

## BAB II TINJAUAN PUSTAKA

Bagian ini memuat kajian dan uraian sistematis tentang informasi hasil penelitian yang pernah dilakukan peneliti lain dalam pustaka dan menghubungkannya dengan masalah penelitian. Hal tersebut digunakan sebagai dasar membuat struktur landasan teori.

### 2.1 Penelitian terdahulu

Penelitian terdahulu mengenai klasifikasi citra dan *Transfer Learning* menunjukkan bahwa beberapa telah mengaitkan dengan ekstraksi fitur, pengaruh dimensi citra yang digunakan hingga model yang digunakan untuk meningkatkan akurasi klasifikasi. Pada penelitian ini, peneliti telah mengkaji berbagai jurnal yang membahas tentang *machine learning*, *deep learning*, dan *Transfer Learning*.

Penelitian yang dilakukan Gultom, et al pada tahun 2018 melakukan penelitian terkait pembagian terstruktur mengenai batik memakai *Deep ConvNet* dan menerapkan *Transfer Learning*. Gultom mengangkat suatu tantangan dalam pembagian terstruktur mengenai batik, yaitu kasus *invariance dilemma*. Menurutny, *Convolutional Neural Network* (CNN) adalah salah satu arsitektur *deep learning* yang bisa mengatasi perseteruan tadi lantaran sanggup menilik representasi data menggunakan kombinasi teknik *local receptive inputs*, *weight sharing & convolutions*. Pada penelitian ini metode yg diusulkan merupakan *Deep Convolutional Neural Network* yang disusun dengan ekstraktor fitur otomatis VGG-16 yang sudah dilatih sebelumnya tetapi tanpa lapisan atasnya dan *multi-layer perceptron* (MLP) menjadi pengklasifikasi. ConvNet VGG16 sebagai ekstraktor fitur mencapai rata-rata akurasi  $89\pm 7\%$  sedangkan model berbasis SIFT dan SURF mencapai rata-rata  $88\pm 10\%$  dan  $88\pm 8\%$ . Meskipun demikian, SIFT lebih akurat sekitar 5% pada dataset yang dirotasi dan diperbesar [16].

Pada penelitian yang dilakukan oleh Agastya, et al (2018) mengimplementasikan metode klasifikasi batik menggunakan *Convolutional Neural Network* (CNN) yang disebut VGG-16 dan VGG-19 dimana mampu memprediksi hampir 89,3% benar dalam mengklasifikasikan pola batik dengan membuat tiga skenario yaitu skenario yang pertama: percobaan dengan *non-split* dataset, skenario kedua ialah percobaan dengan split dataset. Terakhir skenario dengan mengevaluasi akurasi berdasarkan rotasi dan penskalaan citra. Metode evaluasi yang digunakan ialah *4-fold cross-validation*. Strategi augmentasi yang digunakan dapat meningkatkan akurasi model lebih dari 10% [6].

Selain itu, penelitian oleh Tammina (2019) dilakukan dalam tiga rancangan model. Pertama, membangun jaringan saraf convolutional dasar dari awal kemudian melatih model tersebut pada dataset citra pelatihan dan mengevaluasinya. Kedua akurasi ditingkatkan menggunakan teknik *image augmentation*. Terakhir, memanfaatkan model pra-pelatihan VGG-16 yang sudah dilatih pada kumpulan data besar dengan beragam kategori untuk mengekstrak fitur dan mengklasifikasikan gambar. Model pertama yang dibangun menggunakan *Convolutional Neural Network* memberikan akurasi validasi sebesar 72,40 %. Sedangkan model yang menggunakan teknik data augmentasi dengan pembesaran citra dan .. mencapai akurasi 79,20 %. Model terakhir, kami menggunakan salah satu model pra-pelatihan (VGG-16) yang dilatih pada kumpulan data gambar yang sangat besar dan disetel dengan augmentasi citra mencapai akurasi 95,40 % [18].

Selain itu, peneliti akan menerapkan *Transfer Learning* kedalam model yang dapat meningkatkan akurasi klasifikasi. Hal tersebut merujuk pada penelitian terdahulu yang menyatakan bahwa pengaplikasian *Transfer Learning* dengan CNN dapat meningkatkan akurasi. Seperti pada penelitian Arsa, dkk (2019) dalam penelitiannya mengusulkan metode *deep learning* untuk mengklasifikasikan Batik. Arsa menggunakan arsitektur VGG16 untuk mengekstraksi fitur dari citra batik. Kemudian untuk pengklasifikasi menggunakan *Random Forest*. Berdasarkan hasil yang telah dilakukan, nilai akurasi yang didapatkan sebesar hampir 97% dengan 50 kelas batik [17].

Penelitian yang dilakukan oleh Atho'ul Muwafiq, dkk (2020) melakukan penelitian yang mengimplementasikan *Convolutional Neural Network* (CNN) untuk klasifikasi batik menyatakan akurasi dari metode ini bergantung jumlah dataset dan arsitektur CNN. Pada penelitian itu juga menyebutkan arsitektur terbaik adalah *GoogLeNet* dengan *error rate* 6.67%. Penelitian ini berfokus pada lima motif batik solo yaitu batik kawung, parang, truntum, sidomukti dan satrio manah. dengan dataset sebanyak 200 citra pada data latih dan 100 citra pada data uji dengan ukuran 32x32 piksel. Pada proses training, dimulai dengan memasukkan dataset yang telah diberi label dengan lima kelas klasifikasi yaitu batik kawung, parang, truntum, sidomukti dan satrio manah. Kemudian dari dataset yang telah dimasukkan diproses ke dalam model yang telah dikonfigurasi dan dikompulasi. Pada proses testing, dataset baru dimasukan ke dalam model kemudian model akan membaca citra yang telah dimasukkan untuk diproses agar mengenali motif batik yang ada pada citra tersebut. Setelah itu akan keluar hasil prediksi dari citra tersebut [19].

Selanjutnya, ada juga penelitian yang berfokus pada dimensi yang digunakan pada model seperti penelitian yang dilakukan oleh Rizki Mawan (2020) yang bereksperimen dengan penggunaan tiga ukuran dimensi, yaitu 64x64, 128x128, 256x256. Dataset yang digunakan diambil dengan cara mengunduh citra batik melalui google dengan ekstensi .jpg. banyaknya dataset yang digunakan adalah sebanyak 120 citra yang terbagi menjadi 3 jenis motif yaitu motif megamendung, kawung dan parang. Dataset tersebut dibagi menjadi 100 data pelatihan dan 20 data uji atau dengan perbandingan 80:20. Berdasarkan penelitian yang telah dilakukan, akurasi yang dihasilkan Metode *Convolutional Neural Network* dengan ukuran 64x64 = 92.85%, 128x128 =85%, 256x256 =80% membuktikan bahwa ukuran citra mempengaruhi akurasi yang dihasilkan [13].

Pada penelitian yang dilakukan oleh Khasanah (2020) mengimplementasikan delapan macam augmentasi data pada dataset batik menggunakan model pra-pelatihan VGG-16 dengan teknik *fine-tuning*. Dataset yang digunakan berasal dari mengunduh citra batik dari *Google Image* dengan lima jenis motif batik yaitu Ceplok, Kawung, Lereng, Nitik, dan Parang yang terdiri dari 50 citra/kelas.

Kemudian 50 citra itu ditambah menjadi 100 citra dengan metode *slicing*. Nilai akurasi klasifikasi batik menggunakan model pra latih VGG16 dapat ditingkatkan dengan menerapkan augmentasi data. Berdasarkan percobaan yang telah dilakukan, didapatkan hasil bahwa augmentasi data meningkatkan akurasi sebesar 3,13%, dari 95,83% menjadi 98,96%, dengan menggabungkan augmentasi data melalui proses seleksi [8].

Pada penelitian yang dilakukan oleh Bariyah (2021) melakukan klasifikasi multi-label citra motif batik dengan menggunakan *Convolutional Neural Network* (CNN). Tahap metode penelitian yang dilakukan terdiri dari pengumpulan data citra, preprocessing data citra, pembangunan model CNN, dan pengujian model. Dalam penelitian ini menggunakan 15 motif batik berbeda yang digunakan sebagai label prediksi motif batik, yaitu Banji, Buketan, Ceplok, Encim, Kawung, Lung-lungan, Madura, Mega Mendung, Parang Rusak, Parang, Sekar Jagad, Truntum, Kipas, Semen, dan Fauna dengan total 3000 data citra. Kemudian dataset dibagi kedalam data latih dan data uji dengan perbandingan 90:10. Tahap selanjutnya adalah melakukan preprocessing pada data training dan data testing, yaitu dengan melakukan cropping dan resizing. Setelah tahap preprocessing selesai dilakukan, tahap selanjutnya adalah membangun model. Arsitektur model CNN yang dibangun dalam penelitian ini menggunakan sigmoid sebagai activator dan *Adam* sebagai fungsi optimizer, selain itu digunakan pula fungsi *binary cross entropy* untuk mengurangi data loss. Hasil pengujian didapatkan nilai akurasi terhadap model CNN yang dibangun dengan epoch 100 sebesar 91.41%, loss sebesar 0.344%, recall sebesar 86.96%, precision sebesar 94,5%, dan f-measure sebesar 90.5% [12].

Berdasarkan penjelasan dari beberapa penelitian sebelumnya, maka ringkasan penelitian-penelitian tersebut dapat dimuat didalam tabel 2.1 berikut:

**Tabel 2. 1 Penelitian Terdahulu Terkait CNN dan Transfer Learning**

No	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
1	<i>Convolutional Neural Network Untuk Metode Klasifikasi Multi- Label Pada Motif Batik, Bariyah, et. al., 2021 [12]</i>	Penelitian ini bertujuan untuk melakukan klasifikasi multi-label citra motif batik dengan menggunakan <i>Convolutional Neural Network (CNN)</i> .	Arsitektur yang digunakan pada penelitian ini hanya menggunakan CNN dasar. fungsi aktivasi yang digunakan adalah sigmoid dan fungsi <i>loss</i> yang digunakan adalah <i>binary cross entropy</i> . jumlah motif yang diklasifikasikan terdiri dari 15 motif.	Justifikasi mengenai klasifikasi multi-label sangat mungkin terjadi kasus <i>overfitting</i> dan langkah untuk mengatasi ketidakseimbangan data menggunakan <i>downsampling</i> atau <i>upsampling</i> sudah tepat. Namun jumlah dataset tiap kelas tidak diketahui jumlahnya berapa, sehingga sulit mengetahui apakah dataset yang digunakan seimbang atau tidak. dataset yang <i>imbalance</i> dapat mempengaruhi tingkat akurasi dan performa model. selain itu, untuk meminimalisir kasus <i>overfitting</i> dapat menggunakan teknik regularisasi seperti <i>dropout</i> .	Pada penelitian tersebut hanya dilakukan 2 teknik augmentasi data yaitu rotasi dan penskalaan pada citra. Adapun saran yang diberikan oleh penelitian tersebut yaitu menambah jumlah dataset untuk menghindari <i>overfitting</i> .	Hasil dari penelitian ini menunjukkan teknik augmentasi data dapat meningkatkan akurasi sekitar 10% untuk gambar yang diputar atau gambar yang diskalakan. Pengujian pada model CNN yang dibangun menghasilkan nilai <i>accuracy</i> sebesar 91.41%, <i>loss</i> sebesar 0.344%, <i>recall</i> sebesar 86.96%, <i>precision</i> sebesar 94,5%, dan <i>f-measure</i> sebesar 90.5%.

No	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
2	<i>Implementation of Data Augmentation Using Convolutional Neural Network for Batik Classification</i> , Chan Uswatun Khasanah et. al, 2020 [8]	Penelitian ini bertujuan menggunakan 8 data tambahan dengan Convolutional Neural Network (CNN) untuk mengklasifikasi batik.	Implementasi delapan teknik augmentasi data yaitu <i>rotation, zoom, shear, brightness, width &amp; height shift, random erasing</i> , dan <i>channel shift</i> . Dataset yang digunakan yaitu 500 gambar batik terdiri dari 5 kelas yaitu Ceplok, Kawung, Lereng, Nitik, dan Parang.	Penjelasan sumber dataset, kelas batik, dan jumlah citra per kelas sudah dijelaskan dengan baik. Skenario yang dibuat sudah baik dan sesuai dengan tujuan penelitian yang ingin dicapai. Hal tersebut diperkuat dengan hasil yang diperoleh dapat mencapai tingkat akurasi yang tinggi.	CNN telah diterapkan di berbagai jenis batik. Trisanti et al (2018) dan Handayani et al (2017) menggunakan 4 lapisan konvolusi dan 4 lapisan convolusi. Disamping menggunakan arsitektur CNN yang dirancang sendiri, beberapa peneliti juga mengklasifikasi batik menggunakan model yang teruji seperti VGG16, VGG19 (Wicaksono et al (2018), Agastya dan Setyanto (2018), dan Gultom et al (2018)) dan IncRes (Wicaksono et al (2018)). Penelitian yang dilakukan Gultom et al (2018), CNN (VGG19) menghasilkan akurasi tinggi dibandingkan SIFT (88±1% akurasi) dan SURF (88±8% akurasi) yang berkisar 89±7%.	Saat menggunakan data tambahan yaitu <i>width shift</i> dan <i>zoom</i> dapat meningkat 2.09%. Penggunaan CNN diterapkan pada penambahan data dapat meningkatkan akurasi 3.13%, dari 95.83% ke 98.96% dengan mengkombinasikan data augmentasi gambar melalui proses seleksi.
3.	Pengaruh Dimensi Gambar Pada Klasifikasi Motif Batik Menggunakan Convolutional Neural	Penggunaan beberapa dimensi citra yang dapat memengaruhi keakuratan akurasi pada klasifikasi batik.	Penggunaan dimensi gambar yang dapat mempengaruhi akurasi yang dihasilkan. Dimensi yang	Penelitian yang dilakukan sudah cukup baik dan tujuan jelas terarah. penelitian dapat ditingkatkan dengan	Penelitian sebelumnya A. Y. Wicaksono et al (2018) bertujuan untuk memodifikasi klasifikasi arsitektur batik	Pada penggunaan Convolutional Neural Network ukuran gambar mempengaruhi akurasi yang dihasilkan. Akurasi

No	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
	<i>Network</i> , Rizki Mawan, et. al, 2020 [13]		digunakan adalah 64x64,128x128, dan 256x256.	penambahan sumber dataset (tidak hanya mengunduh dari google) dan menambah lagi jumlah dataset yang digunakan.	menggunakan metode <i>Convolutional Neural Network</i> . Metode CNN yang diusulkan dengan arsitektur jaringan IncRes dapat digunakan untuk klasifikasi citra motif batik dengan akurasi 70,84%. Penelitian sebelumnya Abror, Tujuan dari penelitian ini adalah melakukan klasifikasi citra kebakaran menggunakan CNN. Akurasi yang dihasilkan menggunakan model pada tahap pelatihan sebesar 98.8% dan pada tahap pengujian sebesar 90%.	yang dihasilkan Metode <i>Convolutional Neural Network</i> dengan ukuran 64x64 = 92.85%, 128x128 =85%, 256x256 =80%
4	Implementasi Metode <i>Convolutional Neural Network</i> , Ath'oul Muwafiq, et. al., 2020 [19]	Sistem pengenalan jenis-jenis batik yang optimal melalui pendekatan algoritma CNN	Arsitektur yang digunakan GoogleNet, motif yang diklasifikasikan Kawung, Parang, Truntum, Sidomukti dan Satrio Manah.	Pada penelitian ini tidak dijelaskan apakah ada proses <i>preprocessing</i> atau tidak. data preparation tidak jelas. jumlah data citra tiap kelas tidak diketahui. tidak ada justifikasi yang menjelaskan mengapa arsitektur GoogleNet dikatakan sebagai arsitektur terbaik. Pada	Pada penelitian ini menggunakan GoogleNet dengan probabilitas sejumlah 0.855831 pada saat tahap pengklasifikasian kelas batik. sedangkan pada penelitian yang dilakukan penulis menggunakan arsitektur VGG-16 dan Xception. Kedua arsitektur dapat menghasilkan	Setelah dilakukan pengujian, didapat probabilitas sejumlah 0.855831 pada saat tahap pengklasifikasian kelas batik. sehingga metode ini membuktikan bahwa mampu mengklasifikasi batik dengan cukup baik.

No	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
				kesimpulan tidak diketahui dengan jelas hasil dari model yang dibangun hanya menyebutkan error rate. tidak diketahui tinjauan pustaka penelitian terdahulu seperti apa. metodologi penelitian dan dasar teori tidak jelas.	akurasi lebih tinggi yaitu sekitar 0.8833 sampai 0.9176.	
5	<i>VGG16 in Batik Classification based on Random Forest.</i> Arsa, 2019 [17]	Penelitian ini bertujuan untuk mengkaji lebih dalam klasifikasi batik menggunakan metode VGG16 dengan <i>Random Forest</i> sebagai pemisah.	Melakukan eksperimen dengan menggunakan <i>Random Forest</i> sebagai pengklasifikasi kemudian membandingkannya dengan metode VGG16+SVM.	Tidak dijelaskan tahap <i>preprocessing</i> yang dilakukan seperti apa.	Dataset dibagi kedalam 80:20. Metode yang diusulkan mengungguli penelitian sebelumnya. Dalam beberapa kasus mencapai 100% dalam hal presisi, <i>recall</i> , <i>F-score</i> , dan akurasi. Presisi pada penelitian Aditya (2020) lebih rendah dari <i>recall</i> .	Hasil yang didapat pada penelitian ini dibandingkan dengan penelitian sebelumnya yang menggunakan 50 dataset batik mencapai $\pm 97\%$ akurasi, pengulangan, presisi, dan f-score di semua keadaan.
6	<i>Transfer Learning using VGG-16 with Deep Convolutional Neural Network for Classifying Image,</i> Srikanth Tammina, 2019 [18]	Penelitian ini menggunakan <i>Convolutional Neural Network</i> (CNN) untuk memasukkan gambar melalui serangkaian lapisan yaitu konvolusi, penyatuan, perataan, dan lapisan terhubung sepenuhnya.	Terdapat tiga model yang dibangun, yaitu membangun jaringan saraf <i>convolutional</i> dasar dari awal kemudian melatih model tersebut pada dataset citra pelatihan dan mengevaluasinya, akurasi ditingkatkan menggunakan teknik <i>image augmentation</i>	Terdapat kesalahan pada jumlah keseluruhan dataset yang tidak sesuai dengan rincian jumlah data latih dan data validasi, kemudian tidak sesuai juga dengan nominal yang tertera.	Subjek penelitiannya adalah anjing dan kucing kemudian objek penelitiannya untuk membangun model klasifikasi citra yang kuat dengan batasan terdiri dari beberapa sampel pelatihan anjing dan kucing (masalah klasifikasi biner).	Pada penggunaan CNN menghasilkan 72,40% akurasi yang valid. Kemudian pada penggunaan model yang disesuaikan dengan penambahan gambar mencapai 79,20% akurasi. Manfaat menggunakan model yang terlatih (VGG16) pada dataset yang sangat



No	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
			dan memanfaatkan model pra-pelatihan VGG-16 yang sudah dilatih pada kumpulan data besar dengan beragam kategori untuk mengekstrak fitur dan mengklasifikasikan gambar.			banyak dan teknik augmentasi gambar yang disesuaikan mendapatkan akurasi hingga 95.40%.
7	<i>Classification of Indonesian Batik Using Deep learning Techniques and Data Augmentation</i> , I Made Artha Agastya, et. al., 2018 [6]	Implementasi metode <i>Convolutional Neural Network (CNN)</i> VGG-16 dan menggunakan teknik augmentasi data untuk meningkatkan akurasi.	Uji coba yang dilakukan berupa 3 skenario yaitu <i>non-split dataset, split dataset</i> , dan evaluasi keakuratan apabila gambar diputar atau diubah skalanya.	Penjelasan sumber dataset, kelas batik, dan jumlah citra per kelas sudah dijelaskan dengan baik.	Pada pengujian yang dilakukan Gultom et al (2018), CNN menunjukkan hasil yang menjanjikan karena dapat mencapai 89%±7%. Metode ini mengalahkan metode SIFT dan SURF dalam mengklasifikasi 6 tipe pola batik dengan data sejumlah 2092 gambar. Dalam pekerjaan berat yang dilakukan oleh Wicaksono et al (2017) dapat mencapai 70.84% akurasi dengan data sejumlah 7112 gambar yang diklasifikasikan dalam 11 jenis.	Pada penggunaan cnn VGG16 dan VGG19 menunjukkan bahwa dapat memprediksi mendekati 90% tepat dalam pengklasifikasian pola batik. Namun variasi gambar batik diputar dan diskalakan gambarnya maka tidak terdeteksi dalam pengklasifikasian pola batik. Sebagai gambaran, akurasi pengklasifikasian batik menjadi kurang dari 56% pada pola batik di skala 2.0, kemudian cnn diuji dengan augmentasi data untuk meningkatkan akurasi. Hasilnya dengan augmentasi data dapat

No	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
						meningkatkan 10% akurasi saat gambarnya diputar atau diubah skalanya.
8	<i>Batik Classification Using Deep Convolutional Network Transfer Learning</i> , Yohanes Gultom, et. al., 2018 [16]	Menggunakan arsitektur <i>Convolutional Network</i> untuk klasifikasi motif batik.	Mengatasi masalah <i>invariance dilemma</i> pada klasifikasi batik dengan melatih model yang diusulkan yaitu VGG-16 kemudian membandingkannya dengan model SIFT dan SURF.	Membandingkan kinerja model pra-pelatihan lainnya seperti VGG19, Xception, resnet50 dll pada dataset Batik, pelabelan data yang lebih baik (lebih ketat) dapat lebih meningkatkan akurasi model klasifikasi, menghapus data berkualitas rendah dan memproses data berkualitas tinggi dapat menghasilkan data yang homogen dan meningkatkan akurasi pengklasifikasi.	Model yang diusulkan (VGG16 MLP), mencapai akurasi yang sedikit lebih baik (1%) dan penyimpangan yang lebih sedikit daripada model SIFT dan SURF terbaik (SIFT logreg dan SURF MLP). Akurasi rata-rata yang dicapai oleh model yang diusulkan adalah juga $\pm 8\%$ lebih baik dari <i>Stacked-Autoencoder</i> yang menggunakan dataset dari asal yang sama. VGG16 pra-pelatihan mampu menangani dilema invarians pada citra Batik hampir sama baiknya dengan ekstraktor SIFT dan SURF.	Eksperimen menggunakan dataset 2,092 potongan foto Batik (5 kelas) menunjukkan bahwa model yang menggunakan ConvNet VGG16 sebagai ekstraktor fitur mencapai rata rata akurasi $89\pm 7\%$ sedangkan model berbasis SIFT dan SURF mencapai rata-rata $88\pm 10\%$ dan $88\pm 8\%$ . Meskipun demikian, SIFT lebih akurat sekitar 5% pada dataset yang dirotasi dan diperbesar.

Berdasarkan tinjauan pustaka yang telah dilakukan, dapat ditarik kesimpulan bahwa dalam penelitian ini akan mengambil dataset yang berasal dari beberapa sumber yaitu dataset penelitian terdahulu, *google image* dan jepretan kamera [8]. Dataset yang digunakan memiliki ukuran/dimensi sebesar 224x224 piksel [13]. Motif yang digunakan pada penelitian ini ada lima jenis motif batik, yaitu motif Ceplok, Kawung, Megamendung, Parang dan Sidomukti. Kemudian model klasifikasi yang dibangun menggunakan *Convolutional Neural Network* dengan memadukan dua model Transfer Learning yaitu VGG-16 dan Xception [16]. Agar dataset lebih bervariasi lagi, maka akan ditingkatkan dengan menggunakan teknik augmentasi data sehingga dapat memperkaya dataset yang dimiliki dan diharapkan dapat terhindar dari kasus overfitting [8]. Tujuan memadukan model CNN dengan *Transfer Learning* adalah untuk meningkatkan hasil akurasi yang sebelumnya didapatkan dari pelatihan model CNN [8] [18].

## 2.2 Dasar Teori

### 2.2.1 Batik

Batik memiliki nilai seni yang tinggi dan merupakan warisan nenek moyang yang telah menjadi bagian dari budaya Indonesia (khususnya Jawa). Kata "batik" berasal dari kata Jawa "tik" yang berarti "titik/matik" (kata kerja, membuat titik), yang kemudian berkembang menjadi batik. Salah satu bentuk seni kuno untuk mewarnai kain batik adalah teknik celup blok menggunakan lilin. Menurut Kamus Besar Bahasa Indonesia, batik adalah kain lukis yang dibuat khusus yang digunakan atau dililin dan diselesaikan melalui proses tertentu [20]. Batik merupakan salah satu kerajinan dan warisan budaya Indonesia yang memiliki nilai seni dan ekonomi yang tinggi. Batik adalah kerajinan berbentuk kain dengan motif tertentu, biasanya digunakan sebagai bahan pakaian. Batik juga diakui oleh *United Nations Educational, Scientific and Cultural Organization* (UNESCO) pada tahun 2009. Batik memiliki banyak motif yang unik. Motif batik sangat beragam, terutama pada batik tulis, karena dibuat oleh ahli batik [7]. Pada penelitian ini, peneliti menggunakan lima jenis motif batik yaitu Ceplok, Kawung, Parang, Megamendung dan Sidomukti.

#### b. Ceplok


Batik Ceplok memiliki pola dasar yang menggabungkan empat persegi dan lingkaran, umumnya terdiri dari garis dan kolom yang tersusun rapi [3].



**Gambar 2. 1 Contoh Motif Batik Ceplok**

c. Kawung

Kawung berpola bulat-bulat seperti buah kawung yang menyerupai kelapa atau kolang-kaling. Motif Kawung menunjukkan bahwa manusia harus selalu membantu dan bermanfaat bagi orang lain.



**Gambar 2. 2 Contoh Motif Batik Kawung**

d. Megamendung

Ini merupakan pola hias pengaruh Cina; awan terdiri dari gradasi biru berlatar merah; garis awan dihasilkan dengan pewarnaan langsung menggunakan kuas, dan latar diwarnai dengan celup tong. Istilah mendung diartikan sebagai orang yang sabar dan tidak mudah marah. Jadi, diharapkan orang yang memakai batik motif ini pun menjadi lebih sabar dan tenang [22].



**Gambar 2. 3 Contoh Motif Batik Megamendung**

e. Parang


Kata “parang” berasal dari kata “pereng” yang berarti lereng yang berarti lereng, maka motif garis miring diagonal. Kalau diperhatikan, motif membentuk huruf S, terjalin tanpa gangguan, mewakili kontinuitas dan semangat tanpa akhir.



**Gambar 2. 4 Contoh Motif Batik Parang**

f. Sidomukti

Sidomukti berarti mulia dan kaya dalam hidup. Kain batik ini ini dikenakan oleh calon pengantin, baik pria maupun wanita, pada saat akad nikah atau acara panggih [21].



**Gambar 2. 5 Contoh Motif Batik Sidomukti**

### 2.2.2 Pengolahan Citra Digital

Pemrosesan citra adalah studi tentang algoritma yang mengambil citra sebagai input dan mengembalikan citra sebagai output. Pemrosesan citra sekarang menjadi alat penting di banyak bidang ilmiah, termasuk ilmu komputer, teknik elektro, robotika, fisika, kimia, ilmu lingkungan, biologi, dan psikologi. Pemrosesan citra adalah subkelas pemrosesan sinyal. Input dari pemrosesan sinyal adalah citra, dan outputnya juga merupakan citra atau fitur yang terkait dengan citra itu. Saat ini, teknologi pengolahan citra berkembang pesat, dan banyak penelitian yang dilakukan pada pengolahan citra di bidang teknologi komputer dan rekayasa. [22]. Pengolahan citra digital (image processing) adalah proses memanipulasi piksel-piksel dari suatu citra digital untuk tujuan tertentu. Suatu citra dikatakan digital jika citra yang dihasilkan merupakan hasil dari komputer, kamera, scanner, atau alat

elektronik lainnya. Pengolahan citra digital dilakukan oleh komputer dengan menggunakan algoritma.. Citra digital direpresentasikan sebagai matriks, pemrosesan citra digital terutama tentang memanipulasi elemen matriks menjadi piksel [23].

### 2.2.3 *Deep learning*

Pembelajaran mendalam dapat memecahkan masalah inti pembelajaran representasi dengan memperkenalkan representasi yang diekspresikan dalam bentuk representasi sederhana lainnya. Pembelajaran mendalam memungkinkan komputer untuk menghasilkan konsep kompleks dari yang lebih sederhana [13]. Pembelajaran mendalam adalah cabang bidang pembelajaran mesin yang menggunakan jaringan saraf tiruan untuk memecahkan masalah pada kumpulan data besar. Teknik pembelajaran yang mendalam menyediakan arsitektur yang sangat kuat untuk pembelajaran yang diawasi dengan menambahkan lapisan tambahan, model pelatihan dapat mewakili citra yang diberi label dengan baik [19].

### 2.2.4 *Convolutional Neural Network (CNN)*


CNN merupakan salah satu algoritma deep learning yang merepresentasikan pengembangan multi-layer perceptrons (MLP) untuk dapat mengklasifikasikan data berlabel menggunakan CNN. *Convolutional Neural Network* (CNN) merupakan salah satu model deep learning yang banyak digunakan untuk keperluan analisa citra visual [24]. Namun, tidak seperti MLP, yang merepresentasikan neuron dalam satu dimensi, CNN merepresentasikan neuron dalam dua dimensi. [15].

*Convolutional Neural Network* memiliki 4 layer utama, yaitu :

#### a. *Convolutional Layer*

Lapisan convolutional melakukan operasi konvolusi pada input atau output dari lapisan sebelumnya. Tujuan dilakukannya konvolusi pada data citra yaitu untuk mengekstraksi fitur dari citra input. untuk

mengekstrak fitur dari citra masukan. *Feature Extraction* merupakan salah satu teknik untuk membentuk dataset baru dari original dataset. Dataset baru adalah hasil turunan dari dataset awal, sehingga ukurannya cenderung lebih kecil [25]. Konvolusi menghasilkan transformasi linier data masukan menurut informasi tertentu dalam data. Bobot lapisan menentukan kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan input pada CNN [19]. Konvolusi adalah jenis khusus dari operasi linier yang banyak digunakan di berbagai bidang seperti pemrosesan citra, statistik, dan fisika.



**Gambar 2. 6 Proses *Convolution Layer* [26]**

Seperti terlihat pada Gambar 2.6, convolution mengimplementasikan kernel (kotak kuning) pada gambar di semua kemungkinan offset. Kotak hijau keseluruhan mewakili gambar yang akan dikonvolusi. Kernel (kotak berwarna kuning) bergerak dari sudut kiri atas ke sudut kanan bawah. Sehingga hasil konvolusi dari citra dapat dilihat pada gambar di sebelah kanannya [26].

b. *Activation Layer*


Pada activation layer terdapat beberapa fungsi aktivasi yang digunakan untuk menentukan apakah neuron dari jaringan tersebut akan diaktifkan atau dinonaktifkan. Secara umum, ada dua jenis fungsi aktivasi: linier dan non-linier. Ada beberapa fungsi aktivasi yang berbeda untuk digunakan: Sigmoid merupakan fungsi non-linear dengan mempunyai nilai rentang antara 0 dan 1, Tanh merupakan fungsi non-linear yang memiliki nilai keluaran berada dalam rentang  $-1$  dan  $1$ , kemudian Rectified linear unit (ReLU) bersifat non-linear dengan kombinasi linear sehingga layers yang berbeda dapat ditumpuk



bersama. Nilai keluarannya berada dalam kisaran 0 hingga tak terbatas [27].

c. *Pooling Layer*

Kelemahan dari keluaran peta fitur dari lapisan konvolusi adalah bahwa ia merekam posisi yang tepat dari fitur dalam masukan. Ini berarti selama pemotongan, rotasi, atau perubahan kecil lainnya pada citra input akan sepenuhnya menghasilkan peta fitur yang berbeda. Untuk mengatasi masalah ini, kami mendekati pengambilan sampel lapisan konvolusi. *Downsampling* dapat dicapai dengan menerapkan lapisan penyatuan setelah lapisan nonlinier. Pooling membantu membuat representasi lebih atau kurang invarian terhadap terjemahan kecil dari input. Invarians terjemahan berarti bahwa menerjemahkan beberapa input tidak mengubah sebagian besar nilai dalam output [28].




**Gambar 2.7 Metode Pooling [18]**

Seperti yang ditunjukkan pada Gambar 2.7, ada dua metode pooling yang biasa digunakan yaitu *average pooling* dan *max pooling*. Pada *average pooling*, nilai yang diperoleh adalah nilai rata-rata dari matriks yang menjalani operasi pooling. Sedangkan *max pooling* adalah dengan mengambil nilai tertinggi. *Pooling layer* yang disisipkan di antara *convolutional layer* yang berurutan dalam arsitektur CNN dapat mengurangi ukuran volume output pada *feature map*, sehingga

mengurangi jumlah parameter dan komputasi dalam jaringan dan mengontrol *overfitting*. Lapisan pooling bekerja di setiap tumpukan feature map dan melakukan pengurangan pada ukurannya [29].

d. *Fully Connected Layer*

*Fully connected layer* terdiri dari beberapa lapisan yang didalamnya tersusun atas beberapa node/neuron yang sepenuhnya terhubung ke lapisan sebelumnya. Metode yang digunakan pada layer ini adalah *multi-layer perceptron*. Lapisan ini memproses nilai-nilai yang diperoleh dari proses sebelumnya untuk memastikan hasil yang diharapkan. Pada dasarnya, metode yang digunakan dalam *fully connected layer* akan melihat kombinasi fitur-fitur yang didapat dari lapisan sebelumnya untuk dipelajari, sehingga akan menunjukkan bahwa rangkaian fitur-fitur tersebut termasuk ke dalam kelas tertentu [30]. Mungkin ada satu atau lebih dari lapisan ini. *Fully connected* artinya setiap node pada layer pertama terhubung dengan setiap node pada layer kedua seperti yang terlihat pada Gambar 2.8 di bawah ini [18].

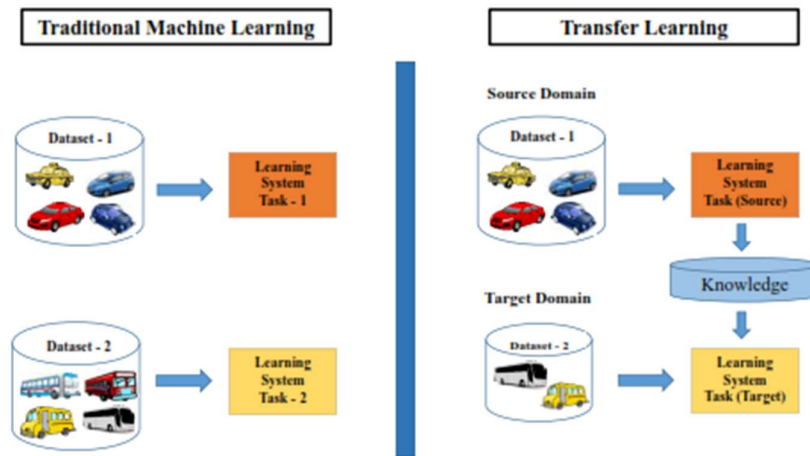


**Gambar 2. 8 Fully Connected Layer [31]**

### 2.2.5 *Transfer Learning*

*Transfer learning* adalah teknik pembelajaran mendalam baru yang menerapkan pengetahuan dari domain yang berbeda tetapi terkait ke domain target. Tujuan *transfer learning* adalah untuk meningkatkan proses

pembelajaran domain target dengan mentransfer pengetahuan ketika tidak ada pola pelatihan yang cukup di domain target [32].



**Gambar 2. 9 Perbedaan Traditional Machine Learning dengan Transfer Learning [33]**


Gambar 2.9 menunjukkan perbedaan antara pendekatan pembelajaran mesin tradisional dan pendekatan pembelajaran transfer. Pada gambar, ada dua dataset berbeda yang diambil, masing-masing mobil dan bus. Dataset memiliki dua tugas berbeda yang yaitu klasifikasi mobil dan bus. Pembelajaran mesin tradisional membutuhkan pelatihan untuk mempelajari tugas dari waktu ke waktu, sementara pembelajaran transfer membutuhkan pelatihan dari model yang sebelumnya dilatih ke domain target baru menggunakan sampel pelatihan yang lebih kecil.

Terdapat tiga metode pada Transfer Learning. metode pertama adalah transfer instan. Dalam pendekatan ini, data dari domain sumber dapat digunakan kembali di domain target bersama dengan data target untuk meningkatkan tugas target. Ini disebut sebagai pembobotan ulang. Transfer representasi fitur adalah pendekatan kedua di mana tugas target dapat ditingkatkan dengan mempelajari representasi fitur dari sumbernya. Ini mencoba untuk mengurangi perbedaan antara sumber dan domain target dan mengurangi kesalahan model prediktif dengan menemukan fitur yang baik.

Lapisan menengah model pra-terlatih telah disesuaikan dengan dataset ImageNet untuk mempelajari tugas-tugas baru dengan mentransfer fitur melalui fitur buatan sendiri [34].

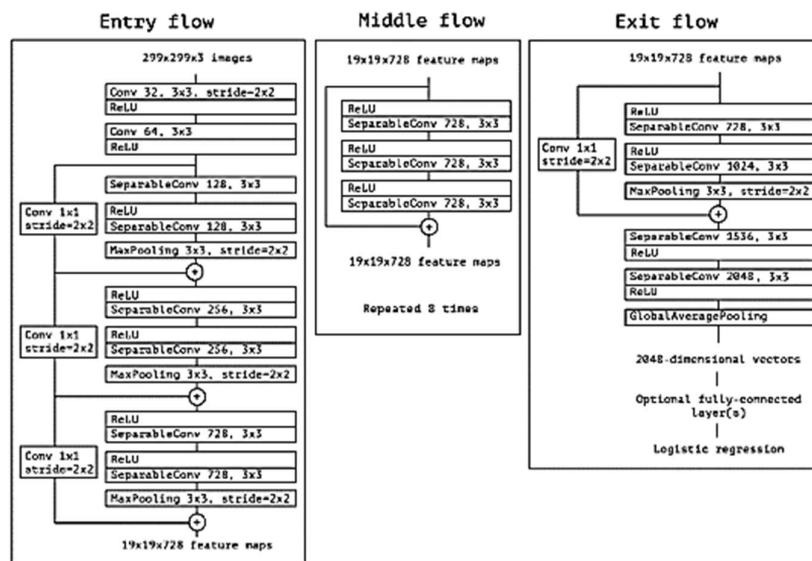
Jaringan konvolusi dengan cara Transfer Learning yang dapat dimanfaatkan pada CNN adalah ResNet, VGG, Inception, dan Xception. Namun, hanya VGG dan Xception yang digunakan dalam penelitian ini..

1. VGG: Dalam ajang kompetisi *ImageNet*, jaringan VGG mampu bersaing dalam hal lokalisasi dan klasifikasi objek. Selain itu, VGG terbukti mengungguli GoogleNet dalam tugas *multiple migration learning*. Arsitektur VGG terdiri atas blok-blok konvolusi yang diantaranya terdapat *Rectified Linear Unit* (ReLU) dan maxpooling sebagai penghubung, yang kemudian diakhiri dengan *fully connected layer* dengan 1.000 kelas. Salah satu fitur ReLU dan Maxpooling dalam arsitektur adalah untuk mengurangi dimensi proses blok konvolusi hanya dengan menggunakan satu langkah dan satu padding. Di bawah ini adalah Gambar 2.10 Arsitektur VGG-16 [35].



**Gambar 2. 10 Arsitektur VGG-16 [35]**

2. Xception: *Xception* atau *Extream Inception* merupakan pengembangan dari Inception tradisional yang mempunyai 36 lapisan konvolusional yang membentuk basis jaringan ekstraksi fitur. Lapisan konvolusional ini dipisahkan oleh jaringan residual yang menghubungkan satu sama lain [36]. Baru-baru ini jaringan Xception dapat mengungguli varian jaringan lebih dalam yang sekaligus memiliki lebih sedikit parameter [37]. Pada arsitekturnya, setelah blok konvolusional pertama dilakukan pemisahan setiap saluran secara spasial dengan cara melakukan konvolusi  $1 \times 1$ , kemudian keluaran tersebut ditangkap untuk mendapatkan korelasi *cross-channel*. Arsitektur ini diwakili dengan Gambar 2.11.



**Gambar 2. 11 Arsitektur Xception [38]**

Pemisahan saluran menggunakan konvolusi dengan ukuran  $1 \times 1$  dan dengan *depthwise separable convolution* kemudian menangkap keluaran tersebut dengan melakukan filter concat untuk kemudian dilakukan pemrosesan ke jaringan konvolusi berikutnya. Pada penelitian sebelumnya, Xception mampu menghasilkan score lebih unggul daripada Inception dalam penggunaan dataset ImageNet pada klasifikasi objek dengan 17.000 kelas [35].

### 2.2.6 Confusion Matrix

*Confusion matrix* adalah salah satu metode pengukuran keputusan yang banyak digunakan dalam *supervised machine learning* [39]. Matriks konfusi berisi informasi tentang hasil aktual dan prediksi dari sistem klasifikasi [30]. Berikut pada Tabel 2.2 adalah acuan confusion matrix yang memperlihatkan prediksi dan kondisi sebenarnya dari data yang dihasilkan oleh algoritma yang digunakan. Informasi yang ditampilkan dalam confusion matrix merupakan angka-angka probabilitistik [39].

**Tabel 2. 2 Confusion Matrix**

Predicted Values	Actual Values	
	1 (Positive)	0 (Negative)
1 (Positive)	TP ( <i>True Positive</i> )	FP ( <i>False Positive</i> )
0 (Negative)	FN ( <i>False Negative</i> )	TN ( <i>True Negative</i> )

Keterangan:

TP (*True Positive*) : jumlah prediksi yang benar dalam kelas positif

FP (*False Positive*) : jumlah prediksi yang salah dalam kelas positif

FN (*False Negative*) : jumlah prediksi yang salah dalam kelas negatif

TN (*True Negative*) : jumlah prediksi yang benar dalam kelas positif

Penentuan baik atau tidaknya performa suatu model klasifikasi dapat dilihat dari parameter pengukuran performanya, yaitu tingkat akurasi, recall, dan presisi.

- a. Akurasi merupakan persentase keakuratan pengklasifikasi dalam mengklasifikasikan data uji dengan benar. Di bawah ini merupakan persamaan (2.1) untuk menghitung nilai akurasi:

$$Accuracy = \frac{TP}{TP+TN+FP+F} * 100\% \quad (2.1)$$

- b. Presisi adalah ukuran presisi untuk menentukan proporsi tupel yang ditandai sebagai positif dan benar-benar positif. Di bawah ini merupakan persamaan (2.2) untuk menghitung nilai akurasi:

$$Precision = \frac{TP}{TP+} \% \quad (2.2)$$

- c. *Recall* atau *true positive rate* merupakan porsi dari tuple positif yang diklasifikasi dengan benar. Di bawah ini merupakan persamaan (2.3) untuk menghitung nilai akurasi:

$$Recall = \frac{TP}{TP+FN} \quad (2.3)$$

- d. *F1-Score*

*F1-Score* merupakan parameter tunggal yang menggabungkan *recall* dan presisi untuk mengukur keberhasilan pencarian. Nilai *F1-Score* merupakan hasil perkalian presisi dan *recall*, dibagi dengan jumlah presisi dan *recall*, dan dikalikan dua.

### 2.2.7 Bahasa Pemrograman Python

Python merupakan bahasa pemrograman dengan tujuan umum yang dirancang secara khusus untuk membuat source code mudah dibaca. Python juga memiliki library yang lengkap sehingga memungkinkan programmer untuk membuat aplikasi yang mutakhir dengan menggunakan source code yang tampak sederhana [40].

### 2.2.8 TensorFlow

*Tensorflow* merupakan perpustakaan perangkat lunak yang dikembangkan oleh Tim Google Brain dalam organisasi penelitian Mesin Cerdas Google, untuk tujuan melakukan pembelajaran mesin dan penelitian jaringan syaraf dalam. Tensorflow mencakup teknik pengoptimalan kompilasi aljabar komputasi yang mempermudah penghitungan banyak ekspresi matematis dimana masalahnya adalah waktu yang dibutuhkan untuk melakukan perhitungan [40].

Fitur utamanya meliputi:

- a. Mendefinisikan, mengoptimalkan, dan menghitung secara efisien ekspresi matematis yang melibatkan array multi-dimension (tensors).

- b. Pemrograman pendukung jaringan syaraf dalam dan teknik pembelajaran mesin.
- c. Penggunaan GPU yang transparan, mengotomatisasi manajemen dan optimalisasi memori yang sama dan data yang digunakan. Tensorflow bisa menulis kode yang sama dan menjalankannya baik di CPU atau GPU.
- d. Skalabilitas komputasi yang tinggi di seluruh mesin dan kumpulan data yang besar.