 2.

Tabel 4.2 juga menunjukkan bahwa dengan menggunakan dua jenis fitur (fitur 1 dan fitur 2), namun fitur 2 secara konsisten memberikan hasil yang lebih baik dibandingkan fitur 1. Hal ini disebabkan karena variabel pada fitur 1 tidak bisa digunakan untuk memprediksi dengan baik meskipun menggunakan beberapa model *Machine Learning* (ML).

Di sisi lain, Tabel 4.2 juga menunjukkan bahwa dengan menggunakan mekanisme 4 bulan pelatihan, dan 1 bulan pengujian nilai MAPE yang dihasilkan dari model *Machine Learning* (ML) lebih kecil, namun lebih dinamis, hal ini menyebabkan model harus terus beradaptasi dengan data baru, yang dapat mempengaruhi stabilitas dan akurasi prediksi. Untuk mekanisme 2 ini lebih memberikan wawasan yang lebih dinamis dan bisa lebih cocok untuk prediksi jangka pendek yang membutuhkan adaptasi cepat. Berbeda dengan mekanisme 1, mekanisme ini lebih stabil karena melibatkan pelatihan dengan data yang lebih banyak dan pengujian dengan data yang lebih konsisten dari tahun 2023, sehingga model dapat lebih baik dalam menangkap pola jangka panjang.

Tabel 4. 3 Interpretasi Nilai MAPE

Tabel ini merupakan interpretasi nilai MAPE dari Lewis:

MAPE	INTERPRETASI
< 10	Peramalan yang akurat
10-20	Peramalan Baik
20-50	Peramalan Wajar
>50	Permalan tidak akurat

Sumber : (Özdemir & Sarici, 2020)

Pada Tabel 4.3 dapat dilihat bahwa nilai MAPE memiliki *range* interpretasi. Dari tabel 4.2 dapat dilihat bahwa pada fitur 1 yang berisi variabel (CFI, Kondisi Pasang Surut, Rute Kapal, dan Kapasitas) tidak dapat digunakan, karena memiliki nilai *error* yang besar yang ditunjukkan dengan nilai MAPE yang tinggi, oleh sebab itu ditambahkan variabel lain, yang dapat dilihat pada fitur 2 yang berisi variabel (CFI, Kondisi Pasang Surut, Rute Kapal, Kapasitas, serta hari ke-9, -8, -7, -6, dan -5) hasil prediksi menunjukkan nilai eror yang jauh lebih baik, yang ditunjukkan dengan nilai MAPE yang lebih kecil. Dapat diambil contoh penggunaan fitur 1 dengan mekanisme 1 dengan model *XGBoost* menghasilkan nilai MAPE sebesar 74%, dari hasil MAPE tersebut, model dinyatakan tidak akurat. Sedangkan untuk penggunaan fitur 1 dengan mekanisme dengan model *XGBoost* menghasilkan nilai MAPE sebesar 18,35% model dinyatakan baik. Dari ketiga

mekanisme yang diterapkan, penggunaan data dan peramalan dengan *rolling horizon* memberikan hasil prediksi yang paling baik.