

Analisis Klasifikasi Populasi Ternak Kambing dan Domba dengan Model Convolutional Neural Network

Alusyanti Primawati¹, Intan Mutia², Dwi Marlina³

^{1,2,3}Department of Informatic Engineering, Universitas Indraprasta PGRI, Indonesia

Article Info

Article history:

Received Feb 8, 2021

Revised Feb 18, 2021

Accepted March 10, 2021

Keywords:

Classification

Population

Goat and Lamb

CNN

PLF

ABSTRACT

The number of goat populations is increasing all over the world. Sheep and goats are economically potential for business development because they do not require large areas of land, relatively small investment in business capital, and are easy to market. However, the similarities between goats and sheep can make small breeders who are just starting out in business nervous. Therefore, in goats and sheep, an intensive and efficient Precision Livestock Farming system is required. To answer this problem, goat and sheep objects was studied out using the collaboration software programming R and Python which was executed in RStudio editor and Anaconda3 with the Tensor flow package. The sample data use were 40 images. The model obtained from the classification results uses 20 pictures of goats and 20 pictures of sheep for training and testing. It is concluded that Epoch 70 produces an accuracy of 0.84375 and a loss of 0.5909 in training data and an accuracy of testing data results of 0.875 and a loss of 0.640. While the epoch 100 produces an accuracy of 1.00 and a loss of 0.02 on the training data with testing data having an accuracy of 0.875 and a loss of 0.593.

Copyright © 2021 Universitas Indraprasta PGRI.
All rights reserved.

Corresponding Author:

Alusyanti Primawati,

Department of Informatic Engineering,

Universitas Indraprasta PGRI,

Jl. Nangka No. 58 C, Tanjung Barat, Jagakarsa, Jakarta Selatan.

Email: alus.unindra23@gmail.com

1. PENDAHULUAN

Jumlah populasi kambing semakin meningkat di seluruh dunia.[1] Pada dasarnya, pengembangan usaha ternak kambing dan domba bertujuan untuk memenuhi kebutuhan rumah tangga, baik peternak maupun konsumen. Peternakan kambing dan domba juga dinilai ramah lingkungan. Indonesia yang merupakan negara tropis memiliki dukungan yang besar untuk ternak kambing dan domba, mulai dari tipe iklim, kondisi lahan yang luas serta kondisi produksi hijauan yang sangat banyak.[2] Hasil produk kambing dan domba umumnya berupa daging dan susu, makin banyak dikonsumsi masyarakat Indonesia. Produksi inilah yang menjadi aspek potensial untuk pengembangan usaha ternak kambing dan domba baik secara pribadi maupun industri.[3] Kambing dan domba yang memiliki postur badan dan kualitas produk yang baik akan memiliki harga jual yang lebih tinggi. [4]

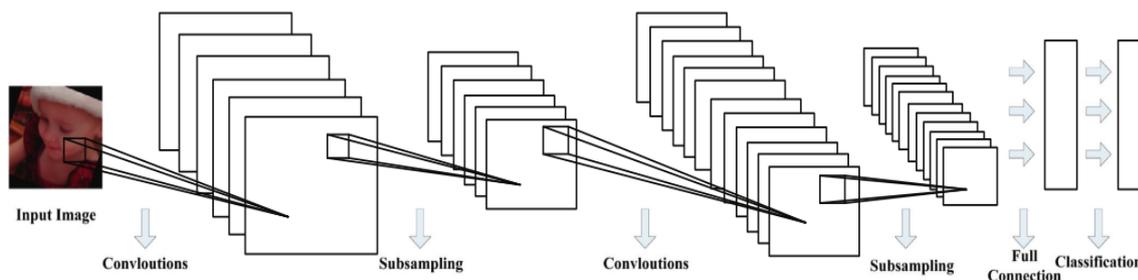
Untuk tahun ke depan, produksi kambing dan domba diharapkan akan menjadi sumber protein hewani pendamping yang dapat dikonsumsi masyarakat, setara dengan daging sapi dan ayam. [5] Ternak kambing domba dan kambing secara ekonomi memiliki potensi sebagai pengembangan usaha. [6] Beberapa kelebihan ternak kambing dan domba karena memiliki badan yang kecil, cepat mencapai usia dewasa, dan mudah cara pemeliharannya. [7] Kemudahan usaha ternak kambing dan domba tidak membutuhkan lahan yang luas, investasi modal usaha yang relatif kecil, serta mudah dipasarkan sehingga modal cepat berputar dan kembali kepada peternak. Untuk penjualan atau kegiatan pemasaran kambing dan domba, umumnya dapat dilakukan

langsung di lokasi peternak maupun di pasar hewan yang disediakan pemerintah daerah. Karena rantai pemasaran yang terlalu panjang dapat menyebabkan kerugian, baik bagi peternak maupun bagi konsumen yang dikenakan beban biaya pemasaran dengan harga lebih tinggi daripada seharusnya. [8]

Bagi peternak yang memulai usahanya untuk ukuran peternakan kecil, maka kambing dan domba yang dipelihara dari skala 2-10 ekor / peternak. Kemiripan antara kambing dan domba dapat membuat peternak kecil yang baru merintis usaha mengalami gamang. Oleh karena itu, dalam ternak kambing dan domba memerlukan sistem intensif dan efisien dalam mengolah sumber daya sehingga akan meningkatkan laba dan memberikan kontribusi yang signifikan bagi ekonomi nasional. [9] Dengan menggunakan manajemen peternakan presisi (*Precision Livestock Farming*) yang berbasis pengetahuan dan teknologi maka dapat membantu peternak untuk meningkatkan efisiensi produksi peternakannya. [10]

Manajemen peternakan presisi (PLF) memiliki kekhasan dalam menyimpan, memverifikasi, memvisualisasikan representasi pengetahuan tentang domain produksi peternakan, sumber daya produksi, peralatan mesin peternakan, dan sumber daya material lainnya yang digunakan untuk memaksimalkan kinerja peternakan. [11] Manajemen peternakan presisi (PLF) menjawab tantangan peternak dalam mempertahankan pendapatan dalam konteks produksi yang selalu berubah misalnya iklim dan fluktuasi harga pasar. [12] Masalah yang timbul dan masih sering dialami peternak kecil yang masih minim pengetahuan antara lain adalah sulit untuk membedakan kambing dan domba. Data yang lengkap tentang kambing dan domba dengan berbagai variabel-variabel harus dipelajari, akan membutuhkan waktu jangka panjang seiring bertambah pengalaman peternak. Agar dapat memberikan bantuan untuk memperkaya pengetahuan peternak kecil yang masih gamang akan perbedaan kambing dan domba, maka solusi sistem teknologi pembelajaran berbantuan kecerdasan buatan (*artificial intelligent*) dapat digunakan.

Salah satu cabang dari Artificial Intelligent (AI) yaitu Machine Learning (ML) dimana mesin akan diajari pengetahuan yang nantinya dapat berfikir seperti manusia. Salah satu pendekatan ML yaitu deep learning (DL). Deep Learning memiliki kemampuan untuk melakukan pembelajaran lebih dalam, yang sangat baik digunakan dalam visi komputer [13]. Salah satunya adalah pada kasus klasifikasi objek pada citra, citra yang akan digunakan adalah gambar kambing dan domba. Algoritme DL yang digunakan untuk pengenalan citra adalah *Convolution Neural Network* (CNN) [14]. CNN yang merupakan pengembangan dari Multilayer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi. Untuk klasifikasi citra, MLP dirasa kurang sesuai karena menganggap setiap piksel adalah fitur yang independen dan tidak menyimpan informasi spasial dari data citra sehingga memberikan hasil yang kurang baik. Hal ini membuat CNN lebih baik untuk diaplikasikan pada data citra karena memiliki kedalaman jaringan yang tinggi dengan layer yang memiliki susunan neuron 3D (lebar, tinggi, kedalaman). Lebar dan tinggi merupakan ukuran layer sedangkan kedalaman mengacu pada jumlah layer [15].



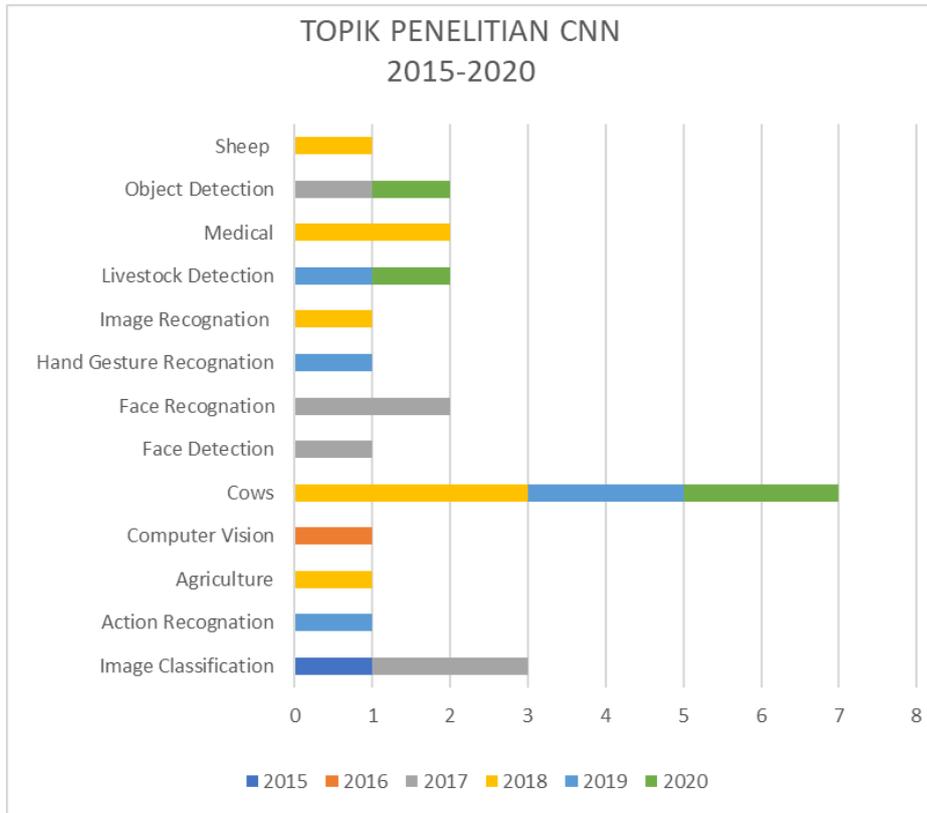
Gambar 1. Struktur CNN untuk Pengenalan Citra [16]

Fitur yang terdapat pada Struktur CNN memberikan kemudahan untuk banyak studi dan pemodelan yang kompleks, sehingga pada klasifikasi citra, deteksi objek, estimasi dan segmentasi citra memiliki hasil dan kemajuan yang sangat pesat oleh sebab itu penerapannya menjadi tren dimasa depan baik pada kasus identifikasi manusia ataupun hewan [17]. Penerapan CNN pada berbagai bidang sudah banyak ditemukan pada 5 tahun terakhir, perjalanan penelitian CNN dijelaskan pada Gambar 2. CNN sudah banyak diterapkan pada Citra sangat populer dilakukan bahwa mulai diterapkan pada bidang Pertanian, Peternakan, dan Medis.

Pada peternakan sudah banyak dilakukan penerapan CNN pada sapi seperti melacak sapi perah [18], estimasi kondisi tubuh sapi [19], indentifikasi individual sapi [20][21][22], estimasi kondisi tubuh sapi [23], dan lainnya. Deteksi hewan ternak juga sudah dilakukan melalui pengambilan gambar hewan ternak dari udara [24][25]. Pada tahun 2018 mulai dilakukan penerapan CNN untuk mendeteksi dan menghitung jumlah domba dengan menggunakan Video UAV [26]. Berdasarkan rangkuman topik CNN tahun 2015-2020 kami berkontribusi penerapan CNN untuk mengidentifikasi Kambing dan Domba dikarenakan keduanya terlihat sama.

Tujuan dari penelitian ini adalah mengembangkan model CNN yang dapat digunakan untuk membantu peternak kecil dalam mengklasifikasi populasi ternak kambing dan domba. CNN dikenal memiliki hasil yang bagus pada saat identifikasi objek yang sama, sehingga kami melakukan hal yang berbeda pada penelitian ini

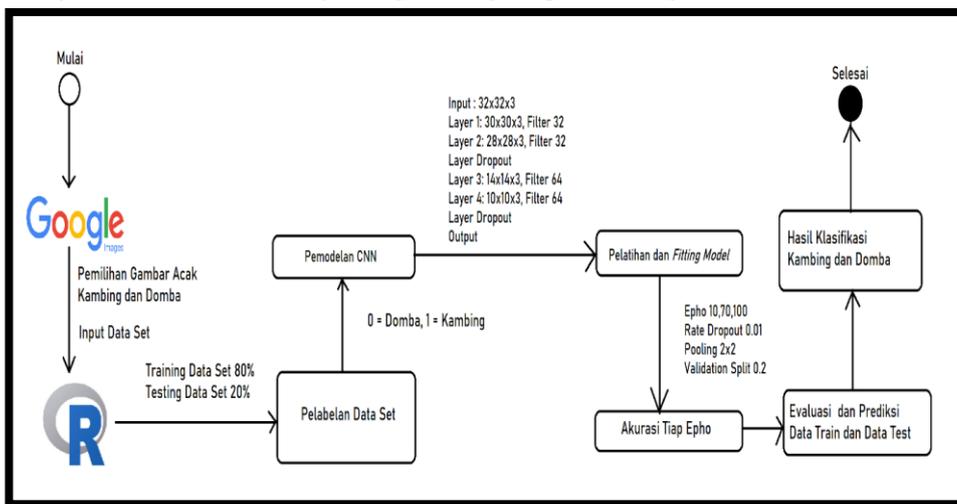
yaitu apakah CNN berhasil mengklasifikasi dua jenis yang agak serupa seperti Kambing dan Domba. Pada penelitian awal ini kami melakukan dengan mengambil banyak gambar Kambing dan Domba melalui *Google Image* secara acak dan menggunakan CNN untuk mengklasifikasi Kambing dan Domba.



Gambar 2. Topik Penelitian CNN Tahun 2015-2020
(Sumber Data: Google Scholar 2015-2020, Kunci: *Convolution Neural Network, Convolution Neural Network Livestock*)

2. METODE

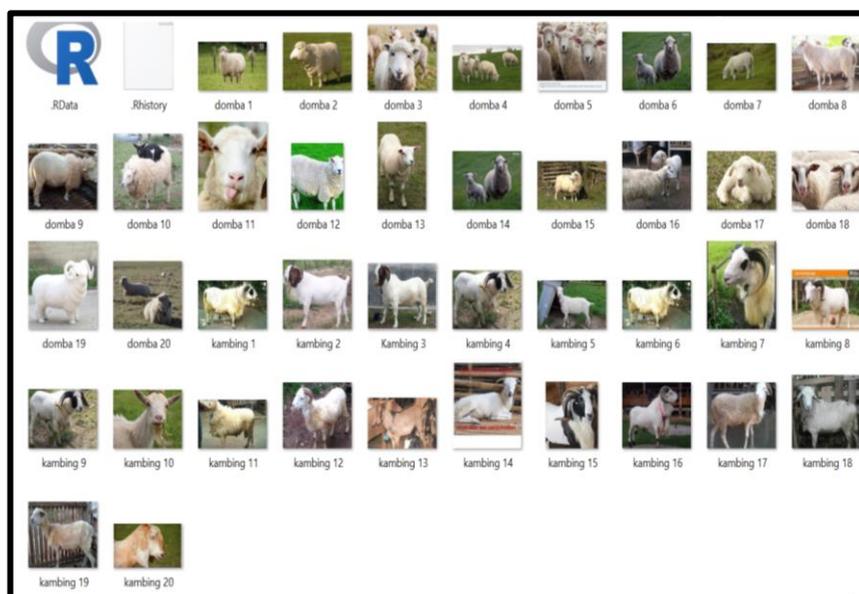
Langkah-langkah dalam proses klasifikasi populasi ternak kambing dan domba dapat digunakan sebagai alat bantu peternak untuk mempercepat proses identifikasi. Metode yang digunakan dalam memprediksi yaitu *Convolution Neural Network (CNN)* dengan data sekunder yang bersumber dari *Google Image*. Dataset tersebut dibagi dua menjadi data latih dan data uji. Langkah-langkah penelitian dijelaskan melalui Gambar.



Gambar 3. Tahapan Penelitian

Populasi dan Sampel Penelitian

Populasi yang digunakan dalam penelitian ini adalah seluruh citra kambing dan domba sedangkan sampel pada penelitian ini adalah citra kambing 20 gambar dan domba 20 gambar, sehingga total 40 gambar. Sampel Penelitian merupakan dataset yang akan dilatih dan diuji. Penelitian sebelumnya menggunakan image yang tertangkap langsung dengan video AUV [26] sedang penelitian ini menggunakan image pada *Google Image*.



Gambar 2. Dataset untuk Pengenalan Citra Kambing dan Domba (sumber: hasil olahan penulis)

Metode Analisis Data

Proses analisis data dalam penelitian ini menggunakan Algoritma *Convolution Neural Network* (CNN) yang digunakan untuk klasifikasi populasi ternak kambing dan domba. *Software* yang digunakan merupakan kolaborasi antara Bahasa pemrograman R dan Phyton yang dieksekusi dalam editor *RStudio* sebagai editor utama, dan *Anaconda3* untuk mendukung pustaka *package Tensorflow*.

Metode analisis dimulai dengan mempersiapkan dataset menggunakan metode pemrosesan citra (*image processing*). Selanjutnya, menggunakan metode *Convolution Neural Network* (CNN) library *Keras* untuk melakukan pemodelan *Neural Network* pada dataset berbasis citra. Fungsi aktivasi yang digunakan adalah *Relu – Softmax*. *Rectified Linear Function* menjadi fungsi aktivasi yang paling umum digunakan karena ketahanannya terhadap efek gradien hilang dalam algoritma *BackPropagation*. *Dropout* adalah teknik yang efektif untuk mencegah jaringan saraf dari *overfitting* dalam pelatihan. Untuk meningkatkan kemampuan rata-rata model dari hasil *dropout*, digunakan *max pooling* terhadap fitur-fitur sebagai fungsi aktivasi [27]. Metode *Pooling* membagi sejumlah inputan kedalam Blok Ruang Lokal dan memaksimalkan pembagian (*Max Pooling*) di setiap blok yang memastikan keluaran memiliki dimensi tetap [17]. Langkah analisis data menggunakan *Convolution Neural Network* (CNN) sebagai berikut:

1. Mempersiapkan *input Data*
2. Mempersiapkan Dataset (*Resize dan Combine*)
3. Pemodelan
4. Pelatihan dan *Fitting Model*
5. Evaluasi dan Prediksi Data Latih (*training*) dan Data Uji (*testing*)

3. HASIL DAN PEMBAHASAN

3.1 Hasil Analisis Data

Hasil dari setiap tahapan analisis menggunakan algoritme *Convolution Neural Network* (CNN) dijelaskan sebagai berikut:

1. Masukkan Dataset (*input Dataset*)

Dataset yang digunakan adalah 40 citra dengan masing-masing 20 gambar pertama adalah domba sedangkan 20 gambar selanjutnya adalah kambing. Semua gambar dapat dibaca oleh program terlihat dalam gambar 3.

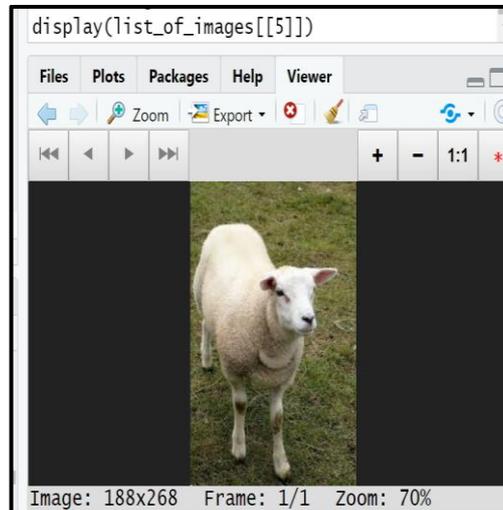
```

> images
[1] "domba 1.jpg" "domba 10.jpg" "domba 11.jpg"
[4] "domba 12.jpg" "domba 13.jpg" "domba 14.jpg"
[7] "domba 15.jpg" "domba 16.jpg" "domba 17.jpg"
[10] "domba 18.jpg" "domba 19.jpg" "domba 2.jpg"
[13] "domba 20.jpg" "domba 3.jpg" "domba 4.jpg"
[16] "domba 5.jpg" "domba 6.jpg" "domba 7.jpg"
[19] "domba 8.jpg" "domba 9.jpg" "kambing 1.jpg"
[22] "kambing 10.jpg" "kambing 11.jpg" "kambing 12.jpg"
[25] "kambing 13.jpg" "kambing 14.jpg" "kambing 15.jpg"
[28] "kambing 16.jpg" "kambing 17.jpg" "kambing 18.jpg"
[31] "kambing 19.jpg" "kambing 2.jpg" "kambing 20.jpg"
[34] "kambing 3.jpg" "kambing 4.jpg" "kambing 5.jpg"
[37] "kambing 6.jpg" "kambing 7.jpg" "kambing 8.jpg"
[40] "kambing 9.jpg"
> summary(images)
  Length      Class      Mode
  40 character character
> |

```

Gambar 3. Dataset untuk Pengenalan Citra Kambing dan Domba (sumber: hasil olahan penulis)

Untuk memastikan gambar terbaca maka dilakukan *display* gambar 5 yang merupakan domba, ditampilkan pada gambar 4.



Gambar 4. Display gambar 5 (sumber: hasil olahan penulis)

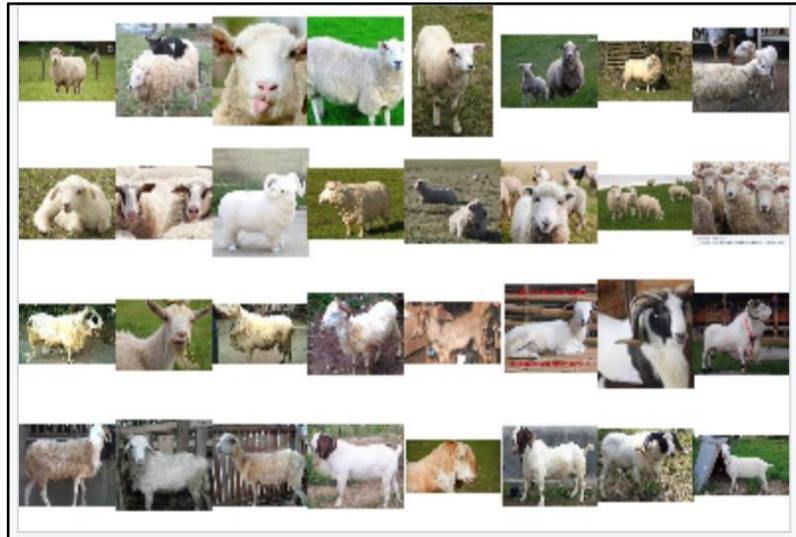
2. Pelatihan (*Training*) dan Pengujian (*Testing*) Dataset

Langkah ini mempersiapkan dataset untuk pelatihan dan pengujian dengan melakukan pembagian data. Untuk pelatihan (*training data*) diambil sebanyak 80% dari dataset sedangkan untuk pengujian (*testing data*) sebesar 20%, dijelaskan melalui Tabel 1.

Tabel 1. Pembagian Dataset untuk Pelatihan (*Training*) dan Pengujian (*Testing*)

Variabel	Data Set	Set Train	Set Test
Domba	20	16	4
Kambing	20	16	4
Total	40	32	8

Untuk memastikan pembagian data set berhasil, maka data set *training* dan *testing* dijadikan data matrix, yang ditampilkan dalam gambar 5a dan 5b.



Gambar 5a. Dataset *training* (sumber: hasil olahan penulis)



Gambar 5b. Dataset *testing* ukuran 2×4 (sumber: hasil olahan penulis)

Seperti yang terlihat dalam gambar 5a dan 5b, ukuran setiap gambar berbeda-beda sehingga perlu dilakukan penyesuaian ukuran (*Resize*) dan penyatuan (*Combine*) pada Dataset. Hasil *Resize* dan *Combine* ditunjukkan pada Gambar 6a dan 6b.



Gambar 6a. Hasil *Resize* dan *Combine* Dataset *training* (sumber: hasil olahan penulis)



Gambar 6b. Hasil *Resize* dan *Combine* Dataset *testing* (sumber: hasil olahan penulis)

Langkah berikutnya melakukan pelabelan pada Dataset *training* dan *testing* menggunakan sintaks *to_categorical*. Sebelumnya pada Dataset dilakukan penyesuaian *reorder dimension* sehingga urutan data terbaca. Pelabelan yang dilakukan pada data hanya 2 yaitu Label 0 untuk Domba sedangkan 1 untuk Kambing.

```
> trainLabels
      [,1] [,2]
[1,]    1    0
[2,]    1    0
[3,]    1    0
[4,]    1    0
[5,]    1    0
[6,]    1    0
[7,]    1    0
[8,]    1    0
[9,]    1    0
[10,]   1    0
[11,]   1    0
[12,]   1    0
[13,]   1    0
[14,]   1    0
[15,]   1    0
[16,]   1    0
[17,]   0    1
[18,]   0    1
[19,]   0    1
[20,]   0    1
[21,]   0    1
[22,]   0    1
[23,]   0    1
[24,]   0    1
[25,]   0    1
[26,]   0    1
[27,]   0    1
[28,]   0    1
[29,]   0    1
[30,]   0    1
[31,]   0    1
[32,]   0    1
> testLabels
      [,1] [,2]
[1,]    1    0
[2,]    1    0
[3,]    1    0
[4,]    1    0
[5,]    0    1
[6,]    0    1
[7,]    0    1
[8,]    0    1
```

Gambar 7. Pelabelan Dataset *training* dan *testing* (sumber: hasil olahan penulis)

3. Pemodelan CNN

Model CNN yang dibangun pada penelitian ini menggunakan *Max Pooling* 2 x 2 dan tanpa menggunakan Teknik *Padding* (*Padding* = 0). Pada *summary model* digambarkan ada 4 Layer. Inputan berukuran 32x32x3 (32x32 pixel dengan *Kernel* sebanyak 3). Dengan menggunakan fungsi aktivasi *Relu-Softmax* maka Layer pertama berukuran 30x30, filter 32 menghasilkan Layer 2 dengan ukuran 28x28 filter 32. Selanjutnya dilakukan *Pooling* dan *Dropout* pada layer 2 dan menghasilkan Layer 3 dengan ukuran 14x14 filter 64. Layer 4 yang dihasilkan berukuran 10x10 filter 64 akan masuk ke layer *Pooling* dan *Dropout* sehingga menghasilkan *Output* 5x5 dengan filter 64

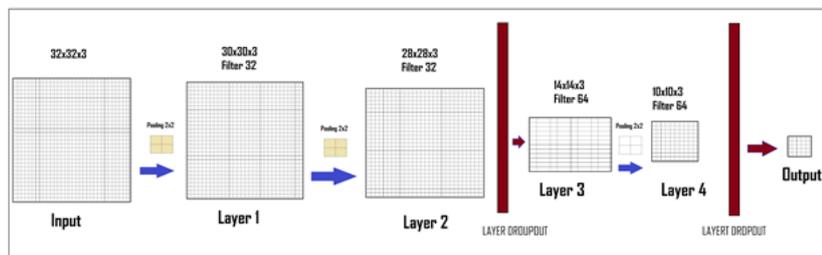
```
> summary(mode1)
```

Layer (type)	Output Shape	Param #
conv2d_24 (Conv2D)	(None, 30, 30, 32)	896
conv2d_25 (Conv2D)	(None, 28, 28, 32)	9248
max_pooling2d_12 (MaxPool2D)	(None, 14, 14, 32)	0
dropout_18 (Dropout)	(None, 14, 14, 32)	0
conv2d_26 (Conv2D)	(None, 12, 12, 64)	18496
conv2d_27 (Conv2D)	(None, 10, 10, 64)	36928
max_pooling2d_13 (MaxPool2D)	(None, 5, 5, 64)	0
dropout_19 (Dropout)	(None, 5, 5, 64)	0
dense_12 (Dense)	(None, 256)	409856
dropout_20 (Dropout)	(None, 256)	0
dense_13 (Dense)	(None, 2)	514

=====
 Total params: 475,938
 Trainable params: 475,938
 Non-trainable params: 0
 =====

Gambar 8. Summary Model (sumber: hasil olahan penulis)

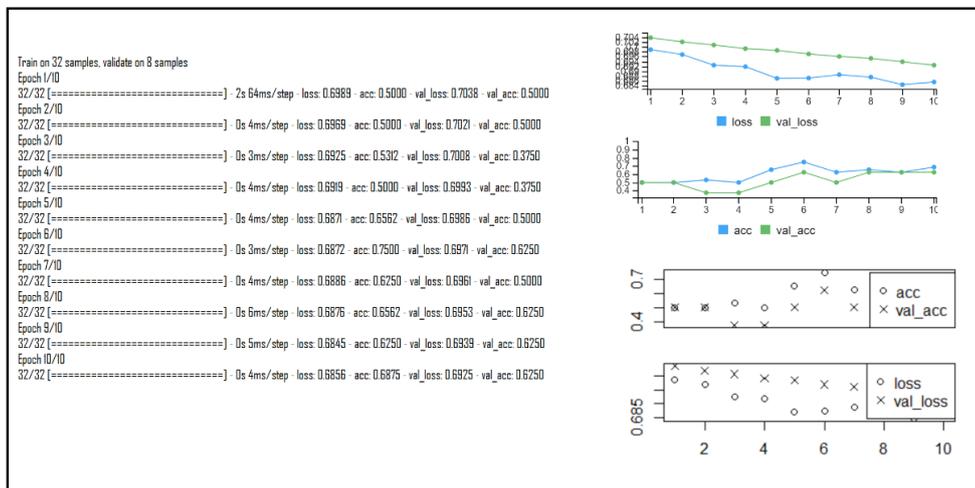
Dan menghasilkan struktur CNN pada penelitian ini ditunjukkan dalam gambar 9.



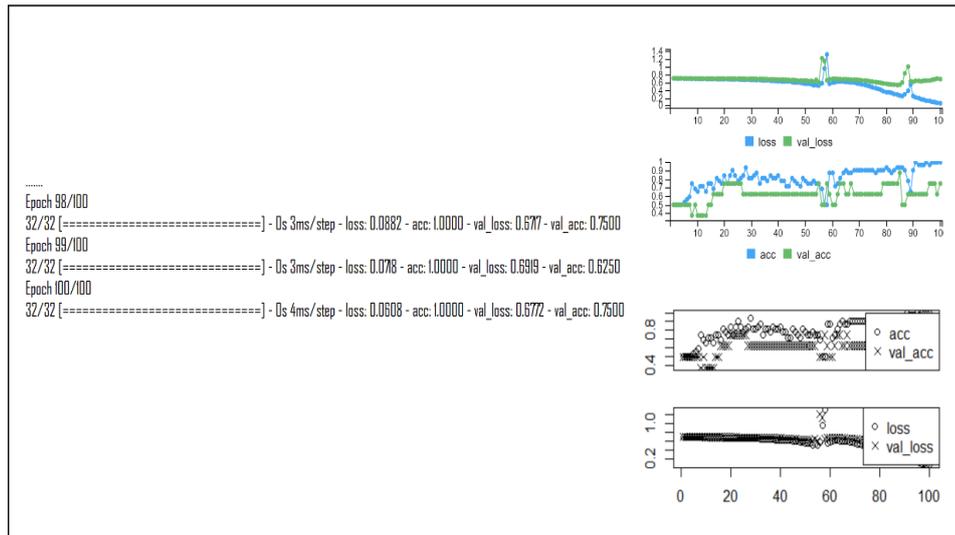
Gambar 9. Struktur CNN pada penelitian ini (sumber: hasil olahan penulis)

4. Pelatihan dan *Fitting* Model

Pelatihan data pada penelitian dianalisis dengan menggunakan hasil dari epoch yaitu 10, 70, dan 100 untuk melihat perbedaan dari setiap pelatihan. *Rate dropout* yang digunakan sebesar 0.01 dengan Pooling 2 x 2 serta validation split = 0.2. Hasil akurasi pelatihan tiap epoch digambarkan melalui gambar 10a dan 10b.

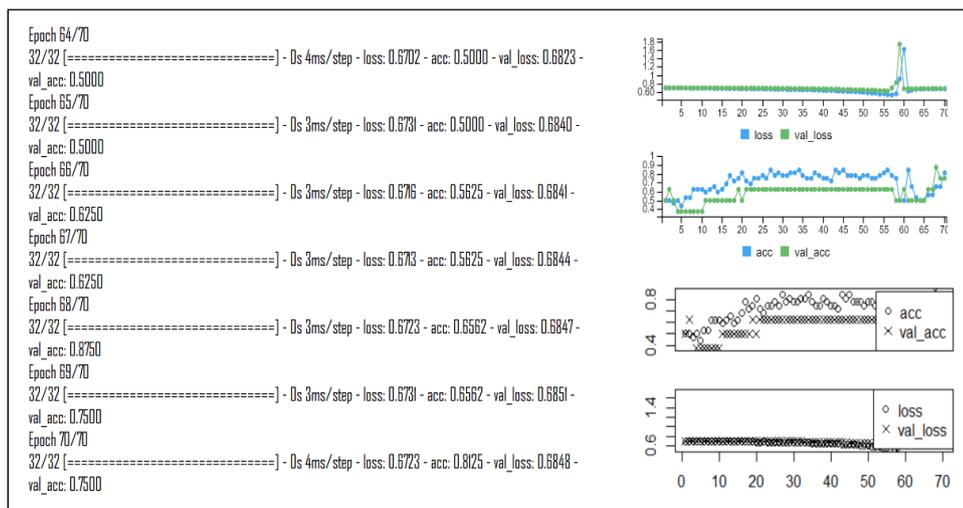


Gambar 10a. Nilai dan Plot Akurasi dan Kesalahan Model pada Epoch 10 (sumber: hasil olahan penulis)



Gambar 10b. Nilai dan Plot Akurasi dan Kesalahan Model pada Epoch 100 (sumber: hasil olahan penulis)

Pada Plot Akurasi dan Kesalahan Epoch 100 terlihat bahwa terjadi perubahan signifikan pada epoch antara 50 dan 60 untuk kesalahan model sedangkan epoch antara 60 dan 70 untuk akurasi model. Sehingga peneliti mencoba melakukan analisis ulang pada model di epoch 70, seperti terlihat di gambar 11. Sedangkan Rangkuman nilai dan kesalahan model tiap epoch terdapat pada tabel 2.



Gambar 11. Nilai dan Plot Akurasi dan Kesalahan Model pada Epoch 70 (sumber: hasil olahan penulis)

Tabel 2. Perbedaan Nilai Akurasi dan Kesalahan Model Tiap Epoch

Epoch	Akurasi	Loss (Kesalahan)
10	0.6875	0.6856
70	0.8125	0.6723
100	1.0000	0.6008

Dari hasil epoch 10, 70, dan 100 diketahui bahwa model pada penelitian ini cukup baik (*fit*) saat dilakukan pelatihan (*training*) lebih dari 70 epoch. Dengan demikian model dapat digunakan untuk evaluasi prediksi pada data *training* dan data *testing*.

5. Evaluasi & Prediksi Data Train dan Data Test

Berdasarkan hasil epoch 10, 70 dan 100 maka diperoleh evaluasi prediksi dari masing-masing epoch. Epoch 10 menghasilkan akurasi 0.656 dan loss 0.687 pada data *training*. Hasil prediksi data *training* yang diperoleh 12 gambar domba teridentifikasi sebagai Domba selain itu ada 4 gambar domba yang teridentifikasi sebagai Kambing. Dan 9 gambar Kambing berhasil teridentifikasi sebagai Kambing selain itu ada 7 gambar Kambing teridentifikasi sebagai Domba. Pada data *testing* diperoleh akurasi sebesar 0.5 dan Loss 0.693, diidentifikasi 2 gambar domba sebagai Domba sedangkan 2 lainnya sebagai Kambing dan 3 gambar Kambing sebagai Kambing sedangkan 1 lainnya sebagai Domba.

Epoch 70 menghasilkan akurasi 0.84375 dan loss 0.5909 pada data *training*. Hasil prediksi data *training* yang diperoleh 12 gambar domba teridentifikasi sebagai Domba selain itu ada 4 gambar domba yang teridentifikasi sebagai Kambing. Dan 15 gambar Kambing diidentifikasi sebagai Kambing selainnya 1 gambar sebagai Domba. Pada data *testing* diperoleh akurasi sebesar 0.875 dan loss 0.640, diidentifikasi 4 gambar domba sebagai domba dan 3 gambar Kambing diidentifikasi sebagai Kambing sedangkan 1 gambar kambing sebagai Domba.

Terakhir pada epoch 100 menghasilkan akurasi 1.00 dan loss 0.02 pada data *training*. Hasil prediksi data *training* yang diperoleh yaitu semua gambar Domba teridentifikasi sebagai Domba dan semua gambar Kambing teridentifikasi sebagai Kambing. Sedangkan pada data *testing* memiliki akurasi 0.875 dan loss 0.593 dengan hasil prediksi data test bahwa 4 gambar domba teridentifikasi sebagai Domba dan 3 gambar Kambing sebagai Kambing. Hasil rangkuman dijabarkan dalam tabel 3.

Tabel 3. Hasil evaluasi prediksi Data *training* dan Data *testing*

Epoch	Data Train				Data Test			
	Akurasi	Loss	Prediksi	Actual	Actual	Loss	Prediksi	Actual
10	0.656	0.687	0 1 1 0 0 0 1 0 0 1 0 0 0 0 0 0 0 0 0 1 1 0 0 1 0 1 0 1 1 1 1 1	0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1	0.5	0.693976	0 1 1 0 0 0 1 1	0 0 0 0 1 1 1 1
70	0.84375	0.5909	1 0 1 0 0 0 0 1 0 0 1 0 0 0 0 0 1 1 0 1 1 1 1 1 1 1 1 1 1 1 1 1	0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1	0.875	0.64039	0 0 0 0 1 0 1 1	0 0 0 0 1 1 1 1
100	1	0.0289	0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1	0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1	0.875	0.593	0 0 0 0 1 0 1 1	0 0 0 0 1 1 1 1

3.2 Pembahasan Model CNN

Dalam pelatihan (*training*) dengan epoch 10, 70 dan 100 terlihat akurasi menjadi lebih baik setelah epoch ke 70 meskipun kesalahan (*Loss*) terkadang berubah secara drastis namun signifikan mendekati 0. Hasil evaluasi terlihat jelas bahwa akurasi data *training* dengan *testing* ada perbedaan, meskipun demikian semua signifikansi bergerak mendekati 1 pada akurasi dan 0 pada kesalahan. Dalam tabel 3, terlihat bahwa prediksi data *training* saat epoch 70 dan 100 memiliki akurasi yang tepat dengan data aktualnya. Hal ini memperkuat bahwa model yang digunakan baik (*fit*) terhadap dataset *training*, akan tetapi pada saat diterapkan pada dataset *testing*, hasil prediksi belum mendekati sempurna. Epoch 70 mengidentifikasi ada 1 Gambar Kambing yang dikenali sebagai Domba begitu juga pada Epoch 100, meskipun pada epoch 10 belum berhasil dikenali atau diidentifikasi karena akurasi yang masih rendah. Hal ini menyebabkan adanya kekhawatiran bahwa dataset *testing* yang digunakan memiliki kesalahan. Jika diperhatikan kembali Gambar 6b, gambar kambing yang teridentifikasi sebagai domba yaitu kambing kedua (dalam gambar 12).



Gambar 12. Kambing yang teridentifikasi sebagai Domba (sumber: hasil olahan penulis)

Hal ini dimungkinkan karena Kambing tersebut mungkin saja merupakan persilangan dengan domba sehingga teridentifikasi sebagai domba karena memiliki bulu yang cukup lebat tidak seperti seekor kambing pada umumnya.

4. PENUTUP

Berdasarkan dari hasil dan pembahasan yang telah dijabarkan, Epoch 70 menghasilkan akurasi 0.84375 dan loss 0.5909 pada data training dan akurasi hasil data *testing* sebesar 0.875 dan loss 0.640. Sedangkan pada epoch 100 menghasilkan akurasi 1.00 dan loss 0.02 pada data *training* dengan data *testing* memiliki akurasi 0.875 dan loss 0.593. Maka peneliti menyimpulkan bahwa terlihat jelas bahwa akurasi data *training* dengan *testing* memang memiliki perbedaan, meskipun signifikan mendekati 1 untuk akurasi dan 0 pada error. Hal ini memperkuat bahwa algoritme *Convolution Neural Network* (CNN) dapat digunakan untuk mengidentifikasi Kambing dan Domba melalui penangkapan citra sehingga Kambing dan Domba pada suatu daerah dapat dibedakan dengan cepat karena akurasi yang tinggi dan kesalahan yang rendah. Ide selanjutnya yang dapat dikembangkan, tidak hanya sebagai prediksi pengenalan atau klasifikasi melainkan juga sebagai perhitungan cepat populasi Kambing dan Domba melalui *Image Processing* dengan menggunakan Algoritme CNN.

UCAPAN TERIMAKASIH

Kami ingin menyampaikan terima kasih kepada Departemen Ilmu Komputer, Institut Pertanian Bogor, terutama kepada Dr.Eng. Wisnu Ananta Kusuma, S.T., M.T yang telah memberikan dukungan untuk melakukan dan menyelesaikan studi ini.

DAFTAR PUSTAKA

- [1] A. Argüello, "Trends in goat research, a review," *J. Appl. Anim. Res.*, vol. 39, no. 4, pp. 429–434, 2011, doi: 10.1080/09712119.2011.637362.
- [2] A. Maesya and S. Rusdiana, "Prospek Pengembangan Usaha Ternak Kambing dan Memacu Peningkatan Ekonomi Peternak," *Agriekonomika*, vol. 7, no. 2, p. 135, 2018, doi: 10.21107/agriekonomika.v7i2.4459.
- [3] dan Adiati, L. Praharani, and S. Rusdiana, "Prospek Dan Strategi Perdagangan Ternak Kambing Dalam Merebut Peluang Pasar Dunia," *Agriekonomika*, vol. 3, no. 2, pp. 203–222, 2014.
- [4] N. Rasminati, "Grade Kambing Peranakan Ettawa pada Kondisi Wilayah yang Berbeda," *Sains Peternak.*, vol. 12, no. 1, p. 43, 2017, doi: 10.20961/sainspet.v11i1.4856.
- [5] Ditjen PKH and K. Pertanian, "Penuhi Protein Hewani, Kementan Tambah Jumlah Kambing Saanen," 2020. .
- [6] I. Daskiran *et al.*, "Goat production systems of Turkey: Nomadic to industrial," *Small Rumin. Res.*, vol. 163, no. March, pp. 15–20, 2018, doi: 10.1016/j.smallrumres.2017.10.001.
- [7] B. Winarso, "Prospek dan Kendala Pengembangan Agribisnis Ternak Kambing dan Domba di Indonesia," pp. 246–264, 2010.
- [8] S. R. dan U. A. Broto Wibow, "Pemasaran Ternak Domba Di Pasar Hewan Palasari Kabupaten Indramayu," *Agriekonomika*, vol. 5, pp. 85–93, 2016.
- [9] B. A. Kaufmann, C. G. Hülsebusch, and S. Krätli, *Pastoral livestock systems*, vol. 3. Elsevier, 2018.
- [10] C. Rojo-Gimeno, M. van der Voort, J. K. Niemi, L. Lauwers, A. R. Kristensen, and E. Wauters, "Assessment of the value of information of precision livestock farming: A conceptual framework," *NJAS - Wageningen J. Life Sci.*, vol. 90–91, no. November 2018, p. 100311, 2019, doi: 10.1016/j.njas.2019.100311.
- [11] P. O. Skobelev, E. V. Simonova, S. V. Smirnov, D. S. Budaev, G. Y. Voshchuk, and A. L. Morokov, "Development of a knowledge base in the 'smart farming' system for agricultural enterprise management," *Procedia Comput. Sci.*, vol. 150, pp. 154–161, 2019, doi: 10.1016/j.procs.2019.02.029.
- [12] I. Sneessens, L. Sauvée, H. Randrianasolo-Rakotobe, and S. Ingrand, "A framework to assess the

- economic vulnerability of farming systems: Application to mixed crop-livestock systems,” *Agric. Syst.*, vol. 176, no. August 2018, p. 102658, 2019, doi: 10.1016/j.agsy.2019.102658.
- [13] M. Liang and X. Hu, “Recurrent convolutional neural network for object recognition,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 07-12-June, no. Figure 1, pp. 3367–3375, 2015, doi: 10.1109/CVPR.2015.7298958.
- [14] A. Santoso and G. Ariyanto, “Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah,” *Emit. J. Tek. Elektro*, vol. 18, no. 01, pp. 15–21, 2018, doi: 10.23917/emit.v18i01.6235.
- [15] M. Zufar and B. Setiyono, “Convolutional Neural Networks Untuk Pengenalan Wajah Secara Real-time,” *J. Sains dan Seni ITS*, vol. 5, no. 2, p. 128862, 2016.
- [16] M. Duan, K. Li, C. Yang, and K. Li, “A hybrid deep learning CNN–ELM for age and gender classification,” *Neurocomputing*, vol. 275, pp. 448–461, 2018, doi: 10.1016/j.neucom.2017.08.062.
- [17] A. A. M. A-Saffar, H. Tao, and M. A. Talab, “Review of Deep Convolution Neural Network in Image Classification,” in *International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications Review*, 2017, pp. 26–31.
- [18] O. Guzhva, H. Ardö, M. Nilsson, A. Herlin, and L. Tufvesson, “Now You See Me : Convolutional Neural Network Based Tracker for Dairy Cows,” *Front. Robot. AI*, vol. 5, no. September, pp. 1–9, 2018, doi: 10.3389/frobt.2018.00107.
- [19] J. Rodríguez *et al.*, “Body condition estimation on cows from depth images using Convolutional Neural Networks,” *Comput. Electron. Agric.*, vol. 155, no. September, pp. 12–22, 2018, doi: 10.1016/j.compag.2018.09.039.
- [20] Z. Li, S. Shen, C. Ge, and X. Li, “Cow Individual Identification Based on Convolutional Neural Network,” in *ACAI’18*, 2018.
- [21] W. Shen *et al.*, “Individual identification of dairy cows based on convolutional neural networks,” *Multimed. Tools Appl.*, 2019.
- [22] B. Achour, M. Belkadi, I. Filali, and M. Laghrouche, “ScienceDirect Image analysis for individual identification and feeding behaviour monitoring of dairy cows based on Convolutional Neural Networks (CNN),” *Biosyst. Eng.*, vol. 198, pp. 31–49, 2020, doi: 10.1016/j.biosystemseng.2020.07.019.
- [23] J. R. Alvarez *et al.*, “Estimating Body Condition Score in Dairy Cows From Depth Images Using Convolutional Neural Networks , Transfer Learning and Model Ensembling Techniques,” *Agronomy*, 2018, doi: 10.3390/agronomy9020090.
- [24] C. Zuo, L. Han, P. Tao, and X. L. Meng, “Livestock Detection Based on Convolutional Neural Network,” in *ICCCV’20*, 2020, pp. 1–6.
- [25] L. Han, P. Tao, and R. R. Martin, “Livestock detection in aerial images using a fully convolutional network,” *Computational Visual Media*. Springer, pp. 1–8, 2019.
- [26] F. Sarwar, A. Griffin, P. Periasamy, K. Portas, and J. Law, “Detecting and Counting Sheep with a Convolutional Neural Network,” in *15th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, 2018, no. 1, pp. 1–6.
- [27] and S. Z. L. Xuezhi Liang, Xiaobo Wang, Zhen Lei, Shengcai Liao, “Soft-Margin Softmax for Deep Classification,” in *International Conference on Neural Information Processing*, 2017, vol. 3, no. October, pp. 118–125, doi: 10.1007/978-3-319-70096-0.