

Peramalan Harga Minyak Mentah Dunia Menggunakan Metode *Radial Basis Function Neural Network*

Muhammad Fadil, Meira Parma Dewi

Departemen Matematika, Universitas Negeri Padang

Article Info

Article history:

Received August 19, 2025
Revised January 09, 2025
Accepted January 14, 2025

Keywords:

Crude oil price
Forecasting
RBFNN
MAPE
Artificial Neural Network

Kata Kunci:

Harga minyak mentah
Peramalan
RBFNN
MAPE
Jaringan syaraf tiruan

ABSTRACT

Crude oil prices are a key indicator of global economic stability because they affect the energy, transportation, and fiscal policy sectors. This study applies the Radial Basis Function Neural Network (RBFNN) method to forecast monthly crude oil prices from February 2000 to July 2025 using normalized data. By varying the *center* percentage, the best model configuration was obtained at lags 1, 2, 53, and 54, using 80% training data and 14% *center*. This combination yielded a MAPE value of 6.48% (very good category). The model was then used to predict crude oil prices up to July 2026, showing a relatively stable price trend between USD 53.39 and USD 66.28 per barrel. These results indicate that RBFNN is a highly accurate method for supporting energy policy formulation and economic planning.

ABSTRAK

Harga minyak mentah merupakan indikator utama kestabilan ekonomi global karena mempengaruhi sektor energi, transportasi, dan kebijakan fiskal. Penelitian ini menerapkan metode *Radial Basis Function Neural Network* (RBFNN) untuk meramalkan harga minyak mentah bulanan dari Februari 2000 hingga Juli 2025 menggunakan data yang telah dinormalisasi. Dengan memvariasikan persentase *center*, konfigurasi model terbaik diperoleh pada lag ke-1, 2, 53, dan 54, menggunakan 80% data latih dan 14% *center*. Kombinasi ini menghasilkan nilai MAPE sebesar 6,48% (kategori sangat baik). Model ini kemudian digunakan untuk memprediksi harga minyak mentah hingga Juli 2026, yang menunjukkan tren harga yang relatif stabil antara USD 53,39 hingga USD 66,28 per barel. Hasil menunjukkan bahwa RBFNN merupakan metode yang sangat akurat untuk mendukung perumusan kebijakan energi dan perencanaan ekonomi.

This is an open access article under the [CC BY-SA](#) license.



Penulis Korespondensi:

Muhammad Fadil

Departemen Matematika Universitas Negeri Padang
Email: mf56858@gmail.com

1. PENDAHULUAN

Minyak mentah merupakan salah satu sumber daya alam yang mempunyai peranan strategis dalam perekonomian global. Sebagai bahan baku utama dalam industri energi, minyak mentah digunakan untuk beragam keperluan, seperti bahan bakar, transportasi, pembangkit listrik, dan bahan baku industri petrokimia. Oleh karena itu, fluktuasi harga minyak mentah dapat memberikan dampak yang luas terhadap kestabilan ekonomi, baik di tingkat nasional maupun internasional [1]. Berdasarkan data harga minyak mentah dari tahun 2000 sampai dengan tahun 2025 dari situs investing.com, data

tersebut sangat dipengaruhi oleh berbagai faktor fundamental dan spekulatif. Faktor fundamental meliputi keseimbangan antara permintaan dan penawaran global, kebijakan produksi yang diterapkan oleh negara-negara penghasil minyak seperti anggota Organization of the Petroleum Exporting Countries (OPEC) dan Negara non-OPEC, serta kondisi ekonomi negara-negara konsumen minyak utama seperti Amerika Serikat, Tiongkok, dan Uni Eropa [2]. Di sisi lain, faktor spekulatif seperti ketidakpastian geopolitik, nilai tukar mata uang, dan sentimen pasar juga berkontribusi terhadap volatilitas harga minyak [3].

Peramalan harga minyak sering menggunakan metode statistik seperti regresi linier dan *AutoRegressive Integrated Moving Average* (ARIMA). Namun metode ini cenderung kurang efektif dalam menghadapi pola data yang bersifat non-linear dan dinamis karena banyak faktor global serta fluktuasi yang tidak menentu. Kompleksitas dalam pergerakan harga minyak mentah menjadikan peramalan harga sebagai tantangan yang memerlukan metode analisis yang akurat dan adaptif. Oleh karena itu, penggunaan metode berbasis kecerdasan buatan seperti Jaringan Saraf Tiruan (JST) dapat menjadi alternatif lain dalam meningkatkan akurasi prediksi harga minyak mentah [4].

Jaringan Syaraf Tiruan (JST) merupakan salah satu metode dalam kecerdasan buatan yang terinspirasi dari cara kerja otak manusia dalam memproses informasi. JST mampu mempelajari hubungan kompleks dan non-linear antara variabel input dan output melalui proses pelatihan [5]. Melalui proses pelatihan, JST dapat mempelajari hubungan yang kompleks dan non-linear antara variabel input dan output. Dengan kemampuan ini, JST dapat digunakan untuk berbagai tujuan, seperti pengenalan pola, klasifikasi, dan peramalan [6]. Metode peramalan konvensional sering kali tidak mampu mengidentifikasi pola dinamis dalam peramalan harga minyak mentah global karena banyak faktor global dan fluktuasi yang tidak menentu. Oleh karena itu, metode yang lebih responsif dan pintar diperlukan, dan pendekatan JST adalah salah satunya [3].

Berbagai arsitektur JST tersedia untuk berbagai tujuan dan karakteristik data yang berbeda. Diantaranya yang cukup populer adalah *Radial Basis Function Neural Network* (RBFNN), *General Regression Neural Network* (GRNN), dan *Probabilistic Neural Network* (PNN) [7]. RBFNN digunakan terutama untuk peramalan dan regresi, yaitu memprediksi nilai-nilai numerik berdasarkan pola historis dalam data. Struktur RBFNN terdiri dari tiga lapis, yaitu input layer, hidden layer dengan fungsi aktivasi radial dan output layer [8]. Model ini efektif dalam menangkap pola non-linear karena setiap neuron di hidden layer yang bekerja berdasarkan kedekatan data input terhadap pusatnya, memungkinkan pemodelan lokal yang lebih fleksibel [5].

Metode RBFNN dipilih untuk penelitian ini karena memiliki beberapa keunggulan yang relevan dengan karakteristik data harga minyak mentah. RBFNN juga memiliki struktur yang sederhana dan pelatihan yang cepat, selain memiliki kemampuan untuk menangkap hubungan non-linear yang kompleks [8]. RBFNN dapat secara efektif beradaptasi dengan perubahan pola data berkat kemampuan untuk melakukan pemodelan lokal melalui fungsi basis radial, yang membuatnya responsif terhadap variasi lokal dalam data [9]. Karena lebih stabil dan lebih akurat dalam mengestimasi nilai kontinu, RBFNN lebih cocok untuk tugas peramalan regresi seperti prediksi harga dibandingkan dengan GRNN dan PNN [10]. Dengan mempertimbangkan keuntungan-keuntungannya, RBFNN dianggap sebagai metode yang tepat untuk meramalkan harga minyak mentah dunia berdasarkan data historis. Model ini akan dianalisis untuk mengevaluasi tingkat akurasi serta efektivitasnya dalam menangkap pola perubahan harga minyak.

Dengan adanya hasil penelitian ini, diharapkan dapat memberikan kontribusi dalam pengembangan metode peramalan harga minyak yang lebih akurat serta memberikan wawasan bagi pengambil kebijakan, pelaku industri energi, dan investor dalam menghadapi dinamika pasar minyak global.

2. METODE

Adapun langkah-langkah yang dilakukan dalam penelitian ini adalah :

1. Pengumpulan data, mengumpulkan data harga minyak mentah yang diperoleh dari website investing.com.
2. Pengolahan data, menginput data harga minyak mentah dunia ke dalam sistem dan menentukan lag input.
3. Pembagian data, membagi data menjadi dua set, yaitu data latih dan data uji.

4. Perhitungan jarak Euclidean, menghitung jarak Euclidean untuk menentukan kesamaan antara data latih dan data uji.
5. Perhitungan nilai aktivasi, menghitung nilai aktivasi dari jaringan saraf tiruan yang digunakan dalam model.
6. Perhitungan bobot, menghitung bobot yang diperlukan untuk model RBFNN.
7. Peramalan data, melaksanakan peramalan harga minyak mentah dunia menggunakan model yang telah dibangun.
8. Analisis hasil, menganalisis hasil peramalan dan menarik kesimpulan mengenai akurasi model serta prediksi harga minyak mentah dunia periode selanjutnya.


3. HASIL DAN PEMBAHASAN

Pada penelitian ini variabel yang digunakan yakni harga minyak mentah dunia periode Februari 2000 hingga Juli 2025.

Tabel 1. Harga Bulanan Minyak Mentah Februari 2000 – Juli 2025

No	Tanggal	Harga (USD)
1	02/01/2000	30.43
2	03/01/2000	26.90
3	04/01/2000	25.74
4	05/01/2000	29.01
5	06/01/2000	32.50
⋮	⋮	⋮
304	05/01/2025	60.79
305	06/01/2025	65.11
306	07/01/2025	65.18

Setelah diperoleh data harga minyak mentah seperti yang terlihat pada Tabel 1, data tersebut selanjutnya akan dinormalisasikan menggunakan MinMaxScaler agar nilainya berada antara 0 sampai 1. Tujuan dilakukan normalisasi yaitu untuk mempercepat proses pelatihan dan meningkatkan akurasi dari model RBFNN. Langkah selanjutnya, dataset dibagi menjadi 2 yakni data latih dan data uji. Tujuannya untuk menentukan lag menggunakan Fungsi Autokorelasi Parsial (PACF). Pada proses penentuan lag, langkahnya adalah dengan melakukan pengujian menggunakan software minitab, sehingga diperoleh hasil seperti Gambar 1.



Gambar 1. Plot Partial Autocorrelation Function

Dari Gambar 1 dapat ditentukan bahwa nilai lag yang akan digunakan adalah nilai yang melewati nilai ambang batas pada PACF. Dimana nilai ambang batas ini diperoleh dengan rumus nilai kritis

distribusi normal pada tingkat kepercayaan 95% yaitu 1,96 dibagi dengan jumlah data latih yang digunakan, sehingga diperoleh nilai batas signifikannya adalah $\pm \frac{1,96}{\sqrt{240}} = \pm 0,126$.

Tanda $\pm$ disini digunakan untuk menunjukkan arah korelasi antara lag tertentu pada suatu deret waktu. Dapat dilihat pada Gambar 1 bahwa nilai lag yang melewati $\pm 0,126$ terdapat pada lag 1,2,53, dan 54. Jadi pada penelitian ini akan digunakan 4 lag seperti yang diperoleh dari PACF. Untuk nilai lebih jelas dapat dilihat pada Tabel 2 berikut :

Tabel 2. Nilai PACF untuk Tiap Lag

Lag	PACF	Lag	PACF	Lag	PACF
1	0,970342	22	-0,01804	43	-0,01873
2	-0,21414	23	-0,05688	44	0,041898
3	-0,08225	24	0,082299	45	-0,00133
4	0,000926	25	0,034624	46	0,003901
5	0,015653	26	-0,08696	47	-0,09688
6	0,080818	27	-0,01369	48	0,02749
7	0,073928	28	0,037884	49	-0,03815
8	0,050372	29	-0,04087	50	-0,00524
9	0,006763	30	-0,01188	51	-0,0548
10	0,005501	31	0,059479	52	0,106023
11	-0,02909	32	0,00695	53	-0,12789
12	-0,07641	33	-0,05771	54	0,1423
13	0,055046	34	-0,08216	55	-0,01352
14	0,011251	35	-0,06431	56	0,006386
15	0,061593	36	0,00636	57	-0,00652
16	0,037669	37	0,093114	58	0,01072
17	-0,02612	38	0,029762	59	-0,08113
18	0,01652	39	-0,06052	60	0,0767
19	-0,02402	40	0,001647		
20	0,007846	41	-0,01815		
21	-0,04844	42	-0,12146		

3.1. Pembentukan Model

Pembentukan model dilakukan melalui proses uji coba kombinasi beberapa parameter yaitu nilai lag, rasio data latih dan jumlah *center*. Dalam penelitian ini nilai-nilai yang akan diuji adalah nilai lag yang berjumlah 4 lag, sebagai bentuk representasi dari jumlah data sebelumnya yang digunakan sebagai input. Rasio data latih yang digunakan yaitu 90% dari jumlah data dan persentase jumlah *center* yaitu 10% dari data latih yaitu sebanyak 23 data *center*. Kombinasi parameter ini menghasilkan akurasi MAPE sebesar 4,83% yang akan digunakan sebagai acuan dalam melakukan prediksi pada penelitian ini. Adapun langkah-langkahnya yakni :

3.1.1 Menentukan Jarak Euclidean

Jarak Euclidean digunakan untuk mengukur kedekatan antara setiap data latih dengan titik pusat (*center*) yang diperoleh melalui algoritma KMeans. Nilai jarak ini menjadi dasar dalam menentukan seberapa kuat aktivasi sebuah neuron dalam *hidden layer* terhadap suatu input. Semakin kecil jarak yang diperoleh, maka semakin tinggi nilai aktivasi yang diperoleh. Berikut ditampilkan hasil kalkulasi jarak Euclidean antara input data dengan nilai *center*. Hasil kalkulasi jarak Euclidean antara data latih dan nilai *center* dapat dilihat pada Tabel 2.

Nilai-nilai dalam Tabel 3 diatas menunjukkan jarak antara masing-masing vektor input dan nilai pusatnya. Hal ini mnggambarkan hubungan spasial antar data dalam ruang fitur berdimensi lag.

3.1.2 Perhitungan Nilai Aktivasi

Setelah hasil jarak Euclidean diperoleh, nilai tersebut akan digunakan dalam fungsi basis radial Gaussian untuk memperoleh nilai aktivasi neuron. Nilai aktivasi ini akan digunakan sebagai input pada proses regresi pada output layer. Semakin dekat nilai sebuah input dengan *centernya*, maka nilai

aktivasi Gaussian akan semakin mendekati 1. Nilai dari aktivasi Gaussian diperoleh dengan rumus

$$\varphi_{ik} = e^{-(b_1 * D_{ik})^2} \quad (1)$$

Tabel 3. Jarak Euclidean Antara Data latih dengan Nilai *Center*

<i>Center</i>					
Data Latih	0,609777	0,196186	...	0,508666	0,492489
0,095685	0,775313	0,172204	...	0,672739	0,392884
0,066523	0,766006	0,200990	...	0,667891	0,367883
⋮	⋮	⋮	⋮	⋮	⋮
0,264856	0,249751	0,495074	...	0,169608	0,326283
0,219296	0,305883	0,456790	...	0,26372	0,202026

Dengan D_{ik} adalah nilai yang diperoleh dari jarak euclied yang telah diperoleh sebelumnya, nilai b_1 adalah

$$\frac{d_{max}}{\sqrt{2 \times \text{jumlah center}}} = \frac{1}{\sqrt{2 \times 28}} = \frac{1}{\sqrt{56}} = 0,133630 \quad (2)$$

sehingga dari nilai tersebut diperoleh nilai aktivasi seperti pada Tabel 4.

Tabel 4. Nilai Aktivasi Gaussian

0,000107	0,637188	...	0,001029	0,095755
0,000133	0,354120	...	0,001136	0,127850
⋮	⋮	⋮	⋮	⋮
0,387517	0,024126	...	0,645837	0,198293
0,241230	0,041953	...	0,348011	0,537778

Nilai aktivasi ini akan digunakan membentuk matriks Φ (phi) dalam persamaan linier yang digunakan pada pelatihan model. Matriks ini akan menjadi representasi nonlinier dari data yang telah ditransformasikan melalui fungsi Gaussian.

Tabel 5. Bobot Output

Bobot ke-	Nilai	Bobot ke-	Nilai
1	-0,182853672	13	-0,182853672
2	-0,061970374	14	-0,061970374
3	0,042603351	15	0,042603351
4	-0,009776365	16	0,829921847
5	0,114574038	17	0,487106792
6	0,132059638	18	0,776490095
7	-0,421216059	19	-0,072292326
8	0,010189435	20	0,411338510
9	0,616811575	21	0,228631654
10	-0,078978436	22	-0,140345751
11	0,078978436	23	0,026746484
12	0,115177292		

3.1.3 Perhitungan Bobot

Tahap selanjutnya adalah menghitung bobot antara hidden layer dan output layer. Bobot ini diperoleh melalui solusi persamaan linier menggunakan metode least squares. Nilai bobot ini akan menunjukkan seberapa besar kontribusi masing-masing neuron terhadap output akhir.

Nilai bobot yang diperoleh digunakan dalam fungsi output untuk menghitung hasil prediksi. Bobot positif menunjukkan kontribusi penguatan, sedangkan bobot negatif mengindikasikan kontribusi pelemahan terhadap output jaringan.

Dengan menyelesaikan ketiga tahap perhitungan ini, model RBFNN yang telah terbentuk akan digunakan untuk pengujian dan prediksi harga minyak mentah. Tahapan-tahapan ini menggambarkan bagaimana jaringan belajar dari data historis untuk menghasilkan output prediksi yang akurat.

3.2 Analisis Hasil Prediksi

Berikut ditampilkan nilai hasil prediksi harga bulanan minyak mentah menggunakan model RBFNN untuk periode Agustus 2025 – Juli 2026.

Tabel 6. Prediksi Harga Periode Agustus 2025 – Juli 2026	
Prediksi ke-	Prediksi Harga
1	68,942174
2	72,942919
3	76,937022
4	78,844914
5	78,574691
6	77,387824
7	77,340328
8	74,545785
9	66,120979
10	64,582089
11	61,592847
12	60,935944

Tabel diatas menyajikan hasil prediksi harga bulanan minyak mentah dunia untuk 12 periode ke depan, yaitu mulai dari Agustus 2025 hingga Juli 2026, menggunakan model RBFNN terbaik. Berdasarkan hasil prediksi, harga minyak pada periode pertama diperkirakan sebesar USD 68,94 per barel. Prediksi menunjukkan tren yang cenderung stabil dengan fluktuasi ringan, di mana harga tertinggi diperkirakan terjadi pada periode ke-2 yaitu pada bulan November 2025 sebesar USD 78,84 barel dan harga terendah diperkirakan pada Juli 2026 sebesar USD 60,93 per barel. Nilai-nilai prediksi ini konsisten dengan grafik pada Gambar 4, di mana model tidak hanya menangkap arah tren secara umum, tetapi juga menjaga kestabilan prediksi tanpa menunjukkan perubahan ekstrem. Prediksi yang dihasilkan dapat menjadi acuan awal dalam menyusun strategi kebijakan atau keputusan bisnis yang berkaitan dengan fluktuasi harga energi.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan pada penelitian ini dapat disimpulkan jikalau metode RBFNN akan digunakan untuk memprediksi harga minyak mentah dunia berdasarkan data bulanan dari Februari 2000 hingga Juli 2025. Langkah yang dilakukan dimulai dari menormalisasikan data dan disusun dalam format lag berdasarkan analisis PACF. Model dibangun dengan 4 lag, 90% data latih, dan 10% *center* yang dipilih menggunakan K-Means. Dengan demikian, model ini dapat digunakan memprediksi harga minyak selama Agustus 2025 hingga Juli 2026 dengan hasil prediksi menunjukkan kecenderungan harga yang stabil dengan sedikit fluktuasi, berada di kisaran USD 60,93 hingga USD 78,84 per barel. Akurasi model cukup baik dengan nilai MAPE sebesar 4,83%, serta mampu mengikuti pola perubahan harga secara tepat.

REFERENSI

- [1] Hamilton, J. D. (2007). Cause and Consequence of the Oil Shock 2007 - 08. *Brooking's Papers on Economic Activity*, 225–235.
- [2] Baumeister, C., & Kilian, L. (2016). Understanding the decline in the price of oil since June 2014. *Journal of the Association of Environmental and Resource Economists*, 3(1), 131–158.
- [3] Zhang, Y. J., Fan, Y., Tsai, H. T., & Wei, Y. M. (2008). Spillover effect of US dollar exchange rate on oil prices. *Journal of Policy Modeling*, 30(6), 973–991. <https://doi.org/10.1016/j.jpolmod.2008.02.002>
- [4] Yu, L., Wang, S., & Lai, K. K. (2005). A novel nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign

- exchange rates. *Computers and Operations Research*, 32(10), 2523–2541. <https://doi.org/10.1016/j.cor.2004.06.024>
- [5] Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson Education.
- [6] Dreyfus, G. (2005). *Neural Networks: Methodology and Applications*. Springer.
- [7] Specht, D. F. (1990). Probabilistic neural networks. *Neural Networks*, 3(1), 109–118.
- [8] Broomhead, D. S., & Lowe, D. (1988). Multivariable functional interpolation and adaptive networks. *Complex Systems*, 2(3), 321–355.
- [9] Moody, J., & Darken, C. J. (1989). Fast learning in networks of locally-tuned processing units. *Neural Computation*, 1(2), 281–294
- [10] Park, J., & Sandberg, I. W. (1991). Universal Approximation Using Radial-Basis-Function Networks. *Neural Computation*, 3(2), 246–257. <https://doi.org/10.1162/neco.1991.3.2.246>