

PREDIKSI HARGA KOMODITI PERTANIAN MENGGUNAKAN *ALGORITME LONG SHORT TERM MEMORY* DI DESA KABANDUNGAN SUKABUMI

Anggra Haristu¹⁾, Yeni Herdiyeni²⁾, Marimin³⁾

^{1,2} Fakultas Matematika Dan Ilmu Pengetahuan Alam , Instirut Pertanian Bogor, Bogor

³ Fakultas Teknologi Pertanian, Institut Pertanian Bogor, Bogor

¹anggraharistu@apps.ipb.ac.id, ²yeni.herdiyeni@apps.ipb.ac.id, ³marimin@apps.ipb.ac.id

Abstract

The agricultural sector is very important for national economic development, contributing to GDP, employment, business opportunities, income and foreign exchange. Fluctuations in agricultural commodity prices have a significant impact on farmers and markets, causing uncertainty and risk. Therefore, forecasting future prices is very important, and the Long Short Term Memory (LSTM) method is effective for short-term forecasting. Market price predictions are very important for farmers to maximize profits and for the public sector in planning agricultural development programs. The main objective of this research is to develop a price prediction model for agricultural commodities using the Long Short Term Memory (LSTM) algorithm. The model was created to help farmers, traders and business people make better decisions based on estimates of future agricultural commodity prices. LSTM was chosen because of its ability to model continuous patterns and remember long-term information. This research took place in Kabandungan, Sukabumi Regency, an area with significant agricultural production.

Keywords: *Price Fluctuations, Agricultural Commodities, Long Short-Term Memory, National Development, Price Prediction.*

Abstrak

Sektor pertanian sangat penting bagi perkembangan ekonomi nasional, memberikan kontribusi terhadap PDB, lapangan kerja, peluang bisnis, pendapatan, dan devisa. Fluktuasi harga komoditas pertanian memiliki dampak yang signifikan bagi petani dan pasar, menyebabkan ketidakpastian dan risiko. Oleh karena itu, meramalkan harga di masa depan sangat penting, dan metode Long Short Term Memory (LSTM) efektif untuk ramalan jangka pendek. Prediksi harga pasar sangat penting bagi petani untuk memaksimalkan keuntungan dan bagi sektor publik dalam merencanakan program pengembangan pertanian. Tujuan utama dari penelitian ini adalah untuk mengembangkan sebuah model prediksi harga komoditas pertanian menggunakan algoritme *Long Short Term Memory* (LSTM). Model dibuat untuk membantu petani, pedagang, dan pelaku bisnis dalam mengambil keputusan yang lebih baik berdasarkan perkiraan harga komoditi pertanian di masa depan. LSTM dipilih karena kemampuannya dalam memodelkan pola berkelanjutan dan mengingat informasi jangka panjang. Penelitian ini mengambil lokasi di Kabandungan, Kabupaten Sukabumi, sebuah daerah dengan produksi pertanian yang signifikan.

Kata kunci: Fluktuasi Harga, Komoditas Pertanian, Long Short Term Memory, Pembangunan Nasional, Prediksi Harga.

1. PENDAHULUAN

Pertanian adalah kegiatan usaha yang mencakup budidaya tanaman pangan, hortikultura, perkebunan, peternakan,

perikanan, dan kehutanan. Sebagai sektor penting dalam pembangunan ekonomi nasional, pertanian memberikan kontribusi yang signifikan terhadap Produk Domestik

Bruto (PDB), penyerapan tenaga kerja, penciptaan kesempatan kerja, peningkatan pendapatan masyarakat, dan sumber devisa. Sektor pertanian dianggap strategis karena memiliki kemampuan khusus untuk mendorong pertumbuhan ekonomi yang berkualitas. Selain itu, sektor pertanian memiliki potensi besar dan prospek cerah untuk dikembangkan. Peran baru sektor pertanian dalam menyediakan pangan, pakan, dan energi menjadikannya sektor yang layak menjadi andalan dalam pembangunan nasional (BPS 2020). Selain dinilai strategis, sektor pertanian juga memiliki potensi besar dan prospek yang cerah untuk dikembangkan. Peran baru sektor pertanian dalam menyediakan pangan (food), pakan (feed), dan energi (biofuel) menjadikan sektor pertanian layak dijadikan sektor andalan dalam pembangunan nasional (Daryanto 2012). Kontribusi sektor pertanian terhadap PDB nasional sebesar 13-14% dan penduduk Indonesia masih dominan bekerja di sektor pertanian dengan pangsa pasar tenaga kerja sebesar 24,96% pada tahun 2020 atau 35,00 juta orang dari total angkatan kerja 140,22 juta orang (RENSTRA KEMANTAN 2022)

Sebagai perbandingan, tren pertumbuhan produksi beberapa komoditi seperti beras, jagung, kedelai, gula, dan daging sapi sejak tahun 1975 hingga 2012 masing-masing hanya sebesar 2,54%, 4,94%, 0,59%, 1,42%, dan 2,33%. Sedangkan pertumbuhan impornya pada periode yang sama masing-masing mencapai 1,99%, 13,65%, 7,66%, 8,28%, dan 4,58% (BPS 2013). Dengan kontribusi yang besar terhadap PDB nasional, petani di Indonesia masih dihadapkan dengan fluktuasi harga produk pertanian sehingga pada saat musim panen, petani mengalami kerugian akibat harga jual produk pertanian dibawah harga produksi.

Menurut (Cetin dan Esengun. 2013) Fluktuasi harga merupakan salah satu aspek penting dalam ekonomi pertanian. Dalam kaitannya dengan harga produk pertanian, pengaruh produsen dan biaya, cukup terbatas dibandingkan dengan pengaruhnya di sektor industri. Produsen biasanya harus menerima harga yang ditetapkan karena harga suatu produk pertanian untuk tahun tertentu tidak ditentukan oleh biaya yang dikeluarkan selama

tahun itu, tetapi oleh total penawaran dan permintaan produk selama tahun tersebut (Arisoy dan Bayramoğlu 2017). Beberapa faktor yang mempengaruhi fluktuasi harga diantaranya adalah stok, rantai pasok, permintaan, transportasi, penyimpanan, dan musim. Singh (2011) mengatakan bahwa fluktuasi harga yang tinggi di sektor pertanian merupakan suatu fenomena yang umum akibat ketidakstabilan (*inherent instability*).

Penanganan ketidakstabilan tidak begitu jelas karena persepsi mungkin tidak sama bagi produsen atau konsumen. Misalnya, dari sudut pandang produsen, hanya fluktuasi harga komoditas yang menurun yang dapat dianggap sebagai masalah karena dampaknya pada pendapatan petani. Namun, dari sudut pandang konsumen, fluktuasi harga yang naik mungkin menjadi khawatir karena dampaknya pada pengeluaran makanan mereka. Tentu saja, pergerakan besar ke arah mana pun penting bagi pembuat kebijakan. Dalam makalah ini, kami mempertimbangkan volatilitas pasar secara keseluruhan dalam kedua arah tersebut.

Tujuan utama dari penelitian ini adalah untuk mengembangkan sebuah model prediksi harga komoditas pertanian menggunakan algoritme *Long Short Term Memory* (LSTM). Model dibuat untuk membantu petani, pedagang, dan pelaku bisnis dalam mengambil keputusan yang lebih baik berdasarkan perkiraan harga komoditi pertanian di masa depan. LSTM dipilih karena kemampuannya dalam memodelkan pola berkelanjutan dan mengingat informasi jangka panjang.

2. METODE PENELITIAN

Long Short Term Memory (LSTM) merupakan sebuah arsitektur *Recurrent Neural Network* (RNN) (Ahmed *et al.* 2018) yang memiliki *memory cell*. Dengan *memory cell*, arsitektur LSTM dapat bekerja lebih baik dibanding jaringan saraf rekuren biasa, karena memiliki kemampuan untuk mengingat informasi untuk periode waktu yang lebih lama, sehingga menjadikannya algoritme yang lebih baik untuk prediksi data berjenis *time series* (Prasetyanwar dan J. 2018).

LSTM pertama kali diperkenalkan oleh oleh Hochreiter & Schmidhuber pada tahun 1997. Hingga saat ini penelitian terus dilakukan untuk mengembangkan arsitektur LSTM


dalam berbagai bidang terutama dibidang Speech recognition dan forecasting, karena dengan adanya LSTM masalah ketergantungan waktu jangka panjang dapat diatasi (A. Arfan and E. Lussiana. 2019).

LSTM sebagai model yang efektif dan dapat diskalakan untuk beberapa masalah pembelajaran yang terkait dengan data sekuensial. Metode sebelumnya untuk mengatasi masalah tertentu atau tidak berskala untuk ketergantungan waktu yang lama. LSTM di sisi lain bersifat umum dan efektif dalam dependensi temporal jangka panjang. (Pham *et al.* 2013). LSTM adalah turunan dari (RNN) yang terbukti berhasil digunakan untuk prediksi data time series (Cieh. S. H dan Jhen. R. J 2018). RNN mampu menggunakan informasi yang telah direkam sebelumnya yang panjang urutannya atau *sequence*-nya beragam.

RNN memiliki masalah *vanishing gradient* oleh karena itu, pembangunan sistem ini dibuat dengan metode *Regresi LSTM*. Penggunaan LSTM dengan koreksi kesalahan berdasarkan dukungan *vektor regresi* digunakan untuk mewujudkan prediksi *time series*, karena parameter model LSTM yang terlatih tidak dapat diperbarui (Shuai.C. L, *et al.* 2018). Metode regresi adalah metode statistik matematika yang paling umum digunakan. Mempertimbangkan faktor kesalahan, pendekatan regresi dapat menggambarkan hubungan antar variabel (Jin. T dan Xuanhe. Z 2009).

Secara rinci tahapan pada LSTM adalah sebagai berikut :

a. *Forget Gate*



Gambar 1. *Forget gate*

Pada Gambar 2, gerbang ini memutuskan informasi apa yang harus dibuang atau disimpan. Informasi dari keadaan tersembunyi sebelumnya dan informasi dari masukan saat


ini dilewatkan melalui fungsi sigmoid. Nilai keluar antara 0 dan 1. Semakin dekat ke 0 berarti dilupakan, dan semakin dekat ke 1 berarti disimpan.

$$f_t = (W_f [h_{t-1} * x_t] + b_f) \quad (1)$$

Tabel.1 Fungsi Matematika *Forget gate*

| Rumus | Keterangan |
|-----------|--|
| f_t | = fungsi <i>sigmoid</i> , |
| W_f | = nilai <i>weight</i> untuk <i>forget gate</i> , |
| h_{t-1} | = nilai output sebelum orde ke t , |
| x_t | = nilai input pada orde ke t , |
| b_f | = nilai bias pada <i>forget gate</i> |

b. *Input Gate*



Gambar 2. *Input gate*

Pada Gambar 3 menentukan nilai mana yang akan diperbaharui. Selanjutnya, lapisan tanh membuat vektor nilai baru it , yang dapat ditambahkan ke $cell\ state$. Selanjutnya digabungkan untuk pembaharuan ke $cell\ state$

$$it = \sigma (W_i * [h_{t-1} * x_t] + b_i) \quad (2)$$


Tabel.2 Fungsi Matematika *Input Gate*

| Rumus | Keterangan |
|-----------|---|
| it | = <i>input gate</i> |
| σ | = fungsi <i>sigmoid</i> |
| W_i | = nilai <i>weight</i> untuk <i>input gate</i> |
| h_{t-1} | = nilai <i>output</i> sebelum orde ke t |
| x_t | = nilai input pada orde ke t |
| b_i | = nilai bias pada <i>input gate</i> |

Tabel.3 Fungsi Matematika *Input Gate*

| Rumus | Keterangan |
|------------|--|
| C_t | = nilai baru yang dapat ditambahkan ke <i>cell state</i> |
| σh | = fungsi tan h |
| Wc | = nilai <i>weight</i> untuk <i>cell state</i> |
| $ht - 1$ | = nilai output sebelum orde ke t |
| xt | = nilai input pada orde ke t |
| bc | = nilai bias pada <i>input gate</i> |

c. *cell state*



Gambar 3. *Cell state*


Pada gambar 4, memperbarui *cell state* lama, $C_t - 1$, ke *cell state* baru C_t . Dengan mengalikan keadaan *state* lama dengan ft , Lalu tambahkan it dikalikan dengan C_t . Ini adalah nilai baru, diskalakan berapa banyak untuk perbaharuan setiap *cell state*.

$$C_t = ft * C_t - 1 + it * C_t \quad (4)$$

Tabel.4 Fungsi Matematika *Cell state*

| Rumus | Keterangan |
|-----------|--|
| C_t | = <i>cell state</i> |
| ft | = <i>forget gate</i> |
| $C_t - 1$ | = <i>Cell state</i> sebelum orde ke t |
| it | = <i>input gate</i> |
| C_t | = nilai baru yang dapat ditambahkan ke <i>cell state</i> |

d. *Output Gate*



Gambar 4. *Output gate*

$$C_t = \sigma h (Wc * [ht - 1 * xt] + bc) \quad (3)$$

Menjalankan lapisan *sigmoid* yang menentukan bagian *cell state* mana yang menjadi output. Kemudian, menempatkan *cell state* melalui tanh (untuk mendorong nilai antara -1 dan 1

$$O_t = \sigma (W \circ * [ht - 1 * xt] + b \circ) \quad (5)$$

Tabel.5 Fungsi Matematika *Output gate*

| Rumus | Keterangan |
|-----------|--|
| O_t | = <i>output gate</i> |
| σ | = fungsi <i>sigmoid</i> |
| $W \circ$ | = nilai <i>weight</i> untuk <i>output gate</i> |
| $ht - 1$ | = nilai <i>output</i> sebelum orde ke t |
| xt | = nilai input pada orde ke t |
| $b \circ$ | = nilai bias pada <i>output gate</i> |

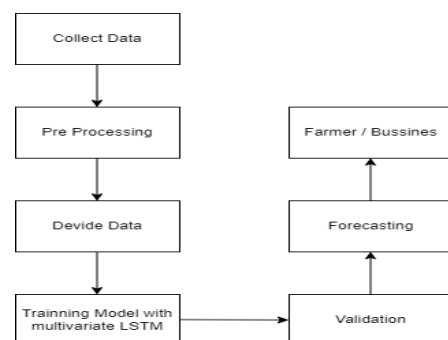
$$ht = \circ t * \sigma h(C_t) \quad (6)$$

Tabel.6 Fungsi Matematika *Output gate*

| Rumus | Keterangan |
|------------|---------------------------------|
| ht | = nilai <i>output</i> |
| $\circ t$ | = Nilai bias <i>output gate</i> |
| σh | = fungsi tanh |
| C_t | = <i>Cell state</i> |

3. HASIL DAN PEMBAHASAN

Tahapan-tahapan yang dilakukan dalam menyelesaikan penelitian ini adalah dimulai dari collect data, berikut tahapan penelitian dapat dilihat pada gambar 5.



Gambar 5. Tahapan Penelitian

3.1 Data Collection

Data yang diolah dalam penelitian ini diunduh dari website harga produk pertanian milik parameter yang diambil adalah nama produk, data harga.

Tabel.7 Data Collection Prediksi Harga

| Nama atribut | Jenis data | Keterangan |
|---------------------------------|----------------------|---|
| Tanggal | Numerik, Datetime | Tanggal terjadinya perkembangan harga Cabai Merah, Bawang Merah dan Bawang Putih di Indonesia |
| Harga Bawang Merah | Time series, Numerik | Harga Komoditas Bawang Merah pada pasar tradisional dalam satuan kilogram |
| Harga Bawang Putih | Time series, Numerik | Harga Komoditas Bawang Putih pada pasar tradisional dalam satuan kilogram |
| Harga Cabai Merah, Upah , Pupuk | Time series, Numerik | Harga Komoditas Bawang Putih pada pasar tradisional dalam satuan kilogram |

3.2 PreProcessing

Data mentah yang didapatkan akan dinormalisasi untuk menghilangkan data missing. Data yang diperoleh pada tahapan pengumpulan data masih berupa data mentah, artinya data tersebut belum bisa diolah.

$$dn = ((n)(Xmax - Xmin) + (Xmin))(7)$$

3.3 Devide Data

Dalam konteks Long Short-Term Memory (LSTM), "divide data" mengacu pada proses membagi dataset menjadi subset yang berbeda untuk pelatihan, validasi, dan pengujian model LSTM. Pada umumnya, dataset dibagi menjadi tiga bagian utama: data pelatihan (training data) dan data pengujian (testing data). Menurut Jauhari (2016) dari hasil pengujian menunjukkan bahwa semakin banyak data latih, maka akan menghasilkan akurasi yang lebih akurat.

a. Data Pelatihan (Training Data)

Data pelatihan digunakan untuk melatih model LSTM. Ini adalah subset data yang digunakan untuk mengoptimalkan parameter dan bobot dalam jaringan LSTM. Model LSTM belajar dari data ini untuk mempelajari pola dan menghasilkan prediksi yang akurat. Umumnya, data pelatihan merupakan bagian terbesar dari dataset, mencakup sebagian besar contoh yang digunakan untuk mengajari model.

Tabel 8. Data Training

| Date | Provinsi | HargaPasar | Pupuk | Upah |
|------------|------------|------------|-------|------|
| 2018-01-02 | Jawa Barat | 10950 | 3285 | 2738 |
| 2018-01-03 | Jawa Barat | 10950 | 3285 | 2738 |
| 2018-01-04 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-05 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-08 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-09 | Jawa Barat | 11100 | 3330 | 2775 |

| | | | | |
|------------|------------|-------|------|------|
| 2018-01-10 | Jawa Barat | 11200 | 3360 | 2800 |
| 2018-01-11 | Jawa Barat | 11400 | 3420 | 2850 |
| 2018-01-12 | Jawa Barat | 11750 | 3525 | 2938 |
| 2018-01-15 | Jawa Barat | 11800 | 3540 | 2950 |
| 2018-01-16 | Jawa Barat | 11800 | 3540 | 2950 |
| 2018-01-17 | Jawa Barat | 11800 | 3540 | 2950 |

b. Data Pengujian (Testing Data)

Data pengujian digunakan untuk menguji kinerja akhir dari model LSTM setelah pelatihan selesai. Ini adalah subset data yang independen dan tidak terlihat oleh model selama pelatihan dan validasi. Data pengujian bertujuan untuk memberikan gambaran obyektif tentang seberapa baik model LSTM dapat melakukan prediksi pada data baru yang tidak pernah dilihat sebelumnya. Hasil pengujian memberikan perkiraan kinerja akhir model dan memungkinkan evaluasi keseluruhan.

Tabel 9. Data Testing

| Date | Provinsi | rgaPasar | Pupuk | Upah |
|------------|------------|----------|-------|------|
| 2018-01-02 | Jawa Barat | 10950 | 3285 | 2738 |
| 2018-01-03 | Jawa Barat | 10950 | 3285 | 2738 |
| 2018-01-04 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-05 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-08 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-09 | Jawa Barat | 11100 | 3330 | 2775 |
| 2018-01-10 | Jawa Barat | 11200 | 3360 | 2800 |
| 2018-01-11 | Jawa Barat | 11400 | 3420 | 2850 |
| 2018-01-12 | Jawa Barat | 11750 | 3525 | 2938 |
| 2018-01-15 | Jawa Barat | 11800 | 3540 | 2950 |

3.4 Training Model dengan LSTM

Melakukan prediksi harga dengan menggunakan metode LSTM, sehingga dihasilkan sebuah prediksi harga yang dapat digunakan untuk menentukan harga jual dari produk pertanian

3.5 Validasi

Untuk mengevaluasi kinerja model prediksi, digunakan beberapa indeks kinerja. Kriteria ini diterapkan pada model yang dikembangkan untuk mengetahui seberapa baik model tersebut bekerja. Kriteria tersebut digunakan untuk membandingkan nilai prediksi dan nilai aktual

4. HASIL DAN PEMBAHASAN

Hasil dan Pembahasan memuat hasil olahan data, yang dibahas dan diarahkan pada penarikan kesimpulan.

4.1 Praproses Data

Sebelum membuat model prediksi harga, dilakukan praproses terhadap data dengan tujuan tidak ada missing value pada data, dan juga dilakukan penyesuaian atribut agar data harga yang akan dijadikan model prediksi bisa diolah menggunakan bahasa pemrograman python. Untuk data yang digunakan dalam penelitian ini adalah:

Tabel 10. Data Penelitian

| Date | Provinsi | Harga Pasar | Pupuk | Upah |
|------------|------------|-------------|-------|------|
| 2018-01-02 | Jawa Barat | 10950 | 3285 | 2738 |
| 2018-01-03 | Jawa Barat | 10950 | 3285 | 2738 |
| 2018-01-04 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-05 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-08 | Jawa Barat | 11050 | 3315 | 2763 |
| 2018-01-09 | Jawa Barat | 11100 | 3330 | 2775 |
| 2018-01-10 | Jawa Barat | 11200 | 3360 | 2800 |
| 2018-01-11 | Jawa Barat | 11400 | 3420 | 2850 |

| | | | | |
|------------|------------|-------|------|------|
| 2018-01-12 | Jawa Barat | 11750 | 3525 | 2938 |
| 2018-01-15 | Jawa Barat | 11800 | 3540 | 2950 |
| 2018-01-16 | Jawa Barat | 11800 | 3540 | 2950 |
| 2018-01-17 | Jawa Barat | 11800 | 3540 | 2950 |

| Date | Provinsi | Harga Pasar | Pupuk | Upah | x_Harga Pasar | x_Pupuk | x_Upah |
|------------|------------|-------------|-------|------|---------------|---------|--------|
| 2018-01-02 | Jawa Barat | 10950 | 3285 | 2738 | 0.027 | 0.027 | 0.027 |
| 2018-01-03 | Jawa Barat | 10950 | 3285 | 2738 | 0.028 | 0.028 | 0.028 |
| 2018-01-04 | Jawa Barat | 11050 | 3315 | 2763 | 0.032 | 0.032 | 0.032 |
| 2018-01-05 | Jawa Barat | 11050 | 3315 | 2763 | 0.032 | 0.032 | 0.032 |
| 2018-01-08 | Jawa Barat | 11050 | 3315 | 2763 | 0.033 | 0.033 | 0.033 |
| 2018-01-09 | Jawa Barat | 11100 | 3330 | 2775 | 0.033 | 0.033 | 0.033 |
| 2018-01-10 | Jawa Barat | 11200 | 3360 | 2800 | 0.033 | 0.033 | 0.033 |

4.2 Penanganan data yang hilang (missing value)

Missing value merupakan kondisi dimana terdapat data yang hilang atau informasi yang tidak dapat ditemukan pada atribut tertentu di dalam dataset. Missing value dapat terjadi karena nilai tersebut tidak relevan dengan kasus tertentu, tidak dapat direkam pada saat pengumpulan data, dan disebabkan adanya privasi atau perlindungan data (Gimpy et al. 2014). Karena pada saat praposes data sudah dilakukan check missing value, maka cukup dilakukan dengan code dari python berupa:

```
print(data.isnull().sum())
```

Gambar 3 Function check missing value

Tabel 11. Hasil check missing value

| | |
|------------|-------|
| Date | 0 |
| Provinsi | 0 |
| HargaPasar | 0 |
| Pupuk | 0 |
| Upah | 0 |
| dtype: | int64 |

4.3 Eksplorasi Data

Eksplorasi data dilakukan untuk melihat gambaran dan mengidentifikasi

karakteristik data yang disajikan dalam periode harian sebanyak 7411 data pengamatan. Gambaran karakteristik data dilihat melalui statistik deskriptif dari setiap atribut yang digunakan di dalam dataset. Apabila penyebaran data sangat besar terhadap nilai rata-rata maka nilai simpangan baku akan besar, akan tetapi apabila penyebaran data sangat kecil terhadap nilai rata-rata maka nilai simpangan baku akan kecil (Yusniyanti dan Kurniati 2017)

Tabel 12. Eksplorasi Data

| | HargaPasar | Pupuk | Upah |
|-------|--------------|--------------|--------------|
| count | 7411.000000 | 7411.000000 | 7411.000000 |
| mean | 20098.839563 | 6029.651869 | 5024.968560 |
| std | 12297.836095 | 3689.350828 | 3074.462338 |
| min | 9550.000000 | 2865.000000 | 2388.000000 |
| 25% | 11150.000000 | 3345.000000 | 2788.000000 |
| 50% | 12450.000000 | 3735.000000 | 3113.000000 |
| 75% | 28250.000000 | 8475.000000 | 7063.000000 |
| max | 87500.000000 | 26250.000000 | 21875.000000 |

4.4 Training Model dengan LSTM

Melakukan prediksi harga dengan menggunakan metode LSTM, sehingga dihasilkan sebuah prediksi harga yang dapat digunakan untuk menentukan harga jual dari produk pertanian

```
# Build the LSTM model
model = Sequential()
model.add(LSTM(50,
return_sequences=True,
input_shape=(window_size,
1)))

model.add(LSTM(50))
model.add(Dense(1))
model.compile(loss='mean
_squared_error',
optimizer='adam')

# Train the model
model.fit(train_X,
train_Y, epochs=100,
batch_size=16, verbose=2)

# Make predictions on
the test data
test_predictions =
model.predict(test_X)
test_predictions =
```

```

scaler.inverse_transform(test_predictions)

# Calculate RMSE
rmse =
np.sqrt(np.mean((test_predictions -
scaler.inverse_transform(test_Y.reshape(-1, 1)))*2))
print("RMSE:", rmse)
print("-----")

```

Gambar 10. Function LSTM

Membangun model LSTM dengan uraian function:

1. Membuat objek model menggunakan Sequential dari library Keras.
2. Menambahkan layer LSTM pertama dengan 50 unit LSTM, return_sequences=True digunakan karena kita akan memiliki layer LSTM berikutnya.
3. Menambahkan layer LSTM kedua juga dengan 50 unit LSTM.
4. Menambahkan layer Dense dengan 1 unit untuk output.
5. Mengompilasi model dengan menggunakan fungsi loss mean_squared_error (MSE) sebagai fungsi loss dan optimizer 'adam' untuk proses pelatihan.

Dari function diatas, hasil prediksi akan mendapatkan nilai RMSE dengan rincian sebagai berikut :

Tabel 13. Nilai RMSE dari data yang diprediksi

| No | Provinsi | Nilai RMSE |
|----|---------------|------------|
| 1 | Banten | 291.69 |
| 2 | DI Yogyakarta | 80.62 |
| 3 | Jawa Barat | 317.79 |
| 4 | DKI Jakarta | 367.32 |
| 5 | Jawa Tengah | 475.90 |
| 6 | Jawa Timur | 118.42 |

RMSE merupakan pengukuran dengan menghitung perbedaan nilai dari prediksi sebuah model sebagai estimasi nilai observasi.

RMSE menghasilkan akar kuadrat Mean Square Error. Estimasi keakuratan model ditandai dengan nilai RMSE yang kecil. Sehingga semakin kecil nilai RMSE maka semakin akurat model yang didapatkan. Dalam menghitung RMSE, nilai actual dan peramalan dikuadrakan dan dijumlahkan keseluruhan hasil. Kemudian dibagi dengan banyaknya data, dan dihitung Kembali nilai dari akadr kuadratnya (T. Chai and R. R. Draxler.2014)

4.4 Validasi

Untuk mengevaluasi kinerja model prediksi, digunakan beberapa indeks kinerja Kriteria ini diterapkan pada model yang dikembangkan untuk mengetahui seberapa baik model tersebut bekerja. Kriteria tersebut digunakan untuk membandingkan nilai prediksi dan nilai aktual.

Tabel 14. Perbandingan Nilai Prediksi

| Tanggal | Provinsi | Prediksi HargaPasar | Harga Aktual | RMSE |
|------------|------------|---------------------|--------------|--------|
| 2022-01-11 | Jawa Barat | 11849 | 11300 | 35,438 |
| 2022-01-12 | Jawa Barat | 11849 | 11300 | 35,438 |
| 2022-01-13 | Jawa Barat | 11848 | 11300 | 35,373 |
| 2022-01-14 | Jawa Barat | 11848 | 11300 | 35,373 |
| 2022-01-17 | Jawa Barat | 11848 | 11300 | 35,373 |
| 2022-01-18 | Jawa Barat | 11848 | 11300 | 35,373 |
| 2022-01-19 | Jawa Barat | 11848 | 11300 | 35,373 |
| 2022-01-20 | Jawa Barat | 11848 | 11350 | 32,146 |
| 2022-01-21 | Jawa Barat | 11885 | 11350 | 34,534 |
| 2022-01-24 | Jawa Barat | 11897 | 11350 | 35,309 |
| 2022-01-25 | Jawa Barat | 11899 | 11350 | 35,438 |
| 2022-01-26 | Jawa Barat | 11899 | 11350 | 35,438 |
| 2022-01-27 | Jawa Barat | 11899 | 11850 | 3,163 |
| 2022-01-28 | Jawa Barat | 12272 | 11350 | 59,515 |
| 2022-01-31 | Jawa Barat | 12011 | 11350 | 42,667 |

| Tanggal | Provinsi | Prediksi HargaPasar | Harga Aktual | RMSE |
|------------|-------------|---------------------|--------------|--------|
| 2022-01-13 | DKI Jakarta | 13292 | 13550 | 16,724 |
| 2022-01-14 | DKI Jakarta | 13309 | 13550 | 15,622 |
| 2022-01-17 | DKI Jakarta | 13302 | 13550 | 16,075 |

| | | | | |
|------------|----------------|-------|-------|--------|
| 2022-01-18 | DKI Jakarta | 13297 | 13550 | 16,400 |
| 2022-01-19 | DKI Jakarta | 13294 | 13550 | 16,594 |
| 2022-01-20 | DKI Jakarta | 13298 | 13550 | 16,335 |
| 2022-01-21 | DKI Jakarta | 13298 | 13550 | 16,335 |
| 2022-01-24 | DKI Jakarta | 13298 | 13550 | 16,335 |
| 2022-01-25 | DKI Jakarta | 13298 | 13550 | 16,335 |
| 2022-01-26 | DKI Jakarta | 13298 | 13550 | 16,335 |
| 2022-01-27 | DKI Jakarta | 13298 | 13550 | 16,335 |
| 2022-01-28 | DKI Jakarta | 13298 | 13550 | 16,335 |
| 2022-01-31 | DKI Jakarta | 13298 | 13550 | 16,335 |

mungkin perlu ditingkatkan lebih lanjut.

4.5 Forecasting

Untuk membantu petani atau pun pebisnis dalam melakukan keputusan dalam melakukan penjualan atau pun pembelian komoditas pertanian, maka dalam penelitian ini membandingkan harga komoditas pertanian dengan provinsi terdekat, sehingga dapat memberikan keuntungan maksimal bagi petani maupun pebisnis

Pada perbandingan 2 hasil prediksi ini, terdapat selisih hasil prediksi harga dengan harga actual pada rentang Rp.200 hingga Rp.500 yang akan digunakan oleh para petani dan pebisnis untuk menentukan bagaimana keputusan mereka untuk menjual hasil pertanian mereka, dan dari hasil pengujian RSME (*Root Mean Squared Error*) perlu diperhatikan beberapa hal, yaitu :

1. Jika RMSE relatif kecil, berarti nilai prediksi model mendekati nilai aktual dengan baik. Model prediksi dianggap memiliki akurasi yang baik dalam memperkirakan nilai data.
2. Jika RMSE relatif besar, berarti nilai prediksi model memiliki selisih yang signifikan dengan nilai aktual. Model prediksi mungkin perlu ditingkatkan atau lebih disesuaikan dengan data yang ada.
3. Perbandingan dengan Skala Data Asli: Penting untuk memperhatikan skala data asli untuk menginterpretasikan RMSE. Jika RMSE yang relatif kecil dalam skala data asli (misalnya, RMSE = 5 untuk data dengan rentang 0-100), ini menunjukkan prediksi yang baik. Namun, jika RMSE yang relatif kecil dalam skala data yang lebih besar (misalnya, RMSE = 50.000 untuk data dengan rentang 0-100), maka model

Tabel 15. Hasil Prediksi Harga Wilayah Jawa Barat

| Tanggal | Provinsi | Prediksi HargaPasar |
|------------|------------|---------------------|
| 2022-12-01 | Jawa Barat | 12148 |
| 2022-12-02 | Jawa Barat | 12150 |
| 2022-12-05 | Jawa Barat | 12150 |
| 2022-12-06 | Jawa Barat | 12149 |
| 2022-12-07 | Jawa Barat | 12187 |
| 2022-12-08 | Jawa Barat | 12235 |
| 2022-12-09 | Jawa Barat | 12249 |
| 2022-12-12 | Jawa Barat | 12288 |
| 2022-12-13 | Jawa Barat | 12299 |
| 2022-12-14 | Jawa Barat | 12301 |
| 2022-12-15 | Jawa Barat | 12300 |
| 2022-12-16 | Jawa Barat | 12300 |

Tabel 16. Hasil Prediksi Harga Wilayah DKI Jakarta

| Tanggal | Provinsi | Prediksi HargaPasar |
|------------|-------------|---------------------|
| 2022-12-01 | DKI Jakarta | 13581 |
| 2022-12-02 | DKI Jakarta | 13620 |
| 2022-12-05 | DKI Jakarta | 13668 |
| 2022-12-06 | DKI Jakarta | 13677 |

| | | |
|------------|-------------|-------|
| 2022-12-07 | DKI Jakarta | 13676 |
| 2022-12-08 | DKI Jakarta | 13676 |
| 2022-12-09 | DKI Jakarta | 13715 |
| 2022-12-12 | DKI Jakarta | 13723 |
| 2022-12-13 | DKI Jakarta | 13724 |
| 2022-12-14 | DKI Jakarta | 13723 |
| 2022-12-15 | DKI Jakarta | 13723 |
| 2022-12-16 | DKI Jakarta | 13762 |



Gambar 6. Grafik Prediksi Harga DKI Jakarta



Gambar 7. Grafik Prediksi Harga Jawa Barat

5. SIMPULAN DAN SARAN

Dalam prediksi harga menggunakan LSTM, dapat disimpulkan bahwa:

1. LSTM merupakan salah satu metode yang cukup efektif dalam memprediksi harga.
2. Proses persiapan data yang baik sangat penting dalam menjalankan algoritma LSTM.

3. Parameter seperti jumlah time steps, jumlah neurons, dan jumlah epoch mempengaruhi performa model.
4. Data historis merupakan faktor utama dalam memprediksi harga, namun faktor lain seperti situasi ekonomi dan politik juga dapat mempengaruhi harga.
5. Hasil prediksi perlu dievaluasi menggunakan metrik evaluasi seperti RMSE untuk mengetahui akurasi prediksi.
6. Validasi hasil menggunakan RMSE perlu diperhatikan :

1. RMSE Kecil: Jika RMSE relatif kecil, berarti nilai prediksi model mendekati nilai aktual dengan baik. Model prediksi dianggap memiliki akurasi yang baik dalam memperkirakan nilai data.

2. RMSE Besar: Jika RMSE relatif besar, berarti nilai prediksi model memiliki selisih yang signifikan dengan nilai aktual. Model prediksi mungkin perlu ditingkatkan atau lebih disesuaikan dengan data yang ada.

3. Perbandingan dengan Skala Data Asli: Penting untuk memperhatikan skala data asli untuk menginterpretasikan RMSE. Jika RMSE yang relatif kecil dalam skala data asli (misalnya, RMSE = 5 untuk data dengan rentang 0-100), ini menunjukkan prediksi yang baik. Namun, jika RMSE yang relatif kecil dalam skala data yang lebih besar (misalnya, RMSE = 50.000 untuk data dengan rentang 0-100), maka model mungkin perlu ditingkatkan lebih lanjut.

7. Visualisasi hasil prediksi dalam bentuk grafik dan tabel dapat membantu dalam menganalisis data dan menentukan keputusan bisnis yang lebih baik

Beberapa saran untuk penelitian prediksi harga menggunakan LSTM adalah:

1. 1 Gunakan sumber data yang terpercaya dan lengkap dengan rentang waktu yang memadai. Data yang kurang lengkap atau tidak terpercaya dapat mempengaruhi akurasi prediksi.
2. Selain harga, pertimbangkan juga variabel lain seperti cuaca, stok, atau faktor ekonomi lain yang dapat mempengaruhi harga. Dalam penelitian yang lebih kompleks, menggunakan lebih dari satu variabel dapat meningkatkan akurasi prediksi.
3. Lakukan analisis dan pemrosesan data yang cermat. Pastikan data telah dinormalisasi, dan lakukan deteksi outlier atau data yang tidak masuk akal. Analisis data juga dapat membantu dalam menentukan rentang waktu yang optimal untuk prediksi.
4. Perhatikan arsitektur model LSTM yang digunakan. Ada berbagai variasi arsitektur LSTM, dan masing-masing memiliki kelebihan dan kelemahan. Pilih arsitektur yang paling sesuai dengan data dan tujuan penelitian.
5. Lakukan evaluasi dan optimasi model secara berkala. Evaluasi dan optimasi dapat dilakukan dengan mengukur nilai RMSE, MAE, atau metric lain yang relevan. Optimasi dapat dilakukan dengan mencoba variasi arsitektur model, parameter, atau teknik lain seperti dropout atau early stopping.
6. Gunakan hasil prediksi secara hati-hati dan bijaksana. Prediksi harga tidak selalu akurat dan dapat dipengaruhi oleh berbagai faktor yang sulit diprediksi. Pastikan hasil prediksi digunakan dengan hati-hati dalam pengambilan keputusan bisnis atau investasi.
7. Pada penelitian ini masih banyak keterbatasan, karena belum

menyertakan faktor – faktor eksternal seperti curah hujan, temperatur udara, kecepatan angin, dan faktor alam lainnya. Sehingga nantinya bisa tercipta suatu sistem yang disebut “*Smart Agriculture*” yang sangat membantu petani dan pebisnis untuk terjun langsung dalam berniaga dibidang pertanian ini.

8. Untuk penelitian kedepan penulis mengharapkan peran serta pemerintah khususnya Kementerian Pertanian dalam menyajikan ketersediaan data harga untuk komoditas pertanian yang lebih luas. Hal ini berkaca pada ketersediaan data saham IDX (Indonesia Stock Exchange) dengan *datafeed realtime* bisa membantu kegiatan pebisnis dalam melakukan jual beli saham

6. UCAPAN TERIMAKASIH

Puji serta syukur penulis haturkan kehadiran Allah SWT berkat rahmat dan hidayah-Nya saya dapat menyelesaikan penelitian ini. Saya ucapkan terima kasih kepada mentor sekaligus rekan kerja pada PT. Yuanta Sekuritas yaitu Bapak Ganes Darmawan dan Bapak Martin Tobing atas masukan dan saran dalam pengerjaan penelitian ini

7. DAFTAR PUSTAKA

- [BPS] Badan Pusat Statistik Kabupaten Sukabumi.2018.Kecamatan Kabandungan dalam Angka.
- [BPS] Badan Pusat Statistik.2020. Indikator Pertanian 2020. Katalog: 5102001
- [KEMENTAN] RENCANA STRATEGIS Kementerian Pertanian 2020 – 2024
- A. Arfan and E. Lussiana, “Prediksi Harga Saham Di Indonesia Menggunakan Algoritma Long Short-Term Memory,” vol. 3, 2019.
- Ahmed W, Mehrdad B. 2018. "The accuracy of the lstm model for predicting the s&p 500 index and the difference between prediction and backtesting".

- Arısoy H, Bayramoğlu.2017. Determination of the Effect of Price Fluctuations on Producer Income the Case of Potatoes. *Turkish Journal of Agriculture - Food Science and Technology*, 5(11): 1342-1349
- Cetin I dan Esengün K.2013. Amasya İlinde Yaygın Olarak Yetistirilen Urunlerde Verim ve Fiyat Riski. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi* 15 (25): 57-65.
- Cieh S. H dan Jhen. R. J.2018.“Remaining useful life estimation using long short-term memory deep learning,” *Proc. 4th IEEE Int. Conf. Appl. Syst. Innov. 2018, ICASI 2018*, pp. 58–61.
- Daryanto, A.2018. Memposisikan Secara Tepat Pembangunan Pertanian dalam Perspektif Pembangunan Nasional. IPB Press.
- Gimpy et al. 2014. Missing Value Imputation in Multi Attribute Data Set
- Hochreiter, S. dan Schmidhuber.1997. LONG SHORT-TERM MEMORY Neural Computation 9(8).
- Jauhari D, Himawan A, Dewi C. 2016. Prediksi Distribusi Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation di PDAM Kota Malang. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*. 3(2): 83-87
- Pham, dan Christopher D.2013. "Effective approaches to attention-based neural machine translation." *arXiv preprint arXiv:1508.04025*.
- Prasetyanwar H dan J.2018. "Peramalan Nilai Tukar IDR-USD Menggunakan Long Short Term Memory," *e-Proceeding of Engineering : Vol.5, No.2 Agustus 2018* , vol. 5, p. 3820.
- Shuai.C.L, H. Fang,B. Shi.2018.“Multi-StepAhead Prediction with Long Short Term Memory Networks and Support Vector Regression,” *Chinese Control Conf. CCC*.
- T. Chai and R. R. Draxler, “Root mean square error (RMSE) or mean absolute error (MAE),” *Geosci. Model Dev.*, vol. 7, no. 3, pp. 1247–1250, 2014, doi: 10.5194/gmd-7-1247-2014.
- Yusniyanti dan Kurniati .2017. Analisa Puncak Banjir Dengan Metode MAF (Studi Kasus Sungai Krueng Keureuto) *JURNAL EINSTEIN Jurnal Hasil Penelitian Bidang Fisika*