

# Implementasi *Convolutional Neural Networks* (CNN) Untuk Klasifikasi Citra Benih Kacang Hijau Berkualitas

Oleh: Indah Retno Sari  
Univeristas Muhammadiyah Semarang

---

Article history	Abstract
Submission :	Indonesia is an agricultural country where the majority of the population works as farmers. One of the agricultural commodity exports that contribute to Indonesia's economic growth is green beans. Besides having many benefits, green beans also have many enthusiasts who require farmers to guarantee the availability of green beans in terms of quantity and quality. Classification, which is usually carried out based on direct observation by the human senses, has various weaknesses that can result in the classification process being not optimal. This weakness can be overcome by utilizing technology in the form of digital images so that the classification process can be carried out easily and optimally. An effective method that can be used is the Convolution Netural Network (CNN) with the advantage of being able to carry out an independent learning process in object recognition, object extraction or classification. Testing with a sample of 200 mung bean seed images resulted in an accuracy rate of 100% training data and 90% testing data, so it can be concluded that the CNN method can identify the feasibility of mung bean seeds well.
Revised :	
Accepted :	
<b>Keyword:</b> <i>Convolution Netural Network</i> (CNN), green beans, classification, seed quality.	

---

## PENDAHULUAN

Indonesia merupakan Negara agraris dengan sebagian besar penduduknya bermata pencaharian sebagai seorang petani. Dalam bidang pertanian dapat dihasilkan berbagai jenis bahan pangan seperti beras, holtikultura, sayuran, buah-buahan dan lain sebagainya yang dapat dimanfaatkan dalam kegiatan ekspor dan impor. Jika komoditi dalam kegiatan ekspor Indonesia semakin beragam maka dapat membantu dalam kemajuan perdagangan internasional Indonesia dan dapat meningkatkan devisa Negara.

Kementerian Pertanian (Kementan, 2020) mencatat bahwa ekspor komoditas pada tanaman pangan dari hasil pertanian mengalami kenaikan yang cukup tinggi. Berdasarkan catatan kementerian pertanian data yang dirilis oleh Badan Pusat Statistik (BPS) pada 24 Juni 2019, nilai ekspor pertanian mengalami kenaikan sebanyak 25,19% dibandingkan tahun lalu (*year on year*) atau senilai US\$ 0,32 miliar, kenaikan nilai ekspor pertanian ini merupakan salah satu variabel penting yang menyebabkan

kenaikan ekspor nasional. Salah satu ekspor komoditas tanaman pangan yang mengalami kenaikan sepanjang tahun 2019 adalah kacang hijau yang kini banyak diminati oleh beberapa Negara. Berdasarkan (databoks. 2019) data ekspor komoditas tanaman pangan pada tahun 2014 sampai dengan Juni 2019 diatas, tanaman pangan kacang hijau mampu menduduki peringkat kedua dengan nilai ekspor sebesar 173,3 ton atau sekitar 19,82% setelah ekspor jagung yang menjadi komoditas tanaman pangan terbesar yaitu sebesar 562,6 ton atau 63,34%. Hal tersebut membuktikan bahwa kacang hijau merupakan tanaman pangan yang banyak diminati oleh berbagai Negara. Hal tersebut menjadi sebuah peluang sekaligus menjadi tantangan untuk berinovasi dalam menghasilkan kacang hijau yang berkualitas dan sesuai dengan kebutuhan pasar.

Kacang Hijau memiliki banyak kandungan gizi dan vitamin yang bermanfaat untuk manusia. Selain itu kacang hijau juga dapat menyembuhkan beberapa penyakit seperti tekanan darah tinggi, muntaber, melancarkan pencernaan dan masih banyak lagi. Menurut

data dari BPS dalam (Kementrian Pertanian Badan Litbang Pertanian, 2020) disebutkan terdapat empat provinsi di Indonesia yang memiliki luas panen kacang hijau yang cukup besar di antaranya adalah provinsi Jawa Tengah, Jawa Timur, Sulawesi Selatan, dan Nusa Tenggara Barat (NTB). Varietas tanaman kacang hijau yang di budidayakan petani Indonesia cukup beragam, salah satu kacang hijau yang memiliki kualitas ekspor adalah varietas vima 5. Kacang hijau varietas vima 5 memiliki kriteria warna biji hijau kusam dan banyak diminati dalam pasar ekspor. Produktivitas vima 5 dapat mencapai 2,34 ton per hektar, hal tersebut dapat menjadikan pendapatan petani akan meningkat apabila membudidayakan kacang hijau dengan varietas vima 5.

Banyaknya permintaan kacang hijau di Indonesia dan di berbagai Negara lain mengharuskan terjaminnya ketersediaan kacang hijau dari segi kuantitas maupun kualitas. Terdapat banyak faktor yang mempengaruhi kualitas biji kacang hijau, salah satu cara yang dapat dilakukan adalah dengan cara menyeleksi biji kacang hijau. Hal tersebut cukup penting untuk dilakukan karena bibit kacang hijau yang baik akan menghasilkan tanaman yang baik dan hasil panen yang juga baik.

Proses pemilihan benih kacang hijau yang berkualitas umumnya hanya dilakukan secara manual oleh petani secara langsung dengan melibatkan indera penglihatan manusia sebagai pengambil keputusan. Namun proses tersebut banyak memakan waktu dan keterbatasan visual manusia yang membuat perbedaan persepsi pengamatan terhadap kualitas benih kacang hijau sehingga pemilihan benih kacang hijau yang berkualitas kurang maksimal untuk itu perlu adanya suatu sistem yang mampu menyelaraskan perbedaan pandangan serta mampu memberikan sebuah keputusan dan pemilihan secara otomatis dalam mengenai kualitas benih kacang hijau layak atau tidaknya untuk digunakan. Sistem yang dibangun diharapkan dapat menjadi solusi untuk mengenali kelayakan dalam pemilihan benih kacang hijau berkualitas tanpa merusak sampel (objek).

Beberapa penelitian mengenai *Convolutional Neural Network* (CNN) yang telah dilakukan, seperti penelitian yang dilakukan oleh Nurhikmat (2018) menggunakan *Convolutional Neural Network* pada citra wayang golek dihasilkan klasifikasi yang

optimal dengan akurasi 93%. Penelitian mengenai kelayakan buah tomat dengan menggunakan metode *Convolutional Neural Networks* yang dilakukan oleh Shafira (2018) menunjukkan tingkat akurasi sebesar 90% yang dinilai telah mampu melakukan identifikasi kelayakan buah tomat. Selain itu penelitian yang dilakukan oleh Al Rivian *et al* (2020) yang meneliti tentang klasifikasi jenis kacang-kacangan berdasarkan tekstur menggunakan jaringan syaraf tiruan dihasilkan nilai akurasi sebesar 99,8%, precision 99,6% dan recall sebesar 99,8%. Penelitian oleh Wulandari *et al* (2020) tentang klasifikasi citra digital bumbu dan rempah dengan algoritma *convolutional neural network* (CNN) dihasilkan akurasi sebesar 88.89%.

Mengingat pentingnya pertumbuhan ekonomi dan meningkatnya permintaan ekspor kacang hijau maka perlu dilakukan proses klasifikasi untuk menghasilkan benih kacang hijau yang berkualitas. Berdasarkan penelitian terdahulu belum ada yang melakukan penelitian secara spesifik mengenai klasifikasi benih kacang hijau berkualitas dengan metode CNN, oleh karena itu, *Convolutional Neural Network* digunakan dalam penelitian ini guna untuk mengenali dan mengklasifikasikan benih kacang hijau dengan menghasilkan benih yang berkualitas serta tanaman kacang hijau yang baik.

## LANDASAN TEORI

### Kacang Hijau

Kacang hijau (*Vigna radiate* L.) merupakan tanaman kacang-kacangan yang banyak ditanam oleh petani di Indonesia. Kacang hijau merupakan tanaman palawija yang memiliki banyak varietas dan merupakan salah satu komoditi yang penting karena menghasilkan bahan pangan (Leatemia *et al*, 2011 dalam Rahmat, 2018).

### Citra (*Image*)

Citra (*image*) merupakan suatu gambar pada bidang dua dimensi yang tersusun dengan banyak piksel dari bagian terkecil citra. Pada umumnya, citra gambar terbentuk dari beberapa kotak persegi empat yang teratur sehingga jarak horizontal dan vertical antar piksel sama pada seluruh bagian citra (Idya *et al*, 2010 dalam Dewi, 2018). Pengolahan citra dengan menggunakan komputer dapat dilakukan dengan mempresentasikan suatu citra (kontinu) secara numerik dengan nilai diskrit yang dapat disebut dengan digitalisasi atau citra digital.

Citra digital mempunyai berbagai ukuran yang disebut *pixel*.

Citra atau gambar biasanya juga direpresentasikan dengan matriks yang berukuran N baris dan M kolom. Elemen-elemen matriks pada citra digital yang berukuran N x M maka mempunyai NM buah pixel. Representasi dari citra atau gambar dalam bentuk matriks dapat dilihat pada persamaan berikut (Yusuf, 2017 dalam Putri, 2020):

$$f = \begin{bmatrix} f(1,1) & f(1,2) & \dots & f(1,N) \\ f(2,1) & f(2,2) & \dots & f(2,N) \\ \vdots & \vdots & \ddots & \vdots \\ f(M,1) & f(M,2) & \dots & f(M,N) \end{bmatrix} \quad (1)$$


Keterangan:

M = Banyaknya kolom pada *array* citra

N = Banyaknya baris pada *array* citra

### Convolutional Neural Networks

Convolutional Neural Network (CNN) merupakan salah satu algoritma dari *deep learning* dan merupakan pengembangan dari Multilayer Perceptron (MLP) yang dirancang dan dapat digunakan untuk mengolah data terstruktur atau grid dalam bentuk dua dimensi/2D, misalnya gambar atau suara (Ilahiyah dan Nilogiri, 2018). CNN juga merupakan operasi konvolusi yang terdiri dari beberapa tahap atau lapisan pemrosesan yang terinspirasi dari sistem syaraf biologis (Hu, *et al*, 2015). Menurut (Wulandari *et al*, 2020) CNN juga digunakan sebagai klasifikasi data yang berlabel dengan menggunakan metode *supervised learning* yaitu terdapat data yang dilatih dan terdapat variabel yang ditargetkan sehingga tujuan dari ini yaitu untuk mengelompokkan suatu data ke dalam data yang sudah ada. Tahapan jaringan arsitektur CNN dapat dilihat pada gambar berikut ini:



**Gambar 1. Arsitektur CNN**

Struktur CNN terdiri dari beberapa lapisan tersembunyi (*hidden layer*) yaitu berupa lapisan konvolusi, fungsi aktivasi (ReLU), dan *pooling*. Metode CNN bekerja secara hirarki, sehingga output pada lapisan konvolusi pertama akan digunakan sebagai input pada proses konvolusi berikutnya. Sedangkan pada proses klasifikasi terdiri dari *fully-connected* dan

fungsi aktivasi (*softmax*) yang outpunya berupa hasil klasifikasi (katole *et al*, 2015 dalam Arrofiqoh dan Harintaka, 2018).

### Konvolusi

Proses konvolusi merupakan operasi aljabar linier yang menghasilkan matriks dari filter pada citra yang akan di proses. Proses tersebut dinamakan dengan lapisan konvolusi (*convolutional layer*) yang merupakan lapisan utama dan yang terpenting dalam satu jaringan. *Filter* yang terdapat pada *Convolutional Layer* memiliki panjang, tinggi dan tebal sesuai dengan volume data masukan. Konvolusi juga diartikan sebagai proses yang dilakukan untuk memperoleh suatu piksel yang di dasarnya pada nilai piksel itu sendiri dan tetangganya dengan melibatkan suatu matriks yang disebut sebagai kernel serta mempresentasikan pembobotan (Kusumanto at al, 2011 dalam Ilahiyah dan Nilogiri, 2018).

Sebagai alternatif, operasi konvolusi juga dapat dilihat sebagai perkalian matriks antara citra masukan dan kernel dimana keluarannya dihitung dengan *dot product*. kemudian selain itu, penentuan volume *output* juga dapat ditentukan dari masing-masing lapisan yaitu dengan menggunakan *hyperparameters*. *Hyperparameter* yang digunakan pada persamaan di bawah ini digunakan untuk menghitung seberapa banyaknya neuron aktivasi yang dihasilkan dalam sekali *output*. Persamaan menurut (Nurhikmat, 2018) tersebut adalah sebagai berikut:

$$(W - F + 2P)/(S + 1) \quad (2)$$

Keterangan :

W = Ukuran volume gambar

F = Ukuran Filter/ kernel


P = Nilai *Padding* yang digunakan (0)

S = Ukuran Pergeseran (*Stride*)


Lapisan konvolusi secara signifikan mengalami kompleksitas model melalui optimalisasi outputnya. Hal ini dapat dioptimalkan melalui parameter yaitu *stride* merupakan sebuah parameter yang digunakan dalam menentukan berapa jumlah pergeseran filter melalui *input* citra dan *Zero Padding* yang merupakan suatu parameter yang digunakan dalam menentukan jumlah piksel (berisi nilai nol) yang akan ditambahkan di setiap sisi dari proses input.

Proses konvolusi pada suatu gambar dengan ukuran 5x5 yang ditandai dengan warna

hijau (citra yang akan dikonvolusi) serta ukuran kernel 3x3 yang ditandai dengan warna kuning dan *stride* 1 (kernel yang bergerak dari sudut kiri atas sampai kanan bawah) sehingga hasil dari proses konvolusi dapat dilihat pada gambar disebelah kanannya (pink). Ilustrasi proses konvolusi dapat dilihat pada gambar berikut ini:



**Gambar 2. Ilustrasi Image 5x5 Pixel dan Kernel 3x3**




**Gambar 3. Ilustrasi Proses Konvolusi**

### Pooling Layer

*Pooling layer* merupakan suatu lapisan fungsi dengan *feature map* sebagai input dan mengolahnya dengan berbagai macam operasi statistik dengan berdasarkan nilai piksel terdekat (Ilahiyah dan Nilogiri, 2018), *pooling layer* juga dapat digunakan untuk mengambil nilai rata-rata (*average pooling*) dan nilai maksimal (*max-pooling*) yang diperoleh dari bagian piksel pada sebuah citra. Lapisan *pooling* pada arsitektur model CNN yang dimasukkan antara lapisan konvolusi secara berturut-turut dapat secara progresif mengurangi ukuran volume *output* pada *feature map*, sehingga jumlah parameter dan perhitungan pada jaringan akan berkurang, serta dapat digunakan untuk mengendalikan *overfitting* (Nurhikmat, 2018).

Berikut ini merupakan contoh gambar pada operasi max pooling 2x2 dengan *stride* dua, maka di setiap pergeseran filter nilai maximum pada area 2x2 pixel tersebut yang akan terpilih, sedangkan *average pooling* akan memilih nilai rata-ratanya (Peryanto *et al*, 2019).



**Gambar 4. Proses Max Pooling**

Dari proses *max pooling* pada gambar diatas lapisan *pooling* akan beroperasi disetiap lapisan irisan kedalam volume input secara bergantian. Pada gambar diatas proses *max pooling* dari ukuran input 4x4 pada masing-masing 4 angka pada input operasi tersebut diambil nilai maksimalnya dan dilanjutkan dengan membuat ukuran output baru menjadi ukuran 2x2. Pada kotak yang berwarna merah, hijau, kuning dan biru pada sisi kiri merupakan kelompok kotak yang akan dipilih nilai maksimalnya. Sehingga hasil dari proses tersebut dapat dilihat pada kotak di sebelah kanannya. Output dari proses *pooling* adalah matriks dengan dimensi yang berukuran lebih kecil dibandingkan dengan matrik awal.

### Fully Connected Layer

*Fully-Connected Layer* merupakan sebuah lapisan dimana semua neuron aktivasi pada lapisan sebelumnya terhubung dengan neuron di lapisan selanjutnya sama seperti halnya dengan jaringan syaraf / *neural network* biasa. Setiap aktivasi dari lapisan sebelumnya perlu diubah menjadi data satu dimensi sebelum dihubungkan pada semua neuron di *Fully-Connected Layer*. Pada umumnya *Fully-Connected Layer* digunakan dalam penerapan *Multi Layer Perceptron* (MLP) yang bertujuan untuk melakukan transformasi pada dimensi data agar dapat diklasifikasikan secara linear (Nurhikmat, 2018).

### Dropout Regularization

*Dropout* di definisikan sebagai suatu teknik regularisasi dari jaringan syaraf tiruan dimana beberapa akan dipilih secara *random* dan tidak dipakai selama pelatihan atau data latih. Neuron-neuron ini dapat dibuang juga secara *random*. Hal ini berarti bahwa kontribusi neuron yang dibuang akan dihentikan sementara jaringan dan bobot baru juga tidak ditetapkan pada neuron saat melakukan proses *backpropagation* (Peryanto *et al*, 2019). Teknik ini sangat mudah diaplikasikan pada model CNN dan akan memberikan dampak

pada performa model dalam melatih serta mengurangi *overfitting* (Shafira, 2018).

### Softmax Classifier

Suatu bentuk lain atau regenerasi dari algoritma *Logistic Regression* yang dapat digunakan dalam pengklasifikasian yang lebih dari dua kelas. juga memberikan hasil yang lebih intuitif dan memiliki interpretasi dalam probabilistik yang lebih baik dibandingkan dengan algoritma klasifikasi lainnya. Menurut (Ilahiyah, dan Nilogiri, 2018) *Softmax* mempunyai bentuk persamaan sebagai berikut:

$$f_j(z) = \frac{e^{z_j}}{\sum_k e^{z_k}} \quad (3)$$

Keterangan:

$f_j$  = nilai output ke j

$z$  = hipotesis yang diberikan oleh model pelatihan

$e^{z_j}$  = nilai unit ke-j

$\sum_k$  = jumlah neuron lapisan output

$e^{z_k}$  = nilai neuron ke-k

### Crossentropy Loss Function

*Loss Function* atau *Cost Function* adalah suatu fungsi yang dapat menggambarkan kerugian terkait dengan semua kerugian yang dihasilkan oleh suatu model. *Loss Function* yang baik merupakan fungsi yang dapat menghasilkan error yang paling rendah. Dalam (Wulandari *et al.*, 2020) dapat diketahui persamaan *loss function* dengan *crossentropy* adalah sebagai berikut:

$$L = -\frac{1}{N} \sum_{n=1}^N \sum_{r=1}^M Y_{r,n} \log(f(z_r)_n) \quad (4)$$

Dimana nilai 1 = kelas sesuai dan nilai 0 = kelas tidak sesuai

Keterangan :

$N$  = Jumlah data citra

$M$  = Jumlah kategori

$f(Z_r)$  = Fungsi *Softmax classifier*

$Y_{r,n}$  = Indikator biner

### Adaptive Moment Estimation (Adam)

Adam adalah algoritma algoritma pengoptimalan yang dapat digunakan sebagai pengganti dari prosedur *stochastic gradient descent* (SGD) klasik untuk memperbarui bobot pada suatu jaringan berdasarkan pada training atau pelatihan. Adam juga merupakan algoritma yang populer dibidang deep learning karena ia mencapai hasil yang baik dengan cepat. .

Persamaan dari algoritma optimasi adam adalah sebagai berikut (Anugerah, 2018):

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (5)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (6)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (7)$$

Keterangan:

$\eta$  : merupakan *learning rate*

$m_t$  : nilai decay rata-rata dari iterasi sebelumnya

$v_t$  : nilai decay rata-rata yang dikuadratkan dari iterasi sebelumnya

$\beta$  : nilai decay

$\epsilon$  : penambahan untuk menghindari pembagian dengan nol dimana  $\epsilon = 1e - 8$

### Confusion Matrix

*Confusion Matrix* merupakan suatu metode yang digunakan untuk mengukur performa dari suatu model. terdapat beberapa istilah umum yang dapat dipakai dalam proses pengukuran kinerja dari model klasifikasi yaitu:

1. *True Positive (TP)* merupakan data positif yang diprediksi benar
2. *True Negative (TN)* merupakan data negative yang diprediksi benar
3. *False Positive (FP)* merupakan data negative namun diprediksi sebagai data positif
4. *False Negative (FN)* merupakan data positif namun diprediksi sebagai data negative

*Confusion matrix* tersebut dapat ditunjukkan pada tabel berikut (Shafira, 2018):

**Tabel 1. Confusion Matrix**

		<i>Predicted class</i>		Total
		Yes	No	
<i>Actual class</i>	Yes	TP	FN	P
	No	FP	TN	N
Total		P	N	P+N

### Akurasi, Precision, Recall, dan F-Measure

Akurasi merupakan persentase dari data uji yang diklasifikasikan dalam kelas yang benar. Akurasi digunakan sebagai parameter keakuratan suatu model dalam melakukan

klasifikasi. Persamaan akurasi dapat dinyatakan dalam (Shafira, 2018) persamaan berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

Proses presisi menggambarkan seberapa tepat suatu model dalam memprediksi kejadian positif dalam serangkaian kegiatan prediksi. Untuk menghitung tingkat presisi dalam prediksi suatu kejadian dapat digunakan persamaan (Shafira, 2018) sebagai berikut:

$$Precision = \frac{TP}{TP+FP} \quad (9)$$

Sedangkan *recall* merupakan suatu ukuran kelengkapan berupa persentase *tupple* positif yang diklasifikasikan sebagai kelas positif. Perhitungan *recall* dilakukan berdasarkan persamaan (Shafira, 2018) berikut:

$$Recall = \frac{TP}{TP+FN} \quad (10)$$

F-measure merupakan perhitungan evaluasi dalam dalam informasi retrieval (temu kembali) yang mengkombinasikan *recall* dan *precision*. F-Measure dapat dihitung dengan rumus (Azis, et al. 2020) sebagai berikut:

$$F - Measure = \frac{2*Precision*Recall}{Precision+Recall} \quad (11)$$

## METODE PENELITIAN

### Sumber Data

Data yang digunakan dalam penelitian ini adalah data primer yang diperoleh dengan mengambil citra benih kacang hijau varietas vima 5 secara langsung dengan menggunakan kamera *smartphone realme c2*. Pada penelitian ini benih kacang hijau diperoleh dari seorang petani yang hendak menanam kacang hijau dengan varietas vima 5 dengan populasi yang digunakan pada penelitian ini adalah seluruh benih kacang hijau varietas vima 5 sedangkan pemilihan sampel dilakukan dengan menggunakan teknik *sampling* berupa *purposive sampling*, yaitu penetapan sampel berdasarkan kriteria-kriteria tertentu. Pada penelitian ini data yang digunakan adalah citra gambar benih kacang hijau dengan total 200 citra gambar kacang hijau (benih layak dan benih tidak layak).

### Variabel Penelitian dan Struktur Data

Variabel penelitian yang digunakan berdasarkan tujuan penelitian ini adalah citra gambar benih kacang hijau varietas vima 5 yang di kategorikan dalam 2 kelompok yaitu

benih layak dan benih tidak layak dengan setruktur data dan keterangan sebagai berikut:

**Tabel 2. Struktur Data**

Gambar	Variabel	Keterangan
	Biji Layak	Citra benih kacang hijau ini bermutu bagus dengan ditandai tidak terdapat bagian yang rusak maupun busuk
	Biji Tidak Layak	Citra benih kacang hijau ini ditandai dengan adanya bagian yang rusak, lecet ataupun busuk

### Langkah-langkah Penelitian

Langkah atau tahapan analisis data yang dilakukan pada penelitian ini adalah sebagai berikut:

1. Pengumpulan data
2. Pembentukan citra digital
3. Preprocessing
4. Pembagian data *training* dan data *testing* 80%:20%
5. Pengubahan ukuran citra
6. Pelabelan pada data *training* dan data *testing*
7. Perancangan model dengan fungsi konvolusi, aktivasi dan *pooling*
8. Pengujian Model
9. Melihat Akurasi
10. Interpretasi Hasil

## HASIL PENELITIAN dan PEMBAHASAN

### Pengambilan Data

Tahap pertama sebelum melakukan klasifikasi adalah dengan menyiapkan benih kacang hijau yang terdiri dari biji layak dan tidak layak. Kemudian benih kacang hijau tersebut akan dijadikan data gambar atau citra. Dalam pengambilan gambar dilakukan pada ruang terbuka dengan penambahan pencahayaan lampu agar gambar atau citra benih kacang hijau yang dihasilkan memiliki kualitas yang baik atau terlihat jelas.



Dilihat dari bentuknya yang tidak terlalu bervariasi, penggunaan data citra benih kacang hijau sebanyak 200 dirasa sangat cukup dalam melakukan penelitian benih kacang hijau yang berkualitas dengan dua klasifikasi yang terdiri dari 100 citra biji layak dan 100 citra biji tidak layak. Berikut ini merupakan contoh dari gambar atau citra biji layak dan citra biji tidak layak:



**Gambar 5. Contoh citra biji layak dan tidak layak**

### Pembentukan Citra Digital

Dengan menggunakan *software* R dapat diketahui bahwa sebuah citra gambar dapat memberikan berbagai informasi. Beberapa hasil informasi yang bisa didapatkan dari suatu citra yaitu berupa ukuran *pixel* dan *channel* citra yang dapat mempresentasikan warna dasar pembentukan citra. Berikut ini merupakan contoh representasi dari citra benih kacang hijau:



**Gambar 6. Contoh Citra**

Pada gambar diatas dapat diketahui beberapa informasi yang ada dalam citra yaitu sebagai berikut:

**Tabel 3. Informasi Citra**

Image	
ColorMode	Color
Dimensi	928 748 3

Citra gambar diatas merupakan citra warna yang mengandung komponen warna RGB. Hal tersebut dapat dilihat pada hasil *output colorMode* yang memiliki makna *color*. Selain itu juga didapatkan informasi ukuran citra atau gambar tersebut yaitu sebesar 928x748 yang artinya citra tersebut memiliki ukuran panjang dan lebar dengan satuan *pixel*. Sedangkan angka 3 menunjukkan citra yang memiliki 3 *channel* atau komponen RGB (*Red*, *Green*, dan *Blue*).

Selain itu juga dapat diketahui nilai matriks yang menggambarkan tingkat

kecerahan dari citra benih kacang hijau tersebut dari suatu warna pada setiap *pixel*. Hasil dari nilai matriks tersebut hanya ditampilkan sampai baris ke lima dan kolom ke enam dikarenakan keterbatasan dari Rstudio dalam menampilkan *output*. Nilai matriks yang dihasilkan adalah sebagai berikut:

$$f = \begin{bmatrix} 0.7137255 & 0.7098039 & 0.7058824 & 0.7058824 & 0.7058824 & 0.7058824 & \dots \\ 0.7137255 & 0.7137255 & 0.7098039 & 0.7058824 & 0.7058824 & 0.7098039 & \dots \\ 0.7176471 & 0.7137255 & 0.7098039 & 0.7058824 & 0.7058824 & 0.7098039 & \dots \\ 0.7176471 & 0.7137255 & 0.7098039 & 0.7098039 & 0.7098039 & 0.7098039 & \dots \\ 0.7176471 & 0.7176471 & 0.7137255 & 0.7098039 & 0.7098039 & 0.7137255 & \dots \end{bmatrix}$$

### Preprocessing Citra

Dalam proses preprocessing citra, akan dilakukan *cropping* dan pengubahan ukuran (*resize*) pada data citra benih kacang hijau. Proses *cropping* ini dilakukan untuk mendapatkan objek yang lebih banyak dari benih kacang hijau itu sendiri dibandingkan dengan *background* dari citra. Selain itu proses *cropping* juga sangat efektif jika dilakukan karena objek yang ingin diteliti hanya berupa citra benih kacang hijau saja. Apabila tidak dilakukan proses *cropping* semua objek pada data citra tersebut akan dianalisis oleh komputer. Oleh karena itu proses *cropping* sangat efektif untuk dilakukan.

### Pembagian Data Training dan Data Testing

Pembagian data *training* dan *testing* dalam penelitian ini menggunakan skenario perbandingan data didasarkan pada *pareto principle* yang sudah umum digunakan dalam *data mining* yang menyatakan bahwa 80% kejadian dihasilkan dari 20% sisanya. Perbandingan data 80%:20% juga sudah umum digunakan dalam penelitian. Selain itu juga beracuan terhadap penelitian terdahulu yang dilakukan oleh Shafira (2018) menggunakan skenario 80:20 dihasilkan nilai akurasi yang tinggi. Sehingga pada penelitian ini digunakan skenario pembagian data 80%:20%. Maka pada penelitian ini data training yang digunakan adalah (200 x 80) : 100 =160, sehingga data testing yang digunakan sebesar (200 - 160 = 40).

**Tabel 4. Skenario Pembagian Data**

Benih	Data Train	Data Test
	(80%)	(20%)
Layak (Baik)	80	20
Tidak Layak (Busuk)	80	20
Jumlah	160	40

Data *training* (*train*) diurutkan yang ditentukan pada dataset dari nomor 1-80 yaitu citra benih kacang hijau Baik(1) sampai

Baik(80) dan dataset dari nomor 101-180 merupakan citra benih kacang hijau Busuk(1) sampai Busuk(80), begitu juga saat menentukan data *testing (test)*, dataset yang digunakan untuk biji layak atau baik yaitu dari nomor 81-100 yang merupakan Baik(81) hingga Baik(100) serta dataset untuk biji tidak layak yaitu dari nomor 181-200 yang merupakan Busuk(81)-Busuk(100).

### Pengubahan Ukuran Image

Setelah melakukan pembagian data, tahapan pengolahan citra yang selanjutnya yaitu melakukan implementasi *preprocessing* citra dengan melakukan perulangan untuk mengubah ukuran citra yang awalnya 100x100 menjadi 32x32 *pixel*. Ukuran citra yang digunakan untuk masukan CNN dianjurkan nilai pangkat dua ( $2^n$ ). Resolusi citra yang dipilih peneliti adalah 32x32, ukuran tersebut dipilih karena beberapa pertimbangan yaitu:

1. Apabila menggunakan nilai yang lebih kecil dari 32 yaitu 16x16 dapat menjadikan informasi yang didapat dari gambar akan semakin sedikit seperti pixel akan banyak yang hilang karena terlalu kecil dan dapat berpengaruh terhadap akurasi model.
2. Apabila menggunakan nilai yang lebih besar dari 32 yaitu 64x64 dapat menjadikan pemrosesan akan menjadi lebih berat dan lambat karena keterbatasan performa komputer seperti RAM dan GPU.

### Proses Pelabelan

Sebelum melakukan klasifikasi menggunakan model CNN dilakukan proses pelabelan terlebih dahulu pada data *training* dan data *testing*. Dalam penelitian ini peneliti melakukan pelabelan dengan menggunakan angka 0 (nol) dan 1 (satu). Angka nol digunakan untuk mewakili pelabelan citra benih kacang hijau pada kategori biji layak (Baik), sedangkan angka satu digunakan untuk mewakili pelabelan citra benih kacang hijau dengan kategori biji tidak layak (Busuk). Proses pelabelan ini digunakan untuk memudahkan dalam pembacaan data citra benih kacang hijau antara citra biji layak (Baik) dan biji tidak layak (Busuk).

### Perancangan Model CNN

Pembentukan model atau arsitektur jaringan dalam algoritma *convolutional neural network* dapat mempengaruhi hasil dari akurasi dalam pengujian. Untuk menghasilkan

klasifikasi terbaik diperlukan rancangan model terbaik. Dalam membentuk model terbaik, dapat ditentukan melalui beberapa parameter. Tahapan proses klasifikasi menggunakan model CNN dengan optimasi adam dapat dijelaskan seperti penjelasan berikut ini:

1. Proses Konvolusi, pada penelitian ini dilakukan sebanyak 4 kali yang ditandai dengan banyaknya *convolution layer* yang menjadi lapisan utama dan paling penting untuk digunakan dalam CNN. *Filter* yang digunakan dalam *convolution layer* pertama dan ke dua adalah 32. Sedangkan untuk *convolution layer* ketiga dan keempat adalah 64, hal ini dikarenakan ukuran filter pada 2 lapisan sebelumnya terlalu kecil untuk itu diperlukan lebih banyak filter untuk mengekstrak informasi pada citra. Untuk ukuran *kernel/filter* yang digunakan untuk setiap *layer* yaitu 3x3. Fungsi aktivasi yang digunakan adalah Relu (*Rectified Linear Unit*) yang menjadikan proses *training* menjadi lebih cepat.
2. Proses *Pooling*, pada dasarnya *pooling layer* terdiri dari sebuah *kernel/filter* dengan ukuran tertentu yang secara bergantian akan bergeser pada seluruh *feature map*. Metode *pooling* yang digunakan pada penelitian ini yaitu Max-Pooling. Proses *pooling* dilakukan dua kali, sedangkan ukuran *pooling* yang digunakan yaitu 2x2.
3. Proses penambahan *dropout regularization* dengan meregulasi jaringan syaraf untuk dipilih beberapa neuron secara acak dan tidak dipakai selama proses pelatihan untuk mengurangi *overfitting* yang kemudian mengklasifikasikan hasilnya.
4. Dalam proses *flatten*, mengubah *feature map* atau output *pooling layer* menjadi sebuah *vector*, hal tersebut dilakukan agar dapat di input pada tahap *fully connected layer* untuk kemudian diklasifikasi.
5. Terdapat dua *dense layer* yang digunakan, untuk *layer* pertama digunakan fungsi *activation ReLu* sedangkan pada *layer* yang kedua pada proses akhir dalam klasifikasi digunakan *softmax classifier* untuk memberikan hasil yang lebih intuitif, sehingga memudahkan dalam melakukan klasifikasi dari interpretasi probabilitas untuk semua label yang dihasilkan.



6. Optimasi yang digunakan dalam perbandingan model adalah menggunakan Adam

### Pengujian Model CNN

Berdasarkan penjelasan model CNN sebelumnya, dalam proses *training* didapatkan output model yang dihasilkan sebagai berikut:

**Tabel 5. Hasil Model CNN dan Perhitungan Parameternya**

Layer Type	Output Shape	Parameter
Input	32x32x3	0
Convulasi_1	30x30x32	896
Convulasi_2	28x28x32	9248
Max Pooling_1	14x14x32	0
Dropout_1	14x14x32	0
Convulasi_3	12x12x64	18497
Convulasi_4	10x10x64	36928
Max Pooling_2	5x5x64	0
Dropout_2	5x5x64	0
Flatten	1600	0
Dense_1	256	409856
Dropout_3	256	514
Dense_2	2	0
Total Parameter		475,938

Dari hasil *output* model diatas, pada proses konvolusi pertama, dihasilkan gambar dengan ukuran 30x30x32 dan parameter sebanyak 896. Angka 32 menunjukkan dimensi sebelumnya yang memiliki ukuran 32x32x3 dengan ukuran 32x32 merupakan *pixel* yang sebenarnya merupakan multidimensional *array* sedangkan 3 merupakan jumlah *channel* RGB. Citra ini akan dilakukan beberapa proses sesuai apa yang dibutuhkan oleh model yaitu, filter akan digerakkan dengan *stride* 1 ke seluruh bagian dari input citra dari sudut kiri hingga kanan bawah. Dari setiap pergeseran filter pada input citra dilakukan operasi “*dot*” atau perhitungan matematis. Pada penelitian ini tidak melakukan penambahan *zero padding* sehingga ukuran filter yang digunakan tetap sama 32x32 *pixel*.

Ukuran 30 dari hasil proses konvolusi pertama ini didapatkan dari perhitungan sebagai berikut:

$$(W-F+2P)/S+1 = 32-3+2(0)/1+1 = 30,$$

Angka 32 merupakan filter yang digunakan, angka 3 merupakan ukuran kernel 3x3. Sedangkan parameter sebanyak 896 ini didapatkan dengan perhitungan sebagai berikut:

$$((3 \times 3 \times 3) + 1) \times 32 = 896,$$

Angka 3x3 pertama merupakan ukuran kernel, untuk angka 3 berikutnya merupakan banyaknya kategori pada dimensi awal. Sedangkan angka 1 merupakan unit bias yang pasti ada dalam sebuah perhitungan dan angka 32 merupakan banyak filter. Dengan menggunakan fungsi aktivasi *Relu* dan *pooling* akan didapatkan ukuran citra setelah proses konvolusi pertama. Dengan menggunakan rumus yang sama akan didapatkan *convolutional layer* yang kedua yaitu dengan ukuran gambar 28x28x32 dan banyaknya parameter sebesar 9248. Sedikit berbeda pada perhitungan *max-pooling layer*, dimensi yang dihasilkan yaitu 14x14 didapatkan dari pembagian ukuran *convolutional layer* yang kedua (28x28) dengan ukuran filter 2x2 dan *stride* 1 sehingga pixel 28 pada *convolutional layer* yang kedua dibagi dibagi 2 sehingga output dihasilkan 14x14x32. *Output shape* dari *dropout* mempunyai nilai sama dengan *pooling layer* yaitu 14x14x32. Pada proses ini parameter tidak perlu dihitung kembali, sehingga total parameter bernilai 0.

Ukuran citra yang dihasilkan pada setiap layer konvolusi semakin berkurang. Ukuran citra pada proses konvolusi terakhir sebelum masuk ke *fully connected layer* sebesar 5x5 pixel sedangkan jumlah filter yang digunakan yaitu sebanyak 64. Angka 1600 yang terbentuk pada *flatten layer* merupakan angka yang didapatkan dari perkalian pada dimensi sebelumnya yaitu 5x5x64=1600. Kemudian pada dense layer 256 merupakan angka yang menunjukkan banyaknya neuron yang digunakan dalam penelitian. Sedangkan parameter sebesar 409.856 didapatkan dari hasil perhitungan (1600x256)+256=409.856. Pada *dense layer* kedua dihasilkan angka 2 yang menunjukkan banyaknya kategori gambar yang digunakan dalam klasifikasi yaitu kategori biji layak (Baik) dan biji tidak layak (Busuk) sehingga jumlah parameter yang didapatkan yaitu (256+1)\*2=514. Total jumlah parameter yang dilatih dalam model ini adalah sebanyak 475.938 parameter.

### Melihat Akurasi Pelatihan Data dalam Fit Model

Dalam melakukan fit model pada penelitian ini digunakan *epoch* = 80, *batch size* = 32 dan *validation split* = 0,1. *Epoch* berfungsi untuk melakukan perulangan model dalam menentukan akurasi dan *loss*. sedangkan *batch size* merupakan jumlah contoh dari pelatihan

dalam satu *forward/backward pass*. Semakin tinggi nilai *batch size* yang digunakan maka akan semakin banyak memori yang dibutuhkan.

**Tabel 6. Hasil Fit Model**


Epoch	Data Train		Data Test	
	Acc	Loss	Val Acc	Val Loss
1	0,5312	0,7068	0,5000	0,6953
2	0,5375	0,6983	0,5000	0,6931
3	0,6062	0,6887	0,5000	0,6923
4	0,5000	0,6887	0,5000	0,6871
5	0,7063	0,652	0,5000	0,6642
⋮	⋮	⋮	⋮	⋮
77	1,000	0,0011	0,9000	0,3085
78	1,000	0,0017	0,9000	0,4028
79	1,000	0,0008	0,9000	0,3929
80	1,000	0,0006	0,9000	0,3551

Berdasarkan tabel diatas dapat diketahui hasil dari pelatihan data train dan data test dengan iterasi (*epoch*) sebanyak 80 menghasilkan nilai akurasi dan *loss*. Akurasi merupakan presentase atau suatu nilai yang digunakan untuk mengetahui tingkat keberhasilan model dari data uji yang telah dibuat dan diklasifikasikan ke kelas yang benar, sedangkan nilai *loss* merupakan suatu ukuran dari sebuah *error* yang dibuat oleh *network* yang dihasilkan oleh model.

**Tabel 7. Hasil Akurasi**

Data	Jumlah Data	Epoch 80	
		Nilai Loss	Nilai Accuracy
Training	160	0,0006	100%
Testing	40	0,3551	90%

Dari tabel diatas didapatkan nilai *loss* pada data train sebesar 0,0006 yang lebih rendah dari data test yaitu sebesar 0,3551 yang artinya model yang telah didapat sudah bagus. Hal tersebut juga didukung dengan hasil akurasi dari data training sebesar 100% serta akurasi data testing sebesar 90% yang menunjukkan model yang diperoleh mampu melakukan klasifikasi dengan baik. Selain itu didapatkan grafik pergerakan nilai akurasi dan *loss* dari data train dan test yang dihasilkan pada setiap iterasi (*epoch*) sebagai berikut:



**Gambar 7. Grafik Hasil Iterasi**

Dari gambar grafik diatas dapat diketahui bahwa pergerakan *loss* mendekati angka nol atau rendah dan pergerakan *accuracy* terus meningkat. Hal ini menunjukkan hasil yang baik, semakin besar *epoch* yang digunakan maka nilai akurasi pada data training semakin tinggi dan nilai *loss* yang dihasilkan pada penelitian data semakin rendah.

**Evaluasi dan Prediksi Data Training**

Setelah melakukan pelatihan data citra pada proses training dan testing, maka selanjutnya adalah melakukan evaluasi dan prediksi. Nilai evaluasi dan prediksi tersebut didapatkan dari hasil model yang telah dibuat sebelumnya. Pada penelitian ini nilai model yang didapatkan dari data training sebanyak 160 citra gambar yang terdiri dari 80 citra biji layak (baik) dan 80 biji tidak layak (busuk). Hasil evaluasi pada data training memiliki nilai *loss* sebesar  $5,1770 \times 10^{-4}$  dan akurasi 100%.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

$$Accuracy = \frac{80+80}{80+80+0+0} = \frac{160}{160} = 1 \approx 100\%$$

Ini artinya model dapat melakukan klasifikasi terhadap benih kacang hijau dengan baik. Selain itu klasifikasi pada data training ditunjukkan pada tabel *confution matrix* berikut:

**Tabel 8. Hasil Klasifikasi Data Training**

		Actual	
		0	1
Predict	0	80	0
	1	0	80

Berdasarkan tabel diatas hasil klasifikasi pada data training menunjukkan bahwa citra biji layak (baik) yang berhasil diklasifikasikan dengan benar sebanyak 80 dari 80 citra yang digunakan, sama halnya dengan data citra biji tidak layak (busuk).

## Evaluasi dan Prediksi Data Testing

Nilai evaluasi dan prediksi dari hasil model sebelumnya, dengan pengujian data testing menggunakan data citra biji layak (baik) sebanyak 20 citra dan citra biji tidak layak (busuk) sebanyak 20 citra didapatkan nilai *loos* sebesar 0.3551 dan nilai *accuracy* sebesar 0,9. Hasil klasifikasi dari pengujian tersebut dapat dilihat pada tabel confusion matrix berikut ini:

**Tabel 9. Hasil Klasifikasi Data Testing**

		Actual	
		0	1
Predict	0	17	1
	1	3	19

Berdasarkan tabel diatas hasil klasifikasi pada data training menunjukkan bahwa citra biji layak (baik) yang berhasil diklasifikasikan dengan benar sebanyak 17 dari 20 citra yang digunakan dan memiliki kesalahan klasifikasi sebanyak 3 citra. Sedangkan untuk citra dengan kategori biji tidak layak (busuk) berhasil diklasifikasikan dengan benar sebanyak 19 dari 20 citra dan memiliki kesalahan klasifikasi sebanyak 1 citra. Evaluasi hasil klasifikasi dapat dilihat melalui perhitungan berikut:

- Perhitungan nilai akurasi

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

$$= \frac{17+19}{17+19+3+1} = \frac{36}{40} = 0,9 \approx 90\%$$

Dari perhitungan nilai *accuracy*, dapat diketahui bahwa tingkat kedekatan antara nilai prediksi dan nilai aktual adalah sebesar 90%, yang mempunyai arti bahwa parameter keakuratan dari model dalam melakukan klasifikasi antara kelas prediksi dan kelas aktual yang dihasilkan sudah baik.

- Perhitungan nilai *presision*

$$Presision = \frac{TP}{TP + FP}$$

$$= \frac{17}{17+3} = 0,85 \approx 85\%$$

Dari perhitungan nilai *presision* tersebut dapat diketahui bahwa ketepatan model dalam memprediksi benih kacang hijau pada kelas biji layak (baik) dengan klasifikasi benar yaitu sebesar 85% yang artinya sudah baik.

- Perhitungan nilai *recall*

$$Recall = \frac{TP}{TP + FN}$$

$$= \frac{17}{17+1} = 0,94 \approx 94\%$$

Dari perhitungan nilai *recall* tersebut dapat diketahui bahwa ketepatan model dalam memprediksi benih kacang hijau pada kelas biji layak (baik) dari keseluruhan kelas biji layak (baik) yang sebenarnya yaitu dihasilkan sebesar 94% yang artinya sudah baik.

- Perhitungan nilai F-Measure

$$F - Measure = \frac{2*Precision*Recall}{Precision+Recall}$$

$$= \frac{2*0,85*0,94}{0,85+0,94} = 0,9 \approx 90\%$$

Dengan nilai *F-Measure* sebesar 90%, dapat diketahui bahwa ketepatan model dari rata-rata nilai *presision* dan *recall* sudah baik. Dari perhitungan evaluasi model diatas didapatkan nilai akurasi sebesar 90%, *presision* 85%, *recall* sebesar 94% dan *F-Measure* sebesar 90%. Hal ini menunjukkan bahwa metode CNN mampu melakukan pengklasifikasian citra gambar dengan baik.

## Uji Coba dengan Dataset Baru

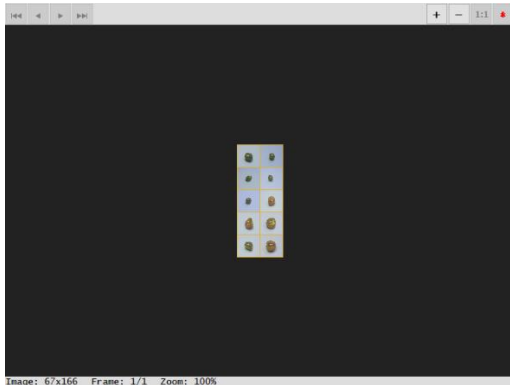
Setelah didapatkan model terbaik dengan akurasi 90%, peneliti ingin menguji model tersebut dengan menggunakan dataset baru citra kacang hijau. Gambar yang digunakan dalam uji coba model ini berjumlah 10 citra yang terdiri dari 5 citra biji layak (baik) dan 5 biji tidak layak (busuk). Kelas prediksi dan aktual yang dihasilkan adalah sebagai berikut:

**Tabel 10. Hasil Klasifikasi Data Kelas Prediksi dan Aktual**

Kelas Prediksi	Aktual
0	0
0	0
0	0
0	0
1	0
1	1
1	1
1	1
1	1
1	1
1	1

Dari Tabel diatas dapat diketahui bahwa hasil klasifikasi citra dengan menggunakan 10 data didapatkan kelas prediksi biji layak (baik) dapat diklasifikasikan dengan baik sebanyak 4 citra, dan 6 citra lainnya di prediksi dengan kelas biji tidak layak (busuk). Untuk hasil data aktual menunjukkan bahwa dari 10 citra, 5 citra diklasifikasikan dengan biji

layak (baik) dan 5 citra sisanya diklasifikasikan dengan biji tidak layak (busuk). Hasil klasifikasi tersebut juga dapat dilihat melalui gambar berikut ini:



**Gambar 8. Klasifikasi Citra**

Hasil klasifikasi dari data baru dapat ditunjukkan melalui tabel *confusion matrix* dibawah ini:

**Tabel 11. Hasil Klasifikasi Dataset Baru**

		Actual	
		0	1
Predict	0	4	0
	1	1	5

Dari hasil klasifikasi diatas dapat diketahui bahwa dari 10 citra yang digunakan, computer salah menebak 1 gambar yaitu pada kategori biji layak (baik). Dari tabel diatas dapat dihitung nilai akurasi yang dihasilkan sebbagai berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN}$$

$$Akurasi = \frac{4+5}{4+5+1+0} = \frac{9}{10} = 0,9 \approx 90\%$$

Dengan hasil nilai akurasi sebesar 90%, dapat disimpulkan bahwa model yang digunakan dalam penelitian dapat melakukan klasifikasi terhadap benih kacang hijau dengan baik.

## SIMPULAN dan SARAN

### Simpulan

Berdasarkan hasil analisis yang telah dilakukan peneliti, diperoleh beberapa kesimpulan sebagai berikut:

1. Hasil klasifikasi citra benih kacang hijau yang berkualitas dengan menggunakan metode CNN dengan layer konvolusi sebanyak empat layer, fungsi aktivasi ReLu, dan beberapa penggunaan parameter lainnya dari hasil data *testing* menghasilkan citra benih kacang hijau

dengan kategori biji layak (baik) berhasil diklasifikasikan dengan benar sebanyak 17 citra dan memiliki kesalahan klasifikasi sebanyak 3 citra. Sedangkan untuk citra dengan kategori biji tidak layak (busuk) berhasil diklasifikasikan dengan benar sebanyak 19 citra dan memiliki kesalahan klasifikasi sebanyak 1 citra.

2. Tingkat akurasi yang berhasil didapatkan dalam pengklasifikasian kelayakan atau kualitas biji kacang hijau menggunakan metode CNN yaitu sebesar 100% pada tahap training dan sebesar 90% pada tahap testing. Sehingga dapat disimpulkan bahwa metode CNN dapat melakukan identifikasi kelayakan benih kacang hijau dengan baik.

### Saran

Berdasarkan kesimpulan diatas, didapatkan beberapa saran sebagai berikut:

1. Sistem ini dapat dikembangkan dengan menggunakan software lain selain software R Studio. Karena masih banyak software lain yang dapat digunakan untuk melakukan klasifikasi gambar.
2. Bagi penelitian selanjutnya dapat melakukan perbandingan dengan melakukan perubahan pada model seperti fungsi aktivasi lain, optimasi lain, banyaknya *epoch*, jumlah data taining dan testing, *batch size*, *learning rate*, dan lain sebagainya
3. Spesifikasi komputer yang digunakan sebaiknya lebih tinggi, seperti menggunakan komputer dengan *Random Access Memory* (RAM) yang tinggi dan *Graphics Processing Unit* (GPU).

### Daftar Pustaka

- Al Rivan, M. E., Rachmad, N., dan Ayustin, M.R. 2020. Klasifikasi Jenis Kacang-kacangan Berdasarkan Tekstur Menggunakan Jaringan Syaraf Tiruan. *Jurnal Komputer Terapan*, 6(1),89-98
- Anugrah, A. G., 2018. Klasifikasi Tingkat Keganasan Kanker Paru-Paru Pada Citra Computed Tomography (CT) Scan Menggunakan Metode Convolutional Neural Network. *Skripsi*. Departemen Informatika. Institut Teknologi Sepuluh November. Surabaya
- Arrofiqoh, E. N., dan Harintaka.2018. Implementasi Metode *Convolutional Neural Network* Untuk Klasifikasi

- Tanaman Pada Citra Resolusi Tinggi. Geomatika Volume 24. (61-68)
- Databoks, 2019. Total Volume Ekspor 7 Komoditas Utama Tanaman Pangan 2014-Juni 2019. <https://databoks.katadata.co.id/datapublish/2019/08/14/berapa-volume-ekspor-tanaman-pangan>. di akses pada 2 Desember 2020
- Dewi, S. R. 2018. Deep Learning Object Detection Pada Video Menggunakan Tensorflow Dan Convolutional Neural Network. *Skripsi*. Prodi Statistika. Universitas Islam Indonesia. Yogyakarta
- Hu, F., Xia, G. S., Hu, J., & Zhang, L. 2015. Transferring Deep Convolutional Neural Network for Scene Classification of High-Resolution Image Sensing Imagery. *Remote Sens* : Hal. 14680-14707.
- Ilahiyah, S. Nilogiri, A. 2018. Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *JUSTINDO (Jurnal Sistem & Teknologi Informasi Indonesia)*, Vol. 3, No. 2
- Kementerian pertanian badan litbang pertanian, 2020. Menangkap Peluang Pasar Ekspor Komoditas Kacang Hijau. <http://www.litbang.pertanian.go.id/info-teknologi/3866/>. diakses pada 24 November 2020
- Kementerian Pertanian, 2020. BPS : Ekspor Pertanian Naik. <https://www.pertanian.go.id/home/?show=news&act=view&id=3810>. diakses pada 24 November 2020
- Nurhikmat, T.2018.Implementasi Deep Learning Untuk Image Classification Menggunakan Algoritma Convolutional Neural Network (CNN) Pada Citra Wayang Golek.*Skripsi*.Prodi Statistika.Universitas Islam Indonesia.Yogyakarta
- Peryanto, A.Yudhana, A., Umar, R. 2019. Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network. *Jurnal Format*. Volume 8 .Nomor 2
- Putri, O. N. 2020. Implementasi Metode CNN dalam Klasifikasi Gambar Jamur pada Analisis Image Processing (Studi Kasus: Gambar Jamur dengan Genus Agaricus dan Amanita). *Skripsi*.Prodi Statistika.Universitas Islam Indonesia.Yogyakarta
- Rahmat, G.D.2018. Pengaruh Konsentrasi Pupuk Hayati Terhadap Pertumbuhan Dan Hasil Tanaman Kacang Hijau (*Vigna Radiata L.*). *Skripsi*. Jurusan Agroteknologi. Universitas Siliwangi Tasikmalaya
- Shafira, T. 2018. Implementasi *Convolutional Neural Networks* Untuk Klasifikasi Citra Tomat Menggunakan *Keras*. *Skripsi*. Prodi Statistika. Universitas Islam Indonesia. Yogyakarta
- Wulandari, I. et al., 2020. Klasifikasi Citra Digital Bumbu dan Rempah Dengan Algoritma Convolutional Neural Network (CNN). *Jurnal Gaussian*. Vol.9, No.3, Hal 273-283

