

Prediksi Luas Sebaran Hama Wareng pada Tanaman Padi dengan RNN Time Series

Selvi Wulandari^{*1}, Putu Sugiartawan², I Made Dedy Setiawan³

^{1,2,3}Program Studi Teknik Informatika, STMIK STIKOM Indonesia, Denpasar, Indonesia

e-mail ¹selviwulandari408@stiki-indonesia.ac.id, ²sugiartawan@stiki-indonesia.ac.id,

³fittryani@stiki-indonesia.ac.id

Abstrak

Di Indonesia, padi sangatlah penting sebagai makanan pokok. Namun, hama wereng batang coklat (WBC) sering mengganggu produksi padi, khususnya di Kabupaten Gianyar, dan mengancam produktivitas pertanian. Oleh karena itu, dibutuhkan suatu prediksi untuk meminimalkan kegagalan panen dan meningkatkan produktivitas padi. Untuk melakukan hal tersebut, sebuah dataset time series dengan 120 data tentang sebaran hama wereng dari tahun 2012 hingga 2021 digunakan. Data tersebut dibagi menjadi 90% data latih dan 10% data uji. Dengan menggunakan arsitektur Recurrent Neural Network (RNN), sebuah model dengan performa terbaik memiliki nilai rata-rata Root Mean Square Error (RMSE) minimal sebesar 10.0503, dengan 500 epoch, learning rate sebesar 0.007, 5 neuron pada input layer, dan 80 neuron pada hidden layer. Model tersebut juga mencapai nilai Mean Absolute Percentage Error (MAPE) sebesar 16.64%, menunjukkan performa prediksi yang baik. Hasil prediksi ini dapat menjadi dukungan keputusan bagi laboratorium untuk mengembangkan strategi peningkatan produktivitas padi.

Kata kunci— prediksi, time series, recurrent neural network, hama wereng batang coklat

Abstract

Rice is a crucial crop in Indonesia as it serves as a staple food. However, rice production is frequently hindered by pests, particularly the brown planthopper (BPH), which poses a serious threat to agricultural productivity in Gianyar District. To minimize crop failures and enhance productivity, predicting the spread of BPH on rice plants is crucial. In this study, a time series dataset consisting of 120 data points on BPH distribution from 2012 to 2021 was utilized. The data was split into 90% training data and 10% testing data. By employing the Recurrent Neural Network (RNN) architecture, the best-performing model achieved a minimal Root Mean Square Error (RMSE) value of 10.0503, with 500 epochs, a learning rate of 0.007, 5 neurons in the input layer, and 80 neurons in the hidden layer. This model also achieved a Mean Absolute Percentage Error (MAPE) value of 16.64%, indicating good predictive performance. The predictive results can be used by laboratories as decision support for rice productivity improvement strategies.

Keywords—forecasting, time series, recurrent neural network, brown planthopper pest

1. PENDAHULUAN

Padi adalah tanaman pokok penting yang menjadi sumber makanan utama bagi lebih dari setengah populasi dunia. Di Indonesia, padi merupakan komoditas utama yang mendukung kebutuhan pangan penduduk [1]. Namun, produksi padi di Indonesia seringkali terancam oleh Organisme Pengganggu Tanaman (OPT), terutama hama. Hama utama yang sering mengganggu produktivitas padi adalah wereng coklat, karena serangga kecil ini menghisap getah dari tanaman padi dan menyebarkan virus yang menyebabkan tanaman padi terinfeksi penyakit [2]. Akibatnya, tanaman padi menjadi kering dan layu dalam semalam, yang mengakibatkan gagal panen bagi petani. Untuk mengatasi penyebaran hama ini, petani telah beralih pada penggunaan pestisida yang berlebihan, yang dapat mengganggu keseimbangan ekosistem.

Kantor Perlindungan Tanaman dan Hortikultura Bali (BPTPH) mencatat tingkat infestasi wereng coklat pada tanaman padi di setiap kabupaten di Bali. Diketahui bahwa kabupaten Gianyar memiliki tingkat infestasi wereng coklat tertinggi antara tahun 2012 dan 2021 dibandingkan dengan kabupaten lainnya. Penyebaran wereng coklat pada tanaman padi menimbulkan ancaman bagi produktivitas pertanian, terutama di kabupaten Gianyar yang telah mengalami gagal panen akibat hama ini. Oleh karena itu, dibutuhkan model prediksi untuk meningkatkan produktivitas dan meminimalkan dampak gagal panen padi.

Prediksi adalah proses memperkirakan apa yang akan terjadi di masa depan dengan memanfaatkan informasi relevan dari waktu sebelumnya (historis) melalui metode ilmiah. Untuk memprediksi penyebaran hama pada padi, diperlukan rentang data deret waktu yang luas tentang infestasi hama pada masa lalu untuk dianalisis guna mengidentifikasi pola yang dapat memperkirakan kondisi di masa depan. Data deret waktu adalah data yang diatur berdasarkan urutan waktu atau data yang dikumpulkan dari waktu ke waktu. Data tersebut dapat diukur dalam detik, menit, jam, hari, minggu, bulan, atau tahun. Salah satu metode yang dapat digunakan untuk memprediksi data deret waktu adalah dengan menggunakan model Recurrent Neural Network (RNN) [3], [4].

Recurrent Neural Network (RNN) memiliki kemampuan yang sangat baik dalam memproses data deret waktu. RNN adalah jenis arsitektur Neural Network yang secara berulang-ulang memproses data input, yang biasanya merupakan data berurutan. Data berurutan memiliki karakteristik di mana sampel data diproses dalam urutan tertentu (seperti waktu), dan satu sampel dalam urutan tersebut memiliki hubungan yang erat dengan sampel berikutnya. Data infestasi hama padi yang luas dapat diklasifikasikan sebagai data berurutan karena diproses dalam urutan waktu.

2. METODE PENELITIAN

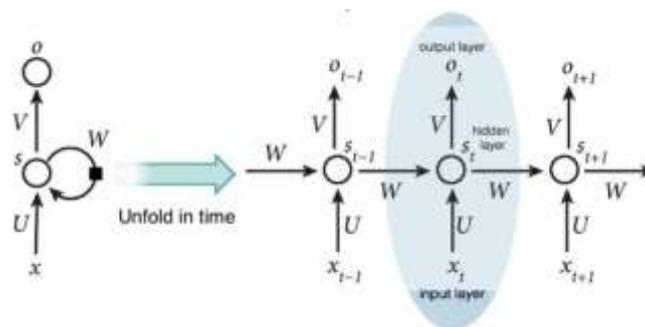
2.1 *Prediksi*

Meramalkan kejadian di masa mendatang disebut prediksi (*forecasting*), yang merupakan seni dan ilmu. Prediksi ini dilakukan dengan merencanakan, mengestimasi, atau memproyeksikan kejadian masa depan yang penting bagi organisasi dalam pengambilan keputusan dan perencanaan jangka panjang untuk meningkatkan peluang mencapai tujuan organisasi dan memperoleh keuntungan. Tujuan prediksi adalah mengurangi ketidakpastian terhadap kejadian masa depan dengan meminimalkan kesalahan peramalan yang dapat diukur dengan Squared error, mean absolute, dan metode lainnya [5].

2.2 *Recurrent Neural Network*

Recurrent Neural Network (RNN) adalah jenis arsitektur Neural Network yang dalam menjalankan prosesnya dipanggil berulang – ulang untuk memproses input yang biasanya adalah data sekuensial. Data sekuensial mempunyai karakteristik di mana sampel data diproses

dengan suatu urutan (misalnya waktu), dan suatu sampel dalam urutan mempunyai hubungan erat satu dengan yang lain. Data timeseries komoditas emas dapat digolongkan sebagai data sekuensial karena diproses dalam suatu urutan waktu. RNN memproses input secara sekuensial, sampel per sampel. Dalam tiap pemrosesan, output yang dihasilkan tidak hanya merupakan fungsi dari sampel itu saja, tapi juga berdasarkan state internal yang merupakan hasil dari pemrosesan sampel-sampel sebelumnya (atau setelahnya, pada bidirectional RNN). RNN dikategorikan sebagai Deep Learning karena data diproses melalui banyak lapis (layer) [6]. RNN merupakan algoritma pertama yang dapat mengingat input dengan adanya memori internal, sehingga sangat cocok untuk problema machine learning yang melibatkan data sekuensial seperti pada studi kasus prediksi harga komoditas emas. Recurrent neural network (RNN) dibangun di atas neuron seperti feedforward neural network tetapi memiliki koneksi tambahan antar layer.



Gambar 1 Algoritma Recurrent Neural Network

Gambar 1 menggambarkan bagaimana cara kerja RNN, Terdapat lapisan input X_t , hidden layer S_t , dan output layer O_t . U , V , dan W merupakan parameter atau bobot yang perlu dipelajari oleh model. Perbedaan antara feedforward neural network dan RNN adalah adanya input tambahan S_{t-1} , yang di masukkan ke dalam lapisan tersembunyi S_t . Jika jalur network yang ditandai dengan warna biru adalah waktu saat ini t , network sebelumnya merupakan waktu $t-1$, dan network setelahnya adalah waktu $t + 1$, dimana hidden layer saat ini S_t akan dimasukkan ke S_{t+1} bersama dengan X_{t+1} . Hidden layer menggunakan fungsi aktivasi untuk memproses hidden layer sebelumnya dan input saat ini X_t . Pada bagian kiri Gambar 1 menunjukkan bahwa RNN memiliki siklus berulang, tapi hubungan antara previous step dan current step pada hidden layer masih tidak berulang.

2. 3 Normalisasi

Normalisasi min- max mengubah ukuran data dari rentang asli, sehingga semua nilai berada dalam kisaran 0 dan 1 [7]. Persamaannya dapat dilihat pada persamaan (1).

$$x' = \frac{(x - \min)}{\max - \min} \quad (1)$$

Keterangan :

- x : data yang dinormalisasi
- x' : data setelah dinormalisasi
- \min : nilai minimum dari keseluruhan data
- \max : nilai maksimum dari keseluruhan data

Setelah diperoleh hasil normalisasi, maka dilakukan perhitungan menggunakan algoritma Recurrent Neural Network (RNN).

2. 4 Time Series

Data runtun waktu (time series) adalah jenis data yang dikumpulkan menurut urutan waktu dalam suatu rentang waktu tertentu. Dapat berupa detik, menit, jam, hari, minggu, bulan atau tahun. Time series ini bertujuan untuk menemukan pola variasi masa lalu yang dapat dipergunakan untuk memperkirakan nilai masa depan, dapat membantu dalam manajemen operasi serta membuat perencanaan. Menganalisis time series berarti membagi data masa lalu menjadi komponen – komponen dan kemudian memproyeksikannya ke masa depan [8]. Hal yang perlu diperhatikan dalam peramalan adalah kesalahan (error), dimana tidak dapat dipungkiri bahwa error menjadi bagian dari sebuah peramalan [9]. Seorang yang meramalkan hanya bisa berusaha untuk membuat error seminimal mungkin karena pada faktanya hasil prediksi masih jarang yang mendekati data sesungguhnya. Jarang bukan berarti tidak bisa, karena yang terpenting dari peramalan adalah nilai error yang minim dan mendekati angka nol. Namun tetap semua kembali kepada teknik yang digunakan untuk meramal, data yang digunakan untuk meramal, jumlah dan banyaknya data tersebut.

$$RMSE = \sqrt{\frac{(x-y)^2}{n}} \quad (2)$$

Keterangan :

x : nilai asli

y : nilai hasil prediksi

n : banyak data

2. 5 Mean Absolute Percentage Error (MAPE)

Untuk mengukur kesalahan hasil prediksi digunakan MAPE yakni rata-rata dari keseluruhan persentase kesalahan (selisih) antara data aktual dengan hasil prediksi. MAPE ini digunakan sebagai evaluasi proses prediksi, ukuran akurasi dicocokkan dengan data runtun waktu, dan ditunjukkan dalam persentase [10]. Semakin kecil nilai MAPE dari hasil komputasi prediksi maka semakin mendekati data aslinya. Satu model prediksi mempunyai kinerja yang sangat akurat jika nilai MAPE di bawah 10% dan mempunyai kinerja baik jika nilai MAPE antara 10% dan 20% . Secara matematis MAPE ditunjukkan dalam persamaan (3), dan interpretasi dari nilai MAPE diperlihatkan pada Tabel 1.

$$MAPE = \sum \frac{|y_i - y'_i|}{y'_i} \times 100\% \quad (3)$$

Keterangan :

y_i : nilai aktual

y'_i : nilai hasil prediksi

n : banyak data

Tabel 1 Interpretasi nilai MAPE

MAPE(%)	Interpretasi
<10	Prediksi sangat akurat
10-20	Prediksi yang baik
20-50	Prediksi yang layak
>50	Prediksi yang tidak akurat

3. HASIL DAN PEMBAHASAN

3.1 Normalisasi Data

Sebelum diproses data-data input tersebut akan dinormalisasi. Normalisasi data dilakukan agar keluaran jaringan sesuai dengan fungsi aktivasi yang digunakan. Data yang digunakan pada penelitian ini diambil dari Fakultas Pertanian Universitas Udayana Denpasar. Total data yang digunakan adalah 120 data yaitu data serangan hama wereng padi Kabupaten Gianyar pada 10 tahun terakhir antara tahun 2012 hingga tahun 2021. Berikut adalah contoh data luas serangan hama padatahun 2014.

Tabel 2 Data Luas Serangan Hama

Hama Wereng Kabupaten Gianyar	
Tanggal	Luas Lahan (ha)
01/01/2014	20,10
01/02/2014	15,00
01/03/2014	27,60
01/04/2014	2,00
01/05/2014	12,80
01/06/2014	14,60
01/07/2014	55,10
01/08/2014	32,75
01/09/2014	12,00
01/10/2014	17,65
01/11/2014	17,25
01/12/2014	10,43

Data *time series* pada Tabel 2 dinormalisasi sesuai dengan range antara 0 sampai dengan 1 untuk menyesuaikan fungsi aktivasinya. Teknik normalisasi yang digunakan menggunakan persamaan (4) berikut perhitungannya.

$$X' = \frac{(x - \min)}{\max - \min} \quad (4)$$

$$\min = 2,00$$

$$\max = 55,10$$

$$\text{Januari} = [(20,10 - 2,00) / (55,10 - 2,00)] = 0,3409$$

$$\text{Februari} = [(15,00 - 2,00) / (55,10 - 2,00)] = 0,2448$$

Normalisasi tersebut akan dilakukan seterusnya dari bulan Januari hingga bulan Desember, sehingga hasil normalisasi dapat dilihat pada Tabel 3.

Tabel 3 Hasil Normalisasi Data Time Series

Normalisasi Data Time Series Kabupaten Gianyar			
Tanggal	XI	XI'	Y'
01/01/2014	20,10	0,8261	0,2609
01/02/2014	15,00	0,2609	0,8261
01/03/2014	27,60	0,8261	0,5652
01/04/2014	2,00	0,5652	0,1739
01/05/2014	12,80	0,1739	0,1739
01/06/2014	14,60	0,1739	1,0000

01/07/2014	55,10	1,0000	0,6957
01/08/2014	32,75	0,6957	0,0000
01/09/2014	12,00	0,0000	0,0870
01/10/2014	17,65	0,0870	0,3478
01/11/2014	17,25	0,3478	0,1739
01/12/2014	10,43	0,1739	

Dimana X_1 adalah data aktual, X_1' adalah data aktual yang sudah dinormalisasi, dan Y' adalah data target setelah dinormalisasi.

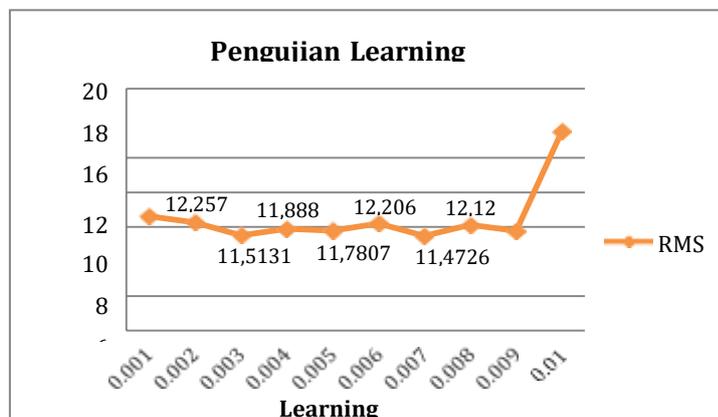
3. 2 Pembahasan Pengujian Pada Learning Rate

Pengujian pertama merupakan pengujian perbedaan *learning rate*. Pengujian dilakukan dengan membedakan jumlah input learning rate yaitu 0.001, 0.002, 0.003, 0.004, 0.005, 0.006, 0.007, 0.008, dan 0.009 dengan jumlah input layer 5, hidden layer 80, dan epoch 500.

Tabel 4 Pengujian Perbedaan Jumlah Learning Rate

Data Latih = 108 & Data Uji = 12, epoch = 500, input layer = 5, hidden layer = 80						
Learning Rate	RMSE					Rata-rata RMSE
	Percobaan Ke-1	Percobaan Ke-2	Percobaan Ke-3	Percobaan Ke-4	Percobaan Ke-5	
0.001	12,0102	14,9471	12,8311	11,6821	11,5633	12,6068
0.002	12,2378	12,5501	11,0087	11,7699	13,7221	12,2577
0.003	11,9506	10,0119	12,8221	12,1221	10,6590	11,5131
0.004	12,1381	12,9841	12,1919	11,3444	10,7832	11,8883
0.005	11,6440	12,0199	11,0172	10,9872	13,2354	11,7807
0.006	11,9051	13,5671	12,1101	12,3290	11,1209	12,2064
0.007	11,3663	11,9111	12,9506	10,9999	10,1350	11,4726
0.008	11,5363	11,4116	12,7765	12,0162	12,8744	12,1230
0.009	11,7648	12,2201	11,9581	11,1873	11,7138	11,7688
0.01	18,0833	18,3416	15,8211	17,0100	18,4223	17,5357

Dari hasil pengujian pada Tabel 4, didapatkan nilai rata-rata RMSE terbaik yaitu 11,4726 yang didapat dari learning rate dengan jumlah nilai adalah 0.007. Dari hasil rata-rata RMSE disetiap pengujian didapatkan grafik pada Gambar 2.



Gambar 2 Grafik Pengujian Perbedaan Learning Rate

Berdasarkan Gambar 2, nilai *learning rate* dengan *input* 0.007 menunjukkan nilai rata-rata RMSE terkecil. Dimana pada *learning rate* 0.007 didapat nilai rata-rata RMSE sebesar 11,4726.

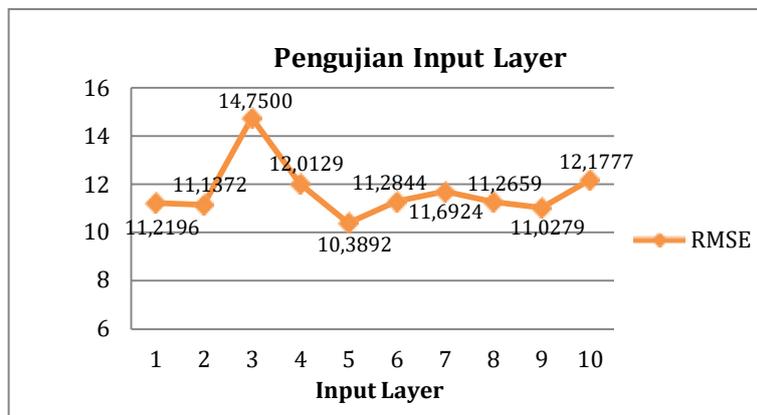
3. 3 Pembahasan Pengujian Pada Input Layer

Pengujian kedua merupakan pengujian banyak input layer. Pengujian dilakukan dengan membedakan jumlah input layer yaitu 1, 2, 3, 4, 5, 6, 7, 8, 9, dan 10 terhadap nilai learning rate 0.007 yang telah diuji pada sub-bab sebelumnya, hidden layer 80, dan epoch sebanyak 500.

Tabel 5 Pengujian Perbedaan Jumlah Input Layer

Data Latih = 108 & Data Uji = 12, epoch = 500, learning rate = 0.007, hidden layer= 80						
Input Layer	RMSE					Rata-rata RMSE
	Percobaan Ke-1	Percobaan Ke-2	Percobaan Ke-3	Percobaan Ke-4	Percobaan Ke-5	
1	10,4721	10,9787	12,8109	10,3360	11,5003	11,2196
2	11,4323	10,2404	10,5510	11,4398	12,0223	11,1372
3	15,6821	19,5030	15,0454	11,1176	12,4021	14,7500
4	10,8214	12,8729	11,2891	12,9540	12,1273	12,0129
5	9,6915	9,1300	9,6245	11,0701	11,4298	10,3892
6	11,0048	13,5648	11,6296	10,6415	9,5811	11,2844
7	11,8320	10,3199	11,6397	12,8701	11,8004	11,6924
8	10,9625	10,7696	10,2855	12,3090	12,0027	11,2659
9	12,2403	9,8790	12,1431	10,7667	10,1103	11,0279
10	12,8824	12,3012	12,1797	11,1801	12,3450	12,1777

Dari hasil pengujian pada Tabel 5, didapatkan nilai RMSE terbaik yaitu 10,3892 yang didapat dari *input layer* dengan jumlah nilai adalah 5. Dari hasil RMSE disetiap pengujian didapatkan grafik pada Gambar 3.



Gambar 3 Grafik Pengujian Perbedaan Input Layer

Berdasarkan Gambar 3 *input layer* dengan jumlah 5 menunjukkan RMSE terkecil. Dimana pada *jumlah input layer* 5 didapat RMSE sebesar 10,3892.

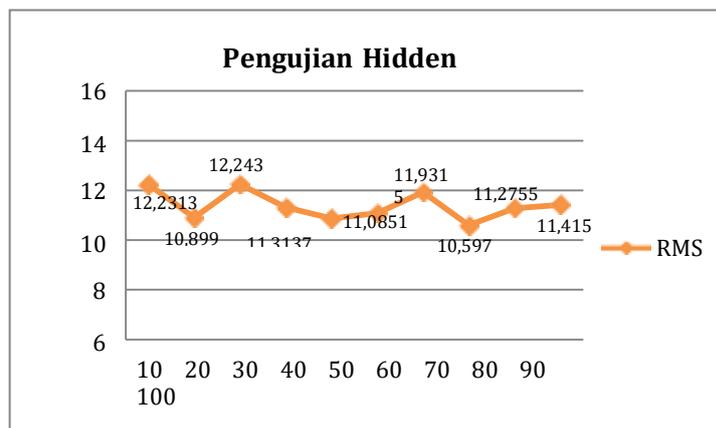
3. 4 Pembahasan Pengujian Pada Hidden Layer

Pengujian perbedaan *hidden layer* dilakukan dengan menggunakan *epoch* 500, *learning rate* 0,007, dan jumlah *input layer* terbaik yang telah dilakukan pada sub bab sebelumnya. Pengujian dilakukan dengan variasi jumlah *hidden layer* yaitu, 10, 20, 30, 40, 50, 60, 70, 80, 90, dan 100 dengan jumlah *input layer* 5 yang selanjutnya akan dihitung perbedaan nilai RMSE.

Tabel 6 Pengujian Perbedaan Jumlah Hidden Layer

Data Latih = 108 & Data Uji = 12, epoch = 500, learning rate = 0.007, input layer= 5						
Hidden Layer	RMSE					Rata-rata RMSE
	Percobaan Ke-1	Percobaan Ke-2	Percobaan Ke-3	Percobaan Ke-4	Percobaan Ke-5	
10	12,6976	12,9089	12,1347	10,5441	12,8712	12,2313
20	11,8668	10,6122	9,9878	10,1123	11,9174	10,8993
30	11,7865	12,8227	12,0551	12,4619	12,0922	12,2437
40	9,4955	12,2111	12,7825	10,3298	11,7494	11,3137
50	10,888	9,7211	10,5609	11,9721	11,1601	10,8604
60	10,5006	10,8022	11,7656	11,4528	10,9045	11,0851
70	12,7733	11,7731	12,6009	12,4231	10,087	11,9315
80	9,0174	11,2751	9,7702	11,123	11,8025	10,5976
90	10,405	10,7606	12,9733	11,418	10,8205	11,2755
100	10,6914	11,2234	12,2003	12,4199	10,5404	11,4151

Dari hasil pengujian pada Tabel 6, didapatkan nilai rata-rata RMSE terbaik yaitu 10,5976 yang didapat dari hidden layer dengan jumlah nilai adalah 80. Dari hasil RMSE disetiap pengujian didapatkan grafik pada Gambar 4.



Gambar 4 Grafik Pengujian Perbedaan *Hidden Layer*

Berdasarkan Gambar 4 *hidden layer* dengan jumlah 80 menunjukkan RMSE terkecil. Dimana pada jumlah *hidden layer* 80 didapat RMSE sebesar 10,5976.

3. 5 Pembahasan Pengujian Jumlah Epoch

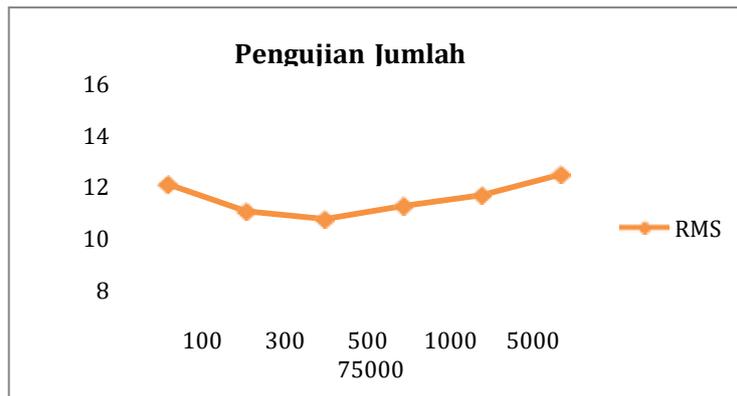
Pengujian jumlah *epoch* dilakukan dengan menggunakan *learning rate*, *input layer*, dan jumlah *hidden layer* terbaik yang telah dilakukan pada sub bab sebelumnya. Pengujian

dilakukan dengan variasi jumlah *epoch* yaitu, 100, 300, 500, 1000, 5000, dan 75000 yang selanjutnya akan dihitung perbedaan nilai RMSE dan menghitung nilai rata-rata MAPE.

Tabel 7 Pengujian Perbedaan Jumlah Epoch

Data Latih = 108 & Data Uji = 12, Hidden layer = 80, learning rate = 0.007, input layer= 5						
Epoch	RMSE					Rata-rata RMSE
	Percobaan Ke-1	Percobaan Ke-2	Percobaan Ke-3	Percobaan Ke-4	Percobaan Ke-5	
100	10,3282	11,0999	13,5488	10,5441	12,3213	11,5685
300	9,0117	9,6122	11,2865	10,1123	11,9174	10,3880
500	8,1551	9,1877	8,8718	12,2874	11,7494	10,0503
1000	10,4527	11,5196	9,7702	8,9038	12,4598	10,6212
5000	12,0424	9,7211	10,5609	11,9721	11,1601	11,0913
75000	15,7264	10,8454	11,7656	11,3494	10,2287	11,9831

Dari hasil pengujian pada Tabel 7, didapatkan nilai rata-rata RMSE terbaik yaitu 10,0503 yang didapat dari jumlah epoch dengan nilai 500. Dari hasil RMSE disetiap pengujian didapatkan grafik pada Gambar 5.



Gambar 5 Grafik Pengujian Jumlah Epoch

Berdasarkan Gambar 5, *epoch* dengan jumlah 500 menunjukkan RMSE terkecil. Dimana pada jumlah *epoch* 500 didapat nilai rata-rata RMSE sebesar 10,0503. Pada penelitian ini untuk mengukur tingkat akurasi prediksi dihitung menggunakan *Mean Absolute Percentage Error* (MAPE) pada data latih dan data uji. Pada Tabel 8, menunjukkan hasil perbandingan perhitungan MAPE pada beberapa nilai epoch yang telah ditentukan pada sub bab sebelumnya yaitu mulai dari epoch 100, 300, 500, 1000, 5000, dan 75000. Semakin kecil nilai MAPE maka semakin kecil kesalahan hasil prediksi, sebaliknya semakin besar nilai MAPE maka semakin besar kesalahan hasil prediksi.

Tabel 8 Hasil Perhitungan MAPE

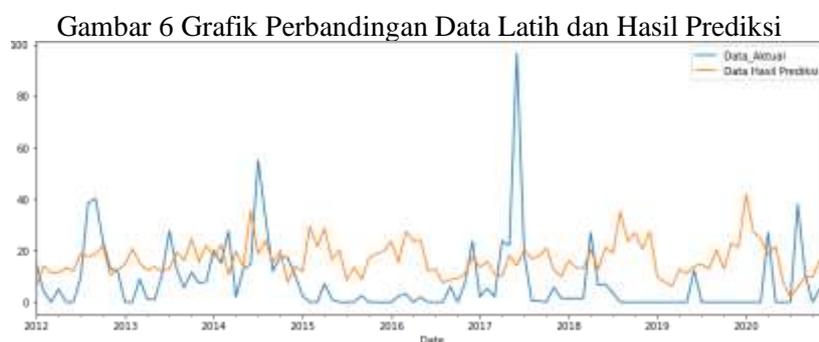
Epoch	Data Latih = 108 & Data Uji = 12	Time Taken
	Nilai Rata-Rata MAPE(%)	
100	27,03	00:00:12
300	22,20	00:00:20
500	16,64	00:00:29

1000	24,08	00:01:04
5000	17,98	00:05:37
75000	22,18	01:37:52

Dapat diketahui bahwa tabel hasil perhitungan rata-rata MAPE dengan total 120 dataset menggunakan epoch 500 menghasilkan tingkat akurasi terkecil sebesar 16,64%. Berdasarkan interpretasi nilai MAPE bahwa tingkat akurasi $>10\%$ dan $<20\%$ menghasilkan prediksi yang baik.

3. 6 Analisa Hasil

Hasil pengujian menggunakan data latih dapat dilihat pada Gambar 6 Perbandingan Data Latih dan Hasil Prediksi yaitu pada garis yang berwarna biru merupakan data latih sebesar 90% dari total keseluruhan data dan garis yang berwarna orange adalah hasil dari prediksi yang di dapat pada pengujian data latih.

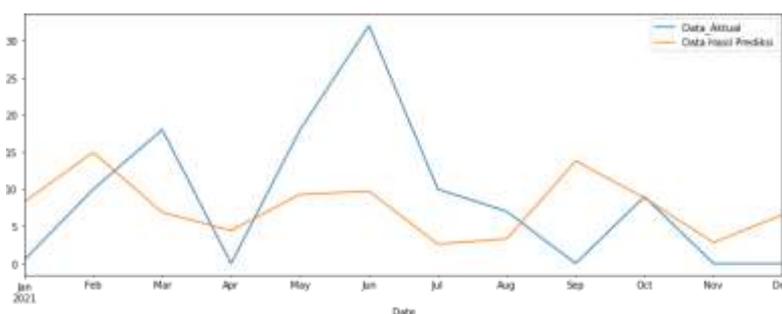


Hasil prediksi luas lahan sebaran hama untuk 1 tahun kedepan dapat dilihat pada Tabel 9 berikut.

Tabel 9 Hasil Prediksi 1 Tahun Kedepan

Bulan	Data Aktual (ha)	Hasil Prediksi (ha)
Januari	0,50	8,60
Februari	10,00	15,49
Maret	18,00	7,11
April	0,00	4,59
Mei	18,00	9,62
Juni	32,00	10,08
Juli	10,00	2,69
Agustus	7,00	3,44
September	0,00	14,28
Oktober	9,00	9,12
November	0,00	2,90
Desember	0,00	6,79

Pada Gambar 7 merupakan Perbandingan Data Uji dan Hasil Prediksi yaitu pada garis yang berwarna biru merupakan data aktual sebesar 10% dan garis yang berwarna orange adalah hasil dari prediksi yang di dapat pada pengujian data uji.



Gambar 7 Grafik Perbandingan Data Uji dan Hasil Prediksi

Setelah melakukan analisis, perancangan implementasi dan pembahasan pengujian dengan menggunakan metode *Recurrent Neural Network* (RNN) untuk memprediksi sebaran hama wereng padi di Kabupaten Gianyar dengan jumlah dataset 120 menunjukkan bahwa hasil prediksi yang diperoleh adalah prediksi yang baik karena mendapatkan nilai MAPE $>10\%$ dan $<20\%$ yakni sebesar 16,64%. Sehingga dapat disimpulkan bahwa pada penelitian tugas akhir ini dengan metode *Recurrent Neural Network* (RNN) dapat bekerja cukup optimal dalam melakukan prediksi penyebaran luas lahan hama wereng padi untuk 1 tahun kedepan.

4. KESIMPULAN

Model terbaik dari arsitektur *recurrent neural network* untuk memprediksi luas lahan sebaran hama wereng padi adalah model dengan 5 *neuron input layer*, 80 *neuron hidden layer* serta nilai *learning rate* 0,007 dengan 500 *epoch* sehingga didapatkan nilai rata-rata RMSE terkecil sebesar 10,0503 dengan MAPE 16,64%. Berdasarkan hasil implementasi yang telah dilakukan, diperoleh bahwa algoritma *Recurrent Neural Network* (RNN) mampu memprediksi data *time series* luas sebaran hama wereng padi dengan nilai rata-rata MAPE sebesar 16,64% atau termasuk kategori prediksi yang baik, sehingga dengan hasil prediksi tersebut dapat digunakan sebagai *decision support* oleh pihak laboratorium untuk strategi pengembangan produktivitas padi.

5. SARAN

Pada penelitian selanjutnya diharapkan menambahkan parameter lain yang mempengaruhi hasil prediksi luas sebaran hama padi seperti faktor suhu, iklim, cuaca, curah hujan, dll.

DAFTAR PUSTAKA

- [1] I. M. A. Sudarma, "Buletin Peternakan Tropis," vol. 2, no. 2, pp. 90–97, 2021.
- [2] M. P. Rein Estefanus Senewe1, Silvia Permatasari, "Respon Hama Wereng Coklat *Nilaparvata lugens* Stal. (Hemiptera: Delphacidae) Terhadap Ketahanan Dan Kerentanan Varietas Padi," *Respon Hama Wereng Coklat Nilaparvata lugens* Stal. (Hemiptera Delphacidae) Terhadap Ketahanan Dan Kerentanan Var. Padi, vol. 16, p. 5, 2020.
- [3] A. M. Siregar, J. H. Jaman, and Abdul Mufti, "Analisa Prediksi Kesehatan Masyarakat Indonesia Menggunakan Recurrent Neural Network," *Anal. Prediksi Kesehat. Masy. Indones. Menggunakan Recurr. Neural Netw.*, vol. 4, no. kesehatan masyarakat, p. 7, 2021.
- [4] H. D. Alwi Aulia, Andi Marwan Elhanafi, "Implementasi Algoritma Gated Recurrent Unit Dalam Melakukan Prediksi Harga Kelapa Sawit Dengan Memanfaatkan Model Recurrent Neural Network (RNN)," *Implementasi Algoritma Gated Recurr. Unit Dalam Melakukan Prediksi Harga Kelapa Sawit Dengan Memanfaatkan Model Recurr. Neural*

- Netw.*, p. 8, 2021.
- [5] Hernadewita, Y. K. Hadi, M. J. Syaputra, and D. Setiawan, "Peramalan Penjualan Obat Generik Melalui Time Series Forecasting Model Pada Perusahaan Farmasi di Tangerang: Studi Kasus," *J. Ind. Eng. Manag. Res. (Jiemar)*, vol. 1, no. 2, pp. 35–49, 2020.
- [6] Muhammad Haris Diponegoro, Sri Suning Kusumawardani, and Indriana Hidayah, "Tinjauan Pustaka Sistematis: Implementasi Metode Deep Learning pada Prediksi Kinerja Murid," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 10, no. 2, pp. 131–138, 2021, doi: 10.22146/jnteti.v10i2.1417.
- [7] K. Analitik, "Correlation Analysis of Minimum Wage To the," no. December, 2021.
- [8] N. A. Fitri and I. Taufiq, "Perbandingan JST Metode Backpropagation dan Metode Radial Basis dalam Memprediksi Curah Hujan Harian Bandara Internasional Minangkabau," *J. Fis. Unand*, vol. 9, no. 2, pp. 217–223, 2020, doi: 10.25077/jfu.9.2.217-223.2020.
- [9] E. Indriastiningsih and S. Darmawan, "Analisa Pengendalian Persediaan Sparepart Motor Honda Beat Fi dengan Metode EOQ Menggunakan Peramalan Penjualan Di Graha Karyaahass XY," *Din. Tek.*, vol. 12, no. 2, pp. 24–43, 2019.
- [10] Y. M. K. min Nur Rais, Rousyati, Indra Jiwana Thira, Desiana Nur Kholifah, Nani Purwati, "Evaluasi Metode Forecasting Pada Data Kunjungan Wisatawan Mancanegara ke Indonesia," *Eval. Metod. Forecast. Data Kunjungan Wisatawan Mancanegara ke Indones.*, vol. 8, p. 12, 2020.