

Prediksi Sebaran Hama Tikus Pada Tanaman Padi Menggunakan Metode Backpropagation Neural Network

Rafika Arimawarni^{*1}, Putu Sugiartawan², Santi Ika Murpratiwi³

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

e-mail: ^{*1}arimawari@stiki-indonesia.ac.id, ²sugiartawan@stiki-indonesia.ac.id,

³murpratiwi@stiki-indonesia.ac.id

Abstrak

OPT (*Organisme Pengganggu Tumbuhan*) adalah setiap kegiatan atau kegiatan yang merusak dan mematikan tanaman, salah satunya disebabkan oleh hama, penyakit, virus, dll. Di Bali khususnya di Kabupaten Tabanan kasus OPT masih sangat tinggi, OPT pada tanaman padi yang disebabkan oleh hama tikus merupakan masalah yang dihadapi petani dan ke depannya harus dicegah dengan mengetahui penyebaran hama tikus. Oleh karena itu, tujuan penelitian ini adalah untuk membantu petani mencegah serangan hama sehingga produktivitas padi dapat ditingkatkan. Pada penelitian ini, metode jaringan syaraf tiruan backpropagation digunakan untuk memprediksi sebaran hama tikus pada tanaman padi. Metode ini menggunakan data sebelumnya yaitu dari tahun 2012-2021 saat data diolah dan dihitung sampai diperoleh nilai error terkecil. Pada penelitian ini diperoleh data dari perhitungan sebaran OPT dalam satuan hektar yang menunjukkan persentase selisih error akurasi sebesar 16,2% yang berarti prediksi perhitungan ini cukup baik untuk dijadikan acuan penelitian selanjutnya.

Kata kunci—Backpropagation neural network, Sebaran hama, Organisme pengganggu tumbuhan

Abstract

OPT (*Plant Pest Organisms*) is any activity or activities that damage and kill plants, one of which is caused by pests, diseases, viruses, etc. In Bali, especially in Tabanan Regency, OPT cases are still very high. OPT in rice plants caused by rats is a problem faced by farmers and in the future, it must be prevented by knowing the spread of rats. Therefore, the purpose of this research is to help farmers prevent pest attacks so that rice productivity can be increased. In this study, the backpropagation neural network method was used to predict the distribution of rat pests on rice plants. This method uses previous data, namely from 2012-2021 when the data is processed and calculated until the smallest error value is obtained. In this study, data were obtained from calculating the distribution of pests in hectares which showed a percentage difference in accuracy error of 16.2%, which means that the prediction of this calculation is good enough to be used as a reference for further research.

Keywords—Backpropagation neural network, distribution of pests, plant-disturbing organisms

1. PENDAHULUAN

Pertanian merupakan sektor yang sangat sensitif terhadap perubahan iklim. Perubahan iklim, yang mempengaruhi kenaikan suhu dan perubahan curah hujan, dapat berdampak negatif pada sektor pertanian karena berdampak pada produktivitas tanaman. Provinsi Bali memiliki salah satu sektor pertanian terbesar dengan luas 79.000 hektar. Kondisi geografis antara pegunungan, dataran dan pantai mempengaruhi kondisi iklim. Pengaruh perubahan iklim di Bali secara langsung maupun tidak langsung melalui serangan Organisme Pengganggu Tumbuhan (OPT), peningkatan fluktuasi suhu dan kelembaban dapat merangsang pertumbuhan dan perkembangan OPT. Organisme Pengganggu Tumbuhan (OPT) adalah semua organisme yang secara langsung dapat menurunkan potensi hasil melalui kerusakan fisik, fisiologis dan gangguan biokimia. Hal ini menyebabkan perlunya penanggulangan atau pencegahan serangan OPT, karena perkembangan serangan OPT yang tidak terkendali berkontribusi terhadap munculnya berbagai masalah [1].

Suhu dan kelembaban relatif secara langsung mempengaruhi siklus hidup, kemampuan reproduksi, umur panjang dan kemampuan mengendalikan serangga. Misalnya, suhu optimum pertumbuhan populasi kutu kebul (*Bemisia tabaci*) adalah 32,5 °C. Contoh lain adalah bahwa pertumbuhan populasi bonggol beras putih bervariasi antara musim kemarau dan musim hujan, sedangkan panjang hari mempengaruhi diapausa bonggol beras putih (*Scirpophaga innotata*). Biasanya hama serangga kecil seperti kutu daun menjadi masalah di musim kemarau atau di rumah kaca karena tidak ada air hujan.

Perubahan iklim telah mempengaruhi evolusi hama. Dengan demikian, jika iklim sebelum terjadinya serangan hama diketahui, maka kejadian hama di masa mendatang juga dapat diketahui. Salah satu teknik yang sering digunakan dalam proses prediksi pada jaringan syaraf tiruan adalah propagasi balik. Pada penelitian peramalan nilai tukar yang dilakukan oleh Dini Oktaviani Maru'ao, nilai produksi atau peramalan tidak jauh berbeda dengan harga sebenarnya. Nilai error maksimal hanya 0,0006. Penelitian Didi Supriyad tentang prediksi penyebaran DBD menggunakan metode jaringan saraf tiruan backpropagation mendapatkan akurasi yang cukup baik antara hasil prediksi dengan data sebenarnya yaitu 88,23%. Studi lain yang dilakukan oleh Saiful Amin, Alamsyah Alamsyah, dan Much Aziz Muslim untuk memprediksi hama tanaman coklat menggunakan jaringan saraf tiruan di Kabupaten Semarang mencapai akurasi 86,46%.

Berdasarkan contoh penelitian, dapat dilihat bahwa jaringan saraf tiruan menggunakan metode backpropagation mencapai akurasi yang tinggi dan karenanya cocok untuk prediksi. Berdasarkan kondisi tersebut, diusulkan suatu sistem yang dapat memprediksi serangan hama pada tanaman padi dengan menggunakan data iklim historis untuk mengidentifikasi dan melacak serangan hama pada tanaman, sehingga serangan hama dapat diprediksi dengan tepat.

2. METODE PENELITIAN

2.1 Penelitian terdahulu

Setiap diadakan penelitian baru tidak lepas dari kajian hasil penelitian penelitian terdahulu karena dijadikan sebagai referensi atau bahan perbandingan atas apa yang akan dilakukan oleh peneliti. Adapun hasil-hasil penelitian yang dijadikan perbandingan tidak terlepas dari topik penelitian yaitu analisis hasil prediksi data time series dengan menggunakan backpropagation neural network dalam bidang pertanian. Berikut beberapa referensi yang digunakan oleh penulis, [2] dengan judul penelitian “Prediksi Data Time-series menggunakan Jaringan Syaraf Tiruan Algoritma Backpropagation Pada Kasus Prediksi Permintaan Beras”. Kemudian, dengan judul “Peramalan Tingkat Inflasi Indonesia Menggunakan Neural Network Backpropagation Berbasis Metode Time Series” pada 2014. Berikutnya dengan judul “Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation” pada tahun 2017. Lalu penelitian [3] dengan judul,

“Algoritma Backpropagation Prediksi Harga Komoditi terhadap Karakteristik Konsumen Produk Kopi Lokal Nasional”. Dan referensi yang terakhir adalah penelitian [4] dengan judul “Implementasi Algoritma Backpropagation Untuk Memprediksi Kelulusan Mahasiswa”.

2. 2 Neural Network

Jaringan Saraf Tiruan (JST) merupakan simulasi dari otak biologis. Tujuan dari JST adalah untuk belajar mengenali pola-pola pada data dan mensimulasikan proses belajar adaptif biologis, walau dalam skala yang sangat sederhana. Sekali JST telah dilatih terhadap data, akan dapat membuat prediksi dengan melakukan deteksi kemiripan/kesamaan pola-pola data masukan. JST bukanlah duplikasi persis dari sistem biologis otak manusia, tetapi jaringan saraf tiruan ini dapat melakukan kemampuan seperti generalisasi, belajar, abstraksi, dan bahkan intuisi. Mudah-mudahan, merupakan suatu model dari sistem saraf biologis yang disederhanakan sebagai suatu alternatif sistem komputer. Kenyataan menunjukkan bahwa banyak masalah dalam kehidupan manusia yang sulit dipecahkan dengan “komputer konvensional” yang paling canggih sekalipun, namun manusia dapat menyelesaikannya dengan baik. Dengan kemampuannya untuk belajar, jaringan saraf tiruan ini diharapkan dapat menyelesaikan masalah yang tidak dapat diselesaikan oleh komputer konvensional. Jaringan saraf tidak diprogram dalam arti tradisional. Sebaliknya dilatih dengan contoh. Latihan itu terdiri dari banyak pengulangan input yang mengungkapkan berbagai hubungan. Dengan memperhalus bobot node sistem (neuron yang disimulasikan) secara progresif, jaringan saraf tiruan ini “menemukan” hubungan antar input. Proses penemuan ini menandakan “belajar”.

JST merupakan salah satu bentuk dari Kecerdasan Buatan. JST dipandang sebagai suatu Black Box yang dapat melakukan prediksi keluaran dari suatu pola masukan yang dia kenali. Untuk itu JST harus dilatih terlebih dahulu terhadap sejumlah pola masukan dan target yang diharapkan dari tiap pola masukan tersebut (Supervised Learning). Sekali dilatihkan.


JST dapat mendeteksi kesamaan masukan, bahkan sebagian masukan yang mungkin belum pernah dilatihkan atau diberikan sebelumnya. Karena JST mempunyai kemampuan interpolasi yang hebat, terutama bila data masukan tidak eksak, banyak gangguan didalamnya. Sehingga memungkinkan JST untuk digunakan sebagai substitusi langsung bagi auto korelasi, regresi multivariabel, regresi linier, trigonometri, dan teknik regresi lainnya. Ketika data dianalisa menggunakan JST, akan memungkinkan untuk melakukan prediksi pola yang penting sebagaimana bila seorang ahli menganalisa data tersebut, karena JST dapat beraksi seperti selayaknya seorang yang ahli di bidangnya [5].

2. 3 Peramalan atau Prediksi

Peramalan adalah proses untuk memperkirakan berapa kebutuhan dimasa yang akan datang yang meliputi kebutuhan dalam ukuran kuantitas, kualitas, waktu dan lokasi yang dibutuhkan dalam rangka memenuhi permintaan barang ataupun jasa. Peramalan permintaan merupakan tingkat permintaan produk-produk yang diharapkan akan terealisasi untuk jangka waktu tertentu pada masa yang akan datang. Pada dasarnya pendekatan peramalan dapat diklasifikasikan menjadi dua pendekatan, yaitu pendekatan kualitatif dan pendekatan kuantitatif. Prediksi (forecasting) merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien khususnya dalam bidang ekonomi. Peramalan atau prediksi mempunyai peranan langsung pada peristiwa eksternal yang pada umumnya berada di luar kendali manajemen seperti: Ekonomi, Pelanggan, Pesaing, Pemerintah, dan lain sebagainya. Peramalan permintaan memegang peranan penting dalam perencanaan dan pengambilan keputusan khususnya di bidang produksi. Aktivitas manajemen operasi menggunakan peramalan permintaan dan perencanaan yang menyangkut produksi, Perencanaan pemenuhan kebutuhan bahan, Perencanaan kebutuhan tenaga kerja, perencanaan kapasitas produksi, perencanaan kapasitas produksi, perencanaan layout fasilitas, penentuan lokasi, penentuan metode proses, penentuan jumlah mesin, Desain aliran peristiwa dengan kebutuhan mendatang [6].

2. 4 Backpropagation

Backpropagation merupakan salah satu model jaringan syaraf tiruan. Backpropagation melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan serta kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa tapi tidak sama dengan pola yang dipakai selama pelatihan [2], [5].



Gambar 1 Arsitektur JST

2. 5 Time Series (Deret Waktu)

Deret Berkala adalah data yang disusun berdasarkan urutan waktu terjadinya dan menggambarkan perkembangan suatu kejadian atau suatu kegiatan. Data masa lampau ini dapat saja dicatat secara berturut-turut dalam interval waktu satu tahun, satu semester, satu kuartal, satu triwulan, bulanan, harian dan satuan waktu lainnya. Analisis Deret Berkala (Time Series Analysis) adalah suatu metode kuantitatif untuk menentukan pola data masa lampau yang telah dikumpulkan secara teratur. Apabila kita telah menemukan pola data masa lampau, maka kita dapat menggunakannya untuk mengadakan peramalan di masa yang akan datang [7].

Variabel deret berkala dipengaruhi oleh empat gerakan atau perubahan yang disebut komponen-komponen deret berkala. Keempat komponen deret berkala tersebut adalah:

1. Trend Sekuler, yaitu gerakan yang berjangka panjang, lamban, seolah-olah alun ombak dan berkecenderungan menuju ke satu arah menaik atau menurun.
2. Variasi Musiman (M), yaitu gerak naik atau turun secara periodic dalam jangka waktu kurang dari satu tahun.
3. Variasi Siklis (S), yaitu gerak naik atau turun secara periodic didalam jangka waktu panjang, misalnya 5 tahun, 10 tahun, 20 tahun, 25 tahun atau lebih.
4. Variasi Rasidu (I), yaitu gerakan yang tidak teratur dan sulit untuk diramalkan dan merupakan gerakan yang disebabkan oleh factor kebetulan.

2. 6 Root Mean Squared Error

Salah satu teknik evaluasi hasil prediksi yang digunakan dalam penelitian ini adalah Root Mean Squared Error (RMSE). RMSE telah digunakan sebagai matrik statistik standar untuk mengukur keakuratan kinerja berbagai model. Evaluasi untuk mengetahui tingkat perbedaan antara hasil peramalan dengan nilai data yang sebenarnya terjadi [8].

2. 7 Mean Absolute Percentage Error

Nilai Mean Absolute Percentage Error (MAPE) memberikan petunjuk mengenai seberapa besar rata – rata kesalahan absolut peramalan dibandingkan dengan nilai sebenarnya [9].

2. 8 K-fold Cross validation

Cross-validation adalah model statistik yang digunakan untuk mengevaluasi algoritma pembelajaran dengan membagi data menjadi dua set data. Dataset pertama digunakan untuk data training sedangkan dataset kedua digunakan untuk data validasi. Validasi silang juga

berfungsi untuk mengonfirmasi keakuratan model yang dibangun berdasarkan kumpulan data tertentu. Saat mengevaluasi tingkat kesalahan di bidang pengenalan pola, seperti prediksi dan klasifikasi, validasi silang k-fold dapat digunakan, yang merupakan varian dari metode validasi silang. Penggunaan model ini bertujuan untuk menghilangkan bias data dengan cara membagi data menjadi k subset/fold yaitu $S_1, S_2, \dots, S_k$, masing-masing subset berukuran kurang lebih sama. Standar jumlah lipatan yang digunakan untuk memprediksi tingkat kesalahan data menggunakan validasi silang 10 kali lipat [10].

2. 9 Flowchart

Flowchart adalah representasi grafis dari langkah-langkah dan urutan kegiatan dalam sebuah program. Biasanya membantu memecahkan masalah yang memerlukan penyelidikan khusus dan evaluasi lebih lanjut. Diagram alir dapat digunakan untuk menunjukkan operasi manual, operasi pemrosesan, atau keduanya [11].



Gambar 2 Arsitektur JST

3. HASIL DAN PEMBAHASAN

3. 1 Analisis pengujian

Pada bab ini terdapat 4 jenis pengujian yang akan dilakukan diantaranya yaitu: pengujian learning rate yang akan dilakukan pertama, pengujian hidden layer yang dilakukan kedua, pengujian neuron pada hidden layer yang dilakukan ketiga, dan pengujian epoch yang terakhir dilakukan. Tiap pengujian akan menggunakan data yang sama yaitu, 120 data. Selanjutnya data akan dibagi menjadi 98 data latih dan 20 data uji.


3. 2 Pengujian dan Analisis Perbedaan Learning Rate

Pengujian pertama merupakan pengujian perbedaan learning rate. Pengujian dilakukan dengan membedakan jumlah input learning rate yaitu 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, dan 1 dengan jumlah hidden layer 50, hidden neuron 5, dan maksimum epoch 1000. Pengujian dilakukan sebanyak 5 kali yang selanjutnya akan dihitung rata-rata dari nilai RMSE.

Tabel 1 Pengujian Perbedaan Learning Rate

Data Latih = 108 & Data Uji = 12, epoch = 50, hidden layer= 50, output = 1						
Learning Rate	RMSE					Rata-rata RMSE
	Percobaan Ke-1	Percobaan Ke-2	Percobaan Ke-3	Percobaan Ke-4	Percobaan Ke-5	
0.1	12,0102	14,9471	12,8311	11,6821	11,5633	12,6068
0.2	12,2378	12,5501	11,0087	11,7699	13,7221	12,2577
0.3	11,9506	10,0119	12,8221	12,1221	10,6590	11,5131
0.4	12,1381	12,9841	12,1919	11,3444	10,7832	11,8883
0.5	11,6440	12,0199	11,0172	10,9872	13,2354	11,7807
0.6	11,9051	13,5671	12,1101	12,3290	11,1209	12,2064
0.7	11,3663	11,9111	12,9506	10,9999	10,1350	11,4726
0.8	11,5363	11,4116	12,7765	12,0162	12,8744	12,1230
0.9	11,7648	12,2201	11,9581	11,1873	11,7138	11,7688

Dari hasil pengujian pada Tabel 1, didapatkan nilai rata-rata RMSE terbaik yaitu 11,4726 yang didapat dari learning dengan jumlah nilai learning rate adalah 0.7. Dari hasil rata-rata RMSE disetiap pengujian didapatkan grafik pada Gambar 3.



Gambar 3 Grafik Pengujian Perbedaan Learning Rate

3. 3 Pengujian dan Analisis Perbedaan Jumlah Hidden Layer


Pengujian kedua merupakan pengujian banyak hidden layer. Pengujian dilakukan dengan membedakan jumlah input hidden layer yaitu 1, 2, 3, 4, 5, 6, 7, 8, 9, dan 10 terhadap nilai learning rate 0.8 yang telah diuji pada sub-bab sebelumnya, neuron pada hidden layer 5, dan epoch sebanyak 1000.

Tabel 2 Pengujian Perbedaan 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	
1	12,6976	12,9089	12,1347	10,5441	12,8712	12,2313
2	11,8668	10,6122	9,9878	10,1123	11,9174	10,8993
3	11,7865	12,8227	12,0551	12,4619	12,0922	12,2437
4	9,4955	12,2111	12,7825	10,3298	11,7494	11,3137
5	10,888	9,7211	10,5609	11,9721	11,1601	10,8604
6	10,5006	10,8022	11,7656	11,4528	10,9045	11,0851
7	12,7733	11,7731	12,6009	12,4231	10,087	11,9315

8	9,0174	11,2751	9,7702	11,123	11,8025	10,5976
9	10,405	10,7606	12,9733	11,418	10,8205	11,2755
10	10,6914	11,2234	12,2003	12,4199	10,5404	11,4151

Dari hasil pengujian pada Tabel 2, didapatkan nilai rata-rata RMSE terbaik yaitu 10,5976 pada input hidden layer berjumlah 4, 5, 6, 7, 8, 9, dan 10. Namun, pada pengujian ini nilai input hidden layer yang diambil berjumlah 3 dikarenakan pada input hidden layer 4 sampai dengan 10 menghasilkan hasil prediksi yang tidak ada perubahan dan cenderung seragam. Berikut salah satu pengujian sistem menggunakan hidden layer berjumlah 4 dapat dilihat pada tabel 4.3. Dari hasil rata-rata RMSE disetiap pengujian didapatkan grafik pada Gambar 4.



Gambar 4 Grafik Pengujian Perbedaan Hidden Layer

Berdasarkan Gambar 4 nilai hidden layer dengan jumlah 4, 5, 6, 7, 8, 9, dan 10 memiliki nilai rata – rata RMSE yang sama yang mengakibatkan tidak ada perubahan yang signifikan terhadap hasil prediksi yang didapatkan. Kecilnya nilai rata – rata RMSE pada hidden layer 4 sama dengan 10 dikarenakan hasil prediksi yang cenderung sama lebih banyak mendekati nilai target, sehingga nilai rata – rata RMSE yang didapatkan kecil.


3. 4 Pengujian dan Analisis Perbedaan epoch

Pengujian perbedaan epoch dilakukan dengan menggunakan maksimum epoch 1000, learning rate, dan jumlah hidden layer terbaik yang telah dilakukan pada sub bab sebelumnya.

Tabel 3 Pengujian Perbedaan Epoch

Data Latih = 108 & Data Uji = 12, Hidden layer = 50, learning rate = 0.7, input layer= 5						
Epoch	RMSE					Rata-rata RMSE
	Percobaan Ke-1	Percobaan Ke-2	Percobaan Ke-3	Percobaan Ke-4	Percobaan Ke-5	
200	10,3282	11,0999	13,5488	10,5441	12,3213	11,5685
400	9,0117	9,6122	11,2865	10,1123	11,9174	10,3880
600	8,1551	9,1877	8,8718	12,2874	11,7494	10,0503
800	10,4527	11,5196	9,7702	8,9038	12,4598	10,6212
1000	12,0424	9,7211	10,5609	11,9721	11,1601	11,0913

Dari hasil pengujian pada Tabel 3, didapatkan nilai rata-rata RMSE terbaik yaitu 10,0503 yang didapat dari jumlah epoch. Grafik hasil rata-rata RMSE disetiap pengujian epoch dapat pada Gambar 5 berikut.



Gambar 5 Grafik Pengujian Perbedaan Epoch

3. 5 Pengujian K – Fold Cross Validation

Pengujian yang keempat adalah pengujian K-Fold Cross Validation. Pengujian K-fold dilakukan untuk melihat kestabilan pengujian data dengan mengelompokkan data berdasarkan beberapa K. Selain itu, pengujian ini bertujuan untuk melihat nilai RMSE terhadap perubahan data latih dan data uji. Pada pengujian ini menggunakan epoch 10000, learning rate, hidden layer, neuron pada hidden layer, dan 108 data latih dan 12 data uji yang telah dibagi berdasarkan K tertentu terhadap keseluruhan data. Hasil pengujian K-fold dapat dilihat pada Tabel 4.


Tabel 4 Pengujian K – Fold Cross Validation

Learning Rate = 0.8, Hidden Layer = 3, Neuron = 4, Epoch = 1000			
Nomor	Data Latih	Data Uji	Hasil RMSE
Percobaan 1	fold 1 - fold 2 - fold 3 - fold 4	fold 5	11.712
Percobaan 2	fold 2 - fold 3 - fold 4 - fold 5	fold 1	5.826
Percobaan 3	fold 3 - fold 4 - fold 5 - fold 1	fold 2	6.924
Percobaan 4	fold 4 - fold 5 - fold 1 - fold 2	fold 3	8.237
Percobaan 5	fold 5 - fold 1 - fold 2 - fold 3	fold 4	8.364
Rata - rata RMSE			8.2126

Berdasarkan Tabel 4 hasil rata – rata RMSE pada seluruh percobaan adalah 8.2126. Hasil RMSE terbesar didapatkan pada percobaan 1 dengan hasil RMSE 11.712 dengan data latih fold 1 – fold 2 – fold 3 – fold 4 dan data uji fold 5. Sedangkan untuk hasil RMSE terkecil didapatkan pada percobaan 2 dengan hasil RMSE 5.826 dengan data latih fold 2 – fold 3 – fold 4 – fold 5 dan data uji fold 1.

3. 6 Hasil Prediksi

Parameter neuron terbaik yang didapat pada proses training, akan diuji untuk memprediksi sehingga mendapatkan hasil data testing. Hasil pengujian menggunakan data training dapat dilihat pada Gambar 6 Perbandingan Data Training dan Hasil Prediksi yaitu pada grafik scatter yang berwarna biru merupakan hasil dari prediksi data training sebesar 80% dari total keseluruhan data dan grafik yang berwarna orange adalah hasil dari prediksi yang di dapat pada pengujian data training.



Gambar 6 Grafik Pengujian Perbedaan Epoch

Tabel 5 Hasil Grafik Prediksi

Data Asli (Dalam Satuan Hektar)	Hasil Prediksi (Dalam Satuan Hektar)
39	8
25	2
80	3
34	39
56	4
188	22
55	27
53	5
58	48
81	3
73	49
73	8
123	4
81	3
168	19
192	25
77	2
43	10
83	22
9	10

Pada table 5 menjelaskan hasil grafik prediksi dimana didapatkan nilai nilai hasil prediksi menggunakan acuan data asli dalam satuan hektar, sehingga didapatkan hasil nilai luas lahan penyebaran pada table diatas. Pada penelitian ini, artificial neural network algoritma backpropagation diimplementasikan pada grafik yang dibuat dengan output nilai asli dan nilai perhitungan hasil prediksi yang berupa luas sebaran dengan satuan hektar. Penelitian ini menggunakan sebanyak 120 sampel data yang mana 80 % data digunakan sebagai data uji atau training dan 20 % data digunakan sebagai data latih atau testing. Dari hasil perhitungan tabel diatas diperoleh persentase akurasi selisih error sebesar 16.2% yang artinya prediksi pada perhitungan ini cukup baik untuk digunakan sebagai acuan penelitian periode selanjutnya.

4. KESIMPULAN

Pada penelitian ini penulis mendapatkan beberapa kesimpulan. Pertama, nilai learning rate yang optimal sangat berpengaruh terhadap hasil prediksi produktivitas padi. Penggunaan nilai learning rate yang terlalu besar dapat membuat sistem divergen dan menghasilkan error yang mencapai local minimal. Dalam penelitian ini, nilai learning rate optimal adalah 0,8 yang memiliki nilai RMSE rata-rata terkecil dibandingkan dengan nilai lainnya. Kedua, pelatihan jaringan syaraf tiruan backpropagation pada hama tikus menunjukkan hasil terbaik dengan

durasi waktu 1 detik pada alfa 0,7, dan jumlah neuron tersembunyi sebanyak 50. Pelatihan berhenti pada epoch ke-50 dan menghasilkan MSE sebesar 11661521,4. Pada proses pengujian, MSE terkecil yang dihasilkan adalah 0,0000005542. Ketiga, berhasilnya prediksi pada penelitian ini bergantung pada beberapa kali percobaan yang dilakukan untuk mendapatkan nilai error terkecil dengan menggunakan metode backpropagation neural network, sehingga metode ini mampu memprediksi sebaran hama tikus untuk bulan berikutnya.

DAFTAR PUSTAKA

- [1] S. Sudewi, A. Ala, B. Baharuddin, and M. F. BDR, "Keragaman Organisme Pengganggu Tanaman (OPT) pada Tanaman Padi Varietas Unggul Baru (VUB) dan Varietas Lokal pada Percobaan Semi Lapangan," *Agrikultura*, vol. 31, no. 1, p. 15, 2020, doi: 10.24198/agrikultura.v31i1.25046.
- [2] G. I. Marthasari, S. A. Astiti, and Y. Azhar, "Prediksi Data Time-series menggunakan Jaringan Syaraf Tiruan Algoritma Backpropagation Pada Kasus Prediksi Permintaan Beras," *J. Inform. ...*, vol. 6, no. 3, pp. 187–193, 2021, [Online]. Available: <http://ejournal.poltektegal.ac.id/index.php/informatika/article/view/2627>.
- [3] P. Indrayati Sijabat, Y. Yuhandri, G. Widi Nurcahyo, and A. Sindar, "Algoritma Backpropagation Prediksi Harga Komoditi terhadap Karakteristik Konsumen Produk Kopi Lokal Nasional," *Digit. Zo. J. Teknol. Inf. dan Komun.*, vol. 11, no. 1, pp. 96–107, 2020, doi: 10.31849/digitalzone.v11i1.3880.
- [4] M. D. Yalidhan, "Implementasi Algoritma Backpropagation Untuk Memprediksi Kelulusan Mahasiswa," *Klik - Kumpul. J. Ilmu Komput.*, vol. 5, no. 2, p. 169, 2018, doi: 10.20527/klik.v5i2.152.
- [5] M. N. D. SAWITRI, I. W. SUMARJAYA, and N. K. T. TASTRAWATI, "Peramalan Menggunakan Metode Backpropagation Neural Network," *E-Jurnal Mat.*, vol. 7, no. 3, p. 264, 2018, doi: 10.24843/mtk.2018.v07.i03.p213.
- [6] E. Rohadi and R. Wakhidah, "Sistem Peramalan Penjualan Studi Kasus Topi Punggul H . M . Thoha dengan Metode Trend," *Semin. Inform. Apl. Polinema*, 2021.
- [7] Y. A. Hakim and M. T. Randy Erfa Saputra, S.T., "Sistem Pendukung Keputusan Penyiraman Tanaman Cabai Dengan Memanfaatkan Kecerdasan Buatan Menggunakan Algoritma Lstm Decision Support System of Chili Planting Using Artificial Intelligence Using Lstm Algorithm," pp. 4959–4967, 2020.
- [8] F. I. Sanjaya and D. Heksaputra, "Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 7, no. 2, pp. 163–174, 2020, doi: 10.35957/jatisi.v7i2.388.
- [9] M. L. Ashari and M. Sadikin, "Prediksi Data Transaksi Penjualan Time Series Menggunakan Regresi Lstm," *J. Nas. Pendidik. Tek. Inform.*, 2020.
- [10] P. Sugiartawan, A. A. J. P. Permana, and P. I. Prakoso, "Forecasting Kunjungan Wisatawan Dengan Long Short Term Memory (LSTM)," *J. Sist. Inf. dan Komput. Terap. Indones.*, vol. 1, no. 1, pp. 43–52, 2018.
- [11] I. Budiman, S. Saori, R. N. Anwar, Fitriani, and M. Y. Pangestu, "Analisis Pengendalian Mutu Di Bidang Industri Makanan," *J. Inov. Penelit.*, vol. 1, no. 0.1101/2021.02.25.432866, pp. 1–15, 2021.