

LETTER OF ACCEPTANCE

Paper Number #825

Dear, Elva Andrian, Susilawati

This is to inform you that the manuscript entitled: "**Pengenalan Tulisan Tangan Angka Pada Dataset MNIST Menggunakan Arsitektur SqueezeNet**", which was sent on **April 16th 2025**, is **ACCEPTED**.

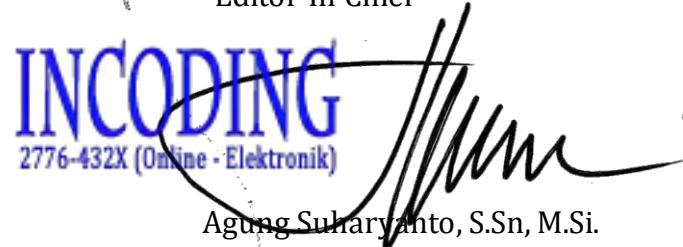
We keep to ensuring a high standard of articles published in the **INCODING: Journal of Informatics and Computer Science Engineering**, and the manuscript that is being sent to you has been submitted after a first selection process based on the agreement of the **Associate Editors**. In general, the standard of manuscripts forwarded to me after the vetting is **good**.

This paper is well organized and follows the manuscript guidelines of the journal to a large extent. The introduction section is good and shows the importance of the study. The literature review is adequate. The outcomes of the study are consistent with the findings. The approach used is praiseworthy. In my opinion, it should be published without **revision again**

Based on the review results, this manuscript is **ACCEPTED**, and **PUBLISHED** in **Mei 2025** for **Volume 3, No. 2, 2025**.

Thank you very much for your contribution. Congratulations on a wonderful job.

Warmest Regards,
Editor In Chief


INCODING
2776-432X (Online - Elektronik)
Agung Sularyanto, S.Sn, M.Si.

Editorial Office:

MaheSa Research Center

Perumahan Griya Nafisa 2, Blok A No 10, Jalan Benteng Hilir

Titi Sewa, RT 06, Dusun XVI Flamboyan,

Kecamatan Percut Sei Tuan, Deli Serdang, 20371

Sumatera Utara, Indonesia

Phone: 08126493527

Email: incoding.journal@gmail.com

INCODING: Journal of Informatics and Computer Science Engineering



UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 26/5/25

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber

2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah

3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Access From (repository.uma.ac.id)26/5/25

Pengenalan Tulisan Tangan Angka Pada Dataset MNIST

Menggunakan Arsitektur *SqueezeNet*

Handwritten Digit Recognition on MNIST Dataset Using SqueezeNet Architecture

Elva Andrian & Susilawati*

Teknik Informatika, Fakultas Teknik, Universitas Medan Area

*Corresponding author, e-mail:susilawati@staff.uma.ac.id

Abstrak

Pengenalan tulisan tangan angka merupakan suatu proses mengenali dan mengidentifikasi angka menggunakan algoritma kecerdasan buatan seperti *Convolutional Neural Network* (CNN). Penerapan pengenalan tulisan tangan angka bisa dikembangkan dan digunakan dalam identifikasi nomor kode pos pada surat, identifikasi nominal pada cek bank dan lainnya. Namun sebelum melakukan penerapan tersebut dibutuhkan pelatihan model pada algoritma yang akan digunakan supaya pengenalan angka menjadi tepat karena permasalahan yang dihadapi dalam mengenali tulisan tangan angka ialah gambar atau data tulisan yang beragam dan sulit diidentifikasi. Pada penelitian ini digunakan algoritma CNN dengan arsitektur *SqueezeNet* dengan dataset MNIST (*Modified National Institute of Standards and Technology*) yang terbagi atas 60000 data latih dan 10000 data uji. Platform yang digunakan untuk melakukan proses pelatihan dan pengujian yaitu *Google Colab*. Pelatihan dilakukan sebanyak 12 kali menggunakan *hyperparameter* seperti *Optimizer* yaitu *Adam*, *SGD*, dan *RMSprop*, *Learning rate* yaitu 0.1, 0.01, 0.001, 0.0001 dan *Batch Size* 64. Berdasarkan hasil penelitian dari 12 model yang dilatih diperoleh 1 model dengan hasil terbaik pada *Optimizer* yaitu *Adam*, *Learning rate* yaitu 0.0001 dan *Batch Size* 64 menghasilkan akurasi sebesar 99.11%.

Kata Kunci: CNN, MNIST, Squeeze Net, Pengenalan tulisan tangan angka

Abstract

Handwritten digit recognition is a process of recognizing and identifying numbers using artificial intelligence algorithms such as Convolutional Neural Network (CNN). The application of handwritten number recognition can be developed and used in identifying postal code numbers on letters, identifying nominal amounts on bank checks and others. However, before carrying out the application, model training is needed on the algorithm that will be used so that number recognition is accurate because the problem faced in recognizing handwritten numbers is that images or written data are diverse and difficult to identify. In this study, the CNN algorithm was used with the SqueezeNet architecture with the MNIST (Modified National Institute of Standards and Technology) dataset which is divided into 60,000 training data and 10,000 test data. The platform used to carry out the training and testing process is Google Colab. Training was carried out 12 times using hyperparameters such as Optimizer namely Adam, SGD, and RMSprop, Learning rate namely 0.1, 0.01, 0.001, 0.0001 and Batch Size 64. Based on the research results from 12 trained models, 1 model was obtained with the best results on the Optimizer namely Adam, Learning rate namely 0.0001 and Batch Size 64 resulting in an accuracy of 99.11%.

Keywords: CNN, MNIST, Squeeze Net, Handwritten digit recognition

PENDAHULUAN

Image classification atau klasifikasi gambar adalah hal yang mendasar dalam *computer vision* yang penerapannya dalam dunia nyata meliputi diagnosis medis, agrikultur, *e-commerce*, kontrol kualitas dan termasuk juga pada pengenalan tulisan angka yang menjadi fokus pada penelitian ini. *Image classification* melibatkan pemberian label pada gambar, kemudian melakukan proses pelatihan model

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 26/5/25

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Access From (repository.uma.ac.id)26/5/25

pembelajaran untuk mengklasifikasikan atau mendeteksi objek yang beragam atau pola yang ada pada gambar tersebut [1]

Pengenalan tulisan tangan angka termasuk ke dalam *image classification* yang mana melibatkan proses pemberian label dan melakukan klasifikasi pada data yang akan digunakan. Pengenalan tulisan tangan angka merupakan kemampuan komputer untuk mengidentifikasi dan mengenali tulisan tangan angka manusia yang diambil dari berbagai media seperti gambar, kertas, layer sentuh dan yang lainnya yang kemudian diklasifikasikan menjadi 10 kelas terdiri dari 0-9 [2]. CNN merupakan satu dari sekian banyak algoritma yang bisa digunakan dalam proses pelatihan pengenalan tulisan angka. CNN adalah salah satu algoritma turunan dari *Deep Learning* yang mengambil data masukkan dalam bentuk gambar dan menentukan aspek yang akan dipelajari untuk memprediksi, mengidentifikasi atau membedakan gambar berdasarkan label yang telah ditentukan sebelumnya [3]. CNN memiliki beberapa model arsitektur seperti *LeNet*, *Alexnet*, *ResNet*, *GoogleNet* dan *SqueezeNet* yang mana arsitektur-arsitektur ini akan terus berkembang dan menyesuaikan terhadap kemajuan teknologi yang ada [4]. *SqueezeNet* merupakan salah satu model arsitektur CNN yang dirancang untuk mencapai akurasi setara dengan *AlexNet* namun dengan jumlah parameter yang jauh lebih sedikit dibanding arsitektur CNN lainnya, akan tetapi tetap memiliki performa yang optimal untuk melakukan klasifikasi gambar [5]. *SqueezeNet* pertama kali diperkenalkan pada tahun 2016 oleh tim peneliti yang terdiri dari Forrest N. Iandola, Song Han, Matthew W. Moskewicz, Khalid Ashraf, William J. Dally, dan Kurt Keutzer. Dengan jumlah parameter yang jauh lebih sedikit, *SqueezeNet* memiliki beberapa keuntungan seperti efisiensi komputasi, penghematan *bandwidth*, dan bisa diimplementasikan pada perangkat dengan memori yang terbatas [6].

Permasalahan dan tantangan yang dihadapi pada klasifikasi gambar pengenalan tulisan angka ialah berupa gaya tulisan yang beragam, variasi spasi dan tulisan tangan yang inkonsisten [7]. Penelitian pengenalan tulisan tangan angka menggunakan dataset MNIST telah banyak dilakukan dan menghasilkan akurasi yang beragam. Penelitian yang dilakukan oleh Yevhen Chychkarov dengan menggunakan algoritma *Support Vector Machine* (SVM), *K-Nearest Neighbour* (KNN), *Random Forest* (RF) dan CNN yang mana dari ke empat algoritma ini menghasilkan akurasi terbaik pada CNN yaitu sebesar 97.6% [8]. Penelitian yang dilakukan oleh Ali Abdullah Yahya menggunakan CNN dengan *batch normalization* dan *optimizer* yaitu RMSprop menghasilkan akurasi sebesar 99.98% dan

99.40% dengan penambahan *noise* 50% pada dataset MNIST [9]. Penelitian dilakukan oleh Firta Panjaitan menggunakan SVM dan *feature extraction* yaitu *Histogram of Oriented Gradients* (HOG) dan *Principal Component Analysis* (PCA) mampu mencapai akurasi sebesar 98-99% [10]. Penelitian terkait lainnya juga dilakukan oleh Ruomin Zhu menggunakan *Neuromorphic Nanowire Network* dengan basis kernel CNN dan penambahan *theoretic metrics* berupa *Mutual Information (MI)*, *Transfe Entropy (TE)*, dan *Active Information Storage (AIS)* untuk menganalisis dinamik pembelajaran pada MNIST dan hasil akurasi yang didapat mencapai 98% [11].

Penelitian ini bertujuan untuk mengevaluasi performa arsitektur CNN *SqueezeNet* pada pengenalan tulisan tangan angka dengan mengukur nilai akurasi dan stabilitas model selama proses pelatihan. Nantinya akan digunakan tiga *optimizer* yang berbeda dan juga empat nilai *learning rate* yang berbeda. Hasil penelitian ini dapat memberikan wawasan mengenai efektivitas arsitektur CNN *SqueezeNet* dengan mengkomparasikannya dengan penelitian terkait.

METODE PENELITIAN

A. Dataset

Pada penelitian ini, akan digunakan dataset MNIST. Dataset MNIST dibangun oleh *Institute National Standard Technology* (NIST) yang datanya berupa gambar tulisan tangan angka 0 sampai 9 dan dibagi dalam 60000 data latih dan 10000 data uji [12]. Dataset MNIST merupakan data bertipe *grayscale* (hitam-putih) berukuran 28*28 piksel yang tiap pikselnya memiliki rentang nilai 0 sampai 255 dimana nilai 0 berarti hitam, 255 berarti putih dan keabu-abuan diantara nilai 0 dan 255 tersebut [13].

Tabel 1 Distribusi Dataset MNIST

Angka	0	1	2	3	4	5	6	7	8	9	Total
Data Latih	5926	6742	5942	6155	5849	5421	5913	6265	5851	5936	60000
Data Uji	980	1135	1032	1010	982	892	958	1028	974	1009	10000



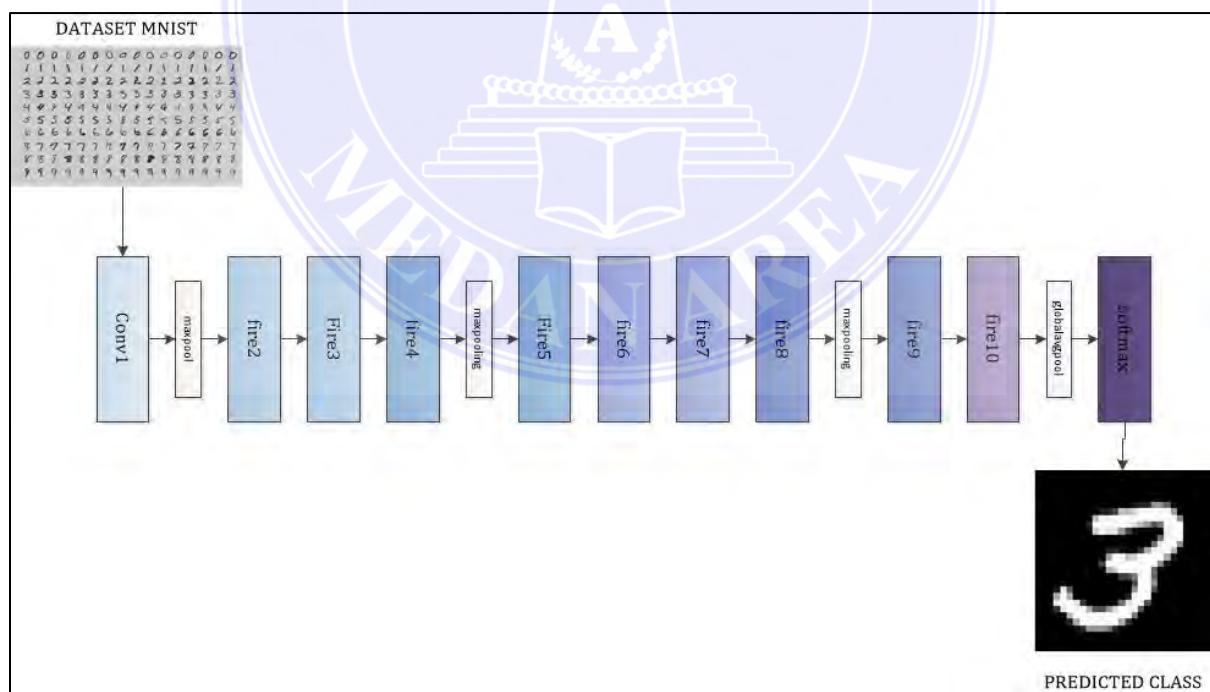
Gambar 1 Sampel Dataset MNIST

B. Normalisasi Data

Normalisasi data adalah sebuah proses mengubah nilai piksel gambar ke dalam skala tertentu dan bertujuan mempercepat proses pelatihan model, menghindari masalah numerik dan meningkatkan stabilitas model [14]. Pada dataset MNIST dilakukan normalisasi data dengan mengubah piksel gambar skala 0 sampai 255 menjadi 1 dan 0 dengan membagi 255 pada tiap piksel. Skala nilai pada piksel yang baru dapat membantu performa pelatihan model karena dapat mengurangi *noise* yang tinggi dan relevansi yang rendah [15].

C. SqueezeNet

SqueezeNet memanfaatkan strategi pemisahan konvolusional yang mana mengubah standar konvolusional menjadi *fire modules*. Di dalam *fire modules* terdiri dari *expand layer* dan *squeeze layer* yang setiap modulnya terdapat fungsi aktivasi ReLU yang bertujuan menambahkan non-linearitas dan membantu model belajar fitur yang kompleks [16]. Pada *squeeze layer* tersusun atas 1x1 konvolusional yang berfungsi mengurangi bobot parameter dan pada *expand layer* tersusun atas gabungan 3x3 dan 1x1 konvolusional yang berfungsi untuk memastikan presisi model arsitektur *squeezeNet* [17].



Gambar 2 Layer pada *SqueezeNet*

Pada gambar 2 di atas dapat dijelaskan secara berututan:

- 1) *Input* yang merupakan dataset MNIST berukuran 28x28 piksel yang telah dilakukan normalisasi
- 2) *Conv1* yaitu lapisan konvolusi awal untuk mengekstraksi fitur dasar dari input dataset MNIST
- 3) *Fire modules (fire2-fire10)* yaitu lapisan yang berfungsi mengekstraksi fitur secara bertahap
- 4) *Global Average Pooling* yaitu lapisan yang berfungsi mengurangi *overfitting* dan memperkecil ukuran fitur menjadi 1 dimensi
- 5) *Softmax* yaitu lapisan yang bertujuan menghasilkan probabilitas untuk masing-masing label (0-9)
- 6) *Output* yaitu berupa prediksi label terdiri dari 0-9

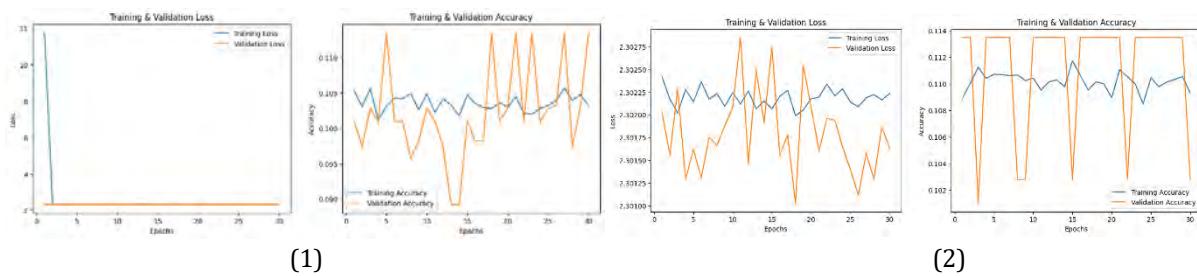
D. Fine-Tuning Hyperparameter

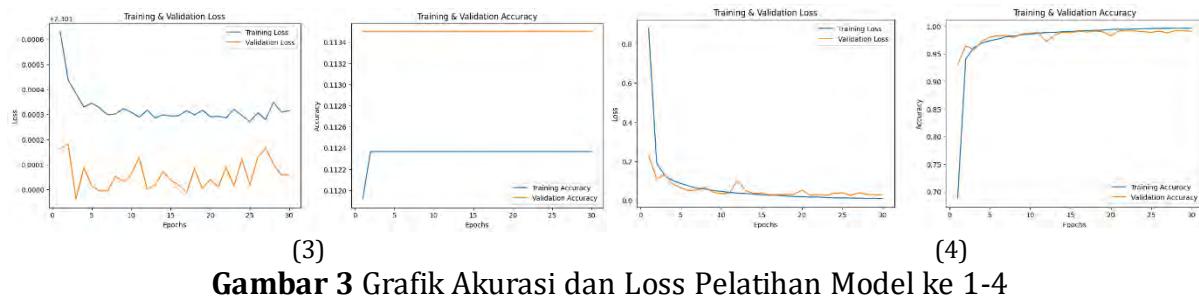
Fine-tuning hyperparameter ialah proses penyesuaian parameter yang nilainya diberikan oleh *user* sebelum melakukan pelatihan pada model dengan tujuan mengontrol cara model belajar dan mempengaruhi performa yang dihasilkan [18]. Beberapa parameter yang biasa dilakukan penyesuaian tersebut diantaranya adalah *epoch*, *learning rate*, *batch size* dan *optimizer* [19]. Pada penelitian ini akan menggunakan 4 nilai *learning rate* yaitu 0.1, 0.01, 0.001 dan 0.0001, 3 *optimizer* yaitu SGD, Adam, RMSprop, *batch size* 64 dan *epoch* sebanyak 30.

HASIL DAN PEMBAHASAN

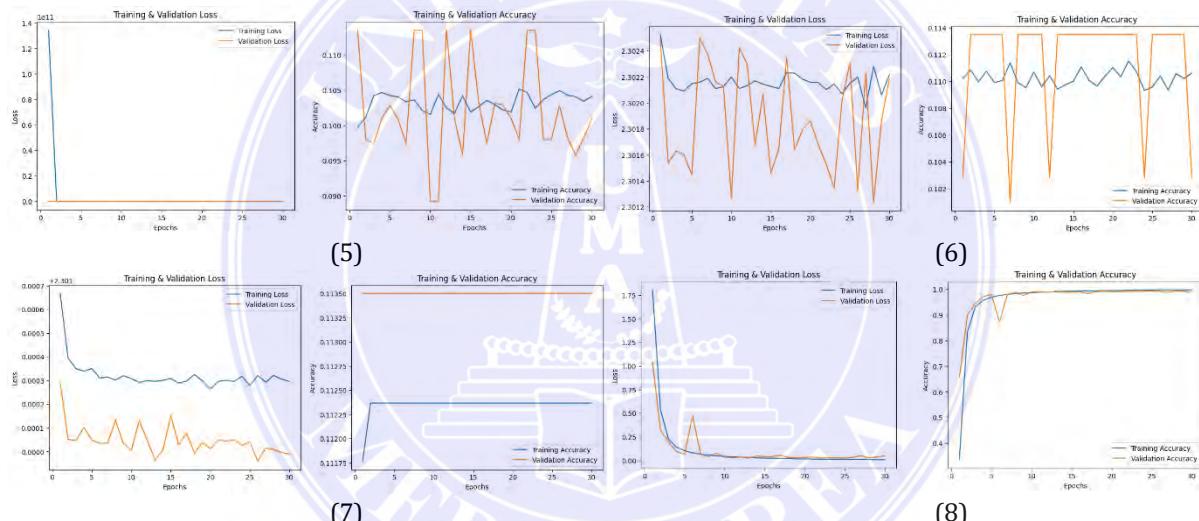
A. Model Pelatihan

Model dilatih dengan data latih yang dibagi 10% untuk validasi sehingga data menjadi 50000 untuk data latih dan 10000 untuk data validasi serta dilakukan penyesuaian *hyperparameter* terdiri dari 3 *optimizer* dan 4 nilai *learning rate* yang berbeda dengan *batch size* 64 dan *epoch* sebanyak 30. Ada sebanyak 12 model yang dilatih dan berikut grafik akurasi dan nilai *loss* dari hasil pelatihan yang dilakukan:

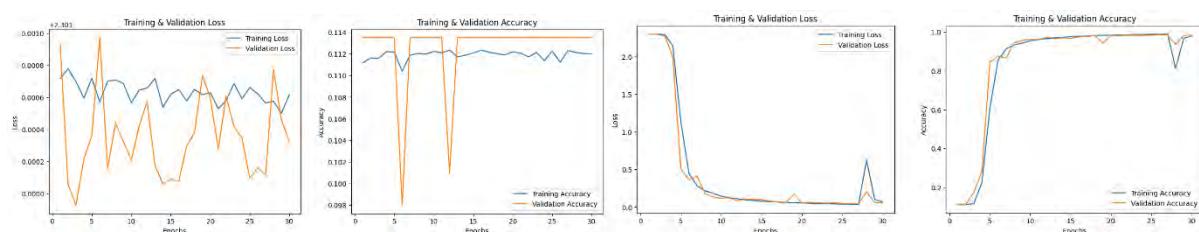


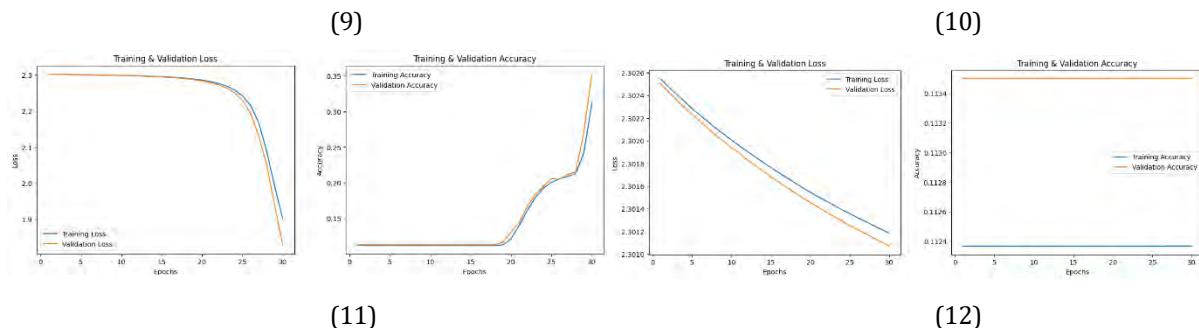
**Gambar 3** Grafik Akurasi dan Loss Pelatihan Model ke 1-4

Pada gambar 3 di atas merupakan grafik akurasi dan loss pada pelatihan model ke 1-4 dengan *optimizer* Adam dan *learning rate* 0.1, 0.01, 0.001 dan 0.0001 berurut sesuai nomor yang tertera pada gambar. Dapat dilihat bahwa pada gambar di atas hanya model ke-4 dengan *learning rate* 0.0001 memiliki tingkat akurasi yang terus meningkat dan pada epoch 30 mencapai akurasi sebesar 99%, sementara model lainnya tidak mengalami peningkatan selama 30 epoch dan hanya menetap pada akurasi sekitar sebesar 11%.

**Gambar 4** Grafik Akurasi dan Loss Pelatihan Model ke 5-8

Pada gambar 4 di atas merupakan grafik akurasi dan loss pada pelatihan model ke 5-8 dengan *optimizer* RMSprop dan *learning rate* 0.1, 0.01, 0.001 dan 0.0001 berurut sesuai nomor yang tertera pada gambar. Dapat dilihat bahwa pada gambar di atas hanya model ke-8 dengan learning rate 0.0001 memiliki tingkat akurasi yang terus meningkat dan pada epoch 30 mencapai akurasi sebesar 98%, sementara model lainnya tidak mengalami peningkatan selama 30 epoch dan hanya menetap pada akurasi sekitar sebesar 11%.



**Gambar 5** Grafik Akurasi dan Loss Pelatihan model ke 9-12

Pada gambar 5 di atas merupakan grafik akurasi dan loss pada pelatihan model ke 9-12 dengan *optimizer* SGD dan *learning rate* 0.1, 0.01, 0.001 dan 0.0001 berurut sesuai nomor yang tertera pada gambar. Dapat dilihat bahwa pada gambar di atas hanya model ke-10 dengan learning rate 0.01 memiliki tingkat akurasi yang terus meningkat dan pada epoch 30 mencapai akurasi sebesar 98%, sementara model ke-9 dan ke-12 tidak mengalami peningkatan dan hanya menetap pada akurasi sekitar 11% dan untuk model ke-11 cukup mengalami peningkatan akurasi pada epoch 20 sampai 30, namun hanya mencapai akurasi sekitar 35%

Berdasarkan 12 model di atas selama pelatihan model, dapat dilihat bahwa model ke-4 dengan *optimizer* Adam dan *learning rate* 0,0001, model ke-8 dengan *optimizer* RMSprop dan learning rate 0.0001 dan model ke-10 dengan *optimizer* SGD dan learning rate 0.01 adalah tiga model terbaik dengan akurasi yang terus mengalami peningkatan dan sebaliknya nilai *loss* terus mengalami penurunan dari epoch 1 hingga epoch 30.

B. Model Pengujian

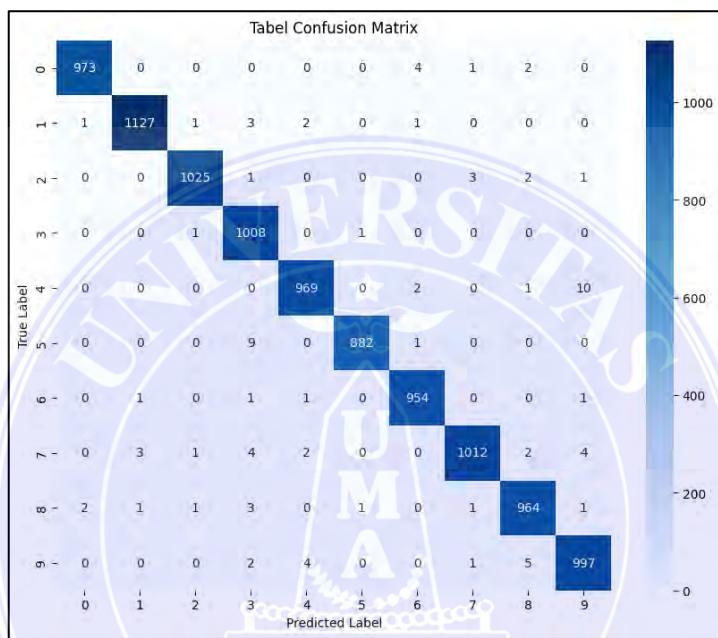
Pengujian model dilakukan dengan data uji yang terdiri atas 10000 data. Di bawah ini ditampilkan tabel yang memberikan informasi mengenai akurasi pengujian pada 12 model beserta data prediksi pada 10 label yaitu angka 0 sampai 9 yang dilengkapi dengan nilai *precision*, *recall* dan *f-1 score* di tiap label.

Tabel 2 Perbandingan Hasil Pada 12 Model

Model	Optimizer	Learning Rate	Accuracy	Label	Jumlah Aktual	Jumlah Terprediksi Benar	Accuracy Label	Precision	Recall	F-1 Score	Model	Optimizer	Learning Rate	Accuracy	Label	Jumlah Aktual	Jumlah Terprediksi Benar	Accuracy Label	Precision	Recall	F-1 Score
Model 1	Adam	0.1	11.35%	0	980	0	0	0	0	0	Model 7	RMSprop	0.001	11.35%	0	980	0	100%	0.1135	1.00	0.2039
				1	1135	1035	100%	0.1135	1.00	0.2039					1	1135	1035	100%	0.1135	1.00	0.2039
				2	1032	0	0	0	0	0					2	1032	0	0	0	0	0
				3	1010	0	0	0	0	0					3	1010	0	0	0	0	0
				4	982	0	0	0	0	0					4	982	0	0	0	0	0
				5	992	0	0	0	0	0					5	992	0	0	0	0	0
				6	1026	0	0	0	0	0					6	1026	0	0	0	0	0
				7	1028	0	0	0	0	0					7	1028	0	0	0	0	0
				8	974	0	0	0	0	0					8	974	0	0	0	0	0
				9	1009	0	0	0	0	0					9	1009	0	0	0	0	0
Model 2	Adam	0.01	10.28%	0	980	0	0	0	0	0	Model 8	RMSprop	0.0001	98.90%	0	980	977	99.69%	0.9899	0.9969	0.9934
				1	1135	0	0	0	0	0					1	1135	1131	99.64%	0.9966	0.9965	0.9965
				2	1032	0	0	0	0	0					2	1032	1019	98.74%	0.9971	0.9874	0.9922
				3	1010	0	0	0	0	0					3	1010	1007	99.70%	0.9962	0.9970	0.9829
				4	982	0	0	0	0	0					4	982	971	98.87%	0.9918	0.9888	0.9903
				5	992	0	0	0	0	0					5	992	872	97.75%	0.9932	0.9776	0.9853
				6	1026	0	0	0	0	0					6	1026	929	99.15%	0.9981	0.9981	0.9869
				7	1028	1028	100%	0.1020	1.00	0.1864					7	1028	1026	99.80%	0.9734	0.9981	0.9856
				8	974	0	0	0	0	0					8	974	955	98.04%	0.9938	0.9805	0.9871
				9	1009	0	0	0	0	0					9	1009	993	98.41%	0.9883	0.9841	0.9866
Model 3	Adam	0.001	11.35%	0	980	0	0	0	0	0	Model 9	SGD	0.1	11.35%	0	980	0	0	0	0	0
				1	1135	1035	100%	0.1135	1.00	0.2039					1	1135	1035	100%	0.1135	1.00	0.2039
				2	1032	0	0	0	0	0					2	1032	0	0	0	0	0
				3	1010	0	0	0	0	0					3	1010	0	0	0	0	0
				4	982	0	0	0	0	0					4	982	0	0	0	0	0
				5	992	0	0	0	0	0					5	992	0	0	0	0	0
				6	1026	0	0	0	0	0					6	1026	0	0	0	0	0
				7	1028	0	0	0	0	0					7	1028	0	0	0	0	0
				8	974	0	0	0	0	0					8	974	0	0	0	0	0
				9	1009	0	0	0	0	0					9	1009	0	0	0	0	0
Model 4	Adam	0.0001	99.11%	0	980	973	99.28%	0.9969	0.9929	0.9949	Model 10	SGD	0.01	98.32%	0	980	973	99.28%	0.9818	0.9929	0.9873
				1	1135	1127	99.29%	0.9956	0.9930	0.9943					1	1135	1116	98.32%	0.9964	0.9833	0.9898
				2	1032	1025	99.32%	0.9961	0.9932	0.9947					2	1032	1021	98.93%	0.9798	0.9893	0.9846
				3	1010	1008	99.80%	0.9777	0.9968	0.9878					3	1010	993	98.31%	0.9881	0.9832	0.9856
				4	982	969	98.67%	0.9984	0.9868	0.9848					4	982	974	99.18%	0.9911	0.9911	0.9814
				5	992	882	90.76%	0.9777	0.9777	0.9788					5	992	880	90.11%	0.9743	0.9743	0.9690
				6	1026	954	99.50%	0.9917	0.9958	0.9928					6	958	923	98.34%	0.9957	0.9815	0.9793
				7	1028	1012	98.44%	0.9941	0.9844	0.9892					7	1028	1019	99.12%	0.9789	0.9912	0.9850
				8	974	964	98.97%	0.9877	0.9897	0.9887					8	974	974	97.22%	0.9803	0.9723	0.9763
				9	1009	997	98.81%	0.9832	0.9881	0.9857					9	1009	986	97.72%	0.9883	0.9772	0.9811
Model 5	RMSprop	0.1	10.09%	0	980	0	0	0	0	0	Model 11	SGD	0.001	35.23%	0	980	0	0	0	0	0
				1	1135	0	0	0	0	0					1	1135	1123	98.94%	0.7278	0.9884	0.8387
				2	1032	0	0	0	0	0					2	1032	23	2.22%	0.1014	0.0223	0.0365
				3	1010	0	0	0	0	0					3	1010	981	97.12%	0.1746	0.9713	0.2960
				4	982	0	0	0	0	0					4	982	349	37.3%	0.0443	0.1744	0.4530
				5	992	0	0	0	0	0					5	992	0	0	0	0	0
				6	958	0	0	0	0	0					6	958	331	34.55%	0.7275	0.3455	0.4685
				7	1028	0	0	0	0	0					7	1028	716	63.64%	0.4483	0.6965	0.5455
				8	974	0	0	0	0	0					8	974	0	0	0	0	0
				9	1009	1009	100%	0.1009	1.00	0.1833					9	1009	0	0	0	0	0
Model 6	RMSprop	0.01	10.28%	0	980	0	0	0	0	0	Model 12	SGD	0.0001	11.35%	0	980	0	0	0	0	0
				1	1135	0	0	0	0	0					1	1135	1035	100%	0.1135	1.00	0.2039
				2	1032	0	0	0	0	0					2	1032	0	0	0	0	0
				3	1010	0	0	0	0	0					3	1010	0	0	0	0	0
				4	982	0	0	0	0	0					4	982	0	0	0	0	0
				5	992	0	0	0	0	0					5	992	0	0	0	0	0
				6	1026	0	0	0	0	0					6	1026	0	0	0	0	0
				7	1028	1028	100%	0.1028	1.00	0.1864											

C. Evaluasi Akhir

Evaluasi akhir dilakukan dengan menampilkan grafik confusion matrix yang memberikan informasi mengenai kesalahan prediksi pada 10 label yang terdiri dari angka 0 sampai 9. Pada proses pengujian, dapat diketahui bahwa model ke-4 dengan optimizer Adam dan learning rate 0.0001 adalah model yang terbaik dengan tingkat akurasi mencapai 99.11% dan model ke-4 inilah yang kemudian dilakukan evaluasi. Berikut di bawah ini grafik confusion matrix pada model ke-4 tersebut



Gambar 6 Grafik Confusion Matrix

Berdasarkan gambar 6 di atas dapat diketahui informasi label yang terprediksi dengan benar dan terprediksi sebagai label lain. Kesalahan prediksi terjadi paling banyak yaitu pada label angka 9 yang diprediksi sebanyak 5 kali sebagai angka 8, pada label angka 5 yang diprediksi sebanyak 9 kali sebagai angka 3 dan pada label angka 4 yang diprediksi sebanyak 10 kali sebagai angka 9.

KESIMPULAN

Penelitian ini melakukan klasifikasi pada dataset MNIST untuk melakukan pengenalan tulisan tangan angka menggunakan arsitektur CNN SqueezeNet yang dilakukan *fine-tuning hyperparameter* yaitu menggunakan *learning rate* terdiri dari 0.1, 0.01, 0.001 dan 0.0001, *optimizer* berupa Adam, SGD, dan RMSprop, *batch size* 64 dan *epoch* sebanyak 30 yang mana menghasilkan 12 model. Berdasarkan 12 model yang telah dilakukan pengujian, diperoleh 1 model terbaik kombinasi *hyperparameter* yaitu Adam

dengan *learning rate* 0.0001 yang menghasilkan nilai akurasi sebesar 99.11%. Pada grafik *confusion matrix*, terdapat aktual label dan label yang diprediksi dan model yang terbaik ini banyak terjadi kesalahan prediksi pada label angka 5 yang diprediksi sebanyak 9 kali sebagai label angka 3 dan pada label angka 4 yang diprediksi sebanyak 10 kali sebagai angka 9. Penelitian menggunakan dataset yang sama yaitu MNIST dilakukan oleh Ali Abdullah Yahya menghasilkan akurasi sebesar 99.98% dengan menerapkan algoritma CNN menggunakan *optimizer* RMSprop. Jika dibandingkan dengan hasil CNN *SqueezeNet* pada penelitian ini hanya berbeda 0.87%, dengan ini dikatakan bahwa CNN *SqueezeNet* mampu untuk mengklasifikasikan dataset MNIST untuk pengenalan tulisan tangan angka dengan baik. Diharapkan penelitian ini dapat menjadi referensi untuk penelitian mendatang dan menambahkan nilai *hyperparameter* yang lebih banyak supaya hasil akurasi meningkat dan menjadi lebih baik lagi.

DAFTAR PUSTAKA

- [1] M. Khalil, A. Khalil and A. Ngom, "A Comprehensive Study of Vision Transformer In Image Classification Task," *arXiv*, 2023.
- [2] R. Dixit, R. Kushwah and S. Pashine, "Handwritten Digit Recognition Using Machine Deep Learning Algorithms," *International Journal of Computer Applications*, 2021.
- [3] S. Dewi, F. Ramadhani and S. Djasmayena, "Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network)," *Hello World Jurnal Ilmu Komputer*, 2024.
- [4] M. K. Santosa, M. H. P. Swari and A. N. Sihananto, "Implementasi Arsitektur Alexnet dan Resnet34 Pada Klasifikasi Citra Penyakit Daun Kentang Menggunakan Transfer Learning," *Jurnal Mahasiswa Teknik Informatika*, 2023.
- [5] W. Setiawan, A. Ghofur, F. H. Rachman and R. Rulaningtyas, "Deep Convolutional Neural Network Alexnet and SqueezeNet for Maize Leaf Disease Image Classification," *KINETIK: Game Technology, Information System, Computer Network, Computing, Electronics and Control*, 2021.
- [6] B. Gope, S. Pande, N. Karale, S. Dharmale and P. Umekar, "Handwritten Digit Identification Using MNIST Database Via Machine Learning Models," *PURPOSE-LED PUBLISHING*, 2021.
- [7] L. M. Seng, B. B. C. Chiang, Z. A. A. Salam, G. Y. Tan and H. T. Chai, "MNIST Handwritten Digit Recognition with Different CNN Architectures," *Journal of Applied Technology and Innovation*, 2021.
- [8] Y. Chychkarov, A. Serhiienko, I. Syrmamiikh and A. Kargin, "Handwritten Digit Recognition Using SVM, KNN, RF and Deep Learning Neural Network," *CEUR-WS.org*, 2021.

- [9] A. A. Yahya, J. Tan and M. Hu, "A Novel Handwritten Digit Classification System Based on Convolutional Neural Network Approach," *MDPI*, 2021.
- [10] F. Panjaitan, R. S. Simbolon and J. Batubara, "Handwritten Digit Recognition Using Support Vector Machine (SVM) with Radial Basis Function (RBF) Kernel," *Journal Basic Science and Technology*, 2025.
- [11] R. Zhu, A. Loeffler, J. Hochstetter, A. D. Alvarez, T. Nakayama, A. Stieg, J. Gimzewski, J. T. Lizier and Z. Kuncic, "MNIST Classification Using Neuromorphic Nanowire Network," *Association for Computing Machinery*, 2021.
- [12] Susilawati, "Algoritma Restricted Boltzmann Machines (RBM) Untuk Pengenalan Tulisan Tangan Angka," *Seminar Nasional Teknologi Informatika*, 2017.
- [13] T. Soupizet, Z. Jouni, S. Wang, A. Benlarbi-Delai and P. M. Ferreira, "Analog Spiking Neural Network Synthesis for MNIST," *Journal of Integrated Circuits and Systems*, 2023.
- [14] F. Adam, R. A. D. Anggoro, M. B. Satria, A. W. Oktavia and N. Chamidah, "Perbandingan Normalisasi Data Untuk Klasifikasi Wine Menggunakan Algoritma Naive Bayes, Decision Tree dan Support Vector Machine," *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya*, 2021.
- [15] G. A. B. Suryanegara, Adiwijaya and M. D. Purbalaksono, "Peningkatan Hasil Klasifikasi Pada Algoritma Random Forest Untuk Deteksi Pasien Penderita Diabetes Menggunakan Metode Normalisasi," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 2021.
- [16] Q. Baohua, Y. Zhai, M. Zhou, X. Yang, B. Peng, Wang Yufeng and Y. Pang, "SqueezeNet and Fusion Network-Based Accurate Fast Fully Convolutional Network for Hand Detection and Gesture Recognition," *IEEE Access*, 2021.
- [17] P. Theerthagiri, A. U. Ruby, J. G. C. Chandran, T. H. Sardar and A. S. B.M, "Deep SqueezeNet Learning Model for Diagnosis and Prediction of Maize Leaf Disease," *Journal of Big Data*, 2024.
- [18] M. Sipper, "High Per Parameter: A Large-Scale Study of Hyperparameter Tuning for Machine Learning Algorithms," *MDPI*, 2022.
- [19] A. julianto, A. Sunyoto and F. W. Wibowo, "Optimizer Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi," *Jurnal Teknikmedia*, 2022.