

IDENTIFIKASI CITRA DAUN SELADA DALAM MENENTUKAN KUALITAS TANAMAN MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN)

Muhammad Rahman^{1*}, Asriyanik², Agung Pambudi³

^{1,2,3} Universitas Muhammadiyah Sukabumi; Jl. R. Syamsudin, S.H. No. 50, Cikole, Kec. Cikole, Kota Sukabumi, Jawa Barat 43113; Telp. (0266) 218345

Riwayat artikel:

Received: 28 Juli 2023

Accepted: 20 Agustus 2023

Published: 11 September 2023

Keywords:

Hidroponik, *Crawling*, Selada, Klasifikasi Citra, Kualitas Tanaman Selada, *Convolutional Neural Network*

Correspondent Email:

rahmanmuh823@gmail.com

Abstrak. Indonesia dikenal sebagai negara agraris hal ini menjadikan sebagian penduduk bekerja pada sektor pertanian menurut Badan Pusat Statistik tahun 2022 sekitar 29,96% penduduk Indonesia bekerja pada sektor pertanian. Bertani pada saat ini bisa dilakukan dengan hidroponik yaitu bertanam dengan air yang tercampur nutrisi sebagai media tanamnya. Selada merupakan sayuran yang cocok ditanam secara hidroponik, selada memiliki kandungan gizi dan fungsi yang baik bagi tubuh dalam mencegah penyakit kolesterol tinggi, sembelit, dan *insomnia*. Walaupun bertanam secara hidroponik mudah dan praktis akan tetapi kendala dapat saja terjadi sehingga mempengaruhi kualitas tanaman yang disebabkan oleh faktor seperti lingkungan dan kurangnya pengetahuan akan kondisi tanaman selada sehingga memicu tanaman terserang penyakit. Dalam mengatasi hal tersebut dibuat sistem klasifikasi kualitas tanaman selada berdasarkan citra daun selada untuk mengetahui kondisi tanaman menggunakan algoritma *convolutional neural network* dengan merancang arsitektur model yang terbaik. Pada pembagian rasio *dataset* 80% *training*, 10% *validation*, 10% *testing*, dilakukan penambahan *dropout* setelah lapisan *pooling* kedua dan ketiga sebesar 0.2 dan *dropout* pada *fully connected layer* sebesar 0.3, *optimizer* Adam, nilai *learning rate* 0.0001, dengan *epoch* 50. Hasil akurasi terbaik pada proses pelatihan mencapai 90% dan hasil evaluasi menggunakan *confusion matrix* pada data *testing* mendapatkan akurasi terbaik mencapai 84%.

Abstract. Indonesia is known as an agricultural country, this makes a portion of the population work in the agricultural sector, according to the Central Bureau of Statistics in 2022 around 29.96% of Indonesia's population work in the agricultural sector. Farming at this time can be done with hydroponics, namely planting with water mixed with nutrients as a planting medium. Lettuce is a vegetable that is suitable for growing hydroponically. Lettuce contains nutrients and functions that are good for the body in preventing high cholesterol, constipation, and *insomnia*. Even though hydroponic farming is easy and practical, problems can occur that affect the quality of plants caused by factors such as the environment and lack of knowledge about the condition of lettuce plants, which triggers disease. In order to overcome this problem, a quality classification system for lettuce based on the image of lettuce leaves was created to determine the condition of the plants using a convolutional neural network algorithm by designing the best architectural model. In the distribution of the dataset ratio of 80% training, 10% validation, 10% testing, additional dropouts after the second and third pooling layers are 0.2 and the dropouts on the fully connected layer are 0.3, optimizer Adam, the learning rate is 0.0001, with an epoch of 50. The best accuracy results in the training process reach 90% and the evaluation results using the confusion matrix on data testing get the best accuracy reaching 84%.

1. PENDAHULUAN

Negara agraris merupakan salah satu sebutan bagi Indonesia dalam sisi geografis Indonesia terletak pada daerah tropis dengan anugrah sumber daya alam dan lahan pertanian yang melimpah hal ini menjadikan sektor pertanian sebagai sumber mata pencaharian bagi penduduk Indonesia. Menurut data BPS (Badan Pusat Statistik) per Februari 2022 sekitar 29,96 % dari 208,54 juta orang di Indonesia bekerja pada sektor pertanian [1]. Hortikultura merupakan salah satu subsektor pertanian yang memiliki kemudahan untuk dikembangkan oleh kelompok tani. Produk Domestik Bruto subsektor hortikultura menyumbang rata-rata 14% pertumbuhan pertanian nasional. Kenaikan ini menunjukkan produk hortikultura dapat diterima pasar dengan baik dan menarik dikembangkan oleh pihak swasta dan kelompok tani [2]. Dalam melakukan kegiatan pertanian saat ini tidak hanya dapat dilakukan di daerah pedesaan dan memiliki lahan yang luas, saat ini terdapat salah satu metode yang populer bernama hidroponik. Hidroponik adalah cara bertanam dengan menggunakan larutan mineral bernutrisi tanpa menggunakan tanah sebagai media tanamnya [3]. Metode ini melibatkan air yang tercampur nutrisi sebagai media utama tanamnya sehingga bertanam dengan metode ini lebih praktis, bersih dan mudah dilakukan tanpa memiliki lahan yang luas. Selada merupakan salah satu sayuran yang cocok ditanam dengan metode hidroponik selada mempunyai kandungan gizi dan fungsi yang baik bagi tubuh Berdasarkan USDA *National Nutrient Data Base* dalam setiap 100 gram selada mengandung energi sebanyak 15 kalori, 0.15 gram lemak, 1.36 gram protein, dan 2.87 gram karbohidrat kandungan tersebut memiliki fungsi yang baik bagi tubuh diantaranya membersihkan darah, dan lemak, baik untuk orang yang menderita batuk dan juga mencegah penyakit kolesterol tinggi, sembelit, dan *insomnia*. Dengan kegunaan dan kandungan tersebut menjadikan selada diminati bagi orang yang mengharapkan pola hidup yang sehat [4]. Walaupun bertanam selada dengan metode hidroponik memiliki kemudahan tidak sedikit kendala yang dialami sehingga menghasilkan tanaman yang kurang baik hal ini disebabkan oleh beberapa faktor seperti perawatan yang kurang tepat, suhu udara tinggi, dan tanaman yang kelebihan atau kekurangan nutrisi, selain

itu minimnya pengetahuan akan kondisi tanaman menjadikan tanaman berpotensi terserang penyakit sehingga berpengaruh terhadap kualitas tanaman.

Dalam menangani masalah tersebut, terdapat metode lain untuk mengidentifikasi kondisi tanaman selada dengan menerapkan sistem pakar dengan sistem pakar dipilih beberapa ciri dan gejala tanaman berdasarkan pilihan yang tersedia oleh sistem kemudian setelah semua informasi terkumpul, sistem akan menyimpulkan penyakit sesuai gejala yang telah dipilih [4], Dilihat dari keefektifan dan waktu pemrosesan sistem pakar memerlukan banyak waktu untuk memasukan beberapa informasi sehingga rentan dalam memasukan informasi yang salah. Maka dari itu, dibutuhkan sebuah teknologi untuk mengidentifikasi kualitas tanaman selada berdasarkan data dari citra daun yang dapat dilakukan dengan *Deep learning*. *Deep learning* adalah bidang ilmu dari *machine learning* yang berdasar dari jaringan syaraf tiruan [5]. *Convolutional Neural Network* atau ConvNet termasuk salah satu kelas *deep-feedforward artificial neural networks* yang diterapkan untuk mengolah data dalam bentuk dua dimensi dan hasil pengembangan dari MLP yang mampu mengolah citra digital dengan efisien secara komputasi. Selain itu CNN terinspirasi oleh proses biologi dengan pola konektivitas antar *neurons* yang berupaya menyerupai *visual cortex* hewan pada sistem pengenalan citra [6].

Terdapat penelitian sebelumnya yang menjadi acuan pada penelitian ini salah satunya oleh Tri Purwanto dengan judul “Sistem Pakar Mendiagnosa Hama Penyakit Tanaman Selada (*Lactuca Sativa L*) Hidroponik Menggunakan Metode *Forward Chaining* Dan *Certainty Factor*”. Metode yang digunakan *forward chaining* dan *certainty factor* untuk mendiagnosa penyakit pada tanaman selada hidroponik dengan hasil tingkat keyakinan tertinggi sebanyak 80% dan terendah 50% yang diimplementasikan berupa *website* [4]. Penelitian lainnya dilakukan oleh Reni Rahmadewi dengan judul “Identifikasi Jenis Tumbuhan Menggunakan Citra Daun Berbasis Jaringan Saraf Tiruan (*Artificial Neural Networks*)” penelitian ini mengidentifikasi jenis tumbuhan berdasarkan daun dengan menggunakan citra pada daun menggunakan metode jaringan syaraf tiruan *dataset* yang

digunakan sebanyak 16 sampel dari 4 jenis daun dalam pengujian maksimal 1000 epoch didapatkan hasil 93,75% keberhasilan mengidentifikasi dengan benar [7], penelitian lainnya yang dilakukan oleh Sarirotul Ilahiyah dengan judul “Implementasi *Deep Learning* Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan *Convolutional Neural Network*” penelitian ini melakukan klasifikasi jenis *genus* tumbuhan berdasarkan citra daun dengan menggunakan algoritma *Convolutional Neural Network* dengan hasil akurasi mencapai 90,8% [5], penelitian lainnya yang sejenis oleh Alang Mulya Lesmana dengan judul “Identifikasi Penyakit Pada Citra Daun Kentang Menggunakan *Convolutional Neural Network (CNN)*” penelitian ini mengidentifikasi penyakit pada tanaman kentang berdasarkan citra daun kentang dengan menggunakan CNN hasil akurasi tertinggi yang didapatkan untuk *training* mencapai 93% dan validasi 99% [8], penelitian lainnya yang dilakukan oleh Fachrie Reza Megantara dengan judul “Deteksi Kondisi Tanaman Selada Berdasarkan Citra Menggunakan Metode *Convolutional Neural Network (CNN)*” penelitian ini mendeteksi kondisi tanaman selada yang terdiri dari dua kelas baik dan tidak baik dengan menggunakan pembagian data latih sebesar 90% dan data uji 10% didapatkan akurasi mencapai 99,2% [9].

Berdasarkan penelitian terdahulu, penelitian ini dilakukan untuk membuat sistem klasifikasi kualitas tanaman selada berdasarkan citra daun yang terdiri lebih dari dua kelas. *Dataset* citra tanaman selada pada penelitian ini dikumpulkan dengan teknik *crawling image* dimana dilakukan penentuan label dari setiap citra berdasarkan pakar selada hidroponik. Fokus pada penelitian ini adalah melakukan identifikasi kualitas tanaman selada lebih dari dua label yang berbeda (*multiclass classification*) berdasarkan citra dari daun selada menggunakan algoritma *convolutional neural network* dengan melakukan uji coba scenario berdasarkan kombinasi parameter diantaranya penggunaan *dropout*, *optimizer*, serta nilai *learning rate* untuk mendapatkan hasil akurasi yang terbaik pada perancangan model algoritma *convolutional neural network*.

2. TINJAUAN PUSTAKA

2.1. Selada

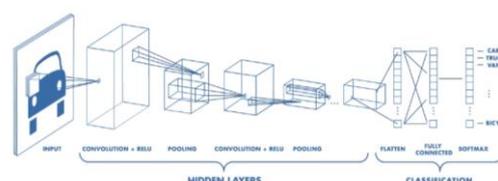
Selada (*Lactuca sativa L*) termasuk dalam famili *compositae* dari genus *Lactuca* Berdasarkan USDA *National Nutrient Database* dalam setiap 100 gram selada mengandung energi sebanyak 15 kalori, 0.15 gram lemak, 1.36 gram protein, dan 2.87 gram karbohidrat kandungan tersebut memiliki fungsi yang baik bagi tubuh diantaranya membersihkan darah, dan lemak, baik untuk orang yang menderita batuk dan juga mencegah penyakit kolesterol tinggi, sembelit, dan *insomnia* [4].

2.2. Citra Digital

Citra digital merupakan foto atau video yang dapat diolah komputer karena memiliki bentuk data numerik dimana merupakan larik (*array*) berisikan sekumpulan nilai *real* yang menunjukkan besar intensitas pada setiap *pixel* ataupun kompleks yang diwakili oleh susunan bit tertentu [10]. Citra digital direpresentasikan dengan sebuah matriks yang terdiri dari banyaknya kolom dan baris, yang mana perpotongan di antara keduanya merupakan elemen terkecil yang disebut *pixel (picture element)*

2.3. Convolutional Neural Network (CNN)

Convolutional Neural Network atau ConvNet termasuk salah satu kelas *deep-feedforward artificial neural networks* yang diterapkan untuk mengolah data dalam bentuk dua dimensi dan hasil pengembangan dari MLP (*Multi Layer Perceptron*) yang mampu mengolah citra digital dengan efisien secara komputasi. Selain itu CNN terinspirasi oleh proses biologi dengan pola konektivitas antar *neurons* yang berupaya menyerupai *visual cortex* hewan pada sistem pengenalan citra [6].



Gambar 1. Arsitektur CNN [11]

Secara umum *Convolutional Neural Network* terbagi dari dua lapisan (*layer*) yaitu adalah ekstraksi fitur dan klasifikasi. Pada

ekstraksi fitur terdiri dari berbagai lapisan dimana pada lapisan ini gambar pertama kali diterima setelah itu diproses dengan beberapa lapisan yang terdiri dari *convolutional layer* atau lapisan konvolusi, dan *pooling layer* atau lapisan *pooling* pada setiap lapisan konvolusi diberlakukan fungsi aktivasi *ReLU (Rectifier Linear Unit)* lalu menghasilkan keluaran vektor yang selanjutnya diproses pada lapisan berikutnya, kemudian pada lapisan kedua merupakan lapisan klasifikasi yang terdiri dari beberapa lapisan jaringan yang terhubung secara penuh (*fully connected*) atas setiap *neuron*. Setelah ekstraksi fitur berupa vektor yang dihasilkan pada lapisan pertama maka pada lapisan ini hasil keluaran pada lapisan pertama dijadikan *input* kemudian diubah dengan melakukan *flattening* supaya dapat diproses pada lapisan kedua dengan jaringan yang terhubung secara penuh yang terdiri dari beberapa lapisan *hidden layer* dengan hasil *output* akhir berupa hasil klasifikasi dan akurasi yang didapatkan.

3. METODE PENELITIAN

Tahapan penelitian pada penelitian ini menggunakan metode SEMMA. SEMMA merupakan sebuah metode yang mudah dimengerti dan digunakan sebagai acuan pada proyek *data mining* dimana proses model ini memiliki keunggulan yang lebih terpusat pada aspek pengembangan model sehingga menjadikan pembuatan model lebih terstruktur [12]. Metode ini terdiri yang terdiri dari 5 tahap yaitu *sample, explore, modify, model, dan assess*

3.1. Sample

Sample merupakan tahapan pertama dimana pada tahap ini melakukan sebuah proses dalam pengumpulan data dan informasi yang signifikan yang digunakan sebagai data utama dalam penelitian. *Dataset* yang digunakan pada penelitian ini merupakan data citra selada yang dikumpulkan dengan teknik *crawling*. *Crawling* adalah proses menjelajahi suatu *website* secara sistematis dan otomatis dengan tujuan untuk mengumpulkan data [13].

3.2. Explore

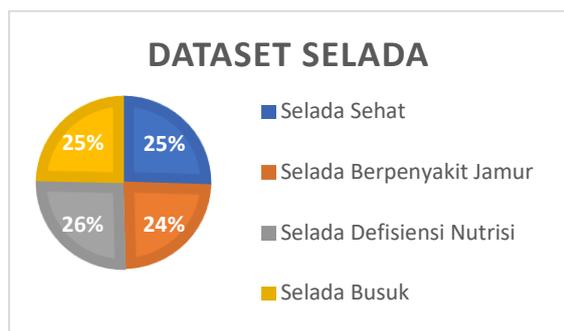
Explore merupakan sebuah proses eksplorasi data dalam mencari kumpulan data yang terkait dengan ide-ide yang dibangun

dimana pada tahapan ini bertujuan untuk menentukan variabel serta deskripsi dari variabel yang digunakan. *Dataset* yang terkumpul pada penelitian ini telah dilakukan pemilahan dan diberikan label sebagai variabel yang ditentukan berdasarkan hasil wawancara dengan pakar selada hidroponik.

Tabel 1. Deskripsi Data

Variabel	Definisi Operasional Variabel
Selada sehat (<i>healthy</i>)	Memiliki warna hijau sempurna dan segar, tidak berwarna kecoklatan dan kekuningan
Selada mengalami defisiensi nutrisi (<i>Min-nutrition</i>)	Adanya bercak-bercak hitam pada daun, ujung daun mati berwarna hitam seperti terbakar, dan sekitar daun berwarna kekuningan
Selada berpenyakit jamur (<i>Mildew</i>)	Permukaan daun yang berwarna kekuningan dan daun yang terserang penyakit ini memiliki bintik-bintik putih atau lapisan bulu tebal berwarna putih
Selada busuk (<i>Rot</i>)	Adanya kelayuan ditandai dengan dimulainya bagian batang tanaman berubah menjadi warna kecoklatan secara tidak teratur dengan bercak kebasahan kemudian menyebar pada bagian leher tanaman sehingga menjadi busuk dan mengeluarkan lendir

Datasset terkumpul sebanyak 361 terdiri dari selada sehat (*healthy*) sebanyak 92 data, selada berpenyakit jamur (*mildew*) sebanyak 87 data, selada defisiensi nutrisi (*min-nutrition*) sebanyak 93 data, dan selada busuk (*rot*) sebanyak 89 data. Penyajian data ditampilkan pada gambar berikut:



Gambar 2. Dataset

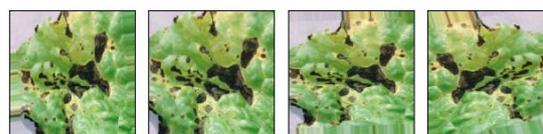
3.3. Modify

Modify merupakan sebuah proses untuk memodifikasi data, pada penelitian ini dilakukan modifikasi data berupa *cropping* gambar untuk memfokuskan gambar terhadap ciri yang dimiliki dan dilakukan kompresi dimensi data gambar menjadi ukuran 256 x 256 pixel. Pembagian rasio *dataset* dilakukan pada tahap ini dengan membagi rasio data yang akan diujicobakan sebagai berikut:

Tabel 2. Rasio Pembagian Dataset

<i>train</i>	<i>validation</i>	<i>testing</i>
80%	10%	10%
70%	15%	15%
60%	20%	20%

Selain itu sebelum dilakukan pemodelan data, pada tahap ini dilakukan *preprocessing image* dan augmentasi. *Preprocessing image* dilakukan untuk normalisasi gambar dengan menggunakan *library* keras yaitu *rescale* yang digunakan untuk mengubah citra dari [0, 255] menjadi [0,1] proses ini dapat mengurangi *loss* dan meningkatkan akurasi pada proses pelatihan data, sementara itu pada augmentasi digunakan *library* dari keras yaitu *ImageDataGenerator* yang bekerja dengan meningkatkan jumlah data dengan cara memodifikasi data sehingga model mengenali data tersebut sebagai data yang berbeda sehingga cocok apabila *dataset* yang digunakan berjumlah sedikit, penggunaan augmentasi bertujuan untuk meningkatkan kinerja model mencegah *overfitting* dan *underfitting*.



Gambar 3. Augmentasi Gambar

3.4. Model

Pada tahap ini dilakukan pemodelan data untuk melakukan klasifikasi citra dengan menggunakan arsitektur model *cnn* dengan *convolution layer* terdiri dari tiga *filter* (32,64,64) *kernel size* berukuran (3,3), *stride* 1, *padding default* bernilai *valid*, aktivasi yang digunakan pada *convolution layer* adalah *relu*, *pooling layer* menggunakan *maxpooling layer* berukuran (3,3) dan pada *fully connected layer* terdiri dari *dense* 64 dan *output* berjumlah 4 dengan menggunakan fungsi aktivasi *softmax*, serta penambahan *dropout* yang digunakan setelah *pooling layer* dan pada *fully connected layer*. Adapun skenario yang akan diujicobakan untuk meningkatkan akurasi model adalah dengan melakukan perbandingan untuk mencari parameter terbaik dengan arsitektur model *convolution layer* dengan *filter* (32,64,64), *fully connected layer* dengan *dense* (64). Penggunaan *dropout* setelah *pooling layer* dan pada *fully connected layer*, penentuan *optimizer* serta nilai *learning rate* yang digunakan berdasarkan tabel berikut:

Tabel 3. Uji Coba Skenario

Skenario	Dropout	Dropout	Optimizer	Learning rate
	setelah pooling layer	pada fully connected layer		
1	-	-	Adam, RMSprop	0.001
2	0.15, 0.2	0.25	Adam, RMSprop	0.001
3	0.2, 0.2	0.3	Adam, RMSprop	0.0001

3.5. Asses

Asses merupakan evaluasi data dimana merupakan tahapan akhir yang digunakan untuk menilai seberapa baik kinerja model yang telah dibangun, pada tahap ini dilakukan pengujian data baru dengan melakukan evaluasi berupa *accuracy*, *precision*, *recall*, serta *F1-score*. *Accuracy* adalah skala perbandingan antara

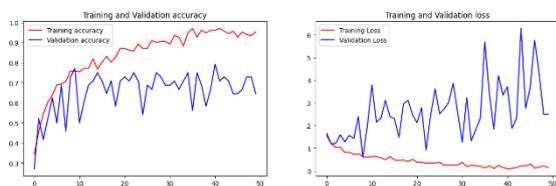
prediksi yang benar (positif dan negatif) dengan keseluruhan data, *precision* adalah skala perbandingan prediksi yang benar positif dengan data seluruh hasil prediksi positif, *recall* adalah perbandingan skala prediksi benar positif dengan seluruh data yang benar positif, sedangkan *F1-score* adalah rata-rata *precision* dibandingkan *recall*.

4. HASIL DAN PEMBAHASAN

Pengujian pada penelitian ini menggunakan tiga skenario yang telah diusulkan dalam menentukan kombinasi parameter terbaik untuk meningkatkan akurasi pada rancangan model *convolutional neural network*

4.1. Skenario pertama

Pada skenario pertama dilakukan pelatihan model dengan arsitektur model *convolution layer* terdiri dari tiga *filter* berurutan (32,64,64), *fully connected layer* dengan *dense* (64), *optimizer* Adam dan RMSprop, nilai *learning rate* sebesar 0.001, dengan 50 *epoch*. Hasil akurasi terbaik yang didapatkan adalah sebagai berikut:

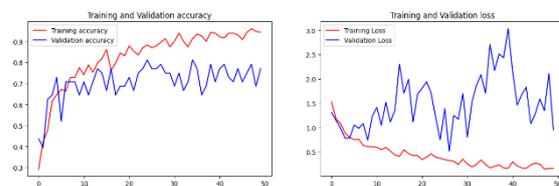


Gambar 4. Hasil akurasi dan *loss* skenario pertama

Pada gambar diatas hasil akurasi terbaik yang didapatkan di dapat pada model dengan pembagian rasio *dataset* 60% *training*, 20% *validation*, dan 20% *testing* dengan menggunakan *optimizer* RMSprop dengan nilai *learning rate* 0.001. Hasil *training accuracy* mencapai 94% dan *validation accuracy* 64% dan *training loss* mencapai 14% dan *validation loss* 250%. Pada skenario ini model memiliki hasil yang kurang baik pada kurva tersebut *training accuracy* semakin lama menjauh dengan *validation accuracy* dan *validation loss* memiliki hasil yang tidak stabil yang semakin menjauh dengan *training loss* pada proses ini pelatihan model dikatakan mengalami *overfitting*.

4.2. Skenario kedua

Pada skenario kedua dilakukan pelatihan model dengan arsitektur model *convolution layer* terdiri dari tiga *filter* berurutan (32,64,64), *fully connected layer* dengan *dense* (64), *optimizer* Adam dan RMSprop, nilai *learning rate* sebesar 0.001, jumlah *epoch* 50, serta digunakan *dropout* setelah *pooling layer* pada lapisan kedua dan ketiga sebesar 0.15 dan 0.2 dan *dropout* pada *fully connected layer* sebesar 0.25. Hasil akurasi terbaik yang didapatkan adalah sebagai berikut:

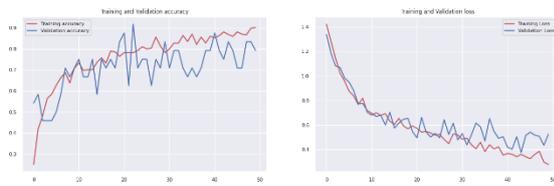


Gambar 5. Hasil akurasi dan *loss* skenario kedua

Pada gambar diatas hasil akurasi terbaik yang didapatkan terdapat pada model dengan pembagian rasio *dataset* 60% *training*, 20% *validation*, dan 20% *testing* dengan menggunakan *optimizer* Adam. Hasil *training accuracy* mencapai 94% dan *validation accuracy* mencapai 77% dan *training loss* mencapai 15% dan *validation loss* 95%. Dibandingkan dengan skenario pertama pada skenario ini *validation accuracy* meningkat dan pada *validation loss* memiliki hasil yang tidak begitu stabil tetapi mengalami penurunan dengan hasil akhir mencapai 95%. Walaupun begitu model masih mengalami *overfitting*.

4.3. Skenario ketiga

Pada skenario ketiga dilakukan pelatihan model dengan arsitektur model *convolution layer* terdiri dari tiga *filter* berurutan (32,64,64), *fully connected layer* dengan *dense* (64), *optimizer* Adam dan RMSprop, nilai *learning rate* sebesar 0.01, *epoch* 50, serta digunakan *dropout* setelah *pooling layer* pada lapisan kedua dan ketiga sebesar 0.2 dan 0.2 dan *dropout* pada *fully connected layer* sebesar 0.3. Hasil akurasi terbaik yang didapatkan adalah sebagai berikut:



Gambar 6. Hasil akurasi dan *loss* skenario ketiga

Pada gambar diatas hasil akurasi terbaik yang didapatkan terdapat pada model dengan pembagian rasio *dataset* 80% *training*, 10% *validation*, dan 10% *testing* dengan *optimizer* Adam hasil *training accuracy* di dapat mencapai 90% dan *validation accuracy* mencapai 79%, *training loss* mencapai 27% dan *validation loss* mencapai 52%, pada skenario ketiga model sudah memiliki akurasi yang baik dan *loss* yang stabil, pada kurva tersebut perbandingan jarak antara *training* dan *validation* baik itu pada *accuracy* dan *loss* tidak saling berjauhan sehingga model dikatakan *goodfitting*.

4.4. Analisis Hasil

Berdasarkan uji coba skenario pertama, kedua, dan ketiga terdapat perbedaan yang signifikan antara ketiganya. Pada uji coba model pertama dan kedua keduanya mempunyai *training accuracy* yang baik tetapi dalam pelatihan model mengalami *overfitting*, dan pada skenario ketiga proses pelatihan model *training* dan *validation* baik itu pada *accuracy* dan *loss* memiliki hasil yang stabil sehingga pada skenario ketiga ini model cukup baik dan dikatakan *goodfitting*. Dan untuk mengetahui evaluasi model dilakukan pengujian data baru yang mana hal ini adalah data *testing*. Evaluasi pada data *testing* menggunakan *library* dari *sklearn.metrics* yaitu *confusion matrix* evaluasi berupa *accuracy* (*Acc*), *precision*, *recall*, dan *F1-score* Adapun detail dari hasil yang didapatkan pada seluruh skenario sebagai berikut:

Tabel 4. Hasil evaluasi skenario pertama, kedua, dan ketiga

Rasio (train:val :test)	optimizer	Skena rio	Test Macro Avg			
			Precs ion	Rec all	F1 Sco re	A cc
80% 10% 10%	Adam	1	81	79	80	79
		2	80	77	76	76
		3	84	84	84	84
		1	75	74	72	74

70 % 15% 15%	RMSp	2	74	74	73	74
	rop	3	76	77	75	76
	Adam	1	73	71	72	71
60% 20% 20%	rop	2	78	77	77	77
	RMSp	3	81	75	74	75
	rop	1	75	71	71	71
	rop	2	69	70	69	70
	RMS	3	79	77	76	77
	rop	1	74	73	73	73
	RMS	2	80	80	79	80
	rop	3	78	77	77	77
	RMSp	1	78	78	78	78
	rop	2	77	72	70	72
	rop	3	79	79	79	78

Pada tabel diatas hasil akurasi terbaik yang didapatkan pada data *testing* adalah model yang dirancang dengan uji coba skenario ketiga, dihasilkan akurasi mencapai 84%.

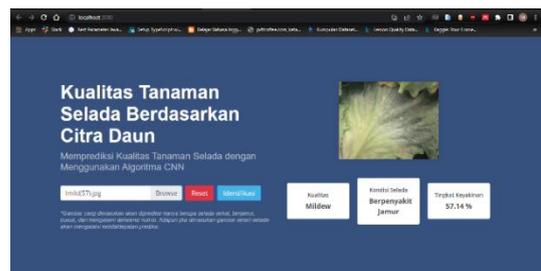
4.5. Simulasi Penggunaan Model CNN

Simulasi penggunaan model *convolutional neural network* merupakan bagian dari proses evaluasi. Model yang dipilih merupakan model yang mempunyai akurasi terbaik. Adapun proses simulasi ini diimplementasikan pada sebuah *website* yang terdiri dari satu halaman untuk memasukan data *testing* berupa gambar selada.



Gambar 7. Tampilan *website*

Gambar yang dimasukan akan dilakukan pemrosesan oleh model untuk mengidentifikasi gambar sesuai kelas kualitas tanaman selada yang telah ditentukan. Berikut tampilan dari hasil identifikasi yang telah dilakukan



Gambar 8. Tampilan hasil identifikasi selada berpenyakit jamur

5. KESIMPULAN

1. Rancangan model *Convolutional Neural Network* (CNN) terbaik didapatkan pada pembagian rasio *dataset* 80% *training*, 10% *validation*, dan 10% *testing* dengan arsitektur model *convolution layer* yang mempunyai *filter* berurutan (32,64,64), *fully connected layer* dengan *dense* (64) yang ditambahkan penggunaan *dropout* pada *pooling layer* sebesar 0.2 pada lapisan kedua dan ketiga dan *dropout* pada *fully connected layer* 0.3, menggunakan *optimizer* Adam dengan nilai *learning rate* sebesar 0.0001. Menghasilkan akurasi pada model mencapai 90% pada *training* dan 79% pada *validation*, dan nilai *loss* pada *training* mencapai 27% dan 52% pada *validation*, dan data *testing* atau data baru sebanyak 38 untuk diujikan ke dalam model yang terbaik. Hasil akurasi yang didapatkan untuk data *testing* dalam mengidentifikasi kualitas tanaman selada mencapai 84%.
2. Saran bagi penelitian selanjutnya, Menggunakan *dataset* yang lebih banyak dari citra daun selada dan jumlah kelas dari kualitas tanaman selada.

UCAPAN TERIMA KASIH

Terimakasih saya ucapkan kepada orang tua saya yang selalu memberikan semangat dan do'a, dan kepada dosen pembimbing saya Ibu Asriyanik, M.T., Bapak Agung Pambudi S.Kom., M.Cs., dan semua pihak yang telah membantu kami dalam mengerjakan jurnal penelitian ini hingga selesai.

DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, "Berita Resmi Statistik No.36/05/Th. Xxv, 09 Mei 2022," No. 34, 2022.
- [2] Direktorat Jenderal Hortikultura, "Revisi I Rencana Strategis Direktorat Jenderal Hortikultura Tahun 2020-2024," 2020.
- [3] J. Linda, M. N. S. Qamaria, A. F. Hafid, H. B. Samsuddin, And A. Rahim, "Hidroponik Sebagai Sarana Pemanfaatan Lahan Kosong Di Kantor Lurah Salo, Watang Sawitto, Pinrang," *J. Lepa-Lepa Open*, Vol. 1, No. 3, Pp. 503–510, 2021.
- [4] T. Purwanto, W. Edi, And F. Sifa, "Sistem Pakar Mendiagnosa Hama Penyakit Tanaman Selada (*Lactuca Sativa* L) Hidroponik Menggunakan Metode Forward Chaining Dan Certainty Factor Tri," *Ilm. Inform.*, Vol. 14, No. 1, Pp. 1–12, 2021.
- [5] 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.
- [6] Suyanto, *Machine Learning Tingkat Dasar Dan Lanjut*. Bandung: Informatika Bandung, 2018.
- [7] R. Rahmadewi, E. Purwanti, And V. Efelina, "Identifikasi Jenis Tumbuhan Menggunakan Citra Daun Berbasis Jaringan Saraf Tiruan (Artificial Neural Networks)," *J. Media Elektro*, Vol. VII, No. 2, Pp. 38–43, 2018, Doi: 10.35508/Jme.V0i0.427.
- [8] A. M. Lesmana, R. P. Fadhillah, And C. Rozikin, "Identifikasi Penyakit Pada Citra Daun Kentang Menggunakan Convolutional Neural Network (Cnn)," *J. Sains Dan Inform.*, Vol. 8, No. 1, Pp. 21–30, 2022, Doi: 10.34128/Jsi.V8i1.377.
- [9] F. R. Megantara, Y. Purwanto, And C. Setianingsih, "Deteksi Kondisi Tanaman Selada Berdasarkan Citra Menggunakan Metode Convolutional Neural Network (Cnn) Lettuce Plant Condition Detection Based On Image Using Convolutional Neural Network (Cnn) Method," Vol. 7, No. 3, Pp. 9330–9338, 2020.
- [10] N. Z. Munantri, H. Sofyan, And M. Y. Florestiyanto, "Aplikasi Pengolahan Citra Digital Untuk Identifikasi Umur Pohon," *Telematika*, Vol. 16, No. 2, P. 97, 2020, Doi: 10.31315/Telematika.V16i2.3183.
- [11] F. Angga Irawan, M. Sudarma, And D. Care Khrisne, "Rancang Bangun Aplikasi dentifikasi Penyakit Tanaman Pepaya California Berbasis Android Menggunakan Metode Cnn Model Arsitektur SqueezeNet," *Spektrum*, Vol. 8, No. 2, Pp. 18–26, 2021, [Online]. Available: <https://ojs.unud.ac.id/index.php/spektrum/article/view/75393>
- [12] Y. A. Suwitono And F. J. Kaunang, "Implementasi Algoritma Convolutional Neural Network (Cnn) Untuk Klasifikasi Daun Dengan Metode Data Mining Semma Menggunakan Keras," Vol. 6, No. 2, Pp. 109–121, 2022.
- [13] R. Yuni, S. Si, And M. Kom, "Aplikasi Pengolahan Citra Untuk Deteksi Tingkat Kematangan Pada Buah Kelengkeng Dengan Metode Perbandingan Kadar Warna," *Jstie (Jurnal Sarj. Tek. Inform.)*, Vol. 6, No. 1, Pp. 64–72, 2020.