

Algoritme *Machine Learning Multi-Layer Perceptron* dan *Recurrent Neural Network* untuk Prediksi Harga Cabai Merah Besar di Kota Tangerang

Kahfi Heryandi Suradiradja¹

¹Fakultas Teknik Program Studi Teknik Informatika, Universitas Pamulang, Indonesia

Article Info

Article history:

Received August 9, 2021

Revised Oct 21, 2021

Accepted Oct 22, 2021

Keywords:

Machine Learning

Regression

Multilayer Perceptron

Recurrent Neural Network

harga cabai

ABSTRACT

Chilli consumption keeps increasing along with the annual population increase in Indonesia. Meanwhile, chilli prices also fluctuate due to rainfall, affecting production and inflation. In the industrial era 4.0, IT support is crucial in various fields including in agriculture such as chilli planting to help stakeholders, both in the economy and agriculture sectors, make decisions based on accurate predictive data support. The study aims to compare the accuracy of two machine learning algorithm models, i.e., Multi-Layer Perceptron (MLP) and Recurrent Neural Network (RNN), for time-series regression implementable to predict chilli prices in Tangerang City. The experimental method stages include business understanding, data understanding, data preparation, modelling, evaluation, and deployment stages. The required dataset attributes include red chilli prices, date, inflation, and rainfall. This research is expected to contribute to machine learning algorithms to assist stakeholders and to be implemented by information system developers. The research result indicates that the MLP algorithm with the rmsprop optimizer performs better than the RNN with the metric measurement of Loss = 0.0038, MSE = 10271959,0 and MAPE = 3.79%. Suggestions for further research include the urgency to innovate architectural models, either for activation functions, optimizers, or other regression algorithms for better metric measurement results.

Copyright © 2021 Universitas Indraprasta PGRI.

All rights reserved.

Corresponding Author:

Kahfi Heryandi Suradiradja,

Fakultas Teknik Program Studi Teknik Informatika,

Universitas Pamulang,

Jl. Raya Puspipetek, Buaran, Kec. Pamulang, Kota Tangerang Selatan, Banten

Email: dosen01514@unpam.ac.id

1. PENDAHULUAN

Di era industri 4.0 dukungan teknologi informasi menjadi pendukung penting dalam berbagai bidang, salah satunya di bidang pertanian seperti cabai. Cabai tidak hanya berfungsi sebagai bahan pangan saja tetapi merupakan juga bahan baku industri saat ini. Kebutuhan cabai per kapita di Indonesia sangat fluktuatif dari tahun ke tahun. Jumlah konsumsi cabai terus mengalami peningkatan seiring dengan pertambahan jumlah penduduk Indonesia setiap tahunnya. Konsumsi cabai per kapita cenderung meningkat dari 1,35 kg pada tahun 2003 menjadi 1,47 kg pada tahun 2007. Tahun 2008 pasokan per hari ke industri tersebut mencapai 70 ton cabai besar merah, 15 ton cabai keriting dan 10 ton cabai rawit. Sebagai kebutuhan bahan baku industri maka

hal tersebut mendorong meningkatnya minat petani untuk menanam cabai [1, p. 7]. Demikian juga di Kota Tangerang, peningkatan produksi cabai dapat dilihat pada Tabel 1.

Tabel 1 Pertumbuhan produksi cabai di Kota Tangerang

Jenis	Tahun (Kwintal)		Kenaikan (%)
	2018	2019	
Cabai Besar	22	112	554,55

Sumber: Diolah dari Badan Pusat Statistik

Disisi lain fluktuasi harga cabai merah naik dikarenakan permintaan pasar meningkat. Seperti data dari statistik harga cabai rata-rata besar pada Tabel 2 yang menampilkan fluktuasi harga rata-rata cabai besar atau cabai merah di Kota Tangerang. Berdasarkan uraian diatas, yang menjadi permasalahan adalah diperlukan sebuah pilihan model algoritme guna membantu memberikan prediksi jumlah produksi cabai merah, hal ini dibutuhkan untuk mendukung para pengambil keputusan baik dibidang ekonomi maupun pertanian membutuhkan dukungan sistem yang dapat memprediksi dari fluktuasi harga tersebut yakni dengan teknologi *machine learning*.

Tabel 2 Fluktuasi harga cabai di Kota Tangerang

	Tahun (Rp/Kg)		
	2018	2019	2020
Kota Tangerang	63.604	76.208	100.375
% Kenaikan		19,82	31,71

Sumber: Diolah dari Pusat Informasi Harga Pangan Strategis Nasional

1.1. Machine learning

Machine learning merupakan bagian dari *data mining* yang istilahnya lebih populer yakni menggali pengetahuan dalam *datawarehouse*, Gartner Group dalam [2, p. 2] menyebutkan " *Data mining* adalah proses menemukan korelasi baru yang bermakna, pola dan tren dengan memilah-milah data besar yang tersimpan dalam repositori, menggunakan teknologi pengenalan pola serta teknik-teknik statistik dan matematika." Berdasarkan [2, p. 11], kegiatan - kegiatan dalam data mining dikategorikan:

- Deskripsi (*Description*)
- Estimasi (*Estimation*)
- Prediksi (*Prediction*)
- Klasifikasi (*Classification*)
- Pengelompokan (*Clustering*)
- Asosiasi (*Association*).

Kategori prediksi (*Prediction*) mirip dengan klasifikasi dan estimasi, namun untuk prediksi, nilai hasil akan ada di masa depan. Metode dan Teknik yang digunakan untuk klasifikasi dan estimasi dapat juga digunakan untuk prediksi, termasuk metode statistik tradisional, regresi linear dan regresi berganda, serta data mining dan metode penemuan pengetahuan seperti neural network, *Decision Tree*, K-Nearest Neighbors. Contoh prediksi dalam bisnis dan penelitian yaitu prediksi harga saham tiga bulan ke depan, prediksi persentase kenaikan kematian lalu lintas tahun depan jika batas kecepatan meningkat atau memprediksi pemenang seri baseball musim gugur tahun ini, berdasarkan perbandingan statistik tim. Berdasarkan kategori *machine learning task* terbagi menjadi:

a. Supervised Learning

Data sudah memiliki contoh masukan dan keluaran yang menjadi target. Beberapa kasus, masukan hanya sebagian tersedia dengan beberapa keluaran tanpa target atau diberikan hanya sebagai umpan balik untuk tindak lanjut dalam lingkungan yang dinamis (*reinforcement learning*). Dalam *supervised*, keahlian yang diperoleh (*trained model*) digunakan untuk memprediksi keluaran (label) untuk data pengujian.

b. Unsupervised learning

Tidak ada perbedaan antara *training set* dan *test set* dengan data yang tidak berlabel atau target. Pemrosesan data masukan bertujuan menemukan pola yang tersembunyi

Salah satu model *supervised* algoritme adalah Artificial Neural Networks atau Jaringan saraf tiruan yang biasanya digunakan untuk masalah *time series* atau *regression* dan *classification*. Model algoritma ini terinspirasi oleh fungsi otak manusia, meniru fungsi kompleks seperti pembentukan pola, kognisi, pembelajaran, dan pengambilan keputusan [3]. Otak manusia terdiri dari milyaran neuron yang saling berkomunikasi dan memproses informasi yang diberikan. Demikian pula dalam ANN sebagai model sederhana

dari struktur jaringan saraf tiruan, terdiri dari unit pemrosesan yang saling berhubungan yang diatur dalam topologi tertentu. Sejumlah node disusun dalam beberapa layer:

- Layer input sebagai tempat data dimasukkan ke dalam sistem,
- Satu atau lebih *hidden layer* sebagai tempat pembelajaran berlangsung, dan
- Layer output di mana keputusan / prediksi dikeluarkan.

ANN dikembangkan lagi menjadi beberapa algoritme yang sering kita dengar yakni istilah *deep learning* yakni dengan beberapa lapisan tersembunyi (*hidden layer*) antara lapisan masukan (*input layer*) dan keluaran (*output layer*) dan berupa *supervised*, *reinforcement* dan *unsupervised*. Kebanyakan model deep learning yang meniru struktur dasar sistem saraf manusia [4]. Beberapa contoh model-model algoritma dalam deep learning adalah:

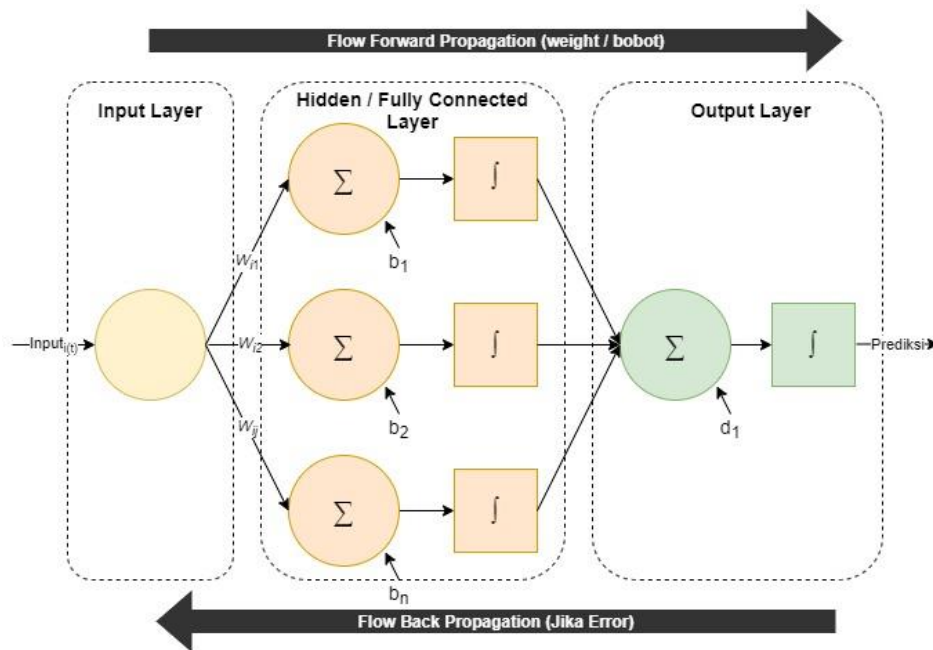
- Single Layer Perceptron*
- Multi-Layer Perceptron*
- Recurrent Neural Network*
- Convolutional Neural Network*

Dalam algoritme Deep Learning neural network digunakan metode optimizer, yaitu teknik pencarian yang digunakan untuk memperbarui bobot dalam model pengembangan ANN yang dibuat. Beberapa yang sering digunakan metode optimasi ini yaitu:

- SGD: *stochastic gradient descent*, yang support untuk momentum.
- RMSprop: *adaptive learning rate optimization method* yang di ajukan oleh Geoff Hinton.
- Adam: Adaptive Moment Estimation (Adam) yang juga metode ini menggunakan *adaptive learning rates*.

1.2. Multi-Layer Perceptron (MLP)

Multilayer merupakan arsitektur dengan bentuk penggabungan beberapa layer dan neuron tiap layer dalam *layer perceptron*.

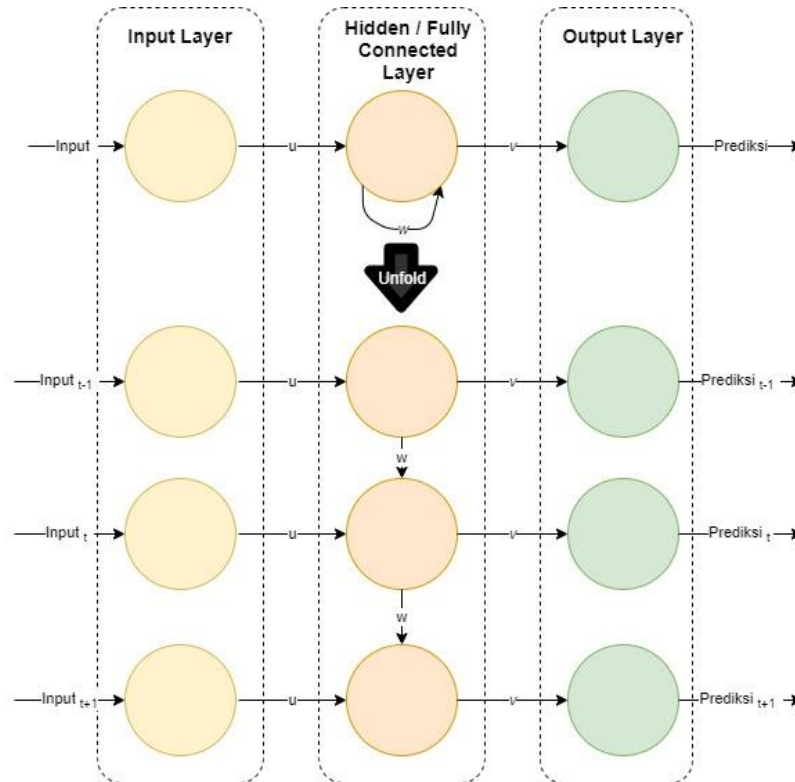


Gambar 1 Multilayer Perceptron (MLP)

Multilayer Perceptron (MLP) merupakan arsitektur yang banyak digunakan untuk *neural network*. Karena target nilai *real* dalam set pelatihan diketahui. Pada Gambar 1 ditunjukkan proses kerja utama dari mulai input dari suatu waktu ($i(t)$) ke hidden layer dan sampai output layer. Kegiatan itu yang menurut [5] dinamakan *feed forward*. Sedangkan proses *backtracking* yakni melakukan alur kembali dari *output* menuju *input*, menyesuaikan bobot (w) *neural network* atau jaringan saraf dengan tujuan mengurangi kesalahan. Proses *feed propagation* dari *input* ke *output* dan *backpropagation* diulang beberapa kali sampai kesalahan mencapai nilai di bawah ambang batas yang telah ditentukan.

1.3. Recurrent Neural Network

Recurrent Neural Network (RNN) adalah salah satu juga dari pengembangan jenis arsitektur *Neural Network* atau jaringan saraf tiruan, dimana *layer output* dari *hidden layer* akan menjadi input lagi bagi pemrosesan selanjutnya. Menurut [6] ide dasar dari RNN adalah topologi jaringan yang dibuat mampu merepresentasikan data sekuensial atau *time-series*.



Gambar 2 Recurrent Neural Network (RNN)

Ciri dari RNN yakni melakukan prediksi pada data yang tidak hanya menggunakan satu waktu input saja, tetapi juga dibutuhkan sebuah masukan dari input waktu (t) sebelumnya. Maka antar *input* saling terhubung serta menggunakan relasi tersebut untuk memberikan informasi ke seluruh *hidden layer* yang ada dalam RNN. Rancangan RNN memiliki memori yang berisi hasil rekaman informasi dari hasil sebelumnya. Adapun formula yang terbentuk dari RNN ini adalah *forward propagation* dalam RNN, *hidden layer*, *output gate* dan target.

1.4. Parameter Evaluasi.

Alasan utama untuk mengukur akurasi prediksi model *time-series* [7] adalah:

- a. Pada tahap pengembangan dan identifikasi model ukuran akurasi dibutuhkan guna membandingkan model alternatif satu dengan model lainnya serta untuk menentukan kemunculan nilai parameter dalam ekspresi pada fungsi prediksi. Selanjutnya akurasi dalam tahap mengidentifikasi model prediksi, setiap model dianggap penerapannya pada data masa lalu serta dipilih model dengan total error yang minimum.
- b. Secara berkala dibutuhkan penilaian keakuratan, guna mendeteksi kelainan dan kekurangan dalam sebuah model yang mungkin timbul di waktu lain sehingga diperlukan evaluasi akurasi dan peramalan kinerja model yang berbeda.

Contoh indeks evaluasi seperti *Mean Absolute Percentage Error (MAPE)* dan *Mean Square Error (MSE)*. MAPE adalah nilai absolute dari persentase error data terhadap mean [8], dapat dirumuskan sebagai berikut:

$$MAPE = \frac{\sum \left(\frac{Prediksi - Aktual}{Aktual} \right) \times 100}{n}$$

Selanjutnya MSE adalah suatu salah satu alternatif metode untuk mengevaluasi suatu teknik peramalan. Semakin kecil nilai rata-rata jumlah kuadrat dari MSE, maka semakin kecil pula error peramalan atau

prediksinya pada suatu model algoritme (Arsyad, 2001). Rumus untuk mendapatkan MSE adalah sebagai berikut:

$$MSE = \frac{(\text{Aktual} - \text{Prediksi})^2}{n}$$

Semakin kecil nilai error yang didapat dari MSE maupun persentase dari MAPE maka akurasi terhadap model seakin baik. Menurut [9] akurasi memiliki tingkat diagnosa berdasarkan nilai:

- a. Antara 0,90 – 1,00 = Sangat Baik
- b. Antara 0,80 – 0,90 = Baik
- c. Antara 0,70 – 0,80 = Cukup
- d. Antara 0,60 – 0,70 = Kurang
- e. Antara 0,50 – 0,60 = Gagal

1.5. Penelitian Machine Learning Pada Objek Cabai

Beberapa penelitian *machine learning* pada objek cabai untuk bidang pertanian yang telah dilakukan sebelumnya salah satunya yakni penelitian yang dilakukan oleh [10] adalah untuk klasifikasi kualitas dengan menggunakan 100 data sampel dengan 70 data latih dan 30 data uji. Dari pengujian didapatkan akurasi 96,67% terhadap data sampel. Hasil penelitian disimpulkan bahwa penelitian menggunakan metode *Fuzzy K-Nearest Neighbor (FKNN)* memiliki kinerja yang baik dalam klasifikasi kualitas cabai di kota Blitar.

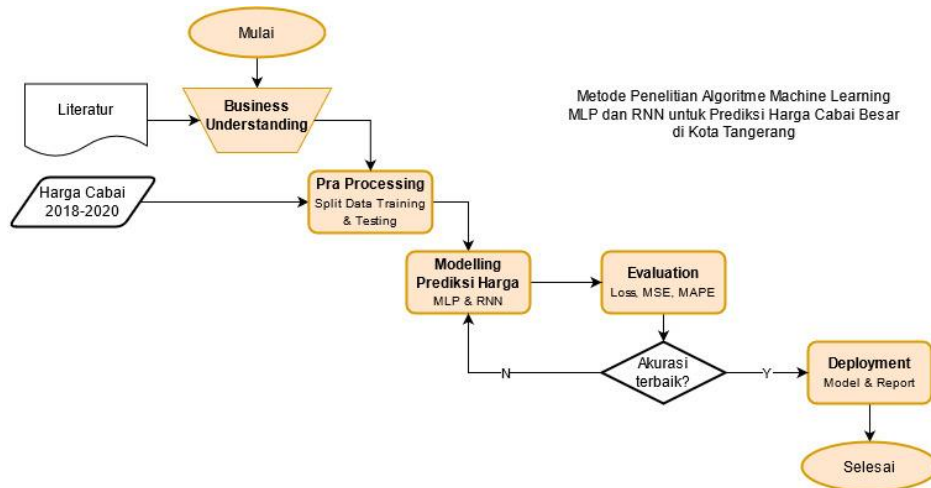
Penelitian lainnya telah dilakukan juga oleh [11] mengidentifikasi buah berdasarkan karakteristik warna oleh alat bantu komputer. Buah tomat dan cabai di dipantau sejak satu bulan sebelum panen hingga masa panen. Segmentasi gambar menggunakan Metode Clustering K-Means sedangkan deteksi kematangan menggunakan fuzzy logika. Hasil penelitian menunjukkan tingkat keberhasilan untuk mendeteksi kematangan buah adalah 80% untuk tomat dan 90% untuk cabai.

2. METODE

Metode yang digunakan dalam penelitian ini menggunakan metode standar CRISP-DM yang disesuaikan dengan kondisi penelitian. Dimana disebutkan oleh (Larose, 2005, p. 6) bahwa *Cross-Industry Standard Process for Data Mining (CRISP-DM)* dikembangkan pada tahun 1996 oleh analis yang mewakili DaimlerChrysler, SPSS, dan NCR. CRISP menyediakan proses standar yang *non-proprietary* dan tersedia secara bebas untuk menyesuaikan data mining ke dalam strategi pemecahan masalah umum dari bisnis atau unit penelitian. Menurut (Larose, 2005) CRISP-DM, siklus proyek data mining memiliki enam fase, yakni:

- a. *Business Understanding*
- b. *Data Understanding*
- c. *Data Preparation*
- d. *Modelling*
- e. *Evaluation*
- f. *Deployment*

Penyesuaian dari fase-fase global CRISP-DM pada prosedur kerja untuk penelitian ini dapat diilustrasikan pada Gambar 3. Urutan fase adalah bersifat adaptif, artinya fase berikutnya sering kali bergantung pada hasil yang terkait dengan fase sebelumnya. Digambarkan ketergantungan paling signifikan antar fase ditunjukkan oleh gambar panah.



Gambar 3 Metode Penelitian

2.1. Business Understanding

Tahapan pekerjaan dalam pemahaman penelitian untuk mengembangkan model prediksi harga cabai dengan perumusan identifikasi masalah, batasan penelitian dan tujuan penelitian yang dituangkan kedalam proposal penelitian.

2.2. Data Understanding

Data yang digunakan adalah data fluktuasi cabai tahun 2020 yang tentunya panen cabai ini juga menurut analisa peneliti berkorelasi juga dengan curah hujan dan juga kondisi inflasi. Tahap pengumpulan data harga cabai diambil dari Pusat Informasi Harga Pangan Strategis Nasional dengan data komoditas cabai di tangerang provinsi banten pada tahun 2020 yang dapat diakses secara online pada website resminya <http://hargapangan.id/tabel-harga/pasar-tradisional/komoditas>. Data tersebut dikombinasi juga dengan data statistik inflasi Bank Indonesia pada tahun 2020 dari website resmi Bank Indonesia <https://www.bi.go.id/id/statistik/indikator/data-inflasi.aspx> dan data curah hujan di tahun 2020 dari situs akses data online pada <https://dataonline.bmkg.go.id> dan <https://banten.bps.go.id/indikator/151/372/1/curah-hujan-menurut-bulan-dan-stasiun-pengamatan-di-provinsi-banten.html>.

2.3. Data Preparation

Tahap persiapan dataset untuk penelitian dengan pemodelan machine learning ini mencakup compile dataset dari data fluktuasi harga cabai dimana harga setiap hari atau tanggal data tersebut menjadi target class dari dataset yang akan digunakan dalam pemodelan machine learning. Dataset yang digunakan pada Tabel 4 adalah data 3 (tiga) tahun mulai 1 Januari 2018 hingga 31 Desember 2020 dengan jumlah data sebanyak 733 record dengan pemisahan 600 record data training dan 700 record data testing.

Tabel 3 Dataset Harga Cabai, Inflasi dan Curah Hujan Kota Tangerang

FIELD	TIPE DATA	KETERANGAN
TANGGAL	DATE	Tanggal pengambilan data
CURAH_HUJAN	DECIMAL	Rata-rata curah hujan bulanan
INFLASI	DECIMAL	Rata-rata inflasi bulanan
HARGA	DECIMAL	Harga caba merah besar pada tanggal pengambilan data

2.4. Modelling

Pada tahap pemodelan ini pemilihan algoritme machine learning yang digunakan adalah *Multi Layer Percepton* (MLP) dibandingkan dengan *Recurrent Neural Network* (RNN). Data hasil preprocessing akan menjadi input model dari kedua algoritme tersebut.

2.5. Evaluation

Tahap evaluasi terhadap model guna mengambil keputusan mengenai dari masing–masing algoritme model machine learning menggunakan metrik pengujian MSE dan MAPE.

2.6. Deployment

Tahap pemanfaatan model yang telah dibuat sehingga model tersebut selanjutnya dapat dikembangkan dalam program aplikasi sebagai sebuah function atau method untuk memprediksi harga cabai kedepan untuk kasus di kota Tangerang.

3. HASIL DAN PEMBAHASAN

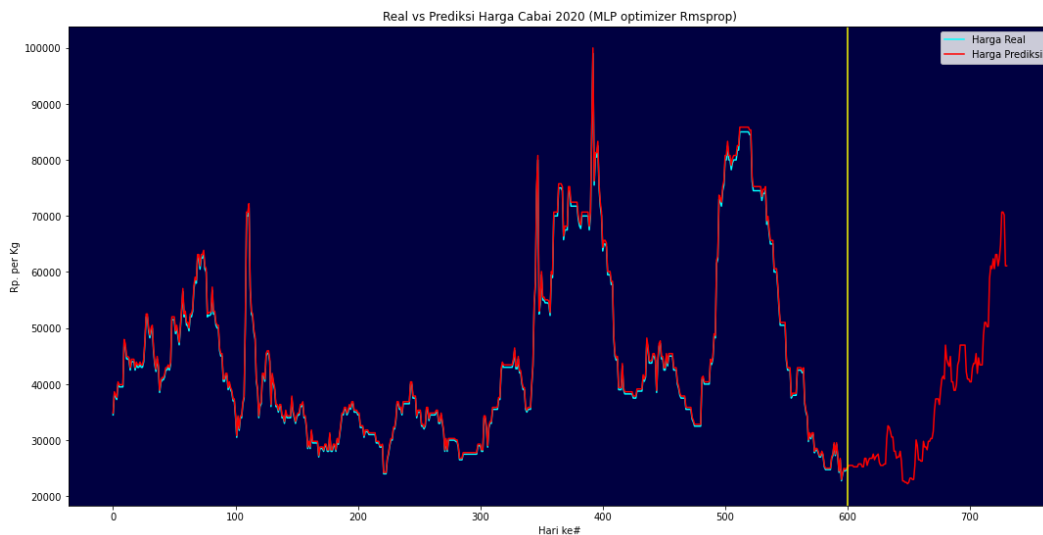
3.1. Proses Pemodelan Multi-Layer Perceptron

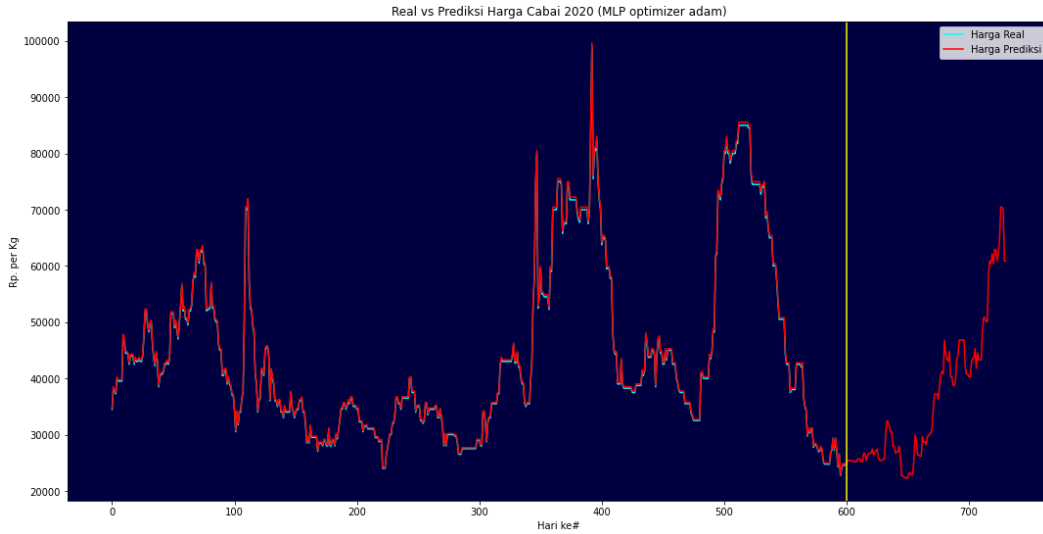
Model jaringan *regression Multi-Layer Perceptron* (MLP) yang digunakan dari input layer ke *fully connected layer* MLP yang akan mengekstrak 64 fitur menggunakan activation RELU dengan dropout 0,2 output shape 64 untuk mengurangi *over fitting*, kemudian terakhir dengan 1 output layer yang akan menghitung *prediction class*. Metode *optimizer* yang digunakan adalah *adaptive learning rate optimization*. Secara ringkasan model arsitektur ditampilkan pada Tabel 4.

Tabel 4 Model arsitektur jaringan MLP

Layer (type)	Output Shape	Param #
dense_20 (Dense)	(None, 64)	128
dropout_10 (Dropout)	(None, 64)	0
dense_21 (Dense)	(None, 1)	65

Secara visualisasi grafik antara data training dibandingkan dengan data hasil prediksi model regression dengan Multilayer Perceptron dari data training dan data testing digambarkan pada Gambar 4 baik menggunakan optimizer rmsprop maupun menggunakan optimizer adam.





Gambar 4 Grafik real vs prediksi harga cabai 2020 dengan MLP

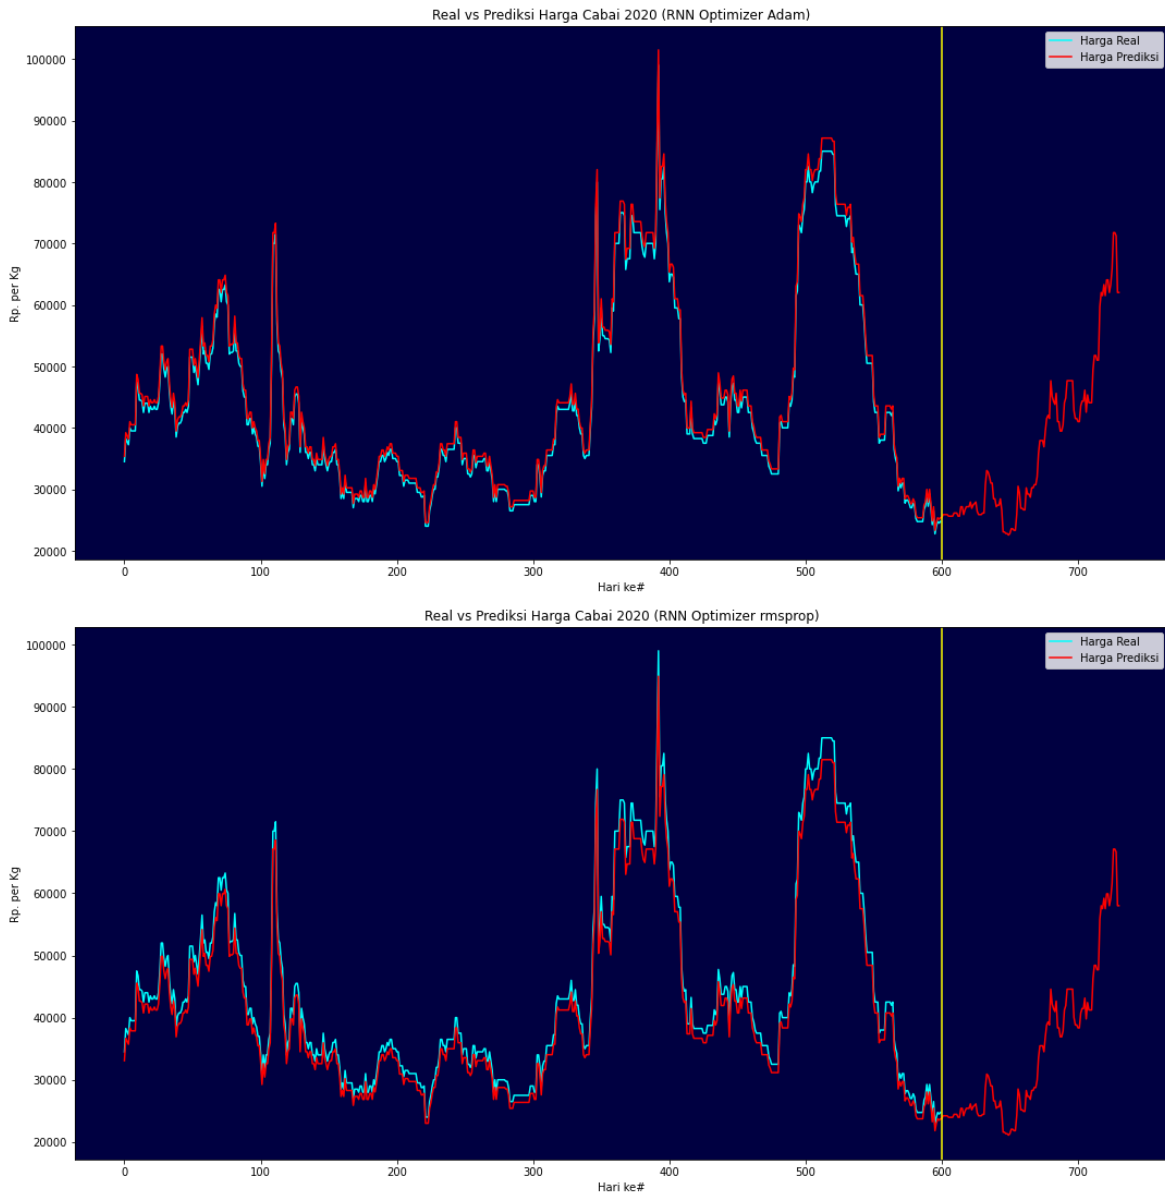
3.2. Proses Pemodelan Recurrent Neural Network

Model jaringan regression Recurrent Neural Network yang digunakan dari input layer ke hidden layer RNN yang akan mengekstrak 96 fitur menggunakan *activation* RELU dengan dropout 0,2 untuk mengurangi *over fitting* setelah itu masih ada hidden fully connected layer lagi yang mengekstrak 32 fitur dengan fungsi *activation* RELU. Setelah itu kemudian ke layer terakhir yaitu layer output yang akan menghitung prediction class. Metode *optimizer* yang digunakan adalah *adaptive learning rate optimization*. Secara ringkasan model arsitektur jaringan ditampilkan pada Tabel 5.

Tabel 5 Model summary arsitektur jaringan RNN

Layer (type)	Output Shape	Param #
simple_rnn (SimpleRNN)	(None, 96)	9408
dropout (Dropout)	(None, 96)	0
dense (Dense)	(None, 32)	3104
dense_1 (Dense)	(None, 1)	33

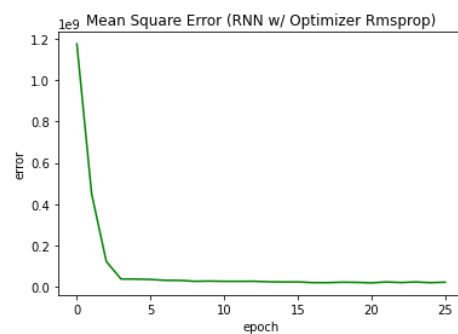
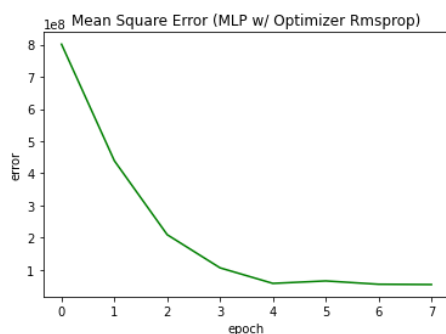
Secara visualisasi grafik antara data training dibandingkan dengan data hasil prediksi model regression dengan *Recurrent Neural Network* dari data training dan data testing ditampilkan pada Gambar 5 baik menggunakan optimizer rmsprop maupun menggunakan optimizer adam.

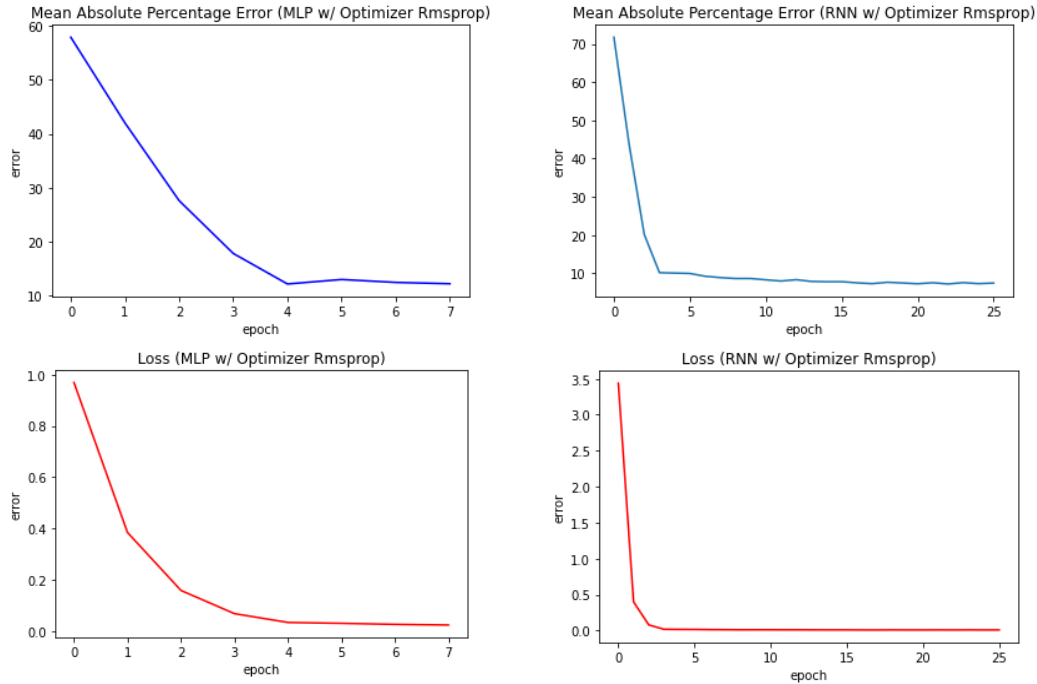


Gambar 5 Grafik real dan prediksi harga cabai 2020 dengan RNN

3.3. Evaluasi Hasil Proses

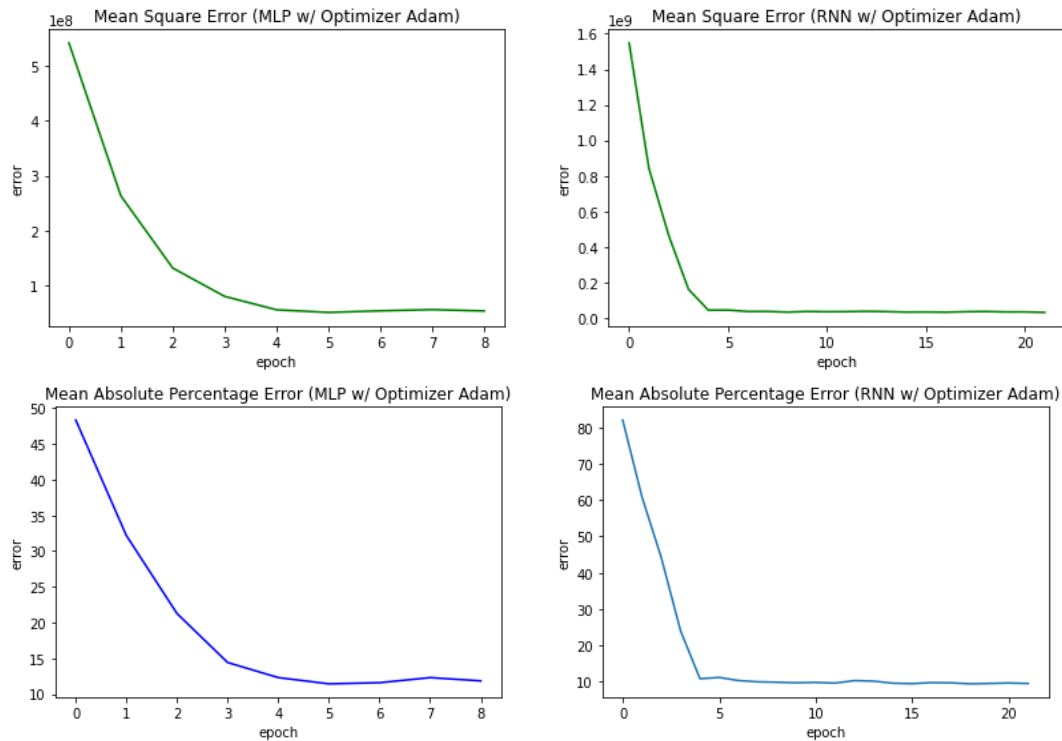
Perbandingan hasil evaluasi kedua model MLP dan RNN yang menggunakan metric optimizer rmsprop dapat dilihat pada Gambar 6 yang menunjukkan *metric* pengukuran dengan MSE, MAPE dan Loss. Loss dari kedua algoritme menggunakan MSLE, Target Epochs 100 dengan fitur early stop mode=minimum dan patience = 3. Metric pengukuran selain Loss juga memonitor nilai MSE dan MAPE.






Gambar 6 Hasil evaluasi model MLP vs RNN dengan optimize rmsprop

Perbandingan hasil evaluasi kedua model MLP dan RNN yang menggunakan metric adam dapat dilihat pada Gambar 7 yang menunjukkan *metric* pengukuran dengan MSE, MAPE dan Loss. Loss dari kedua algoritme menggunakan MSLE, Target Epocs 100 dengan fitur early stop mode=minimum dan patience = 3. Metric pengukuran selain Loss juga memonitor nilai MSE dan MAPE.





Gambar 7 Hasil evaluasi model MLP vs RNN dengan optimize adam

Nilai rata-rata yang diperoleh dari *metric* pengukuran Loss, MSE dan MAPE ditunjukkan dalam Tabel 6 berdasarkan algoritme dan optimizer yang digunakan dalam penelitian termasuk waktu eksekusi disaat posisi epocs berhenti karena kondisi patience tercapai dari target 100 epocs yang ditentukan awal.

Tabel 6 Metric Pengukuran Hasil Algoritme MLP vs RNN

ALGORITME	OPTIMIZER	LOSS	MSE	MAPE	Early Stop Epocs	Exec Time
Multilayer Perceptron	RMSPROP	0,0039	10427776,0	3,95 %	8 / 100	3s
Recurrent Neural Network	ADAM	0,0038	10271959,0	3,79 %	9 / 100	5s
	RMSPROP	0,0055	13437319,0	5,49 %	26 / 100	28s
	ADAM	0,0044	11778658,0	4,82 %	22 / 100	4s

4. PENUTUP

4.1. Simpulan

Berdasarkan hasil penelitian dan pengukuran dapat disimpulkan penggunaan optimizer yang digunakan di kedua algoritme yakni *adaptive learning rate optimization method* (rmsprop) dan *Adaptive Moment Estimation* (Adam), maka jenis optimizer Adam lebih baik hasilnya dibanding optimizer rmsprop. Sedangkan algoritme untuk memprediksi harga cabai dengan kondisi dataset yang digunakan sedikit yakni hanya 733 data atau dibawah 1.000 data ini, maka algoritme multilayer perceptron (MLP) lebih cocok dibandingkan dengan algoritme Recurrent Neural Network (RNN), berdasarkan baik dari *metric* pengukuran Loss dengan nilai 0,0038 kemudian MSE dengan nilai 10271959,0 dan MAPE dengan nilai persentase 3,79% walaupun dari sisi aspek waktu bukan yang tercepat.

Dengan demikian, algoritme multilayer perceptron untuk kasus prediksi cabai ini sebagai algoritme berbasis neural network yang memprediksi lebih akurat diharapkan mampu memberikan solusi bagi *stake holder* untuk memprediksi harga cabai dengan keterbatasan data tiga tahun.

4.2. Saran

Analisis dan perbandingan dalam penelitian prediksi harga cabai ini hanya membandingkan 2 algoritme saja dengan arsitektur jaringan neural network sederhana, dua jenis optimizer dan jumlah dataset yang sedikit. Saran penelitian selanjutnya perlu dilakukan inovasi penelitian model arsitektur jaringan lainnya termasuk fungsi aktivasi ataupun optimizer yang berbeda ataupun dengan algoritme regression lainnya untuk mendapatkan pilihan algoritme dengan *metric* pengukuran yang lebih baik lagi.

DAFTAR PUSTAKA

- [1] M. Syukur, R. Yuniarti e R. Dermawan, Sukses Panen Cabai Setiap Hari, Jakarta: Penebar Swadaya, 2012, p. 2012.
- [2] D. T. Larose e C. D. Larose, Discovering Knowledge in Data: An Introduction to Data Mining, Wiley, 2005.
- [3] L. Yu, J. Chen, G. Ding, Y. Tu, J. Yang e J. Sun, "Spectrum prediction based on taguchi method in deep learning with long short-term memory," *IEEE Access*, vol. 6, p. 15923–15933, 2018.
- [4] T. Beysolow, Introduction to Deep Learning Using R, Apress, 2017.
- [5] T. Mitchell, Machine Learning, Mc Graww-Hill, 1997.

- [6] J. Elman, "Finding Structure Intime," *Cognitive Science*, vol. 14, pp. 179-211, 1990.
- [7] C. Vercellis, *Business Intelligence: Data Mining and Optimization for Decision Making*, Milano, Italy: John Wiley & Sons Ltd, 2009.
- [8] P. V. V. K. Theja e V. Lelitha, "Short Term Prediction of Traffic Parameters Using Support Vector Machines Technique," em *International Conference on Emerging Trends in Engineering and Technology*, 2010.
- [9] F. Gorunescu, *Data Mining Concepts, Models and Techniques*, Berlin: Springer, 2011.
- [10] A. A. Wiratmaka, I. F. Rozi e R. A. Asmara, "Klasifikasi Kualitas Tanaman Cabai Menggunakan Metode Fuzzy K-Nearest Neighbor (FKNN)," *Journal Informatika Polinema (JIP)*, p. 25, 2017.
- [11] A. Taofik, N. Ismail, Y. A. Gerhana e K. Komarujaman, "Design of Smart System to Detect Ripeness of Tomato and Chili," *IOP Conference Series*, p. 288, 2018.
- [12] M. Bramer, *Principles of Data Mining*, London: Springer, 2007.