

## Klasifikasi Kucing Besar Berdasarkan Pelindung Tubuh

Fernanda Januar Pratama<sup>1</sup>, Wikky Fawwaz Al Maki<sup>2</sup>, Febryanti Sthevanie<sup>3</sup>

<sup>1,2,3</sup> Universitas Telkom, Bandung

<sup>1</sup>fernandapratama@students.telkomuniversity.ac.id,

<sup>2</sup>wikkyfawwaz@telkomuniversity.ac.id, <sup>3</sup>sthevanie@telkomuniversity.ac.id

---

### Abstrak

Pertumbuhan jumlah populasi manusia yang semakin meningkat setiap tahunnya yang dapat berdampak buruk bagi populasi hewan. Dampak buruk dari pertumbuhan manusia tersebut mengakibatkan berkurangnya habitat yang dimiliki oleh populasi hewan, sehingga dapat mengakibatkan penurunan jumlah populasi hewan di alam liar seperti jenis kucing besar. Oleh karena itu, untuk membantu mengatasi penurunan populasi hewan tersebut maka dibangun sebuah model klasifikasi yang akurat dan efisien. Model dibangun dengan menggabungkan fitur Pyramid Histogram of Oriented Gradient (PHOG) dan pengklasifikasi Support Vector Machine (SVM). Citra input di proses pada tahap *preprocessing* dan citra disegmentasi dengan menggabungkan median filter dan metode otsu untuk memisahkan pola pada pelindung tubuh hewan dari latar belakang pada citra. Selanjutnya citra di ekstraksi menggunakan fitur PHOG dan terakhir, citra yang telah di ekstraksi kemudian diklasifikasikan menggunakan pengklasifikasi SVM. Hasil penelitian ini berhasil mengklasifikasi citra yang berisikan pola pelindung tubuh yang dimiliki hewan dengan akurasi sebesar 89.87%.

**Kata kunci :** Klasifikasi, PHOG, SVM, *Median Filter*, Metode Otsu

---

### Abstract

The growth of the human population is increasing every year which can have a negative impact on animal populations. The negative impact of human growth results in the reduction of habitat owned by animal populations so that it can result in a decrease in the number of animal populations in the wild such as big cats. Therefore, to help overcome the decline in the animal population, an accurate and efficient classification model was built. The model is built by combining the features of the Pyramid Histogram of Oriented Gradient (PHOG) and the Support Vector Machine (SVM) classifier. The input image is processed at the preprocessing stage and the image is segmented by combining the median filter and the otsu method to separate the pattern on the animal's body armor from the background on the image. Furthermore, the image is extracted using the PHOG feature and finally, the extracted image is then classified using the SVM classifier. The results of this study succeeded in classifying the image containing the pattern of body armor owned by the animal with an accuracy of 91.07%.

**Keywords:** Classification, PHOG, SVM, Median Filter, Otsu Method

---

## 1. Pendahuluan

### Latar Belakang

Berdasarkan data terbaru yang diambil dari WWF Living Planet Report menunjukkan bahwa jumlah populasi mamalia, burung, ikan, reptil, dan amfibi yang ada di dunia mengalami penurunan hampir 60% dalam waktu kurang dari 40 tahun [1] yang mana berbanding lurus dengan pertumbuhan jumlah populasi manusia yang semakin meningkat setiap tahunnya. Meningkatnya laju pertumbuhan manusia akan berdampak buruk terhadap jumlah populasi hewan di dunia, terutama hewan langka yang terancam punah seperti harimau, cheetah, jaguar, dan lain sebagainya. Kerusakan lingkungan alam yang semakin meningkat akibat ulah manusia menyebabkan banyak satwa liar kehilangan tempat tinggalnya, pencemaran lingkungan, penebangan pohon secara berlebihan dan perburuan liar menjadi faktor yang mempercepat penurunan populasi satwa tersebut.

Penurunan jumlah satwa langka yang semakin tinggi setiap tahunnya sehingga memaksa kita untuk mengambil Langkah yang lebih cepat dalam melakukan pencegahan atau hal-hal preventif yang dibutuhkan. Untuk itu dengan memanfaatkan kemajuan teknologi, terutama di bidang pengolahan citra digital dan teknologi kamera dan video. Pemanfaatan dari penggunaan kamera digital dapat membantu mencegah dan melindungi satwa langka terutama hewan dalam kategori sebagai keluarga kucing besar (*Felidae*) yang terdapat pola pada pelindung tubuh seperti harimau, cheetah, jaguar, leopard dan lainnya dari kepunahan yang diakibatkan oleh kerusakan lingkungan. Citra yang dihasilkan oleh kamera digital diklasifikasikan sesuai dengan spesies hewan yang terdapat pada citra tersebut. Proses klasifikasi yang dilakukan berfokus pada pola yang dimiliki oleh pelindung tubuh hewan. Hewan yang tergolong sebagai kucing besar memiliki pelindung tubuh berupa bulu. Istilah bulu secara umum hanya dimiliki pada mamalia dimana seluruh tubuh mereka ditutupi oleh rambut yang sangat tebal [2].

Citra yang dihasilkan pada kamera digital diproses dahulu sebelum diubah menjadi citra grayscale. Citra diaugmentasi dan kemudian disegmentasi menggunakan median filtering dan metode otsu. Median filtering digunakan untuk membersihkan citra dari noise yang ada, sehingga hasil yang diperoleh dari proses segmentasi menjadi lebih optimal. Citra yang telah disegmentasi kemudian diekstraksi menggunakan fitur PHOG untuk mendapatkan fitur deskriptor yang terdapat pada citra. Fitur deskriptor kemudian diklasifikasikan menggunakan pengklasifikasi SVM dengan parameter yang telah ditentukan menggunakan tahap *Hyperparameter Tuning*. Setelah citra hewan berhasil diklasifikasikan dan termasuk pada hewan yang terancam punah, selanjutnya tindakan perlindungan yang diperlukan dapat diambil.

Algoritma klasifikasi merupakan algoritma yang dapat mengkategorikan data citra menurut kelasnya masing-masing. Akan tetapi dalam penerapannya, metode klasifikasi pada citra memiliki banyak kendala, seperti ukuran data yang digunakan terlalu besar dan penggunaan sensor beresolusi tinggi yang menyebabkan waktu komputasi yang lama, pengambilan citra pada lingkungan terbuka yang melibatkan hewan dengan latar belakang yang kompleks, postur hewan yang berbeda, dan pencahayaan [2]. Masalah utama lainnya bahwa hewan memiliki variasi intra-kelas yang tinggi dan kesamaan antar-kelas yang dapat mempengaruhi akurasi pada sistem.

Sebagai pendeskripsi bentuk spasial, fitur PHOG digunakan karena citra pola kulit hewan pada setiap kelas memiliki bentuk yang berbeda-beda, sehingga sangat cocok menggunakan fitur PHOG. Berdasarkan penelitian sebelumnya, kombinasi fitur PHOG dengan pengklasifikasi SVM diimplementasikan sebagai metode klasifikasi telah sukses dalam mengklasifikasikan citra. Kesuksesan tersebut meliputi pengenalan tulisan tangan dengan akurasi tertinggi mencapai 96.4% yang diperoleh dengan menggunakan fitur PHOG level 5 [3], pengenalan penyakit daun pada tanaman dengan tingkat akurasi mencapai 85.64% pada daun apel dan 87.55% pada daun ketimun [4], dan deteksi glaucoma pada retina dengan tingkat akurasi mencapai 73% yang diperoleh dari kombinasi fitur PHOG dan SVM [5].

## Topik dan Batasannya

Topik dan Batasan masalah dalam penelitian ini adalah untuk menganalisa apakah model yang dibangun dapat mengklasifikasikan citra yang berfokus pada pola pelindung tubuh yang dimiliki hewan dengan tingkat akurasi yang optimal. Pada penelitian ini dataset yang digunakan untuk klasifikasi terdiri dari tiga kelas hewan yaitu harimau, cheetah, dan jaguar yang diperoleh dari website [www.kaggle.com](http://www.kaggle.com) [7] dengan jumlah dataset yang terbatas. Proses klasifikasi dilakukan hanya menggunakan tiga kelas hewan dari banyaknya kelas pada keluarga kucing besar (*Felidae*). Hal ini dikarenakan keterbatasan dataset yang tersedia sehingga peneliti kesulitan dalam mengumpulkan seluruh dataset berdasarkan kelas hewan yang diteliti.

## Tujuan

Adapun tujuan dari penelitian ini adalah membangun suatu model klasifikasi yang dapat mengklasifikasikan pola citra kulit hewan menurut kelas yang telah ditentukan. Model yang dibangun dapat mengklasifikasikan pola pada pelindung tubuh yang dimiliki hewan dengan tingkat akurasi yang optimal dengan proses klasifikasi yang sederhana tanpa mengurangi akurasi yang diperoleh.

## 2. Studi Terkait

### 2.1 Data Augmentation

*Data augmentation* merupakan sebuah metode yang digunakan untuk meningkatkan jumlah data yang ada. Peningkatan jumlah pada data bertujuan untuk mengurangi tingkat kesalahan (*error*) dan meminimalkan jarak antara *training set* dan *validation set*. Terdapat dua pendekatan yang digunakan antara lain *Basic Image Manipulation* dan *Deep Learning* [7]. Manipulasi citra (*Basic Image Manipulation*) dapat dilakukan dengan transformasi warna dan geometri pada citra, *Flipping*, *Cropping*, *Rotation*, *Translation*, *Noise Injection*, *Random Erasing*, dan *Mixing Images*. Sedangkan pendekatan *Deep Learning* dapat menggunakan metode *Generative Adversarial Networks* (GAN), *Adversarial training*, *Feature space augmentations*, *Neural Style Transfer* dan sebagainya..

### 2.2 Contrast Limited Adaptive Histogram Equalization (CLAHE)

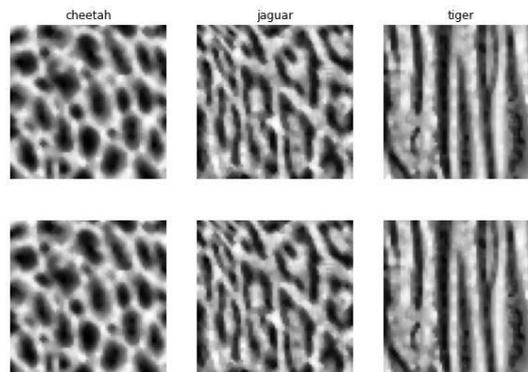
*Contrast Limited Adaptive Histogram Equalization* (CLAHE) merupakan algoritma yang diusulkan untuk mengatasi masalah yang sering dihadapi oleh citra yaitu kebisingan (*noise amplification*) terutama pada wilayah yang homogen dan menghindari peningkatan kontras yang berlebihan yang biasanya terjadi saat pengambilan citra. CLAHE dikembangkan berdasarkan *Adaptive Histogram Equalization* (AHE) [8]. AHE merupakan hasil generalisasi dari *Histogram Equalization* (HE) agar dapat menekan kebisingan (*noise*) dan mempertajam citra. Akan tetapi AHE rentan terhadap kebisingan terutama pada wilayah yang relatif homogen. Cara kerja CLAHE adalah citra dibagi menjadi wilayah kecil yang disebut dengan *tiles*. Selanjutnya histogram dibentuk berdasarkan dengan wilayah (*tiles*) pada citra. Nilai pada histogram yang melebihi batas klip (*cliplimit*) diakumulasikan dan didistribusi kembali. Selanjutnya penskalaan dan pemetaan dilakukan menggunakan *Cumulative Distribution*

*Function* (CDF) yang dihitung berdasarkan nilai *tiles* pada citra. Selanjutnya *tiles* disatukan menjadi satu citra utuh dengan menggunakan interpolasi bilinear (*bilinear interpolation*).

### 2.3 Segmentation

#### 2.4.1 Median Filter

Median filter merupakan implementasi penyaringan non-linear yang umum digunakan untuk menghapus kebisingan (*impulse noise*) pada pemrosesan citra [9]. Cara kerja filter median sangat sederhana, pertama urutkan seluruh piksel yang ada pada jendela (*sliding window*) dari nilai terkecil ke terbesar (*ascending*). Selanjutnya menentukan nilai median dari piksel yang telah diurutkan tersebut dan menggantu nilai tengah pada *sliding window* dengan nilai median yang didapatkan. Ukuran *sliding window* pada median filter sudah ditentukan. Ketika ukuran jendela terlalu besar dapat berdampak buruk bagi citra seperti detail pada citra akan terhapus sehingga dapat mengurangi informasi pada citra. Hasil dari filter median dapat dilihat pada gambar 1.



Gambar 1. Citra hasil *filtering* menggunakan *median filter*

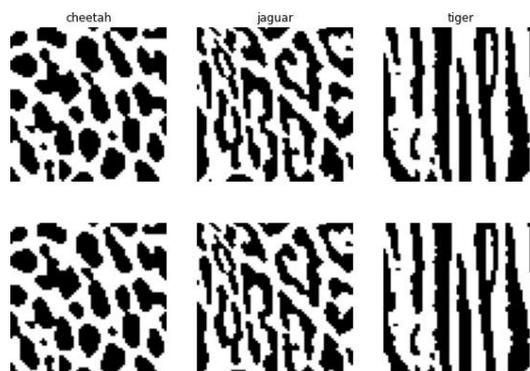
#### 2.4.2 Otsu Method

Otsu merupakan metode segmentasi citra dasar yang umum digunakan dikarenakan implementasi yang sederhana namun efektif. Cara kerja metode otsu adalah citra input dikonversikan menjadi citra hitam putih atau biasanya disebut dengan citra biner (*binary image*). Proses ini dinamakan binarisasi citra (*Image Binarization*) dimana proses ini dilakukan berdasarkan perhitungan nilai ambang batas (*Thresholding*) yang didapatkan dengan meminimalkan nilai variasi piksel *intra-class* antara 2 kelas yang berbeda [10]. Proses binarisasi citra dapat dihitung dengan menggunakan persamaan 1 dan 2 [11].

$$J(x, y) = \begin{cases} 255 & \text{if } I(x, y) \geq T \\ 0 & \text{Otherwise} \end{cases} \quad (1)$$

$$T = M[x, y, p(x, y), I(x, y)] \quad (2)$$

Berdasarkan persamaan 1 dan 2,  $I(x, y)$  merupakan koordinat dari nilai piksel pada citra,  $T$  merupakan nilai *threshold*, dan  $p(x, y)$  merupakan nilai rata-rata dari lingkungan (*neighborhood*) yang *focus* pada koordinat  $I(x, y)$ . Metode Otsu termasuk metode ambang batas global (*global threshold*) yang bergantung pada nilai keabuan (*gray-value*) suatu citra. Hasil segmentasi citra dapat dilihat pada Gambar 2.

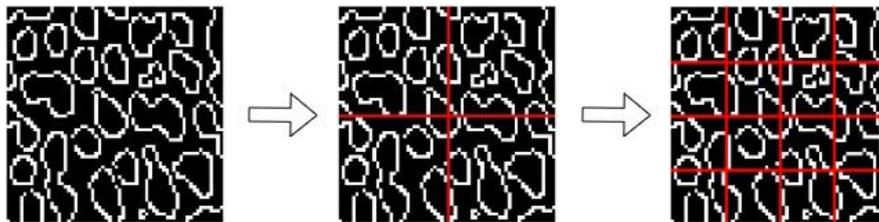


Gambar 2. Citra hasil segmentasi menggunakan Otsu Method

#### 2.4 Pyramid Histograms of oriented gradients (PHOG)

*Pyramid Histograms of oriented gradients* (PHOG) merupakan fitur deskriptor yang menggabungkan fitur *Histogram of Orientation Gradients* (HOG) dengan representasi tingkatan piramida yang diimplementasikan pada citra. PHOG diusulkan oleh Bosch et al. [12] dan digunakan untuk merepresentasikan citra berdasarkan pada

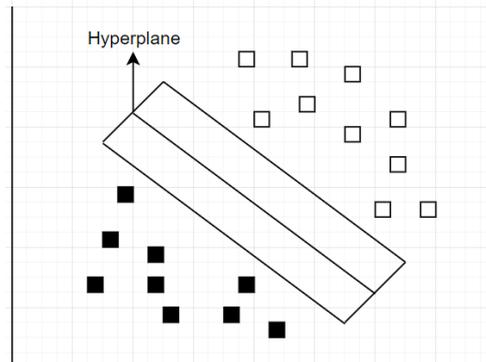
bentuk lokal (*local shape*) dan tata ruang bentuk (*spatial layout*) yang dimiliki citra tersebut. Berdasarkan pada [13] mendeskripsikan cara kerja fitur PHOG, pertama kontur tepi (*edge contours*) pada citra diekstraksi menggunakan pendeteksi *canny edge*. Citra kemudian diuraikan menjadi beberapa grid berdasarkan pada tingkat piramida yang ditentukan. Tingkatan pada piramida ditentukan oleh persamaan  $2^l$ , dimana setiap tingkatan ( $l$ ) menghasilkan resolusi grid yang berbeda. Semakin besar tingkat piramida, maka semakin banyak jumlah grid yang dihasilkan dari citra. Ilustrasi tingkatan pada piramida dapat dilihat pada gambar 3. Selanjutnya fitur HOG dihitung pada setiap urutan grid untuk setiap tingkatan pada piramida. Terakhir, hasil dari fitur HOG digabungkan sehingga membentuk satu vektor baru yang merepresentasikan bentuk dari citra yang diolah. Pada penelitian ini, parameter pada fitur HOG ditentukan seperti jumlah K-bins, ukuran *pixel per cell*, dan ukuran *cell per block*. Untuk detail pada parameter fitur HOG dapat dilihat pada bagian 3.



Gambar 3. Ilustrasi pembagian citra menjadi beberapa grid pada fitur PHOG

## 2.5 Support Vector Machines (SVM)

*Support Vector Machines (SVM)* merupakan model pembelajaran terawasi (*supervised learning*) yang dapat digunakan untuk klasifikasi dan regresi pada data. Pengklasifikasi SVM secara umum banyak digunakan untuk identifikasi pada citra [13]. Ide utama dari pengklasifikasi SVM adalah untuk menemukan *hyperplane* terbaik yang diilustrasikan seperti pada gambar 4. Data input yang berisikan kumpulan citra dipetakan kedalam ruang n-dimensi atau ruang dimensi yang tak terbatas yang dapat mengubah data *non-linear* menjadi data yang dapat dikategorikan secara *linear*. Akan tetapi, semakin tinggi tingkat dimensi pada pengklasifikasi SVM, maka semakin besar waktu komputasi yang dihasilkan pada pengklasifikasi tersebut. Selanjutnya *hyperplane* terbaik dipilih berdasarkan jarak maksimum antara *margin* atau garis pemisah dengan titik terdekat pada masing-masing kelas.



Gambar 4. Ilustrasi *Hyperplane* pada pengklasifikasi SVM

Pada penelitian ini, pemilihan parameter yang optimal pada pengklasifikasi SVM dilakukan secara otomatis dengan menggunakan metode hyperparameter tuning dan cross validation. Hal ini agar dapat meminimalkan kesalahan saat mengklasifikasikan setiap kelas pada data. Parameter yang disetel seperti pemilihan kernel, nilai C, dan nilai gamma. Nilai C merupakan nilai penalti untuk kesalahan yang dilakukan dalam klasifikasi data. Semakin besar nilai C yang digunakan maka tingkat akurasi yang didapat semakin menurun (*underfitting*). Sebaliknya, semakin kecil nilai C yang digunakan maka model yang digunakan rentan terhadap *overfitting*. Pada fungsi kernel, umumnya pengklasifikasi SVM menggunakan kernel seperti linear, polynomial, radial basis function (RBF) dan sigmoid. Untuk nilai gamma merupakan representasi dari kurva batas dalam fungsi kernel. Semakin kecil nilai gamma yang digunakan, maka kurva batas (*decision boundary curve*) semakin lebar dan memiliki bentuk garis lurus. Sebaliknya, semakin besar nilai gamma yang digunakan, maka kurva batas (*decision boundary curve*) menjadi berbentuk seperti lingkaran.

## 2.6 Performance Testing

Dalam penelitian ini, model klasifikasi dievaluasi dengan menggunakan metode analisis yang dihitung berdasarkan confusion matrix. Terdapat empat parameter yang digunakan untuk menganalisis model klasifikasi seperti akurasi, AUC-ROC, F1-score, Precision, dan recall.

*Accuracy* merupakan ukuran seberapa baik suatu model dalam mengenali suatu data berdasarkan pada kelas tertentu. Akurasi dapat dihitung dengan membandingkan True Positive dan True Negative pada kasus yang telah dievaluasi. Secara matematis dapat dilihat pada persamaan 3 [14].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

*Area Under the Receiver Operating Characteristic Curve* (AUC-ROC) merupakan metode yang digunakan untuk mengukur seberapa baik parameter dalam model klasifikasi membedakan antara dua atau lebih kelas. AUC-ROC akan mengukur kualitas klasifikasi dengan menghitung luas daerah di bawah kurva yang terbentuk dari hasil perhitungan true positive rate (TPR) dan false positive rate (FPR) [15]. Pengklasifikasi dianggap optimal jika pengklasifikasi memiliki nilai AUC sebesar 1. Pengklasifikasi dianggap bagus jika nilai AUC lebih besar dari 0.5, dan ketika nilai AUC kurang dari atau sama dengan 0.5, maka pengklasifikasi dikategorikan sebagai pengklasifikasi buruk.

Presisi (*Precision*) atau dikenal dengan *Positive Predictive Value* (PPV) adalah perbandingan antara *True Positive* dengan seluruh data yang terklasifikasi positif. Rumus yang digunakan dapat dilihat pada persamaan 4 [16].

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

*Recall* atau yang dikenal sebagai sensitivitas (*sensitivity*) adalah perbandingan antara *True Positive* dengan seluruh data positif dalam dataset yang sebenarnya. Rumus yang digunakan dapat dilihat pada persamaan 5 [16].

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

*Specificity* atau biasa dikenal sebagai True Negative Rate (TNR) merupakan ukuran seberapa baik model klasifikasi dalam mengklasifikasi data negative atau *True Negative* (TN). Rumus yang digunakan dapat dilihat pada persamaan 6 [17].

$$Specificity = \frac{TN}{TN+FP} \quad (6)$$

*Negative Predictive Value* (NPV) merupakan perbandingan antara *True Negative* dengan seluruh data yang terklasifikasi negatif. Rumus yang digunakan dapat dilihat pada persamaan 7 [18].

$$NPV = \frac{specificity \times (1 - prevalence)}{specificity \times (1 - prevalence) + (1 - sensitivity) \times prevalence} = \frac{TN}{TN+FN} \quad (7)$$

*F1-Score* merupakan nilai rata-rata yang dihitung berdasarkan hasil dari *recall* dan presisi. Rumus yang digunakan dapat dilihat pada persamaan 6 [16].

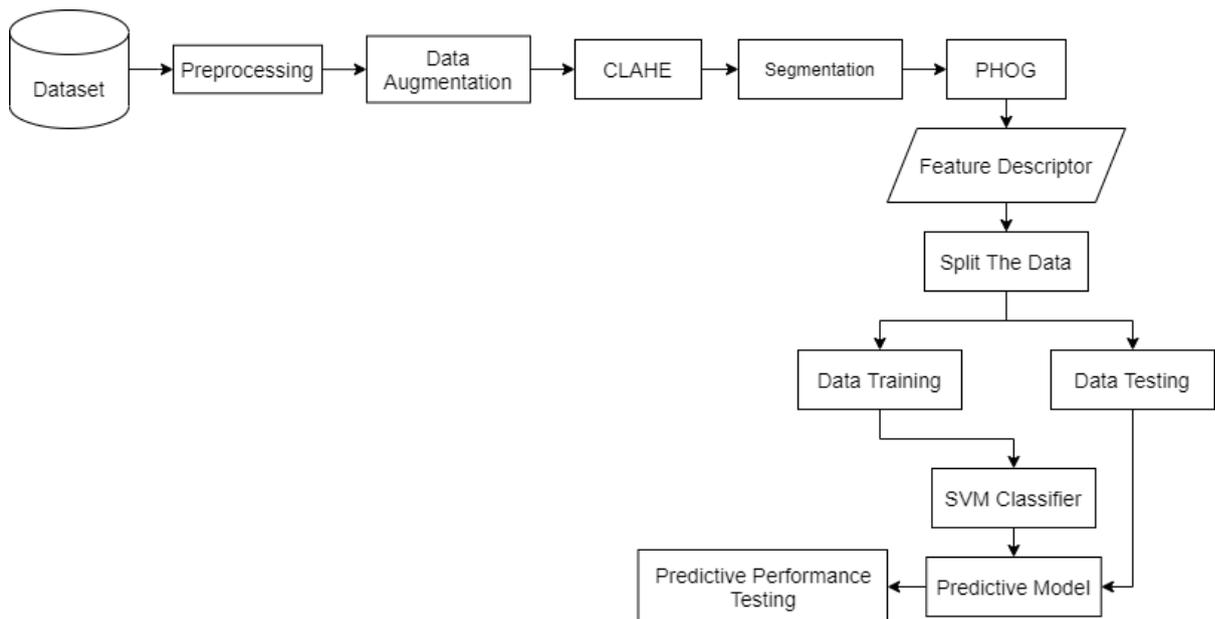
$$F1 = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (8)$$

Berdasarkan pada persamaan 3, 4, 5, 6, 7, dan 8, dimana *True Positive* (TP) berisikan citra yang telah diprediksi dengan benar sebagai cheetah/harimau/jaguar dan sesuai dengan data sebenarnya. *False Positive* (FP) berisikan citra yang telah diprediksi benar tetapi berbeda dari kelas pada data yang sebenarnya. *False Negative* (FN) berisikan citra yang telah diprediksi salah tetapi benar pada data yang sebenarnya. *True Negative* (TN) berisikan citra yang telah diprediksi salah dan sesuai dengan data sebenarnya.

### 3. Sistem yang Dibangun

Berdasarkan diagram pada gambar 5, dimana tahap-tahap pemrosesan klasifikasi dilakukan dengan alur seperti berikut.

1. Pada preprocessing, dataset berjumlah 1000 citra pada setiap kelasnya. Akan tetapi penelitian ini hanya menggunakan 200 citra pada setiap kelas dari dataset yang diperoleh dan 200 citra tersebut diambil dari data train, sehingga total citra yang digunakan adalah 600 citra. Citra tersebut kemudian di-crop untuk mengurangi latar belakang pada citra yang tidak diperlukan sehingga penelitian dapat fokus pada pola kulit saja. Citra di-crop pada bagian tubuh hewan yang memiliki pola kulit yang jelas, crop tersebut dilakukan secara acak dan memiliki ukuran yang sama, yaitu 64 x 64 piksel. Hasil citra yang telah diproses dapat dilihat pada Gambar 6.
2. Dataset yang digunakan adalah kumpulan citra yang terdiri dari 3 kelas seperti cheetah, harimau, dan jaguar.
3. Citra kemudian diaugmentasi untuk mengurangi tingkat kesalahan (*error*) dan mencegah terjadinya *overfitting* pada saat proses klasifikasi berlangsung.



Gambar 5. Arsitektur model klasifikasi yang diusulkan



Gambar 6. Contoh citra kulit hewan pada data yang digunakan

4. Citra kemudian diproses menggunakan metode CLAHE untuk mengatasi masalah peningkatan kontras yang berlebihan. Metode CLAHE menggunakan dua parameter yaitu *cliplimit* dengan ukuran 40.0 dan *blocksize* dengan ukuran (8, 8).
5. Citra kemudian disegmentasi dengan menggunakan kombinasi antara *median filter* dengan ukuran 2 x 2 dan metode otsu. Median filter digunakan untuk menghapus noise pada citra dan metode otsu digunakan untuk memisahkan pola pelindung tubuh dengan latar belakang (*background*) pada citra.
6. Citra yang telah disegmentasi kemudian diekstraksi menggunakan fitur PHOG untuk mendapatkan fitur deskriptor yang terdapat pada citra. Fitur PHOG menggunakan 9-bins *orientation* dengan rentang sudut antara 0 sampai 180, *pixel per cell* dengan ukuran 8 x 8, dan *cell per block* dengan ukuran 2 x 2.
7. Fitur deskriptor membentuk dataset baru yang digunakan dalam klasifikasi. Akan tetapi, dataset yang berisikan fitur deskriptor tersebut dibagi menjadi dua kategori yaitu data latih dan data uji dengan rasio perbandingan 8:2. Hal ini agar proses evaluasi pada model klasifikasi dapat dilakukan secara optimal. Pembagian data dilakukan dengan menggunakan data yang sama untuk mencegah perbedaan data dan agar lebih memahami karakteristik model dengan baik.
8. Model kemudian dilatih dengan menggunakan data latih dan pengklasifikasi multi-SVM. Dalam mendesain model klasifikasi, parameter pada SVM seperti fungsi kernel, nilai C, dan gamma dicari secara otomatis menggunakan metode *hyperparameter tuning* dan *cross-validation* dengan 10-fold. Hasil yang diperoleh dimana fungsi kernel yang digunakan adalah Radial Basis Function (RBF), nilai C yaitu 10, dan gamma sebesar 0.1.

9. Selanjutnya model yang telah dilatih kemudian di analisis menggunakan data uji. Hasil dari klasifikasi kemudian dianalisis dengan menggunakan empat parameter seperti akurasi, *F1-score*, presisi, dan *recall*.

#### 4. Evaluasi

##### 4.1 Hasil Pengujian

Pada penelitian ini, jumlah seluruh dataset yang digunakan sebanyak 15000 citra yang merupakan gabungan dari hasil metode augmentasi dan citra hasil preprocessing. Sebagai perbandingan, penelitian ini menggunakan fitur HOG dengan menggunakan 9-bins orientation dengan rentang sudut antara 0 sampai 180, pixel per cell dengan ukuran 8 x 8, dan cell per block dengan ukuran 2 x 2 yang sama seperti digunakan pada fitur PHOG. Sehingga terdapat tiga ekstraksi fitur (feature extraction) yang digunakan meliputi HOG, PHOG level 1, dan PHOG level 2. Kemudian ketiga ekstraksi fitur tersebut dibandingkan dengan menggunakan dua metode klasifikasi yaitu SVM dan KNN, dimana parameter SVM telah ditentukan dengan menggunakan hyperparameter tuning dan cross validation. Untuk rincian hasil evaluasi kinerja setiap ekstraksi fitur dan pengklasifikasi dapat dilihat pada tabel 1 dan 2.

Tabel 1. Perbandingan hasil evaluasi dengan menggunakan pengklasifikasi SVM

Methods	HOG	PHOG level 1	PHOG level 2
<b>Accuracy</b>	89.70%	89.87%	89.43%
<b>AUC-ROC</b>	97.46%	97.69%	97.58%
<b>F1</b>	89.67%	89.79%	89.34%
<b>NPV</b>	94.87%	94.99%	94.78%
<b>Precision</b>	89.64%	89.77%	89.33%
<b>Recall</b>	89.70%	89.87%	89.43%
<b>Specificity</b>	94.85%	94.93%	94.72%

Tabel 2. Perbandingan hasil evaluasi dengan menggunakan pengklasifikasi KNN

Methods	HOG	PHOG level 1	PHOG level 2
<b>Accuracy</b>	69.87%	71%	70.97%
<b>AUC-ROC</b>	90.36%	89.32%	89.42%
<b>F1</b>	65.55%	68.21%	68.29%
<b>NPV</b>	88.47%	87.97%	87.83%
<b>Precision</b>	79.04%	75.79%	75.53%
<b>Recall</b>	69.87%	71%	70.97%
<b>Specificity</b>	84.93%	85.5%	85.48%

Tabel 1 dan 2 menunjukkan hasil nilai *Accuracy*, *AUC-ROC*, *F1*, *NPV*, *Precision*, *Recall*, dan *Specificity* dari proses klasifikasi. Dari hasil penelitian, PHOG merupakan deskriptor fitur terbaik dibandingkan dengan HOG. Sedangkan proses klasifikasi menggunakan SVM merupakan classifier terbaik dibandingkan dengan KNN.

##### 4.2 Analisis Hasil Pengujian

Berdasarkan hasil penelitian yang diperoleh, model klasifikasi dengan menggunakan kombinasi fitur PHOG level 1 dan pengklasifikasi SVM memiliki performansi terbaik dengan akurasi 89.87% lebih unggul dibandingkan dengan model klasifikasi menggunakan PHOG level 2 dengan akurasi 89.43% dan HOG dengan akurasi 89.70%. Sementara itu, model klasifikasi dengan menggunakan SVM memiliki hasil yang lebih tinggi dibandingkan dengan KNN.

#### 5. Kesimpulan

Berdasarkan hasil dan analisis pengujian yang telah dilakukan, dapat disimpulkan bahwa model klasifikasi yang dibangun dengan kombinasi PHOG dan SVM berhasil diimplementasikan dalam klasifikasi pola pelindung

tubuh hewan dengan hasil akurasi yang optimal sebesar 89.87%. Sementara itu, model klasifikasi dengan menggunakan kombinasi HOG dan SVM menghasilkan akurasi sebesar 89.70%. PHOG merupakan ekstraksi fitur terbaik dibandingkan dengan HOG, karena PHOG menggunakan overlapping block yang dapat merepresentasikan citra menjadi informasi bentuk lokal dan globalnya sehingga dapat meningkatkan durabilitasnya [19]. Berdasarkan pada tabel 1 dan 2, model klasifikasi menggunakan SVM menghasilkan nilai kinerja yang lebih baik pada ketiga ekstraksi fitur dibandingkan dengan KNN. Pengklasifikasi SVM dapat menemukan hyperplane terbaik dengan menggunakan fungsi kernel yang cocok. Hyperplane yang optimal dapat mengelompokkan data secara tepat sehingga proses klasifikasi dapat menghasilkan nilai akurasi yang optimal.

Hasil penelitian menunjukkan bahwa ada potensi untuk mengembangkan model yang lebih kuat yang menggunakan kumpulan data gambar yang lebih kompleks yang dapat mengklasifikasikan seluruh jenis hewan yang termasuk keluarga kucing besar (*Felidae*). Diharapkan penelitian ini dapat diimplementasikan di beberapa organisasi perlindungan hewan sehingga dapat mempermudah dalam mengidentifikasi dan mengambil tindakan yang tepat dan cepat dalam mencegah penurunan angka kepunahan hewan bertahap.

## Referensi

- [1] Johnson, Chris. 2018. Living Planet Report 2018. [Online] Available at: <https://www.worldwildlife.org/pages/living-planet-report-2018/> [Accessed 14 May 2021].
- [2] Syufy, Franny. 2019. What Is the Difference Between Cat Hair and Fur?. [Online] Available at: <https://www.thesprucepets.com/cat-fur-vs-hair-554813/> [Accessed 11 September 2021].
- [3] Taheri, S., & Toygar, Ö. (2018). Animal classification using facial images with score-level fusion. *IET Computer Vision*, 12(5), 679–685. <https://doi.org/10.1049/iet-cvi.2017.0079>.
- [4] Ghanim, T. M., Khalil, M. I., & Abbas, H. M. (2018). PHOG features and kullback-leibler divergence based ranking method for handwriting recognition. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*: Vol. 11081 LNAI. Springer International Publishing. [https://doi.org/10.1007/978-3-319-99978-4\\_23](https://doi.org/10.1007/978-3-319-99978-4_23).
- [5] Zhang, S., Wang, H., Huang, W., & You, Z. (2018). Plant diseased leaf segmentation and recognition by fusion of superpixel, K-means and PHOG. *Optik*, 157, 866–872. <https://doi.org/10.1016/j.jjleo.2017.11.190>.
- [6] Gour, N., & Khanna, P. (2019). Automated glaucoma detection using GIST and pyramid histogram of oriented gradients (PHOG) descriptors. *Pattern Recognition Letters*, xxxx. <https://doi.org/10.1016/j.patrec.2019.04.004>.
- [7] Kaggle. 2020. Cheetah, Hyena, Jaguar and Tiger. [Online] Available at: <https://www.kaggle.com/iluvchicken/cheetah-jaguar-and-tiger/> [Accessed 15 October 2020].
- [8] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>.
- [9] Ma, J., Fan, X., Yang, S. X., Zhang, X., & Zhu, X. (2018). Contrast Limited Adaptive Histogram Equalization-Based Fusion in YIQ and HSI Color Spaces for Underwater Image Enhancement. *International Journal of Pattern Recognition and Artificial Intelligence*, 32(7), 1–26. <https://doi.org/10.1142/S0218001418540186>.
- [10] George, G., Oommen, R. M., Shelly, S., Philipose, S. S., & Varghese, A. M. (2018). A Survey on Various Median Filtering Techniques For Removal of Impulse Noise From Digital Image. *Proc. IEEE Conference*.
- [11] -, 5, Azmi, S., Hashim, M., Jamaluddin, N., & Hasbullah, A. (2018). Automatic Classification of Animal Skin for Leather Products Using Backpropagation Neural Network. *4th National Conference on Research and Education*, May 2017.
- [12] Niharika, E., Adeeba, H., Krishna, A. S. R., & Yugander, P. (2017). K-means based noisy SAR image segmentation using median filtering and Otsu method. *IEEE International Conference on IoT and Its Applications, ICIOT 2017*, 3–6. <https://doi.org/10.1109/ICIOTA.2017.8073630>.
- [13] Bosch, A., Zisserman, A., & Munoz, X. (2007). Representing shape with a spatial pyramid kernel. *Proceedings of the 6th ACM International Conference on Image and Video Retrieval, CIVR 2007*, 401–408. <https://doi.org/10.1145/1282280.1282340>.
- [14] Guenther, N., & Schonlau, M. (2016). Support vector machines. *Stata Journal*, 16(4), 917–937. <https://doi.org/10.1177/1536867x1601600407>.
- [15] Yaseen, A., Abbasi, W. A., & Minhas, F. U. A. A. (2018). Protein binding affinity prediction using support vector regression and interfacial features. *Proceedings of 2018 15th International Bhurban Conference on Applied Sciences and Technology, IBCAST 2018*, 2018-Janua, 194–198. <https://doi.org/10.1109/IBCAST.2018.8312222>.
- [16] Singh, G. A. P., & Gupta, P. K. (2019). Performance analysis of various machine learning-based approaches for detection and classification of lung cancer in humans. *Neural Computing and Applications*, 31(10), 6863–6877. <https://doi.org/10.1007/s00521-018-3518-x>.

- [17] Suganya, R. (2016). An automated computer aided diagnosis of skin lesions detection and classification for dermoscopy images. 2016 International Conference on Recent Trends in Information Technology, ICRTIT 2016. doi: 10.1109/ICRTIT.2016.7569538.
- [18] Kelly, H., Bull, A., Russo, P., & McBryde, E. S. (2008). Estimating sensitivity and specificity from positive predictive value, negative predictive value and prevalence: application to surveillance systems for hospital-acquired infections. *Journal of Hospital Infection*, 69(2), 164–168. doi: 10.1016/j.jhin.2008.02.021.
- [19] Bulbul, M. F. (2018). Searching Human Action Recognition Accuracy from Depth Video Sequences Using HOG and PHOG Shape Features. *Advances in Image and Video Processing*, 6(5). <https://doi.org/10.14738/aivp.65.5340>.

## Lampiran