TUGAS AKHIR – IS184853

PERAMALAN HARGA BAHAN POKOK DI PROVINSI DKI JAKARTA MENGGUNAKAN METODE RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

FORECASTING STAPLE FOODS PRICES IN DKI JAKARTA PROVINCE USING RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

SAIFUDDIN NURUL MUHTI
0521 16 4000 0027

Dosen Pembimbing
Edwin Riksakomara, S.Kom., M.T.
Retno Aulia Vinarti, S.Kom., M.Kom., Ph.D.

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
Surabaya 2020

Halaman ini sengaja dikosongkan.

TUGAS AKHIR - IS184853

PERAMALAN HARGA BAHAN POKOK DI PROVINSI DKI JAKARTA MENGGUNAKAN METODE RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

SAIFUDDIN NURUL MUHTI
0521 16 4000 0027

Dosen Pembimbing
Edwin Riksakomara, S.Kom., M.T.
Retno Aulia Vinarti, S.Kom., M.Kom., Ph.D.

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
Surabaya 2020

Halaman ini sengaja dikosongkan.

UNDERGRADUATE THESIS - IS184853

FORECASTING STAPLE FOODS PRICES IN DKI JAKARTA PROVINCE USING RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

SAIFUDDIN NURUL MUHTI
0521 16 4000 0027

Supervisor
Edwin Riksakomara, S.Kom., M.T.
Retno Aulia Vinarti, S.Kom., M.Kom., Ph.D.

INFORMATION SYSTEM DEPARTMENT
Faculty of Intelligent Electrical and Informatics Technology
Sepuluh Nopember Institute of Technology
Surabaya 2020

Halaman ini sengaja dikosongkan.

LP/P/20/054

LEMBAR PENGESAHAN

PERAMALAN HARGA BAHAN POKOK DI PROVINSI DKI JAKARTA MENGGUNAKAN METODE RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer (S.Kom)
pada
Departemen Sistem Informasi
Fakultas Teknologi Elektro dan Informatika Cerdas (ELECTICS)
Institut Teknologi Sepuluh Nopember

Oleh

Saifuddin Nurul Muhti
05211640000027

Surabaya, 14 Agustus 2020

Kepala Departemen Sistem Informasi

Dr. Mudjahidin, ST., MT.
NIP. 197010102003121001

Halaman ini sengaja dikosongkan.

LEMBAR PERSETUJUAN

PERAMALAN HARGA BAHAN POKOK DI PROVINSI DKI JAKARTA MENGGUNAKAN METODE RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Departemen Sistem Informasi
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember

Oleh:

SAIFUDDIN NURUL MUHTI
NRP. 05211640000027

Disetujui Tim Penguji : Tanggal Ujian:
Periode Wisuda : September 2020

Edwin Riksakomara, S.Kom., M.T. **(Pembimbing I)**

Retno Aulia Vinarti, S.Kom., M.Kom., Ph.D. **(Pembimbing II)**

Ahmad Muklason, S.Kom., M.Sc., Ph.D. **(Penguji I)**

Faizal Mahananto, S.Kom., M.Eng., Ph.D. **(Penguji II)**

Halaman ini sengaja dikosongkan.

PERAMALAN HARGA BAHAN POKOK DI PROVINSI DKI JAKARTA MENGGUNAKAN METODE RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

Nama Mahasiswa	**: Saifuddin Nurul Muhti**
NRP	**: 0521 16 4000 0027**
Departemen	**: Sistem Informasi FTEIC-ITS**
Pembimbing I	**: Edwin Riksakomara, S.Kom, M.T**
Pembimbing II	**: Retno Aulia Vinarti, S.Kom, M.Kom., Ph.D.**

ABSTRAK

Pangan merupakan suatu kebutuhan dasar utama bagi manusia untuk dapat mempertahankan hidup. Oleh karena itu, terpenuhinya kebutuhan akan pangan terutama bahan pokok adalah salah satu hal yang penting dalam kehidupan. Pada umumnya, harga terbentuk karena adanya interaksi antara penawaran dan permintaan. Jika penawaran tinggi dan permintaan rendah, maka harga akan turun. Sebaliknya, jika penawaran rendah sedangkan permintaan tinggi, maka harga akan naik. Hal ini sedikit berbeda dengan bahan pokok, terutama untuk produk pertanian. Hal ini dikarenakan sifatnya yang sangat penting bagi kehidupan. Permintaan akan bahan pokok cenderung tidak stabil (inelastis) terhadap perubahan harga yang menyebabkan harga bahan pokok menjadi fluktuatif saat terjadi perubahan penawaran terutama di Provinsi DKI Jakarta yang merupakan ibukota negara. Peramalan harga bahan pokok sangat penting dilakukan bagi pihak Dinas Ketahanan Pangan, Kelautan, dan Pertanian (KPKP) agar dapat menjamin harga bahan pokok tetap terjangkau oleh konsumen. Pada penelitian ini dilakukan peramalan terhadap harga dua macam komoditas di Pasar Induk Kramat Jati Provinsi DKI Jakarta, yaitu cabai dan bawang merah dengan menggunakan metode Radial Basis Function Neural Network dimana terdapat empat kualitas pada komoditas cabai dan satu kualitas pada komoditas bawang merah. Hasil dari penelitian

ini adalah model peramalan dengan nilai akurasi peramalan yang paling optimal untuk dapat mengetahui harga bahan pokok tujuh hari mendatang. Penelitian ini menghasilkan model dengan nilai akurasi optimal yang diukur menggunakan MAPE dan RMSE pada komoditas bawang merah sebesar 8.564% dan 2561.992, cabai merah keriting sebesar 13.146% dan 4891.733, cabai merah besar sebesar 10.973% dan 5547.738, cabai rawit merah sebesar 8.525% dan 4507.603, dan cabai rawit hijau sebesar 10.835 dan 2322.133.

Kata Kunci : *Radial Basis Function Neural Network, Harga Bahan Pokok, Cabai, Bawang Merah*

FORECASTING STAPLE FOODS PRICES IN DKI JAKARTA PROVINCE USING RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

Name	**: Saifuddin Nurul Muhti**
NRP	**: 0521 16 4000 0027**
Department	**: Information System FTEIC-ITS**
Supervisor I	**: Edwin Riksakomara, S.Kom, M.T.**
Supervisor II	**: Retno Aulia Vinarti, S.Kom, M.Kom., Ph.D.**

ABSTRACT

Food is a basic basic need for humans to be able to sustain life. Therefore, meeting the need for food, especially staples, is one of the important things in life. Generally, prices are formed because of the interaction between supply and demand. If supply is high and demand is low, prices will go down. Conversely, if supply is low while demand is high, then prices will rise. This is slightly different from staples, especially for agricultural products. This is because it is very important for life. Demand for staples tends to be unstable (inelastic) to price changes that cause prices of staples to fluctuate when there is a change in supply, especially in DKI Jakarta Province which is the country's capital. Forecasting the price of staples is very important for the Department of Food Security, Maritime Affairs and Agriculture (KPKP) to be able to guarantee the prices of basic commodities remain affordable by consumers. In this study forecasting the price of two kinds of commodities in the Kramat Jati Central Market of DKI Jakarta Province, namely chili and shallots using the Radial Basis Function Neural Network method where there are four qualities in chilli commodities and one quality in shallots. The expected results of this study are forecasting models with the most optimal forecasting accuracy values to be able to find out the price of staples for the next seven days. This research produces a model

with optimal accuracy values measured using MAPE and RMSE on red onion commodities at 8.564% and 2561.992, curly red chilies at 13.146% and 4891.733, large red chilies at 10.973% and 5547.738, red cayenne peppers at 8.525% and 4507.603 , and green cayenne pepper of 10.835 and 2322.133.

***Keywords**: Radial Basis Function Neural Network, Staple Food Prices, Chili, Bawang Shallot.*

SURAT PERNYATAAN BEBAS PLAGIARISME

Saya yang bertandatangan di bawah ini:

Nama	: Saifuddin Nurul Muhti
NRP	: 05211640000027
Tempat / Tanggal lahir	: Semarang / 5 Mei 1998
Fakultas / Departemen	: FTEIC / Sistem Informasi
Nomor Telp / Hp / Email	: 085733501879 / saifudnm@gmail.com

Dengan ini menyatakan dengan sesungguhnya bahwa penelitian/makalah/tugas akhir saya yang berjudul:

PERAMALAN HARGA BAHAN POKOK DI PROVINSI DKI JAKARTA MENGGUNAKAN METODE RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

Bebas Dari Plagiarisme Dan Bukan Hasil Karya Orang Lain.

Apabila dikemudian hari ditemukan seluruh atau sebagian penelitian/makalah/tugas akhir tersebut terdapat indikasi plagiarisme, maka saya bersedia menerima sanksi sesuai peraturan dan ketentuan yang berlaku. Demikian surat pernyataan ini saya buat dengan sesungguhnya dan untuk dipergunakan sebagaimana mestinya.

Surabaya, 09 Agustus 2020

Saifuddin Nurul Muhti

NRP.05211640000027

Halaman ini sengaja dikosongkan.

KATA PENGANTAR

Dengan mengucapkan rasa syukur kepada Tuhan Yang Maha Pengasih dan Maha Penyayang atas izin-Nya penulis dapat menyelesaikan buku yang sederhana ini dengan judul

"PERAMALAN HARGA BAHAN POKOK DI PROVINSI DKI JAKARTA MENGGUNAKAN METODE RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)".

Penyelesaian Tugas Akhir ini, penulis diiringi oleh pihak-pihak yang selalu memberi dukungan, saran, dan doa sehingga penelitian berlangsung dengan lancar. Secara khusus penulis mengucapkan terima kasih dari lubuk hati terdalam kepada:

1. Tuhan, yang selalu menemani dan membimbing penulis dalam segala aspek kehidupan.
2. Bapak Edwin Riksakomara, S.Kom, M.T dan Ibu Retno Aulia Vinarti, S.Kom, M.Kom., Ph.D selaku dosen pembimbing yang telah mencurahkan segenap tenaga, waktu dan pikiran dalam penelitian ini, serta memberikan motivasi yang membangun.
3. Bapak Ahmad Muklason, S.Kom., M.Sc., Ph.D dan Faizal Mahananto, S.Kom, M.Eng, Ph.D selaku dosen penguji yang telah memberikan kritik dan saran yang membuat kualitas penelitian ini lebih baik lagi.
4. Segenap dosen dan karyawan Departemen Sistem Informasi.
5. Bapak Muhammad Solihin Arianto dan Ibu Indaryanti selaku orang tua penulis yang tiada hentinya mendoakan dan memberikan dukungan.
6. Teman-teman grup 'HH' yang telah memberikan informasi, motivasi, dan canda tawa selama proses penulisan berlangsung.
7. Ayun dan Mira yang telah membantu memahami konsep dari teori yang digunakan dalam penelitian ini.

8. Rekan-rekan ARTEMIS yang telah memberikan banyak kenangan manis dan pahit semasa kuliah
9. Pihak lainnya yang berkontribusi dalam tugas akhir yang belum dapat penulis sebutkan satu per satu.

Penyusunan tugas akhir ini masih jauh dari kata sempurna, untuk itu penulis menerima segala kritik dan saran yang membangun sebagai upaya menjadi lebih baik lagi ke depannya. Semoga buku tugas akhir ini dapat memberikan manfaat untuk pembaca.

Surabaya, 23 Mei 2020

Penulis

DAFTAR ISI

LEMBAR PENGESAHAN vii
LEMBAR PERSETUJUAN ix
ABSTRAK xi
ABSTRACT xiii
SURAT PERNYATAAN BEBAS PLAGIARISME xv
KATA PENGANTAR xvii
DAFTAR ISI xix
DAFTAR GAMBAR xxiii
DAFTAR TABEL xxvii
DAFTAR KODE xxix
BAB I PENDAHULUAN 1
1.1 Latar Belakang 1
1.2 Rumusan Masalah 3
1.3 Batasan Permasalahan 4
1.4 Tujuan 4
1.5 Manfaat 5
1.6 Relevansi 5
BAB II TINJAUAN PUSTAKA 7
2.1 Penelitian Sebelumnya 7
2.2 Landasan Teori 12
2.2.1 Kebutuhan Pokok 12
2.2.2 Pangan 12
2.2.3 Teknik Peramalan 13
2.2.4 Radial Basis Function Neural Network 13
2.2.5 Pengukuran Akurasi Peramalan 15
BAB III METODOLOGI 17
3.1 Metodologi 17
3.2 Uraian Metodologi 18
3.2.1 Studi Literatur 18
3.2.2 Persiapan Data 18
3.2.3 Pra-Processing Data 18
3.2.4 Pembentukan Model RBFNN 19
3.2.5 Pengujian Model RBFNN 19
3.2.6 Pemilihan Model RBFNN 19
3.2.7 Peramalan Data 19

3.2.8 Penyusunan Buku TA 20
BAB IV PERANCANGAN 21
4.1 Persiapan Data..... 21
4.2 *Pra-Processing* Data 21
4.2.1 Normalisasi Data..... 21
4.2.2 Pembentukan Lag..... 22
4.2.3 Pembagian Data 23
4.3 Pembentukan Model RBFNN 24
4.3.1 Pemilihan Hidden Neuron..... 25
4.3.2 Penentuan Jumlah Maksimum Iterasi (*Epochs*) .. 25
4.4 Pengujian Model RBFNN..... 25
4.4.1 Denormalisasi Data 25
4.4.2 Pengukuran Akurasi 25
4.5 Pemilihan Model RBFNN..... 26
4.6 Peramalan Data 26
BAB V IMPLEMENTASI 27
5.1 Persiapan Implementasi 27
5.2 *Pre-Processing* Data 28
5.2.1 Normalisasi Data..... 28
5.2.2 Pembentukan Lag..... 28
5.2.3 Pembagian Data 29
5.3 Pembentukan Model RBFNN 30
5.3.1 Penentuan Hidden Neuron 31
5.3.2 Penentuan Jumlah Maksimum Iterasi (*Epochs*) .. 32
5.4 Pengujian Model RBFNN..... 33
5.4.1 Denormalisasi Data 33
5.4.2 Pengukuran Akurasi 33
5.5 Pemilihan Model RBFNN..... 34
5.6 Peramalan Data 35
BAB VI HASIL DAN PEMBAHASAN..... 37
6.1 Persiapan Data..... 37
6.2 Uji Coba Model RBFNN 38
6.2.1 Komoditas Bawang Merah..... 38
6.2.2 Komoditas Cabai Merah Keriting 42
6.2.3 Komoditas Cabai Merah Besar 46
6.2.4 Komoditas Cabai Rawit Merah..... 50
6.2.5 Komoditas Cabai Rawit Hijau 53

6.3 Pemilihan Model Optimal 57
6.4 Peramalan Model RBFNN 58
6.4.1 Komoditas Bawang Merah..... 58
6.4.2 Komoditas Cabai Merah Keriting 59
6.4.3 Komoditas Cabai Merah Besar 59
6.4.4 Komoditas Cabai Rawit Merah..... 60
6.4.5 Komoditas Cabai Rawit Hijau 61
BAB VI KESIMPULAN DAN SARAN 63
7.1 Kesimpulan 63
7.2 Saran 64
DAFTAR PUSTAKA 65
BIODATA PENULIS 67
LAMPIRAN A. PERBANDINGAN HARGA KOMODITAS BAWANG MERAH A1
LAMPIRAN B. HASIL UJI COBA KOMODITAS BAWANG MERAH B1
LAMPIRAN C. HASIL UJI COBA KOMODITAS CABAI MERAH KERITING C1
LAMPIRAN D. HASIL UJI COBA KOMODITAS CABAI MERAH BESAR D1
LAMPIRAN E. HASIL UJI COBA KOMODITAS CABAI RAWIT MERAH E1
LAMPIRAN F. HASIL UJI COBA KOMODITAS CABAI RAWIT HIJAU F1

Halaman ini sengaja dikosongkan.

DAFTAR GAMBAR

Gambar 2.1 Arsitektur dari RBFNN 14
Gambar 3.1 Alur Pengerjaan 17
Gambar 6.1 Grafik Nilai RMSE tiap epochs pada Komoditas Bawang Merah 39
Gambar 6.2 Grafik Pengujian Komoditas Bawang Merah dengan Persentase 75:25 40
Gambar 6.3 Perbandingan Data Uji Aktual dan Peramalan Komoditas Bawang Merah Persentase 75:25 40
Gambar 6.4 Grafik Pengujian Komoditas Bawang Merah dengan Persentase 80:20 41
Gambar 6.5 Perbandingan Data Uji Aktual dan Peramalan Komoditas Bawang Merah Persentase 80:20 41
Gambar 6.6 Grafik Pengujian Komoditas Bawang Merah dengan Persentase 90:10 42
Gambar 6.7 Perbandingan Data Uji Aktual dan Peramalan Komoditas Bawang Merah Persentase 90:10 42
Gambar 6.8 Grafik Nilai RMSE tiap epochs pada Komoditas Cabai Merah Keriting 43
Gambar 6.9 Grafik Pengujian Komoditas Cabai Merah Keriting dengan Persentase 75:25 44
Gambar 6.10 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Keriting Persentase 75:25 44
Gambar 6.11 Grafik Pengujian Komoditas Cabai Merah Keriting dengan Persentase 80:20 45
Gambar 6.12 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Keriting Persentase 80:20 45
Gambar 6.13 Grafik Pengujian Komoditas Cabai Merah Keriting dengan Persentase 90:10 46
Gambar 6.14 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Keriting Persentase 90:10 46
Gambar 6.15 Grafik Nilai RMSE tiap epochs pada Komoditas Cabai Merah Besar 47
Gambar 6.16 Grafik Pengujian Komoditas Cabai Merah Besar dengan Persentase 75:25 47

Gambar 6.17 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Besar Persentase 75:25 48
Gambar 6.18 Grafik Pengujian Komoditas Cabai Merah Besar dengan Persentase 80:20 48
Gambar 6.19 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Besar Persentase 80:20 49
Gambar 6.20 Grafik Pengujian Komoditas Cabai Merah Besar dengan Persentase 90:10 49
Gambar 6.21 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Besar Persentase 90:10 50
Gambar 6.22 Grafik Nilai RMSE tiap epochs pada Komoditas Cabai Rawit Merah 50
Gambar 6.23 Grafik Pengujian Komoditas Cabai Rawit Merah dengan Persentase 75:25 51
Gambar 6.24 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Merah Persentase 75:25 51
Gambar 6.25 Grafik Pengujian Komoditas Cabai Rawit Merah dengan Persentase 80:20 52
Gambar 6.26 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Merah Persentase 80:20 52
Gambar 6.27 Grafik Pengujian Komoditas Cabai Rawit Merah dengan Persentase 90:10 53
Gambar 6.28 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Merah Persentase 90:10 53
Gambar 6.29 Grafik Nilai RMSE tiap epochs pada Komoditas Cabai Rawit Hijau 54
Gambar 6.30 Grafik Pengujian Komoditas Cabai Rawit Hijau dengan Persentase 75:25 55
Gambar 6.31 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Hijau Persentase 75:25 55
Gambar 6.32 Grafik Pengujian Komoditas Cabai Rawit Hijau dengan Persentase 80:20 56
Gambar 6.33 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Hijau Persentase 80:20 56
Gambar 6.34 Grafik Pengujian Komoditas Cabai Rawit Hijau dengan Persentase 90:10 57
Gambar 6.35 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Hijau Persentase 90:10 57

Gambar 6.36 Hasil Prediksi Komoditas Bawang Merah 59
Gambar 6.37 Hasil Prediksi Komoditas Cabai Merah Keriting 59
Gambar 6.38 Hasil Prediksi Komoditas Cabai Merah Besar . 60
Gambar 6.39 Hasil Prediksi Komoditas Cabai Rawit Merah. 60
Gambar 6.40 Hasil Prediksi Komoditas Cabai Rawit Hijau .. 61

Halaman ini sengaja dikosongkan.

DAFTAR TABEL

Table 1.1 Roadmap Lab. RDIB (Rekayasa Data dan Intelegensi Bisnis) 6
Table 4.1 Sampel Data Hasil Normalisasi (September 2018) 22
Table 4.2 Skenario Pembentukan Lag..... 23
Table 4.3 Skenario Pembagian Data 24
Table 4.4 Skenario Pembentukan Model 24
Table 5.1 Spesifikasi Perangkat Keras Laptop..... 27
Table 5.2 Daftar *Library* yang Digunakan 27
Table 5.3 Penjelasan Kode 5.1 28
Table 5.4 Penjelasan Kode 5.2 29
Table 5.5 Penjelasan Kode 5.3 30
Table 5.6 Penjelasan Kode 5.4 31
Table 5.7 Penjelasan Kode 5.5 32
Table 5.8 Penjelasan Kode 5.6 33
Table 5.9 Penjelasan Kode 5.8 33
Table 5.10 Penjelasan Kode 5.9 34
Table 5.11 Penjelasan Kode 5.10 35
Table 5.12 Penjelasan Kode 5.11 35
Table 6.1 Sampel Data dari Sumber Data (September 2018) 38
Table 6.2 Model Paling Optimal di setiap Komoditas 58

Halaman ini sengaja dikosongkan.

DAFTAR KODE

Kode 5.1 Normalisasi Min Max 28
Kode 5.2 Pembentukan Lag 28
Kode 5.3 Pembagian Data Pelatihan dan Pengujian 29
Kode 5.4 Variabel Masukan dan Keluaran 30
Kode 5.5 Penentuan *Hidden Neuron* 31
Kode 5.6 Penentuan Jumlah Maksimum Iterasi 32
Kode 5.7 Denormalisasi Data 33
Kode 5.8 Pengukuran Akurasi 34
Kode 5.9 Pemilihan Model RBFNN 35
Kode 5.10 Peramalan Data 35

Halaman ini sengaja dikosongkan.

BAB I
PENDAHULUAN

Pada bab pendahuluan akan diuraikan proses identifikasi masalah penelitian yang meliput latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, manfaat kegiatan tugas akhir, dan relevansi terhadap pengerjaan tugas akhir. Berdasarkan uraian pada bab ini, harapannya gambaran umum permasalahan dan pemecahan masalah pada tugas akhir dapat dipahami.

1.1 Latar Belakang

Terpenuhinya kebutuhan akan bahan pokok merupakan salah satu hal yang penting dalam kehidupan. Hanya saja, ketidakstabilan harga membuat kebutuhan ini menjadi sulit terpenuhi. Pada umumnya, harga terbentuk karena adanya interaksi antara penawaran dan permintaan. Jika penawaran tinggi dan permintaan rendah, maka harga akan turun. Sebaliknya, jika penawaran rendah sedangkan permintaan tinggi, maka harga akan naik. Hal ini sedikit berbeda dengan bahan pokok, terutama untuk produk pertanian. Produksi pertanian terbagi dalam golongan harga stabil dan harga tidak stabil. Golongan harga stabil terdiri dari terong, mentimun, kacang panjang, dan kubis. Sedangkan golongan harga tidak stabil adalah komoditas yang mempunyai fluktuasi harga cukup tinggi meliputi cabai dan bawang merah. Hal ini dikarenakan tidak seimbangnya antara pasokan dan tingkat permintaan yang ada di pasaran. Sehingga biaya yang dikeluarkan untuk memenuhi kebutuhan terhadap cabai dan bawang merah akan sulit untuk diprediksi [1]. Selain itu, peran pemerintah dalam mengatur harga cabai dan bawang merah hanya sebatas mengandalkan kebijakan harga. Hal tersebut berbeda dengan komoditas beras dimana pemerintah selain dapat melakukan kebijakan harga, juga melakukan pengelolaan stok yang bekerja sama dengan Bulog [2].

Komoditas cabai dan bawang merah termasuk dalam golongan harga tidak stabil serta mempunyai fluktuasi harga yang cukup tinggi jika dibandingkan dengan komoditas lain. Pada sisi konsumsi, cabai dan bawang merah menjadi salah satu bumbu masakan yang harus ada pada menu harian sebagian masyarakat Indonesia. Apabila harga cabai melonjak, maka akan berdampak pada daya beli masyarakat dan juga menimbulkan keresahan. Dalam menghadapi masalah tersebut salah satu solusinya adalah dengan cara melakukan peramalan harga yang dapat digunakan untuk memprediksi kemungkinan kenaikan harga komoditas cabai dan bawang merah [3].

Studi ini bertujuan untuk memprediksi harga bahan pokok di Pasar Induk Kramat Jati Provinsi DKI Jakarta dalam jangka pendek (1 hingga 7 hari ke depan). Dengan adanya prediksi harga yang akurat, maka pemerintah dapat menjamin harga bahan pokok tetap terjangkau oleh konsumen melalui mekanisme operasi pasar saat harga diprediksi naik secara drastis [4].

Pada studi ini, *Radial Basis Function Neural Network* (RBFNN) digunakan untuk memprediksi harga harian 2 macam komoditas bahan pokok dalam jangka pendek antara 1 hingga 7 hari ke depan. Model RBFNN merupakan metode peramalan yang tergolong dalam model *Neural Network* (NN) atau Jaringan Saraf Tiruan (JST). Ciri khas yang membedakan RBFNN dengan algoritma NN yang lain adalah RBFNN hanya memiliki satu *hidden layer*, sedangkan algoritma yang lain dapat memiliki satu atau lebih *hidden layer*. Selain itu, pada RBFNN menggunakan fungsi aktivasi basis pada *hidden layer* dan fungsi linear pada *input layer* dimana fungsi aktivasi yang sering digunakan pada algoritma NN yang lain adalah fungsi *sigmoid*. Ciri khas RBFNN ini menyebabkan proses kerja RBFNN lebih cepat dari algoritma NN yang lain [5].

Penelitian ini akan memprediksi harga komoditas bahan pokok berupa cabai dan bawang merah di Pasar Induk Kramat Jati Provinsi DKI Jakarta berdasarkan data pada tahun 2018-2019. Dalam penelitian ini terdapat 4 kualitas cabai dan 1 kualitas

bawang merah, yaitu cabai merah besar, cabai merah kriting, cabai rawit hijau, cabai rawit merah, dan bawang merah medium. Alasan peneliti meramalkan harga dari 4 kualitas cabai dan 1 kualitas bawang merah karena komoditas tersebut termasuk dalam produksi pertanian dengan harga tidak stabil atau mempunyai fluktuasi yang cukup tinggi jika dibandingkan dengan komoditas lain. Selain itu, alasan peneliti memilih Pasar Induk Kramat Jati sebagai objek karena pasar tersebut merupakan *food station* (terminal buah dan sayuran) untuk wilayah DKI Jakarta [6]. Seluruh buah dan sayuran yang masuk ke DKI Jakarta harus melalui Pasar Induk Kramat Jati sehingga harga buah dan sayuran di pasar-pasar DKI Jakarta mengikuti naik turunnya harga di Pasar Induk Kramat Jati. Artinya harga komoditas di Pasar Induk Kramat Jati merupakan representatif dari harga komoditas pasar-pasar lain di wilayah DKI Jakarta.

Uraian latar belakang di atas merupakan alasan peneliti tertarik membahas RBFNN. Untuk mengetahui teknik peramalan dengan menggunakan model RBFNN yang diterapkan dalam peramalan harga bahan pokok di Pasar Induk Kramat Jati Provinsi DKI Jakarta, tugas akhir ini diberi judul “Peramalan Harga Bahan Pokok di Provinsi DKI Jakarta Menggunakan Metode *Radial Basis Function Neural Network* (RBFNN)”.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang, maka rumusan permasalahan yang menjadi fokus dan akan diselesaikan dalam tugas akhir ini antara lain:

1. Bagaimana model yang dihasilkan dari peramalan metode RBFNN?
2. Bagaimana hasil peramalan harga bahan pokok untuk komoditas cabai dan bawang merah di Pasar Induk Kramat Jati Provinsi DKI Jakarta dengan menggunakan metode RBFNN?
3. Bagaimana tingkat akurasi dari hasil peramalan dengan menggunakan metode RBFNN?

1.3 Batasan Permasalahan

Berikut batasan masalah dalam pengerjaan tugas akhir ini berdasarkan pada penguraian rumusan masalah di atas:

1. Data yang diambil adalah data sekunder harian harga komoditas bawang merah dan cabai di Pasar Induk Kramat Jati Provinsi DKI Jakarta pada bulan September 2018 hingga bulan Januari 2020 yang didapatkan dari website infopangan.jakarta.go.id. Terdapat 518 data untuk setiap komoditasnya.
2. Penelitian ini memprediksi harga empat kualitas dari komoditas cabai dan satu kualitas dari komoditas bawang merah. Empat macam kualitas pada komoditas cabai yaitu cabai merah besar, cabai merah kriting, cabai rawit hijau, dan cabai rawit merah. Sedangkan untuk komoditas bawang merah hanya memiliki satu kualitas yaitu bawang merah medium.
3. Dalam menentukan pembagian data pelatihan dan pengujian untuk RBFNN, penelitian ini menggunakan persentase 75:25, 80:20, dan 90:10.
4. *Tools* yang digunakan dalam penelitian yaitu Microsoft Excel dan Spyder dimana bahasa pemrogaman yang digunakan pada *tools* Spyder adalah Python.

1.4 Tujuan

Berikut tujuan dari tugas akhir ini berdasarkan pada pemaparan latar belakang dan rumusan masalah di atas :

1. Membuat model peramalan harga masing-masing kualitas dari 2 komoditas bahan pokok yaitu cabai dan bawang merah di Pasar Induk Kramat Jati Provinsi DKI Jakarta dengan metode RBFNN.
2. Mengimplementasikan metode RBFNN untuk model peramalan harga masing-masing kualitas dari 2 komoditas bahan pokok yaitu cabai dan bawang merah di Pasar Induk Kramat Jati Provinsi DKI Jakarta.

3. Mengetahui tingkat akurasi dari hasil peramalan dengan metode RBFNN untuk model peramalan harga masing-masing kualitas dari 2 komoditas bahan pokok yaitu cabai dan bawang merah di Pasar Induk Kramat Jati Provinsi DKI Jakarta.

1.5 Manfaat

Berikut merupakan manfaat yang diharapkan dari penelitian yang dilakukan:

1. Bagi Peneliti
   Menambah dan memperkaya pengetahuan mengenai model RBFNN serta penerapannya pada data time series.
2. Bagi Pembaca
   a. Menambah pengetahuan mengenai model RBFNN
   b. Memberikan suatu metode alternatif untuk melakukan peramalan menggunakan model RBFNN.

1.6 Relevansi

Hingga saat ini, permintaan akan bahan pokok untuk komoditas cabai dan bawang merah di Provinsi DKI Jakarta cenderung inelastis yang menyebabkan harga bahan pokok untuk 2 komoditas tersebut menjadi sangat fluktuatif saat terjadi perubahan penawaran. Untuk dapat menjamin harga bahan pokok tetap terjangkau oleh konsumen, maka perlu untuk dilakukan peramalan menggunakan metode RBFNN, yang dipelajari pada mata kuliah Analitika Bisnis. Sementara untuk bentuk peramalan itu sendiri dipelajari pada matakuliah Teknik Peramalan.

Tugas Akhir yang ditulis oleh peneliti ini termasuk dalam Peramalan, Data Mining, dan Jaringan Saraf Tiruan jika disesuaikan dengan Roadmap Laboratorium RDIB pada Tabel 1

Table 1.1 Roadmap Lab. RDIB (Rekayasa Data dan Intelegensi Bisnis)

Sistem Pendukung Keputusan	Pemodelan Sistem dan Analisis
	Peramalan
Manajemen Data	Sistem Manajemen Basis Data
	Data Warehouse
Analisis Bisnis	Optimasi
	Data Mining
	Web Analytic
Manajemen Pengetahuan	Sistem Manajemen Pengetahuan
	Ontology
Sistem Cerdas	Algoritma Genetika
	Jaringan Syaraf Tiruan
	Logika Fuzzy
	Expert System
	Intelligent Agent

BAB II
TINJAUAN PUSTAKA

Pada bab ini berisi penelitian sebelumnya yang dijadikan acuan dalam pengerjaan tugas akhir dan juga berisi dasar teori untuk menunjang penelitian pada tugas akhir.

2.1 Penelitian Sebelumnya

Terdapat beberapa penelitian yang memiliki topik yang hampir serupa dengan penelitian ini. Adapun penelitian-penelitian tersebut akan dijelaskan pada **Tabel 2.1.**

Tabel 2.1 Penelitian Yang Terkait

Penelitian 1 [6]	
Judul Penelitian	Application of ARIMA Model for Forecasting Agricultural Prices
Penulis	V. Jadhav, B.V Chinnappa Reddy, G. M. Gaddi
Tahun	2017
Deskripsi Umum Penelitian	Peneliti ini ingin memprediksi dan memvalidasi harga produk pertanian berupa padi, ragi, dan jagung di negara bagian Karnataka untuk tahun 2016 menggunakan data *time series* dari tahun 2002 hingga 2016. Metode yang digunakan adalah ARIMA dengan menggunakan beberapa model yaitu AR, MA, ARMA, dan ARIMA. Hasil perhitungannya dievaluasi dengan menggunakan *Mean Square Error (MSE), Mean Average*

	Percentage Error (MAPE), dan *Theils U.*
Kelebihan	Penelitian ini telah melakukan pendekatan dalam beberapa model dengan beberapa variasi variabel terkait dengan harga produk pertanian.
Kekurangan	Penelitian tersebut kurang dalam memperhatikan hubungan non-linear antar variabel yang digunakan.
Keterkaitan dengan Tugas Akhir	Penelitian ini dapat dijadikan sebagai referensi pengerjaan tugas akhir mengenai peramalan harga bahan pokok dengan komoditas utama yaitu cabai dan bawang merah.
Penelitian 2 [7]	
Judul Penelitian	The optimal omnichannel strategy for SMEs Apparel retailers
Penulis	Made Larita Ditakristy, Deni Saepudin, Fhira Nhita
Tahun	2016
Deskripsi Umum Penelitian	Penelitian ini berfokus pada prediksi harga berbagai komoditas pertanian dengan banyak variable terkait menggunakan metode peramalan Radial Basis Function Neural Network. Hasil dari penelitian ini adalah nilai akurasi seberapa besar komoditas pertanian yang harus diproduksi oleh

	petani berdasarkan pada data prediksi harga komoditas pertanian di masa yang akan datang.
Kelebihan	RBFNN merupakan gabungan dari Teknik *supervised* dan *unsupervised learning* sehingga cakupan model data dapat diolah oleh metode ini menjadi lebih luas dari metode ANN.
Kekurangan	Tidak menggunakan metode optimasi dalam membangun system RBFNN nya sehingga peneliti menggunakan metode *trial and error* dalam penentuan input *neuron*nya.
Keterkaitan dengan Tugas Akhir	Penelitian ini akan menjadi referensi dalam menentukan metode yang akan digunakan untuk menyelesaikan permasalahan yang diangkat pada tugas akhir ini dan metode peramalan data yang digunakan akan diadopsi dalam penelitian.
Penelitian 3 [1]	
Judul Penelitian	Prediksi Harga Cabai dengan Pemodelan Time Series ARIMA
Penulis	F. N. Hadiansyah
Tahun	2017
Deskripsi Umum Penelitian	Penelitian ini berfokus pada prediksi harga cabai menggunakan data-data harga cabai sebelumnya untuk dijadikan sebagai

	perbandingan sehingga dapat memprediksi harga cabai di masa yang akan datang. Data akan dianalisis dan dibuatkan kedalam beberapa bentuk model ARIMA, kemudian ditentukan model ARIMA mana saja yang memungkinkan untuk dimodelkan sehingga akan didapatkan model yang efisien untuk pemodelan harga cabai ini. Hasil penelitian ini menghasilkan 4 model yaitu ARIMA (1 2 1), AR (1), ARI (1 2) dan IMA (2 1) yang kemudian dilakukan uji kebaikan untuk menentukan model terbaik dengan menggunakan RMSE, MAPE dan R-square. Berdasarkan skenario testing dan training, diperoleh model dengan performansi yang baik adalah ARIMA.
Kelebihan	Penelitian ini memberikan hasil peramalan dengan menggunakan variabel pendukung yang dapat mempengaruhi harga cabai.
Kekurangan	Penelitian tersebut kurang mendetailkan beberapa variabel yang digunakan.
Keterkaitan dengan Tugas Akhir	Penelitian ini dapat dijadikan sebagai referensi pengerjaan tugas akhir ini mengenai peramalan harga bahan

	pokok dengan komoditas utama yaitu cabai.
Penelitian 4 [4]	
Judul Penelitian	Prediksi Harga Bahan Pokok Nasional Jangka Pendek Menggunakan ARIMA
Penulis	Mohammad Arif Rasyidi
Tahun	2017
Deskripsi Umum Penelitian	Fluktuasi harga bahan pokok yang tidak terkendali dapat menyebabkan kerugian bagi konsumen maupun produsen. Salah satu langkah untuk mengatasi permasalahan tersebut yaitu dengan membuat prediksi harga yang akurat sehingga tindakan preventif dapat dilakukan untuk meminimalkan gejolak harga. Dalam studi ini, ARIMA digunakan untuk memprediksi harga bahan pokok nasional dalam jangka pendek. Data harga harian dari dua belas bahan pokok pada empat horizon prediksi (1 hingga 30 hari ke depan) digunakan untuk menguji kinerja ARIMA dalam memprediksi harga bahan pokok. Hasil eksperimen menujukkan bahwa model ARIMA yang dihasilkan mampu memprediksi harga dengan tingkat error rata-rata sebesar 2.22%.

Kelebihan	Penelitian ini memberikan hasil peramalan dengan menggunakan variabel pendukung yang dapat mempengaruhi harga bahan pokok.
Kekurangan	Penelitian tersebut kurang mendetailkan beberapa variabel yang digunakan.
Keterkaitan dengan Tugas Akhir	Penelitian ini dapat dijadikan sebagai referensi pengerjaan tugas akhir ini mengenai peramalan harga bahan pokok dengan komoditas utama yaitu cabai.

2.2 Landasan Teori

Landasan teori berisi teori-teori yang digunakan dalam pengerjaan penelitian tugas akhir. Dalam landasan teori, acuan yang digunakan adalah berdasarkan penelitian dan buku.

2.2.1 Kebutuhan Pokok

Kebutuhan utama untuk setiap manusia terdiri dari kebutuhan sandang, pangan, dan papan. Di zaman yang semakin maju ini kebutuhan manusia semakin beraneka ragam, sehingga mengakibatkan masyarakat kesulitan dalam menentukan mana kebutuhan yang primer dan mana yang sekunder. Namun, dari sekian banyak kebutuhan manusia, hanya 3 yang masih menjadi kebutuhan pokok dan selalu menempati urutan teratas dalam hal permintaan kebutuhan masyarakat yaitu kebutuhan pangan, sandang, dan papan [8]. Dalam tugas akhir ini, peneliti hanya mengambil data mengenai kebutuhan pangan.

2.2.2 Pangan

Pangan merupakan suatu kebutuhan dasar utama bagi manusia untuk dapat mempertahankan hidup. Oleh karena itu, kebutuhan pangan bagi setiap orang merupakan hak asasi yang harus

dipenuhi. Sebagai kebutuhan dasar dan hak asasi manusia, pangan mempunyai peran yang sangat penting bagi kehidupan suatu bangsa dan negara. Ketersediaan pangan yang lebih kecil dibandingkan dengan kebutuhan dapat menciptakan ketidakstabilan ekonomi suatu negara. Berbagai gejolak sosial dan politik dapat terjadi jika ketahanan pangan terganggu, yang pada akhirnya dapat membahayakan stabilitas nasional. Berdasarkan kenyataan tersebut masalah pemenuhan kebutuhan pangan bagi seluruh penduduk setiap saat di suatu wilayah menjadi sasaran utama kebijakan pangan bagi pemerintah suatu negara [8].

2.2.3 Teknik Peramalan

Peramalan (*forecasting*) merupakan suatu teknik yang digunakan untuk memprediksi atau memperkirakan suatu nilai pada masa depan dengan memperhatikan data atau informasi yang relevan pada masa lalu dan saat ini. Metode peramalan dapat dibagi menjadi dua kategori, yaitu metode kualitatif dan metode kuantitatif [9]. Metode kualitatif bersifat subjektif dan intuitif karena hanya memanfaatkan pendapat dari para ahli dan hasilnya tergantung orang yang menyusunnya. Sedangkan metode kuantitatif bersifat objektif dan dibuat berdasarkan data masa lalu [10].

2.2.4 Radial Basis Function Neural Network

Model RBFNN terdiri dari 3 lapisan, yaitu lapisan input (input layer), lapisan tersembunyi (hidden layer), dan lapisan output (output layer). *Input layer* menerima suatu vektor x yang kemudian dibawa ke hidden layer yang akan memproses data input secara nonlinear dengan fungsi aktivasi. Output dari hidden layer selanjutnya diproses di *output layer* secara linear [11].

Model RBFNN menggunakan fungsi basis sebagai fungsi aktivasi untuk setiap *neuron* pada *hidden layer*. Fungsi aktivasi yang biasa digunakan dalam RBFNN adalah fungsi Gaussian karena mempunyai sifat local, yaitu jika *input* dekat dengan

rata-rata maka fungsi akan menghasilkan nilai 1, sedangkan jika *input* jauh dari rata-rata maka fungsi memberikan nilai 0.

$$\varphi(x) = e^{(-x^2/2\sigma^2)} \qquad (2\text{-}1)$$

dengan

x = jarak Euclidean antara vektor *input* x dengan pusat *hidden neuron* μ

Arsitektur RBFNN dapat dilihat pada Gambar 3.1 berikut:

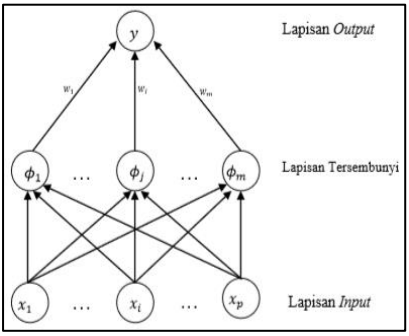

Gambar 2.1 Arsitektur dari RBFNN

Pada arsitektur di atas terdapat *p* komponen vektor *input* **x**, *m* buah fungsi basis sebagai fungsi aktivasi *hidden neuron* dan satu buah *output*. *Output* y yang dihasilkan dari model RBFNN merupakan kombinasi linear dari bobot $\{w_j\}_{j=1}^{m}$ dengan fungsi aktivasi $\varphi_j(\mathbf{x})$ dan dirumuskan sebagai berikut [12]:

$$y = \sum_{j=1}^{m} w_j \varphi_j(\mathbf{x}) \qquad (2\text{-}2)$$

dengan

m = banyak fungsi aktivasi *hidden neuron*
w_j = bobot *output* ke-*j*
$\varphi_j(\mathbf{x})$ = fungsi aktivasi *hidden neuron* ke-*j*
$\mathbf{x} = [x_1, x_2, \dots, x_p]$ yang merupakan *input vector*

2.2.5 Pengukuran Akurasi Peramalan

Untuk mengetahui keakuratan hasil peramalan dilakukan evaluasi dengan menggunakan metode perhitungan kesalahan dalam peramalan. *Root Mean Square Error* (RMSE) merupakan nilai rata-rata dari jumlah kuadrat kesalahan yang dihasilkan oleh suatu model perkiraan. Semakin rendah nilai RMSE menunjukkan model peramalan memiliki kemampuan yang baik. Rumus RMSE secara umum dapat dituliskan seperti berikut.

$$RMSE = \sqrt{\frac{\sum_{t=1}^{N}(A_t - F_t)^2}{n}} \qquad (2\text{-}3)$$

dengan

n = banyaknya data
At = nilai actual indeks pada periode ke t
Ft = nilai *forecasting* data pada periode ke t

Selain menggunakan RMSE sebagai metode dalam perhitungan kesalahan, peneliti juga menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE merupakan ukuran ketepatan relatif yang digunakan untuk mengetahui persentase penyimpangan hasil peramalan. Suatu model mempunyai kinerja bagus jika nilai MAPE berada di bawah 20% [13]. Rumus MAPE secara umum dapat dituliskan seperti berikut.

$$MAPE = \frac{1}{n}\sum_{t=1}^{n}\left|\frac{A_t - F_t}{A_t}\right| \times 100\% \qquad (2\text{-}4)$$

dengan
n = banyaknya data
At = nilai actual indeks pada periode ke t
Ft = nilai *forecasting* data pada periode ke t

Halaman ini sengaja dikosongkan.

BAB III
METODOLOGI

Bab Metodologi Penelitian akan menjelaskan bagaimana alur dari penelitian beserta penjelasan dari tiap tahapannya sebagai metodologi yang digunakan.

3.1 Metodologi

Gambar 3.1 merupakan diagram penjelasan mengenai alur penelitian yang akan dihasilkan.

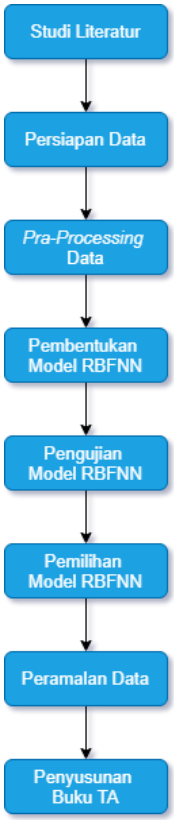

Gambar 3.1 Alur Pengerjaan

3.2 Uraian Metodologi

Metodologi yang digunakan pada penelitian ini mengadaptasi metode Radial Basis Function Neural Network yang disesuaikan dengan kebutuhan penelitan dan pengembangan. Berikut adalah uraian dari metodologi yang digunakan sebagaimana yang digambarkan pada bagian sebelumnya.

3.2.1 Studi Literatur

Studi literatur merupakan tahapan paling awal yang dilakukan pada penulisan tugas akhir ini yang bertujuan untuk menentukan topik dengan menganalisa latar belakang permasalahan terkait harga bahan pokok di Provinsi DKI Jakarta. Pada tahap ini, peneliti menentukan batasan masalah, tujuan, dan manfaat dari penelitian.

3.2.2 Persiapan Data

Pada proses persiapan data ini merupakan langkah awal pada suatu penelitian. Data yang digunakan pada penelitian ini adalah data harian harga 2 bahan pokok yaitu bawang merah dan cabai pada bulan September 2018 hingga Januari 2020 yang didapatkan dari website infopangan.jakarta.go.id. Termasuk di dalamnya penentuan data dari pasar mana yang representatif untuk digunakan dalam penelitian ini.

3.2.3 Pra-Processing Data

Pada penelitian ini akan dilakukan normalisasi, pembentukan lag, dan partisi data. Normalisasi data bertujuan untuk mengubah data aktual menjadi lebih kecil dari sebelumnya dan memiliki batasan, tetapi tidak menghilangkan karakteristik seluruhnya. Nilai *range* yang digunakan yaitu pada interval 0 sampai 1.

Kemudian dilakukan pembentukan lag karena data yang akan diolah merupakan *univariate time series.* Pembentukan lag ini bertujuan untuk mentransformasi data *time series* menjadi data input pembelajaran mesin yang bersifat *cross-sectional.*

Setelah itu dilakukan partisi data yaitu membagi keseluruhan data menjadi 2 yaitu data latih dan data uji. Pembagian data dilakukan dengan persentase 75:25, 80:20, dan 90:10.

3.2.4 Pembentukan Model RBFNN

Tahap ini berfokus dalam melakukan pelatihan dengan membangun model RBFNN dari data pelatihan (*train set*) yang dimiliki. Model dibangun dengan cara *trial and error* menggunakan data dari beberapa skenario pembagian data yang telah ditentukan pada tahap *pra-processing* data dimana di setiap skenario juga akan dilakukan *trial and error* menggunakan parameter *hidden neuron*.

3.2.5 Pengujian Model RBFNN

Tahap pengujian model merupakan tahap mengukur akurasi model RBFNN yang telah dibangun dengan memprediksi harga komoditas tiap bahan pokok pada data pengujian (*test set*). Kemudian hasil dari prediksi tersebut dibandingkan dengan nilai aktual menggunakan metode MAPE dan RMSE. Model yang nantinya dipilih untuk melakukan peramalan adalah model dengan nilai MAPE paling kecil.

3.2.6 Pemilihan Model RBFNN

Tahap pemilihan model merupakan tahap untuk menentukan model paling optimal yang akan digunakan untuk melakukan peramalan terhadap harga komoditas 7 hari ke depan. Pemilihan model optimal ini berdasarkan lag dengan nilai MAPE terkecil dari 10 lag.

3.2.7 Peramalan Data

Tahap peramalan data merupakan tahap meramalkan harga masing-masing komoditas dari bawang merah dan cabai di Pasar Induk Kramat Jati untuk 7 hari ke depan. Peramalan data menggunakan model paling optimal yang didapatkan dari tahap sebelumnya.

3.2.8 Penyusunan Buku TA

Penyusunan buku Tugas Akhir merupakan proses terakhir dalam penelitian ini namun dapat dilakukan bersamaan dengan tahapan yang lain. Tujuan dari penyusunan buku TA adalah sebagai dokumentasi dari penelitian sehingga dapat dijadikan referensi untuk penelitian selanjutnya.

Pada Bab 1 Pendahuluan akan diuraikan proses identifikasi masalah penelitian yang meliput latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, manfaat kegiatan tugas akhir, dan relevansi terhadap pengerjaan tugas akhir. Kemudian pada Bab 2 Tinjauan Pustaka berisi penelitian sebelumnya yang dijadikan acuan dalam pengerjaan tugas akhir dan juga berisi dasar teori untuk menunjang penelitian pada tugas akhir. Selanjutnya Bab 3 Metodologi Penelitian akan menjelaskan bagaimana alur dari penelitian beserta penjelasan dari tiap tahapannya sebagai metodologi yang digunakan. Setelah membuat alur penelitian pada Bab 4 Perancangan akan menjelaskan mengenai perancangan model yang dibentuk menggunakan model RBFNN sebelum melakukan peramalan. Setelah itu pada Bab 5 Implementasi dijelaskan mengenai implementasi metode jaringan RBFNN ke dalam Bahasa Python menggunakan software Spyder juga pengolahan data pada Microsoft Excel. Setelah dilakukan implementasi makan dilanjutkan dengan Bab 6 Hasil dan Pembahasan yang menjelaskan mengenai hasil dari proses uji coba dan pembahsan serta analisis terhadap hasil yang diperoleh dari proses pelatihan dan pengujian jaringan RBFNN. Terakhir yaitu Bab 7 Kesimpulan dan Saran yang membahas mengenai kesimpulan dari semua proses yang telah dilakukan dan saran yang dapat diberikan untuk pengembangna yang lebih baik.

BAB IV
PERANCANGAN

Bab ini menjelaskan mengenai perancangan model yang dibentuk menggunakan model RBFNN sebelum melakukan peramalan. Model jaringan yang dibentuk disesuaikan dengan langkah-langkah yang telah dijelaskan pada Bab Metodologi. Rancangan yang dibutuhkan yaitu meliputi proses persiapan data, *pra-processing* data, pembentukan model RBFNN, pengujian model RBFNN, pemilihan model RBFNN, peramalan data, serta proses yang dilakukan menggunakan *tools* Spyder dengan bahasa pemrogaman Python.

4.1 Persiapan Data

Data yang digunakan pada tugas akhir ini adalah data harga komoditas bawang merah dan cabai yang didapat dari website https://infopangan.jakarta.go.id dimana komoditas cabai mempunyai 4 kualitas yaitu cabai merah besar, cabai merah keriting, cabai rawit hijau, dan cabai rawit merah di Pasar Induk Kramat Jati Provinsi DKI Jakarta dengan periode harian dari bulan September 2018 hingga bulan Januari 2020, sehingga diperoleh sebanyak 518 data. Data pada tiap komoditas memiliki jumlah yang sama yaitu 518 data dikarenakan tidak terdapat *missing value*.

4.2 *Pra-Processing* Data

Setelah mendapatkan data, maka dilakukan *pre-processing* data. Terdapat tiga tahapan *pre-processing* data sebelum dilakukan pengolahan data untuk peramalan, yaitu sebagai berikut.

4.2.1 Normalisasi Data

Pada penelitian dilakukan normalisasi dengan tujuan mengubah data aktual menjadi lebih kecil dari sebelumnya dan memiliki batasan. Normalisasi data yang digunakan dalam penelitian ini adalah normalisasi *MinMax* seperti yang ditujukkan pada Persamaan 4.1.

$$X_{baru} = \frac{\mathbf{x - min\ (X)}}{\mathbf{max(X) - min\ (X)}} \quad (4\text{-}1)$$

Data hasil normalisasi yang dihasilkan mempunyai rentang nilai antara 0 hingga 1. Variabel akan semakin mendekati 0 jika nilai mendekati angka minimum dan mendekati 1 untuk nilai yang mendekati angka maksimum. Tabel 4.1 merupakan sampel data hasil normalisasi pada kurun waktu 1 September hingga 10 September 2018.

Table 4.1 Sampel Data Hasil Normalisasi (September 2018)

Tanggal	Bawang Merah	Cabai Merah Keriting	Cabai Merah Besar	Cabai Rawit Merah	Cabai Rawit Hijau
01/09/2018	0.065	0.115	0.221	0.059	0.065
02/09/2018	0.065	0.115	0.221	0.059	0.065
03/09/2018	0.065	0.098	0.206	0.059	0.065
04/09/2018	0.065	0.131	0.176	0.074	0.065
05/09/2018	0.065	0.115	0.162	0.059	0.065
06/09/2018	0.097	0.148	0.162	0.074	0.097
07/09/2018	0.129	0.148	0.191	0.088	0.129
08/09/2018	0.161	0.180	0.132	0.103	0.161
09/09/2018	0.161	0.197	0.147	0.132	0.161
10/09/2018	0.194	0.213	0.162	0.132	0.194

4.2.2 Pembentukan Lag

Data deret berkala yang telah dilakukan normalisasi perlu diubah menjadi data *cross-sectional* dengan melakukan pembagian lag yang nantinya digunakan sebagai input metode RBFNN. Pada penelitian ini terdapat 10 skenario pembentukan lag seperti pada Tabel 4.2. Jumlah lag optimal ditentukan berdasarkan nilai MAPE, semakin kecil nilai MAPE maka lag dengan jumlah tersebut semakin optimal.

Table 4.2 Skenario Pembentukan Lag

Skenario	Deskripsi
Lag-1	Penambahan 1 lag sebagai input pembelajaran mesin
Lag-2	Penambahan 2 lag sebagai input pembelajaran mesin
Lag-3	Penambahan 3 lag sebagai input pembelajaran mesin
Lag-4	Penambahan 4 lag sebagai input pembelajaran mesin
Lag-5	Penambahan 5 lag sebagai input pembelajaran mesin
Lag-6	Penambahan 6 lag sebagai input pembelajaran mesin
Lag-7	Penambahan 7 lag sebagai input pembelajaran mesin
Lag-8	Penambahan 8 lag sebagai input pembelajaran mesin
Lag-9	Penambahan 9 lag sebagai input pembelajaran mesin
Lag-10	Penambahan 10 lag sebagai input pembelajaran mesin

4.2.3 Pembagian Data

Sebelum melakukan pembentukan model terlebih dahulu data dibagi menjadi data pelatihan dan data pengujian. Data pada masing-masing komoditas yaitu bawang merah, cabai merah keriting, cabai merah besar, cabai rawit hijau, dan cabai rawit merah memiliki jumlah yang sama. Data pelatihan digunakan untuk pembentukan model dari arsitektur RBFNN yang dirancang, sedangkan data pengujian digunakan untuk mengevaluasi model-model peramalan beserta pemilihan model terbaik.

Table 4.3 Skenario Pembagian Data

Skenario	Persentase Data	
	Data Pelatihan	Data Pengujian
75:25	75%	25%
80:20	80%	20%
90:10	90%	10%

4.3 Pembentukan Model RBFNN

Pembentukan model yang dilakukan pada penelitian ini terdiri dari beberapa skenario untuk tiap komoditas, yaitu kombinasi dari skenario pembentukan lag (Tabel 4.2), pembagian data (Tabel 4.3), dan pemilihan *hidden neuron* yang ditunjukkan pada Tabel 4.4. Dari hasil semua skenario yang dilakukan pada penelitian ini, dapat diketahui model yang menghasilkan nilai MAPE terkecil. Kemudian model yang memiliki nilai MAPE terkecil pada tiap komoditas akan dipilih untuk digunakan pada peramalan 7 hari ke depan.

Table 4.4 Skenario Pembentukan Model

Komoditas	**Persentase Data**	**Lag**	**Hidden Neuron**
Bawang Merah	75%-25% 80%-20% 90%-10%	1-10	1-30
Cabai Merah Keriting	75%-25% 80%-20% 90%-10%	1-10	1-30
Cabai Merah Besar	75%-25% 80%-20% 90%-10%	1-10	1-30
Cabai Rawit Merah	75%-25% 80%-20% 90%-10%	1-10	1-30
Cabai Rawit Hijau	75%-25% 80%-20% 90%-10%	1-10	1-30

4.3.1 Pemilihan Hidden Neuron

Hidden neuron pada penelitian ini direpresentasikan sebagai node. Banyaknya node pada model akan mempengaruhi kecepatan komputasi yang akan semakin lama. Jumlah node yang dilakukan uji coba dalam penelitian ini mulai dari 1 hingga 30 node.

4.3.2 Penentuan Jumlah Maksimum Iterasi (*Epochs*)

Jumlah maksimum *epochs* yang diperlukan pada saat *model fitting* (seberapa baik suatu model meniru pola dari data asli) oleh jaringan saraf tiruan bertujuan untuk mendapatkan pembelajaran seoptimal mungkin. Penggunaan jumlah *epochs* pada penelitian ini dilakukan dengan proses *trial and error*, dengan nilai awal iterasi yang digunakan adalah 1000 *epochs*. Jika nilai RMSE pada tiap *epochs* tidak mengalami perubahan yang signifikan atau bahkan memiliki nilai RMSE yang hampir sama dengan *epochs* sebelumnya maka nilai *epochs* akan dikurangi.

4.4 Pengujian Model RBFNN

Tahap pengujian model terdiri dari denormalisasi data pada variabel prediksi dan pengukuran akurasi model RBFNN.

4.4.1 Denormalisasi Data

Denormalisasi data bertujuan untuk mengembalikan nilai sesuai dengan data asli setelah dilakukan normalisasi pada tahap *pra-processing* data. Denormalisasi data dilakukan terhadap variabel prediksi dan variabel dependen pada data testing agar hasil pengukuran akurasi lebih akurat.

4.4.2 Pengukuran Akurasi

Setelah data variabel prediksi dan variabel dependen pada data testing telah dilakukan denormalisasi, selanjutnya mengukur akurasi model RBFNN untuk setiap *trial and error* pada parameter *hidden neuron* terhadap variabel prediksi yang dihasilkan oleh *output layer*. Pengukuran akurasi menggunakan metode MAPE dan RMSE.

4.5 Pemilihan Model RBFNN

Tahap pemilihan model merupakan tahap untuk menentukan model paling optimal yang akan digunakan untuk melakukan peramalan terhadap harga komoditas 7 hari ke depan. Pemilihan model ini dilakukan dengan melihat perbandingan nilai MAPE antar skenario pembagian data dan lag dari lag 1 sampai lag 10 dimana setiap lag juga dilakukan pengujian parameter *hidden neuron* dari node ke-1 hingga node ke-30. Model yang dipilih untuk digunakan pada tahap peramalan tiap komoditas adalah model dengan nilai MAPE terkecil dari tiga skenario pembagian data dimana tiap pembagian data dipilih lag dengan nilai MAPE terkecil dan dari tiap lag dipilih parameter *hidden neuron* dengan nilai MAPE terkecil.

4.6 Peramalan Data

Tahap peramalan data merupakan tahap meramalkan harga masing-masing komoditas yaitu bawang merah, cabai merah keriting, cabai merah besar, cabai rawit merah, dan cabai rawit hijau di Pasar Induk Kramat Jati untuk 7 hari ke depan dalam kurun waktu 1 Februari hingga 7 Februari 2020. Peramalan data menggunakan model paling optimal yang didapatkan dari tahap sebelumnya yaitu pemilihan model RBFNN.

BAB V
IMPLEMENTASI

Pada bab ini, dijelaskan mengenai implementasi metode jaringan RBFNN ke dalam Bahasa Python menggunakan software Spyder juga pengolahan data pada Microsoft Excel. Hal ini dilakukan berdasarkan urutan proses pada Bab Metodologi dan rancangan kode disesuaikan dengan perancangan yang sudah dilakukan pada Bab Perancangan.

5.1 Persiapan Implementasi

Penelitian ini menggunakan perangkat keras dan lunak untuk membantu proses pengerjaan. Untuk spesifikasi perangkat keras yang digunakan dapat dilihat pada Tabel 5.1.

Table 5.1 Spesifikasi Perangkat Keras Laptop

Nama Perangkat	Laptop
Processor	Intel(R) Core(TM) i5-5200 CPU @ 2.20GHz 2.19 GHz
Memory	12,0 GB
Sistem Operasi	Windows 10 Pro 64-bit

Aplikasi dikembangkan dengan menggunakan beberapa teknologi seperti *code editor*, bahasa pemrogaman, dan *library* yang disajikan dalam Tabel 5.2.

Table 5.2 Daftar *Library* yang Digunakan

Bahasa Pemrogaman	Python
***Code Editor* (IDE)**	Spyder
Library	numpy, pandas, time, matplotlib, sklearn, keras

5.2 *Pre-Processing* Data

Tahap *pra-processing* data merupakan tahap untuk melakukan normalisasi seluruh variabel yang terlibat dan pembagian data menjadi data pelatihan dan pengujian.

5.2.1 Normalisasi Data

Normalisasi data yang digunakan pada penelitian ini adalah normalisasi min max seperti Kode 5.1.

```
# Normalization
scaler = MinMaxScaler()
select_comodity = scaler.fit_transform(select_comodity.values)
```

Kode 5.1 Normalisasi Min Max

Keterangan dari kode 5.1 dijelaskan pada Tabel 5.1.

Table 5.3 Penjelasan Kode 5.1

Atribut	Penjelasan
MinMaxScaler()	Sebuah package yang disediakan oleh python untuk normalisasi nilai dengan default range dari 0 sampai 1
select_comodity	Variabel yang berisi data salah satu komoditas
fit_transform()	Fungsi lanjutan dari MinMaxScaler() yang digunakan untuk mengaplikasikan normalisasi sekaligus mengubah nilai variabel select_comodity

5.2.2 Pembentukan Lag

Data yang telah dinormalisasi selanjutnya dilakukan pembentukan lag dengan jumlah lag awal sebanyak 7 lag karena *output* yang ingin dihasilkan yaitu prediksi 7 hari ke depan. Jumlah lag akan bertambah satu jika periode yang digunakan juga bertambah satu seperti yang ditunjukkan pada Kode 5.2.

```
data_lag = pd.DataFrame()
for i in range(output+period):
    data_lag['lag-'+str(i)] = select_comodity.iloc[:,0].shift(-i)
```

Kode 5.2 Pembentukan Lag

Keterangan dari kode 5.2 dijelaskan pada Tabel 5.5

Table 5.4 Penjelasan Kode 5.2

Atribut	Penjelasan
output	Nilai dari output yaitu 7 karena output dari penelitian ini yaitu harga komoditas untuk 7 hari ke depan
period	Menambah jumlah lag sesuai dengan periode yang digunakan
select_commodity	Variabel yang berisi data salah satu komoditas
shift()	Fungsi untuk membuat kolom baru dengan menghilangkan baris pertama pada kolom sebelumnya

5.2.3 Pembagian Data

Data pelatihan dan data pengujian yang digunakan dalam tugas akhir ini menggunakan perbandingan 80:20, 75:25, dan 90:10. Pada kode program 5.3 menggunakan pembagian data 80:20 karena nilai test_size yang dimasukkan adalah 1/5. Untuk pembagian data 75:25 maka nilai test_size diubah menjadi 1/4 dan untuk pembagian data 90:10 maka nilai test_size diubah menjadi 1/10.

```
X_train, X_test, y_train, y_test = train_test_split(X, y,
                                                    test_size=1/5,
                                                    random_state=0,
                                                    shuffle=False)
```

Kode 5.3 Pembagian Data Pelatihan dan Pengujian

Keterangan dari kode 5.3 dijelaskan pada Tabel 5.6.

Table 5.5 Penjelasan Kode 5.3

Atribut	Penjelasan
X_train	Data training dari variabel bebas
X_test	Data testing dari variabel bebas
y_train	Data training dari variabel terikat
y_test	Data testing dari variabel terikat
train_test_split()	Fungsi untuk melakukan partisi data menjadi data training dan testing
test_size	Parameter yang menunjukkan jumlah data yang dialokasikan untuk data testing
random_state	Parameter untuk menjaga nilai agar tidak berubah saat dirun ulang
shuffle	Parameter agar pembagian data dilakukan secara ascending, tidak acak

5.3 Pembentukan Model RBFNN

Seperti yang telah dijelaskan pada subbab 4.3, pembentukan model yang dilakukan pada penelitian ini terdiri dari beberapa skenario untuk tiap komoditas, yaitu kombinasi dari skenario pembentukan lag (Tabel 4.2), pembagian data (Tabel 4.3), dan pemilihan *hidden neuron* yang ditunjukkan pada Tabel 4.4.

Terdapat variabel masukan untuk arsitektur RBFNN berupa lag yang dijadikan sebagai variabel independen, seperti yang dibangun pada Kode 5.4.

```
X = data_bm_lag.iloc[:, :lag]
y = data_bm_lag.iloc[:, lag:]
```

Kode 5.4 Variabel Masukan dan Keluaran

Keterangan dari kode 5.4 dijelaskan pada Tabel 5.7. Jumlah kolom pada variabel **X** sesuai dengan nilai pada variabel **lag**. Sebagai contoh untuk lag 1, terdapat 1 kolom variabel **X** dan 7 kolom variabel **y** karena output yang ingin dihasilkan yaitu prediksi 7 hari ke. Sedangkan pada lag 2, terdapat 2 kolom variabel **X** dan 7 kolom variabel **y**. Sehingga setiap bertambah

1 lag maka jumlah kolom variabel **X** bertambah 1 dengan jumlah variabel **y** tetap 7 kolom.

Table 5.6 Penjelasan Kode 5.4

Atribut	Penjelasan
X	Variabel independen
y	Variabel dependen
data_bm_lag	Variabel keluaran dari tahap pembuatan lag dengan penghapusan pada baris yang berisi nilai NaN
lag	jumlah lag

5.3.1 Penentuan Hidden Neuron

Parameter yang dapat dilakukan *trial and error* pada jaringan RBFNN menggunakan *package* 'rbflayer' di Python yaitu *hidden neuron* atau node pada lapisan tersembunyi, seperti yang dibangun pada Kode 5.5.

```
model = Sequential()
model.add(RBFLayer(node,
                   InitCentersKMeans(X_train),
                   input_shape=(period,)))
model.add(Dense(output))
```

Kode 5.5 Penentuan *Hidden Neuron*

Keterangan dari kode 5.5 dijelaskan pada Tabel 5.8.

Table 5.7 Penjelasan Kode 5.5

Atribut	Penjelasan
Sequential()	Fungsi yang terdapat pada package keras untuk dapat melakukan berbagai metode modelling dengan Neural Network
RBFLayer()	Salah satu fungsi pada Sequential yang digunakan untuk melakukan modelling dengan metode RBFNN
node	Representasi dari parameter hidden neuron yang dapat dilakukan trial and error dengan nilai 1 sampai 30 node. Nilai parameter node dapat dikatakan optimal jika menghasilkan MAPE paling kecil dari pada nilai lainnya.
InitCenterKMeans	Metode klustering yang digunakan untuk mengubah nilai parameter pada hidden neuron
input_shape	Nilai pada parameter ini berisi banyaknya kolom yang terdapat pada variabel independent

5.3.2 Penentuan Jumlah Maksimum Iterasi (*Epochs*)

Penggunaan jumlah *epochs* pada penelitian ini dilakukan dengan proses *trial and error*, dengan nilai awal iterasi yang digunakan adalah 1000 *epochs*. Jika nilai RMSE pada tiap *epochs* tidak mengalami perubahan yang signifikan atau bahkan memiliki nilai RMSE yang hampir sama dengan *epochs* sebelumnya maka nilai *epochs* akan dikurangi.

```
model.fit(X_train, y_train, epochs=1000, verbose=1)
```

Kode 5.6 Penentuan Jumlah Maksimum Iterasi

Keterangan dari kode 5.6 dijelaskan pada Tabel 5.9.

Table 5.8 Penjelasan Kode 5.6

Atribut	Penjelasan
epochs	Jumlah iterasi maksimum dalam satu kali modelling

5.4 Pengujian Model RBFNN

Tahap pengujian model terdiri dari denormalisasi data pada variabel prediksi dan pengukuran akurasi model RBFNN.

5.4.1 Denormalisasi Data

Denormalisasi data dilakukan terhadap variabel prediksi dan variabel dependen pada data testing agar hasil pengukuran akurasi lebih akurat.

```
y_pred = model.predict(X_test)
y_pred_denormalization = scaler.inverse_transform(y_pred)
y_test_denormalization = scaler.inverse_transform(y_test)
```

Kode 5.7 Denormalisasi Data

Keterangan pada kode 5.8 dijelaskan pada Tabel 5.11.

Table 5.9 Penjelasan Kode 5.8

Atribut	Penjelasan
predict()	Fungsi yang digunakan untuk menghasilkan prediksi berdasarkan variabel independen dari data testing.
y_pred_denormalization	Variabel prediksi pada output layer yang telah dilakukan denormalisasi
y_test_denormalization	Variabel dependen pada data testing yang telah dilakukan denormalisasi

5.4.2 Pengukuran Akurasi

Setelah variabel prediksi dan variabel dependen pada data testing, selanjutnya mengukur akurasi model RBFNN untuk setiap *trial and error* pada parameter *hidden neuron* terhadap

variabel prediksi yang dihasilkan oleh *output layer*. Pengukuran akurasi menggunakan metode MAPE dan RMSE.

```
def mape(y, y_pred):
    return np.mean(np.abs((y-y_pred)/y))

# MAPE
new_mape = mape(y_test_denormalization, y_pred_denormalization)
# RMSE
new_rmse = np.sqrt(mean_squared_error(
        y_test_denormalization, y_pred_denormalization))
```

Kode 5.8 Pengukuran Akurasi

Keterangan dari kode 5.9 dijelaskan pada Tabel 5.12.

Table 5.10 Penjelasan Kode 5.9

Atribut	Penjelasan
mape()	Fungsi untuk menghitung akurasi model
new_mape	Variabel sementara yang menampung nilai MAPE setiap model
new_rmse	Variabel sementara yang menampung nilai RMSE setiap model

5.5 Pemilihan Model RBFNN

Setelah dilakukan pengukuran nilai akurasi untuk satu model oleh variabel new_mape dan new_rmse maka variabel tersebut ditampung ke dalam suatu list agar nilai akurasi pada model tersebut tidak hilang saat menjalankan model yang baru. Sehingga untuk variabel new_mape akan ditampung ke dalam variabel mape_list dan variabel new_rmse akan ditampung ke dalam variabel rmse_list. Selanjutnya setelah *trial and error* dalam satu periode selesai dilakukan, maka diambil nilai MAPE terkecil untuk dibandingkan dengan nilai MAPE terkecil dari *trial and error* pada model di periode selanjutnya menggunakan fungsi best_mape().

```
def best_mape():
    period_mape_list = list()
    for i in range(0,len(mape_list)-iteration+1,iteration):
        period_mape_list.append(min(mape_list[i:i+iteration])*100)
    return period_mape_list

mape_list.append(new_mape)
rmse_list.append(new_rmse)
# Period DataFrame
period_df = pd.DataFrame({'Period':[i for i in range(1,period+1)],
                                  'MAPE':best_mape()}).set_index('Period')
```

Kode 5.9 Pemilihan Model RBFNN

Keterangan dari kode 5.10 dijelaskan pada Tabel 5.13.

Table 5.11 Penjelasan Kode 5.10

Atribut	Penjelasan
mape_list	Variabel yang digunakan untuk menampung nilai dari variabel new_mape
rmse_list	Variabel yang digunakan untuk menampung nilai dari variabel new_rmse
periode_df	Variabel untuk menampilkan data frame berisi nilai MAPE terkecil dari setiap periode yang tertampung di variabel mape_list
best_mape()	Fungsi untuk mendapatkan nilai MAPE terkecil di setiap periode yang tertampung di variabel mape_list

5.6 Peramalan Data

Tahap terakhir yaitu melakukan peramalan terhadap harga masing-masing komoditas dari bawang merah dan cabai di Pasar Induk Kramat Jati untuk 7 hari ke depan.

```
forecast_result = scaler.inverse_transform(model.predict(
        data_bm.iloc[data_bm.shape[0]-best_period:data_bm.
                    shape[0]-best_period+1,0:best_period]))
```

Kode 5.10 Peramalan Data

Keterangan dari kode 5.11 dijelaskan pada Tabel 5.14.

Table 5.12 Penjelasan Kode 5.11

Atribut	Penjelasan
forecast_result	Variabel untuk menampilkan prediksi harga komoditas 7 hari ke depan

Halaman ini sengaja dikosongka

BAB VI
HASIL DAN PEMBAHASAN

Pada bab ini dijelaskan mengenai hasil dari proses uji coba dan pembahsan serta analisis terhadap hasil yang diperoleh dari proses pelatihan dan pengujian jaringan RBFNN.

6.1 Persiapan Data

Data komoditas bawang merah, cabai merah besar, cabai merah keriting, cabai rawit hijau, dan cabai rawit merah yang didapatkan dari website infopangan.jakarta.go.id berupa data harian dari bulan September 2018 hingga bulan Januari 2020. Pada penelitian ini menggunakan data harga komoditas di Pasar Induk Kramat Jati karena seluruh buah dan sayuran yang masuk ke DKI Jakarta harus melalui Pasar Induk Kramat Jati sehingga harga buah dan sayuran di pasar-pasar DKI Jakarta mengikuti naik turunnya harga di Pasar Induk Kramat Jati. Sehingga harga komoditas di Pasar Induk Kramat Jati dapat menjadi representatif dari harga komoditas pasar-pasar lain di wilayah DKI Jakarta. Perbandingan harga komoditas bawang merah setiap pasar di DKI Jakarta ditunjukkan dengan grafik pada **LAMPIRAN A**, dimana grafik pada lampiran tersebut menunjukkan bahwa Pasar Induk Kramat Jati dengan garis berwarna biru memiliki harga bawang merah paling murah dari pasar lain di wilayah DKI Jakarta. Salah satu contoh data pada bulan September 2018 dari semua komoditas di Pasar Induk Kramat Jati ditunjukkan oleh Tabel 5.3.

Table 6.1 Sampel Data dari Sumber Data (September 2018)

Tanggal	Bawang Merah	Cabai Merah Keriting	Cabai Merah Besar	Cabai Rawit Merah	Cabai Rawit Hijau
01/09/2018	11000	13000	24000	11000	12000
02/09/2018	11000	13000	24000	11000	12000
03/09/2018	11000	12000	23000	11000	10000
04/09/2018	11000	14000	21000	12000	11000
05/09/2018	11000	13000	20000	11000	10000
06/09/2018	12000	15000	20000	12000	11000
07/09/2018	13000	15000	22000	13000	10000
08/09/2018	14000	17000	18000	14000	9000
09/09/2018	14000	18000	19000	16000	9000
10/09/2018	15000	19000	20000	16000	10000

6.2 Uji Coba Model RBFNN

Pada proses uji coba model dilakukan pengubahan persentase pembagian data dan penggunaan parameter yang dapat berpengaruh pada proses pelatihan model RBFNN. Pembagian data pelatihan dan data pengujian menggunakan persentase 75:25, 80:20, dan 90:10, sedangkan parameter yang diubah-ubah yaitu jumlah node pada lapisan tersembunyi. Hal tersebut dilakukan untuk mengetahui bagaimana kombinasi yang dapat menghasilkan minimum *error*.

Setelah menentukan parameter yang digunakan pada saat uji coba, selanjutnya dibuat skenario uji coba untuk mengetahui hasil pelatihan dan pengujian model RBFNN. Pemilihan hasil uji coba model dilakukan dengan memilih nilai MAPE terkecil yang diperoleh dari *trial and error* parameter jumlah node di setiap periode. Selanjutnya memilih nilai MAPE terkecil dari percobaan sepuluh periode sehingga dihasilkan periode yang optimal untuk melakukan peramalan.

6.2.1 Komoditas Bawang Merah

Pada Gambar 6.1 terlihat bahwa mulai pada *epochs* 200, nilai RMSE hampir tidak mengalami perubahan, sehingga nilai

epochs pada saat uji coba model komoditas bawang merah dapat dikurangi dari 1000 menjadi 200 *epochs* agar waktu yang dibutuhkan untuk uji coba model lebih efektif. Nilai RMSE yang dihasilkan pada Gambar 6.1 sangat kecil karena nilai variabel masukan berupa hasil normalisasi dengan *range* 0 sampai 1.

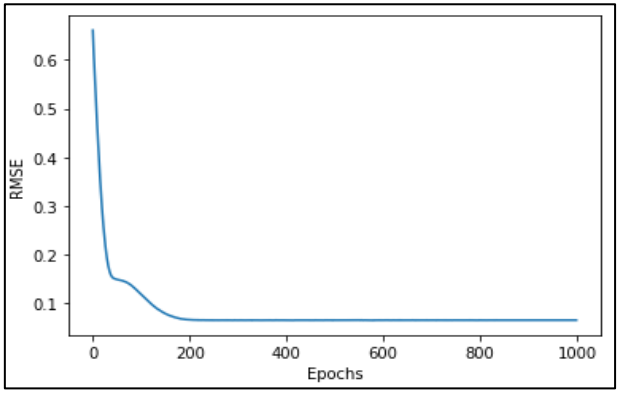

Gambar 6.1 Grafik Nilai RMSE tiap epochs pada Komoditas Bawang Merah

Pada komoditas bawang merah terdapat beberapa skenario yang dibangun untuk pengujian model dengan membandingkan nilai MAPE di setiap persentase pembagian data yaitu 75:25, 80:20, dan 90:10. Untuk nilai MAPE dan RMSE setiap periode pada proses uji coba komoditas bawang merah dapat dilihat pada **LAMPIRAN B**.

a. Pengujian dengan Persentase 75:25

   Pada Gambar 6.2 menunjukkan bahwa periode paling optimal terdapat pada periode 6. Hal ini dikarenakan periode 6 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

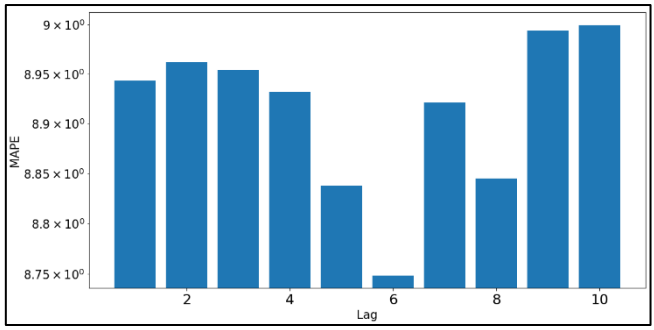

Gambar 6.2 Grafik Pengujian Komoditas Bawang Merah dengan Persentase 75:25

Gambar 6.3 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas bawang merah menggunakan persentase 75:25 saat menghasilkan nilai MAPE terkecil yaitu pada periode 6 sebesar 8.748%.

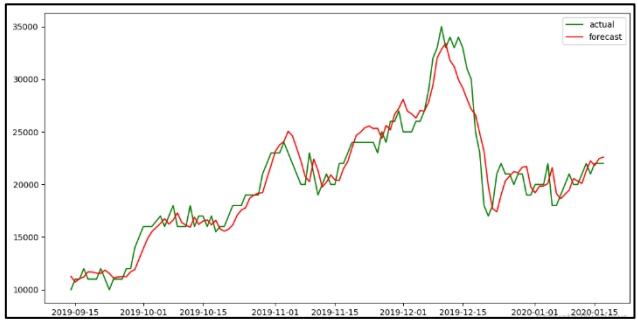

Gambar 6.3 Perbandingan Data Uji Aktual dan Peramalan Komoditas Bawang Merah Persentase 75:25

b. Pengujian dengan Persentase 80:20

Pada Gambar 6.4 menunjukkan bahwa periode paling optimal terdapat pada periode 10. Hal ini dikarenakan periode 10 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

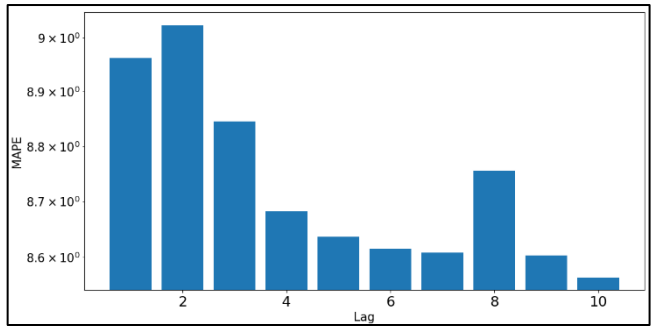

Gambar 6.4 Grafik Pengujian Komoditas Bawang Merah dengan Persentase 80:20

Gambar 6.5 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas bawang merah menggunakan persentase 80:20 saat menghasilkan nilai MAPE terkecil yaitu pada periode 10 sebesar 8.564%.

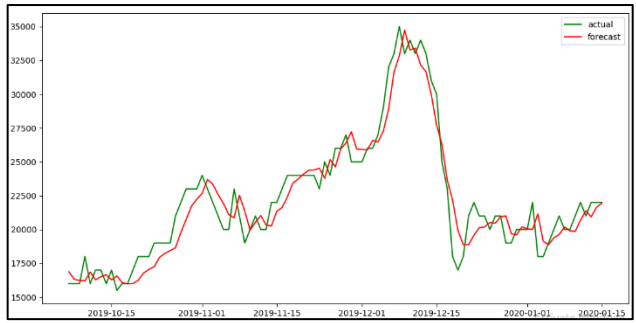

Gambar 6.5 Perbandingan Data Uji Aktual dan Peramalan Komoditas Bawang Merah Persentase 80:20

c. Pengujian dengan Persentase 90:10

Pada Gambar 6.6 menunjukkan bahwa periode paling optimal terdapat pada periode 8. Hal ini dikarenakan periode 8 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

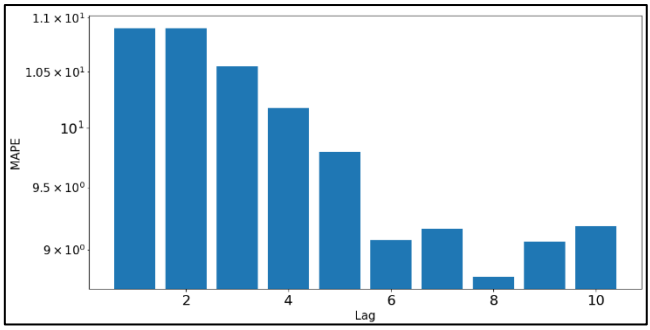

Gambar 6.6 Grafik Pengujian Komoditas Bawang Merah dengan Persentase 90:10

Gambar 6.7 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas bawang merah menggunakan persentase 90:10 saat menghasilkan nilai MAPE terkecil yaitu pada periode 8 sebesar 8.794%.

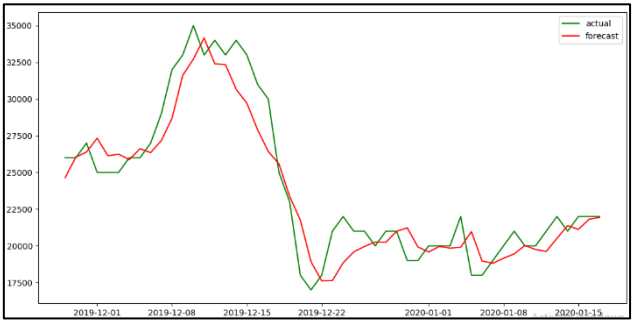

Gambar 6.7 Perbandingan Data Uji Aktual dan Peramalan Komoditas Bawang Merah Persentase 90:10

6.2.2 Komoditas Cabai Merah Keriting

Pada Gambar 6.8 terlihat bahwa mulai pada *epochs* 200, nilai RMSE hampir tidak mengalami perubahan, sehingga nilai *epochs* pada saat uji coba model komoditas cabai merah keriting dapat dikurangi dari 1000 menjadi 200 *epochs* agar waktu yang dibutuhkan untuk uji coba model lebih efektif. Nilai RMSE yang dihasilkan pada Gambar 6.8 sangat kecil karena nilai variabel masukan berupa hasil normalisasi dengan *range* 0 sampai 1.

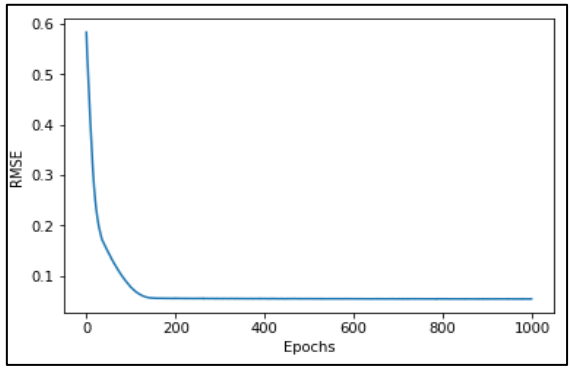

Gambar 6.8 Grafik Nilai RMSE tiap epochs pada Komoditas Cabai Merah Keriting

Pada komoditas cabai merah keriting terdapat beberapa skenario yang dibangun untuk pengujian model dengan membandingkan nilai MAPE pengujian di setiap persentase pembagian data yaitu 75:25, 80:20, dan 90:10. Untuk nilai MAPE dan RMSE setiap periode pada proses uji coba komoditas cabai merah keriting dapat dilihat pada **LAMPIRAN C**.

a. Pengujian dengan Persentase 75:25

   Pada Gambar 6.9 menunjukkan bahwa periode paling optimal terdapat pada periode 2. Hal ini dikarenakan periode 2 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

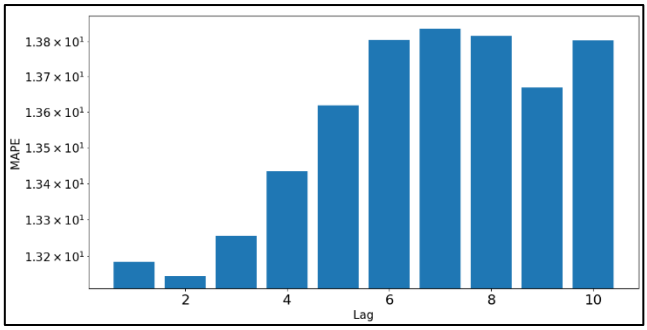

Gambar 6.9 Grafik Pengujian Komoditas Cabai Merah Keriting dengan Persentase 75:25

Gambar 6.10 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai merah keriting menggunakan persentase 75:25 saat menghasilkan nilai MAPE terkecil yaitu pada periode 2 sebesar 13.146%.

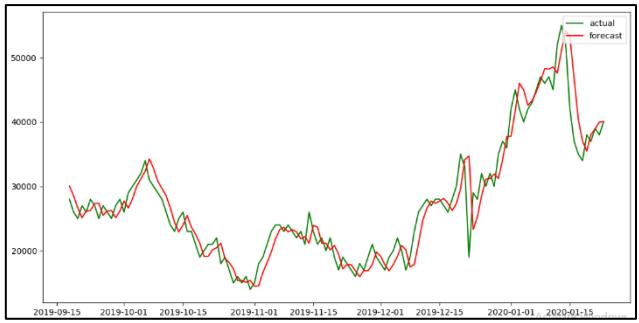

Gambar 6.10 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Keriting Persentase 75:25

b. Pengujian dengan Persentase 80:20

Pada Gambar 6.11 menunjukkan bahwa periode paling optimal terdapat pada periode 1. Hal ini dikarenakan periode 1 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

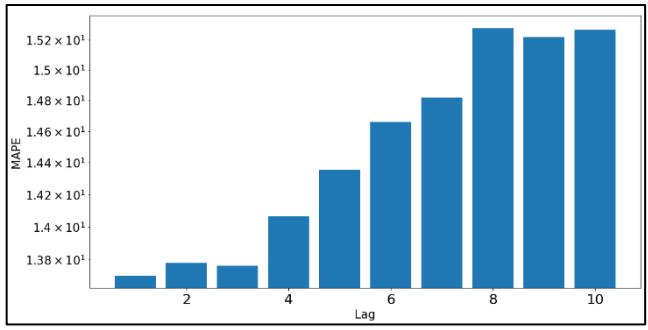

Gambar 6.11 Grafik Pengujian Komoditas Cabai Merah Keriting dengan Persentase 80:20

Gambar 6.12 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai merah keriting menggunakan persentase 80:20 saat menghasilkan nilai MAPE terkecil yaitu pada periode 1 sebesar 13.704%.

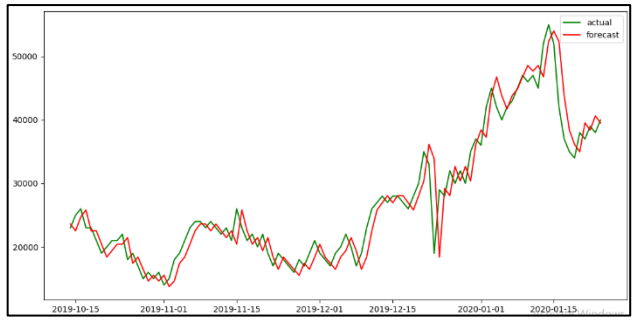

Gambar 6.12 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Keriting Persentase 80:20

c. Pengujian dengan Persentase 90:10

Pada Gambar 6.13 menunjukkan bahwa periode paling optimal terdapat pada periode 3. Hal ini dikarenakan periode 3 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

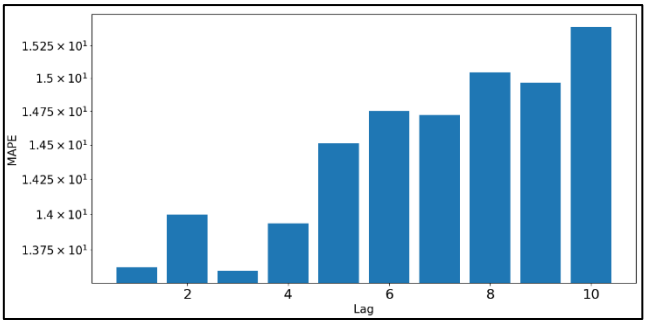

Gambar 6.13 Grafik Pengujian Komoditas Cabai Merah Keriting dengan Persentase 90:10

Gambar 6.14 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai merah keriting menggunakan persentase 90:10 saat menghasilkan nilai MAPE terkecil yaitu pada periode 3 sebesar 13.602%.

Gambar 6.14 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Keriting Persentase 90:10

6.2.3 Komoditas Cabai Merah Besar

Pada Gambar 6.15 terlihat bahwa mulai pada *epochs* 200, nilai RMSE hampir tidak mengalami perubahan, sehingga nilai *epochs* pada saat uji coba model komoditas cabai merah besar dapat dikurangi dari 1000 menjadi 200 *epochs* agar waktu yang dibutuhkan untuk uji coba model lebih efektif. Nilai RMSE yang dihasilkan pada Gambar 6.15 sangat kecil karena nilai

variabel masukan berupa hasil normalisasi dengan *range* 0 sampai 1.

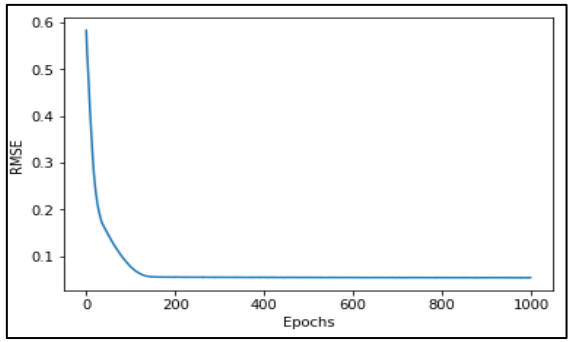

Gambar 6.15 Grafik Nilai RMSE tiap epochs pada Komoditas Cabai Merah Besar

Pada komoditas cabai merah besar terdapat beberapa skenario yang dibangun untuk pengujian model dengan membandingkan nilai MAPE pengujian di setiap persentase pembagian data yaitu 75:25, 80:20, dan 90:10. Untuk nilai MAPE dan RMSE setiap periode pada proses uji coba komoditas cabai merah besar dapat dilihat pada **LAMPIRAN D**.

a. Pengujian dengan Persentase 75:25

   Pada Gambar 6.16 menunjukkan bahwa periode paling optimal terdapat pada periode 1. Hal ini dikarenakan periode 1 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

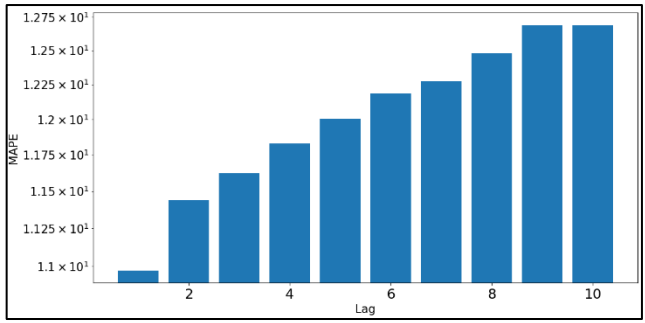

Gambar 6.16 Grafik Pengujian Komoditas Cabai Merah Besar dengan Persentase 75:25

Gambar 6.17 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai merah menggunakan persentase 75:25 saat menghasilkan nilai MAPE terkecil yaitu pada periode 1 sebesar 10.973%.

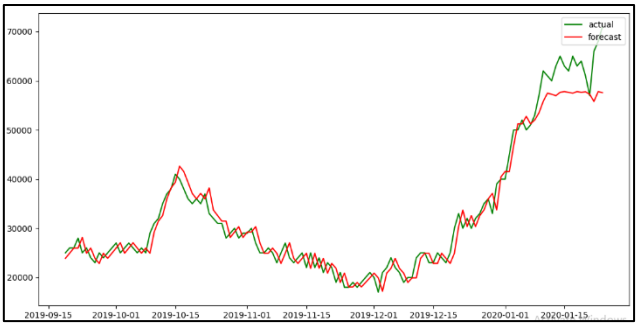

Gambar 6.17 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Besar Persentase 75:25

b. Pengujian dengan Persentase 80:20

Pada Gambar 6.18 menunjukkan bahwa periode paling optimal terdapat pada periode 1. Hal ini dikarenakan periode 1 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

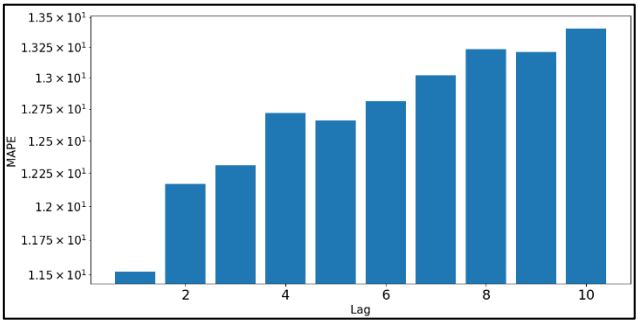

Gambar 6.18 Grafik Pengujian Komoditas Cabai Merah Besar dengan Persentase 80:20

Gambar 6.19 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai merah besar menggunakan persentase 80:20 saat menghasilkan

nilai MAPE terkecil yaitu pada periode 1 sebesar 11.520%.

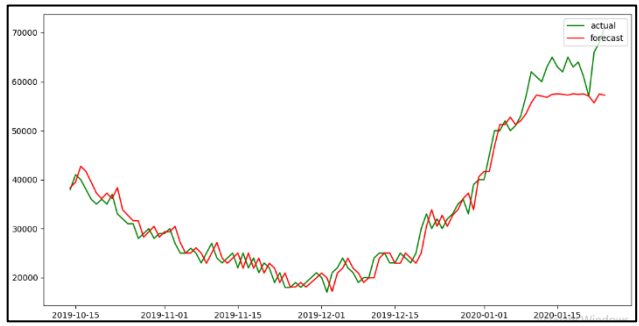

Gambar 6.19 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Besar Persentase 80:20

c. Pengujian dengan Persentase 90:10

Pada Gambar 6.20 menunjukkan bahwa periode paling optimal terdapat pada periode 2. Hal ini dikarenakan periode 2 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

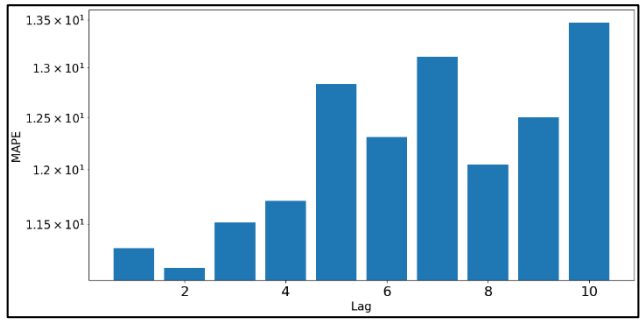

Gambar 6.20 Grafik Pengujian Komoditas Cabai Merah Besar dengan Persentase 90:10

Gambar 6.21 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai merah besar menggunakan persentase 90:10 saat menghasilkan nilai MAPE terkecil yaitu pada periode 2 sebesar 11.110%.

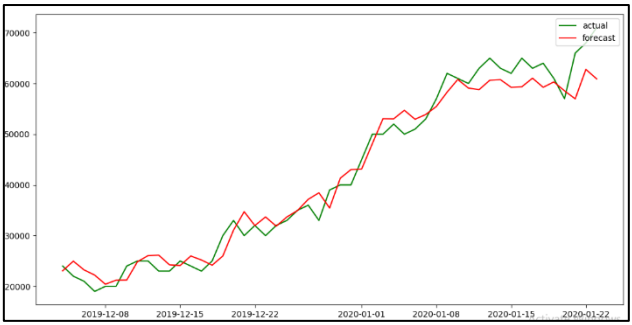

Gambar 6.21 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Merah Besar Persentase 90:10

6.2.4 Komoditas Cabai Rawit Merah

Pada Gambar 6.22 terlihat bahwa mulai pada *epochs* 200, nilai RMSE hampir tidak mengalami perubahan, sehingga nilai *epochs* pada saat uji coba model komoditas cabai rawit merah dapat dikurangi dari 1000 menjadi 200 *epochs* agar waktu yang dibutuhkan untuk uji coba model lebih efektif. Nilai RMSE yang dihasilkan pada Gambar 6.22 sangat kecil karena nilai variabel masukan berupa hasil normalisasi dengan *range* 0 sampai 1.

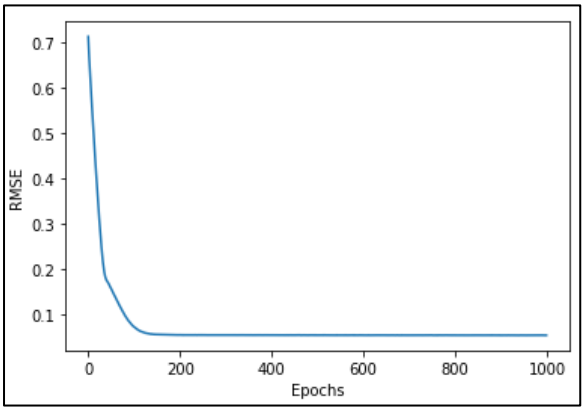

Gambar 6.22 Grafik Nilai RMSE tiap epochs pada Komoditas Cabai Rawit Merah

Pada komoditas cabai rawit merah terdapat beberapa skenario yang dibangun untuk pengujian model dengan membandingkan

nilai MAPE pengujian di setiap persentase pembagian data yaitu 75:25, 80:20, dan 90:10. Untuk nilai MAPE dan RMSE setiap periode pada proses uji coba komoditas cabai rawit merah dapat dilihat pada **LAMPIRAN E**.

a. Pengujian dengan Persentase 75:25

Pada Gambar 6.23 menunjukkan bahwa periode paling optimal terdapat pada periode 6. Hal ini dikarenakan periode 6 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

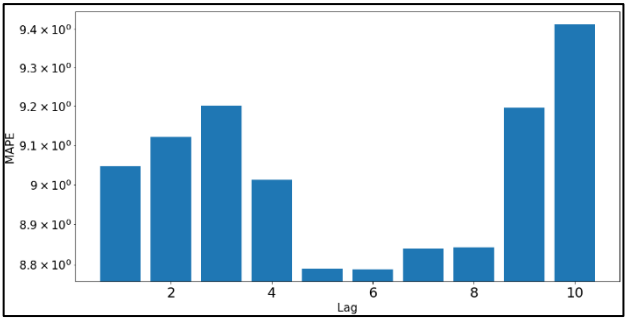

Gambar 6.23 Grafik Pengujian Komoditas Cabai Rawit Merah dengan Persentase 75:25

Gambar 6.24 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai rawit merah menggunakan persentase 75:25 saat menghasilkan nilai MAPE terkecil yaitu pada periode 6 sebesar 8.789%.

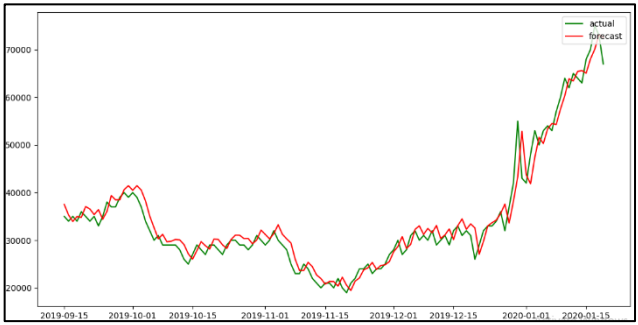

Gambar 6.24 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Merah Persentase 75:25

b. Pengujian dengan Persentase 80:20

Pada Gambar 6.25 menunjukkan bahwa periode paling optimal terdapat pada periode 8. Hal ini dikarenakan periode 8 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

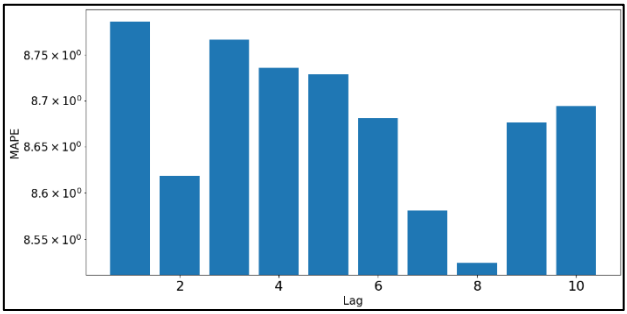

Gambar 6.25 Grafik Pengujian Komoditas Cabai Rawit Merah dengan Persentase 80:20

Gambar 6.26 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai rawit merah menggunakan persentase 80:20 saat menghasilkan nilai MAPE terkecil yaitu pada periode 8 sebesar 8.525%.

Gambar 6.26 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Merah Persentase 80:20

c. Pengujian dengan Persentase 90:10

Pada Gambar 6.27 menunjukkan bahwa periode paling optimal terdapat pada periode 10. Hal ini dikarenakan

periode 10 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

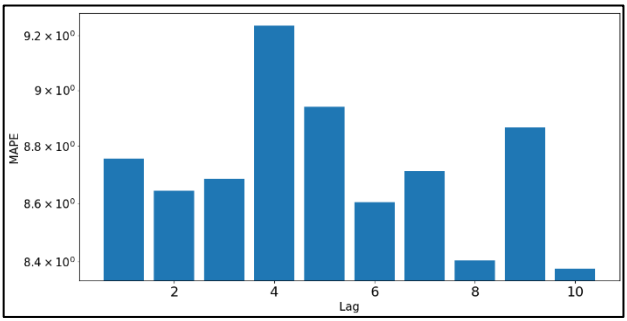

Gambar 6.27 Grafik Pengujian Komoditas Cabai Rawit Merah dengan Persentase 90:10

Gambar 6.28 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai rawit merah menggunakan persentase 90:10 saat menghasilkan nilai MAPE terkecil yaitu pada periode 10 sebesar 8.377%.

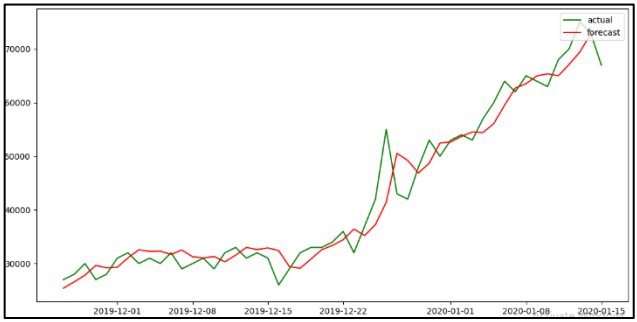

Gambar 6.28 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Merah Persentase 90:10

6.2.5 Komoditas Cabai Rawit Hijau

Pada Gambar 6.29 terlihat bahwa mulai pada *epochs* 200, nilai RMSE hampir tidak mengalami perubahan, sehingga nilai *epochs* pada saat uji coba model komoditas cabai rawit hijau dapat dikurangi dari 1000 menjadi 200 *epochs* agar waktu yang dibutuhkan untuk uji coba model lebih efektif. Nilai RMSE

yang dihasilkan pada Gambar 6.29 sangat kecil karena nilai variabel masukan berupa hasil normalisasi dengan *range* 0 sampai 1.

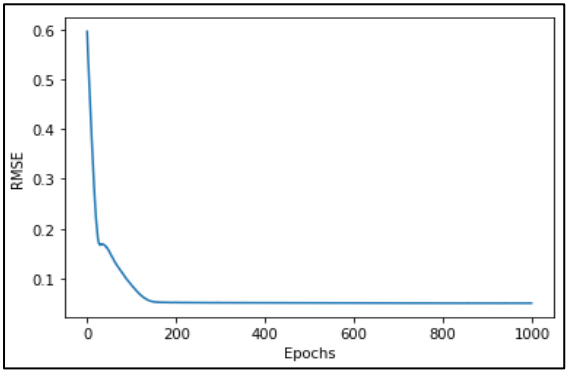

Gambar 6.29 Grafik Nilai RMSE tiap epochs pada Komoditas Cabai Rawit Hijau

Pada komoditas cabai rawit hijau terdapat beberapa skenario yang dibangun untuk pengujian model dengan membandingkan nilai MAPE pengujian di setiap persentase pembagian data yaitu 75:25, 80:20, dan 90:10. Untuk nilai MAPE dan RMSE setiap periode pada proses uji coba komoditas cabai rawit hijau dapat dilihat pada **LAMPIRAN F**.

a. Pengujian dengan Persentase 75:25

   Pada Gambar 6.30 menunjukkan bahwa periode paling optimal terdapat pada periode 5. Hal ini dikarenakan periode 5 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

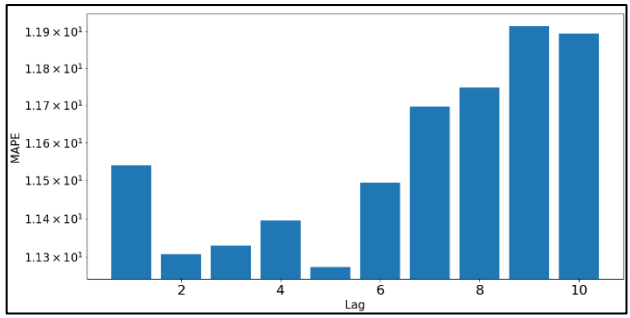

Gambar 6.30 Grafik Pengujian Komoditas Cabai Rawit Hijau dengan Persentase 75:25

Gambar 6.31 merupakan grafik perbandingan data aktual dan data peramalan pada data uji komoditas cabai rawit hijau menggunakan persentase 75:25 saat menghasilkan nilai MAPE terkecil yaitu pada periode 5 sebesar 11.274%.

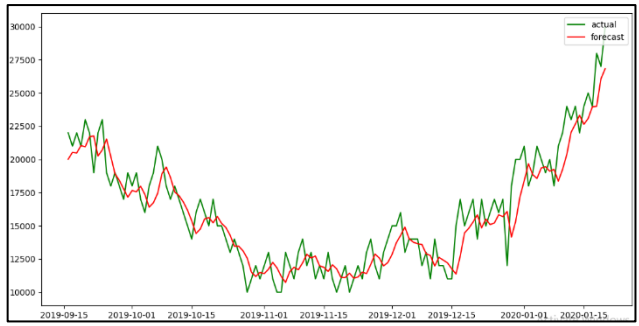

Gambar 6.31 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Hijau Persentase 75:25

b. Pengujian dengan Persentase 80:20

Pada Gambar 6.32 menunjukkan bahwa periode paling optimal terdapat pada periode 10. Hal ini dikarenakan periode 10 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

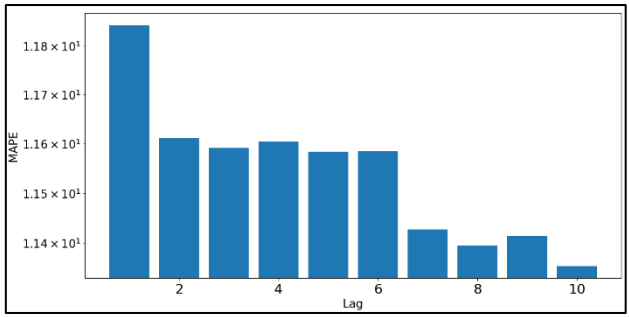

Gambar 6.32 Grafik Pengujian Komoditas Cabai Rawit Hijau dengan Persentase 80:20

Gambar 6.33 merupakan grafik perbandingan data aktual dan data peramalan pada data uji cabai rawit hijau menggunakan persentase 80:20 saat menghasilkan nilai MAPE terkecil yaitu pada periode 10 sebesar 11.354%.

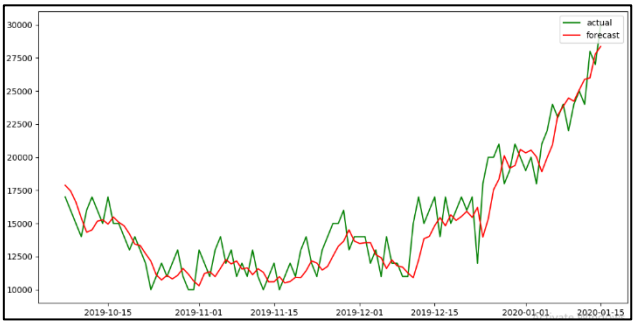

Gambar 6.33 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Hijau Persentase 80:20

c. Pengujian dengan Persentase 90:10

Pada Gambar 6.34 menunjukkan bahwa periode paling optimal terdapat pada periode 10. Hal ini dikarenakan periode 10 memiliki nilai MAPE paling kecil dibanding dengan periode yang lain.

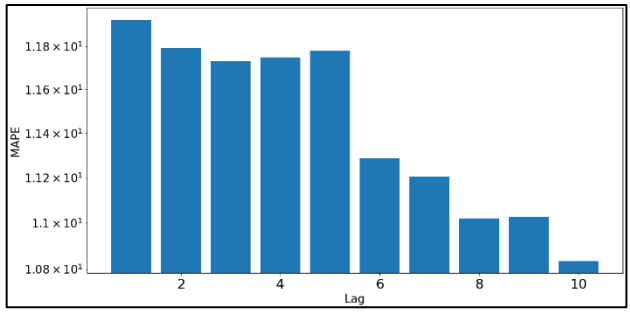

Gambar 6.34 Grafik Pengujian Komoditas Cabai Rawit Hijau dengan Persentase 90:10

Gambar 6.35 merupakan grafik perbandingan data aktual dan data peramalan pada data uji cabai rawit hijau menggunakan persentase 80:20 saat menghasilkan nilai MAPE terkecil yaitu pada periode 10 sebesar 10.834%.

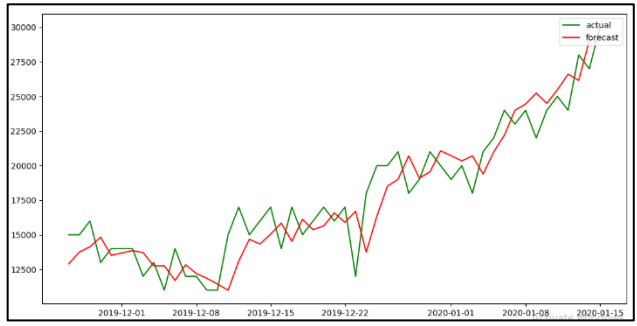

Gambar 6.35 Perbandingan Data Uji Aktual dan Peramalan Komoditas Cabai Rawit Hijau Persentase 90:10

6.3 Pemilihan Model Optimal

Setelah melakukan tahap uji coba model RBFNN akan didapat nilai akurasi dari setiap skenario dan parameter. Pada tahap ini dilakukan pemilihan model paling optimal untuk setiap komoditas yang ditentukan menggunakan MAPE dan diakhiri dengan perhitungan rata-rata nilai MAPE optimal dari semua komoditas untuk mengetahui performa RBFNN, seperti yang ditunjukkan oleh Tabel 6.2.

Table 6.2 Model Paling Optimal di setiap Komoditas

Komoditas	Persentase	Periode	MAPE	RMSE
Bawang Merah	80:20	4	8.564%	2561.992
Cabai Merah Keriting	75:25	21	13.146%	4891.733
Cabai Merah Besar	75:25	1	10.973%	5547.738
Cabai Rawit Merah	80:20	12	8.525%	4507.603
Cabai Rawit Hijau	90:10	19	10.835%	2322.133
Rata-rata			**10.409%**	**3966.240**

6.4 Peramalan Model RBFNN

Pada sub bab ini dijelaskan hasil peramalan harga komoditas bawang merah dan cabai di Pasar Induk Kramat Jati Provinsi DKI Jakarta. Peramalan dilakukan pada 7 hari mendatang menggunakan model paling optimal dari proses uji coba.

6.4.1 Komoditas Bawang Merah

Gambar 6.36 merupakan hasil peramalan 7 hari mendatang pada komoditas bawang merah menggunakan persentase data yang paling optimal, yaitu 80:20. Persentase tersebut memiliki MAPE paling kecil dari persentase lainnya pada komoditas bawang merah sebesar 8.564%.

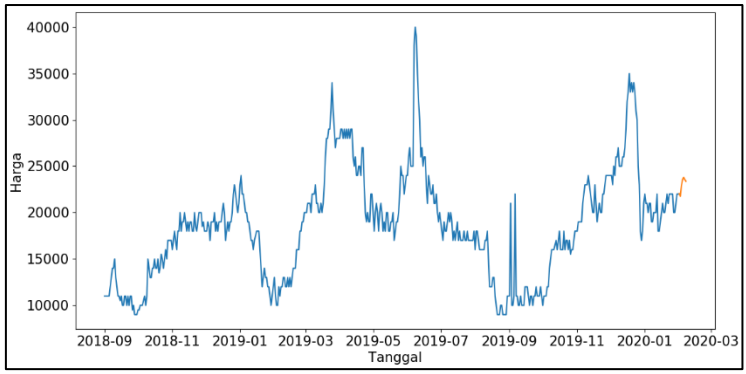

Gambar 6.36 Hasil Prediksi Komoditas Bawang Merah

6.4.2 Komoditas Cabai Merah Keriting

Gambar 6.37 merupakan hasil peramalan 7 hari mendatang pada komoditas cabai merah keriting menggunakan persentase data yang paling optimal, yaitu 75:25. Persentase tersebut memiliki MAPE paling kecil dibanding persentase lainnya pada komoditas cabai merah keriting sebesar 13.146%.

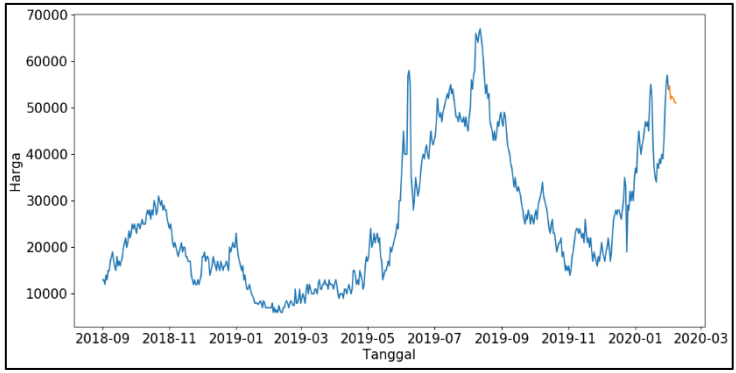

Gambar 6.37 Hasil Prediksi Komoditas Cabai Merah Keriting

6.4.3 Komoditas Cabai Merah Besar

Gambar 6.38 merupakan hasil peramalan 7 hari mendatang pada komoditas cabai merah besar menggunakan persentase data yang paling optimal, yaitu 75:25. Persentase tersebut memiliki

MAPE paling kecil dibanding persentase lainnya pada komoditas cabai merah besar sebesar 10.973%.

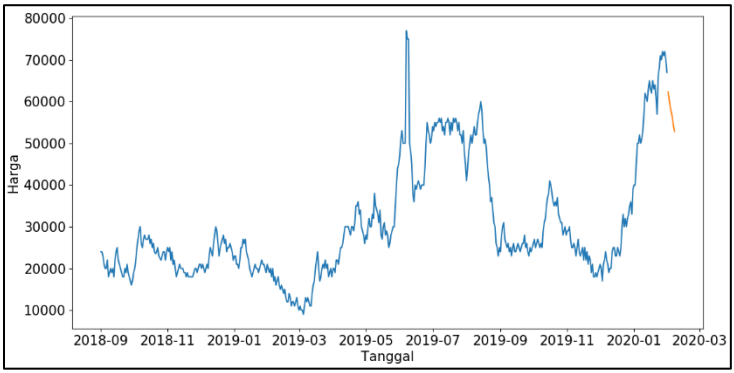

Gambar 6.38 Hasil Prediksi Komoditas Cabai Merah Besar

6.4.4 Komoditas Cabai Rawit Merah

Gambar 6.39 merupakan hasil peramalan 7 hari mendatang pada komoditas cabai rawit merah menggunakan persentase data yang paling optimal, yaitu 80:20. Persentase tersebut memiliki MAPE paling kecil dibanding persentase lainnya pada komoditas cabai rawit merah sebesar 8.525%.

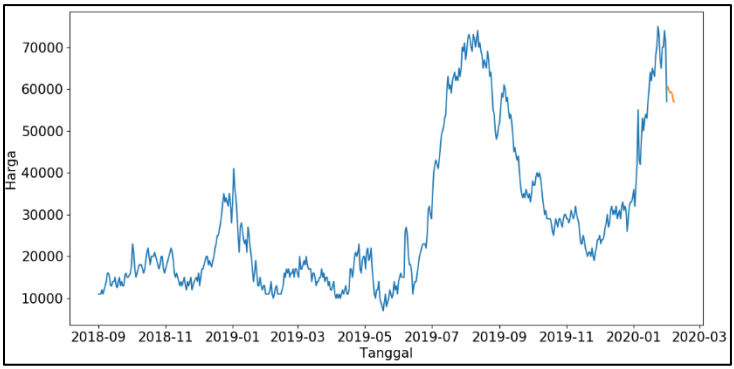

Gambar 6.39 Hasil Prediksi Komoditas Cabai Rawit Merah

6.4.5 Komoditas Cabai Rawit Hijau

Gambar 6.40 merupakan hasil peramalan 7 hari mendatang pada komoditas cabai rawit hijau menggunakan persentase data yang paling optimal, yaitu 90:10. Persentase tersebut memiliki MAPE paling kecil dibanding persentase lainnya pada komoditas cabai rawit hijau sebesar 10.835%.

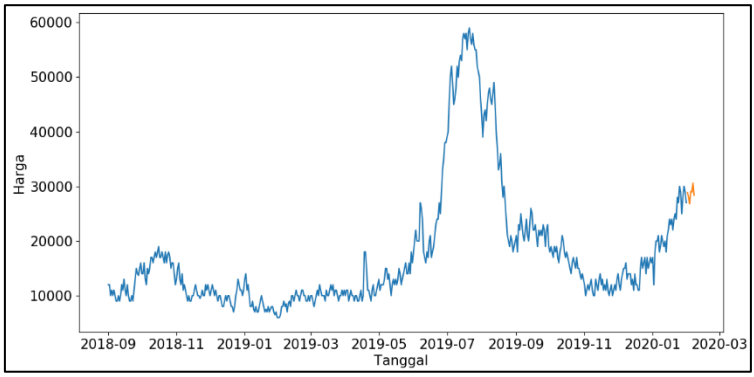

Gambar 6.40 Hasil Prediksi Komoditas Cabai Rawit Hijau

Halaman ini sengaja dikosongkan.

BAB VI
KESIMPULAN DAN SARAN

Pada bab ini dibahas mengenai kesimpulan dari semua proses yang telah dilakukan dan saran yang dapat diberikan untuk pengembangna yang lebih baik.

7.1 Kesimpulan

Berdasarkan pembahasan mengenai peramalan harga komoditas bawang merah dan cabai di Pasar Induk Kramat Jati DKI Jakarta dengan menggunakan metode Radial Basis Function Neural Network (RBFNN) dapat diperoleh kesimpulan sebagai berikut:

1. Hasil *trial and error* menggunakan parameter *hidden neuron* dengan interval 1 sampai 30 membuat nilai MAPE pada komoditas bawang merah, cabai merah keriting, cabai rawit merah, dan cabai rawit hijau menjadi lebih optimal dari pada hanya menggunakan 1 *hidden neuron*. Namun, *trial and error* pada parameter *hidden neuron* tidak berperan signifikan pada komoditas cabai merah besar karena MAPE optimal terdapat pada *hidden neuron* 1 sehingga tidak efektif jika melakukan *trial and error*.

2. Performa metode RBFNN terhadap data harga komoditas bawang merah cabai di Pasar Induk Kramat Jati DKI Jakarta dapat dikatakan cukup akurat dengan rata-rata MAPE 10.409%, karena MAPE tersebut memiliki akurasi di bawah 20%. Namun, akurasi tersebut masih cukup rendah jika dibandingkan penelitian sebelumnya yang mampu menghasilkan MAPE 2.22% menggunakan metode ARIMA.

3. Pada hasil peramalan harga komoditas bawang merah dan cabai rawit hijau cenderung mengalami peningkatan, sedangkan pada harga komoditas cabai merah keriting,

cabai merah besar, dan cabai rawit merah mengalami penurunan.

4. Upaya yang dapat dilakukan pemerintah untuk menstabilkan peningkatan harga komoditas bawang merah dan cabai rawit hijau yaitu dengan menerapkan kebijakan harga yang tepat berdasarkan hasil peramalan pada penelitian ini. Kebijakan harga ini bertujuan untuk melindungi produsen dan konsumen melalui penetapan harga minimum secara sah dalam bentuk peraturan oleh pemerintah dimana harga komoditas yang dijual produsen ditentukan batas minimalnya.

7.2 Saran

Berdasarkan pembahasan mengenai peramalan harga komoditas bawang merah dan cabai di Pasar Induk Kramat Jati DKI Jakarta dengan menggunakan metode Radial Basis Function Neural Network (RBFNN) dapat diperoleh kesimpulan sebagai berikut:

1. Dalam Tugas Akhir ini pada proses uji coba model RBFNN hanya menggunakan *hidden neuron* dengan nilai 1 sampai 30. Untuk penelitian selanjutnya dapat melakukan *trial and error* pada parameter *hidden neuron* dengan nilai 1 sampai 100 agar nilai MAPE yang dihasilkan dapat lebih kecil.
2. Dapat ditambahkan variabel-variabel lain yang mungkin memiliki pengaruh terhadap peningkatan harga pada komoditas bawang merah dan cabai, seperti curah hujan dan tingkat inflas

DAFTAR PUSTAKA

[1] F. N. Hardiansyah, "Prediksi Harga Cabai dengan Pemodelan Time Series ARIMA," *Indonesian Journal on Computing* , vol. 2, pp. 71-78, 2017.

[2] M. Farid , B. Wicaksena and Y. Nuryati, "Analisis Kebijakan Harga Pada Komoditas Pertanian," KEMENTERIAN PERDAGANGAN , 2014.

[3] M. F. d. N. A. Subekti, "Tinjauan terhadap produksi, konsumsi, distribusi dan dinamika harga cabe di Indonesia," *Buletin Ilmiah, Litbang Perdagangan,* p. 211–233, 2012.

[4] M. A. Rasyidi, "Prediksi Harga Bahan Pokok Nasional Jangka Pendek Menggunakan ARIMA," *Journal of Information Systems Engineering and Business Intelligence,* vol. 2, 2017.

[5] F. Juliaristi, PERAMALAN BANYAK KASUS DEMAM BERDARAH DI D.I.Y DENGAN MODEL RADIAL BASIS FUNCTION, Yogyakarta, 2014.

[6] V. &. B. V. R. C. &. G. G. Jadhav, "Application of ARIMA Model for Forecasting Agricultural Prices," *Journal of Agricultural Science and Technology,* vol. 19, pp. 981-992, 2017.

[7] M. L. Ditakristy, D. Saepuddin and F. Nhita, "Analisis dan Implementasi Radial Basis Function Neural Network dalam Prediksi Harga Komoditas Pertanian," 2016.

[8] A. Suryana, "Menelisik Ketahanan Pangan, Kebijakan Pangan dan Swasembada Beras," 2008.

[9] N. Nachrowi, Teknik Pengambilan Keputusan,, Jakarta: Grasindo, 2004.

[10] S. Makridakis, Metode dan Aplikasi Peramalan Edisi Kedua, Jakarta: Erlangga, 1998.

[11] X. G. C. W. d. D. W. W. Shen, "Forecasting stock indices using radial basis function neural networks optimized by

artificial fish swarm algorithm," *Knowlege-Based System*, vol. 24, pp. 378-385, 2011.

[12] Orr, Introduction to Radial Basis Function Networks, Edinburgh: University of Edinburgh,, 1996.

[13] I. A. R. a. M. E. Noor Y.B. Zainun, "Forecasting low-cost housing demand in Johor Bahru, Malaysia using artificial neural networks (ANN)," *Journal of Mathematics Research*, vol. 2, pp. 14-19, 2010.

[14] H. S. P. H. M. Dhita Deviacita Ayani, "Implementasi Web Scraping untuk Pengambilan Data pada Situs Marketplace," *Jurnal Sistem dan Teknologi Informasi*, vol. 7, no. 4, 2019.

[15] C. Varvello, "The optimal omnichannel strategy for SMEs Apparel retailers," Universidade Católica Portuguesa, Lisbon, 2019.

[16] S. A. S. M. A. A. M. A. T. K. Jawahire Nakash*, "Real Time Product Analysis using Data Mining," *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)* , vol. 4, no. 3, p. 815, 2015.

[17] A. M. S. A. D. K. S. N. B. U. S. D.Pratiba, "Web Scraping dan Data Acquisition Using Google Scholarq," in *Computational Systems and Information Technology for Sustainable Solutions*, Bangalore, 2018.

[18] I. Primiana, "Menggerakkan Sektor Riil UKM &Industri," Alfabeta, Bandung, 2009.

[19] F. Juliaristi, PERAMALAN BANYAK KASUS DEMAM BERDARAH DI D.I.Y DENGAN MODEL RADIAL BASIS FUNCTION, Yogyakarta, 2014.

BIODATA PENULIS

Penulis lahir di Surabaya pada tanggal 05 Mei 1998 dan merupakan anak pertama dari tiga bersaudara pasangan Bapak Muhammad Solihin Arianto dan Ibu Indaryanti. Penulis menempuh Pendidikan formal di SD Negri 1 Kalasan, SMP Negri 1 Kalasan dan SMA Negri 6 Yogyakarta.

Pada tahun 2016 penulis melanjutkan Pendidikan jenjang sarjana dengan jalur SNMPTN di Departemen Sistem Informasi, Fakultas Teknologi Elektro dan Informatika Cerdas (F-Electics), Institut Teknologi Sepuluh Nopember(ITS), Surabaya dan terdaftar sebagai mahasiswa dengan NRP 05211640000027. Selama masa perkuliahan penulis aktif mengikuti organisasi kerohanian mahasiswa, seperti Kajian Islam Sistem Informasi (KISI) dan Jamaah Masjid Manarul Ilmi (JMMI). Penulis juga aktif dalam mengikuti lomba di bidang *Data Science and Analytics* dengan pernah menjadi Juara Favorit 1 Lomba Data Analisis tingkat Nasional di Universitas Padjajaran tahun 2019.

Pada tahun keempat, penulis memilih untuk fokus di bidang Pengolahan Data khususnya *Forecasting* dan *Data Analytics*. Oleh karena itu, penulis terdaftar sebagai mahasiswa tugas akhir di Laboratorium Rekayasa Data dan Intelegensi Bisnis, Departemen Sistem Informasi, ITS. Penulis dapat dihubungi melalui email saifudnm@gmail.com.

LAMPIRAN A. PERBANDINGAN HARGA KOMODITAS BAWANG MERAH

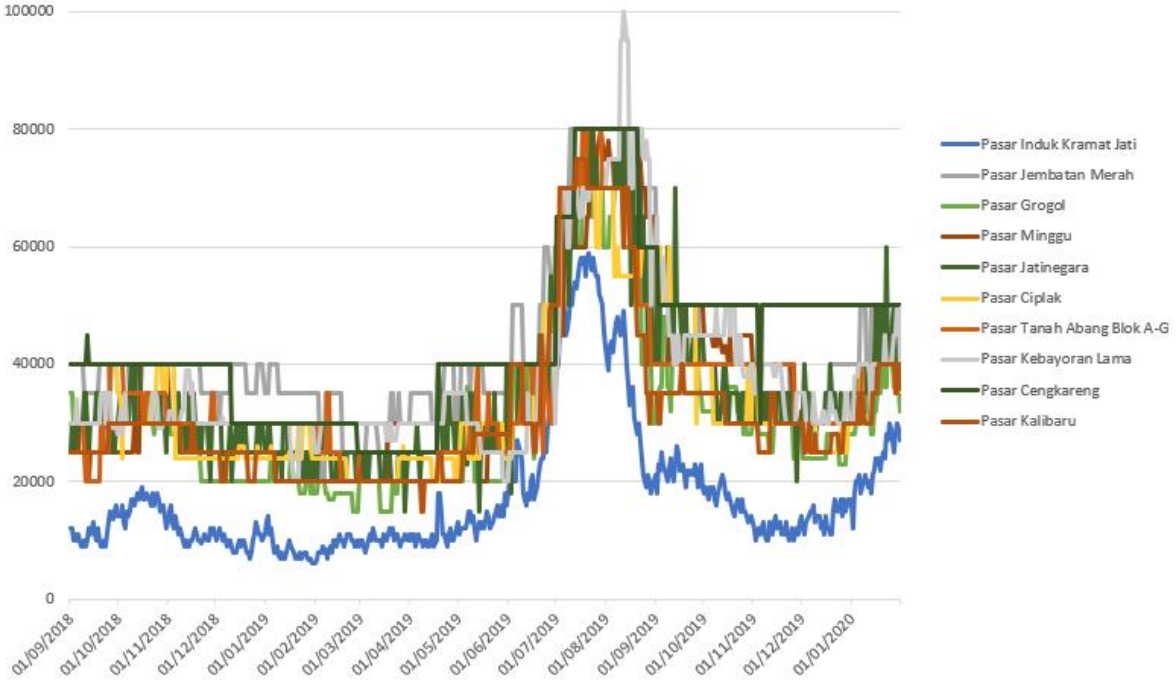

LAMPIRAN B. HASIL UJI COBA KOMODITAS BAWANG MERAH

Lampiran ini menunjukkan hasil dari proses uji coba model RBFNN di semua periode pada komoditas bawang merah menggunakan persentase pembagian data yang berbeda, yaitu 75:25, 80:20, dan 90:10.

Persentase Data	**Periode**	**Minimal MAPE**	**Jumlah Node**	**RMSE**
75:25	1	8.943%	24	2661.684
	2	8.962%	23	2661.662
	3	8.954%	9	2609.977
	4	8.932%	13	2573.820
	5	8.838%	15	2546.975
	6	8.749%	30	2474.278
	7	8.921%	23	2519.026
	8	8.845%	5	2453.380
	9	8.994%	22	2498.246
	10	9.000%	15	2497.903
80:20	1	8.962%	11	2873.499
	2	9.023%	25	2851.312
	3	8.845%	15	2771.277
	4	8.682%	13	2681.165
	5	8.636%	5	2613.265
	6	8.616%	9	2609.631
	7	8.608%	10	2572.451
	8	8.756%	6	2646.547
	9	8.603%	5	2550.641
	10	8.564%	4	2561.992
90:10	1	10.903%	16	3645.473
	2	10.902%	26	3625.317
	3	10.551%	5	3448.009
	4	10.176%	15	3320.503
	5	9.794%	5	3143.162
	6	9.077%	5	2969.442
	7	9.163%	1	2974.045
	8	8.794%	5	2885.987
	9	9.063%	4	2942.530
	10	9.188%	2	3032.467

LAMPIRAN C. HASIL UJI COBA KOMODITAS CABAI MERAH KERITING

Lampiran ini menunjukkan hasil dari proses uji coba model RBFNN di semua periode pada komoditas cabai merah keriting menggunakan persentase pembagian data yang berbeda, yaitu 75:25, 80:20, dan 90:10.

Persentase Data	Periode	Minimal MAPE	Jumlah Node	RMSE
75:25	1	13.184%	14	4957.783
	2	13.146%	21	4891.733
	3	13.257%	15	4937.977
	4	13.434%	29	5075.092
	5	13.619%	24	5161.42
	6	13.805%	10	5091.119
	7	13.837%	16	5108.298
	8	13.816%	14	5180.458
	9	13.668%	7	5074.068
	10	13.803%	12	5157.41
80:20	1	13.704%	1	5257.434
	2	13.779%	11	5113.749
	3	13.762%	8	5145.312
	4	14.065%	11	5161.910
	5	14.355%	8	5363.395
	6	14.660%	5	6570.479
	7	14.819%	4	6758.931
	8	15.278%	10	7006.019
	9	15.219%	21	6677.484
	10	15.264%	29	6707.342
90:10	1	13.626%	11	6279.462
	2	13.998%	21	6453.944
	3	13.602%	14	6312.664
	4	13.934%	19	6424.306
	5	14.513%	25	6574.558
	6	14.750%	15	6713.205
	7	14.720%	20	6738.287

	8	15.044%	11	6826.649
	9	14.966%	15	6705.864
	10	15.397%	19	6872.607

LAMPIRAN D. HASIL UJI COBA KOMODITAS CABAI MERAH BESAR

Lampiran ini menunjukkan hasil dari proses uji coba model RBFNN di semua periode pada komoditas cabai merah besar menggunakan persentase pembagian data yang berbeda, yaitu 75:25, 80:20, dan 90:10.

Persentase Data	Periode	Minimal MAPE	Jumlah Node	RMSE
75:25	1	10.973%	1	5547.738
	2	11.439%	9	5986.145
	3	11.621%	30	6229.320
	4	11.828%	23	6572.144
	5	12.003%	19	6596.409
	6	12.184%	25	7080.031
	7	12.272%	30	7334.475
	8	12.478%	13	7440.191
	9	12.689%	15	7785.354
	10	12.689%	27	7991.211
80:20	1	11.520%	1	5905.952
	2	12.169%	23	6538.829
	3	12.311%	18	6876.670
	4	12.720%	29	7000.207
	5	12.657%	23	7490.067
	6	12.812%	18	7767
	7	13.018%	30	7567.299
	8	13.235%	15	7851.239
	9	13.210%	29	8211.96
	10	13.407%	20	8225.324
90:10	1	11.280%	24	6852.511
	2	11.110%	18	6956.819
	3	11.516%	28	7551.009
	4	11.711%	28	7668.395
	5	12.835%	29	8475.662
	6	12.310%	16	8702.736
	7	13.115%	18	9199.614

	8	12.046%	21	8956.097
	9	12.506%	22	9612.305
	10	13.473%	13	10370.96

LAMPIRAN E. HASIL UJI COBA KOMODITAS CABAI RAWIT MERAH

Lampiran ini menunjukkan hasil dari proses uji coba model RBFNN di semua periode pada komoditas cabai rawit merah menggunakan persentase pembagian data yang berbeda, yaitu 75:25, 80:20, dan 90:10.

Persentase Data	Periode	Minimal MAPE	Jumlah Node	RMSE
75:25	1	9.047%	18	4545.938
	2	9.121%	15	4513.317
	3	9.202%	21	4548.949
	4	9.011%	29	4521.048
	5	8.789%	15	4457.142
	6	8.789%	25	4317.43
	7	8.840%	23	4441.866
	8	8.843%	23	4354.554
	9	9.196%	16	4513.334
	10	9.414%	27	4540.921
80:20	1	8.787%	28	4444.640
	2	8.618%	28	4241.848
	3	8.767%	25	4520.161
	4	8.736%	9	4434.585
	5	8.729%	28	4478.912
	6	8.681%	16	4419.380
	7	8.581%	24	4351.635
	8	8.525%	12	4507.603
	9	8.676%	30	4253.742
	10	8.694%	8	4523.056
90:10	1	8.755%	18	5502.487
	2	8.644%	27	5351.539
	3	8.686%	23	5553.957
	4	9.238%	28	5819.152
	5	8.940%	21	5629.579
	6	8.602%	12	5526.603
	7	8.711%	11	5452.323

	8	8.403%	8	5312.433
	9	8.866%	23	5179.737
	10	8.477%	5	5386.198

LAMPIRAN F. HASIL UJI COBA KOMODITAS CABAI RAWIT HIJAU

Lampiran ini menunjukkan hasil dari proses uji coba model RBFNN di semua periode pada komoditas cabai rawit hijau menggunakan persentase pembagian data yang berbeda, yaitu 75:25, 80:20, dan 90:10.

Persentase Data	**Periode**	**Minimal MAPE**	**Jumlah Node**	**RMSE**
75:25	1	11.540%	1	2472.871
	2	11.306%	5	2388.151
	3	11.330%	4	2273.767
	4	11.394%	5	2275.489
	5	11.274%	5	2277.055
	6	11.494%	3	2334.58
	7	11.697%	4	2323.002
	8	11.747%	7	2339.166
	9	11.915%	13	2365.943
	10	11.895%	27	2393.133
80:20	1	11.843%	1	2472.298
	2	11.611%	4	2322.707
	3	11.592%	4	2237.543
	4	11.605%	13	2331.354
	5	11.584%	18	2235.605
	6	11.585%	14	2250.659
	7	11.428%	10	2215.768
	8	11.395%	8	2221.826
	9	11.415%	18	2190.466
	10	11.355%	8	2136.135
90:10	1	11.924%	15	2641.892
	2	11.790%	13	2668.413
	3	11.731%	12	2443.033
	4	11.748%	19	2582.462
	5	11.778%	8	2585.418
	6	11.285%	22	2428.944
	7	11.202%	19	2424.287

	8	11.019%	17	2338.425
	9	11.027%	27	2409.414
	10	10.835%	19	2322.133