

Pemanfaatan Convolutional Neural Network (Cnn) Untuk Klasifikasi Jenis Beras Berbasis Citra

1st Victor Aji Admaja Pellokila
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
ajipellokila@student.telkomuni-
versity.ac.id

2nd Koredianto Usman
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
korediantousman@telkomuniver-
sity.co.id

3rd Nor Kumalasari Caecar Pratiwi
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
caecarnkcp@telkomuniversity.ac.id

Abstrak — Beras merupakan makanan pokok untuk orang Asia, terutama di Indonesia. Untuk melakukan pengolahan padi menjadi beras, ada dua hal yang harus dilakukan yaitu dengan cara tradisional seperti ditumbuk dan ada juga seperti cara modern seperti penggilingan menggunakan mesin. Seperti yang diketahui, banyak jenis beras yang telah beredar di pasaran. Dengan adanya beragam jenis beras yang beredar, tentu juga ada hal yang tidak bisa dilakukan oleh manusia dalam mengklasifikasi jenis beras dengan mengandalkan indera penglihatan saja. Maka dari itu, pengolahan citra digital dapat berperan penting agar dapat memudahkan manusia untuk mengklasifikasi jenis beras. Tujuan penelitian ini, untuk mengklasifikasikan jenis beras dengan menggunakan metode Convolutional Neural Network (CNN) arsitektur AlexNet berbasis pengolahan citra. Adapun dataset yang digunakan pada penelitian berjumlah 2500 citra yang bersumber dari Kaggle, dimana ada lima jenis beras yang akan diklasifikasikan yaitu beras arborio, beras basmati, beras ipsala, beras jasmine dan beras karacadag. Pada penelitian ini parameter yang akan dianalisis adalah akurasi, loss, presisi, recall, dan F1-Score. Di tiap pengujian, akan dilakukan empat skenario pengujian terhadap hyperparameter berupa input size, optimizer, learning rate, batch size. Dari pengujian yang telah dilakukan didapatkan hasil terbaik dengan citra asli menggunakan input size 128×128, optimizer SGD, learning rate 0.0001, dan batch size 32. Berdasarkan dari hasil pengujian tersebut, test accuracy yang didapatkan sebesar 98.40% dengan testing loss 0.0659

Kata kunci— Jenis Beras, CNN, Deep Learning, AlexNet.

I. PENDAHULUAN

Bagi penduduk Indonesia, beras merupakan salah satu bahan pangan utama yang dibutuhkan sehari-hari untuk kesehatan, mencukupi kebutuhan gizi dan nutrisi untuk kesehatan, makanan lokal lainnya seperti umbi-umbian tidak mampu mengganti keberadaan beras sebagai bahan pangan utama [1]. Proses pengolahan padi untuk menjadi beras dilakukan dengan dua cara yaitu dengan proses pengolahan yang ditumbuk dan proses pengolahan penggilingan dengan menggunakan alat. Beras merupakan komponen penting dalam makanan sehari-hari. Ada beberapa jenis beras yang beredar di pasaran yaitu beras pandan wangi, beras rojolele, beras merah, beras hitam, dan lain-lain. Dengan mempunyai

beraneka ragam bentuk, warna, dan jenis beras yang ada di pasaran sehingga banyak kelemahan yang dimiliki manusia dalam membedakan klasifikasi jenis beras dengan mengandalkan secara visual saja, oleh karena itu dituntut adanya pengawasan terhadap standar kualitas beras. Pengamatan secara visual terhadap kualitas beras cukup rentan terhadap kesalahan karena tiap pengamatan yang dilakukan secara subjektifitas berbeda-beda [2].

Maka dari itu pada penelitian ini akan dilakukan klasifikasi jenis beras berbasis citra dengan menggunakan sebuah algoritma yang dapat membantu sistem dalam mengidentifikasi jenis-jenis beras secara cepat dan akurat. Sehingga dapat memudahkan masyarakat dalam memilih jenis beras yang akan dibeli dan juga guna menghindari kecurangan yang dilakukan oleh penjual yang menjual beras dengan campuran varietas beras lainnya atau yang mengandung bahan kimia. Seiring perkembangan era digital pada saat ini, dapat memungkinkan adanya sebuah komputasi yang bisa mengolah informasi dari suatu citra untuk mengetahui objek secara otomatis, melalui image processing. Telah banyak penelitian yang dilakukan sebelumnya terkait dengan klasifikasi jenis beras dan juga banyak metode yang telah digunakan agar bisa mendapatkan hasil akurasi yang lebih baik dalam penelitian tentang studi kasus tersebut. Contohnya seperti Identifikasi Kualitas Beras Menggunakan Metode k-Nearest Neighbor dan Support Vector Machine oleh Sofia Saidah, Muhammad Bayu Adinegara, Rita Magdalena, dan Nor Kumalasari Caesar Pratiwi, yang dimana pada penelitian tersebut memperoleh hasil akurasi sebesar 96,67% [2].

Adapun penelitian lainnya yaitu Identifikasi Citra Digital Jenis Beras Menggunakan Metode Adaptive Neuro Fuzzy Inference System (ANFIS) oleh Gansar Suwanto merupakan salah satu penelitian yang pengujiannya menggunakan 140 citra dengan mengandalkan nilai bentuk dan tekstur citra. Dari pengujian yang dia lakukan, berhasil mendapatkan tingkat keakurasian sebesar 85.2% dan pengaruh akurasi sebesar 3% deteksi tepi sobel sebagai metode tambahan [3]. Dan juga penelitian yang dilakukan oleh Jurni, Utami Tri Sulistyorini, dan Azizah yang membahas tentang Identifikasi Jenis Beras Melalui Akurasi Kemiripan Fitur Bentuk dan Warna, dengan melakukan pengujian yang menggunakan 9

jenis beras dengan total 90 citra dan masing-masing jenis beras memiliki 10 citra dengan tingkat akurasi yang didapatkan mencapai 80% [4].

Pada penelitian kali ini, mengusulkan klasifikasi jenis beras berbasis citra dengan menggunakan Convolutional Neural Network (CNN). Convolutional Neural Network (CNN) didesain untuk melakukan pengolahan data dua dimensi dan juga memiliki kedalaman jaringan yang tinggi dan sering diaplikasikan pada data citra. Serta untuk arsitekturnya penulis akan menggunakan arsitektur AlexNet yang mempunyai tingkat akurasi yang tinggi dalam melakukan pengolahan citra dua dimensi. AlexNet memiliki salah satu karakteristik yaitu mempunyai down sampling yang sangat cepat dari representasi intermediate melalui stride konvolusi dan max pooling layer. Alexnet juga memenangkan kompetisi ILSVCR pada tahun 2010 dan 2012 dengan menghasilkan jumlah rate terendah yaitu 15,03%. Adapun klasifikasi yang dilakukan menggunakan 1.2 juta data citra beresolusi tinggi dengan 1000 kategori berbeda.

II. KAJIAN TEORI

A. Beras

Beras merupakan hasil pengolahan dari produk pertanian yaitu padi, dan merupakan salah satu bahan pokok utama yang dijadikan makanan oleh sebagian besar masyarakat Asia, khususnya di Indonesia. Menurut Peraturan Menteri Perdagangan RI Nomor 19/M-DAG/PER/3/2014 dijelaskan bahwa beras adalah biji-bijian baik berkulit, tidak berkulit, diolah atau tidak diolah yang berasal dari *Oriza Sativa*. Dalam hal ini beras meliputi beras giling, beras pecah kulit, dan gabah. Umumnya, beras adalah bagian bulir padi (gabah) yang telah dipisah dari sekam dan dedak. Diketahui pada tahun 2021, di Indonesia total dari produksi padi mencapai kisaran 55,27 juta ton GKG [5]. Lebih dari setengah penduduk dunia bertumpu pada beras sebagai makanan pokok utama, khususnya di Asia Tenggara, Cina, dan India, dan lain-lain [6].


B. Citra Digital

Citra adalah gambar dua dimensi yang ditampilkan pada suatu layar komputer berbentuk piksel berdasarkan nilai digital dengan pendekatan yang berdasarkan sampling dan kuantisasi. Sampling menjelaskan tentang besarnya kotak-kotak yang terdiri atas baris dan kolom. Sampling merupakan bentuk dari suatu piksel pada citra yang berukuran besar atau kecil. Kuantisasi menyatakan tentang nilai keabuan yang berdasarkan dari besarnya nilai tingkat kecerahan. Dalam hal ini, citra digital mengacu pada pemrosesan setiap data dua dimensi.[15]. Citra digital juga dapat diartikan sebagai fungsi $f(x,y)$ dengan ukuran M dan N kolom, dimana x dan y merupakan koordinat spasial dan amplitud f berada di titik koordinat (x,y) yang menunjukkan nilai intensitas atau skala keabuan dari citra pada titik tersebut. Umumnya, citra digital mempunyai bentuk persegi panjang dengan dimensi ukurannya dapat dinyatakan sebagai tinggi \times lebar. Pada persamaan 2.1 dapat merepresentasikan citra digital yang memiliki dimensi $M \times N$ dalam bentuk matriks.

$$f(x,y) = \begin{bmatrix} f(0,0) & \dots & f(0,M-1) \\ \vdots & & \vdots \\ f(n-1,0) & \dots & f(n-1,M-1) \end{bmatrix} \quad [2.1]$$

C. Citra Biner


Citra biner adalah citra yang hanya mempunyai dua graylevel, yaitu 0 dan 1. Artinya, hitam = 1 dan putih = 0 atau sebaliknya. Seperti yang ditunjukkan pada contoh Gambar 2.7. Di dalam citra biner, untuk kebutuhan memori hanya mempunyai 1 bit/pixel. Citra biner menggunakan tiga operasi logika, yaitu AND, OR, NOT sehingga waktu komputasinya lebih kecil. Citra biner juga mampu memisahkan objek dari gambar latar belakangnya agar lebih fokus pada analisis bentuk morfologi, yang dalam artian, intensitas dari pixel tidak terlalu penting dibandingkan bentuknya. Setelah objek dipisahkan dari latar belakangnya, maka morfologi objek dan properti geometri dapat dihitung dari citra biner [16].



GAMBAR 1
Citra Biner

D. Citra Grayscale

Citra Grayscale merupakan format yang digunakan untuk bentuk digital yang per pikselnya mempunyai nilai 1. Yang berarti, Red = Green = Blue. Untuk menunjukkan intensitas suatu warna dapat menggunakan nilai ini. Seperti yang ditunjukkan pada Gambar 2.7 merupakan contoh jenis citra yang terdiri dari grayscale. Dimana, warna hitam merupakan intensitas minimum (0) dan warna putih merupakan intensitas maksimal (1). Setiap piksel yang terdapat pada citra grayscale diwakili oleh 8 bit atau 1 byte, yang direpresentasikan oleh gradasi warna hitam dan putih. Untuk pengolahan citra sangat cocok menggunakan rentang warna pada grayscale. Salah satu contoh pengaplikasian citra digital yaitu pada bidang kedokteran, yakni X-ray [17].




GAMBAR 2
Citra Grayscale

E. Citra RGB (Red, Green, Blue)

Citra RGB merupakan citra berwarna yang memiliki matriks berukuran $m \times n \times 3$, yang nilai dari intensitas pikselnya terdiri atas 3 saluran warna yaitu merah, hijau, dan biru. Warna yang dapat digunakan maksimum berjumlah 256. Seperti yang tertera pada Gambar 2.8 menjelaskan bahwa warna utama mempunyai jangkauan nilai. Setiap warna dari masing-masing piksel dapat

mempengaruhi kombinasi intensitas dari warna merah, hijau, dan biru [17].



GAMBAR 3
Citra RGB


F. Deep Learning

Deep learning merupakan salah satu cabang dari ilmu pembelajaran mesin (Machine Learning) yang di dalamnya tersusun atas algoritma permodelan abstraksi tingkat tinggi pada data dengan menggunakan sekumpulan fungsi transformasi non-linier yang diatur berlapis-lapis dan mendalam. Deep learning dapat digunakan untuk kebutuhan pembelajaran searah (supervised learning), pembelajaran tak searah (unsupervised learning) dan semi-terarah (semi supervised) untuk berbagai aplikasi yang digunakan seperti pada pengenalan citra, pengenalan suara, klasifikasi teks, dan sebagainya. Deep learning juga merupakan salah satu algoritma jaringan saraf tiruan yang menggunakan metadata sebagai proses input lalu mengolahnya menggunakan sejumlah lapisan yang tersembunyi (hidden layer) transformasi data linier dari data masukan untuk menghitung nilai output. Deep learning mempunyai struktur dan jumlah jaringan saraf yang ada pada algoritmanya sangat banyak bahkan sampai ratusan lapisan dan deep learning juga memiliki fitur unik yang mampu mengekstraksi secara otomatis [18]. Pada jaringan saraf tiruan seperti deep learning, setiap lapisan tersembunyi mempunyai tanggung jawab untuk melatih serangkaian fitur unik berdasarkan output dari jaringan sebelumnya. Ketika jumlah lapisan tersembunyi (hidden layer) semakin banyak bertambah banyak maka deep learning akan menjadi lebih kompleks dan bersifat abstrak. Hirarki sederhana dapat terbentuk dengan beberapa lapisan hingga tingkat tinggi atau banyak lapisan (multilayer) yang disebabkan oleh jaringan saraf yang dimiliki oleh deep learning. Karena hal itulah deep learning dapat digunakan sebagai pemecah masalah yang kompleks dan rumit dan terdiri dari sejumlah besar lapisan non linier.

G. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah pengembangan dari multilayer perceptron (MLP) yang dirancang untuk mengolah data dalam bentuk dua dimensi. Contohnya, seperti suara atau gambar. CNN digolongkan sebagai Deep Neural Network karena mempunyai kedalaman jaringan yang tinggi dan sering digunakan pada data citra. CNN juga merupakan salah satu metode deep learning yang sering digunakan untuk mengolah data citra. CNN dapat menerima masukan dari sebuah citra kemudian menentukan objek yang ada pada citra tersebut untuk dikenali dan dipelajari. CNN juga sering digunakan untuk deteksi citra medis, dalam hal ini seperti rontgen dada, CT X-ray, analisis citra jantung, perut atau muskuloskeletal [19]. Proses konvolusi yang digunakan oleh CNN dengan menggerakkan


sebuah kernel konvolusi atau filter suatu gambar dan informasi representatif baru akan di dapatkan dari hasil perkalian dari segmen gambar tersebut dengan filter yang digunakan [20]. Arsitektur CNN terdiri atas 2 bagian, yaitu Feature Learning dan Classification. Terdapat tiga lapisan yang ada pada bagian Feature Extraction Layer yaitu Convolutional Layer, Rectified Layer Unit (ReLU) Activation Layer, dan Pooling Layer. Sedangkan untuk bagian Classification tahapannya terdiri dari Flatten Layer, Fully Connected Layer, dan Softmax [20]. CNN mempunyai beberapa lapisan tersembunyi (hidden layers) dari sebuah masukan berupa vector tunggal, dengan masukan berupa citra yang dijadikan vector tunggal 32×32 . Di tiap hidden layers mempunyai beberapa neuron seperti empat feature maps C1, dimana neuron yang ada pada C1 dihubungkan dengan neuron di S1, dan seterusnya. Lapisan lapisan tersembunyi yang telah dihubungkan dengan lapisan terakhir disebut dengan output layer dan merepresentasikan hasil akhir dari klasifikasi kelas.



GAMBAR 4
Arsitektur CNN

H. AlexNet

Alexnet merupakan salah satu arsitektur yang ada pada CNN yang dikembangkan oleh Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever. AlexNet mempunyai delapan layer ekstraksi, yang terdiri dari lima convolution layer, tiga pooling layer dan lima ReLU. Pada bagian awal arsitektur terdapat Extraxtion layer yang berfungsi untuk menerima gambar secara langsung dan output yang berupa gambar vektor. Kemudian layer yang kedua adalah classification layer yang tersusun atas fully connected layer, ReLU dan softmax, Pada tiga fully connected layer, dua ReLU dan softmax disusun secara berselang-seling. Hasil dari pemrosesan pada extraction layer, input yang diterima berupa gambar vektor dan hasil dari keseluruhan dari classification layer merupakan output pemrosesan yang berupa gambar yang telah terklasifikasi [21].



GAMBAR 5
Arsitektur AlexNet

I. Confusion Matrix

Pada suatu sistem klasifikasi memerlukan evaluasi kinerja yang berperan penting mengetahui seberapa baik sistem yang akan dibangun dalam mengklasifikasikan data.

Confusion matrix merupakan salah satu metode yang bisa digunakan untuk mengukur hasil dari kinerja sistem telah kita buat khususnya pada deep learning [22]. Pada umumnya confusion matrix digunakan sebagai pengukuran kinerja sistem klasifikasi untuk membandingkan hasil klasifikasi oleh sistem dengan hasil klasifikasi sesungguhnya. Ada empat istilah yang ada pada confusion matrix yaitu, True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN) untuk mempresentasikan hasil perbandingan klasifikasi sistem dan klasifikasi sesungguhnya [22]. Pada dasarnya dari hasil perbandingan antara hasil klasifikasi sistem dan klasifikasi sesungguhnya akan diberikan informasi oleh confusion matrix dalam bentuk tabel matriks. Tabel matriks akan menunjukkan bagaimana melakukan klasifikasi pada kumpulan data validasi dengan nilai sesungguhnya yang diketahui.

TABEL 1
Confusion Matrix

Predicted Class	Actual Class	
	True	False
True	TP	FP
False	FN	TN

Untuk menghitung kinerja pengklasifikasian sistem yang telah dibikin, kita dapat menghitung performance matrix seperti accuracy (persamaan 2.2), precision (persamaan 2.3), recall (persamaan 2.4), dan F1-Score (persamaan 2.5) dengan menggunakan confusion matrix [23].

TABEL 2
Confusion Matrix sistem

Predicted Class	Actual Class				
	Class A	Class B	Class C	Class D	Class E
Class A	X_{AA}	X_{AB}	X_{AC}	X_{AD}	X_{AE}
Class B	X_{BA}	X_{BB}	X_{BC}	X_{BD}	X_{BE}
Class C	X_{CA}	X_{CB}	X_{CC}	X_{CD}	X_{CE}
Class D	X_{DA}	X_{DB}	X_{DC}	X_{DD}	X_{DE}
Class E	X_{EA}	X_{EB}	X_{EC}	X_{ED}	X_{EE}

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad [2.2]$$


$$precision = \frac{TP}{TP + FP} \quad [2.3]$$

$$recall = \frac{TP}{TP + FN} \quad [2.4]$$

$$F1 - score = \frac{2 \times recall \times precision}{recall + precision} \quad [2.5]$$

III. METODE

A. Dataset



GAMBAR 6

Rice Image dataset (a) arborio, (b) basmati, (c) ipsala, (d) jasmine, (e) karacadag

Pada penelitian ini untuk dataset yang akan digunakan adalah dataset yang akan diambil dari Kaggle, dengan jumlah sebanyak 2.500 citra butir beras dari lima jenis beras yaitu beras arborio, beras basmati, beras ipsala, beras jasmine dan beras karacadag dengan masing-masing jenis berasnya terdapat 500 citra butir beras yang berformat JPG

B. Desain Sistem

Pada penelitian untuk mengklasifikasi data metode yang digunakan adalah CNN dan menggunakan arsitektur AlexNet. Untuk data input yang akan digunakan berupa citra digital beberapa jenis beras yang telah disediakan. Alur kerja pada sistem ini dapat dilihat dari diagram alir sebagai berikut.




GAMBAR 7

Diagram alir klasifikasi citra data latih dan data uji

Pada gambar 7 merupakan proses pelatihan model AlexNet diawali dengan melakukan penginputan citra dari dataset sampai diperolehnya hasil klasifikasi dari jenis beras. Pelatihan model dilakukan supaya model mampu mengklasifikasikan citra jenis beras dengan tingkat akurasi yang tinggi. Dalam hal ini, proses pelatihan model dilakukan dengan cara memasukan beberapa citra jenis beras yang telah memiliki label dari masing-masing kelas, agar bisa melewati model yang sudah dibuat. Untuk mendapatkan parameter terbaik, model akan melakukan proses pelatihan secara berulang-ulang, sehingga klasifikasi secara akurat dapat dilakukan oleh model.

C. Pre-processing

Pre-processing adalah proses yang terjadi sebelum citra dimasukan kedalam sistem. Tujuan dilakukannya pre processing ini agar bisa memperbaiki atau meningkatkan kualitas citra dan menyesuaikan citra supaya dapat meningkatkan performansi dari sistem. Apabila tidak melakukan proses pre-processing pada data yang akan digunakan, maka performansi dari model tidak akan bekerja secara maksimal ini disebabkan karena kesulitan mengolah data yang dialami oleh model pada saat proses pre-processing.



GAMBAR 8
Diagram Alir Pre-processing

Berdasarkan diagram alir pre-processing diatas, hal yang dilakukan pertama kali yaitu menginput seluruh dataset citra. Setelah itu, ukuran dari inputan citra tersebut akan diubah melalui proses resize, dengan cara menaikkan atau menurunkan jumlah piksel yang ada pada ukuran citra tersebut. Pada penelitian menggunakan empat resize citra dengan ukuran yang berbeda, yaitu 128×128 piksel, 224×224 piksel, 227×227 , dan 250×250 . Setelah melakukan proses resize maka hasil data citra telah didapatkan dan akan dilakukan proses pengolahan citra selanjutnya.

D. Performansi Sistem

Performansi sistem dapat dilakukan apabila tahapan pada training data dan testing data sudah selesai dilakukan. Untuk mengukur performansi kerja sistem dapat menggunakan empat parameter yaitu accuracy, precission, recall, dan F1-Score, dengan dibantu menggunakan confusion matrix.

IV. HASIL DAN PEMBAHASAN

A. Skenario I: Input Size

Pengujian skenario pertama adalah pengujian yang dilakukan dengan membandingkan pengaruh dari empat input size yaitu 128×128 , 224×224 , 227×227 , dan 250×250 pada citra asli. Adapun nilai hyperparameter lainnya seperti optimizer SGD, learning rate 0.01 dan batch size 32 yang digunakan untuk melakukan pengujian terhadap nilai dari input size.

TABEL 3
Hasil Pengujian Input Size

Input Size	Train Accuracy	Train Loss	Test Accuracy	Test Loss
128×128	99.00%	0.0296	97.20%	0.1135
224×224	63.80%	1.6459	63.80%	1.7233
227×227	40.10%	1.1713	41.20%	1.1354
250×250	72.10%	0.5721	72.20%	0.5526

Berdasarkan hasil dari Tabel 3 didapatkan hasil akurasi terbaik pada pengujian dengan ukuran citra 128×128 piksel dengan nilai test accuracy sebesar 97.20% dengan loss 0.1135. Dengan hasil yang telah didapatkan ini, maka penggunaan ukuran citra 128×128 dinilai sudah baik dalam mengenali lima jenis kelas beras karena mampu mendapatkan akurasi tertinggi, sehingga fitur yang ada pada citra menjadi lebih baik dan beban pada saat komputasi tidak terlalu berat.

B. Skenario II: Optimizer

Setelah mendapatkan hasil terbaik dari input size pada pengujian sebelumnya yaitu 128×128 , maka langkah selanjutnya adalah menguji pengaruh dari beberapa optimizer yang digunakan pada pengujian ini. Adapun optimizer yang akan diuji adalah SGD, Adam, RMSprop. Pada pengujian ini learning rate yang digunakan adalah bernilai 0,01 dengan batch size 32.

TABEL 4
Hasil Pengujian Optimizer

Optimizer	Train Accuracy	Train Loss	Test Accuracy	Test Loss
SGD	99.00%	0.0296	97.20%	0.1135
Adam	20.40%	1.6105	18.40%	1.6165
RMSprop	47.90%	6.1484	45.60%	6.4613

Berdasarkan Tabel 4, optimizer terbaik yang berhasil didapatkan yaitu SGD, yang ditunjukkan dengan hasil test accuracy sebesar 97.20% dengan loss 0.1143. Dengan hasil tersebut, optimizer yang baik digunakan pada skenario selanjutnya adalah optimizer SGD.

C. Skenario III: Learning Rate

Setelah berhasil memperoleh hasil dari optimizer terbaik yaitu SGD pada pengujian sebelumnya, maka selanjutnya adalah melakukan pengujian pengaruh learning rate terhadap parameter. Learning rate yang akan digunakan pada pengujian yaitu bernilai 0.01, 0.001, 0.0001, 0.00001. Nilai hyperparameter lainnya seperti batch size yang digunakan bernilai 32 dan input size yang berukuran 128×128 .

TABEL 5
Hasil Pengujian Learning Rate

Learning Rate	Train Accuracy	Train Loss	Test Accuracy	Test Loss
0.01	99.00%	0.0296	97.20%	0.1135
0.001	99.90%	0.0035	98.00%	0.0882
0.0001	99.95%	0.0066	98.40%	0.0659
0.00001	99.75%	0.0286	98.00%	0.0654

Berdasarkan hasil yang diperoleh pada tabel 4.6, bahwa pengujian yang dilakukan berhasil mendapatkan hasil yang terbaik dengan menggunakan learning rate 0.0001 dengan tingkat akurasi yang mencapai 98.40% dengan loss 0.0659. Pada pengujian juga mampu membuktikan bahwa nilai loss yang besar dapat disebabkan oleh learning rate yang terlalu tinggi.

D. Skenario IV: Batch Size

Dari hasil terbaik yang telah didapatkan pada pengujian sebelumnya yaitu optimizer SGD dengan learning rate 0.0001. Pada pengujian ini, selanjutnya sistem akan diuji

dengan batch size 8, 16, 32, dan 64 dengan menggunakan citra asli . Lalu hyperparameter lain yang ditetapkan selain optimizer dan learning rate yaitu input size 128x128. Input Size Train Accuracy Train Loss Test Accuracy Test Loss 128x128 99.00% 0.0296 97.20% 0.1135 224x224 63.80% 1.6459 63.80% 1.7233 227x227 40.10% 1.1713 41.20% 1.1354 250x250 72.10% 0.5721 72.20% 0.5526

TABEL 6
Hasil Pengujian Batch Size

Learning Rate	Train Accuracy	Train Loss	Test Accuracy	Test Loss
8	99.90%	0.0096	98.20%	0.0693
16	99.75%	0.0105	98.20%	0.0699
32	99.95%	0.0066	98.40%	0.0659
64	99.85%	0.0116	98.00%	0.0588


Berdasarkan hasil yang tertera pada tabel 6, diketahui bahwa hasil terbaik yang didapatkan pada pengujian yaitu *batch size* 32 dengan menggunakan *optimizer* sebelumnya yaitu SGD dan *learning rate* 0.0001 dengan tingkat akurasi sebesar 98.40% dengan *loss* 0.0659.

E. Hasil Pengujian Terbaik

TABEL 7
Hasil Pengujian Terbaik


Hyperparameter	Train Accuracy	Train Loss	Test Accuracy	Test Loss
Inout Size: 128x128	99.95%	0.0066	98.40%	0.0659
Optimizer: SGD				
Learning Rate: 0.0001				
Batch Size: 32				

Setelah melakukan pengujian dengan menggunakan empat skenario yaitu input size, optimizer, learning rate, dan batch size, maka dengan ini dapat disimpulkan hasil dan analisa dari pengujian terbaik. Hasil pengujian terbaik dapat dilihat pada Tabel 7. Pada pengujian tersebut diketahui tingkat akurasi terbaiknya, dimana nilai test accuracy terbaik dapat mencapai 98.40% dengan test loss 0.0659, lalu untuk training accuracy yang didapatkan sebesar 99.95% dengan loss 0.0066.



GAMBAR 9
Grafik Pengujian Terbaik

Kemudian kalau ditinjau dari grafik training loss dan validation loss pada gambar 9 bahwa data yang diuji memiliki grafik yang good fitting. Oleh karena itu, hyperparameter yang cocok pada penelitian ini agar dapat mendapatkan hasil terbaik yaitu dengan menggunakan input size 128x128, optimizer SGD, learning rate 0.0001, dan batch size 32. Selain itu, pada gambar 10 akan akan dilihat hasil dari confusion matrix yang menunjukkan bahwa secara keseluruhan kinerja model sudah sangat baik dalam mengklasifikasi data, walaupun masih ada sedikit kesalahan prediksi pada beberapa kelas. Hal ini ditandai dengan diagonal yang ada pada confusion matrix, apabila tingkat warna semakin terang maka prediksi yang dilakukan sistem bisa dikatakan tepat.



GAMBAR 10
Confusion Matrix Best Model

V. KESIMPULAN

Berdasarkan hasil pengujian dan simulasi yang telah dilakukan pada penelitian ini, dapat dikatakan bahwa pemanfaatan CNN untuk klasifikasi jenis beras berbasis citra digital dapat berjalan dengan baik untuk mengklasifikasi kelas dari jenis-jenis beras. Dari Hasil tersebut juga dapat diambil beberapa kesimpulan dari penelitian yang telah dilakukan, yakni sebagai berikut:

Perancangan model sistem yang telah dilakukan dapat bekerja secara optimal dalam mengklasifikasin jenis beras berdasarkan kelasnya masing-masing yaitu beras arborio, beras basmati, beras ipsala, beras jasmine, dan beras karacadag. Dengan berdasarkan empat skenario pengujian yang telah dilakukan, dimana hasil akurasi yang didapatkan rata-rata diatas 90% di hampir setiap skenario pengujian yang telah dilakukan. Pengklasifikasian jenis beras yang dibantu oleh sistem masih dilakukan dengan cara visual.

Dengan menggunakan arsitektur AlexNet pada penelitan ini mampu memperoleh hasil akurasi terbaik dengan menggunakan gabungan dari hyperparameter input size 128x128 piksel, optimizer SGD, learning rate 0.0001, dan batch size 32, dengan nilai test accuracy yang didapatkan mencapai 98.40% dan loss 0.0659.

Maka dari itu, performansi yang dimiliki oleh model sistem pada penelitian ini sangat baik dalam melakukan klasifikasi jenis beras arborio, basmati, ipasala, jasmine, dan karacadag yang menggunakan CNN dengan arsitektur AlexNet, sehingga pada untuk pengembangan penelitian yang akan dilakukan selanjutnya dapat dijadikan sebagai referensi awal.

REFERENSI

- [1] N. Afifah and N. Zakiyah, "Review Artikel: Indeks Glikemik Pada Berbagai Varietas Beras," *Farmaka*, vol. 18, no. 2, pp. 1–15, 2020.
- [2] S. Saidah, M. B. Adinegara, R. Magdalena, N. Kumalasari, C. Pratiwi, and F. T. Elektro, "Identifikasi Kualitas Beras Menggunakan Metode k-Nearest Neighbor dan Support Vector Machine Rice Quality Identification using k-Nearest Neighbor and Support Vector Machine Method," *Telka*, vol. 5, no. 2, pp. 114–121, 2019.
- [3] Gansar Suwanto, R. Ibnu Adam, and Garno, "Identifikasi Citra Digital Jenis Beras Menggunakan Metode Anfis dan Sobel," *J. Inform. Polinema*, vol. 7, no. 2, pp. 123–128, 2021, doi: 10.33795/jip.v7i2.406.
- [4] J. Jumi, U. T. Sulistyorini, and A. Azizah, "Identifikasi Jenis Beras Melalui Akurasi Kemiripan Fitur Bentuk Dan Warna," *Just TI (Jurnal Sains Terap. Teknol. Informasi)*, vol. 11, no. 1, p. 31, 2019, doi: 10.46964/justti.v11i1.128.
- [5] Badan Pusat Statistik Provinsi Jawa Tengah, "Luas Panen dan Produksi Padi di Indonesia 2021 (Angka Sementara)," *Ber. Resmi Stat.*, vol. 2021, no. 77, pp. 1–14, 2021.
- [6] K. Hori, K. Suzuki, K. Iijima, and K. Ebana, "Variation in cooking and eating quality traits in Japanese rice germplasm accessions," *Breed. Sci.*, vol. 66, no. 2, pp. 309–318, 2016, doi: 10.1270/jsbbs.66.309.
- [7] E. Wickert et al., "SCS123 Pérola: A Brazilian Rice Variety for Risotto," *Agric. Sci.*, vol. 09, no. 12, pp. 1589–1600, 2018, doi: 10.4236/as.2018.912111.
- [8] L. T. Pangesthi, D. Kristiastuti, and R. D. Soeyono, "Organoleptik Risotto Instan Sifat," vol. 10, no. 1, pp. 166–174, 2021.
- [9] P. Bhattacharjee, R. S. Singhal, and P. R. Kulkarni, "Basmati rice: A review," *Int. J. Food Sci. Technol.*, vol. 37, no. 1, pp. 1–12, 2002, doi: 10.1046/j.1365-2621.2002.00541.x.
- [10] E. Y. Purwani and I. P. Wardana, "Karakteristik Fisiko kimia Varietas Beras Khusus untuk Pangan Inovatif," *J. Penelit. Pertan. Tanam. Pangan*, vol. 2, no. 3, p. 165, 2019, doi: 10.21082/jpopt.v2n3.2018.p165-172.
- [11] M. Koklu, I. Cinar, and Y. S. Taspinar, "Classification of rice varieties with deep learning methods," *Comput. Electron. Agric.*, vol. 187, no. November 2020, p. 106285, 2021, doi: 10.1016/j.compag.2021.106285. [12] R. Nurfalah, Dwiza Riana, and Anton, "Identifikasi Citra Beras Menggunakan Algoritma Multi-SVM Dan Neural Network Pada Segmentasi K-Means," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 55–62, 2021, doi: 10.29207/resti.v5i1.2721.
- [13] S. Pitiphunpong, S. Champangern, and P. Suwannaporn, "The Jasmine rice (KDML 105 variety) adulteration detection using physico-chemical properties," *Chiang Mai J. Sci.*, vol. 38, no. 1, pp. 105–115, 2011.
- [14] A. L. P. Aydin, S. Yesilmen, A. Vural, and H. S. Guran, "Determination of some agronomical characteristics and Ochratoxin-A level of Karacadag rice (*Oryza sativa* L.) in Diyarbakir ecological conditions, Turkey," *African J. Agric. Res.*, vol. 5, no. 15, pp. 1965–1972, 2010.
- [15] "(Cattle Wiegth Estimation Based on Digital Image With Fractal," vol. 8, no. 2, pp. 1385–1393, 2021. [16] I. F. Interpretasi, "Citra Biner," 2019.
- [17] O. N. Shpakov and G. V. Bogomolov, "Technogenic activity of man and local sources of environmental pollution," *Stud. Environ. Sci.*, vol. 17, no. C, pp. 329–332, 1981, doi: 10.1016/S0166-1116(08)71924-1.
- [18] S. E. Limantoro, Y. Kristian, and D. D. Purwanto, "Pemanfaatan Deep Learning pada Video Dash Cam untuk Deteksi Pengendara Sepeda Motor," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 7, no. 2, 2018, doi: 10.22146/jnteti.v7i2.419.
- [19] F. U. Adah and S. Rizal, "Deteksi Parasit Plasmodium pada Citra Mikroskopis Hapusan Darah dengan Metode Deep Learning," vol. 9, no. 2, 2021.
- [20] Y. N. Fu'adah, N. C. Pratiwi, M. A. Pramudito, and N. Ibrahim, "Convolutional Neural Network (CNN) for Automatic Skin Cancer Classification System," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 982, no. 1, 2020, doi: 10.1088/1757-899X/982/1/012005.
- [21] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 3, no. 2, pp. 49–56, 2018.
- [22] P. Wulandari, "Klasifikasi Tingkat Keganasan Kanker Serviks Menggunakan Metode Deep Residual Network," p. 125, 2019. [23] N. Kumalasari, C. Pratiwi, and Y. Nur, "Early Detection of Deforestation through Satellite Land Geospatial Images based on CNN Architecture," vol. 13, no. 2, 2021