

Implementasi *Deep Learning* Menggunakan Metode *Convolutional Neural Network* untuk Mendeteksi Kehalalan pada Kosmetik

Hafsah Qonita^{1*}, Pringgo Widyo Laksono², dan Yusuf Priyandari³

¹ Program Studi Teknik Industri, Fakultas Teknik, Universitas Sebelas Maret,
Jl. Ir Sutami 36A Surakarta 57126 Indonesia

Email: hafsahqonita04@student.uns.ac.id¹ pringgo@ft.uns.ac.id², priyandari@ft.uns.ac.id³

Abstrak

Tingkat pertumbuhan industri kosmetik menunjukkan perkembangan yang baik yaitu mencapai 9,39% pada tahun 2020. Dengan banyaknya produk kosmetik yang beredar, maka konsumen harus lebih teliti dalam memilih produk yang digunakan. Selain faktor keamanan, kehalalan pada kosmetik juga perlu diperhatikan, terutama bagi konsumen muslim. Penelitian ini bertujuan untuk membuat model deteksi kehalalan pada kosmetik dengan mengimplementasikan *deep learning* menggunakan metode *convolutional neural network* (CNN). Penelitian sebelumnya telah berhasil membuat model deteksi kehalalan pada kosmetik korea menggunakan CNN dengan tingkat akurasi 95,56%. Penelitian ini bermaksud mengembangkan penelitian sebelumnya dengan menambahkan kelas dan jumlah *dataset*. CNN akan dimanfaatkan untuk membuat model deteksi kehalalan pada kosmetik dengan mempelajari fitur-fitur *input* berupa potongan gambar kandungan kosmetik untuk mengetahui kehalalannya. Klasifikasi dilakukan berdasarkan dua kelas yaitu Halal dan *Syubhat*. Hasil penelitian menunjukkan model CNN yang dirancang mendapatkan nilai *accuracy* sebesar 98,66% dengan *loss* 0,0615 dalam mengklasifikasikan kehalalan kosmetik. Pengujian model menggunakan *dataset testing* mendapatkan nilai *accuracy* sebesar 98,67%. Nilai *F1-score* pada masing-masing kelas adalah 98,66% untuk kelas halal dan 98,67 untuk kelas *syubhat*. Model CNN yang dibangun dikatakan layak karena menunjukkan nilai akurasi yang tinggi dan *loss* yang rendah pada data *training*, *validation*, dan *testing* tanpa mengalami *overfitting* atau *underfitting*.

Kata Kunci: Kosmetik, Halal, *Convolutional Neural Network* (CNN)

Abstract

The growth rate of the cosmetics industry shows good development, reaching 9.39% in 2020. With so many cosmetic products in the market, consumers must be more careful in choosing the cosmetic products. In addition to the safety factor, the halalness of cosmetics also needs to be considered, especially for Muslim consumers. This research aims to create a halal detection model in cosmetics by implementing one of the deep learning methods, namely convolutional neural network (CNN). Previous research has successfully created a halal detection model on Korean cosmetics using CNN with an accuracy rate of 95.56%. This research intends to develop previous research by adding classes and the number of datasets. CNN will be used to create a halal detection model in cosmetics by learning the input features in the form of the image of cosmetic ingredient to determine its halalness. Classification is done based on two classes, which are Halal and Shubhat. The results show that the CNN model gets an accuracy value of 98.66% with a loss of 0.0615 in classifying the halalness of cosmetics. Model testing using the testing dataset gets an accuracy value of 98.67%. The F1-score value in each class is 98.66% for the halal class and 98.67 for the shubhat class. The CNN model that has been created is appropriate because it shows high accuracy and low loss on training, validation, and testing data without experiencing overfitting or underfitting.

Keywords: Cosmetic, Halal, *Convolutional Neural Network*

1. Pendahuluan

Industri kimia, farmasi, dan obat tradisional (termasuk kosmetik) mengalami pertumbuhan yang baik sebesar 9,39% pada tahun 2020 (Kementerian Perindustrian, 2021). Hal ini disebabkan oleh meningkatnya gaya hidup, penggunaan media sosial, kesadaran akan pentingnya perawatan kulit, dan anggapan bahwa penampilan dan kecantikan adalah hal yang penting dalam kehidupan. Kini semakin banyak produk kosmetik yang beredar di pasaran, sehingga konsumen harus lebih teliti dalam memilih produk

kosmetik karena penting untuk memperhatikan kandungan kosmetik yang aman untuk digunakan. Selain faktor keamanan, kehalalan produk kosmetik juga penting untuk diperhatikan, terutama bagi konsumen muslim.

Saat ini populasi muslim di Indonesia mencapai 229,62 juta jiwa yaitu sekitar 87,2% dari seluruh penduduk Indonesia (Matsuki, 2020). Sebagai negara mayoritas muslim, sudah sepatutnya lebih memperhatikan perihal halal dan haram pada produk yang beredar. Berdasarkan survey, faktor kehalalan

* Penulis korespondensi

mendapatkan nilai 51% dari faktor pertimbangan membeli kosmetik (Yanti, 2018). Dengan melihat jumlah penduduk muslim di Indonesia, angka tersebut masih menunjukkan bahwa kesadaran masyarakat dalam memperhatikan kehalalan kosmetik yang dipakai masih rendah.

Pemerintah Indonesia telah menetapkan lembaga yang berwenang untuk menentukan kehalalan suatu produk, yaitu Majelis Ulama Indonesia (MUI). Namun, menurut MUI, masih banyak produk kosmetik yang belum bersertifikat halal, terutama produk impor, perlu diperhatikan status kehalalannya (Nadha, 2021). Masyarakat diharuskan untuk membaca dan memperhatikan bahan-bahan yang terkandung dalam produk tersebut untuk memastikan bahwa produk yang digunakannya halal. Kurangnya kesadaran masyarakat dalam memperhatikan status kehalalan kosmetik dikarenakan masyarakat tidak mengetahui bahan-bahan yang terkandung dalam kosmetik tersebut termasuk mengenai kehalalannya. Oleh karena itu, diperlukan suatu alat bantu yang memudahkan konsumen untuk mengetahui apakah kandungan yang ada di dalam kosmetik tersebut halal atau *syubhat*.

Metode deep learning yaitu *convolutional neural network* (CNN) akan digunakan sebagai pendekatan untuk mengatasi permasalahan yang telah diuraikan. CNN memiliki keunggulan dalam memproses dan menganalisis data berupa teks, gambar, dan suara secara efisien. CNN akan digunakan untuk membuat model deteksi kehalalan kosmetik dengan mempelajari fitur-fitur dari *input* berupa potongan gambar kandungan kosmetik untuk menentukan status kehalalannya.

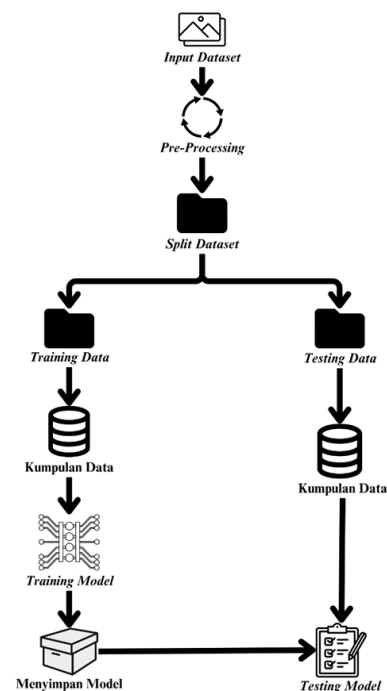
CNN telah diterapkan dalam berbagai bidang seperti dalam mendeteksi jenis sampah (Stephen et al., 2019), mengenali ekspresi manusia (Adi Nugroho et al., 2020), mengidentifikasi jenis tanaman (Ilahiyah & Nilogiri, 2018) merekomendasikan tiket pesawat (Heidari & Rafatirad, 2020), mendeteksi kehalalan pada kemasan makanan (Fadhilah et al., 2018), dan lain-lain. Pada tahun 2022, penelitian berhasil menerapkan CNN dalam deteksi kehalalan pada kosmetik Korea dengan akurasi sebesar 95,56% menggunakan *dataset* berupa potongan gambar kandungan pada komposisi kosmetik dengan label *syubhat* (Ramdania et al., 2022). Meskipun hasil tersebut menunjukkan kemajuan yang signifikan dalam mendeteksi kehalalan produk kosmetik, namun perlu diperhatikan bahwa salah satu kelemahan dalam penelitian tersebut adalah kurangnya *dataset* dimana penelitian belum menggunakan *dataset* yang secara spesifik mencantumkan kandungan halal pada kosmetik. Penelitian ini bermaksud untuk mengisi kesenjangan tersebut dan meningkatkan kinerja model dengan menambahkan kelas dan jumlah *dataset*. Berikut tabel 1 merupakan perbandingan penelitian sebelumnya.

Table 1. Perbandingan Penelitian

| Penelitian | Objek Penelitian | Kelas | Jumlah Data | Jumlah Layer | Optimizer |
|-----------------------|--------------------------------------|-------------------|-------------|--------------|-----------|
| Ramdania et al., 2022 | Kandungan Kosmetik Berbahasa Korea | Halal | 900 | 4 Layer | ADAM |
| Penelitian ini | Kandungan Kosmetik Berbahasa Inggris | Halal dan Syubhat | 3000 | 6 Layer | ADAM |

2. Metode Penelitian

Dalam penelitian ini, metodologi *Convolutional Neural Network* (CNN) digunakan sebagai pendekatan utama untuk menganalisis dan mengolah data. Bagian ini akan memaparkan langkah-langkah yang dilakukan dalam merancang, melatih, dan menguji model CNN untuk mendeteksi kehalalan pada kosmetik. Gambar 1 menunjukkan ilustrasi alur kerja dari model deteksi kehalaln pada kosmetik yang dibuat pada penelitian ini.



Gambar 1. Rancangan Model Deteksi Kehalalan Kosmetik

2.1. Pengumpulan *Dataset*

Dataset yang digunakan dalam penelitian ini adalah kumpulan potongan gambar bahan kosmetik dengan status halal dan *syubhat* dalam format .jpeg. Dari berbagai macam bahan kosmetik tersebut, berikut ini pada tabel 2 adalah rincian bahan halal dan *syubhat* yang digunakan dalam penelitian ini (Jaswir et al., 2020).

Tabel 2. Dataset

| No. | Nama bahan | Status Kehalalan |
|-----|----------------------------|------------------|
| 1. | <i>Cetyl Alcohol</i> | Halal |
| 2. | <i>Jojoba Oil</i> | Halal |
| 3. | <i>Methylparaben</i> | Halal |
| 4. | <i>Phosporic Acid</i> | Halal |
| 5. | <i>Propylene Glycol</i> | Halal |
| 6. | <i>Propylparaben</i> | Halal |
| 7. | <i>Salicylic Acid</i> | Halal |
| 8. | <i>Silica</i> | Halal |
| 9. | <i>Sodium Benzoate</i> | Halal |
| 10. | <i>Sodium Fluoride</i> | Halal |
| 11. | <i>Sodium Saccharin</i> | Halal |
| 12. | <i>Sorbitol</i> | Halal |
| 13. | <i>Titanium Dioxide</i> | Halal |
| 14. | <i>Water</i> | Halal |
| 15. | <i>Xylitol</i> | Halal |
| 16. | <i>AHA</i> | Syubhat |
| 17. | <i>Allantoin</i> | Syubhat |
| 18. | <i>Collagen</i> | Syubhat |
| 19. | <i>Elastin</i> | Syubhat |
| 20. | <i>Ethanol</i> | Syubhat |
| 21. | <i>Fragrance</i> | Syubhat |
| 22. | <i>Glycerin</i> | Syubhat |
| 23. | <i>Hydrolized Keratin</i> | Syubhat |
| 24. | <i>Hydrolized Collagen</i> | Syubhat |
| 25. | <i>Lanolin</i> | Syubhat |
| 26. | <i>Lecithin</i> | Syubhat |
| 27. | <i>Tretinoin</i> | Syubhat |
| 28. | <i>Vitamin A</i> | Syubhat |
| 29. | <i>Vitamin E</i> | Syubhat |
| 30. | <i>Xanthan Gum</i> | Syubhat |

2.2. Pre-processing Image

Pre-processing image diperlukan untuk mempersiapkan gambar sehingga sesuai dengan model yang dibangun. *Pre-processing* akan membuat model

menjadi lebih efektif dan efisien dalam mengekstraksi fitur dan melakukan proses klasifikasi atau deteksi terhadap gambar yang diberikan. Ada beberapa tahapan dalam *pre-processing image* yang dilakukan pada penelitian ini, yaitu *grayscale*, *resize*, dan normalisasi.

a. Grayscale

Citra berwarna memiliki tiga komponen warna yaitu *red*, *green*, *blue* (RGB) pada setiap pikselnya. Sedangkan citra *grayscale* hanya memiliki satu komponen warna yang akan mengurangi kompleksitas data dan memungkinkan CNN untuk fokus pada fitur-fitur penting pada citra. *Dataset* yang telah dikumpulkan diubah menjadi *grayscale* menggunakan `cv2.cvtColor()` untuk mengurangi kompleksitas dan dimensi data.

b. Resize

Gambar diperoleh dari berbagai sumber dengan ukuran yang berbeda-beda. Oleh karena itu, mengubah ukuran gambar menjadi ukuran yang sama akan menyederhanakan proses *training* model. Untuk menghindari distorsi, tahap perubahan ukuran dilakukan dengan mempertahankan rasio aspek gambar asli. Gambar yang sudah melalui tahap *grayscale* akan diubah menjadi ukuran 30x90 piksel menggunakan `cv2.resize`.

c. Normalisasi

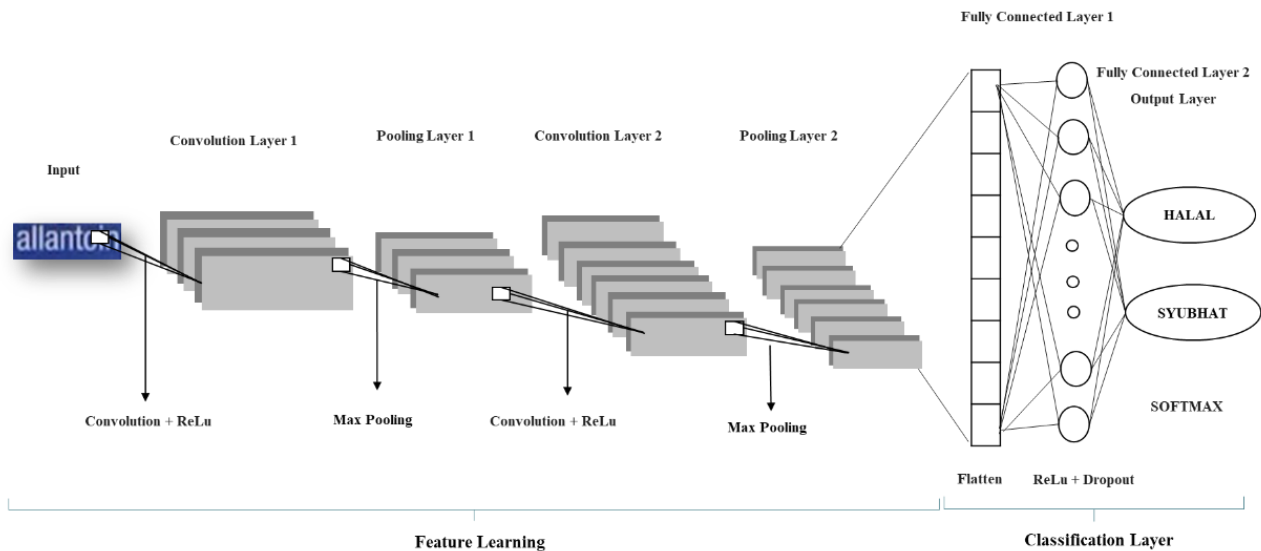
Normalisasi data dilakukan untuk meningkatkan performa model CNN dengan membantu algoritma *machine learning* bekerja lebih cepat. Setiap piksel pada gambar dibagi dengan 255 untuk mengubah nilai piksel dari rentang 0-255 menjadi rentang 0-1.

2.3. Split Dataset

Dalam metode CNN, *dataset* perlu dibagi menjadi *dataset training dan testing*. Skenario data perlu dibuat untuk menghasilkan pembagian data yang konsisten setiap kali kode dijalankan. Beberapa langkah yang umum digunakan dalam pemrosesan data sebelum melatih model meliputi, konversi label ke *One-Hot Encoding*, konverdi data dan label ke *Array-Numpy*, pembagian data menjadi *training dan testing*, dan pembagian set pengujian menjadi *validation dan testing*.

2.4. Perancangan Arsitektur Model CNN

Arsitektur jaringan pada CNN yang dirancang akan mempengaruhi hasil dan akurasi dari model yang dibuat. Perancangan model CNN umumnya terdiri dari dua tahapan yaitu *feature learning dan classification layer*. Gambar 2 merupakan arsitektur jaringan CNN yang akan dirancang pada penelitian ini.



Gambar 2. Arsitektur CNN

2.5. Proses Training Pembentukan Model

Setelah merancang arsitektur model CNN, tahap selanjutnya adalah melakukan proses *training* pembentukan model berdasarkan model yang telah dibuat. Proses *training* sangat penting dalam melakukan pengenalan pola dan prediksi. Salah satu aspek penting dalam proses *training* model CNN adalah *Epoch*. *Epoch* menggambarkan satu siklus *training* di mana keseluruhan *Dataset training* digunakan untuk mengoptimalkan bobot dan bias dalam model. Pada setiap *Epoch*, model akan menerima input data train, menghitung nilai *loss* (kerugian) dan *accuracy* (akurasi), dan menggunakan algoritma optimisasi untuk melakukan penyesuaian yang akan memperbaiki kemampuan model. Proses ini akan berulang sesuai jumlah *Epoch* yang ditentukan. Model akan belajar secara bertahap dari *Dataset* untuk meningkatkan kinerjanya.

2.6. Proses Testing Model pada Dataset Testing

Setelah model dilatih, maka model dapat digunakan untuk melakukan prediksi terhadap data *testing* untuk menghasilkan probabilitas kelas untuk setiap *sample* data. Tahap ini akan menghasilkan tabel *confusion matrix* untuk mengevaluasi performa model dengan membandingkan label prediksi dan label sebenarnya. Setelah itu akan dibuat tabel classification report sebagai metrik evaluasi kinerja model meliputi precision, recall, f1-score, dan support untuk setiap kelas. *Confusion matrix* merupakan tabel yang dapat digunakan untuk menentukan performa dari sebuah algoritma klasifikasi. Beberapa istilah dalam menentukan nilai akurasi pada *confusion matrix* adalah *true positive (TP)*, *true negative (TN)*, *false positive (FP)*, dan *false negative (FN)*. Gambar 3 merupakan contoh *confusion matrix* yang digunakan pada klasifikasi dua kelas.

| | | Actual Values | |
|------------------|--------------|---------------|--------------|
| | | Positive (1) | Negative (1) |
| Predicted Values | Positive (1) | TP | FP |
| | Negative (1) | FN | TN |

Gambar 3. Confusion Matrix

3. Hasil dan Pembahasan

Seperti yang sudah dijelaskan sebelumnya, dalam membuat model CNN untuk mendeteksi kehalalan pada kosmetik, terdapat beberapa tahap yang harus dilakukan yaitu pengumpulan *dataset*, *split dataset*, *preprocessing image*, perancangan arsitektur model CNN, proses *training*, dan proses *testing*. Berikut merupakan hasil dan pembahasan dari tahapan yang telah dilakukan pada penelitian ini.

3.1. Pengumpulan Dataset

Tahapan pertama yang dilakukan adalah pengumpulan *dataset*. Data yang dikumpulkan dalam penelitian ini meliputi 3000 data yang terdiri dari 1500 data kandungan halal dan 1500 data kandungan *syubhat*. Setiap kelas memiliki 15 subkelas yang masing-masing berisi 100 gambar yang disimpan dalam folder dengan nama sesuai dengan kandungannya. Data potongan gambar kandungan kosmetik diperoleh melalui pengambilan foto langsung terhadap komposisi produk sebanyak 100 gambar dan observasi melalui internet pada *google image*, *website*, dan *platform* lainnya sebbanauk 2900 gambar. Pengambilan gambar melalui internet dilakukan dengan mencari kata kunci, kemudian menyimpan gambar dan menggunakan teknik *cropping* untuk memisahkan setiap kandungan kosmetik. Tabel 3 merupakan *sample dataset* pada kandungan halal dan

Tabel 4 merupakan *sample dataset* pada kandungan syubhat.

Tabel 3. Sample Dataset Halal

| No | Kandungan | Sample dataset | Jumlah |
|----|-------------------|------------------|--------|
| 1 | Cetyl Alcohol | Cetyl alcohol | 100 |
| 2 | Joboba Oil | Jojoba Oil | 100 |
| 3 | Methylparaben | Methylparaben | 100 |
| 4 | Phosporic Acid | Phosphoric Acid | 100 |
| 5 | Prophylene Glycol | PROPYLENE GLYCOL | 100 |
| 6 | Propylparaben | Propylparaben | 100 |
| 7 | Salicylic Acid | Salicylic Acid | 100 |
| 8 | Silica | SILICA | 100 |
| 9 | Sodium Benzoate | SODIUM BENZOAT | 100 |
| 10 | Sodium Fluoride | Sodium Fluoride | 100 |
| 11 | Sodium Saccharin | Sodium Saccharin | 100 |
| 12 | Sorbitol | Sorbitol | 100 |
| 13 | Titanium Dioxide | Titanium Dioxide | 100 |
| 14 | Water | Water | 100 |
| 15 | Xylitol | Xylitol | 100 |

Tabel 4. Sample Dataset Syubhat

| No | Nama bahan | Sample Dataset | Jumlah |
|----|---------------------|---------------------|--------|
| 1 | AHA | AHA | 100 |
| 2 | Allantoin | Allantoin | 100 |
| 3 | Collagen | Collagen | 100 |
| 4 | Elastin | ELASTIN | 100 |
| 5 | Ethanol | Ethanol | 100 |
| 6 | Fragrance | FRAGRANCE | 100 |
| 7 | Glycerin | Glycerin | 100 |
| 8 | Hydrolized Keratin | Hydrolyzed Keratin | 100 |
| 9 | Hydrolized Collagen | HYDROLYZED COLLAGEN | 100 |
| 10 | Lanolin | Lanolin | 100 |
| 11 | Lecithin | Lecithin | 100 |

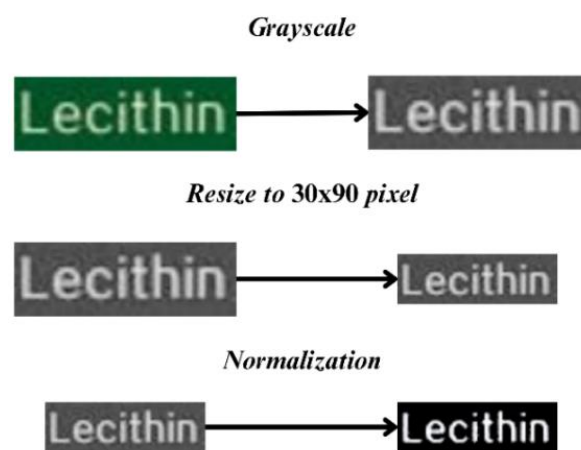
| | | | |
|----|-------------|-------------|-----|
| 12 | Tretinoin | Tretinoin | 100 |
| 13 | Vitamin A | Vitamin A | 100 |
| 14 | Vitamin E | Vitamin E | 100 |
| 15 | Xanthan Gum | Xanthan Gum | 100 |

3.2. Pre Processing Image

Pre-processing image dilakukan terhadap setiap *dataset* yang telah dikumpulkan yang terdiri dari tahap *grayscale*, *resize*, dan normalisasi gambar. *Dataset* gambar yang telah dikumpulkan diubah menjadi *grayscale* menggunakan `cv2.cvtColor()` untuk mengurangi kompleksitas dan dimensi data. Setelah itu gambar-gambar diubah menjadi ukuran 30x90 piksel menggunakan `cv2.resize`. Tahap *pre-processing* selanjutnya yaitu *pixel values* gambar dinormalisasi menjadi rentang 0-1 dengan membagi setiap piksel dengan 255. Proses dilakukan menggunakan *Google Colab* dengan algoritma yang ditunjukkan pada gambar 4. Gambar 5 merupakan contoh *pre-processing image* yang dilakukan pada kandungan lecithin yang dilakukan pada penelitian ini.

```
img = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY) # Mengubah gambar menjadi grayscale
img = cv2.resize(img, (90, 30)) # Mengubah ukuran gambar menjadi 30x90
img = img / 255.0 # Normalisasi pixel values menjadi range 0-1
```

Gambar 4. Algoritma Pre-Processing



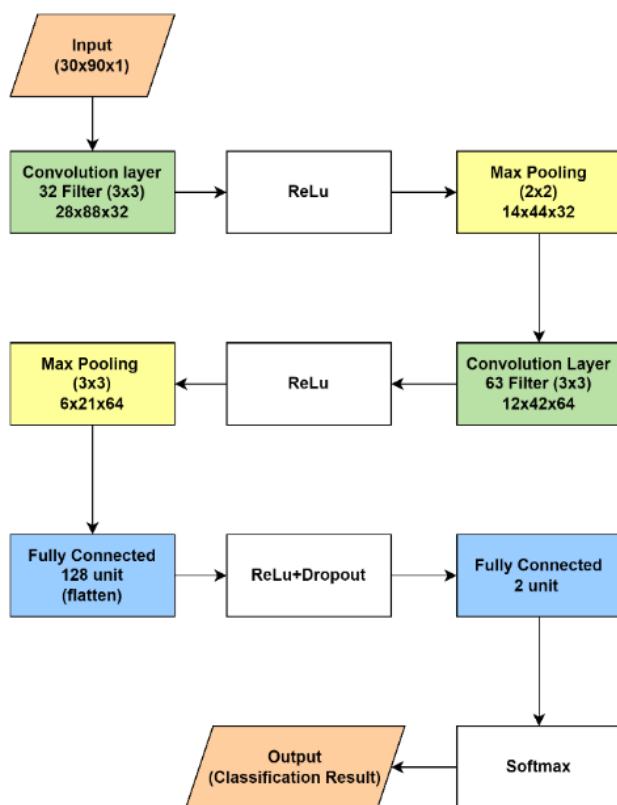
Gambar 5. Pre Processing Image

Setelah melalui tahap *pre-processing*, *Dataset* pada setiap kelas akan dibagi secara *random* dengan persentase 80% untuk data *training* dan 10% untuk data *testing* dan validasi. Tahap ini terdiri dari konversi label ke *One-Hot Encoding*, konversi data dan label ke *Array-Numpy*, pembagian data menjadi *training* dan *testing*, dan pembagian set pengujian menjadi *validation* dan *training*.

3.3. Perancangan Arsitektur Model CNN

Arsitektur jaringan pada CNN yang dirancang akan mempengaruhi hasil dan akurasi dari model yang dibuat. Salah satu aspek dalam membangun dan mengoptimalkan model CNN adalah parameter. Penentuan parameter model harus disesuaikan dengan *dataset* yang digunakan dalam penelitian karena tidak ada aturan baku mengenai hal tersebut. Parameter yang baik akan membuat model lebih efektif dalam mengekstraksi fitur dan melakukan klasifikasi yang diinginkan.

Perancangan model CNN umumnya terdiri dari dua tahapan yaitu tahap *feature learning* dan *classification layer*. Gambar 6 merupakan arsitektur yang dirancang untuk membangun model CNN yang dirancang berdasarkan pada penelitian ini menggunakan *input* gambar berukuran 30x90x1.



Gambar 6. Arsitektur Model CNN

1) Feature learning

a. Convolution Layer 1

Convolution layer pertama menggunakan 32 filter dan ukuran kernel 3x3. Ditambahkan fungsi aktivasi ReLu (*rectified linear unit*) yang berfungsi untuk menghilangkan nilai *negative* pada matriks yang dihasilkan (nilai *negative* menjadi nol). Hasil dari *convolution layer* 1 memiliki ukuran 28x88x32.

b. Pooling Layer 1

Tahap selanjutnya setelah *convolution layer* adalah *pooling layer*. Penelitian ini menggunakan *maxpooling* dengan ukuran 2x2 untuk menghasilkan matriks baru dengan nilai yang paling maksimum. Hasil dari *pooling layer* 1 memiliki ukuran 14x44x32.

c. Convolution Layer 2

Setelah tahap *pooling* dilanjutkan dengan *convolution layer* kedua dengan *input* matriks gambar 14x44. *Layer* ini menggunakan filter 64 dengan kernel 3x3. Proses ini menggunakan fungsi aktivasi ReLu dan menghasilkan *output* berukuran 12x42x64.

d. Pooling Layer 2

Setelah *convolution layer 2* dilanjutkan dengan proses *pooling*. Tahap ini menggunakan *maxpooling* dengan ukuran 2x2 dan menghasilkan *output* berukuran 6x21x64.

2) Classification Layer

a. Fully Connected Layer 1

Proses konvolusi yang dilakukan sebelumnya menghasilkan *feature maps* dengan bentuk *multidimensional array*. Pada proses *fully connected layer* agar dapat di klasifikasi, *output* dari proses konvolusi di *flatten* terlebih dahulu agar bentuknya berubah menjadi vektor yang dapat digunakan sebagai *input* untuk *layer-layer* berikutnya. *Layer* selanjutnya adalah *Dense layer* yang memiliki 128 unit dan menggunakan fungsi aktivasi ReLu. *Fully connected layer* ini bertujuan untuk melakukan ekstraksi fitur yang lebih kompleks dari representasi vektor yang dihasilkan sebelumnya. Untuk menghindari *overfitting* pada proses *training* ditambahkan *layer Dropout* dengan tingkat 0,5. Lapisan *Dropout* akan secara acak mematikan sebagian unit yang tidak akan digunakan selama proses *training*.

b. Fully Connected Layer 2 (Classification)

Tahap terakhir dari arsitektur jaringan CNN adalah tahap klasifikasi. *Layer* yang terakhir adalah *Dense layer* dengan 2 unit sesuai dengan jumlah kelas yang akan diklasifikasikan). Menggunakan fungsi aktivasi *softmax input* akan menghasilkan probabilitas untuk masing-masing kelas yang akan diklasifikasikan pada kategori yang ditentukan yaitu halal atau *syubhat*. Tabel 5 merupakan tabel model yang terbentuk dari arsitektur yang telah dirancang.

Table 5. Model CNN

| Layer (type) | Output Shape | Parameter |
|------------------------------|--------------|-----------------------------|
| Input | 30*90*1 | 0 |
| conv2d (Conv2D) | 28*88*32 | $((3*3*1)+1)*32 = 320$ |
| max_pooling2d (MaxPooling2D) | 14*44*32 | 0 |
| conv2d (Conv2D) | 12*42*64 | $((3*3*32)+1)*64 = 18496$ |
| max_pooling2d (MaxPooling2D) | 6*21*64 | 0 |
| flatten (Flatten) | 8064 | 0 |
| dense (Dense) | 128 | $((8064*128)+128 = 1032320$ |
| dropout (Dropout) | 128 | 0 |
| Output | 2 | $(128+1)*2 = 258$ |
| Total | | 1.051.394 |

Parameter-parameter yang digunakan dalam membangun model didasarkan pada eksperimen untuk

mendapatkan model dengan performansi yang optimal. Berdasarkan tabel diatas dapat diketahui total parameter yang digunakan pada model yang dibangun adalah sebanyak 1.051.394 parameter. Berikut pada persamaan 2 adalah rumus yang digunakan untuk menghitung *input* kedalam konvolusi.

$$output = input_size - (filter_size - 1) \tag{2}$$

3.4. Training Model

Setelah arsitektur model CNN dibangun, selanjutnya adalah melatih model. Proses pelatihan menggunakan *input* gambar berukuran 90x30 piksel

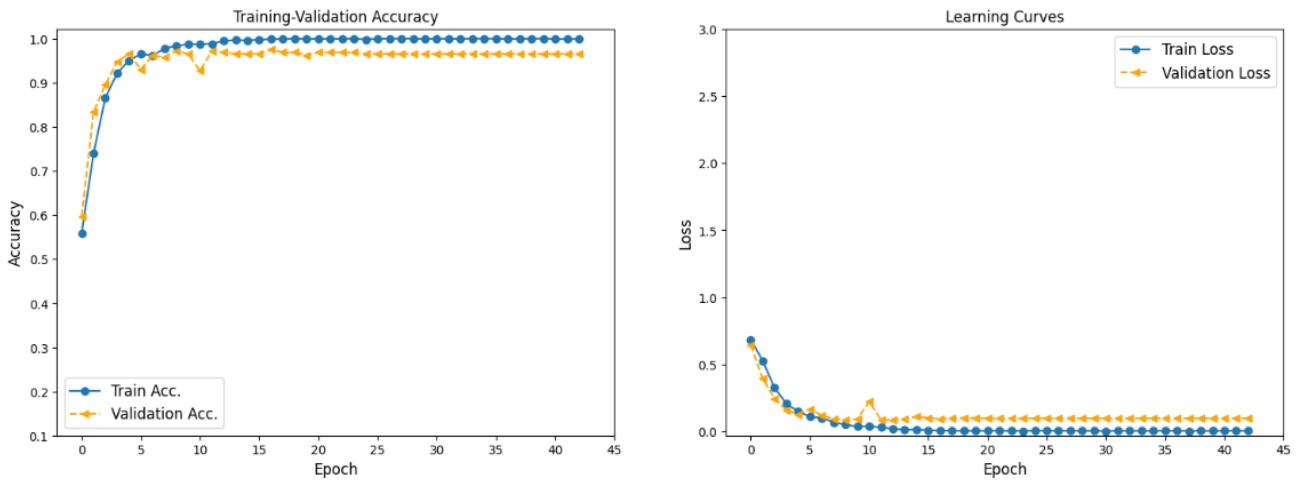
dilakukan sebanyak 50 *epoch*, batch size 32, dan menggunakan ADAM *optimizer* dengan nilai *learning rate* 0,001. Proses ini akan menghasilkan nilai *accuracy* dan *loss*, fungsi *loss* yang digunakan adalah *categorical_crossentropy* karena merupakan masalah *multiclass classification*. Fungsi *callback* yang digunakan yaitu *earlystopping*, *ReduceLROnPlateu*, dan *ModelCheckpoint*. *Earlystopping* akan menghentikan proses *training* jika tidak ada peningkatan yang dignifikan dalam *loss*, *ReduceLROnPlateu* akan mengurangi nilai *learning rate* jika tidak ada peningkatan dalam *validation loss*, dan *ModelCheckPoint* akan menyimpan bobot model terbaik berdasarkan akurasi. Gambar 7 merupakan proses *training* model CNN yang dilakukan pada penelitian ini.

```
Epoch 39: val_categorical_accuracy did not improve from 0.97569
75/75 [=====] - 0s 6ms/step - loss: 0.0054 - categorical_accuracy: 1.0000 - val_loss: 0.0992 - val_categori
Epoch 40/50
74/75 [=====>.] - ETA: 0s - loss: 0.0045 - categorical_accuracy: 1.0000
Epoch 40: val_categorical_accuracy did not improve from 0.97569
75/75 [=====] - 0s 6ms/step - loss: 0.0046 - categorical_accuracy: 1.0000 - val_loss: 0.0992 - val_categori
Epoch 41/50
72/75 [=====>..] - ETA: 0s - loss: 0.0062 - categorical_accuracy: 0.9991
Epoch 41: val_categorical_accuracy did not improve from 0.97569
75/75 [=====] - 0s 6ms/step - loss: 0.0060 - categorical_accuracy: 0.9992 - val_loss: 0.0992 - val_categori
Epoch 42/50
65/75 [=====>....] - ETA: 0s - loss: 0.0057 - categorical_accuracy: 0.9990
Epoch 42: val_categorical_accuracy did not improve from 0.97569
75/75 [=====] - 0s 6ms/step - loss: 0.0055 - categorical_accuracy: 0.9992 - val_loss: 0.0992 - val_categori
Epoch 43/50
75/75 [=====] - ETA: 0s - loss: 0.0059 - categorical_accuracy: 0.9992
Epoch 43: val_categorical_accuracy did not improve from 0.97569
75/75 [=====] - 0s 6ms/step - loss: 0.0059 - categorical_accuracy: 0.9992 - val_loss: 0.0992 - val_categori
Epoch 43: early stopping
10/10 [=====] - 0s 4ms/step - loss: 0.0615 - categorical_accuracy: 0.9867
Loss: 0.06147753447294235
Accuracy: 0.9866666793823242
```

Gambar 7. Training Epoch

Berdasarkan hasil *training epoch* pada gambar diatas, dapat dilihat bahwa proses *training* model menggunakan *dataset training* menghasilkan nilai akursi sebesar 98,66% dengan nilai *loss* 0,0614. Hal ini menunjukkan bahwa model CNN yang dibangun termasuk dalam kategori yang *fit* karena tidak mengalami

overfitting ataupun *underfitting*. Hal tersebut dapat dilihat dari performansi mododel yang tinggi dan nilai *loss* yang rendah. Gambar 8 merupakan grafik perkembangan *accuracy* dan *loss* dari model selama proses *training* dan *validation* yang ditunjukkan pada gambar.

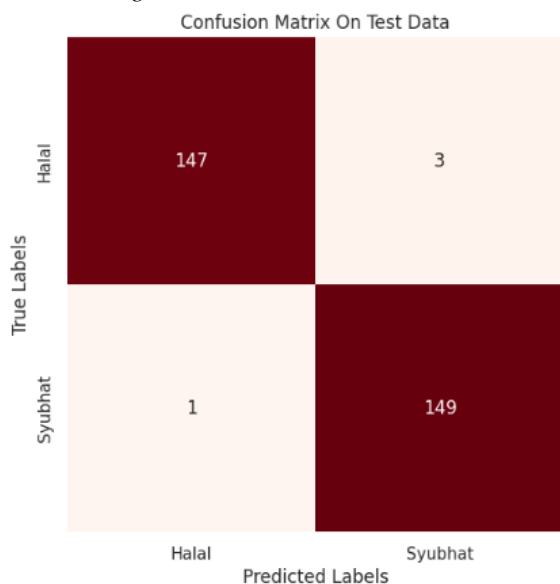


Gambar 8. Training-Validation Accuracy and Loss

Dari grafik *training-validation Accuracy* dan grafik *training-validation loss* terlihat bahwa model berhasil meningkatkan nilai akurasi dan mengurangi nilai loss secara signifikan seiring dengan meningkatnya jumlah *epoch*. Hal ini menunjukkan bahwa model secara bertahap mampu mengenali pola-pola yang ada dalam data dan dapat mengoptimalkan parameter-parameternya untuk menghasilkan prediksi yang optimal.

3.5. Testing Model

Setelah melakukan proses *training* model CNN, dilakukan evaluasi performa model dengan menggunakan data *testing*. Proses evaluasi menggunakan *dataset* sebanyak 300 data *testing* dengan masing-masing 150 gambar pada setiap kelas *halal* dan *syubhat*. Gambar 9 merupakan *confusion matrix* yang dihasilkan pada proses *testing model* menggunakan *dataset testing*.



Gambar 9. Confusion Matrix

Berdasarkan hasil dari *confusion matrix testing* model, pada kategori *halal* dari total data 150 gambar terdapat 147 gambar diklasifikasikan true positive atau *halal* dengan presentase sebesar 98% sehingga terdapat 3 gambar diklasifikasikan false positive atau diklasifikasikan *syubhat*. Pada kategori *syubhat* dari total data 150 gambar terdapat 149 gambar diklasifikasikan true negative atau *syubhat* dengan presentase sebesar 99,33% sehingga terdapat 1 gambar di klasifikasikan false negative atau *halal*. Pada proses *testing* model masih terdapat beberapa kesalahan dalam prediksi, hal tersebut dapat disebabkan oleh resolusi gambar yang kurang baik, distribusi gambar yang terlalu homogen, adanya perbedaan fitur yang sulit diidentifikasi oleh model, dan faktor-faktor lainnya.

Tabel 7 merupakan *classification report* yang menampilkan metrik evaluasi kinerja model yang terdiri dari *precision*, *recall*, *f1-score*, dan *support*.

Tabel 6. Classification Report

| Classification Report : | | | | |
|-------------------------|-----------|--------|-----------|---------|
| | Precision | Recall | F-1 Score | Support |
| Halal | 0.9932 | 0.9800 | 0.9866 | 150 |
| Syubhat | 0.9803 | 0.9933 | 0.9868 | 150 |
| Accuracy | | | 0.9867 | 300 |
| Micro avg | 0.9868 | 0.9867 | 0.9867 | 300 |
| Weighted avg | 0.9868 | 0.9867 | 0.9867 | 300 |

Hasil yang diperoleh dari *classification report* menunjukkan proses deteksi kandungan *halal* mendapatkan nilai *precision* 0,9932, *recall* 0,9800, dan *F1-Score* sebesar 0,9866. Sedangkan pada deteksi kandungan *syubhat* mendapatkan nilai *precision* 0,9803, *recall* 0,9933, dan *F1-score* 0,9868. Pada *classification report* juga dapat diketahui nilai *accuracy* pada proses *testing* yaitu sebesar 98,67% dengan nilai *F1-Score* 0,9867. Dari hasil proses *testing* pada model CNN dapat dilihat bahwa nilai *accuracy* mendekati 1, yang berarti model memiliki akurasi yang sangat baik dalam mengenali gambar yang belum dikenali pada saat proses *training*.

4. Kesimpulan

Metode *convolutional neural network* diimplementasikan untuk membuat model deteksi kehalalan pada kosmetik. Proses pembangunan model terdiri dari beberapa tahapan yaitu pengumpulan dan *split dataset*, *data preprocessing*, perancangan arsitektur model *cnn*, proses *training* model, dan proses *testing* model. Model CNN dalam mengklasifikasikan kehalalan kosmetik mendapatkan nilai *accuracy* sebesar 98,66% dengan *loss* 0,0615. Setelah itu model diuji menggunakan *dataset testing* dan mendapatkan nilai *accuracy* sebesar 98,67%. Nilai *F1-score* pada masing-masing kelas adalah 98,66% untuk kelas *halal* dan 98,67 untuk kelas *syubhat*. Dapat disimpulkan bahwa model menghasilkan nilai *accuracy* yang tinggi dan nilai *loss* yang rendah sehingga model dapat dikatakan termasuk dalam kategori *fit* dan tidak termasuk *overfitting* ataupun *underfitting*. Model dapat mempelajari pola-pola yang ada dalam gambar dan mengklasifikasikannya dengan tingkat akurasi yang sangat baik.

Ucapan Terima Kasih

Terima kasih kepada semua yang telah berkontribusi dan mendukung penelitian ini, termasuk rekan-rekan, dosen pembimbing, pihak teknik industri, fakultas teknik, dan universitas. Terima kasih untuk masukan berharga dan kesempatan dari semua pihak yang turut serta dalam penyusunan dan pelaksanaan penelitian ini.

Daftar Pustaka

Adi Nugroho, P., Fenriana, I., & Arijanto, R. (2020). Implementasi Deep Learning Menggunakan

- Convolutional Neural Network (CNN) pada Ekspresi Manusia. *JURNAL ALGOR*, 2(1). <https://jurnal.buddhidharma.ac.id/index.php/algorithm/index>
- Fadhilah, H., Djamal, E. C., Ilyas, R., & Najmurokhman, A. (2018). Non-Halal Ingredients Detection of Food Packaging Image Using Convolutional Neural Networks. *International Symposium on Advanced Intelligent Informatics (SAIN)*.
- Heidari, M., & Rafatirad, S. (2020, November 9). Using Transfer Learning Approach to Implement Convolutional Neural Network model to Recommend Airline Tickets by Using Online Reviews. *2020 15th International Workshop on Semantic and Social Media Adaptation Aand Personalization*. <https://doi.org/10.1109/SMAP49528.2020.9248443>
- 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)*, 3(2).
- Jaswir, I., Rahayu, El. A., Yuliana, N. D., & Roswiem, A. P. (2020). *Daftar Referensi Bahan-Bahan yang Memiliki Titik Kritis Halal dan Substitusi Bahan Non-Halal* (N. H. Purwanti, Ed.). Komite Nasional Ekonomi dan Keuangan Syariah.
- Kementerian Perindustrian. (2021, June 1). *Tingkatkan Daya Saing IKM Kosmetik, Kemenperin Gencarkan Restrukturisasi Mesin dan Peralatan*. Kementerian Perindustrian Republik Indonesia. <https://kemenperin.go.id/artikel/22550/Tingkatkan-Daya-Saing-IKM-Kosmetik,-Kemenperin-Gencarkan-Restrukturisasi-Mesin-dan-Peralatan>
- Matsuki. (2020, June 11). *Menjadi Muslim, Menjadi Indonesia (Kilas Balik Indonesia Menjadi Bangsa Muslim Terbesar)*. Kementerian Agama Republik Indonesia. <https://kemenag.go.id/opini/menjadi-muslim-menjadi-indonesia-kilas-balik-indonesia-menjadi-bangsa-muslim-terbesar-03w0yt>
- Nadha, C. (2021, November 4). *Awas, Hindari Kosmetik Haram dan Najis*. LPPOM MUI. <https://halalmui.org/awas-hindari-kosmetik-haram-dan-najis/>
- Ramdania, D. R., Aziz, R. M., Mulyana, E., Kaffah, F. M., Maylawati, D. S. A., Al-Amin, M. I., & Ramdhani, M. A. (2022). Convolutional Neural Network for Halal Detection of Korean Cosmetic Composition. *Proceeding of 2022 8th International Conference on Wireless and Telematics, ICWT*. <https://doi.org/10.1109/ICWT55831.2022.9935484>
- Stephen, Raymond, & Handri Santoso. (2019). Aplikasi Convolutional Neural Network untuk Mendeteksi Jenis-Jenis Sampah. *JIST (Jurnal Sistem Informasi Dan Telematika)*, 10(2).
- Yanti, I. (2018). Analisis Pengaruh Faktor Psikologis dan Religiusitas Perilaku Muslimah Kota Medan terhadap Konsumsi Kosmetik Halal dan Baik. *At-Tawassuth*, 3(2).