



Optimasi JST *Backpropagation* dengan *Adaptive Learning Rate* Dalam Memprediksi Hasil Panen Padi

Prihandoko^{1*}, Putrama Alkhairi²

¹Departemen Teknologi Informasi, Universitas Gunadarma, Depok, Indonesia

²STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: pri@staff.gunadarma.ac.id¹, putrama@amiktunasbangsa.ac.id²

Abstract

Artificial Neural Networks (ANN) with the *Backpropagation* algorithm have been widely applied across various domains, including data prediction tasks. However, one of the primary challenges in implementing *Backpropagation* is the selection of an optimal learning rate. A learning rate that is too high can lead to unstable convergence, while one that is too low can significantly slow down the training process. To address this issue, this study proposes an optimization of *Backpropagation* using an *Adaptive Learning Rate* through the implementation of the Adam optimizer. The objective of this research is to analyze the performance comparison between Standard *Backpropagation* and *Backpropagation* with the Adam optimizer in predicting rice harvest yields based on rainfall, temperature, and humidity variables. The dataset consists of 100 synthetic samples generated based on a normal distribution to resemble real-world data. The results show that the use of the Adam optimizer improves the performance of the ANN model compared to the Standard *Backpropagation* method. Model accuracy increased from 92.04% to 92.99%, while the values of loss, Mean Squared Error (MSE), and Root Mean Squared Error (RMSE) decreased significantly, indicating that the model optimized with Adam is more stable and yields lower prediction errors. Therefore, *Adaptive Learning Rate* optimization using the Adam optimizer is proven to be effective in enhancing both the accuracy and efficiency of ANN in data prediction tasks.

Keywords: Artificial Neural Network, *Backpropagation*, *Adaptive Learning Rate*, Adam Optimizer, Data Prediction.

Abstrak

Jaringan Saraf Tiruan (JST) dengan algoritma *Backpropagation* telah banyak digunakan dalam berbagai bidang, termasuk dalam prediksi data. Namun, salah satu tantangan utama dalam penerapan *Backpropagation* adalah pemilihan learning rate yang optimal, karena learning rate yang terlalu besar dapat menyebabkan konvergensi yang tidak stabil, sementara learning rate yang terlalu kecil dapat memperlambat proses pelatihan. Untuk mengatasi masalah ini, penelitian ini mengusulkan optimasi *Backpropagation* menggunakan *Adaptive Learning Rate* dengan menerapkan optimizer Adam. Penelitian bertujuan untuk menganalisis perbandingan kinerja *Backpropagation* Standar dan *Backpropagation* dengan optimizer Adam dalam memprediksi hasil panen padi berdasarkan variabel curah hujan, suhu udara, dan kelembaban udara. Dataset yang digunakan terdiri dari 100 sampel data sintesis yang dibuat berdasarkan distribusi normal agar menyerupai data riil. Hasil penelitian menunjukkan bahwa penggunaan optimizer Adam meningkatkan kinerja model JST dibandingkan metode *Backpropagation* Standar. Akurasi model meningkat dari 92,04% menjadi 92,99%, sementara nilai loss, Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE) mengalami penurunan yang signifikan, menunjukkan bahwa model dengan optimasi Adam lebih stabil dan memiliki kesalahan prediksi yang lebih kecil. Dengan demikian, optimasi *Adaptive Learning Rate* menggunakan optimizer Adam terbukti efektif dalam meningkatkan akurasi dan efisiensi JST dalam tugas prediksi data.

Kata Kunci: Jaringan Saraf Tiruan, *Backpropagation*, *Adaptive Learning Rate*, Optimizer Adam, Prediksi Data.

1. PENDAHULUAN

Pertumbuhan sektor pertanian, khususnya produksi padi, memiliki peran strategis dalam ketahanan pangan dan perekonomian nasional [1], [2]. Produksi padi dipengaruhi oleh berbagai faktor lingkungan seperti curah hujan, suhu udara, dan kelembaban. Ketidakpastian dalam faktor-faktor ini sering kali menyebabkan fluktuasi hasil panen, yang berdampak pada kestabilan pasokan pangan dan harga beras di pasar [3], [4]. Oleh karena itu, pengembangan metode prediksi hasil panen yang akurat sangat diperlukan untuk membantu petani dan pembuat kebijakan dalam pengambilan keputusan yang lebih baik [5].

Dalam jaringan syaraf tiruan (JST), terdapat berbagai metode yang dapat digunakan untuk melakukan prediksi, tergantung pada jenis data dan tujuan analisis. Beberapa metode yang umum digunakan meliputi *Backpropagation* Neural Network (BPNN) [6], [7], yang memanfaatkan algoritma gradient descent untuk menyesuaikan bobot dan bias guna meminimalkan kesalahan prediksi, serta Radial Basis Function Neural Network (RBFNN) yang menggunakan fungsi aktivasi berbasis radial untuk mendeteksi pola dalam data non-linear [8], [9]. Selain itu, metode Long Short-Term Memory (LSTM)[10], [11], [12] sering digunakan dalam prediksi deret waktu karena kemampuannya dalam menangani dependensi jangka panjang, sedangkan Convolutional Neural Network (CNN)[13], [14], [15] lebih efektif dalam menganalisis data spasial seperti gambar atau sinyal. Metode lain seperti Extreme Learning Machine (ELM) menawarkan pendekatan yang lebih cepat dalam pelatihan jaringan dengan bobot tersembunyi yang ditentukan secara acak, sementara Deep Belief Network (DBN) [16] dan Restricted Boltzmann Machine (RBM) [17], [18] sering digunakan dalam pembelajaran mendalam untuk menangkap fitur kompleks dalam data. Dengan berbagai metode ini, JST dapat diterapkan secara luas dalam berbagai bidang seperti keuangan, kesehatan, cuaca, dan pengolahan citra untuk menghasilkan prediksi yang lebih akurat.

Pada penelitian terdahulu yang dilakukan oleh [19] artikel ini membahas jaringan saraf tiruan (ANN) dengan pendekatan feed-forward dan *backpropagation*, di mana sinyal hanya mengalir dari input ke output tanpa umpan balik, sementara *backpropagation* digunakan untuk mengurangi kesalahan dengan menyesuaikan bobot berdasarkan selisih antara output prediksi dan nilai target. Artikel ini memiliki kelebihan dalam memberikan penjelasan sistematis tentang ANN, menjelaskan algoritma *backpropagation* secara rinci, serta menyertakan ilustrasi yang membantu pemahaman. Namun, terdapat beberapa kekurangan, seperti tidak adanya studi kasus atau eksperimen nyata untuk mendukung teori, kurangnya kedalaman dalam aspek matematis bagi pembaca yang menginginkan analisis lebih teknis, serta tidak adanya perbandingan dengan metode pembelajaran mesin lainnya yang mungkin lebih efisien dalam beberapa situasi. Sedangkan pada penelitian berikutnya yang dilakukan oleh [20] artikel ini membahas berbagai teknik dalam jaringan saraf tiruan (JST), khususnya dalam konteks pembelajaran mesin dan optimasi. Artikel ini menjelaskan konsep dasar JST, arsitektur jaringan, serta metode pelatihan seperti *backpropagation* untuk meningkatkan akurasi model. Selain itu, dibahas

juga penerapan JST dalam berbagai bidang, termasuk pengenalan pola, klasifikasi data, dan prediksi. Kelebihan artikel ini terletak pada penyajiannya yang sistematis dan komprehensif, memberikan wawasan mendalam mengenai algoritma pembelajaran serta aplikasinya dalam dunia nyata. Namun, kekurangannya adalah kurangnya studi kasus atau eksperimen empiris yang mendukung teori yang dijelaskan, serta minimnya perbandingan dengan teknik pembelajaran mesin lainnya yang mungkin lebih efisien dalam beberapa skenario.

Berdasarkan studi literatur yang telah diuraikan sebelumnya, seiring dengan perkembangan teknologi, penerapan kecerdasan buatan (Artificial Intelligence - AI) dalam bidang pertanian semakin mendapat perhatian. Salah satu teknik yang banyak digunakan untuk prediksi berbasis data adalah Jaringan Syaraf Tiruan (JST) [3], [21]. JST memiliki kemampuan untuk mengenali pola dalam data historis dan memprediksi hasil panen dengan tingkat akurasi yang tinggi. Namun, salah satu tantangan utama dalam implementasi JST adalah optimasi algoritma pelatihan, terutama dalam proses pembelajaran yang menggunakan metode *Backpropagation* [22], [23].

Metode *Backpropagation* adalah salah satu algoritma pembelajaran yang paling umum digunakan dalam JST untuk mengoptimalkan bobot jaringan berdasarkan perhitungan error [24], [25]. Namun, metode ini memiliki beberapa keterbatasan, seperti konvergensi lambat, terjebak pada minimum lokal, dan sensitivitas terhadap pemilihan nilai learning rate. Penggunaan learning rate tetap sering kali menyebabkan model sulit untuk beradaptasi dengan perubahan pola data, sehingga menghambat efektivitas dalam memprediksi hasil panen secara akurat [24], [25], [26], [27], [28].

Untuk mengatasi masalah ini, digunakan teknik *Adaptive Learning Rate*, salah satunya adalah Adam (Adaptive Moment Estimation) [29], [30]. Adam adalah metode optimasi yang secara dinamis menyesuaikan learning rate untuk setiap parameter berdasarkan estimasi momen pertama (mean) dan momen kedua (variance) dari gradien. Teknik ini telah terbukti lebih efisien dibandingkan dengan Stochastic Gradient Descent (SGD) standar dalam berbagai aplikasi JST [31], [32], termasuk dalam prediksi data time series seperti hasil panen padi.

Penelitian ini bertujuan untuk mengoptimalkan JST *Backpropagation* dengan *Adaptive Learning Rate* menggunakan metode Adam, serta membandingkan kinerjanya dengan metode *Backpropagation* standar. Studi ini akan menguji apakah penggunaan Adam dapat meningkatkan akurasi prediksi, mempercepat konvergensi, dan mengurangi kesalahan dalam model JST. Dengan hasil yang lebih akurat, penelitian ini diharapkan dapat memberikan kontribusi dalam meningkatkan efektivitas perencanaan pertanian, optimalisasi produksi, serta pengelolaan sumber daya secara lebih efisien.

2. METODOLOGI PENELITIAN

Metode penelitian ini bertujuan untuk mengembangkan model prediksi hasil panen padi menggunakan Jaringan Syaraf Tiruan (JST) dengan

Backpropagation, serta mengoptimalkan proses pembelajaran dengan metode *Adaptive Learning Rate* (Adam Optimizer). Penelitian ini akan menggunakan dataset sintetis yang merepresentasikan faktor-faktor cuaca yang berpengaruh terhadap hasil panen, serta membandingkan performa antara metode *Backpropagation* Standar dan *Backpropagation* dengan Adam Optimizer.

Penelitian ini terdiri dari beberapa tahapan, yaitu pengumpulan dan pemrosesan data, perancangan model JST, pelatihan model, evaluasi performa, serta analisis hasil. Setiap langkah dalam penelitian ini dirancang untuk memastikan bahwa model yang dikembangkan memiliki akurasi yang tinggi dalam memprediksi hasil panen berdasarkan data historis.

2.1. Dataset Penelitian

Dataset yang digunakan dalam penelitian ini terdiri dari 100 sampel data bulanan yang mencakup periode sekitar 8 tahun. Dataset ini dibuat secara sintetis dengan mempertimbangkan hubungan antara curah hujan, suhu udara, dan kelembaban udara terhadap hasil panen padi. Data ini dibuat menggunakan distribusi normal dengan nilai rata-rata dan standar deviasi yang disesuaikan agar menyerupai data riil. Variabel-variabel dalam dataset ini terdiri dari:

- a. Curah Hujan (mm) → Jumlah curah hujan bulanan
- b. Suhu Udara (°C) → Suhu rata-rata bulanan
- c. Kelembaban Udara (%) → Tingkat kelembaban rata-rata bulanan
- d. Hasil Panen (ton/ha) → Target yang diprediksi (jumlah hasil panen padi per hektar)

Tabel 1. Sampel Data Penelitian

Tanggal	Curah_Hujan	Suhu	Kelembaban	Hasil_Panen
31/01/2015	164,901425	25,169259	76,788937	4,011833
28/02/2015	145,852071	27,158709	77,803923	3,876573
31/03/2015	169,430656	27,314571	80,415256	4,810530
30/04/2015	195,690896	26,395445	80,269010	5,047702
31/05/2015	142,975399	27,677429	68,111653	3,897665

Pada Tabel 1, dataset dibuat secara sintetis dengan mempertimbangkan hubungan kausal antara variabel cuaca dan hasil panen. Model regresi sederhana digunakan untuk membentuk data hasil panen dengan penambahan noise acak agar menyerupai data riil. Selanjutnya, data ini akan dibagi menjadi data pelatihan (80%) dan data pengujian (20%), serta akan dinormalisasi menggunakan *Min-Max Scaling* untuk meningkatkan stabilitas dan kinerja model JST.

2.2. Perbandingan Model Usulan dan Model Standar

Dalam penelitian ini, dua pendekatan pembelajaran JST akan dibandingkan, yaitu *Backpropagation* Standar dan *Backpropagation* dengan Adam Optimizer. Perbandingan ini dilakukan untuk mengevaluasi bagaimana metode *Adaptive*

Learning Rate dapat meningkatkan akurasi dan efisiensi model dalam mempelajari pola data hasil panen padi.

1. Model JST dengan *Backpropagation* Standar
 - a. Menggunakan algoritma *Stochastic Gradient Descent* (SGD) dengan learning rate tetap sebesar 0.01.
 - b. Model ini sering mengalami konvergensi lambat dan rentan terhadap minimum lokal, sehingga hasil prediksinya mungkin kurang optimal.
2. Model JST dengan *Adam Optimizer (Adaptive Learning Rate)* – Model Usulan
 - a. Menggunakan Adam Optimizer, yang secara otomatis menyesuaikan learning rate berdasarkan gradien momen pertama (mean) dan momen kedua (variance).
 - b. Diharapkan mampu mempercepat konvergensi, menghindari minimum lokal, dan meningkatkan akurasi prediksi.

Performa kedua model akan dibandingkan menggunakan beberapa metrik evaluasi, yaitu:

- a. MSE (*Mean Squared Error*): Mengukur rata-rata error kuadrat antara hasil prediksi dan data aktual.
- b. RMSE (*Root Mean Squared Error*): Mengukur akar kuadrat dari MSE untuk memahami error dalam satuan yang sama dengan data asli.
- c. Akurasi (%): Mengukur tingkat ketepatan prediksi dibandingkan dengan data aktual.
- d. Recall dan Precision: Digunakan untuk menilai kinerja model dalam mendeteksi tren peningkatan atau penurunan hasil panen.

Dengan melakukan perbandingan ini, penelitian bertujuan untuk membuktikan bahwa metode Adam Optimizer lebih unggul dibandingkan dengan metode *Backpropagation* Standar dalam memprediksi hasil panen padi.

2.3. Rancangan Penelitian

Rancangan penelitian ini terdiri dari beberapa tahapan utama yang mencakup persiapan data, pembangunan model, pelatihan, evaluasi, dan analisis hasil. Setiap tahapan ini dirancang agar model JST dapat bekerja secara optimal dalam melakukan prediksi hasil panen berdasarkan data historis. Pada gambar 3. dengan rancangan penelitian ini, diharapkan model JST dengan *Adaptive Learning Rate* (Adam Optimizer) dapat meningkatkan akurasi prediksi hasil panen padi dibandingkan dengan metode *Backpropagation* standar. Berikut penjelasan tahapannya:

1) Persiapan Data

- a. Menghasilkan dataset sintesis berdasarkan faktor cuaca yang berpengaruh terhadap hasil panen padi.
- b. Melakukan *Preprocessing* data, yaitu normalisasi menggunakan Min-Max Scaling untuk meningkatkan stabilitas pelatihan model.
- c. Membagi dataset menjadi 80% data latih dan 20% data uji untuk pengujian performa model.

2) Pembangunan Model JST

- a. Mendesain arsitektur JST dengan:

1. 3 neuron input (Curah Hujan, Suhu, dan Kelembaban).
 2. 2 hidden layer, masing-masing dengan 10 neuron dan aktivasi ReLU.
 3. 1 neuron output untuk prediksi hasil panen.
- b. Melatih model pertama menggunakan *Backpropagation* Standar (SGD Optimizer).
 - c. Melatih model kedua menggunakan *Backpropagation* dengan Adam Optimizer.

3) Training dan Validasi Model

- a. Melatih kedua model selama 200 *epoch*.
- b. Mencatat *training loss* dan *validation loss* pada setiap *epoch* untuk mengevaluasi proses pembelajaran model.

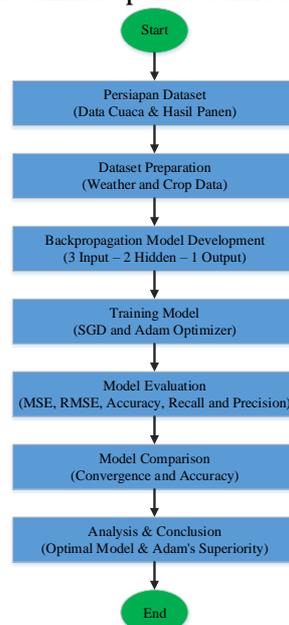
4) Evaluasi dan Perbandingan Model

- a. Menghitung nilai MSE, RMSE, Akurasi, *Precision*, dan *Recall* untuk kedua model.
- b. Menampilkan grafik *loss function* untuk membandingkan konvergensi dari kedua metode.
- c. Membandingkan hasil prediksi terhadap data aktual menggunakan grafik perbandingan hasil prediksi.

5) Analisis Hasil dan Kesimpulan

- a. Menentukan model yang lebih optimal berdasarkan hasil evaluasi.
- b. Menganalisis keunggulan dan keterbatasan masing-masing model dalam memprediksi hasil panen padi.
- c. Memberikan rekomendasi terkait penggunaan metode *Adaptive Learning Rate* dalam JST untuk prediksi data time series di bidang pertanian.

Rancangan penelitian bisa dapat dilihat pada Gambar 1 berikut.



Gambar 1. Rancangan Penelitian

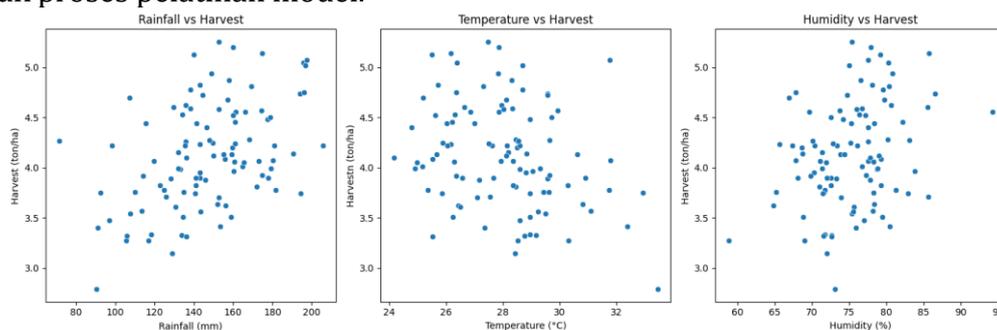
3. HASIL DAN PEMBAHASAN

3.1. Hasil

Hasil penelitian ini menunjukkan bahwa penggunaan *optimizer Adam* dalam metode *backpropagation* memberikan peningkatan kinerja model jaringan saraf tiruan (JST) dibandingkan dengan *backpropagation* standar. Dengan menggunakan dataset sintetis yang terdiri dari 100 sampel data bulanan selama 8 tahun, model diuji berdasarkan metrik akurasi, *loss*, *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Hasilnya, metode *Backpropagation* Standar menghasilkan akurasi sebesar 92,04% dengan nilai *loss* sebesar 0,0289, MSE sebesar 0,1589, dan RMSE sebesar 0,3986. Sementara itu, metode *Backpropagation + Adam* menunjukkan peningkatan akurasi menjadi 92,99%, dengan *loss* yang lebih rendah sebesar 0,0171, MSE sebesar 0,1041, dan RMSE sebesar 0,3226. Dari hasil ini dapat disimpulkan bahwa penggunaan *optimizer Adam* membantu JST dalam meningkatkan akurasi prediksi dan mengurangi tingkat kesalahan secara signifikan, sehingga model dapat melakukan generalisasi yang lebih baik terhadap pola data yang diberikan.

3.1.1. Proses *Preprocessing Data*

Preprocessing data merupakan tahap penting dalam penelitian ini untuk memastikan bahwa data yang digunakan memiliki kualitas yang baik dan dapat diproses dengan optimal oleh jaringan saraf tiruan (JST). Dataset yang digunakan terdiri dari 100 sampel data bulanan selama periode 8 tahun, dengan variabel utama berupa curah hujan (mm), suhu udara (°C), kelembaban udara (%), dan hasil panen (ton/ha) sebagai variabel target yang akan diprediksi. Karena data dibuat secara sintetis menggunakan distribusi normal, langkah *Preprocessing* bertujuan untuk memastikan bahwa dataset memiliki distribusi yang sesuai untuk proses pelatihan model.



Gambar 2. Persebaran Dataset setelah di Preproseing Data

Tahapan *Preprocessing* yang dilakukan meliputi:

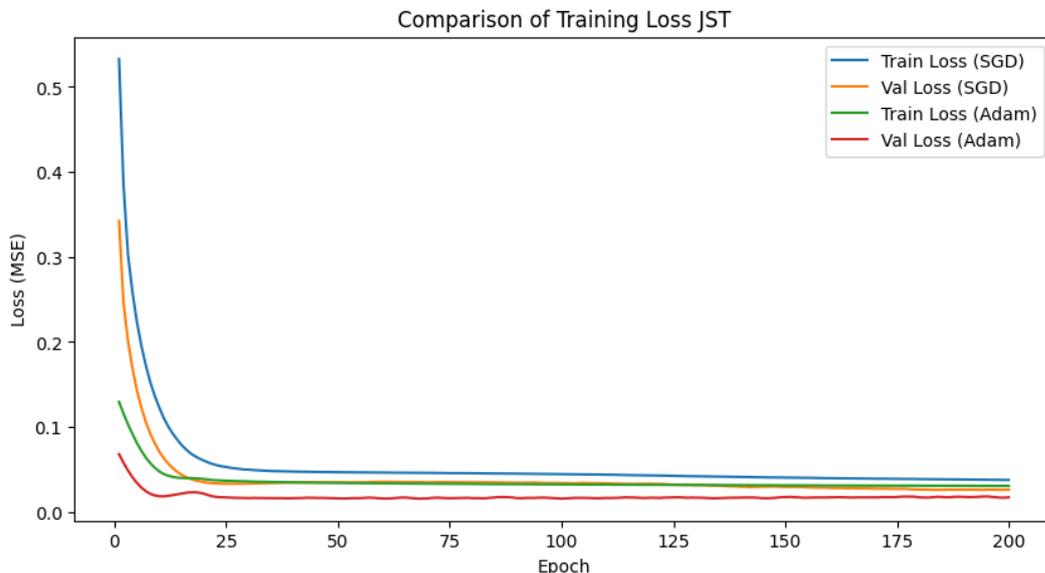
- a) Pemeriksaan dan Penanganan Data Hilang – Meskipun dataset sintetis biasanya tidak mengandung data yang hilang (*missing values*), pemeriksaan tetap dilakukan untuk memastikan integritas data. Jika ditemukan data kosong, metode imputasi seperti interpolasi atau pengisian dengan rata-rata dapat diterapkan.

- b) Normalisasi Data – Untuk meningkatkan kinerja model JST, fitur-fitur input seperti curah hujan, suhu udara, dan kelembaban udara dinormalisasi ke dalam rentang [0,1] menggunakan metode *Min-Max Scaling*. Normalisasi ini dilakukan agar setiap fitur memiliki skala yang seragam, sehingga model dapat belajar lebih efektif dan mempercepat proses konvergensi.
- c) Pembagian Dataset – Dataset dibagi menjadi dua subset utama: 80% untuk data pelatihan dan 20% untuk data pengujian. Data pelatihan digunakan untuk melatih model JST agar mampu mengenali pola hubungan antara variabel input dan hasil panen, sedangkan data pengujian digunakan untuk mengevaluasi kinerja model terhadap data yang belum pernah dilihat sebelumnya.

Dengan *Preprocessing* yang tepat, model dapat belajar dari data secara optimal, menghindari bias akibat skala yang tidak seragam, serta meningkatkan akurasi prediksi hasil panen padi.

3.1.2. Perbandingan Training Akurasi dan Loss JST

Dalam penelitian ini, dua metode digunakan untuk melatih JST, yaitu *Backpropagation Standar* dan *Backpropagation dengan Optimizer Adam*. Perbandingan performa kedua metode diukur menggunakan *loss* selama proses pelatihan.



Gambar 3. Loss Pelatihan

Pada Gambar 3 menjelaskan tentang training *loss* yang merupakan metrik yang digunakan untuk mengukur seberapa besar kesalahan model dalam memprediksi nilai target selama proses pelatihan. Semakin kecil nilai *loss*, semakin baik model dalam menyesuaikan bobot dan bias untuk menghasilkan prediksi yang lebih akurat. Dalam penelitian ini, perbandingan dilakukan antara metode *Backpropagation Standar* dan *Backpropagation dengan Optimizer Adam* untuk melihat efektivitas masing-masing dalam menekan nilai *loss*.

Berdasarkan hasil pelatihan, metode *Backpropagation Standar* menghasilkan nilai *loss* sebesar **0,0289**, sedangkan metode *Backpropagation + Adam* memiliki *loss* yang lebih rendah, yaitu **0,0171**. Perbedaan ini menunjukkan bahwa optimasi Adam lebih efektif dalam memperbaiki bobot jaringan dengan lebih cepat dan stabil dibandingkan metode *backpropagation* standar. Hal ini disebabkan oleh mekanisme Adam yang menggabungkan momentum dan adaptasi learning rate, sehingga pembaruan bobot lebih efisien dan menghindari jebakan *local minima*. Dengan *loss* yang lebih kecil, model yang menggunakan *optimizer Adam* memiliki tingkat kesalahan yang lebih rendah, yang berkontribusi pada peningkatan akurasi prediksi secara keseluruhan.

3.2. Pembahasan

Dari hasil yang diperoleh, terlihat bahwa metode *Backpropagation + Adam* lebih unggul dibandingkan *Backpropagation Standar* dalam berbagai aspek evaluasi. Peningkatan akurasi sebesar 0,95% menunjukkan bahwa model dengan optimasi Adam mampu menggeneralisasi data dengan lebih baik dibandingkan dengan metode standar. Selain itu, penurunan *loss* serta MSE dan RMSE menunjukkan bahwa model dengan *optimizer Adam* memiliki tingkat kesalahan yang lebih rendah, sehingga prediksinya lebih akurat. Keunggulan ini dapat dijelaskan oleh mekanisme kerja Adam, yang menggabungkan momentum dan adaptasi learning rate untuk mempercepat konvergensi dan mengurangi osilasi dalam pembaruan bobot jaringan. Dengan demikian, optimasi Adam memungkinkan model JST untuk belajar lebih efisien dan mencapai performa yang lebih optimal dalam menyelesaikan tugas klasifikasi dan prediksi.

Tabel 2. Hasil Penelitian

Metode	Akurasi	Loss	MSE	RMSE
<i>Backpropagation Standar</i>	92,04	0,0289	0,1589	0,3986
<i>Backpropagation + Adam</i>	92,99	0,0171	0,1041	0,3226

Pada Tabel 2, hasil penelitian menunjukkan bahwa metode *Backpropagation* dengan *Optimizer Adam* memiliki kinerja yang lebih baik dibandingkan dengan *Backpropagation Standar* dalam memprediksi hasil panen berdasarkan variabel curah hujan, suhu udara, dan kelembaban udara. Dari segi akurasi, metode *Backpropagation Standar* menghasilkan 92,04%, sementara metode *Backpropagation + Adam* memiliki akurasi yang lebih tinggi, yaitu 92,99%. Peningkatan ini menunjukkan bahwa *optimizer Adam* mampu membantu jaringan saraf tiruan (JST) dalam menemukan bobot optimal dengan lebih cepat dan akurat. Selain itu, nilai *loss*, *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE) juga menunjukkan perbedaan yang signifikan. *Backpropagation Standar* memiliki *loss* sebesar 0,0289, MSE 0,1589, dan RMSE 0,3986, sedangkan *Backpropagation + Adam* memiliki *loss* yang lebih kecil, yaitu 0,0171, dengan MSE 0,1041 dan RMSE 0,3226. Nilai *loss* dan error yang lebih kecil menunjukkan bahwa model dengan *optimizer Adam* mampu mengurangi kesalahan prediksi secara lebih efektif dibandingkan metode standar.

4. SIMPULAN

Berdasarkan penelitian yang berjudul "Optimasi JST *Backpropagation* Menggunakan *Adaptive Learning Rate*: Studi Kasus pada Prediksi Data", dapat disimpulkan bahwa penggunaan *optimizer Adam* dalam algoritma *Backpropagation* terbukti meningkatkan kinerja jaringan saraf tiruan (JST) dalam memprediksi hasil panen berdasarkan variabel curah hujan, suhu udara, dan kelembaban udara. Hasil penelitian menunjukkan bahwa metode *Backpropagation* Standar menghasilkan akurasi sebesar 92,04% dengan nilai *loss* 0,0289, *Mean Squared Error* (MSE) 0,1589, dan *Root Mean Squared Error* (RMSE) 0,3986. Sementara itu, metode *Backpropagation* + *Adam* menunjukkan peningkatan akurasi menjadi 92,99%, dengan *loss* lebih rendah sebesar 0,0171, MSE 0,1041, dan RMSE 0,3226. Peningkatan kinerja ini menunjukkan bahwa penggunaan *Adaptive Learning Rate* melalui *optimizer Adam* mampu membantu jaringan dalam mempercepat konvergensi, mengurangi tingkat kesalahan prediksi, serta meningkatkan stabilitas pembelajaran dibandingkan dengan metode *Backpropagation* Standar. Dengan demikian, penelitian ini membuktikan bahwa optimasi JST menggunakan *Adaptive Learning Rate* dapat menjadi solusi yang lebih efisien dalam meningkatkan akurasi dan efektivitas model prediksi berbasis JST.

DAFTAR PUSTAKA

- [1] S. Setianingsih, M. U. Chasanah, Y. I. Kurniawan, And L. Afuan, "Implementation Of Particle Swarm Optimization In K-Nearest Neighbor Algorithm As Optimization Hepatitis C Classification Implementasi Particle Swarm Optimization Pada Algoritma K- Nearest Neighbor Untuk Optimasi Penentuan Klasifikasi," Vol. 4, No. 2, Pp. 457-465, 2023.
- [2] B. Gunawan, M. E. Al-Rivan, P. S. Informatika, U. Multi, And D. Palembang, "2nd Mdp Student Conference (Msc) 2023 E-Issn: 2985-7406 Klasifikasi Jenis Beras Putih Menggunakan Cnn Residual Network Optimizer Sgd," Pp. 128-132, 2023.
- [3] C. Karapataki And J. Adamowski, "Comparison Of Multivariate Regression And Artificial Neural Networks For Peak Urban Water-Demand Forecasting: Evaluation Of Different Ann Learning Algorithms," *J. Hydrol. Eng.*, Vol. 17, No. 7, Pp. 834-836, 2012, Doi: 10.1061/(Asce)He.1943-5584.0000472.
- [4] B. S. Laili, D. T. Utomo, And D. Wijanarko, "Implementasi Metode *Backpropagation* Neural Network Dalam Memprediksi Hasil Produksi Kedelai," *J. Teknol. Inf. Dan Terap.*, Vol. 10, No. 1, Pp. 1-6, 2023, Doi: 10.25047/Jtit.V10i1.145.
- [5] F. Yu And X. Xu, "A Short-Term Load Forecasting Model Of Natural Gas Based On Optimized Genetic Algorithm And Improved Bp Neural Network," *Appl. Energy*, Vol. 134, Pp. 102-113, 2014, Doi: 10.1016/J.Apenergy.2014.07.104.
- [6] P. Alkhairi, A. P. Windarto, And M. M. Efendi, "Optimasi Lstm Mengurangi Overfitting Untuk Klasifikasi Teks Menggunakan Kumpulan Data Ulasan Film Kaggle Imdb," Vol. 6, No. 2, Pp. 1142-1150, 2024, Doi: 10.47065/Bits.V6i2.5850.
- [7] S. Defit, A. P. Windarto, And P. Alkhairi, "Comparative Analysis Of Classification Methods In Sentiment Analysis: The Impact Of Feature Selection And Ensemble Techniques Optimization," *Telematika*, Vol. 17, No. 1, Pp. 52-67, 2024, Doi: 10.35671/Telematika.V17i1.2824.
- [8] C. F. Chao And M. H. Horng, "The Construction Of Support Vector Machine

- Classifier Using The Firefly Algorithm," *Comput. Intell. Neurosci.*, Vol. 2015, 2015, Doi: 10.1155/2015/212719.
- [9] I. T. Hidayat, E. C. Djamal, And R. Ilyas, "Brain Computer Interface Untuk Aksi Memutar Lagu Terhadap Tiga Kondisi Emosional Menggunakan Spektral Daya Dan Adaptive *Backpropagation*," Pp. 35–40, 2017.
- [10] H.-K. Jo, S.-H. Kim, And C.-L. Kim, "Proposal Of A New Method For Learning Of Diesel Generator Sounds And Detecting Abnormal Sounds Using An Unsupervised Deep Learning Algorithm," *Nucl. Eng. Technol.*, Vol. 55, No. 2, Pp. 506–515, 2022, Doi: 10.1016/J.Net.2022.10.019.
- [11] M. Ahmad *Et Al.*, "A Lightweight Convolutional Neural Network Model For Liver Segmentation In Medical Diagnosis," Vol. 2022, 2022.
- [12] W. N. Ismail, H. A. Alsalamah, M. M. Hassan, And E. Mohamed, "Auto-Har: An Adaptive Human Activity Recognition Framework Using An Automated Cnn Architecture Design," *Heliyon*, Vol. 9, No. 2, P. E13636, 2023, Doi: 10.1016/J.Heliyon.2023.E13636.
- [13] N. Kesav, "Efficient And Low Complex Architecture For Detection And Classification Of Brain Tumor Using Rcn With Two Channel Cnn," *J. King Saud Univ. - Comput. Inf. Sci.*, Vol. 34, No. 8, Pp. 6229–6242, 2022, Doi: 10.1016/J.Jksuci.2021.05.008.
- [14] B. Eidel, "Deep Cnns As Universal Predictors Of Elasticity Tensors In Homogenization," *Comput. Methods Appl. Mech. Eng.*, Vol. 403, P. 115741, 2023, Doi: 10.1016/J.Cma.2022.115741.
- [15] A. Naik, "Lung Nodule Classification Using Combination Of Cnn, Second And Higher Order Texture Features," *J. Intell. Fuzzy Syst.*, Vol. 41, No. 5, Pp. 5243–5251, 2021, Doi: 10.3233/Jifs-189847.
- [16] L. R. Chilakala, "Optimal Deep Belief Network With Opposition-Based Hybrid Grasshopper And Honeybee Optimization Algorithm For Lung Cancer Classification: A Dbngghb Approach," *Int. J. Imaging Syst. Technol.*, Vol. 31, No. 3, Pp. 1404–1423, 2021, Doi: 10.1002/Ima.22515.
- [17] S. Kamada, T. Ichimura, A. Hara, And K. J. Mackin, "Adaptive Structure Learning Method Of Deep Belief Network Using Neuron Generation – Annihilation And Layer Generation," *Neural Comput. Appl.*, Vol. 0123456789, 2018, Doi: 10.1007/S00521-018-3622-Y.
- [18] S. Kamada And T. Ichimura, "An Adaptive Learning Method Of Deep Belief Network By Layer Generation Algorithm Hj Hj," Pp. 2967–2970, 2016.
- [19] S. A. Balaji, "Feed Forward Back Propagation Neural Network Coupled With Rice Data Simulator For Prediction Of Rice Production In Tamilnadu," Vol. 4, No. 5, Pp. 11–31, 2014.
- [20] M. Palakuru, S. Adamala, And H. B. Bachina, "Modeling Yield And Backscatter Using Satellite Derived Biophysical Variables Of Rice Crop Based On Artificial Neural Networks," *J. Agrometeorol.*, Vol. 22, No. 1, Pp. 41–47, 2020.
- [21] D. Kurniasari *Et Al.*, "Implementation Of Artificial Neural Network (Ann) Using *Backpropagation* Algorithm By Comparing Four Activation," Pp. 93–105, 2023.
- [22] P. Alkhairi, W. Wanayumini, And B. H. Hayadi, "Analysis Of The *Adaptive Learning Rate* And Momentum Effects On Prediction Problems In Increasing The Training Time Of The *Backpropagation* Algorithm," *Aip Conf. Proc.*, Vol. 3048, No. 1, P. 20049, 2024, Doi: 10.1063/5.0203374.
- [23] P. Alkhairi, E. R. Batubara, R. Rosnelly, W. Wanayaumini, And H. S. Tambunan, "Effect Of Gradient Descent With Momentum *Backpropagation* Training Function

- In "Detecting Alphabet Letters," *Sinkron*, Vol. 8, No. 1, Pp. 574–583, 2023, Doi: 10.33395/Sinkron.V8i1.12183.
- [24] M. Shoaib, "Intelligent Computing With Levenberg–Marquardt *Backpropagation* Neural Networks For Third-Grade Nanofluid Over A Stretched Sheet With Convective Conditions," *Arab. J. Sci. Eng.*, Vol. 47, No. 7, Pp. 8211–8229, 2022, Doi: 10.1007/S13369-021-06202-5.
- [25] O. N. A. Al-Allaf, "Improving The Performance Of *Backpropagation* Neural Network Algorithm For Image Compression/Decompression System," *J. Comput. Sci.*, Vol. 6, No. 11, Pp. 1347–1354, 2010, Doi: 10.3844/Jcssp.2010.1347.1354.
- [26] N. A. Setyadi, M. Nasrun, And C. Setianingsih, "Text Analysis For Hate Speech Detection Using *Backpropagation* Neural Network," *Proc. - 2018 Int. Conf. Control. Electron. Renew. Energy Commun. Iccerrec 2018*, Pp. 159–165, 2018, Doi: 10.1109/Iccerrec.2018.8712109.
- [27] P. Alkhairi, E. R. Batubara, R. Rosnelly, W. Wanayaumini, And H. S. Tambunan, "Effect Effect Of Gradient Descent With Momentum *Backpropagation* Training Function In Detecting Alphabet Letters," *Sink. J. Dan Penelit. Tek. Inform.*, Vol. 8, No. 1, Pp. 574–583, 2023, Doi: 10.33395/Sinkron.V8i1.12183.
- [28] Y. Kurniawati, "Optimization Of *Backpropagation* Using Harmony Search For Gold Price Forecasting," *Pakistan J. Stat. Oper. Res.*, Vol. 18, No. 3, Pp. 589–599, 2022, Doi: 10.18187/Pjsor.V18i3.3915.
- [29] R. Poojary, "Comparative Study Of Model Optimization Techniques In Fine-Tuned Cnn Models," Pp. 22–25, 2019.
- [30] Putrama Alkhairi And A. P. Windarto, "Classification Analysis Of Back Propagation-Optimized Cnn Performance In Image Processing," *J. Syst. Eng. Inf. Technol.*, Vol. 2, No. 1, Pp. 8–15, 2023, Doi: 10.29207/Joseit.V2i1.5015.
- [31] R. Leluc And F. Portier, "Sgd With Coordinate Sampling: Theory And Practice," Vol. 23, Pp. 1–47, 2021, [Online]. Available: [Http://Arxiv.Org/Abs/2105.11818](http://Arxiv.Org/Abs/2105.11818)
- [32] D. Irfan And T. S. Gunawan, "Comparison Of Sgd , Rmsprop , And Adam Optimization In Animal Classification Using Cnns," *2nd Int. Conf. Infomation Sci. Anda Technol. Innov.*, 2023.