

Prediksi Harga Minyak Mentah Dunia Menggunakan Metode *Ensemble k-Nearest Neighbor*

Muhamad Fajri¹, Syafriandi², D. Vionanda³, Zilrahmi⁴

¹²³⁴Program Studi Sarjana Statistika, Universitas Negeri Padang
e-mail: fjrmd02@gmail.com

Abstrak

Harga minyak mentah dunia memiliki peran penting dalam perekonomian dunia. Namun, fluktuasi harga minyak yang signifikan sering terjadi dan berdampak luas pada perekonomian global, termasuk inflasi, biaya produksi, harga barang dan jasa, serta pertumbuhan ekonomi negara importir minyak. Prediksi harga minyak membantu perencanaan langkah menghadapi perubahan ekonomi akibat fluktuasi ini. Salah satu metode yang digunakan untuk memprediksi harga minyak mentah dunia adalah *Ensemble k-Nearest Neighbor (kNN)*. Teknik ini menggabungkan hasil prediksi dari berbagai model *kNN* untuk akurasi dan stabilitas prediksi yang lebih baik. Algoritma ini berfokus pada menemukan tetangga-tetangga terdekat dari titik data yang ingin diprediksi berdasarkan nilai-nilai fitur dari tetangga-tetangga tersebut. Berdasarkan analisis yang dilakukan, penggunaan *ensemble* dalam metode *kNN* dapat meningkatkan akurasi prediksi, dengan MAPE sebesar 11.11%. Sedangkan model *kNN* tunggal hanya mampu memperoleh MAPE terkecil sebesar 12.81%. Adapun prediksi harga minyak dunia Januari hingga Desember 2023 menunjukkan tren penurunan yang stabil meskipun juga terjadi fluktuasi harga.

Kata kunci: *Harga Minyak Mentah Dunia, Ensemble kNN, Times Series*

Abstract

The world crude oil price plays a crucial role in the global economy. However, significant price fluctuations of crude oil frequently occur and have broad impacts on the global economy, including inflation, production costs, prices of goods and services, and the economic growth of oil-importing countries. Predicting oil prices assists in planning measures to address economic changes caused by these fluctuations. One of the methods used to forecast world crude oil prices is the *Ensemble k-Nearest Neighbor (kNN)* method. This technique combines prediction outcomes from various *kNN* models for improved accuracy and prediction stability. This algorithm focuses on finding the nearest neighbors to the data point to be predicted based on the feature values of these neighbors. Based on the conducted analysis, the use of ensemble in

the k NN method can enhance prediction accuracy, with a MAPE of 11.11%. Meanwhile, a single k NN model could only achieve the lowest MAPE of 12.81%. The prediction of world oil prices from January to December 2023 exhibits a stable decreasing trend despite the occurrence of price fluctuations.

Keyword: *The World Crude Oil Price, Ensemble k -Nearest Neighbor, Times Series*

PENDAHULUAN

Minyak mentah merupakan salah satu sumber daya alam yang tidak dapat diperbarui yang sangat dibutuhkan oleh negara-negara di seluruh dunia untuk mendorong pertumbuhan ekonomi. Namun, ketersediaan minyak mentah semakin berkurang dari waktu ke waktu. Menurut Dalimunthe dan Rosyidan (2018) tingginya permintaan terhadap minyak mentah mengakibatkan kelangkaan yang menyebabkan fluktuasi harga. Berdasarkan data dari situs *Organization of the Petroleum Exporting Countries* (OPEC), harga minyak mentah dunia mengalami fluktuasi selama sepuluh tahun terakhir. Harga minyak mentah mengalami penurunan yang signifikan dari bulan Agustus 2014 hingga Januari 2015, turun drastis dari 100.75 USD per barel menjadi 44.37 USD per barel. Penurunan serupa juga terjadi dari Januari hingga April 2020, harga minyak mentah turun tajam dari 65.10 USD per barel pada Januari 2020 menjadi 17.66 USD per barel pada April 2020. Namun, terjadi peningkatan harga hingga April 2022.

Naik turunnya harga minyak mentah dunia dipengaruhi oleh banyak faktor, salah satunya kebijakan produksi minyak oleh negara anggota OPEC. Menurut Loresta dan Sulasmiyati (2017) OPEC memainkan peran penting dalam menentukan harga minyak mentah dunia, karena OPEC merupakan produsen minyak mentah terbesar di dunia, yang menghasilkan sekitar 60% dari total minyak mentah yang diperdagangkan internasional. Menurut Ahmad (2007) OPEC memiliki posisi penting sebagai kartel yang berperan dalam mempengaruhi sisi penawaran perdagangan minyak dunia. Fluktuasi harga minyak dapat berdampak signifikan pada perekonomian global dan pada negara-negara yang sangat bergantung pada industri minyak, baik sebagai eksportir maupun sebagai konsumen minyak. Jika harga minyak naik secara tiba-tiba dan signifikan, maka hal ini dapat menyebabkan inflasi dan menurunkan daya beli konsumen, yang pada gilirannya dapat mempengaruhi pertumbuhan ekonomi secara keseluruhan. Di sisi lain, jika harga minyak terlalu rendah, hal ini dapat merugikan produsen minyak, yang dapat mempengaruhi pertumbuhan ekonomi negara-negara produsen minyak. Oleh karena itu, prediksi harga minyak mentah dunia menjadi sangat penting dalam membantu perencanaan dan pengambilan keputusan ekonomi di seluruh dunia. Dengan memprediksi harga minyak dengan tepat, pemerintah, perusahaan, dan investor dapat mengambil langkah-langkah proaktif untuk meminimalkan dampak fluktuasi harga minyak pada ekonomi mereka.

Terdapat berbagai macam metode yang dapat digunakan untuk prediksi data *time series* diantaranya adalah metode *k-Nearest Neighbor* (k NN). Menurut kang (2021) metode k NN tidak memerlukan asumsi khusus mengenai distribusi data yang

harus dipenuhi, sehingga metode ini lebih fleksibel dan efektif untuk diimplementasikan. Metode ini bekerja dengan mencari k titik data terdekat (disebut sebagai "*neighbors*") dari sebuah titik data baru yang ingin diprediksi. Kemudian, nilai dari titik data baru akan ditentukan berdasarkan mayoritas nilai k tetangga terdekatnya. Namun, kelemahan dari metode k NN adalah sensitivitasnya terhadap nilai k dan tidak dapat secara pasti pada jarak k yang mana memiliki hasil yang mendekati nilai sebenarnya. Jika nilai k terlalu kecil dapat menyebabkan *overfitting*, sedangkan jika nilai k terlalu besar dapat menyebabkan *underfitting* (Martínez dkk., 2019). Oleh karena itu, diperlukan optimisasi dengan merancang atau menambahkan metode atau teknik yang dapat memberikan hasil yang konsisten dan baik. Salah satu cara yang dapat digunakan untuk optimasi adalah menerapkan *ensemble* pada metode k NN. Menurut Sinta dkk (2014) prinsip kerja *ensemble* adalah menggabungkan hasil prediksi dari banyak model menjadi satu buah prediksi akhir. Teknik *ensemble* tidak memilih satu model terbaik dari sekian banyak kandidat model yang ada dan kemudian melakukan pendugaan dari model terbaik tersebut, akan tetapi menggabungkan hasil pendugaan dari berbagai model yang ada.

Penelitian menggunakan metode *ensemble k*NN diantaranya dilakukan oleh Dewi Sinta (2014) dengan judul metode *ensemble k-Nearest Neighbor* untuk prediksi harga beras di Indonesia, dalam penelitian tersebut terbukti bahwa menggunakan teknik *ensemble* pada k NN menghasilkan prediksi yang lebih baik dibandingkan hanya menggunakan metode k NN dengan model tunggal. Dalam penelitiannya diperoleh nilai MAPE sebesar 1.46%. Selanjutnya penelitian yang dilakukan oleh Jusman dkk (2022) yang berjudul metode *ensemble k-nearest neighbor* untuk prediksi Indeks Harga Saham Gabungan (IHSG) di Indonesia". Dari penelitiannya diperoleh MAPE sebesar 7.16%, dimana ini menunjukkan bahwa penggunaan metode *ensemble k*NN dalam memprediksi memberikan hasil yang cukup akurat.

Pada penelitian ini yang menjadi rumusan masalah yaitu, berapa akurat metode *ensemble k*NN dalam memprediksi harga minyak mentah dunia serta berapa hasil prediksi harga minyak mentah dunia periode Januari hingga Desember 2023 menggunakan metode *ensemble k*NN. Tujuan penelitian ini adalah mengetahui akurasi metode k NN yang dioptimasi oleh teknik *ensemble* dalam memprediksi harga minyak mentah dunia dan mengetahui hasil prediksi harga minyak mentah dunia periode Januari hingga Desember 2023 menggunakan metode *ensemble k*NN.

METODE

Penelitian ini berjenis penelitian terapan. Data yang digunakan berjenis sekunder yang diambil dari situs resmi *Organization of the Petroleum Exporting Countries* (OPEC). Data yang digunakan merupakan harga rata-rata minyak mentah dunia bulan Januari 2018 hingga Desember 2022. Data yang tersedia di situs tersebut dalam bentuk harian, namun telah diubah menjadi data bulanan untuk keperluan penelitian.

Metode yang digunakan dalam penelitian ini adalah metode *Ensemble k-Nearest Neighbor* (k NN). Langkah-langkah dalam analisis data sebagai berikut.

1. Persiapkan data yang akan digunakan

2. Bagi dataset mejadi data *training* dan data *testing*
Data *training* digunakan untuk melatih model, sementara data *testing* digunakan untuk mengevaluasi kinerja model.
3. Konversi data
Data yang digunakan dalam penelitian ini terdiri dari satu variabel atau disebut juga data univariat. Data harus dikonversi kedalam bentuk multivariat agar dapat digunakan dalam metode ini. Konversi data dari univariat menjadi multivariat pada data *time series* dapat dilakukan dengan menambahkan fitur-fitur baru ke dalam dataset. Fitur-fitur baru ini dihasilkan dari nilai-nilai sebelumnya atau disebut lag (nilai kelambanan) dan dapat disusun dalam bentuk kolom-kolom baru. Menurut Martinez dkk (2019) jika panjang periode musiman data time series adalah m , maka lag 1: m digunakan sebagai vektor fitur. Misalnya, data tersebut merupakan data kuartalan (dalam interval perempat tahun), maka lag 1:4 akan dipilih sebagai vektor fitur dan jika data tersebut merupakan data bulanan, maka lag 1:12 akan dipilih sebagai vektor fitur. Dengan cara ini, pola musiman dapat ditangkap dengan lebih mudah. Misalkan akan dikonversi data time series bulanan sebanyak 60 periode, yaitu $t = \{x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, \dots x_{60}\}$ dengan lags 1:12 sebagai vektor fitur diperoleh hasil konversi yang struktur datanya disajikan pada Tabel 1.

Tabel 1. Struktur Data Training

No	Fitur	Target
1	$x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}, x_{11}, x_{12}$	x_{13}
2	$x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}, x_{11}, x_{12}, x_{13}$	x_{14}
3	$x_3, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}, x_{11}, x_{12}, x_{14}$	x_{15}
⋮	⋮	⋮
36	$x_{48}, x_{49}, x_{50}, x_{51}, x_{52}, x_{53}, x_{54}, x_{55}, x_{56}, x_{57}, x_{58}, x_{59}$	x_{60}

4. Transformasi data
Transformasi data dalam *time series* dapat meningkatkan kinerja model sehingga juga akan meningkatkan akurasi prediksi. Salah satu transformasi yang dapat digunakan adalah transformasi *additive*. Transformasi *additive* adalah proses pengurangan nilai setiap vektor fitur dan target dengan rata-rata dari vektor tersebut. Transformasi untuk vektor fitur dapat dilakukan menggunakan Persamaan (1) dan transformasi untuk vektor target menggunakan Persamaan (2).

$$f_x^{i'} = f_x^i - \frac{1}{n} \sum_{i=1}^n f_x^i \quad (1)$$

(Martínez dkk., 2022)

Dengan:

$f_x^{i'}$: hasil transformasi nilai fitur ke- i data ke- x

f_x^i : nilai fitur ke- i data ke- x
 n : banyak fitur

$$t'_x = t_x - \frac{1}{n} \sum_{i=1}^n f_x^i \quad (2)$$

Dengan:

t'_x : hasil transformasi nilai target data ke- x

f_x^i : nilai fitur ke- i data ke- x

t_x : nilai target data ke- x

n : banyak fitur

5. Hitung jarak *Euclidean*

Jarak *Euclidean* dihitung antara data *training* dengan data yang akan diprediksi. Kemudian diurutkan dari yang terkecil hingga terbesar. Perhitungan jarak *Euclidean* menggunakan Persamaan (2).

$$d(f^i, q) = \sqrt{\sum_{x=1}^n (f_x^i - q_x)^2} \quad (3)$$

(Martínez dkk., 2019)

Dengan:

$d(f^i, q)$: jarak *Euclidean* antara data *training* baris ke- i dengan data yang akan diprediksi

f_x^i : fitur ke- x baris ke- i dari data *training*

q_x : fitur ke- x dari data yang akan diprediksi

n : jumlah data *training*

7. Tentukan beberapa nilai k untuk model k NN

Model k NN dipilih akan digunakan sebagai anggota *ensemble* k NN.

8. Hitung nilai prediksi menggunakan model k NN yang dipilih

Perhitungan nilai prediksi menggunakan Persamaan (4). Hasil prediksi yang diperoleh dijadikan sebagai fitur untuk memprediksi data untuk periode berikutnya. Untuk memprediksi periode pertama, 12 nilai terakhir dari data *training* digunakan sebagai fiturnya. Untuk memprediksi periode kedua, 11 nilai terakhir dari data dan nilai prediksi periode pertama dijadikan sebagai fitur. Begitupun untuk memprediksi periode berikutnya.

$$T = \frac{\sum_{i=1}^k w_i t_i}{\sum_{i=1}^k t_i} \quad (4)$$

(Martínez dkk., 2019)

Dengan:

T : nilai prediksi model

w_i : pembobot untuk tetangga ke- i

t_i : target dari k tetangga terdekat

k : banyaknya tetangga terdekat
Dengan formulasi pembobot pada Persamaan (5).

$$w_i = \frac{1}{d_i^2} \quad (5)$$

(Martínez dkk., 2019)

Dengan:

w_i : pembobot k NN untuk tetangga ke- i yang terpilih.

d_i : jarak *Euclidean* antara data yang akan diprediksi dengan tetangga ke- i .

9. Transformasi ke bentuk awal

Hasil prediksi yang diperoleh ditransformasi ke bentuk awal menggunakan Persamaan (6).

$$\hat{y}' = \hat{y} + \frac{1}{n} \sum_{i=1}^n q_x \quad (6)$$

(Martínez dkk., 2019)

Dengan:

\hat{y}' : hasil prediksi setelah ditransformasi ke bentuk awal

\hat{y} : hasil prediksi (dalam bentuk transformasi *additive*)

q_x : nilai fitur ke- x dari data yang akan diprediksi

n : banyak fitur

10. Gabungkan hasil prediksi

Gabungkan hasil prediksi dari setiap model k NN yang telah ditentukan dengan teknik *ensemble* menggunakan Persamaan (7).

$$\mu = \frac{1}{m} \sum_{i=1}^m \hat{y}_i \quad (7)$$

(Sinta dkk., 2014)

Dengan:

μ : hasil *ensemble*

\hat{y}_i : nilai prediksi dari model ke- i

m : banyaknya model k NN

11. Evaluasi hasil prediksi model

Ketepatan hasil prediksi dapat dihitung menggunakan *Mean Absolute Percentage Error* (MAPE) dengan menggunakan Persamaan (6). Semakin kecil nilai MAPE maka akan semakin akurat hasil prediksi.

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{X_t - F_t}{X_t} \right| \quad (8)$$

(Martínez dkk., 2019)

Dengan:

X_t : nilai aktual

F_t : nilai prediksi dari model ke- t

n : banyaknya data yang digunakan

Akurasi hasil prediksi yang diperoleh berdasarkan nilai MAPE dapat dilihat pada Tabel 2.

Tabel 2. Akurasi Hasil Prediksi Berdasarkan Nilai MAPE

Nilai MAPE	Akurasi
$MAPE \leq 10\%$	Tinggi
$10\% < MAPE < 20\%$	Baik
$20\% < MAPE < 50\%$	Sedang
$MAPE > 50\%$	Rendah

(Gustriansyah, 2017)

12. Optimasi

Jika hasil evaluasi belum memenuhi harapan, dapat mencoba berbagai kombinasi model *k*NN yang berbeda atau mengatur nilai *k* untuk meningkatkan kinerja *ensemble*.

13. Lakukan prediksi untuk periode kedepan

Gunakan model *ensemble k*NN terbaik yaitu yang menghasilkan MAPE terkecil untuk melakukan prediksi untuk periode kedepan.

HASIL DAN PEMBAHASAN

Data harga minyak mentah dunia bulan Januari 2018 hingga Desember 2022 disajikan dalam Gambar 1. Pada Gambar 1 dapat dilihat bahwa rentang harga minyak mentah dalam data sangat bervariasi, berkisar antara 17.66 hingga 117.72 USD per barel. Harga minyak mentah memiliki fluktuasi yang signifikan selama periode tersebut, dengan kenaikan dan penurunan yang tajam dalam beberapa bulan. Harga tertinggi tercatat pada bulan Maret 2022 dengan nilai 113.48 USD per barel, sementara harga terendah terjadi pada bulan April 2020 dengan nilai 17.66 USD per barel. Tren umum harga minyak mentah selama periode ini adalah naik-turun, tetapi ada periode tertentu di mana harga mengalami penurunan drastis seperti pada Maret 2020, mencapai 33,92 USD per barel, yang disebabkan terutama oleh resesi ekonomi global akibat pandemi COVID-19 dan perang harga minyak.



Gambar 1. Grafik Harga Minyak Mentah Dunia Januari 2018-Desember 2022

Prediksi harga minyak mentah dunia menggunakan metode *ensemble k-nearest neighbor* dilakukan menggunakan bantuan *software Rstudio* dengan *package tsfkn*. Proses diawali dengan membagi dataset menjadi data *training* dan data *testing*. Data harga minyak Januari 2018 hingga Desember 2021 dijadikan sebagai data *training* dan data harga minyak Januari hingga Desember 2022 dijadikan sebagai data *testing*. Kemudian, data *training* dikonversi kedalam bentuk multivariat dengan lags 1:12 sebagai vektor fitur. Struktur data *training* dapat dilihat pada Tabel 4.

Tabel 4. Struktur Data Training

No	Fitur	Target
1	66.85, 63.48, 63.76, 68.43, 74.11, 73.22, 73.27, 72.26, ..., 56.94	58.74
2	63.48, 63.76, 68.43, 74.11, 73.22, 73.27, 72.26, ..., 56.94, 58.74	63.83
3	63.76, 68.43, 74.11, 73.22, 73.27, 72.26, ..., 56.94, 58.74, 63.83	66.37
⋮	⋮	⋮
36	49.17, 54.38, 61.05, 64.56, 63.24, 66.91, 71.89, 73.53, ..., 80.37	74.38

Selanjutnya, dilakukan transformasi data. Transformasi yang digunakan dalam penelitian ini adalah transformasi *additive*. Adapun hasil transformasi pada data *training* dapat dilihat pada Tabel 5.

Tabel 5. Hasil Transformasi Data Training

No	Fitur	Target
1	-2.67, -6.04, -5.76, -1.09, 4.60, 3.70, 3.75, 2.74, ..., -12.57	-10.78
2	-5.36, -5.08, -0.41, 5.27, 4.38, 4.42, 3.42, ..., -11.10, -10.10	-5.02
3	-5.11, -0.44, 5.24, 4.35, 4.40, 3.39, ..., -11.93, -10.13, -5.05	-2.50
⋮	⋮	⋮
36	-18.45, -13.24, -6.57, -3.06, -4.38, -0.71, 4.27, 5.91, ..., 12.75	6.76

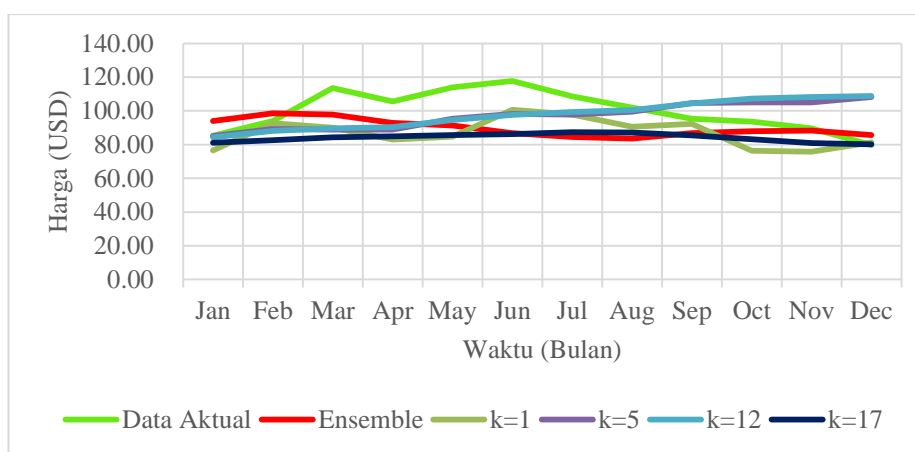
Setelah dilakukan transformasi, langkah selanjutnya adalah mengukur jarak *Euclidean* antara data *training* dengan data yang akan diprediksi. Data yang akan diprediksi menggunakan 12 data terakhir dari data *training* sebagai fiturnya. Perhitungan jarak *Euclidean* dilakukan antara data yang akan diprediksi dengan seluruh data *training*. Perhitungan dilakukan dengan bantuan *software Rstudio*. Hasil pengukurannya terdapat pada Tabel 6.

Tabel 6. Jarak Euclidean Antara Data Yang Akan Diprediksi Dengan Data Training

No	1	2	3	4	5	...	37
1	0.00	19.03	31.02	35.47	37.04	...	28.18
2	19.03	0.00	19.55	31.86	37.42	...	37.54
3	31.02	19.55	0.00	19.70	32.21	...	41.79
4	35.47	31.86	19.70	0.00	19.64	...	42.73
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
37	37.54	41.79	42.73	43.28	42.65	...	0

Berdasarkan Tabel 6 dapat dilihat jarak *Euclidean* data setiap baris. Elemen di baris pertama dan kolom kedua menunjukkan jarak *Euclidean* antara baris pertama dan kedua dari data asli. Namun, karena jarak *Euclidean* simetris (yaitu jarak *Euclidean* antara baris 1 dan 2 sama dengan jarak antara baris 2 dan 1), maka elemen di kolom pertama dan baris kedua juga menunjukkan jarak yang sama. Jarak *Euclidean* antara baris dengan dirinya sendiri selalu nol, sehingga elemen diagonal utama (yaitu elemen di baris pertama dan kolom pertama, baris kedua dan kolom kedua, dan seterusnya) selalu nol.

Selanjutnya, menentukan beberapa nilai k untuk model k NN. Pada penelitian ini menggunakan nilai k yang terdiri dari $k = 1, k = 5, k = 12$ dan $k = 17$. Kemudian dilakukan prediksi menggunakan model yang telah dipilih. Prediksi dilakukan untuk 12 periode ke depan sesuai jumlah periode pada data *testing*. Hasil prediksi dari setiap model digabungkan menggunakan teknik *ensemble* untuk mendapatkan prediksi akhir. Hasil prediksi model k NN dan *ensemble* k NN dapat dilihat pada Gambar 2.



Gambar 2. Grafik Perbandingan Model k NN dan *Ensemble* k NN (Prediksi Data *testing*)

Grafik pada Gambar 2 menunjukkan bahwa model *ensemble* memberikan prediksi yang cukup baik dengan mendekati nilai aktual pada beberapa periode, seperti pada bulan Januari, Maret, dan Mei. Namun, pada beberapa periode seperti periode bulan Juni dan Juli, prediksi dari model *ensemble* justru lebih rendah dibandingkan dengan nilai aktual. Pada model k NN dengan nilai k yang berbeda, terlihat variasi performa prediksi. Misalnya, pada beberapa periode, seperti periode Januari dan April, model k NN dengan $k=1$ dan $k=5$ memberikan hasil prediksi yang mendekati nilai aktual. Namun, pada periode lainnya, seperti periode Juni dan Juli, nilai prediksi dari model k NN dengan $k=1$ dan $k=5$ justru sangat jauh dari nilai aktual. Sementara itu, model k NN dengan $k=12$ dan $k=17$ cenderung memberikan prediksi yang lebih tinggi daripada nilai aktual pada beberapa periode, terutama pada periode tengah sampai akhir. Namun, nilai prediksinya tampak lebih mendekati nilai aktual dibandingkan dengan model k NN dengan $k=1$ dan $k=5$ pada beberapa periode. Dari hasil prediksi

tersebut dapat dilihat bahwa model *ensemble* dan beberapa model *k*NN memiliki performa yang beragam tergantung pada periode tertentu.. Agar lebih jelas, ketepatan hasil prediksi masing-masing model dapat dilihat menggunakan MAPE (*Mean Absolute Percentage Error*). Hasil perhitungan nilai MAPE untuk setiap model dapat dilihat pada Tabel 7.

Tabel 7. Evaluasi Hasil Model *k*NN dan *Ensemble k*NN

<i>k</i> NN	MAPE (%)	Akurasi
$k = 1$	12.81	Baik
$k = 5$	13.56	Baik
$k = 12$	14.02	Baik
$k = 17$	15.00	Baik
<i>Ensemble</i>	11.11	Baik

Berdasarkan Tabel 7, terlihat bahwa model *ensemble k*NN memberikan MAPE terkecil diantara semua model yaitu sebesar 11.11%. Sementara itu, model *k*NN hanya dapat memberikan nilai MAPE terkecil sebesar 12.81% dengan model $k = 1$. Hal ini membuktikan bahwa penggunaan *ensemble* pada *k*NN dapat meningkatkan akurasi prediksi. Walaupun pada segi akurasi baik model *ensemble k*NN maupun model *k*NN tunggal memberikan akurasi yang baik.

Langkah selanjutnya adalah melakukan optimasi. Pada langkah ini jika hasil prediksi yang dihasilkan dari penggabungan model *k*NN tidak memberikan performa yang baik atau nilai MAPE-nya tidak lebih baik dari penggunaan model *k*NN tunggal (tanpa *ensemble*) maka dapat mencoba berbagai kombinasi model *k*NN yang berbeda atau mengatur nilai k untuk meningkatkan kinerja *ensemble*. Pada penggabungan prediksi beberapa model *k*NN sudah memberikan hasil yang baik, maka tahap optimasi tidak dilakukan.

Selanjutnya, melakukan prediksi harga minyak mentah dunia dari bulan Januari hingga Desember 2023 menggunakan metode *ensemble k*NN dengan nilai k yang terdiri dari $k = 1, k = 5, k = 12$ dan $k = 17$. Hasil prediksi disajikan pada Tabel 8.

Tabel 8. Hasil Prediksi Harga Minyak Mentah Dunia Januari-Desember 2023

Bulan	Harga (USD)
Januari	93.95
Februari	98.66
Maret	97.90
April	92.89
Mei	91.42
Juni	86.76
Juli	84.50
Agustus	83.67
September	86.73
Oktober	88.02
November	88.31
Desember	85.57

Berdasarkan hasil prediksi harga minyak mentah dunia untuk bulan Januari hingga Desember 2023 pada Tabel 8, terlihat tren penurunan yang cukup stabil dalam periode tersebut. Pada awal tahun, harga minyak mentah diperkirakan akan berada di sekitar 93.95 USD per barel. Namun, harga cenderung naik sedikit pada bulan Februari menjadi sekitar 98.66 USD per barel, tetapi kemudian mengalami penurunan lagi pada bulan Maret menjadi sekitar 97.90 USD per barel. Selanjutnya, harga terus menurun hingga mencapai 85.57 USD per barel pada bulan Desember. Tren penurunan ini mungkin dapat disebabkan oleh faktor-faktor seperti permintaan yang kurang stabil, pasokan yang berlimpah, atau faktor-faktor geopolitik yang mempengaruhi pasar minyak dunia.

SIMPULAN

Berdasarkan hasil analisis yang dilakukan diperoleh akurasi metode *ensemble k-nearest neighbor* dalam memprediksi harga minyak mentah dunia adalah sebesar 11.11%. Sedangkan, jika hanya menggunakan model *kNN* tunggal (tanpa *ensemble*) diperoleh MAPE sebesar 12.81%. Adapun prediksi harga minyak mentah dunia periode Januari hingga Desember 2023 menggunakan metode *ensemble k-nearest neighbor*, dapat diamati bahwa pada awal tahun dimulai dengan harga 93.95 USD per barel, namun terjadi sedikit kenaikan pada bulan Februari menjadi sekitar 98.66 USD per barel. Namun, kenaikan tersebut tidak berlangsung lama karena harga kembali turun pada bulan Maret menjadi 97.90 USD per barel. Selanjutnya, harga terus menurun dan berakhir pada 85.57 USD per barel pada bulan Desember. Terdapat tren penurunan yang relatif stabil dalam periode tersebut. Meskipun ada fluktuasi harga, pola umum menunjukkan penurunan.

DAFTAR PUSTAKA

- Ahmad, A. A. (2007). Pengaruh Fluktuasi Harga Minyak Pada Ekspor Minyak Mentah Negara-negara Wilayah OPEC(Periode 1970-2005). *Eko Regional*, Vol 2, No.(1), 44.
- Dalimunthe, Y. K., & Rosyidan, C. (2018). Keterkaitan Harga Minyak Indonesia Dengan Harga Minyak Dunia Melalui Koefisien Korelasi. *PETRO:Jurnal Ilmiah Teknik Perminyakan*, 5(1), 22–27. <https://doi.org/10.25105/petro.v5i1.1980>
- Gustriansyah, R. (2017). Analisis Metode Single Exponential Smoothing Dengan Brown Exponential Smoothing Pada Studi Kasus Memprediksi Kuantiti Penjualan Produk Farmasidi Apotek. *Seminar Nasional Teknologi Informasi Dan Multimedia*, 7–12.
- Jusman, M., Nur'eni, N., & Handayani, L. (2022). Metode Ensemble K-Nearest Neighbor untuk Prediksi Indeks Harga Saham Gabungan (IHSG) di Indonesia. *Jurnal Matematika, Statistika dan Komputasi*, 18(3), 423–433. <https://doi.org/10.20956/j.v18i3.19641>
- Kang, S. (2021). k-Nearest Neighbor Learning with Graph Neural Networks. *Mathematics*, 9(8). <https://doi.org/10.3390/math9080830>

- Leoresta, M. P. A., & Sulasmiyati, S. (2017). Pengaruh Produksi Minyak Opec, Gdp Manufacture Output, Konsumsi Minyak, dan Net Ekspor Manufaktur terhadap Fluktuasi Harga Minyak Opec (Studi pada 5 Negara Manufaktur Terbesar dan Perbandingannya dengan Indonesia Periode 1980-2015). *Jurnal Administrasi Bisnis*, 50(5), 152–161.
- Martínez, F., Charte, F., Frías, M. P., & Martínez-Rodríguez, A. M. (2022). Strategies for Time Series Forecasting with Generalized Regression Neural Networks. *Neurocomputing*, 491, 509–521. <https://doi.org/10.1016/j.neucom.2021.12.028>
- Martínez, F., Frías, M. P., Charte, F., & Rivera, A. J. (2019). Time series forecasting with KNN in R: The tsfknn Package. *R Journal*, 11(2), 229–242. <https://doi.org/10.32614/rj-2019-004>
- OPEC. 2022. OPEC : Brief History. OPEC. Dalam https://www.opec.org/opec_web/en/about_us/24.htm (diakses pada 20 November 2022)
- Sinta, D., Wijayanto, H., & Sartono, B. (2014). Ensemble K-Nearest neighbors method to predict rice price in Indonesia. *Applied Mathematical Sciences*, 8(157–160), 7993–8005. <https://doi.org/10.12988/ams.2014.49721>