

Analisis Kinerja Deep Neural Network dalam Klasifikasi Citra Angka MNIST

Lisa Ramadhani

Program Studi : Sistem Informasi, Universitas Darwan Ali

Email : lisaramadhani.oxy@gmail.com

ABSTRACT— This study investigates the application of Deep Learning using a Deep Neural Network (DNN) architecture for handwritten digit image classification on the MNIST dataset. The MNIST dataset is employed as a standard benchmark in the field of computer vision, consisting of 60,000 training images and 10,000 test images of grayscale handwritten digits with a resolution of 28×28 pixels. The Deep Neural Network model is developed using the TensorFlow and Keras frameworks, incorporating Rectified Linear Unit (ReLU) activation functions in the hidden layers and a Softmax activation function in the output layer. The research stages include data preprocessing through pixel value normalization, neural network architecture design, model training using the backpropagation algorithm with the Adam optimizer, and performance evaluation based on accuracy metrics. Experimental results show that the proposed Deep Neural Network model achieves an accuracy of 97.66% on the MNIST test dataset. These results indicate that a relatively simple Deep Neural Network architecture is capable of delivering stable and effective classification performance, making it suitable as a baseline model before employing more complex architectures such as Convolutional Neural Networks (CNNs).

Keywords— Deep Learning, Deep Neural Network, MNIST, Image Classification, Artificial Intelligence.

ABSTRAK— Penelitian ini mengeksplorasi penerapan teknik Deep Learning dengan memanfaatkan struktur Deep Neural Network (DNN) untuk mengklasifikasikan gambar angka yang ditulis tangan dalam dataset MNIST. Dataset MNIST dipilih karena merupakan dataset yang diakui secara luas dalam bidang visi komputer, yang terdiri dari 60.000 data untuk pelatihan dan 10.000 data untuk pengujian berupa gambar grayscale dengan ukuran 28×28 piksel. Model Deep Neural Network dirancang menggunakan framework TensorFlow dan Keras dengan beberapa layer tersembunyi yang menerapkan fungsi aktivasi Rectified Linear Unit (ReLU) serta fungsi Softmax pada layer keluaran. Proses penelitian mencakup pra-pemrosesan data melalui normalisasi nilai piksel, desain arsitektur jaringan syaraf, pelatihan model menggunakan algoritma backpropagation dengan optimizer Adam, dan penilaian kinerja model dengan metrik akurasi. Hasil dari pengujian memperlihatkan bahwa model Deep Neural Network yang dibuat bisa mencapai tingkat akurasi sebesar 97,66% pada data tes MNIST. Temuan ini menandakan bahwa struktur Deep Neural Network yang tergolong sederhana dapat memberikan hasil klasifikasi yang baik dan konsisten, sehingga dapat berfungsi sebagai model dasar sebelum ditingkatkan menjadi arsitektur yang lebih rumit seperti Convolutional Neural Network (CNN).

Kata kunci— Deep Learning, Deep Neural Network, MNIST, Klasifikasi Citra, Artificial Intelligence.

I. PENDAHULUAN

Perkembangan teknologi informasi dan komputasi telah mempercepat penggunaan Kecerdasan Buatan (AI) di berbagai sektor. Salah satu aspek kunci dari AI adalah Pembelajaran Mesin (Machine Learning), memungkinkan komputer untuk mengenali pola dari data dan membuat keputusan tanpa perlu pemrograman yang mendetail. Dengan semakin rumitnya data, terutama yang tidak terstruktur seperti gambar, metode Pembelajaran Mesin tradisional mulai menunjukkan batasan dalam mengekstrak fitur secara manual.

Deep Learning muncul sebagai lanjutan dari Pembelajaran Mesin dengan menggunakan jaringan saraf tiruan yang memiliki banyak lapisan, yang dikenal sebagai Jaringan Saraf Dalam (DNN). Metode ini memungkinkan model untuk secara otomatis dan bertahap mempelajari representasi fitur, sehingga sangat efisien dalam menangani data dengan dimensi tinggi. Deep Learning telah banyak diterapkan untuk berbagai masalah,

terutama dalam bidang penglihatan komputer, seperti pengklasifikasian gambar, deteksi objek, dan identifikasi pola visual.

Pengklasifikasian gambar angka tulisan tangan adalah salah satu tantangan fundamental dalam penglihatan komputer yang sering dijadikan studi dasar dalam penelitian dan pembelajaran Deep Learning. Masalah ini cukup menantang karena adanya variasi dalam bentuk tulisan tangan yang berbeda-beda meskipun jumlah kelas yang perlu dikategorikan relatif terbatas. Dataset MNIST (Modified National Institute of Standards and Technology) merupakan dataset yang paling banyak digunakan untuk masalah ini, karena memiliki struktur data yang terstandarisasi dan telah menjadi tolok ukur dalam menilai performa model pengklasifikasian gambar.

Berbagai studi menunjukkan bahwa struktur Deep Neural Network memiliki kemampuan yang unggul dalam mengklasifikasikan gambar pada dataset MNIST. Walaupun arsitektur yang lebih rumit seperti Convolutional Neural Network (CNN) biasanya

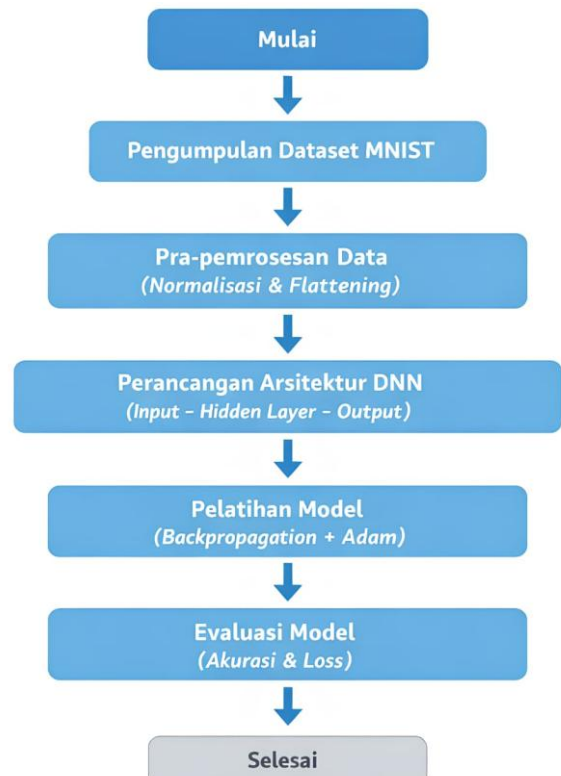
diterapkan untuk meningkatkan tingkat akurasi, DNN yang memiliki lapisan terhubung penuh tetap relevan sebagai model dasar untuk memahami secara lebih mendalam tentang mekanisme serta proses pembelajaran dalam Deep Learning.

Meskipun banyak penelitian telah dilakukan mengenai pengenalan citra angka dari tulisan tangan menggunakan dataset MNIST dengan beragam arsitektur Deep Learning, mayoritas penelitian cenderung fokus pada aplikasi model yang rumit seperti Convolutional Neural Network (CNN) demi mendapatkan akurasi tinggi. Pendekatan ini sering kali melewati pemahaman mendalam tentang kinerja arsitektur Deep Neural Network (DNN) yang lebih sederhana sebagai model fundamental, terutama terkait stabilitas pembelajaran, efisiensi dalam komputasi, dan kemudahan untuk diimplementasikan. Selain itu, penelitian yang memberikan penjelasan sistematis mengenai langkah-langkah desain arsitektur DNN dari pra-pemrosesan data hingga evaluasi kinerja dalam konteks akademik masih sangat terbatas. Akibatnya, penelitian ini berupaya menjembatani kekurangan tersebut dengan menilai kinerja dan efektivitas Deep Neural Network dengan arsitektur sederhana pada dataset MNIST sebagai dasar pemahaman sebelum menerapkan model yang lebih kompleks.

Dengan latar belakang tersebut, tujuan dari penelitian ini adalah merancang dan menerapkan model Deep Neural Network untuk melakukan klasifikasi gambar angka yang ditulis tangan menggunakan dataset MNIST. Penelitian ini juga menganalisis kinerja model berdasarkan metrik akurasi guna menilai seberapa efektif arsitektur yang diaplikasikan. Diharapkan, hasil dari penelitian ini dapat memberikan wawasan mengenai penerapan Deep Learning yang sistematis serta menjadi referensi awal bagi mahasiswa dan peneliti pemula sebelum melanjutkan ke pengembangan model yang lebih rumit.

II. METODOLOGI PENELITIAN

Metodologi penelitian adalah sebuah proses yang teratur yang diadopsi untuk mencapai tujuan penelitian dengan cara yang terstruktur dan bisa dipertanggungjawabkan secara ilmiah. Dalam penelitian ini, metodologi dibuat untuk menerapkan dan menilai model Deep Learning yang bersumber dari Deep Neural Network dalam mengklasifikasikan gambar angka tulisan tangan dengan memanfaatkan dataset MNIST. Setiap langkah dalam metodologi tersebut dirancang agar saling terhubung, mulai dari pengumpulan data hingga penilaian performa model, sehingga hasil yang dicapai dapat memberikan pemahaman yang jelas terkait dengan efektivitas metode yang diterapkan.



Gambar 1. Alur bagan metodologi

A. Tipe dan Metode Penelitian

Dalam penelitian ini, pendekatan yang digunakan adalah kuantitatif dengan metode eksperimen. Pendekatan kuantitatif dipilih karena pengukuran kinerja model dilakukan berdasarkan nilai numerik seperti akurasi dan kehilangan. Metode eksperimen diterapkan melalui tahapan pelatihan dan pengujian model Deep Neural Network dengan dataset MNIST guna mengukur sejauh mana efektifitas dari arsitektur yang telah dirancang.

B. Dataset Penelitian

Dataset yang digunakan dalam penelitian ini adalah MNIST (Institut Nasional Standar dan Teknologi yang Dimodifikasi), yang mencakup 60.000 gambar data pelatihan dan 10.000 gambar data pengujian. Setiap gambar merupakan ilustrasi grayscale berukuran 28×28 piksel yang dikelompokkan ke dalam 10 kategori digit (0–9). Dataset ini dipilih karena merupakan dataset yang umum dan sering digunakan sebagai tolok ukur dalam penelitian klasifikasi gambar serta pengembangan model Deep Learning.

Pemilihan dataset MNIST didasarkan pada beberapa pertimbangan, antara lain ketersediaannya yang bersifat publik, struktur data yang terstandarisasi, serta banyaknya penelitian terdahulu yang menggunakan dataset ini sebagai acuan. Dengan demikian, hasil penelitian ini dapat dibandingkan secara tidak langsung dengan penelitian lain yang relevan.

TABEL I

Parameter	Keterangan
Nama Dataset	MNIST
Jumlah Data Latih	60.000 citra
Jumlah Data Uji	10.000 citra

Ukuran Citra	28 × 28 piksel
Tipe Citra	Grayscale
Jumlah Kelas	10 (digit 0–9)
Format Data	

C. Pra-pemrosesan Data

Tahap awal dalam pengolahan data berfokus pada penyesuaian data agar cocok dengan keperluan model Jaringan Syaraf Dalam dan meningkatkan efisiensi sesi pelatihan. Dalam studi ini, pengolahan awal dilakukan dengan cara menormalkan nilai-nilai piksel dari gambar. Nilai piksel yang awalnya berada dalam kisaran 0 hingga 255 diubah menjadi kisaran 0 hingga 1 dengan membagi setiap nilai piksel dengan 255. Proses normalisasi ini bertujuan untuk menyelaraskan skala data, mengurangi variasi nilai di antara fitur-fitur, serta mempercepat proses konvergensi saat pelatihan model.

Selain normalisasi, data citra juga disesuaikan dengan format input yang dibutuhkan oleh model. Citra dua dimensi berukuran 28 × 28 piksel diubah menjadi vektor satu dimensi melalui proses flattening. Proses ini diperlukan karena arsitektur Deep Neural Network yang digunakan berbasis fully connected layer, yang mengharuskan input berupa vektor satu dimensi. Meskipun flattening menghilangkan informasi spasial citra, pendekatan ini masih relevan untuk dataset MNIST yang memiliki kompleksitas visual relatif rendah.

D. Perancangan Arsitektur Deep Neural Network

Dalam penelitian ini, struktur Deep Neural Network terdiri dari satu lapisan input, dua lapisan tersembunyi, dan satu lapisan output. Lapisan input menerima data dari proses penghilangan dimensi citra MNIST dengan 784 neuron, yang menunjukkan jumlah total piksel dalam setiap gambar.

Lapisan tersembunyi pertama memiliki 128 neuron, sedangkan lapisan tersembunyi kedua memiliki 64 neuron. Keduanya menerapkan fungsi aktivasi Rectified Linear Unit (ReLU) untuk menambahkan elemen non-linear dalam model serta mempercepat proses konvergensi saat pelatihan berlangsung.

Lapisan output terdiri dari 10 neuron yang mencerminkan kelas digit dari 0 hingga 9 dan menggunakan fungsi aktivasi Softmax untuk menghasilkan probabilitas prediksi di setiap kelas. Struktur ini dipilih karena memberikan keseimbangan antara kompleksitas model dan efisiensi komputasi, serta cocok dengan karakteristik dataset MNIST.

TABEL II

Lapisan	Jumlah Neuron	Fungsi Aktivasi
Input	784	–
Hidden Layer 1	128	ReLU
Hidden Layer 2	64	ReLU
Output	10	Softmax

E. Proses Pelatihan Model

Pelatihan model dilakukan dengan algoritma backpropagation untuk secara bertahap memperbaharui bobot jaringan. Fungsi loss yang digunakan adalah Categorical Cross-Entropy, yang cocok untuk masalah klasifikasi dengan banyak kelas.

Optimizer yang dipilih adalah Adam (Adaptive Moment Estimation) dengan learning rate default. Model dilatih selama 10 epoch dengan ukuran batch 32. Selama proses pelatihan, performa model dipantau menggunakan metrik akurasi untuk menilai tingkat ketepatan prediksi model di setiap iterasi.

Selama proses pelatihan, model dilatih menggunakan data latih dan dievaluasi secara berkala untuk memantau perkembangan nilai loss dan accuracy. Monitoring ini penting untuk memastikan bahwa model belajar secara optimal dan tidak mengalami masalah seperti underfitting atau overfitting.

TABEL III

Parameter	Nilai
Optimizer	Adam
Learning Rate	Default Adam
Loss Function	Categorical Cross-Entropy
Epoch	10–20
Batch Size	32
Metrics	Accuracy

F. Evaluasi Kinerja Model

Penilaian kinerja dilaksanakan dengan memanfaatkan data uji MNIST yang tidak diikutsertakan dalam tahap pelatihan. Metode utama yang diterapkan adalah akurasi, yang dihitung dengan membandingkan jumlah prediksi yang tepat dengan total data uji.

Dari hasil penilaian, model Deep Neural Network yang telah dibuat menunjukkan akurasi sebesar 97,66% pada data uji MNIST. Selain itu, analisis grafik kerugian dan akurasi selama proses pelatihan memperlihatkan pembelajaran yang konsisten dengan perbedaan yang kecil antara kinerja data pelatihan dan data pengujian, yang menandakan bahwa model ini memiliki kemampuan generalisasi yang baik.

G. Alur Metodologi Penelitian

Alur metodologi penelitian ini dibentuk secara terencana untuk memastikan setiap fase penelitian dilaksanakan dengan cara yang terstruktur dan dapat dipertanggungjawabkan secara akademis. Penelitian dimulai dengan pengumpulan dataset MNIST yang berisi data untuk pelatihan dan pengujian. Setelah itu, dataset tersebut menjalani tahap pra-pemrosesan dengan melakukan normalisasi nilai piksel dan mengubah format data citra menjadi vektor satu dimensi agar sesuai dengan kebutuhan model Deep Neural Network.

Langkah berikutnya adalah merancang struktur model Deep Neural Network, yang melibatkan lapisan input, beberapa lapisan tersembunyi dengan fungsi aktivasi ReLU, serta lapisan keluaran yang menggunakan fungsi Softmax. Model yang sudah dirancang kemudian dilatih memakai algoritma backpropagation dengan

optimizer Adam untuk memperbarui bobot jaringan secara bertahap.

Setelah proses pelatihan berakhir, model dievaluasi menggunakan data pengujian untuk menilai akurasi dan stabilitas proses pembelajaran. Hasil dari evaluasi ini selanjutnya dianalisis untuk menilai efektivitas model dalam mengklasifikasikan citra angka tulisan tangan. Semua tahap ini ditampilkan dalam format bagan metodologi penelitian untuk mempermudah pemahaman jalannya penelitian secara keseluruhan.

III. DESAIN, HASIL DAN PEMBAHASAN

Bagian ini membahas perancangan sistem, hasil eksperimen yang diperoleh dari proses pelatihan model Deep Neural Network, serta pembahasan terhadap hasil tersebut secara komprehensif. Pembahasan difokuskan pada bagaimana desain arsitektur model memengaruhi kinerja klasifikasi, serta sejauh mana model mampu mempelajari pola-pola pada dataset MNIST secara efektif.

A. Desain Sistem

Desain sistem dalam penelitian ini dirancang untuk mengimplementasikan metode Deep Learning berbasis Deep Neural Network dalam melakukan klasifikasi citra angka tulisan tangan. Sistem yang dibangun terdiri dari beberapa komponen utama, yaitu modul input data, modul pra-pemrosesan, modul pelatihan model, dan modul evaluasi hasil. Setiap komponen saling terintegrasi untuk memastikan alur pemrosesan data berjalan secara sistematis dan efisien.

Pada tahap input, sistem menerima data citra angka tulisan tangan dari dataset MNIST. Setiap citra memiliki ukuran 28×28 piksel dalam format grayscale. Data citra ini kemudian diteruskan ke tahap pra-pemrosesan, di mana dilakukan normalisasi nilai piksel serta penyesuaian format data agar sesuai dengan kebutuhan model. Normalisasi dilakukan untuk meningkatkan stabilitas numerik selama proses pelatihan, sedangkan penyesuaian format data bertujuan agar citra dapat diterima oleh arsitektur Deep Neural Network berbasis fully connected layer.

Model Deep Neural Network pada penelitian ini dirancang menggunakan arsitektur berlapis yang sederhana tetapi tetap optimal dalam kinerja. Setelah data citra melalui tahap perataan dimensi, informasi tersebut diteruskan ke lapisan input dan selanjutnya diproses oleh beberapa lapisan tersembunyi. Setiap lapisan tersembunyi menggunakan fungsi aktivasi Rectified Linear Unit (ReLU) untuk memberikan sifat non-linear, sehingga model mampu menangkap hubungan dan pola yang lebih kompleks pada data. Sementara itu, pada lapisan akhir diterapkan fungsi aktivasi Softmax yang menghasilkan distribusi probabilitas untuk setiap kelas, sehingga model dapat menentukan prediksi digit berdasarkan tingkat keyakinan tertentu.

Desain sistem ini dipilih dengan mempertimbangkan tujuan penelitian, yaitu memberikan gambaran implementasi Deep Learning yang mudah dipahami namun tetap memiliki performa yang baik. Dengan


arsitektur yang tidak terlalu kompleks, proses pelatihan dan evaluasi model dapat dianalisis secara lebih jelas, sehingga sesuai dengan konteks pembelajaran dan penelitian akademik.

B. Hasil Pelatihan Model

Prosedur pelatihan model Deep Neural Network dilaksanakan dengan memanfaatkan dataset MNIST yang telah disiapkan melalui tahap pra-pemrosesan. Dalam tahap pelatihan ini, model mengalami proses pelatihan selama sejumlah epoch dengan ukuran batch yang telah ditentukan untuk secara bertahap memperbarui berat dari jaringan. Evaluasi hasil pelatihan dilakukan dengan mengacu pada nilai loss dan akurasi yang diraih di setiap epoch, baik untuk data pelatihan maupun data pengujian.

Berdasarkan hasil eksperimen, model menunjukkan peningkatan akurasi yang signifikan seiring bertambahnya jumlah epoch. Pada tahap awal pelatihan, nilai akurasi masih relatif rendah karena model belum sepenuhnya mempelajari pola-pola dasar pada data. Namun, seiring dengan berlangsungnya proses backpropagation dan pembaruan bobot jaringan, model mulai mampu mengenali karakteristik visual dari setiap digit secara lebih akurat. Hal ini ditunjukkan oleh peningkatan nilai accuracy dan penurunan nilai loss secara bertahap.

Hasil penilaian terhadap data pengujian mengindikasikan bahwa model Jaringan Neural Dalam yang dikembangkan berhasil mencapai akurasi yang sangat baik, yang mengisyaratkan bahwa model ini tidak hanya berfungsi optimal pada data yang digunakan untuk pelatihan, tetapi juga mampu menggeneralisasi data yang tidak pernah ditemui sebelumnya. Keberhasilan ini menunjukkan bahwa desain model dan parameter pelatihan yang diterapkan telah disesuaikan dengan karakteristik dataset MNIST secara akurat.



Gambar 2. Visualisasi Data

C. Analisis Grafik Loss dan Accuracy

Analisis grafik loss dan akurasi dilakukan untuk mengeksplorasi perilaku pembelajaran dalam model Deep Neural Network selama fase pelatihan dan pengujian. Grafik loss memperlihatkan perubahan nilai kesalahan model ketika dihadapkan pada data, sementara grafik akurasi mencerminkan tingkat ketepatan prediksi model di setiap epoch. Kedua grafik ini menjadi indikator utama dalam mengevaluasi efektivitas struktur jaringan, ketahanan proses pelatihan, serta sejauh mana model dapat menggeneralisasi data baru yang belum pernah ditemui sebelumnya.

Dari grafik loss yang diperoleh, tampak bahwa nilai loss pada data pelatihan menunjukkan penurunan yang signifikan sejalan dengan bertambahnya jumlah epoch. Pada awal epoch, nilai loss masih cukup tinggi karena model belum bisa mengidentifikasi pola-pola dasar dari citra tulisan tangan. Namun, setelah melewati beberapa epoch awal, terpantau ada penurunan konsisten pada nilai loss, yang menunjukkan bahwa proses backpropagation berjalan efektif dan bobot jaringan terus diperbaiki menuju nilai yang optimal. Penurunan loss yang stabil ini menandakan bahwa model berhasil mengurangi kesalahan prediksi selama proses pembelajaran.

Di sisi lain, grafik validation loss menunjukkan pola yang cukup stabil meskipun ada fluktuasi kecil di beberapa epoch. Nilai validation loss cenderung menurun pada awal pelatihan dan kemudian tetap berada dalam rentang yang cukup konstan hingga proses pelatihan selesai. Meskipun ada sedikit peningkatan pada beberapa epoch terakhir, perbedaannya tidak terlalu mencolok bila dibandingkan dengan training loss. Pola ini mengindikasikan bahwa model tidak mengalami overfitting yang mencolok, sebab nilai kesalahan pada data uji tidak mengalami peningkatan yang signifikan seiring bertambahnya epoch.


Pada diagram akurasi, dapat dilihat bahwa angka akurasi pelatihan meningkat secara terus-menerus selama tahap pelatihan. Di awal epoch, tingkat akurasi masih cukup rendah, namun menunjukkan peningkatan yang signifikan setelah beberapa epoch awal. Ini menunjukkan bahwa model mulai dapat mendeteksi fitur-fitur penting dalam citra angka tulisan tangan, seperti bentuk dan pola dasar dari setiap angka. Seiring dengan bertambahnya epoch, kenaikan akurasi berlangsung lebih perlahan dan cenderung stabil, yang menandakan bahwa model hampir mencapai kondisi konvergen.

Grafik akurasi validasi juga menunjukkan peningkatan yang sejalan dengan akurasi pelatihan, meskipun nilainya sedikit lebih rendah. Selisih antara akurasi pelatihan dan akurasi validasi cukup kecil, yang mengindikasikan model memiliki kemampuan generalisasi yang baik. Tidak adanya perbedaan yang signifikan antara kedua kurva tersebut menunjukkan bahwa model tidak hanya menghafal data pelatihan, tetapi juga dapat menghasilkan prediksi yang akurat pada data uji yang belum pernah dilalui dalam proses pelatihan.

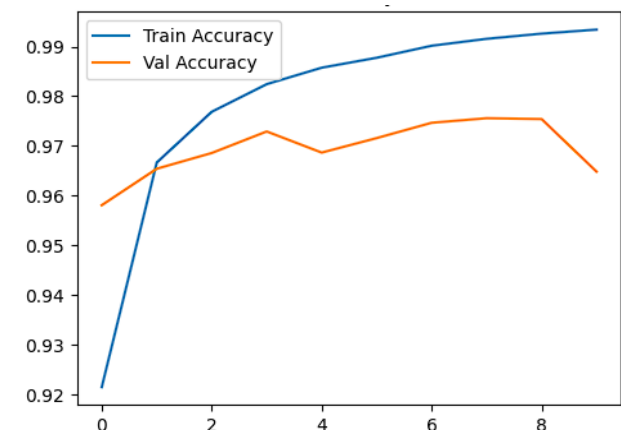
Kestabilan di grafik kehilangan dan akurasi ini mengindikasikan bahwa kombinasi dari arsitektur Jaringan Neural Dalam, fungsi aktivasi Rectified Linear

Unit (ReLU), dan penggunaan optimizer Adam memberikan dampak positif terhadap proses pembelajaran model. Fungsi aktivasi ReLU membantu memastikan aliran gradien tetap stabil selama proses pengembalian gradien, yang mempercepat proses konvergensi. Di sisi lainnya, optimizer Adam memungkinkan penyesuaian tingkat pembelajaran yang adaptif untuk setiap parameter, sehingga meningkatkan efisiensi dan kestabilan pelatihan.

Secara umum, pengamatan terhadap grafik loss dan akurasi menunjukkan bahwa model Deep Neural Network yang dirancang dapat melakukan pembelajaran dengan cara yang efisien dan konsisten. Penurunan nilai loss yang terus menerus serta peningkatan akurasi pada data pelatihan dan pengujian menjadi tanda bahwa struktur dan pengaturan pelatihan yang diterapkan sudah cocok dengan sifat dataset MNIST. Temuan ini menegaskan hasil evaluasi kuantitatif yang menunjukkan bahwa model dapat meraih tingkat akurasi yang tinggi pada data uji, sambil tetap menjaga kemampuan generalisasi yang memuaskan.



Gambar 3. Grafik Loss



Gambar 4. Grafik Accuracy

D. Pembahasan Hasil Penelitian

Pembahasan hasil penelitian difokuskan pada evaluasi kinerja model serta faktor-faktor yang memengaruhi keberhasilan klasifikasi citra angka tulisan

tangan. Salah satu faktor utama yang berkontribusi terhadap performa model adalah pemilihan arsitektur Deep Neural Network yang sesuai dengan tingkat kompleksitas dataset. Meskipun arsitektur yang digunakan relatif sederhana dibandingkan dengan model Deep Learning modern, model tetap mampu mencapai akurasi yang tinggi karena karakteristik dataset MNIST yang memiliki struktur visual yang tidak terlalu kompleks.

Saat membandingkan dengan penelitian sebelumnya yang biasanya menggunakan arsitektur CNN untuk mencapai akurasi di atas 98% pada dataset MNIST, temuan dari penelitian ini menunjukkan bahwa Deep Neural Network dengan struktur yang kurang rumit masih dapat memberikan kinerja yang kompetitif dengan akurasi sebesar 97,66%.

Selain arsitektur model, proses pra-pemrosesan data juga memainkan peran penting dalam meningkatkan kinerja model. Normalisasi nilai piksel membantu mempercepat proses konvergensi dan meningkatkan stabilitas pelatihan. Tanpa normalisasi, model cenderung membutuhkan waktu pelatihan yang lebih lama dan berpotensi mengalami kesulitan dalam menemukan bobot jaringan yang optimal.

Penggunaan optimizer Adam terbukti efektif dalam meningkatkan efisiensi pelatihan model. Dengan kemampuan adaptifnya, Adam mampu menyesuaikan laju pembelajaran untuk setiap parameter secara otomatis, sehingga proses pelatihan menjadi lebih stabil dan cepat. Hal ini sangat penting dalam pelatihan Deep Neural Network, terutama ketika jumlah parameter model cukup besar.

Jika dibandingkan dengan pendekatan Machine Learning tradisional yang memerlukan rekayasa fitur manual, Deep Neural Network menawarkan keunggulan dalam hal otomatisasi ekstraksi fitur. Model mampu mempelajari representasi fitur secara langsung dari data citra mentah tanpa intervensi manual. Keunggulan ini menjadikan Deep Learning sebagai pendekatan yang lebih fleksibel dan skalabel untuk berbagai permasalahan klasifikasi citra.


Secara umum, temuan penelitian ini mengindikasikan bahwa Deep Neural Network (DNN) mampu memberikan kinerja yang baik dan efisien dalam melakukan klasifikasi citra angka tulisan tangan. Walaupun terdapat model yang lebih kompleks seperti Convolutional Neural Network (CNN), penerapan Deep Neural Network masih memiliki relevansi yang tinggi, khususnya sebagai model dasar untuk memahami konsep dan mekanisme utama dalam Deep Learning. Selain itu, hasil penelitian ini memberikan peluang untuk pengembangan selanjutnya, baik melalui penambahan kedalaman dan kompleksitas jaringan maupun dengan penerapan teknik regularisasi guna meningkatkan akurasi dan kestabilan model.

E. Evaluasi Kuantitatif Hasil Klasifikasi

Evaluasi kuantitatif dilakukan untuk menilai kinerja model Deep Neural Network dengan cara yang objektif, berdasarkan hasil yang diperoleh dari pengujian pada dataset MNIST. Metrik utama yang digunakan adalah akurasi, yang merupakan perbandingan antara jumlah

prediksi yang akurat dengan keseluruhan data uji. Dari hasil pengujian, model menunjukkan tingkat akurasi yang tinggi, yang berarti sebagian besar gambar angka tulisan tangan berhasil dikategorikan dengan tepat.

Nilai kerugian pada data uji juga menunjukkan pola yang stabil dan relatif rendah, yang menunjukkan bahwa kesalahan dalam prediksi model dapat dikelola dengan baik. Selisih akurasi antara data pelatihan dan data pengujian tidak terlalu signifikan, sehingga dapat disimpulkan bahwa model tidak mengalami overfitting secara mencolok. Ini menunjukkan bahwa struktur dan parameter pelatihan yang diterapkan sudah sesuai dengan karakteristik dari dataset MNIST.



Gambar 5. Grafik Perubahan Nilai Accuracy dan Loss Selama Proses Pelatihan Model Deep Neural Network

F. Interpretasi Hasil Penelitian

Hasil penelitian menunjukkan bahwa Jaringan Syaraf Dalam memiliki kemampuan yang cukup baik dalam mengenali pola visual dasar pada gambar angka tulisan tangan. Kemampuan ini dicapai melalui metode pembelajaran bertingkat yang memfasilitasi model dalam mengidentifikasi fitur penting dari data gambar secara otomatis. Walaupun model yang diterapkan tidak menggunakan lapisan konvolusi, hasil klasifikasi yang diperoleh tetap bersaing untuk dataset MNIST.

Penafsiran dari hasil ini menegaskan bahwa kerumitan struktur tidak selalu menjadi elemen kunci untuk mencapai performa optimal, terutama pada dataset yang memiliki tingkat kompleksitas visual relatif rendah. Oleh sebab itu, Jaringan Syaraf Dalam yang sederhana tetap sangat relevan sebagai model awal dalam pengembangan sistem klasifikasi gambar yang berbasis Deep Learning.

IV. KESIMPULAN

Berdasarkan temuan dari penelitian yang telah dilakukan, dapat disimpulkan bahwa penggunaan metode Deep Learning dengan arsitektur Deep Neural Network (DNN) menunjukkan performa yang sangat baik dalam mengklasifikasikan citra angka tulisan tangan pada dataset MNIST. Model yang dikembangkan dan

diaplikasikan dalam penelitian ini berhasil mengenali pola visual dasar dari citra angka dengan baik melalui proses pembelajaran bertahap, sehingga dapat memberikan prediksi kelas dengan akurasi yang tinggi pada data uji.

Evaluasi yang dilakukan menunjukkan bahwa model ini tidak hanya berfungsi secara optimal pada data pelatihan, tetapi juga memiliki kemampuan untuk menggeneralisasi dengan baik pada data uji yang belum pernah dilihat sebelumnya. Ini terlihat melalui perbedaan kecil dalam nilai akurasi antara data pelatihan dan data pengujian, serta tren penurunan nilai loss yang konsisten sepanjang proses pelatihan. Dengan demikian, model yang dikembangkan tidak menunjukkan tanda-tanda overfitting yang signifikan dan bisa dikatakan memiliki kestabilan dalam proses pembelajarannya.

Keberhasilan dari model Deep Neural Network dalam penelitian ini dipengaruhi oleh beberapa elemen utama, di antaranya adalah tahapan pra-pemrosesan data yang tepat, desain arsitektur jaringan yang sesuai dengan karakteristik dataset MNIST, serta pemilihan optimizer Adam yang dapat meningkatkan efisiensi dan stabilitas dalam proses pelatihan. Normalisasi data berperan penting dalam mempercepat konvergensi model, sedangkan penerapan fungsi aktivasi Rectified Linear Unit (ReLU) membantu jaringan dalam memahami hubungan non-linear dalam data citra. Fungsi aktivasi Softmax di lapisan keluaran memungkinkan model untuk menghasilkan prediksi klasifikasi multi-kelas dengan probabilitas yang akurat.

Hasil studi ini menunjukkan bahwa struktur Deep Neural Network yang cukup sederhana masih sangat relevan dan efisien sebagai model dasar dalam pembuatan sistem klasifikasi gambar, terutama untuk dataset dengan tingkat kompleksitas rendah hingga menengah seperti MNIST. Penelitian ini juga memberikan wawasan mendalam tentang langkah-langkah pelaksanaan Deep Learning, yang mencakup pemrosesan data, desain model, pelatihan, dan penilaian kinerja.

Sebagai langkah lanjutan, riset ini bisa diperluas dengan menggunakan struktur yang lebih rumit seperti Convolutional Neural Network (CNN), menambah teknik regularisasi, atau melakukan pengoptimalan parameter untuk meningkatkan akurasi dan kinerja model. Dengan kata lain, penelitian ini diharapkan dapat menjadi acuan awal yang berguna bagi mahasiswa dan peneliti pemula dalam memahami dan mengembangkan aplikasi Deep Learning di bidang penglihatan komputer.

V. REFERENSI

- [1] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [2] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [3] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [4] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," in *Proceedings of the International Conference on Learning Representations (ICLR)*, 2015.
- [5] F. Chollet, *Deep Learning with Python*. Shelter Island, NY, USA: Manning Publications, 2017.
- [6] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.
- [7] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ, USA: Pearson Education, 2009.
- [8] M. Nielsen, *Neural Networks and Deep Learning*. San Francisco, CA, USA: Determination Press, 2015.
- [9] S. Raschka and V. Mirjalili, *Python Machine Learning*, 3rd ed. Birmingham, UK: Packt Publishing, 2019.
- [10] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*, 2nd ed. New York, NY, USA: Springer, 2009.
- [11] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 4th ed. New York, NY, USA: Pearson Education, 2018.
- [12] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Advances in Neural Information Processing Systems (NeurIPS)*, pp. 1097–1105, 2012.
- [13] TensorFlow Developers, "MNIST dataset," TensorFlow Documentation. [Online]. Available: <https://www.tensorflow.org/datasets/catalog/mnist>
- [14] J. Brownlee, *Deep Learning for Computer Vision*. Machine Learning Mastery, 2019.
- [15] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," in *Proceedings of the International Conference on Learning Representations (ICLR)*, 2015.