

## BAB II

### TINJAUAN PUSTAKA DAN LANDASAN TEORI

#### 2.1 Tinjauan Pustaka

Penelitian tentang klasifikasi citra motif batik menggunakan model *Convolutional Neural Network* (CNN) sudah banyak dilakukan. Riset-riset sebelumnya menggarisbawahi pentingnya penelitian ini diperlukan sebagai pijakan untuk penelitian lebih lanjut.

Penelitian [21] menggunakan 2.212 citra yang terdiri dari empat jenis motif batik, yaitu Kawung, Megamendung, Merak Ngibing, dan Parang dengan perbandingan pembagian dataset 80:20. Pada tahap *Preprocessing*, data citra dikonversi menjadi pola *edge detection* dengan operator *canny* dan *sobel*. Sebelum dilakukan proses pelatihan, dilakukan augmentasi sebagai tindakan untuk memperbanyak variasi data dan mengatasi potensi kasus *overfitting*. Penelitian ini melakukan perbandingan akurasi pada model CNN menggunakan operator *canny* dan *sobel* dalam mengidentifikasi pola motif batik. Pada data pengujian, *canny model* memperoleh akurasi sebesar 76%, sedangkan untuk *sobel model* mencapai tingkat akurasi 94%. Penjelasan mengenai ukuran citra dan arsitektur model CNN yang digunakan tidak dipaparkan secara mendetail dalam penelitian ini.

Penelitian selanjutnya [2] mengklasifikasi tujuh jenis motif batik Solo dengan 2.256 data citra yang dibagi dengan perbandingan 77:33. Data citra yang digunakan disamakan ukurannya menjadi 32x32 piksel dan dilakukan *edge detection* dengan operator *canny* pada tahap *Preprocessing* untuk mengekstraksi fitur bentuk yang ada dalam data citra. Arsitektur model CNN dalam penelitian ini menggunakan delapan lapisan yang terdiri dari dua pasang lapisan *convolution* dan *maxpooling*, dua lapisan *dense*, dan dua lapisan *dropout*. Setiap lapisan menggunakan *relu* sebagai fungsi aktivasi, kecuali lapisan *dense* terakhir yang menggunakan *softmax*. Setiap lapisan *convolution* memiliki 32 filter (*kernel*) dengan ukuran 3x3, dan setiap lapisan

*maxpooling* memiliki filter dengan ukuran 2x2 dan nilai *stride* dua. Nilai *dense* yang digunakan adalah 128. Penelitian ini juga menggunakan nilai *dropout* 0,5. Lapisan *dropout* digunakan untuk mengurangi *overfitting* selama proses pelatihan. Hasil pengujian model CNN mendapatkan akurasi 95%.

Dilanjutkan dengan penelitian [22] yang menggunakan 12 jenis motif kain songket dengan 265 data yang ukuran citranya diubah menjadi 200x200 piksel dan dilakukan *grayscale*. Hasil menunjukkan CNN mampu mencapai akurasi 93% untuk data uji. Penelitian ini menambahkan nilai *dropout* untuk mempercepat waktu pelatihan hingga dua kali lipat dan meningkatkan akurasi dalam data uji. Nilai *dropout* dapat meningkatkan akurasi data uji dengan model CNN yang dilatih antara 200 sampai 400 *epoch*. Namun, nilai *dropout* tinggi dapat mempersulit model dalam *fitting* data, menyebabkan penurunan nilai *loss* meskipun akurasi model tetap tinggi. Kondisi ini muncul karena adanya *variance* yang tinggi antara data latih dan data uji, yang menunjukkan kebutuhan terhadap proses penambahan data yang lebih banyak.

Didukung penelitian [20] yang mengklasifikasikan 300 citra motif batik dengan 50 kelas berbeda. Penelitian ini menguji dua arsitektur model CNN, yaitu satu arsitektur tanpa lapisan *dropout* dan lainnya dengan lapisan *dropout*. Arsitektur model CNN yang disusun menggunakan 10 lapisan secara keseluruhan. Terdiri dari tiga pasang lapisan *convolution* dan *maxpooling*, dua lapisan *dense*, dan dua lapisan *dropout*. Setiap lapisan menggunakan fungsi *relu*, kecuali untuk lapisan *dense* terakhir menggunakan fungsi *softmax* sebagai aktivasi. Setiap lapisan *convolution* memiliki 32, 50, dan 80 filter (*kernel*). Ukuran filter untuk lapisan *convolution* dan *maxpooling* adalah 2x2 dan nilai *stride* satu. Nilai *dropout* dalam penelitian ini ditetapkan sebesar 0,5. Sebelum dimasukkan ke dalam arsitektur CNN, setiap citra akan diubah ukurannya menjadi 32x32 dengan kedalaman tiga (RGB). Meskipun kedua model dapat menghasilkan nilai akurasi di atas 90%, arsitektur yang tidak menggunakan lapisan *dropout* cenderung mengalami *overfitting*.

Selanjutnya, penelitian [19] mengklasifikasi multi-label pada citra motif batik dengan CNN. Dalam penelitian ini, 15 motif batik diubah ukurannya

menjadi 350x350 piksel, dengan total 3.000 citra yang terdiri dari 2.700 data latih dan 3000 data uji. Proses pelatihan dilakukan dengan *epoch* berjumlah 100, menghasilkan nilai akurasi yaitu 91,4%, *loss* 0,3%, *recall* sebesar 86,9%, *precision* 94,5%, serta nilai *f-measure* 90,5% pada data uji. Menambahkan dataset sebagai upaya untuk mengatasi ketidakseimbangan dapat meningkatkan akurasi dalam klasifikasi multi-tabel ini, namun perlu diingat bahwa tindakan ini dapat memunculkan potensi kasus *overfitting*.

Penelitian [23] melakukan klasifikasi citra batik Indonesia dengan memanfaatkan algoritma CNN. Penelitian ini menggunakan 983 citra motif batik Indonesia dengan 20 jenis motif batik yang dibagi dengan rasio 80:20. Pada tahap *Preprocessing*, dilakukan *cropping*, *resize* 150x150 piksel, dan konversi *grayscale*. Arsitektur model CNN dalam penelitian ini menggunakan 12 lapisan yang terdiri dari 4 pasang lapisan *convolution* dan *maxpooling*, satu lapisan *dropout*, serta tiga lapisan *dense*. Lapisan *convolution* menggunakan neuron berturut-turut sebanyak 32, 64, 128, dan 512 dengan ukuran 3x3, serta fungsi aktivasi *relu*. Kemudian lapisan *maxpooling* menggunakan ukuran filter 2x2. Nilai *dense* yang digunakan adalah 128, 512, serta 20 dengan fungsi aktivasi *relu* dan *softmax*. Hasil menunjukkan model CNN mendapat tingkat akurasi 78% pada data uji. Penambahan jumlah dataset setiap kelasnya, mengurangi dimensi citra, serta merancang model yang lebih optimal dapat mengurangi *loss* dan meningkatkan hasil akurasi.

Pada penelitian [24] memakai tiga motif batik populer, yakni Kawung, Parang, dan Megamendung, digunakan dengan dataset mencakup 120 citra. Pembagian dataset dilakukan dengan rasio 80:20. Penelitian ini berfokus pada perbedaan dimensi citra dan dampaknya terhadap akurasi model, dengan dimensi citra yang digunakan adalah 64x64, 128x128, dan 256x256, masing-masing melibatkan 240 *epoch*. Hasil penelitian menunjukkan tingkat akurasi sebesar 92,85%, 85%, dan 80% untuk setiap dimensi, mengindikasikan bahwa ukuran citra dapat memengaruhi akurasi yang didapatkan oleh model CNN.

Penelitian berikutnya [25] memanfaatkan 120 data citra batik yang mencakup tiga kelas, yakni Kawung, Megamendung, dan Parang. Data dikumpulkan dari sumber *github* dan *fasnina* yang berasal dari internet. Ukuran dataset diubah jadi 250x250 piksel dan terdiri dari 90 data latih dan 30 data uji. Hasil penelitian menunjukkan bahwa model CNN berhasil mencapai tingkat akurasi sebesar 65%, sementara model CNN dengan citra skala abu-abu (*grayscale*) mencapai tingkat akurasi sebesar 70%. Menambah jumlah dataset dan mengubah tekstur citra ke bentuk yang berbeda dapat dilakukan untuk meningkatkan hasil akurasi.

Dilanjutkan dengan penelitian [26] yang menggunakan 840 data citra motif batik Banyuwangi dengan tujuh kelas, yakni Beras Kutah, Gajah Oleng, Kopi Pecah, Gedegan, Paras Gempal, Moto Pitik, dan Sisikan. Data diambil secara langsung dari beberapa sentra batik dengan menggunakan kamera *smartphone*. Dataset disamakan ukurannya menjadi 64x64 piksel, dilakukan proses augmentasi data, dan dibagi dengan rasio 80:20. Dalam penelitian ini, arsitektur model CNN menggunakan delapan lapisan yang terdiri dari tiga pasang lapisan *convolution* dan *maxpooling*, serta dua lapisan *dense*. Lapisan *convolution* menggunakan neuron berturut-turut sebanyak 16, 32, dan 64 dengan ukuran 3x3, serta fungsi aktivasi *relu*. Kemudian lapisan *maxpooling* menggunakan ukuran filter 2x2 dengan nilai *stride* dua. Hasil menunjukkan bahwa model CNN yang dibangun memperoleh nilai akurasi sebesar 63%. Pendekatan dalam proses klasifikasi diperlukan, seperti menggunakan lebih dari satu metode *preprocessing* dan menambah jumlah dataset untuk mengoptimalkan hasil akurasi model CNN.

Penelitian selanjutnya [27] menggunakan 400 citra motif batik Tanah Liat Sumatera Barat dengan empat jenis, yaitu Kabau Padati, Rumah Gadang, Rangkiang, dan Burung Hong. Dataset didapat secara langsung dari pengrajin batik melalui pemotretan dengan kamera DSLR dan *smartphone*. Dalam penelitian ini, ditetapkan perbandingan pembagian dataset 320 citra data latih dan 80 citra data uji. Hasilnya model CNN mencapai tingkat akurasi 62,5%. Kemiripan warna dan motif menyebabkan citra diklasifikasikan kurang tepat.

Berdasarkan studi literatur yang sudah dilakukan, dapat disimpulkan bahwa terdapat beberapa kelemahan dalam penelitian sebelumnya yang menyebabkan hasil akurasi masih belum optimal. Beberapa kelemahan tersebut, antara lain: (1) dataset yang digunakan relatif masih sedikit dan kurang bervariasi [27], (2) dimensi citra terlalu besar [23], (3) teknik *preprocessing* belum maksimal [26], (4) kinerja model CNN kurang optimal [25]. Untuk mengatasi hal tersebut, dalam penelitian ini akan melakukan teknik augmentasi pada data citra asli supaya dataset lebih banyak dan bervariasi [15]. Dataset yang digunakan berukuran 128x128 piksel [24]. Kemudian menggunakan teknik *edge detection* dengan operator *canny* untuk menampilkan karakteristik bentuk dari citra motif batik Banyumasan [2][21]. Pada tahap pemodelan, akan menyusun beberapa model CNN dengan *hyperparameter* dan regularisasi [20][22].

Tabel 2.1 berikut menunjukkan ringkasan penelitian terdahulu yang relevan.

Tabel 2.1 Penelitian Terdahulu

Literatur			Latar Belakang Penelitian		Desain Riset dan Metodologi		
Penulis	Tahun	Judul	Masalah	Tujuan	Metode	Data	Hasil
Lis Utari, Ammar Zulfikar	2023	Penerapan <i>Convolutional Neural Networks</i> menggunakan <i>Edge Detection</i> untuk Identifikasi Motif Jenis Batik	Proses identifikasi motif batik menjadi tidak efektif karena sebagian pola batik menggabungkan pola dasar yang berasal dari motif lain yang membuatnya sulit dikenali.	Menghasilkan akurasi dengan tingkat akurat yang lebih tinggi dalam penerapan CNN dengan memanfaatkan deteksi tepi untuk mengidentifikasi jenis motif batik.	<i>Convolutional Neural Network</i> (CNN) dengan teknik deteksi tepi.	Dataset 2.212 citra yang terdiri dari empat jenis motif batik, yaitu Kawung, Megamendung , Merak Ngibing, dan Parang.	Model CNN- Sobel lebih baik daripada model CNN-Canny dengan akurasi 94% banding 76%.
Tungki Ari Bowo, Hadi Syaputra, Muhammad	2020	Penerapan Algoritma <i>Convolutional Neural Network</i>	Batik Solo memiliki motif yang variatif sehingga sulit	Memperkaya penelitian dan memberikan hasil klasifikasi motif	Algoritma CNN dengan teknik <i>edge detection</i> .	Dataset tujuh motif batik Solo dengan 2.256 citra.	Model CNN menghasilkan akurasi 95%.

Literatur			Latar Belakang Penelitian		Desain Riset dan Metodologi		
Penulis	Tahun	Judul	Masalah	Tujuan	Metode	Data	Hasil
Akbar		untuk Klasifikasi Motif Citra Batik Solo	membedakannya. Diperlukan metode untuk mengenali karakteristik motif batik Solo.	citra batik Solo yang cukup akurat menggunakan metode CNN.			
Muhammad Husein Nashr, Muhammad Fachrurrozi, Eni Triningsih, Kanda Januar Miraswan	2020	Pengenalan Motif Kain Songket pada Citra Kamera <i>Smartphone</i> dengan Beragam Sudut Pandang menggunakan CNN	Motif songket Palembang sangat beragam. Selain itu, gambar motif masih terdapat <i>noise</i> dan <i>blur</i> dan tidak selalu diambil dengan sudut pandang sama.	Mencari <i>classifier</i> yang handal untuk <i>noise</i> , <i>blur</i> , dan transformasi <i>spatial</i> .	Algoritma <i>Convolutional Neural Network</i> (CNN).	Dataset 12 jenis motif kain songket dengan 265 data citra.	Arsitektur model CNN yang disusun dapat mengklasifikasi motif songket dengan akurasi 93%.
Yufis Azhar, Moch. Chamdani	2021	<i>Ensemble Convolutional Neural Network</i>	Dibandingkan dengan metode pembelajaran	Meningkatkan akurasi model CNN dalam	Algoritma <i>Convolutional Neural Network</i>	Dataset Batik300 yang diperoleh dari	Arsitektur yang tidak menggunakan

Literatur			Latar Belakang Penelitian		Desain Riset dan Metodologi		
Penulis	Tahun	Judul	Masalah	Tujuan	Metode	Data	Hasil
Mustaqim, Agus Eko Minarno		<i>for Robust Batik Classification</i>	mesin yang menggunakan ekstraksi fitur <i>hand-crafted</i> , CNN memiliki tingkat keakuratan yang lebih rendah, terutama untuk kumpulan data yang kecil.	klasifikasi citra motif batik.	(CNN).	<i>kaggle</i> .	lapisan <i>dropout</i> cenderung mengalami <i>overfitting</i> .
Taufiqotul Bariyah, Mohammad Arif Rasyidi, Ngatini	2021	<i>Convolutional Neural Network</i> untuk Metode Klasifikasi Multi-Label pada Motif Batik	Orang awam sulit membedakan karena banyaknya variasi motif yang ada. Selain itu, beberapa kain batik ada yang terdiri	Melakukan klasifikasi citra motif batik multi-label menggunakan CNN.	CNN.	Dataset 15 jenis motif batik dengan 3.000 citra.	Dari 300 data uji, akurasi arsitektur CNN untuk melakukan klasifikasi multi-label pada

Literatur			Latar Belakang Penelitian		Desain Riset dan Metodologi		
Penulis	Tahun	Judul	Masalah	Tujuan	Metode	Data	Hasil
			lebih dari satu motif.				15 motif batik mencapai 91,41%.
Fuad Hasyim, Kamil Malik, Fathur Rizal, Yudistira	2021	Implementasi Algoritma <i>Convolutional Neural Network</i> (CNN) untuk Klasifikasi Batik	Indonesia memiliki ratusan motif kain batik. Banyaknya pola mengakibatkan masyarakat sulit untuk mengenali motif atau pola pada kain batik.	Mengidentifikasi motif atau pola pada kain batik dengan algoritma CNN.	Algoritma <i>Convolutional Neural Network</i> (CNN) dengan kombinasi <i>grayscale</i> .	Dataset 983 citra motif batik Indonesia dengan 20 jenis motif batik yang diperoleh dari <i>kaggle</i> .	Hasil menunjukkan model CNN mendapat tingkat akurasi 78% pada data uji.
Rizki Mawan, Kusrini, Hanif Al Fatta	2020	Pengaruh Dimensi Gambar pada Klasifikasi Motif Batik menggunakan	Ketika berurusan dengan pengolahan citra, dimensi citra dapat memberikan dampak signifikan pada proses	Mengetahui pengaruh dimensi gambar terhadap akurasi model CNN pada klasifikasi citra	CNN.	Dataset tiga motif batik populer, yaitu Kawung, Megamendung dan Parang	Hasil menunjukkan bahwa ukuran citra dapat mempengaruhi akurasi yang

Literatur			Latar Belakang Penelitian		Desain Riset dan Metodologi		
Penulis	Tahun	Judul	Masalah	Tujuan	Metode	Data	Hasil
		<i>Convolutional Neural Network</i>	klasifikasi.	motif batik.		dengan 120 data citra.	didapatkan oleh model CNN.
Rizki Mawan	2020	Klasifikasi Motif Batik menggunakan <i>Convolutional Neural Network</i>	Keragaman pola batik di Indonesia menjadikan identifikasi motifnya menantang, terutama bagi orang awam.	Mengetahui motif batik dengan bantuan metode komputasi CNN.	Algoritma <i>Convolutional Neural Network</i> (CNN) dengan kombinasi <i>grayscale</i> .	Dataset tiga motif batik dengan 120 data citra yang diperoleh dari <i>github</i> dan <i>fasnina</i> .	Model CNN dengan kombinasi <i>grayscale</i> menambah akurasi sebesar 5% dari 65% menjadi 70%.
Lutfi Hakim, Hadi Rizaldi Rahmanto, Sepyan Purnama Kristanto, Dianni Yusuf	2023	Klasifikasi Citra Motif Batik Banyuwangi menggunakan <i>Convolutional Neural Network</i>	Berkembangnya motif batik Banyuwangi mengakibatkan masyarakat tidak <i>aware</i> dengan jenis motif yang ada.	Menggunakan CNN untuk melakukan klasifikasi terhadap tujuh motif batik dari Banyuwangi.	CNN.	Dataset tujuh jenis motif batik Banyuwangi dengan 840 data citra.	Model CNN yang dibangun memperoleh nilai akurasi sebesar 63%.

Literatur			Latar Belakang Penelitian		Desain Riset dan Metodologi		
Penulis	Tahun	Judul	Masalah	Tujuan	Metode	Data	Hasil
Khairul Azmi, Sarjon Defit, Sumijan	2023	Implementasi <i>Convolutional Neural Network</i> (CNN) untuk Klasifikasi Batik Tanah Liat Sumatera Barat	Masyarakat sulit membedakan jenis motif karena banyaknya pola dan motif pada kain batik.	Untuk mengetahui performa CNN untuk melakukan klasifikasi batik berjenis tanah liat dari Sumatera Barat.	CNN.	Dataset 400 citra batik Tanah Liat Sumatera Barat dengan empat jenis motif.	Model CNN mencapai tingkat akurasi sebesar 62,5% pada data uji.

## 2.2 Landasan Teori

### 2.2.1 Batik

Kata "batik" memiliki asal-usul dari bahasa Jawa, yakni *amba* dan *nitik*, kata ini mengacu pada proses melempar suatu titik secara berulang pada kain yang lebar [19]. Menurut Kamus Besar Bahasa Indonesia, batik adalah kain bergambar yang dibuat khusus dengan melukis menggunakan malam (lilin) dan diselesaikan melalui proses tertentu [28]. Hingga saat ini, batik terus mengalami perkembangan jenis corak dan motif [29]. Setiap daerah mempunyai corak dan motif yang unik, masing-masing mencerminkan latar belakang serta karakteristik khusus [30].

Umumnya, motif batik terbagi menjadi dua jenis, yakni motif batik geometris dan non-geometris. Motif batik geometris mencakup corak yang menggabungkan elemen garis hingga bangun. Sedangkan, motif batik non-geometris terdiri dari kombinasi corak non-geometris, seperti tanaman, hewan, atau candi [19]. Batik di pulau Jawa juga dibedakan menjadi dua jenis berdasarkan lokasinya, yakni batik pesisir dan batik pedalaman. Batik pedalaman memiliki latar belakang Hindu dan Kejawen, menampilkan corak simbolis, serta didominasi warna hitam, coklat, dan putih. Sementara itu, batik pesisir yang dipengaruhi oleh budaya dari Cina, menampilkan bentuk yang lebih natural dengan warna dominan biru, kuning, coklat, dan merah [31].

### 2.2.2 Batik Banyumasan

Menurut para sesepuh dan perajin batik Banyumas, belum ada yang dapat memastikan asal mula dari batik Banyumasan. Beberapa sumber mengatakan bahwa pusat pemerintahan di daerah Sokaraja pada tahun 1830 merupakan awal batik Banyumasan. Kain batik digunakan sebagai *bebed*, *nyamping* atau ikat kepala oleh para pejabat selama masa pemerintahan. Budaya membatik muncul di lingkungan pemerintahan untuk memenuhi kebutuhan tersebut [32]. Sumber lain menyatakan bahwa munculnya batik Banyumasan dikaitkan dengan pengungsian pengikut Pangeran Diponegoro

ke daerah tersebut, sehingga budaya dari Yogyakarta dan Surakarta mempengaruhi motif batik Banyumasan [33]. Usaha batik Banyumasan telah berkembang pesat dan sekarang mampu membuat batik secara komersial. Sentra industri batik Banyumasan terbanyak saat ini terletak di Kecamatan Banyumas dan Kecamatan Sokaraja [34].

Batik Banyumasan merupakan salah satu warisan penting yang menunjukkan budaya masyarakat Banyumas. Batik Banyumasan termasuk jenis batik pedalaman dengan motif non-geometris yang memiliki beberapa pola unik dan beragam. Salah satu ciri khasnya adalah dominasi warna dasar coklat dan hitam. Dengan motifnya yang tegas, inspirasinya berasal dari tumbuh-tumbuhan dan hewan. Maknanya menggambarkan masyarakat Banyumas yang apa adanya dan menyatu dengan alam [35]. Dalam penelitian ini, penulis menggunakan 11 jenis motif batik Banyumasan, yaitu Angguran, Ayam Puger, Jahe Lumbon, Jahe Puger, Jahe Srim pang, Lumbon, Madu Bronto, Pring Sedapur, Puger Galar, Puger Telu Bal, dan Wit Lumbon. Sebelas motif tersebut dipilih karena menggambarkan budaya masyarakat Banyumas yang menjaga hubungannya dengan sesama manusia, lingkungan, dan Tuhan Yang Maha Esa [32].

#### a. Angguran

Batik Angguran mengandung makna yang dalam tentang kesuburan, kelimpahan, keberuntungan, dan kebahagiaan dalam hidup. Filosofi ini tercermin dalam motif flora berupa tanaman anggur.



Gambar 2.1 Motif Batik Angguran

b. Ayam Puger

Motif Ayam Puger berasal dari fauna, yaitu ayam jantan serta bentuk rumah. Dalam bahasa Banyumas, kata "*puger*" berarti panutan. Motif ini menunjukkan bahwa masyarakat Banyumas, terutama laki-laki harus menjadi panutan bagi keluarga mereka seperti ayam jago. Bentuk rumah menunjukkan bahwa masyarakat Banyumas harus tetap ingat keluarga dan daerah asalnya walaupun sedang pergi merantau [35].



Gambar 2.2 Motif Batik Ayam Puger

c. Jahe Lumbon

Motif Jahe Lumbon berasal dari flora, yaitu jahe dan daun talas. Filosofi yang terkandung dalam motif ini adalah dalam kehidupan bermasyarakat harus mudah beradaptasi dan saling tolong-menolong. Motif ini juga melambangkan keramahan masyarakat Banyumas.



Gambar 2.3 Motif Batik Jahe Lumbon

d. Jahe Puger

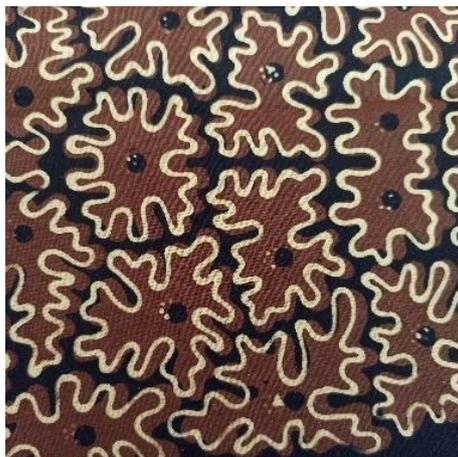
Motif batik ini memiliki arti bahwa harus menjadi manusia yang suka menolong sesama dan tidak boleh melupakan tanah kelahirannya. Motif ini juga menggambarkan semangat baru dalam menjalani kehidupan yang penuh tantangan dan rintangan.



Gambar 2.4 Motif Batik Jahe Puger

e. Jahe Srimpang

Motif Jahe Srimpang merupakan tanaman jahe yang dibelah menjadi dua dan sekilas tampak seperti telapak tangan manusia. Masyarakat Banyumas selalu mempertahankan lima rukun Islam dan lima sila Pancasila. Oleh karena itu, mereka menjaga hubungan dengan Sang Pencipta selain dengan sesama manusia [35].



Gambar 2.5 Motif Batik Jahe Srimpang

f. Lumbon

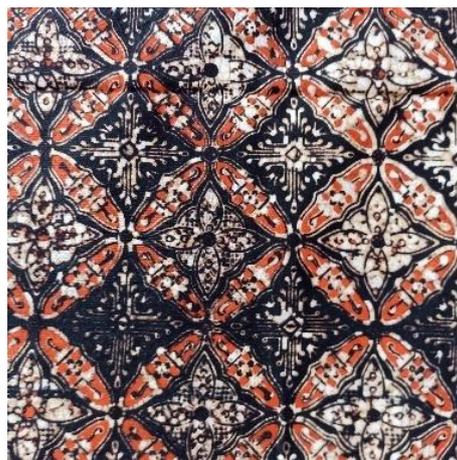
Motif Lumbon berasal dari daun talas. Masyarakat Banyumas yang mampu beradaptasi dengan siapa pun dan dimana pun, digambarkan seperti daun talas yang dapat tumbuh dalam lingkungan apapun [35].



Gambar 2.6 Motif Batik Lumbon

g. Madu Bronto

Motif batik Madu Bronto adalah motif batik khas Banyumas yang menggambarkan perasaan cinta yang manis dan penuh perjuangan. Motif ini terdiri dari dua kata, yaitu "*madu*" yang berarti manis dan "*bronto*" yang berarti bertarung. Motif ini biasa digunakan untuk acara lamaran atau seserahan [32].



Gambar 2.7 Motif Batik Madu Bronto

#### h. Pring Sedapur

Motif ini berasal dari pohon bambu yang banyak ditemukan di wilayah Banyumas. Bentuk pohon bambu yang merunduk menunjukkan bahwa orang Banyumas tidak sombong karena mereka bersikap rendah hati dengan apa yang mereka miliki [32].



Gambar 2.8 Motif Batik Pring Sedapur

#### i. Puger Galar

Motif batik Puger Galar menggambarkan masyarakat Banyumas yang menjunjung tinggi nilai-nilai kebudayaan, keagamaan, dan kepemimpinan. Motif ini juga menggambarkan harapan masyarakat Banyumas untuk hidup makmur dan sejahtera.



Gambar 2.9 Motif Batik Puger Galar

j. Puger Telu Bal

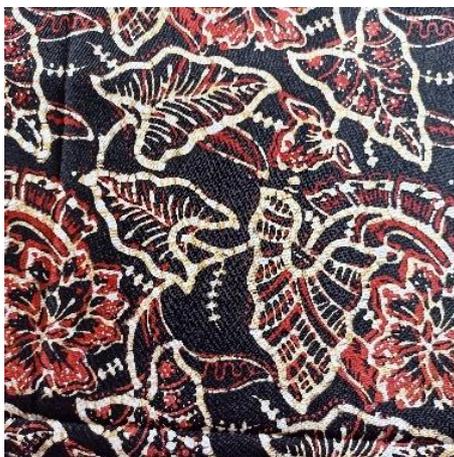
Motif batik Puger Telu Bal menggambarkan masyarakat Banyumas yang menjunjung tinggi nilai-nilai kebudayaan dan keagamaan. Motif ini juga menggambarkan kewajiban manusia untuk menjaga iman, ilmu, amal, serta menghormati para panutan dan teladan yang ada.



Gambar 2.10 Motif Batik Puger Telu Bal

k. Wit Lumbon

Motif batik Wit Lumbon berbentuk tumbuhan talas secara utuh. Motif ini merupakan variasi dari motif Lumbon yang hanya berbentuk daunnya saja. Filosofi motif batik ini adalah menggambarkan kesucian, kejujuran, dan kebaikan hati yang dimiliki oleh masyarakat Banyumas. Motif ini biasa digunakan untuk acara-acara sakral, seperti pernikahan, khitanan atau selamatan [32].



Gambar 2.11 Motif Batik Wit Lumbon

### 2.2.3 Deep Learning

*Deep learning* merupakan salah satu cabang *machine learning* yang memakai jaringan saraf tiruan untuk menyelesaikan masalah pada data berukuran besar [36]. *Deep learning* cocok digunakan dalam *computer vision*, misalnya untuk mengklasifikasikan objek berdasarkan citra. Dengan metode ini, komputer dapat belajar klasifikasi secara *real time* dari data berbentuk citra atau suara. *Deep learning* membuat komputer dapat menghasilkan konsep kompleks dari yang sederhana [24]. Metode ini memberikan arsitektur yang sangat handal untuk pembelajaran terawasi dengan menambah lapisan ekstra sehingga model pelatihan dapat merepresentasikan citra yang sudah diberi label dengan baik [37]. *Deep learning* berkembang dengan dukungan teknologi yang bernama *Graphics Processing Unit (GPU) Acceleration*. Dalam proses komputasi, *deep learning* tidak hanya menggunakan CPU dan RAM, tetapi juga GPU yang membuat proses komputasi menjadi lebih cepat [36].

### 2.2.4 Pengolahan Citra Digital

Pengolahan citra digital merupakan salah satu cabang ilmu komputer yang berkaitan dengan manipulasi dan modifikasi citra dengan berbagai tujuan [38]. Citra digital adalah representasi citra yang terdiri dari piksel, yaitu elemen matriks yang memiliki nilai tertentu. Nilai piksel dapat menunjukkan warna atau keabuan citra, tergantung pada jumlah kanal warna yang digunakan [39]. Suatu citra dikatakan digital apabila citra tersebut diperoleh melalui komputer, kamera, dan *scanner*. Pengolahan citra digital melibatkan berbagai operasi pada citra, seperti operasi piksel, operasi geometrik, operasi pada citra biner, dan segmentasi citra [39]. Operasi-operasi ini dapat digunakan untuk mengenali objek atau mengekstrak informasi dari citra. Pengolahan citra digital memiliki banyak aplikasi di berbagai bidang, seperti pengindraan jauh, deteksi objek, dan pengenalan pola [38].

Pola merupakan entitas yang dapat diidentifikasi dan diberi nama berdasarkan keunikan yang ada. Keunikan tersebut sebagai pembeda pola

satu dengan pola lainnya yang memungkinkan pengelompokan pola berdasarkan ciri-cirinya dengan hasil keakuratan yang tinggi [40]. Dalam bukunya yang berjudul *Pattern Recognition*, Sergios Theodoridis dan Konstantinos Koutroumbas menyatakan bahwa pengenalan pola adalah bidang ilmu yang bertujuan untuk mengklasifikasikan objek ke dalam berbagai kategori [41].



Gambar 2.12 Struktur Sistem Pengenalan Pola

Pada Gambar 2.12 menunjukkan struktur sistem pengenalan pola. Bagian-bagian sistem pengenalan pola dijelaskan berikut [42].

- a. Sensor mempunyai fungsi untuk merekam objek dunia secara nyata dan mengubahnya menjadi *digital signal* melalui proses digitalisasi.
- b. Pada tahap *preprocessing*, citra atau sinyal dipersiapkan untuk meningkatkan ekstraksi ciri. Dalam tahap ini, citra atau sinyal menunjukkan ciri penting dan sinyal pengganggu diminimalkan.
- c. Seleksi fitur bertujuan menghasilkan karakteristik pembeda yang mencerminkan sifat utama sinyal dan mengurangi dimensi sinyal menjadi set angka yang lebih kecil namun tetap representatif.
- d. Algoritma klasifikasi dimanfaatkan sebagai pengelompokan ciri ke dalam kelas yang sesuai.

### 2.2.5 Canny Edge Detection

*Canny Edge Detection* adalah operator deteksi tepi yang mendeteksi berbagai tepi dalam gambar dengan menggunakan algoritma multi-tahap. John Canny mengusulkan metode deteksi tepi *Canny* pada tahun 1986 dalam makalahnya berjudul *A Computational Approach to Edge Detection*, yang menjelaskan pendekatan komputasi untuk deteksi tepi [43]. Metode ini mengurangi jumlah data yang diproses dengan mengekstrak informasi struktural penting dari berbagai objek penglihatan. Algoritma deteksi tepi *Canny* merupakan salah satu yang paling ketat dari berbagai metode deteksi tepi yang telah dikembangkan sejauh ini, dan memberikan hasil deteksi tepi

yang baik dan andal. Metode *Canny* melibatkan setidaknya lima tahapan dalam deteksi tepi secara teknis. Beberapa tahapan yang digunakan berupa penerapan filter *Gaussian*, perhitungan gradien, penekanan batas bawah, menerapkan *double threshold*, dan penggunaan *hysteresis* [44].

a. Filter *Gaussian*

Menerapkan filter *Gaussian* untuk menghaluskan gambar dapat menghilangkan *noise*. Untuk mencapainya, teknik konvolusi gambar diterapkan dengan ukuran *kernel Gaussian* (3x3, 5x5, 7x7, dst.). Agar *kernel* memiliki nilai tengah, ukurannya harus ganjil. Ukuran *kernel* bergantung pada efek buram yang diharapkan.

b. Perhitungan Intensitas Gradien

Langkah penghitungan gradien menggunakan operator deteksi tepi untuk menghitung gradien citra, mendeteksi intensitas dan arah tepi. Perubahan intensitas piksel berhubungan dengan tepi. Cara termudah untuk mengidentifikasinya adalah dengan menggunakan filter yang menyorot perubahan intensitas ini di kedua arah. Turunan  $I_x$  dan  $I_y$  dengan  $x$  dan  $y$  dapat dihitung saat gambar dihaluskan menggunakan gabungan  $I$  dengan *kernel Sobel*  $K_x$  dan  $K_y$  (2.1).

$$K_x = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix}; K_y = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix} \quad (2.1)$$

Selanjutnya, besaran nilai  $G$  dan kemiringan gradien dihitung menggunakan persamaan 2.2 dan 2.3 berikut.

$$G = \sqrt{I_x^2 + I_y^2} \quad (2.2)$$

$$\theta(x,y) = \arctan\left(\frac{I_y}{I_x}\right) \quad (2.3)$$

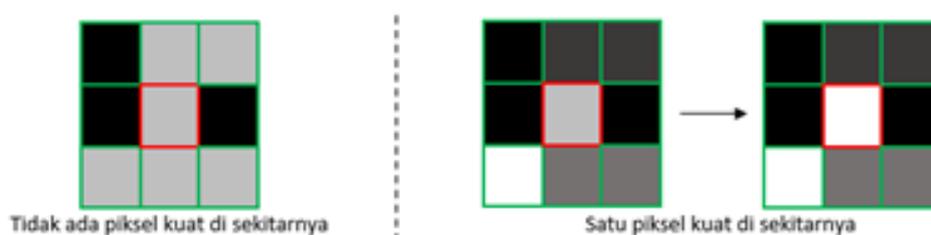
c. Penekanan Batas Bawah

Citra akhir harus memiliki tepi yang tipis. Oleh karena itu, perlu dilakukan penekanan batas bawah untuk menipiskan bagian tepinya. Algoritma menemukan piksel dengan nilai maksimum pada arah tepi setelah menelusuri setiap titik dalam matriks intensitas gradien.

d. *Double Threshold*

Konsep *double threshold* digunakan untuk mengenali tiga kategori piksel, yaitu piksel yang memiliki intensitas tinggi dan berperan dalam membentuk tepi akhir (piksel kuat), piksel dengan nilai intensitas yang tidak begitu besar untuk dianggap kuat namun juga tidak cukup kecil untuk diabaikan dalam proses deteksi tepi (piksel lemah), serta piksel yang tidak berpengaruh dalam deteksi tepi (piksel tidak relevan).

e. Penggunaan *Hysteresis*



Gambar 2.13 Proses *Hysteresis* [44]

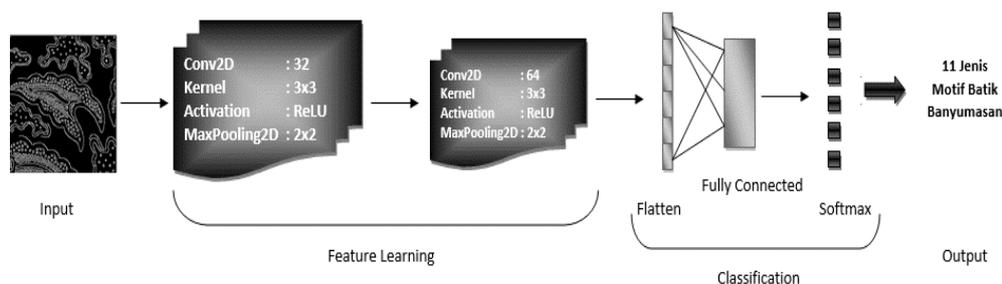
Berdasarkan hasil *threshold*, *hysteresis* terdiri dari konversi piksel lemah menjadi piksel kuat, hingga setidaknya terdapat piksel yang kuat di sekitar piksel yang sedang diproses. Gambar 2.13 merupakan ilustrasi dari penggunaan *hysteresis*.

### 2.2.6 Convolutional Neural Network (CNN)

Algoritma *deep learning*, salah satunya adalah CNN, yang merupakan perluasan dari *Multi-layer Perceptron* (MLP) untuk mengklasifikasikan data dua dimensi yang sudah diberi label, misalnya gambar atau suara [36]. CNN termasuk ke dalam *supervised learning*, hal ini dikarenakan kebutuhan data latih dan data uji untuk dilakukan klasifikasi. Algoritma ini dirancang untuk bisa memproses data yang berukuran besar sehingga sering digunakan pada data yang berbentuk citra atau gambar [45]. CNN mempunyai jaringan yang sangat dalam dan efektif untuk data citra. Oleh karena itu, algoritma ini masuk ke dalam kategori *deep neural network* [20].

CNN memiliki banyak lapisan yang masing-masing lapisan dapat belajar untuk mengenali berbagai citra yang diinputkan [36]. CNN biasanya memiliki tiga lapisan utama, yaitu *convolutional layer*, *pooling layer*, dan

*fully connected layer*. *Convolutional layer* dan *pooling layer* bertugas sebagai lapisan ekstraksi fitur sedangkan *fully connected layer* berfungsi sebagai lapisan klasifikasi [45].

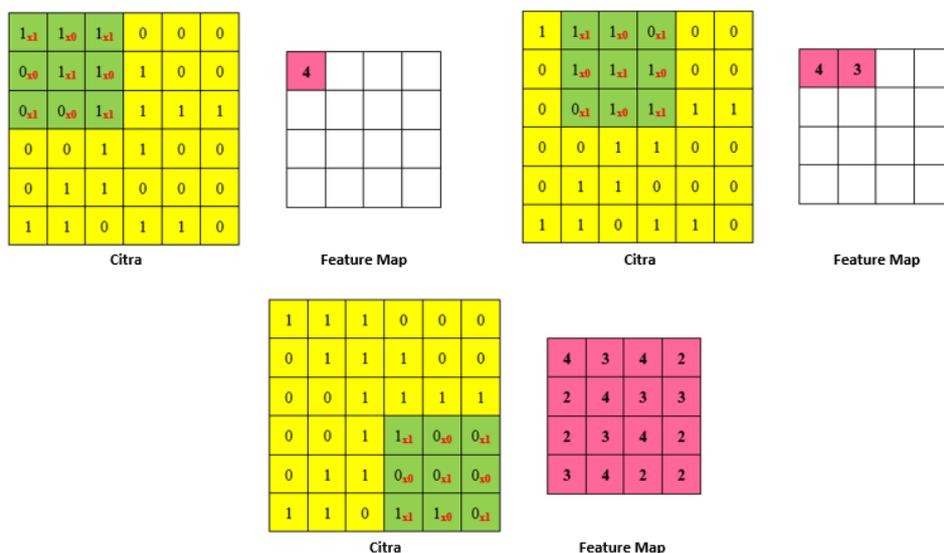


Gambar 2.14 Contoh Arsitektur CNN [36]

Gambar 2.14 menggambarkan arsitektur algoritma CNN yang terdiri dari input data citra, *feature learning* dan klasifikasi. *Feature learning* bertujuan untuk mengekstrak informasi yang paling penting dari citra masukan agar klasifikasi dapat berjalan dengan baik [22]. Proses *feature learning* melibatkan tahapan *convolution layer* dan *pooling layer* untuk mengubah citra menjadi representasi fitur dalam bentuk nilai numerik. Tahapan klasifikasi menggunakan *fully connected layer* untuk mengelompokkan data ke dalam kategori yang sesuai.

#### a. *Convolutional Layer*

*Convolutional layer* menerapkan konvolusi pada input ataupun *output* dari lapisan sebelumnya. Konvolusi bertujuan untuk mengambil fitur dari citra input yang berguna untuk proses selanjutnya. *Feature extraction* merupakan teknik untuk membuat dataset baru yang berasal dari dataset asli. Dataset baru memiliki ukuran yang lebih kecil dari dataset asli karena hanya mengandung fitur-fitur yang penting [42]. Konvolusi melakukan transformasi linier pada data masukan sesuai dengan informasi yang terkandung dalam data tersebut. Dalam konteks matematika, konvolusi adalah operasi yang melibatkan penjumlahan hasil kali pada setiap elemen yang sesuai [46]. *Kernel* konvolusi yang digunakan ditentukan oleh bobot lapisan dan *kernel* konvolusi dapat diubah sesuai dengan input yang diberikan pada CNN [37].

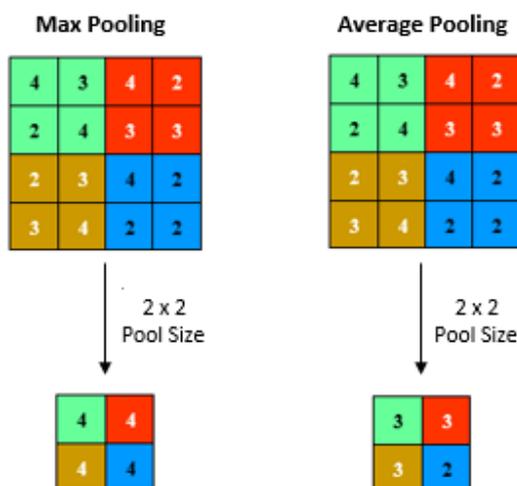
Gambar 2.15 Proses *Convolution Layer* [46]

Lapisan konvolusi bekerja dengan menggeser filter kecil (*kernel*) melintasi gambar input untuk mendeteksi fitur-fitur penting seperti tepi, sudut, dan tekstur. Hasil dari setiap posisi filter adalah nilai yang dimasukkan ke dalam peta fitur, yang kemudian digunakan untuk membangun representasi yang lebih kompleks pada lapisan-lapisan berikutnya. Seperti yang terlihat pada Gambar 2.15, *convolution* menerapkan *kernel* (kotak hijau) pada gambar dengan berbagai macam kemungkinan bias (*offset*). Kotak kuning secara keseluruhan menunjukkan gambar yang akan dikonvolusi. *Kernel* (kotak berwarna hijau) berpindah dari pojok kiri atas ke pojok kanan bawah, menghasilkan representasi hasil konvolusi pada gambar yang terletak di sebelah kanannya.

#### b. *Pooling Layer*

Tahapan yang terjadi dalam *pooling layer* adalah proses reduksi ukuran data citra. Tujuan dari tahap ini adalah membuat fitur lebih tahan terhadap perubahan posisi dan mempercepat perhitungan serta mencegah terjadinya *overfitting* [46]. Lapisan ini bertugas untuk memotong dimensi *feature map* dan mengekstrak fitur yang signifikan dengan berbagai posisi citra sehingga proses pelatihan lebih efektif.

*MaxPooling* dan *AveragePooling* merupakan jenis *pooling* umum yang cukup populer untuk digunakan. Pemilihan jenis lapisan *pooling* yang sesuai dalam model CNN dapat memberikan peningkatan kinerja pada model [46].

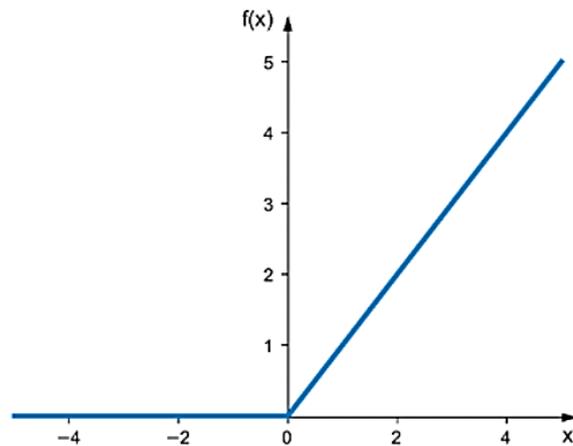


Gambar 2.16 Tahapan *Pooling* [46]

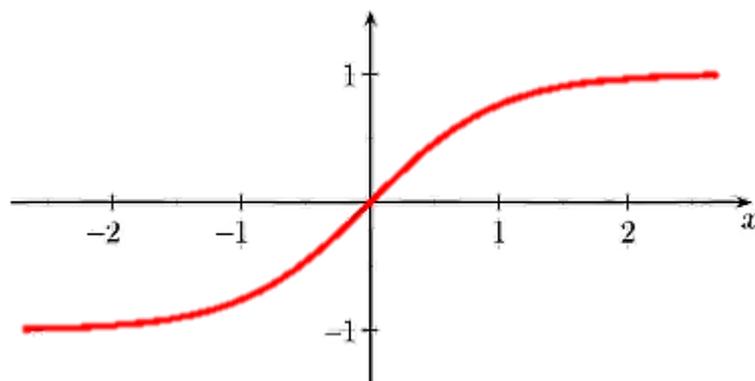
Proses *MaxPooling* dan *AveragePooling* pada Gambar 2.16 menggunakan masukan citra berdimensi 4x4 piksel dan menghasilkan keluaran citra berdimensi lebih kecil, yaitu 2x2 piksel. Nilai yang didapat pada *AveragePooling* adalah rata-rata dari matriks yang telah dilakukan *pooling*. Sementara itu, *MaxPooling* adalah memilih nilai paling besar.

### c. Fungsi Aktivasi

Salah satu komponen penting dari jaringan syaraf tiruan adalah fungsi aktivasi, yang berfungsi sebagai fungsi non-linear. Fungsi ini membantu jaringan saraf mempelajari pola yang kompleks dengan menambahkan non-linearitas ke dalam model. Tanpa fungsi aktivasi, jaringan saraf hanya akan menjadi kombinasi linear, sehingga tidak akan mampu menangani data yang non-linear dengan baik. Dengan cara ini, jaringan syaraf tiruan bisa melakukan proses klasifikasi.

a) Aktivasi Fungsi *ReLU*Gambar 2.17 Aktivasi *ReLU* [38]

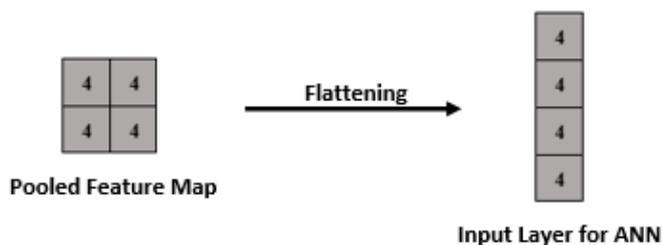
Salah satu jenis fungsi aktivasi yang digunakan pada model CNN adalah *ReLU* atau *Rectified Linear Unit*, yang dapat dilihat pada Gambar 2.17. Fungsi ini menggunakan rumus  $f(x) = \max(0, x)$ , yang berarti fungsi ini akan mengubah keseluruhan nilai piksel yang ada pada gambar masukan yang lebih kecil dari nol menjadi nol [36]. Dengan demikian, fungsi aktivasi melakukan tahapan *thresholding* dengan nilai ambang nol. Keuntungan menggunakan fungsi aktivasi *ReLU* adalah dapat mempercepat proses pelatihan dan pengujian pada jaringan yang memiliki banyak neuron.

b) Aktivasi Fungsi *Softmax*Gambar 2.18 Aktivasi *Softmax* [38]

Sebagaimana ditunjukkan pada Gambar 2.18, aktivasi *Softmax* berfungsi untuk mengestimasi probabilitas tiap kelas yang paling besar kemungkinannya untuk dipilih sebagai prediksi akhir. Aktivasi

*Softmax* merupakan variasi dari *logistic regression* [36]. *Logistic regression* biasa digunakan untuk klasifikasi multi kelas, yaitu klasifikasi yang melibatkan lebih dari dua kelas sehingga dapat menghitung peluang setiap kelas.

d. *Flattening*

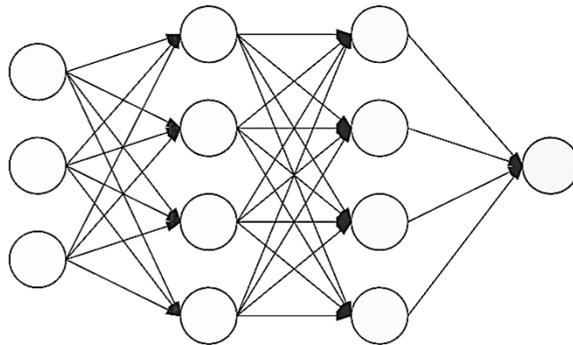


Gambar 2.19 Operasi *Flattening* [46]

Gambar 2.19 menunjukkan operasi *flattening*, yaitu operasi yang mengubah suatu fitur atau matriks input menjadi vektor linear. *Flattening* mengonversi *feature map* yang dihasilkan oleh lapisan sebelumnya menjadi vektor linear agar dapat diolah oleh *fully connected layer* sebagai masukan [46].

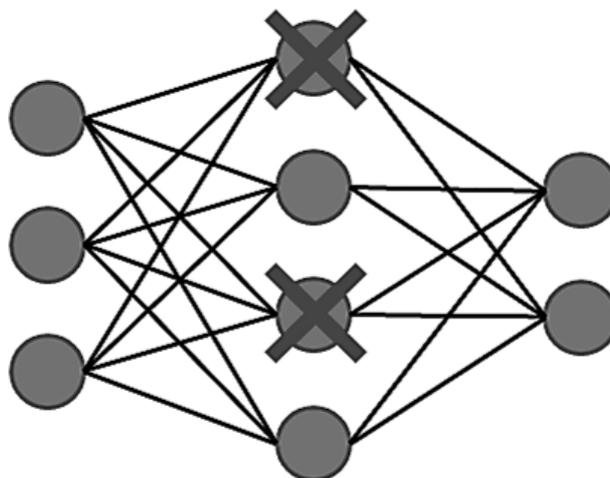
e. *Fully Connected Layer*

Salah satu lapisan pada jaringan saraf tiruan adalah *fully connected layer* yang menggunakan *Multi-Layer Perceptron* untuk mengubah dimensi data agar bisa diklasifikasikan secara linear. Data yang sudah melewati proses *feature extraction* masih memiliki bentuk *array* multidimensional sehingga harus dilakukan proses *Flatten* dahulu [46]. Lapisan ini mampu mengenali fitur yang paling penting dan fitur yang kurang relevan pada citra, dan mengklasifikasikannya dengan aktivasi *Softmax*. *Fully connected* berarti tiap node di lapisan awal terkoneksi dengan tiap node di lapisan berikutnya, seperti ditunjukkan pada Gambar 2.20 berikut.

Gambar 2.20 *Fully Connected Layer* [46]

f. *Dropout*

*Dropout* adalah sebuah teknik regularisasi yang digunakan untuk melakukan pengurangan *overfitting* pada jaringan saraf tiruan, khususnya CNN. *Dropout* bekerja dengan menghapus secara acak sebagian input atau aktivasi dari lapisan tertentu pada CNN sehingga membuat lapisan tersebut lebih tahan terhadap gangguan dan variasi input. *Dropout* biasanya diterapkan pada lapisan tersembunyi dari CNN, antara lapisan konvolusi dan lapisan *fully connected*. *Dropout* juga dapat diterapkan pada lapisan input, tetapi hal ini jarang dilakukan karena dapat menghilangkan informasi penting dari data. *Dropout* membutuhkan sebuah parameter yang disebut *dropout rate* yang menentukan probabilitas setiap input atau aktivasi untuk dihapus. *Dropout rate* biasanya diatur antara 0,2 hingga 0,5, tergantung pada kompleksitas arsitektur model CNN [45]. Proses *dropout* ditunjukkan Gambar 2.21.

Gambar 2.21 Proses *Dropout* [45]

### 2.2.7 Evaluasi Hasil

Untuk mengevaluasi kinerja model yang telah dilatih, dilakukan penghitungan akurasi, presisi, dan *recall* menggunakan *confusion matrix multi-class* yang merupakan sebuah matriks yang menunjukkan seberapa akurat dan presisi model kita. Ukuran *confusion matrix multi-class* lebih dari 2x2 karena jumlah kelasnya lebih dari dua. *Confusion matrix* menyimpan informasi tentang nilai yang sesuai dengan nilai sebenarnya dan nilai yang diprediksi atau diklasifikasikan untuk setiap kelas [19]. Contoh *confusion matrix multi-class* bisa dilihat pada Tabel 2.2 berikut.

Tabel 2.2 *Confusion Matrix Multi-Class*

		Prediksi			Total Aktual
		M	R	S	
Aktual	M	TP (M)	FN (M) / FP (R)	FN (M) / FP (S)	nA (M)
	R	FN (R) / FP (M)	TP (R)	FN (R) / FP (S)	nA (R)
	S	FN (S) / FP (M)	FN (S) / FP (R)	TP (S)	nA (S)
Total Prediksi		nP (M)	nP (R)	nP (S)	N

Keterangan:

M, R, S : Kelas atau label dataset

N : Banyaknya dataset

nA : Banyaknya data aktual per kelas

nP : Banyaknya data prediksi per kelas

TP (*True Positive*) : Data diprediksi bernilai positif dan benar

FN (*False Negative*) : Data diprediksi negatif, aktual positif

FP (*False Positive*) : Data diprediksi positif, aktual negatif

Kinerja model bisa diukur dengan menghitung akurasi, presisi, *recall*, dan *f1-score*. Akurasi adalah persentase kebenaran sistem dalam mengklasifikasikan data baru. Presisi mengukur jumlah data yang sesuai

dari data yang ditemukan oleh sistem. *Recall* mengukur tingkat keberhasilan suatu sistem yang telah dibangun. *F1-Score* adalah harmonisasi rata-rata (*harmonic mean*) dari presisi dan *recall* yang memberikan sebuah ukuran seimbang antara keduanya [46].

Nilai *accuracy*, *precision*, dan *recall* dapat diperoleh dari Tabel 2.2. Untuk menghitung *accuracy*, cukup tambahkan semua nilai TP lalu bagi dengan total data atau total nilai pada kolom tabel. Rumus untuk menghitung akurasi ditunjukkan pada Persamaan 2.4 berikut.

$$Accuracy = \frac{TP (M) + TP (R) + TP (S)}{N} \quad (2.4)$$

Nilai presisi bisa diperoleh dengan membagi nilai prediksi yang tepat pada kelas tertentu dengan jumlah dari semua nilai prediksi pada kelas itu. Rumus untuk mendapatkan *precision* ditampilkan pada Persamaan 2.5.

$$Precision = \frac{TP (M)}{nP (M)} \quad (2.5)$$

*Recall* merupakan nilai yang didapat dengan membagi nilai prediksi yang sesuai pada kelas tertentu dengan jumlah dari semua nilai aktual pada kelas itu. Rumus untuk menghitung *recall* ditulis pada Persamaan 2.6.

$$Recall = \frac{TP (M)}{nA (M)} \quad (2.6)$$

*F1-Score* dapat diperoleh dengan menggabungkan presisi dan *recall* ke dalam satu metrik dengan menggunakan rata-rata harmonik. *F1-Score* memberikan bobot yang sama antara presisi dan *recall*. Rumus menghitung *F1-Score* ditunjukkan pada Persamaan 2.7 berikut.

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (2.7)$$