

# Identifikasi Motif Jepara pada Ukiran dengan Memanfaatkan *Convolutional Neural Network*

## (*Identification of Jepara Motifs on Carvings by Utilizing Convolutional Neural Network*)

Sandhopi<sup>1</sup>, Lukman Zaman P.C.S.W<sup>2</sup>, Yosi Kristian<sup>3</sup>

**Abstract**— The more the development of the carving motifs, the more varied the shapes and variations. It complicates the determination of a carving with Jepara motif. In this paper, the transfer learning method with developed FC was used to identify Jepara's distinctive motifs in a carving. The dataset was divided into three color spaces, i.e., LUV, RGB, and YcrCb. Besides, sliding windows, non-max suppression, and heat maps were utilized for the process of tracing the area of the engraved object and identifying Jepara motifs. The test results of all weights showed that the Xception on the Jepara motif classification had the highest accuracy values, namely 0.95, 0.95, and 0.94 for each LUV, RGB, and YCrCb color space dataset. However, when all the model weights were applied to the Jepara motif identification system, ResNet50 was able to outperform all networks with motif identification percentage values of 84%, 79%, and 80%, for the LUV, RGB, and YCrCb color spaces, respectively. These results prove that the system is able to assist in the process of determining whether a carving is included in the Jepara carving or not, by identifying the typical Jepara motifs contained in the carving.

**Intisari**—Semakin berkembang motif ukiran, semakin beragam bentuk dan variasinya. Hal ini menyulitkan dalam menentukan suatu ukiran bermotif Jepara. Pada makalah ini, metode *transfer learning* dengan FC yang dikembangkan dimanfaatkan untuk mengidentifikasi motif khas Jepara pada suatu ukiran. *Dataset* dibedakan menjadi tiga *color space*, yaitu LUV, RGB, dan YcrCb. Selain itu, *sliding window*, *non-max suppression*, dan *heat maps* dimanfaatkan untuk proses penelusuran area objek ukiran dan pengidentifikasian motif Jepara. Hasil pengujian dari semua bobot menunjukkan bahwa Xception pada klasifikasi motif Jepara memiliki nilai akurasi tertinggi, yaitu 0,95, 0,95, dan 0,94 untuk masing-masing *dataset color space* LUV, RGB, dan YCrCb. Namun, ketika semua bobot model tersebut diterapkan pada sistem identifikasi motif Jepara, ResNet50 mampu mengungguli semua jaringan dengan nilai persentase identifikasi motif sebesar 84%, 79%, dan 80%, untuk masing-masing *color space* LUV, RGB, dan YCrCb. Hasil ini membuktikan bahwa sistem mampu membantu dalam proses menentukan suatu ukiran, termasuk ke dalam ukiran Jepara atau bukan, dengan mengidentifikasi motif-motif khas Jepara yang terdapat dalam ukiran.

**Kata Kunci**— *Color Space, Convolutional Neural Network, Motif Jepara, Transfer Learning, Ukiran.*

<sup>1,2,3</sup> Departemen Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya (ISTTS), Jl. Ngagel Jaya Tengah 73-77, Surabaya, Jawa Timur, Indonesia 60284 (tlp: 031-5027920; e-mail: sandhopi1@mhs.stts.edu, lz@stts.edu, yosi@stts.edu)

### I. PENDAHULUAN

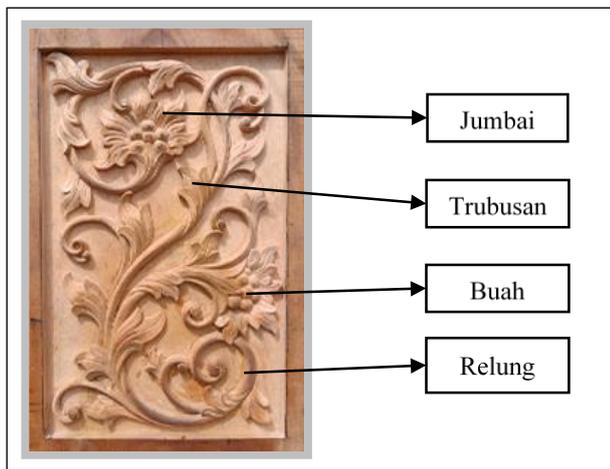
Kota Jepara merupakan salah satu kota yang berada di Jawa Tengah. Seni ukirannya yang terkenal mampu menjadikan kota ini dijuluki dengan Kota Ukir [1]. Selain itu, *The World Carving Center* juga menjadi sebutan untuk kota ini, karena produk-produk ukiran dari Kota Jepara sangat terkenal di berbagai negara dan banyak yang menyukainya [2]. Hal ini disebabkan karena ukiran dari Kota Jepara memiliki motif yang khas di setiap ukirannya [3].

Ciri khas motif Jepara sendiri merupakan ekspresi dari bentuk tanaman yang menjalar. Hal inilah yang membedakan ukiran tersebut merupakan motif Jepara atau bukan. Salah satu cirinya adalah corak dan motif dari ukiran seperti pada Gbr. 1 [3].

Pada Gbr. 1, ciri motif Jepara memiliki jumbai atau ujung relung seperti kipas yang sedang terbuka. Biasanya di tengah jumbai terdapat buah-buah kecil yang berbentuk lingkaran. Selain itu, terdapat juga tiga atau enam biji buah susun yang keluar dari pangkal daun, sedangkan tangkai relungnya memutar dengan gaya memanjang dan menjalar membentuk cabang-cabang kecil yang berguna untuk mengisi ruang dan memperindah tampilan. Di setiap relung menempel daun/trubusan yang ujungnya mengecil atau meruncing.

Ketenaran seni ukir Jepara tidak terlepas dari perkembangan motif yang ada pada ukiran Jepara. Perkembangan motif yang terjadi merupakan wujud inovasi pengrajin dalam memberikan kesan luwes dan lebih rapi pada ukiran supaya tidak monoton dan membosankan. Hal ini yang menjadikan motif pada ukiran Jepara sangat beragam bentuk dan variasinya. Kombinasi motif Jepara dengan motif lain juga menjadi salah satu cara dalam mengembangkan motif ukiran dan hal ini akan semakin mempercantik produk ukiran [4]. Akan tetapi, di sisi lain, semakin berkembang varian motif dan bentuk ukiran Jepara, semakin berkurang karakter dari ciri khas motif Jepara itu sendiri. Hal ini yang menyebabkan suatu ukiran Jepara sulit diidentifikasi, ukiran tersebut termasuk ukiran dengan motif Jepara atau bukan. Dengan belum adanya penelitian yang mencoba mengidentifikasi motif ukiran Jepara dengan *Convolutional Neural Network* (CNN), maka pada makalah ini diusulkan CNN dengan *transfer learning* dimanfaatkan untuk mengatasi masalah tersebut, yang diharapkan mampu mendapatkan hasil yang lebih baik tanpa perlu mengidentifikasi ciri dari motif Jepara secara manual.

Pada penelitian sebelumnya, CNN banyak digunakan dalam mengatasi masalah citra, terutama pada klasifikasi objek. Penelitian tersebut mengusulkan CNN untuk identifikasi motif



Gbr. 1 Motif ukiran Jepara.

tradisional Rumania [5], mendeteksi pendarahan pada otak [6], deteksi dan pengenalan *traffic light* [7], menentukan penyakit pada tanaman [8], dan mengklasifikasi gambar sel malaria [9]. Metode CNN yang digunakan dalam penelitian tersebut memberikan hasil yang menjanjikan. Hal ini dikarenakan dalam prosesnya CNN mampu menemukan ciri-ciri informasi yang terdapat dalam data dengan banyak varian [10], [11], sehingga dalam mengklasifikasi gambar jauh lebih efisien. Di samping itu, juga karena CNN bersifat *scalable* dalam jumlah *dataset* yang besar [5].

Implementasi CNN dalam makalah ini mengusulkan *Residual Network (ResNet)* sebagai jaringan yang digunakan untuk mengklasifikasi objek ukiran dan objek motif pada sebuah citra, karena pada penelitian lain jaringan ini mampu menghasilkan kinerja yang baik, dengan nilai akurasi sebesar 95% [9] dan 98% [8]. Kemudian, karena kinerja dan hasil yang sangat baik, sebuah penelitian tentang ResNet mampu menjadi pemenang di kompetisi ILSVRC & COCO 2015 [12]. Selain menggunakan *ResNet*, makalah ini juga menggunakan beberapa metode *transfer learning* lainnya, seperti VGG16, *InceptionV3*, dan *Exception* sebagai eksperimen dan beberapa teknik penelusuran area objek, seperti *sliding window*, *heat maps*, dan NMS yang bertujuan untuk segmentasi area ukiran dan identifikasi motif Jepara

Kontribusi makalah ini dapat dijelaskan sebagai berikut.

- CNN dengan *transfer learning*, *sliding window*, dan *heat maps/non-max suppression* digunakan untuk segmentasi area ukiran dan identifikasi motif Jepara.
- Makalah ini melakukan tiga kali eksperimen dengan tiga *color space* (RGB, LUV, YCrCb) pada masing-masing pembelajaran untuk mendapatkan hasil yang paling baik di antara ketiga *color space* tersebut ketika bobot diterapkan dalam sistem.
- Segmentasi area ukiran dilakukan dengan menggunakan dua fungsi, yaitu *heat maps* dan *non-max suppression*. Hal ini bertujuan untuk menghasilkan area ukiran yang optimal dan kemudian dipotong sehingga menghasilkan citra ukiran yang kemudian digunakan untuk mengidentifikasi motif Jepara yang ada pada citra ukiran tersebut.

Makalah ini disusun dalam beberapa bagian. Bagian I merupakan pendahuluan, bagian II berisi penelitian terkait yang dibahas, bagian III menjelaskan metodologi mengenai desain sistem dari model yang diusulkan, bagian IV adalah hasil eksperimen dan pembahasan, dan bagian terakhir berisi kesimpulan dan saran.

## II. CONVOLUTIONAL NEURAL NETWORK DALAM KLASIFIKASI

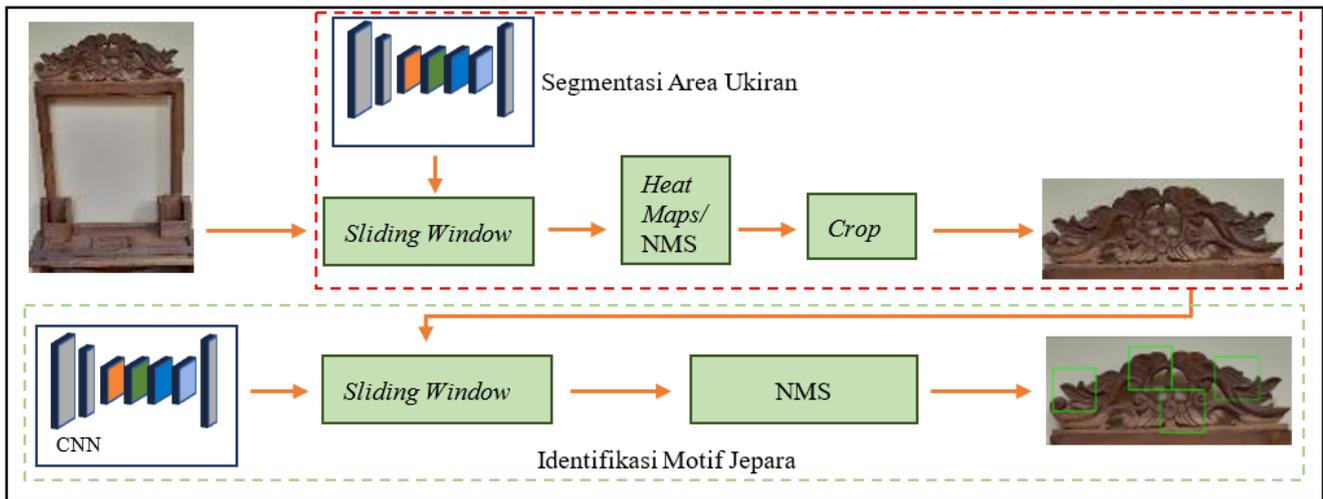
CNN sudah banyak dimanfaatkan untuk mengklasifikasi objek, karena CNN mampu memberikan hasil akurasi yang tinggi dengan waktu yang efisien [5]. Salah satunya adalah tentang pengklasifikasian motif tradisional Rumania [5]. CNN pada penelitian ini digunakan untuk mengidentifikasi dan mengklasifikasi lima kategori yang berbeda dalam motif tradisional Rumania, empat kategori dari kelas motif yang terdiri atas baju, keramik, karpet, telur bergambar, dan gambar yang bukan termasuk kelas motif. Jaringan yang digunakan adalah *ResNet50* yang dimodifikasi. Hasil penelitian memberikan akurasi sebesar 99,4% dengan menggunakan *dataset color space* RGB dan proses pelatihan dilakukan sebanyak dua puluh *epoch* [5].

Pada penelitian lain, CNN juga dimanfaatkan untuk mendeteksi pendarahan pada otak [6]. Sebelum dilakukan pelatihan, *dataset* dengan *color space* RGB sejumlah dua ratus buah, dengan masing-masing seratus gambar otak normal dan seratus gambar otak pendaharan, dilewatkan ke jaringan *autoencoder* dengan ukuran gambar masukan  $128 \times 128$  piksel. Untuk mendapatkan fitur *output image* dari jaringan *encoder*, dilakukan pelatihan menggunakan arsitektur AlexNet dengan *learning rate* senilai 0,001 dan *mini-batch* diatur senilai 16. Setelah itu, dari fitur-fitur yang terbentuk dilakukan pengklasifikasian dengan bantuan SVM sebagai *classifier*. Penelitian ini menghasilkan tingkat akurasi sebesar 98,7%.

Selain CNN dengan jaringan-jaringan tersebut, *ResNet* juga mampu memberikan hasil yang sangat baik. Pada penelitian mengenai *ResNet* [12], penelitian ini mampu memenangkan juara pertama pada kompetisi di bidang *ImageNet detection*, *ImageNet localization*, *COCO detection*, dan *COCO segmentation*. Jaringan ini dimanfaatkan untuk mengklasifikasi gambar sel pada penyakit malaria. *Color space* yang digunakan pada *dataset* adalah RGB dengan ukuran masing-masing gambar  $124 \times 124$  piksel. Penelitian ini menghasilkan validasi akurasi sebesar 95% dan validasi *loss* sebesar 13% [9].

Selanjutnya, *ResNet* ini dimanfaatkan untuk mengidentifikasi penyakit pada tanaman dengan mengambil sampel gambar daun sehat dan yang mempunyai penyakit. Jumlah *dataset* yang digunakan sebanyak 70.295 untuk data pelatihan dan 17.572 untuk data validasi, dengan jumlah kelas target 38. Ukuran gambar yang digunakan sebesar  $224 \times 224$  piksel dengan *color space* RGB. Pada saat pelatihan, *epoch* diatur sebanyak 25, *batch size* 32, dan *step per epoch* 550. Setelah dilakukan pelatihan, dihasilkan tingkat akurasi pada data latih sebesar 99% dan data validasi sebesar 100% [8].

Selain teknik untuk klasifikasi, teknik lokalisasi juga diperlukan pada deteksi objek untuk menentukan area objek. Pada beberapa tahun terakhir, untuk menemukan area objek, teknik *sliding window* banyak dimanfaatkan untuk membantu



Gbr. 2 Tahap-tahap identifikasi motif Jepara.

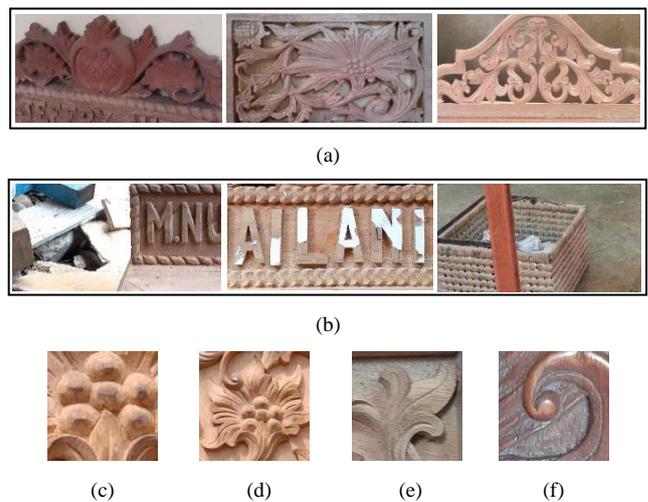
tugas tersebut [13]. *Sliding window* adalah sebuah kotak persegi yang menelusuri dari bagian kiri atas sampai ke bagian kanan bawah dengan berbagai ukuran [14]. Nilai perpindahan terbaik kotak persegi dari setiap pergerakan adalah 25% [15]. Teknik ini dapat mendeteksi objek tertentu dan melokalisasi objek tersebut setelah melakukan penyelidikan bagian per bagian dari gambar [13], [16]. Namun, masih ada masalah dalam teknik ini, yaitu terdapat lebih dari satu kandidat area pada objek yang sama, area yang tumpang tindih, dan redundansi yang tinggi [17]. Oleh karena itu, perlu ditambahkan teknik lain untuk mereduksi beberapa kandidat area tersebut untuk menghasilkan satu area optimal. Dari artikel yang membahas mengenai *Non-Max Suppression (NMS)*, teknik ini mampu menghilangkan beberapa kandidat dengan mengambil nilai maksimum dari masing-masing kandidat area yang muncul [18]. Teknik lain seperti *heat maps* juga mampu menghasilkan hanya satu kandidat area di setiap objek [19], [20]. Pada penelitian deteksi objek yang menggunakan teknik *heat maps*, teknik ini mampu memberikan lokalisasi secara optimum dan memberikan informasi semantik dalam algoritme penelusuran [19].

Berdasarkan pembahasan di atas, makalah ini mengusulkan digunakannya *color space RGB* pada penggunaan *dataset* dan menambahkan LUV serta YCrCb sebagai eksperimen. Selain itu, CNN dimanfaatkan sebagai *classifier* dengan menambahkan fungsi *sliding window* dan *heat maps* atau NMS untuk mendapatkan area akhir objek ukiran dan motif. Arsitektur yang diterapkan pada CNN adalah *transfer learning* dari *ResNet50* dan menambahkan VGG16, *Inception*, dan *Xception* sebagai pembanding.

Teknik *heat maps* dan NMS secara bersamaan digunakan pada proses segmentasi area objek ukiran. Hal ini bertujuan untuk membandingkan dan mendapatkan hasil segmentasi objek ukiran yang paling optimal antara kedua fungsi tersebut.

### III. IDENTIFIKASI MOTIF JEPARA

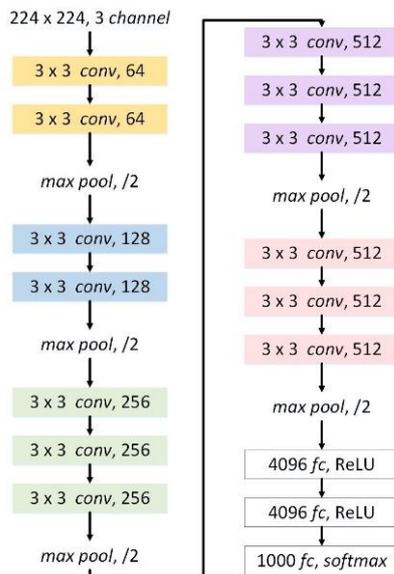
Identifikasi motif Jepara diawali dengan tahap segmentasi area ukiran, kemudian tahap identifikasi motif Jepara itu sendiri. Tahap ini dimulai dengan melakukan pelatihan



Gbr. 3 Gambar *dataset*, (a) ukiran, (b) bukan ukiran, (c) motif b, (d) motif jumbai, (e) motif trubusan, dan (f) bukan motif.

terhadap model yang diusulkan. Pelatihan dilakukan dengan mengklasifikasikan objek ukiran dengan bukan ukiran dan mengklasifikasikan objek motif Jepara (trubusan, buah, dan jumbai) dengan bukan motif Jepara. Bobot terbaik dari pelatihan klasifikasi objek ukiran digunakan untuk proses segmentasi area ukiran dan bobot terbaik dari pelatihan klasifikasi motif digunakan untuk identifikasi motif Jepara. Selanjutnya, teknik *sliding window* dan *heat maps* digunakan untuk mendapatkan area akhir objek ukiran, demikian juga proses identifikasi motif Jepara, tetapi pada pencarian area akhir hanya menggunakan teknik NMS. Penjelasan dari tahap tersebut dapat diilustrasikan pada Gbr. 2.

Pada klasifikasi objek ukiran, *dataset* terdiri atas gambar ukiran dan bukan ukiran, masing-masing sebanyak 3.005 gambar ukiran dan 3.000 gambar bukan ukiran. Sementara itu, dalam klasifikasi motif Jepara, *dataset* terdiri atas gambar motif trubusan, buah, jumbai, dan gambar bukan motif, masing-masing sebanyak 3.750 gambar motif trubusan, 3.750 gambar motif buah, 3.785 gambar motif jumbai, dan 3.800 gambar bukan motif. Contoh *dataset* ditunjukkan pada Gbr. 3.



Gbr. 4 Arsitektur transfer learning VGG16.

Semua *dataset* yang sudah terkumpul tidak dapat secara langsung digunakan, karena ada kemungkinan ukuran piksel yang berbeda. Oleh karena itu, perlu dilakukan praproses terhadap *dataset* data gambar, dari segi ukuran dan warna, untuk memastikan *dataset* dapat diterima ketika diumpangkan ke dalam CNN [21].

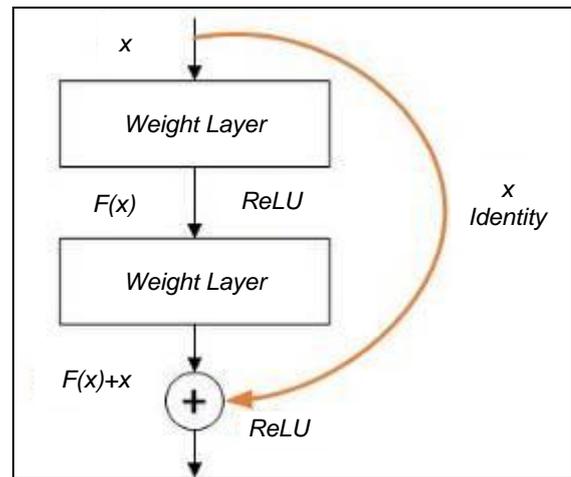
#### A. Praproses

Makalah ini melakukan tiga eksperimen untuk mendapatkan kinerja sistem yang paling baik. Perbedaan dari tiga eksperimen tersebut terletak pada *color space dataset* yang digunakan dalam pelatihan dan konversi warna pada saat proses penelusuran objek yang dilakukan *sliding window* pada tahap klasifikasi objek. Tiga eksperimen tersebut menggunakan tiga jenis *color space*, yaitu RGB, LUV, dan YCrCb. Untuk memenuhi kebutuhan, *dataset* dikonversi ke tiga *color space* (RGB, LUV, dan YCrCb). Setelah dilakukan konversi, ukuran masing-masing *dataset* disamakan untuk konsistensi data, kemudian dilakukan pembagian dari semua *dataset*: 60% untuk data pelatihan, 20% untuk validasi, dan 20% untuk pengujian. Setelah itu, *dataset* siap diumpangkan ke CNN.

#### B. Transfer Learning

Makalah ini mengusulkan pemanfaatan CNN dengan cara *transfer learning*. Jaringan konvolusi yang digunakan adalah *ResNet*, *VGG*, *Inception*, dan *Xception*.

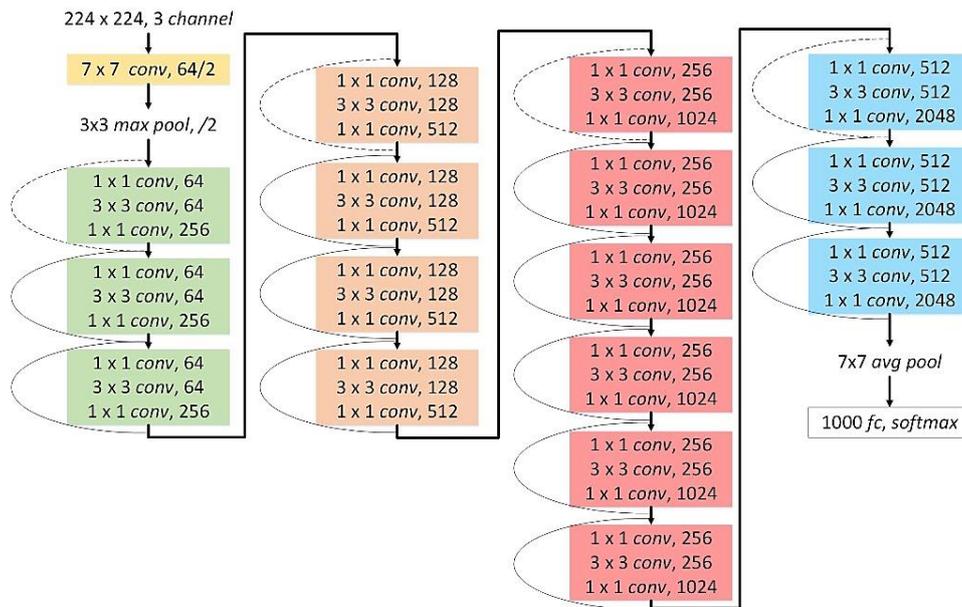
1) *VGG*: Dalam ajang kompetisi *ImageNet*, jaringan VGG mampu bersaing dalam hal lokalisasi dan klasifikasi objek [22]. Selain itu, VGG terbukti berkerja lebih baik daripada *GoogLeNet* dalam tugas *multiple migration learning* [23]. Arsitektur VGG terdiri atas blok-blok konvolusi yang di antaranya terdapat *Rectified Linear Unit (ReLU)* dan *maxpolling* sebagai penghubung, yang kemudian diakhiri dengan *fully connected layer* dengan 1.000 kelas, dalam kasus ini fungsi yang digunakan adalah *softmax*. Fungsi *ReLU* dan *maxpolling* pada arsitektur tersebut adalah untuk mereduksi



Gbr. 5 Skip connection.

dimensi dari proses blok konvolusi yang hanya menggunakan satu *stride* dan satu *padding*. Dalam makalah ini, jaringan VGG yang digunakan adalah VGG16 dengan enam belas lapisan (*layer*). Arsitekturnya ditunjukkan pada Gbr. 4 [22]. Banyaknya parameter yang digunakan mengakibatkan terjadinya kompleksitas dalam proses komputasi [24] dan menurunnya kinerja [23]. Dari kelemahan ini, kemudian ditemukan bahwa dengan menghilangkan *fully connected layer*, parameter dapat direduksi secara signifikan tanpa menurunkan kinerja [22], [24].

2) *Residual Network (ResNet)*: *ResNet* merupakan jaringan saraf tiruan yang dibangun berdasarkan konstruksi dari sel piramidal di korteks serebral. Jaringan bekerja dengan memanfaatkan *skip connection* atau pintasan untuk melompati beberapa lapisan. Lapisan *skip connection* dapat diilustrasikan seperti Gbr. 5 [12]. Pada Gbr. 5, *skip connection* diwakili oleh panah kuning yang hanya membawa masukan  $x$  ke keluaran dua lapisan yang dihasilkan  $F(x)$ , sehingga keluaran keseluruhan adalah  $F(x) + x$ . Formula tersebut memberikan intuisi bahwa jaringan ini memiliki aliran gradien yang tidak terputus dari lapisan pertama sampai ke lapisan terakhir. Hal ini bertujuan untuk menangani informasi gradien yang hilang dan mempertahankan pengetahuan [12], [25]. Pada makalah ini, *ResNet* yang diusulkan adalah *ResNet50*, yang memiliki arsitektur seperti pada Gbr. 6. Jaringan ini memiliki beberapa blok yang juga dihubungkan oleh *skip connection*. Hal ini yang diandalkan *ResNet50* dalam mengatasi *vanishing* atau *exploding gradient* dan masalah degradasi dalam proses pelatihan [8]. Pada lapisan pertama, ukuran *kernel*  $7 \times 7$  dengan 64 filter selanjutnya dilewatkan dengan *max pooling* ukuran *kernel*  $3 \times 3$ . Kelompok lapisan pertama terdiri atas tiga blok, selanjutnya diteruskan dengan empat, enam, dan tiga blok. Di antara blok lapisan ini terdapat *skip connection* yang menghubungkan antar blok lapisan, seperti yang dicontohkan pada Gbr. 5. Beberapa model dari *ResNet* telah diteliti berdasarkan kedalaman dari lapisannya. Meskipun semakin dalam lapisan yang digunakan, kompleksitas *ResNet* masih lebih rendah daripada jaringan lain. Model-model pada *ResNet* diimplementasikan dengan menambahkan *skip connection*



Gbr. 6 Arsitektur transfer learning ResNet50.

antara dua atau tiga lapisan yang di antaranya mengandung *ReLU* dan *batch-normalization* [12].

3) *Inception*: Jaringan yang melakukan pemfaktoran terhadap operasi proses secara eksplisit menjadikan jaringan ini lebih efisien dan mudah [26]. Operasi yang dilakukan dalam jaringan ini menunjukkan korelasi persilangan antar *channel* dan korelasi spasial. Dalam arsitekturnya, lapisan konvolusi tradisional mencoba mempelajari filter ruang tiga dimensi, antara dimensi panjang dan lebar dan dimensi *channel*. Hal ini menunjukkan bahwa jaringan konvolusi mempelajari fitur yang lebih kaya dengan lebih sedikit parameter [24]. Pada makalah ini dipilih *InceptionV3* karena dari segi waktu, *InceptionV3* lebih cepat dibandingkan *InceptionV4* dan *ResNet50* [27]. Arsitektur *InceptionV3* diperlihatkan pada Gbr. 7 [24].

4) *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 [28]. Baru-baru ini jaringan *Xception* dapat mengungguli varian jaringan lebih dalam yang sekaligus memiliki lebih sedikit parameter [29], [30]. 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 Gbr. 8 [24], [28]. 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 [24].

### C. Rectified Linear Unit (ReLU)

Fungsi aktivasi unit linear (*ReLU*) telah menjadi fungsi aktivasi yang paling sukses dan banyak digunakan untuk *deep learning* karena hasil yang bagus dengan proses yang lebih cepat [31]. Adapun persamaan fungsi ini ditunjukkan pada (1).

$$F(x) = \max(0, x) = \begin{cases} xi, & \text{if } xi \geq 0 \\ 0, & \text{if } xi < 0 \end{cases} \quad (1)$$

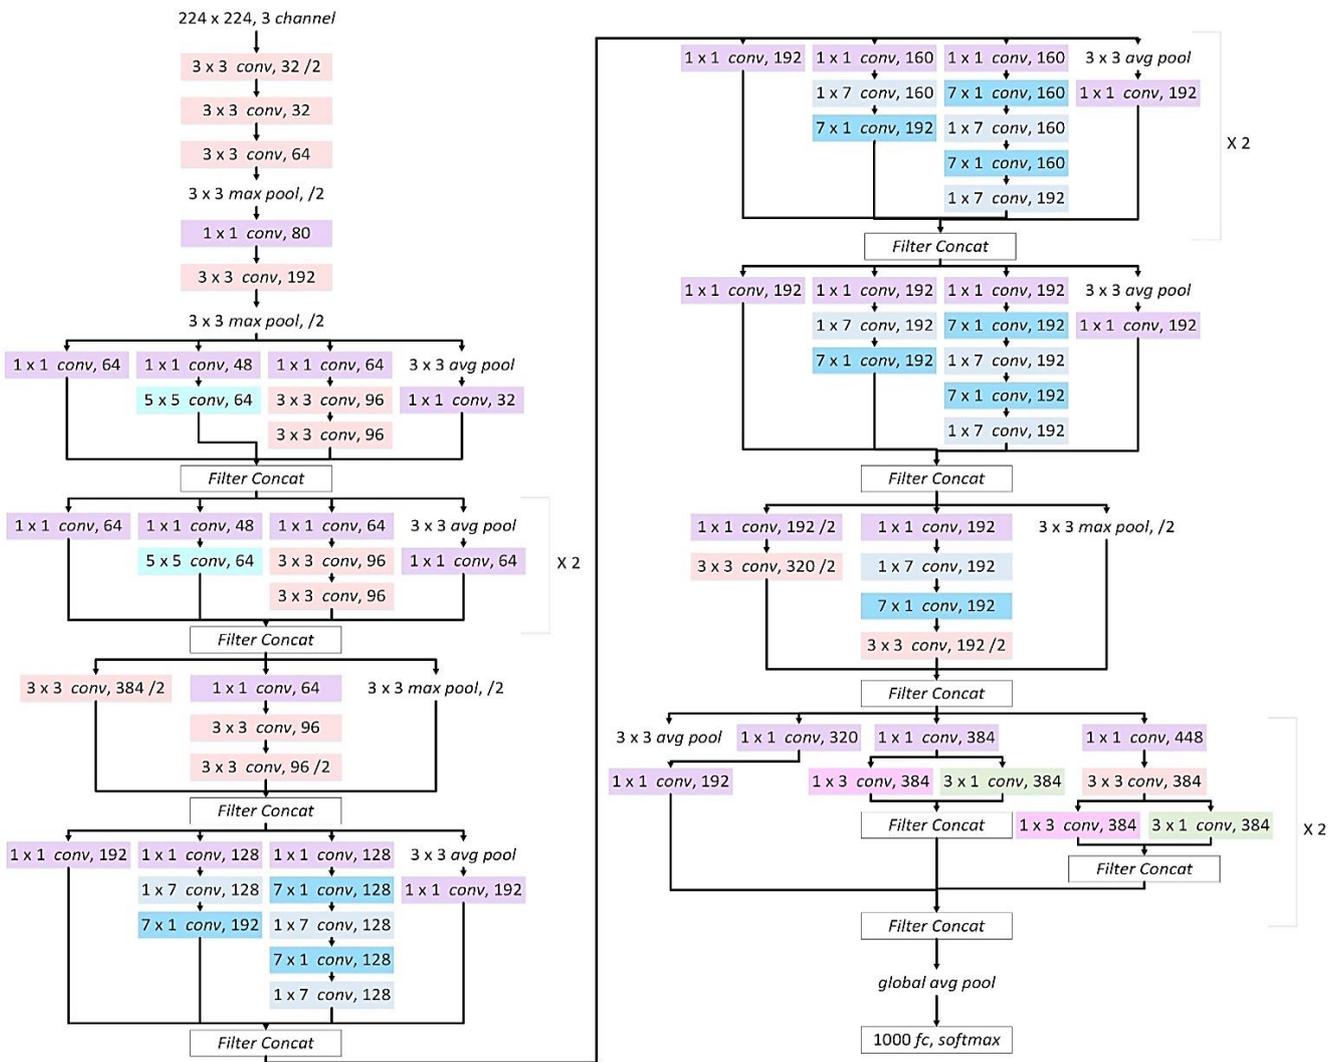
Fungsi ini melakukan operasi ambang batas untuk setiap elemen masukan yang menjelaskan bahwa jika nilai kurang dari nol, maka akan ditetapkan juga menjadi nol.

### D. Batch-Normalization

Dalam jaringan saraf tiruan, seringkali distribusi masukan dalam setiap pelatihan berubah-ubah, yang disebabkan oleh perubahan parameter sebelumnya. Hal ini memperlambat dan mempersulit pembelajaran terhadap model selama pelatihan. Oleh karena itu, diperlukan *batch-normalization*. *Batch-normalization*, atau yang biasa disebut dengan *batch-norm*, merupakan teknik yang digunakan untuk meningkatkan kecepatan, kinerja, dan menstabilkan jaringan saraf tiruan [32].

Dalam klasifikasi gambar, *batch-norm* memberikan hasil dengan akurasi terbaik ketika diterapkan pada klasifikasi *ImageNet*. Jenis normalisasi ini memungkinkan untuk digunakan dalam tingkat pembelajaran yang lebih tinggi dan kurangnya inisialisasi, bahkan dalam proses pelatihan mampu menghilangkan fungsi *drop out* [32].

Terhadap model yang telah diusulkan dengan beberapa pengaturan kemudian dilakukan proses klasifikasi, dengan pembagian data masing-masing 80% untuk pelatihan dan 20% untuk validasi dan pengujian. Proses pelatihan memanfaatkan Google Colab dengan kompilasi model menggunakan parameter optimasi Adam dengan nilai *learning rate* = 0,001, *categorical crossentropy loss function*, dan matriks akurasi. Optimasi Adam bertujuan untuk memperbarui bobot secara



Gbr. 7 Arsitektur transfer learning InceptionV3.

iteratif selama proses pelatihan. Pemakaian Adam sebagai optimasi pengganti SGD dilakukan karena optimasi ini menggabungkan sifat-sifat terbaik dari *AdaGrad* dan *RMSProp* [33].

Karena makalah ini memiliki dua tahap, maka dari tahapan tersebut diperlukan dua klasifikasi objek. Klasifikasi yang pertama adalah klasifikasi objek ukiran dengan bukan ukiran dan yang kedua adalah klasifikasi motif-motif Jepara.

**E. Klasifikasi Objek Ukiran**

Klasifikasi objek ukiran menghasilkan keluaran biner, sehingga pada *fully connected layer* yang diterapkan ke dalam jaringan digunakan fungsi *sigmoid*. Selain fungsi ini, ada beberapa parameter yang ditambahkan, di antaranya fungsi *ReLU* kemudian diikuti dengan *batch-normalization* dan *dropout* yang diatur nilainya menjadi 0,5. Pada proses pelatihan, nilai *epoch* diatur senilai 50. Setelah dilakukan pelatihan, nilai bobot tertinggi yang dilihat dari nilai akurasi pada data validasi dan *loss* pada data validasi berhenti di *epoch* 29. Oleh karena itu, proses pelatihan diulang kembali dengan menggunakan 35 *epoch* dan setelah dilakukan pelatihan ulang

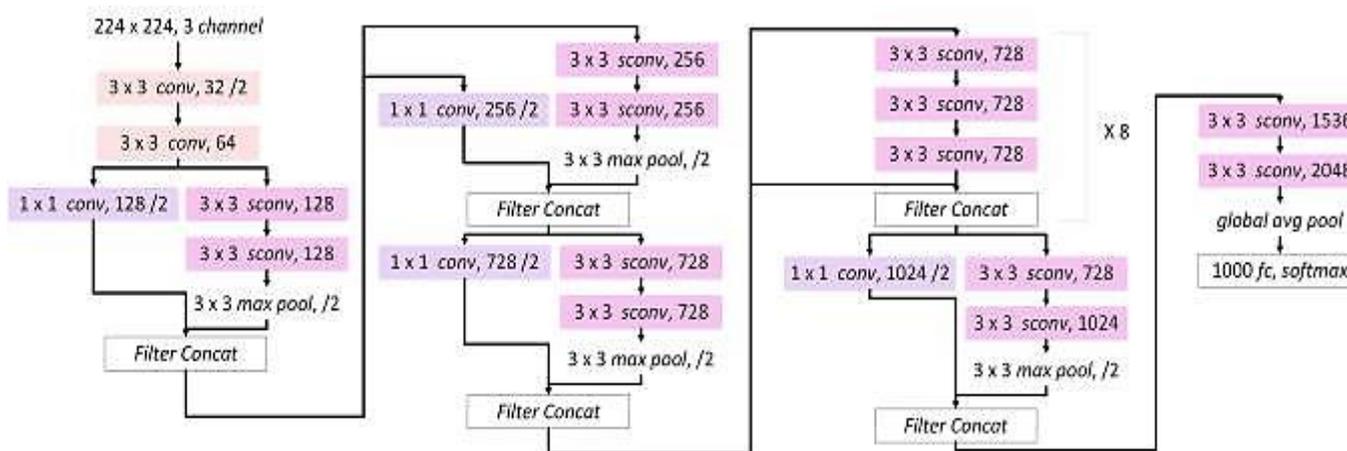
dipastikan bobot yang dihasilkan adalah bobot terbaik. Eksperimen ini dilakukan untuk *dataset* dengan *color space* LUV, RGB, dan YCrCb.

**F. Klasifikasi Motif Jepara**

*Fully connected layer* pada klasifikasi motif Jepara hampir sama dengan *fully connected layer* yang digunakan pada klasifikasi objek ukiran. Namun, karena keluaran klasifikasi motif Jepara sebanyak empat kelas, maka fungsi yang digunakan adalah *softmax*. Pada klasifikasi motif Jepara, pelatihan dilakukan sebanyak lima puluh *epoch* dengan menggunakan masing-masing *dataset color space* LUV, RGB, dan YCrCb.

**G. Evaluasi Model**

Pada kedua klasifikasi, bobot yang sudah didapatkan dari masing-masing *dataset* perlu diuji agar diketahui kinerja masing-masing bobot. Pengujian ini dilakukan menggunakan teknik akurasi dan *F1-Score*, sesuai dengan yang dilakukan pada penelitian sebelumnya [5], [6].



Gbr. 8 Arsitektur transfer learning Xception.

H. Sliding Window

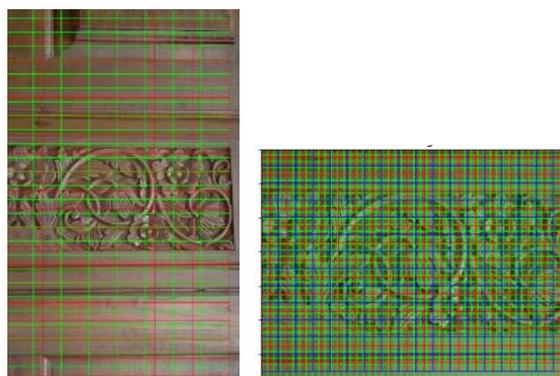
Makalah ini memanfaatkan *sliding window* untuk menyegmentasi area ukiran dan identifikasi motif Jepara. Pada tahap ini, *sliding window* menggunakan masing-masing tiga model dari bobot yang dihasilkan dari tiga *color space* yang berbeda. Bobot-bobot tersebut dihasilkan melalui pelatihan dari *dataset* dengan *color space* yang berbeda, yaitu LUV, RGB, dan YCrCb. Oleh karena itu, sebelum tahap klasifikasi, penyesuaian konversi warna dilakukan untuk mendapatkan hasil yang terbaik. Jika model yang digunakan berasal dari bobot pelatihan *dataset* dengan *color space* LUV, *color space* pada konversi sebelum klasifikasi objek adalah LUV. Demikian juga dengan yang lainnya.

Dalam makalah ini terdapat dua belas bobot model yang dihasilkan pada klasifikasi objek ukiran dan dua belas bobot model yang dihasilkan dari klasifikasi motif Jepara. Dua belas bobot model hasil klasifikasi objek ukiran digunakan untuk segmentasi area ukiran, sedangkan yang lain untuk identifikasi motif Jepara.

Pada segmentasi area ukiran, *window* berukuran  $1200 \times 600$  piksel dengan dua skala 75% dan 100%, sedangkan untuk identifikasi motif Jepara, *window* yang digunakan berukuran  $200 \times 200$  piksel dengan tiga skala: 75%, 100%, dan 125%. *Window* dari masing-masing tahap ini dapat diilustrasikan pada Gbr. 9. Perbedaan skala dibandingkan dengan perbedaan warna kotak (*bounding box*). Pergeseran perpindahan *window* dalam menelusuri area gambar diatur menjadi 25% dan nilai *confidence* untuk *sliding window* pada deteksi area ukiran dan identifikasi motif sebesar 90%.

I. Heat Maps dan Non Max Suppression (NMS)

Setelah melalui proses *sliding window*, dihasilkan beberapa kandidat area dengan nilai probabilitas masing-masing *window* dari klasifikasi objek ukiran maupun motif Jepara perlu dikenai proses lanjutan dengan teknik *heat maps* dan NMS. Kedua teknik ini bertujuan untuk mendapatkan *final localization* dari beberapa kandidat area yang telah terdeteksi. Pada proses deteksi objek area ukiran, nilai *threshold* pada NMS diatur menjadi 0,01. Hasil dari *heat maps* dan NMS ini adalah *bounding box* akhir yang merupakan lokasi dari objek ukiran.



Gbr. 9 Ilustrasi *window*, (a) *window* pada deteksi objek ukiran, (b) *window* pada identifikasi motif.

Area akhir kemudian dipotong untuk selanjutnya dilakukan proses identifikasi motif Jepara.

Pada proses identifikasi motif Jepara, NMS dimanfaatkan untuk mendapatkan lokasi akhir dari beberapa kandidat area motif yang terdeteksi dengan mengambil nilai probabilitas tertinggi. Nilai *threshold* pada NMS diatur menjadi 0,01. Hasil dari proses-proses tersebut akan dijelaskan pada bagian selanjutnya.

IV. HASIL DAN PEMBAHASAN

Model yang telah dirancang digunakan untuk pelatihan dengan *dataset* yang berbeda berdasarkan tiga *color space* (LUV, RGB, dan YCrCb). Dari pelatihan ini didapatkan bobot yang dihasilkan dari penyimpanan nilai akurasi validasi yang tinggi dan nilai *loss* validasi rendah di setiap *epoch*. Bobot ini selanjutnya digunakan untuk memprediksi data pengujian, dalam hal ini di setiap pelatihan dihasilkan nilai pelatihan, validasi, dan pengujian. Validasi digunakan untuk menggeneralisasi model dan pengujian digunakan untuk menguji kinerja model.

Proses pelatihan dilakukan dengan memanfaatkan Google Colab menggunakan tipe *runtime GPU* untuk meningkatkan kecepatan proses. Hasil dari masing-masing CNN pada proses pengujian bobot yang dihasilkan oleh masing-masing jaringan dengan beberapa *dataset* dirangkum ke dalam Tabel I dan

TABEL I  
HASIL PENGUJIAN CNN UNTUK KLASIFIKASI OBJEK UKIRAN

CNN	LUV		RGB		YCrCb	
	Acc.	Loss	Acc.	Loss	Acc.	Loss
<i>ResNet50</i>	<b>0,95</b>	<b>0,10</b>	0,97	0,13	0,94	0,15
VGG16	0,95	0,16	0,96	0,14	0,95	0,12
<i>InceptionV3</i>	0,93	0,30	<b>0,98</b>	<b>0,11</b>	<b>0,97</b>	0,20
<i>Xception</i>	0,94	0,21	0,98	0,20	0,95	0,19

Keterangan: Acc. = akurasi

TABEL II  
HASIL PENGUJIAN CNN UNTUK KLASIFIKASI MOTIF JEPARA

CNN	LUV		RGB		YCrCb	
	Acc.	Loss	Acc.	Loss	Acc.	Loss
<i>ResNet50</i>	0,93	0,43	0,95	0,36	0,94	0,37
VGG16	0,90	0,42	0,93	0,31	0,80	0,81
<i>InceptionV3</i>	0,93	0,37	0,94	0,30	0,92	0,35
<i>Xception</i>	<b>0,95</b>	0,28	<b>0,95</b>	0,20	<b>0,94</b>	0,34

Keterangan: Acc. = akurasi

Tabel II. Tabel I menjelaskan kinerja hasil pengujian CNN dalam mengklasifikasi objek ukiran dan bukan ukiran, sedangkan Tabel II menjelaskan hasil klasifikasi motif Jepara yang diukur menggunakan teknik akurasi dan *loss*.

Pada Tabel I dapat dilihat bahwa dari masing-masing *transfer learning* dan berbagai *dataset* yang digunakan dalam pelatihan, hasilnya sama-sama unggul. Akan tetapi, hasil tertinggi pada klasifikasi objek ukiran didapat oleh *InceptionV3* dengan *dataset* dengan *color space* RGB dan YcrCb, sekaligus nilai *error* yang dihasilkan lebih rendah dibandingkan dengan penelitian lainnya [26]. Untuk *dataset* dengan *color space* LUV, nilai tertinggi dihasilkan oleh *ResNet50* dan VGG16,

tetapi nilai *loss* dari *ResNet50* lebih rendah daripada VGG16. Selanjutnya, pada Tabel II dapat dilihat bahwa nilai tertinggi didominasi oleh *Xception* dengan semua *dataset* yang memiliki *color space* yang berbeda. Hasil ini juga mengungguli hasil pada penelitian sebelumnya [28]. Selain itu, *ResNet50* juga mampu bersaing pada klasifikasi motif Jepara di *dataset* RGB dan YCrCb. Hasil dari kedua klasifikasi objek tersebut ditegaskan dengan hasil perhitungan dari *F1-Score*. Hasil perhitungan ini dirangkum pada Tabel III dan Tabel IV untuk masing-masing klasifikasi.

Pada Tabel III dan Tabel IV tampak bahwa jaringan *InceptionV3* dan *Xception* mendominasi, dengan memiliki hasil tertinggi. Selain itu, *ResNet50* juga mampu bersaing di antara jaringan lain pada klasifikasi objek ukiran dengan *dataset color space* LUV dan *dataset* RGB pada klasifikasi motif Jepara. Hasil beberapa model dengan beberapa *dataset* yang diwakili oleh Tabel I sampai Tabel IV telah memenuhi untuk dilanjutkan ke tahap berikutnya karena nilai akurasi maupun *F1-Score* dapat mencapai 90% ke atas.

Pada tahap selanjutnya, dari semua bobot yang dihasilkan oleh masing-masing *dataset*, dua belas bobot hasil pelatihan pada klasifikasi objek ukiran digunakan untuk proses segmentasi area ukiran, sedangkan yang lainnya digunakan untuk proses identifikasi motif Jepara. Pada proses segmentasi area ukiran, hasil deteksi objek ukiran mendapatkan beberapa kandidat area. Kemudian, dengan bantuan *heat maps* dan NMS, mampu didapatkan area akhir dari objek ukiran.

Selanjutnya, proses identifikasi motif Jepara juga menggunakan dua belas bobot, dibedakan berdasarkan *color space* sumber set datanya. Pada proses ini, pencarian area akhir motif Jepara hanya menggunakan teknik NMS. Hal ini

TABEL III  
HASIL PENGUJIAN DENGAN *F1-Score* PADA KLASIFIKASI OBJEK UKIRAN

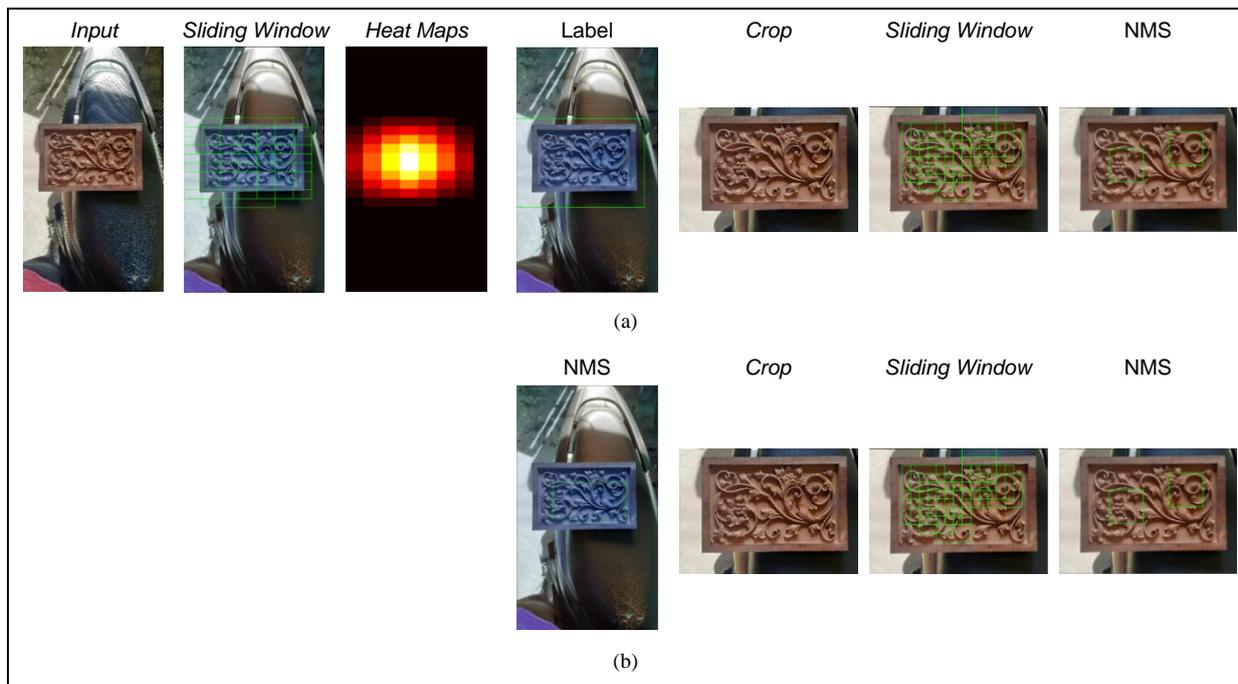
CNN	LUV			RGB			YCrCb		
	Precision	Recall	<i>F1-Score</i>	Precision	Recall	<i>F1-Score</i>	Precision	Recall	<i>F1-Score</i>
<i>ResNet50</i>	0,94	0,94	<b>0,94</b>	0,97	0,97	0,97	0,94	0,94	0,94
VGG16	0,94	0,93	0,93	0,98	0,94	0,96	0,96	0,96	0,96
<i>InceptionV3</i>	0,93	0,94	0,93	0,99	0,98	<b>0,99</b>	0,98	0,98	<b>0,98</b>
<i>Xception</i>	0,90	0,91	0,90	0,99	0,98	0,98	0,99	0,92	0,95

TABEL IV  
HASIL PENGUJIAN DENGAN *F1-Score* PADA KLASIFIKASI MOTIF JEPARA

CNN	LUV			RGB			YCrCb		
	Precision	Recall	<i>F1-Score</i>	Precision	Recall	<i>F1-Score</i>	Precision	Recall	<i>F1-Score</i>
<i>ResNet50</i>	0,93	0,93	0,93	0,95	0,95	<b>0,95</b>	0,94	0,94	0,94
VGG16	0,92	0,90	0,91	0,93	0,93	0,93	0,85	0,80	0,80
<i>InceptionV3</i>	0,94	0,94	0,94	0,94	0,94	0,94	0,93	0,92	0,92
<i>Xception</i>	0,95	0,95	<b>0,95</b>	0,96	0,95	<b>0,95</b>	0,95	0,94	<b>0,95</b>

TABEL V  
HASIL SEGMENTASI AREA UKIRAN

<i>Color Space</i>	<i>ResNet50</i>		%	VGG16		%	<i>InceptionV3</i>		%	<i>Xception</i>		%
	Aktual	Prediksi		Aktual	Prediksi		Aktual	Prediksi		Aktual	Prediksi	
LUV	50	47	94	50	40	80	50	17	34	50	46	92
RGB	50	48	96	50	48	96	50	40	80	50	26	52
YCrCb	50	47	94	50	49	<b>98</b>	50	47	94	50	34	68



Gbr. 10 Proses identifikasi motif Jepara, (a) penggunaan *heat maps*, (b) penggunaan NMS pada segmentasi area ukiran.

TABEL VI  
HASIL IDENTIFIKASI MOTIF JEPARA DARI RESNET50 DAN VGG16

Color Space	ResNet50						VGG16					
	Heat Maps			NMS			Heat Maps			NMS		
	Aktual	Prediksi	%	Aktual	Prediksi	%	Aktual	Prediksi	%	Aktual	Prediksi	%
LUV	374	315	84	133	98	74	324	206	64	171	87	51
RGB	399	316	79	148	95	64	391	254	65	172	101	59
YCrCb	368	296	80	253	169	67	391	57	15	165	23	14
Total	1.141	927	81	534	362	68	1.106	517	47	508	211	42

TABEL VII  
HASIL IDENTIFIKASI MOTIF JEPARA DARI INCEPTIONV3 DAN XCEPTION

Color Space	InceptionV3						Xception					
	Heat Maps			NMS			Heat Maps			NMS		
	Aktual	Prediksi	%	Aktual	Prediksi	%	Aktual	Prediksi	%	Aktual	Prediksi	%
LUV	114	46	40	75	25	33	369	232	63	161	99	61
RGB	381	279	73	143	85	59	163	133	82	95	77	81
YCrCb	413	205	50	123	46	37	252	196	78	158	116	73
Total	908	530	58	341	156	46	784	561	72	414	292	71

dilakukan karena hasil teknik NMS akan secara langsung mengarahkan model untuk memilih area dengan nilai probabilitas tertinggi dan menghapus area-area terdeteksi yang memiliki probabilitas rendah yang masih dalam satu objek yang sama, sehingga tidak terjadi area yang tumpang tindih [18]. Salah satu contoh proses segmentasi area ukiran dan identifikasi motif Jepara dapat diilustrasikan seperti Gbr. 10.

Dari semua proses yang dilakukan, hasil deteksi objek disimpan, kemudian dilakukan pengecekan secara manual. Pengecekan dilakukan di setiap tahap segmentasi area dan tahap identifikasi motif Jepara. Hasil pengecekan dari proses segmentasi area ukiran dirangkum dalam Tabel V. Pada tahap segmentasi area ukiran, penggunaan teknik NMS dan *heat*

*maps* dibedakan, kemudian hasil dari segmentasi area ukiran dari kedua teknik ini digunakan untuk identifikasi motif Jepara. Hasil NMS dan *heat maps* ditunjukkan pada Tabel VI dan Tabel VII, yang sekaligus merangkum hasil identifikasi motif Jepara di masing-masing bobot dari semua jaringan dan *color space* yang digunakan.

Tabel V menunjukkan bahwa hasil tertinggi pada segmentasi area ukiran didapatkan oleh VGG16 yang menggunakan *color space* YCrCb. Jika dibandingkan pada saat klasifikasi objek ukiran, VGG16 menempati tempat kedua setelah *InceptionV3* yang lebih unggul dari yang lain di *color space* YCrCb. Kemudian, Tabel VI dan Tabel VII membuktikan bahwa area akhir objek pada tahap segmentasi area ukiran mampu

dihasilkan menggunakan teknik NMS dan *heat maps*. *Heat maps* mampu menghasilkan tampilan motif lebih banyak, karena teknik ini bekerja dengan cara melakukan *merge* pada setiap *bounding box* area terdeteksi, sehingga mampu menampilkan area penuh ukiran dan menampilkan lebih banyak motif dengan pekerjaan dari teknik NMS. Hal ini dibuktikan pada Tabel VI dan Tabel VII, yaitu jumlah motif terbanyak yang ditampilkan dihasilkan dengan menggunakan teknik *heat maps*. Kemudian, dari beberapa percobaan di tahap identifikasi motif Jepara, metode *transfer learning* dari *ResNet50* mampu menghasilkan tampilan motif lebih banyak dan penggunaan *color space* LUV memberikan nilai persentase identifikasi motif Jepara lebih tinggi daripada yang lain. Hasil ini membuktikan bahwa teknik *heat maps* dapat menghasilkan nilai yang lebih baik tanpa harus memperhatikan luas parameter *window* yang digunakan dalam penelusuran objek.

#### V. KESIMPULAN DAN SARAN

Beberapa model *transfer learning* yang telah diujicobakan mampu bersaing satu sama lain, terutama pada klasifikasi objek dengan *dataset* RGB. Nilai yang dihasilkan dari masing-masing jaringan *transfer learning* saling mengikuti. Ini berarti semua model *transfer learning* menunjukkan kinerja yang baik ketika dihadapkan pada *dataset* dengan *color space* RGB.

Pada proses segmentasi area ukiran, teknik *heat maps* menghasilkan hasil yang lebih optimal daripada teknik NMS. Ini dikarenakan area akhir yang didapat memiliki area yang lebih luas dan mencakup keseluruhan area ukiran, sehingga motif yang dihasilkan juga lebih banyak dan potensi untuk diidentifikasi juga besar. Setelah area ukiran diperoleh, tahap identifikasi motif Jepara dilakukan dan dihasilkan bahwa nilai tertinggi dihasilkan oleh bobot dari *ResNet50* dengan *color space* LUV. Dari hasil tersebut, terbukti bahwa teknik CNN dengan *transfer learning*, *sliding window*, *heat maps*, dan NMS mampu mengidentifikasi motif Jepara dengan baik.

Berdasarkan hasil di atas, perlu dikembangkan penelitian dengan menambahkan jumlah sampel data dan penggunaan *color space* selain LUV, RGB, dan YCrCb. Di samping itu, pada saat identifikasi motif Jepara perlu dihasilkan sampai dengan segmentasi setiap motif Jepara yang terdeteksi. Pada *fully connected layer*, setiap model *transfer learning* juga dapat dikembangkan dengan menggunakan arsitektur lain, bahkan dengan mengombinasikannya dengan jaringan *classifier* yang lain.

#### UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada semua dosen Program Studi Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya (ISTTS), SMK Negeri 2 Jepara, SMP Negeri 6 Jepara, SMP Negeri 3 Jepara, keluarga, dan penulis kedua serta ketiga yang selalu memberikan motivasi dan dukungan selama penelitian berlangsung.

#### REFERENSI

- [1] Pemerintah Kabupaten Jepara, *Buku Analisis: Penanganan Masalah Budaya Lokal Seni Ukir Kabupaten Jepara*, Jepara, Indonesia: Pemerintah Kabupaten Jepara, 2014.
- [2] Alamsyah, "The Ups and Down of Wood Furniture Industry Center at the North Cost of Java and After Reformation Era: The Case of Jepara Furniture Center," *Adv. Sci. Lett.*, Vol. 23, hal. 9981-9983, 2017.
- [3] S. Gustami, *Seni Kerajinan Mebel Ukir Jepara: Kajian Estetik Melalui Pendekatan Multidisiplin*, Yogyakarta, Indonesia: Kanisius, 2000.
- [4] A.P. Pratiwi, K.K. Kenang, dan U.A. Ruki, "Analisa Perkembangan Motif Ukiran di Jepara pada Abad Ke-16 hingga Abad Ke-17," *Kreasi*, Vol. 2, No. 2, hal. 5-25, 2017.
- [5] S.L. Jurj, F. Opritoiu, dan M. Vladutiu, "Identification of Traditional Motifs Using Convolutional Neural Networks," *2018 IEEE 24th Int. Symp. Des. Technol. Electron. Packag.*, 2018, hal. 191-196.
- [6] M. Toğaçar, "Brain Hemorrhage Detection based on Heat Maps, Autoencoder and CNN Architecture," *2019 IEEE 1st Int. Inf. & Software Eng. Conf.*, 2019, hal. 1-5.
- [7] R. Kulkarni, S. Dhavalikar, dan S. Bangar, "Traffic Light Detection and Recognition for Self Driving Cars Using Deep Learning," *Proc. - 2018 4th Int. Conf. Comput. Commun. Control Autom. ICCUBEA 2018*, 2018, hal. 1-4.
- [8] I.Z. Mukti dan D. Biswas, "Transfer Learning Based Plant Diseases Detection Using ResNet50," *2019 4th Int. Conf. Electr. Inf. Commun. Technol. EICT 2019*, 2019, hal. 1-6.
- [9] A.S.B. Reddy dan D.S. Juliet, "Transfer Learning with RESNET-50 for Malaria Cell-Image Classification," *Proc. 2019 IEEE Int. Conf. Commun. Signal Process. ICCSP 2019*, 2019, hal. 945-949.
- [10] W. Cai, J. Li, Z. Xie, T. Zhao, dan K. Lu, "Street Object Detection Based on Faster R-CNN," *2018 37th Chinese Control Conf. (CCC)*, 2018, hal. 9500-9503.
- [11] H. Yanagisawa, T. Yamashita, dan H. Watanabe, "A Study on Object Detection Method from Manga Images Using CNN," *2018 Int. Work. Adv. Image Technol. IWAIT 2018*, 2018, hal. 1-4.
- [12] K. He, X. Zhang, S. Ren, dan J. Sun, "Deep Residual Learning for Image Recognition," *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 2016, hal. 770-778.
- [13] J. Muller, A. Fregin, dan K. Dietmayer, "Disparity Sliding Window: Object Proposals from Disparity Images," *IEEE Int. Conf. Intell. Robot. Syst.*, 2018, hal. 5777-5784.
- [14] C.H. Lampert, M.B. Blaschko, dan T. Hofmann, "Beyond Sliding Windows: Object Localization by Efficient Subwindow Search," *2008 IEEE Conference on Computer Vision and Pattern Recognition*, 2008, hal. 1-8.
- [15] S.E. Limantoro, Y. Kristian, dan D.D. Purwanto, "Pemanfaatan Deep Learning pada Video Dash Cam untuk Deteksi Pengendara Sepeda Motor," *JNETI*, Vol. 7, No. 2, hal. 167-173, 2018.
- [16] K.U. Sharma dan N.V. Thakur, "A Review and an Approach for Object Detection in Images," *Int. J. Comput. Vis. Robot.*, Vol. 7, No. 1, hal. 196-237, 2017.
- [17] V.H.C. De Melo, S. Leao, D. Menotti, dan W.R. Schwartz, "An Optimized Sliding Window Approach to Pedestrian Detection," *Proc. - Int. Conf. Pattern Recognit.*, 2014, hal. 4346-4351.
- [18] L. Tychsen-Smith dan L. Petersson, "Improving Object Localization with Fitness NMS and Bounded IoU Loss," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, 2018, hal. 6877-6885.
- [19] N.T. Do, S.H. Kim, H.J. Yang, G.S. Lee, dan I.S. Na, "Face Tracking with Convolutional Neural Network Heat-Map," *ACM Int. Conf. Proceeding Ser.*, 2018, hal. 29-33.
- [20] M. Oberweger, M. Rad, dan V. Lepetit, "Making Deep Heatmaps Robust to Partial Occlusions for 3D Object Pose Estimation," dalam *Computer Vision - ECCV 2018, ECCV 2018, Lecture Notes in Computer Science*, Vol. 11219, V. Ferrari, M. Hebert, C. Sminchisescu, dan Y. Weiss, Eds., Cham, Switzerland: Springer, 2018., hal. 125-141.
- [21] X. Chen, S. Xiang, C.L. Liu, dan C.H. Pan, "Vehicle Detection in Satellite Images by Hybrid Deep Convolutional Neural Networks," *IEEE Geosci. Remote Sens. Lett.*, Vol. 11, No. 10, hal. 1797-1801, 2014.
- [22] K. Simonyan dan A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015*, 2015, hal. 1-14.
- [23] D. Zhang, J. Lv, dan Z. Cheng, "An Approach Focusing on the Convolutional Layer Characteristics of the VGG Network for Vehicle

- Tracking,” *IEEE Access*, Vol. 8, hal. 112827–112839, 2020.
- [24] M.M. Leonardo, T.J. Carvalho, E. Rezende, R. Zucchi, dan F.A. Faria, “Deep Feature-Based Classifiers for Fruit Fly Identification (Diptera: Tephritidae),” *Proc. - 31st Conf. Graph. Patterns Images, SIBGRAPI 2018*, 2018, hal. 41–47.
- [25] M. Talo, “Automated Classification of Histopathology Images Using Transfer Learning,” *Artif. Intell. Med.*, Vol. 101, hal. 1-16, 2019.
- [26] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, dan Z. Wojna, “Rethinking the Inception Architecture for Computer Vision,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, 2016, hal. 2818–2826.
- [27] K. Liu, S. Yu, dan S. Liu, “An Improved InceptionV3 Network for Obscured Ship Classification in Remote Sensing Images,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 13, hal. 4738–4747, 2020.
- [28] F. Chollet, “Xception: Deep Learning with Depthwise Separable Convolutions,” *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, 2017, hal. 1800–1807.
- [29] T. Stark, M. Wurm, X.X. Zhu, dan H. Taubenbock, “Satellite-Based Mapping of Urban Poverty with Transfer-Learned Slum Morphologies,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, Vol. 13, hal. 5251–5263, 2020.
- [30] P. Pisantanaraj, P. Tanpisuth, P. Sinchawanwat, S. Phasuk, P. Phienphanich, P. Jangtawee, K. Yakoompai, M. Donphongpi, S. Ekgasit, dan C. Tantibundhit, “Automated Firearm Classification from Bullet Markings Using Deep Learning,” *IEEE Access*, Vol. 8, hal. 78236–78251, 2020.
- [31] C. Nwankpa, W. Ijomah, A. Gachagan, dan S. Marshall, “Activation Functions: Comparison of trends in Practice and Research for Deep Learning,” *arXiv:1811.03378*, hal. 1–20, 2018.
- [32] S. Ioffe dan C. Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,” *32nd Int. Conf. Mach. Learn. ICML 2015*, 2015, hal. 448–456.
- [33] D.P. Kingma dan J.L. Ba, “Adam: A Method for Stochastic Optimization,” *Proc. 3rd Int. Conf. Learn. Represent. ICLR 2015*, 2015, hal. 1–15.