

EVALUASI *FILTER EDGE ENHANCEMENT* UNTUK MENINGKATKAN KUALITAS *DATASET SPECIES KAYU*

Dicky Rianto Prajitno, Bambang Sugiarto, Herlan, Riyo Wardoyo

Computer Vision, Pusat Penelitian Informatika LIPI
Jl. Sangkuriang, Bandung, 40135, Indonesia

E-mail: *dick001@lipi.go.id*

ABSTRAK

Pengumpulan dataset kayu dilakukan pada posisi potongan melintang untuk merekam foto bentuk, ukuran, dan sebaran pembuluh dan serat kayu. Pengambilan gambar dilakukan menggunakan kamera *smartphone* yang dilengkapi dengan tambahan lup perbesaran 60 kali. Kondisi pengambilan gambar dengan cara dan peralatan yang tidak ideal menyulitkan untuk mendapatkan gambar dengan kualitas baik dan konsisten, sehingga mengakibatkan tekstur pori-pori dan serat kayu tidak terekspos maksimal, hal ini akan menyebabkan kualitas dataset menurun. Penurunan kualitas dataset akan berdampak pada penurunan akurasi klasifikasi. Oleh sebab itu pada tulisan ini dilakukan penelitian untuk meningkatkan kualitas gambar, dengan menguatkan batas tepian objek pada gambar. Metoda penguatan batas tepian dilakukan menggunakan konvolusi kernel dengan matriks filter edge enhancement, kemudian pengujian performa dilakukan menggunakan dua jenis algoritma ekstraksi pola yaitu LBP dan HOG dengan algoritma klasifikasi pola SVM. Hasil tertinggi yang dicapai dengan metoda penguatan batas tepian objek didapatkan peningkatan akurasi klasifikasi sebesar +7.14% dibanding sebelumnya.

Kata Kunci : penguatan batas tepian, LBP, HOG, spesies kayu, kernel filter

ABSTRACT

The collection of wood datasets is carried out in a cross-sectional position to record images of the shape, size, and distribution of wood vessels and fibers. The image is taken using a smartphone camera which is equipped with an additional 60 times magnification loop. The condition of taking pictures with non-ideal means and equipment makes it difficult to get good quality and consistent images, so that the texture of pores and wood fibers is not maximally exposed, this will cause the quality of the dataset to decrease. The decline in the quality of the dataset will result in a decrease in classification accuracy. Therefore in this paper, research is conducted to improve the quality of the image, by strengthening the boundary edges of the objects in the image. The edge boundary strengthening method is performed using kernel convolution with edge enhancement filter matrix, then performance testing is performed using two types of pattern extraction algorithms namely LBP and HOG with SVM pattern classification algorithm. The highest results achieved with the edge boundary reinforcement method found an increase in classification accuracy of +7.14% compared to before.

Keywords : *edge enhancement, LBP, HOG, wood species, kernel filter*

PENDAHULUAN

Indonesia merupakan negara penghasil kayu yang cukup besar, berdasarkan catatan publikasi ilmiah telah terdeskripsikan anatomi kayu dari 422 genus dengan lebih dari 4000 jenis kayu Asia Tenggara dimana sebagian besar jenis-jenis tersebut tumbuh di Indonesia (FORDA 2013). Pengelompokan kayu berdasarkan ketersediaannya terbagi menjadi

kelompok utama (kayu perdagangan), kayu kurang dikenal (*the lesser known*) dan kayu sangat sedikit dikenal (*the least known*).

Saat ini jumlah jenis kayu yang diperdagangkan di Indonesia, berdasarkan data *License Information Unit* (LIU) per November 2016, sebanyak 1.044 jenis. Seiring waktu, jenis kayu yang diperdagangkan bertambah, dan kurang lebih 226

jenis diantaranya belum terdata, serta belum termasuk 186 kelompok jenis yang ditetapkan melalui Keputusan Menteri Kehutanan No. 163/Kpts-II/2003, tentang Pengelompokan Jenis Kayu Sebagai Dasar Pengenaan Iuran Kehutanan.

Mengetahui jenis-jenis kayu perdagangan adalah sangat penting salah satunya untuk mencegah terjadinya penyelundupan kayu, atau juga penetapan pajak kayu yang tidak sesuai sehingga dapat menyebabkan kerugian devisa negara.

Pada dasarnya jenis kayu yang berbeda merupakan jenis tumbuhan yang berbeda. Ketika sudah berwujud kayu, tentu kita sudah kehilangan informasi seperti bentuk daun, permukaan kulit tumbuhan, bentuk buah, dan lain-lain. Ciri yang mungkin tersisa dari sebuah potongan kayu adalah bau, berat jenis, warna, kekilapan, penampakan dan pola serat kayu, kekerasan, kekuatan kayu, dan lain-lain.

Diperlukan keahlian dan pengalaman yang cukup lama agar seseorang bisa mempelajari ciri-ciri setiap kayu dan kemudian bisa digunakan untuk mengidentifikasi jenis kayu. Ciri-ciri di atas memang bisa menjadi parameter untuk membedakan jenis kayu. Namun, dalam kasus tertentu, informasi-informasi tadi bisa saja berubah karena suatu potongan kayu telah rusak karena pengaruh cuaca, umur, serangan jamur, pengecatan dan lain. Oleh karena itu, masih diperlukan ciri-ciri lain yang lebih dapat diandalkan, misalnya ciri anatomi kayu.

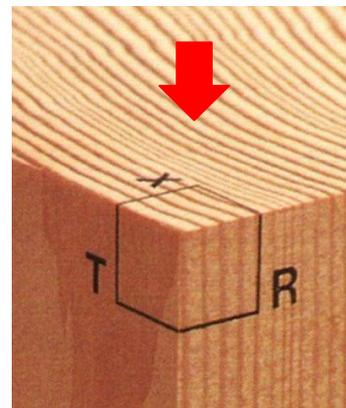
Kayu tersusun atas sel-sel yang memiliki fungsinya masing-masing. Sel-sel tersebut membentuk susunan tertentu yang memunculkan keunikan antara satu jenis dengan jenis kayu yang lain. Lalu, kita bisa menyebutnya sebagai ciri anatomi kayu. Makin mendalam teknik yang digunakan, semakin banyak pula pengalaman dan keahlian yang harus dilatih oleh seorang yang bertugas melakukan identifikasi kayu. Dimana hal ini tentu akan membuat waktu latihan semakin lama.

Telah ada beberapa penelitian yang dilakukan untuk mengidentifikasi spesies kayu dengan menggunakan *computer vision*. (Sugiarto et al. 2018) menggunakan HOG dan SVM untuk mengklasifikasikan 5 jenis kayu dengan akurasi rata-rata sebesar 70.5% dan 77.5%. (Salma et al. 2019) menggabungkan wavelet daubechies dengan LBP untuk mengklasifikasikan 3 jenis kayu dengan akurasi rata-rata 85%. (Gunawan et al. 2014) menggunakan metode 2D-PCA dan SVM untuk mengidentifikasi 4 jenis kayu dengan akurasi

sekitar 95%. (Hadiwidjaja et al. 2019) mengelaborasi LBP dan Hough Transform untuk mengidentifikasi 12 jenis kayu dan mendapatkan performa LBP lebih baik dibandingkan HOG dikarenakan HOG cukup kesulitan untuk mendeteksi setiap lubang pori kayu. (Ravindran et al., 2018) menggunakan CNN untuk mengklasifikasi 10 jenis kayu yang tercatat di CITES, mendapatkan akurasi sebesar 87.4%. (Tang et al. 2018) menggunakan machine vision dan metoda deep learning untuk mengidentifikasi 100 spesies kayu yang biasa diperdagangkan di Malaysia menghasilkan akurasi antara 77,52% dan 87,29%.

BAHAN DAN METODE

Pengumpulan dataset kayu dilakukan menggunakan koleksi potongan kayu dari kelompok kayu perdagangan milik laboratorium anatomi kayu pusat penelitian dan pengembangan hasil hutan (P3HH). Koleksi kayu kemudian difoto pada bagian potongan melintang (*cross-section*) untuk mendapatkan bentuk, ukuran, sebaran dari pembuluh dan serat kayu. Foto bagian penampang potongan melintang (X) ditunjukkan oleh panah seperti diperlihatkan pada gambar 1 dibawah ini.



Gambar 1. Penampang cross section (X) dari kayu (Hoadley 2000)

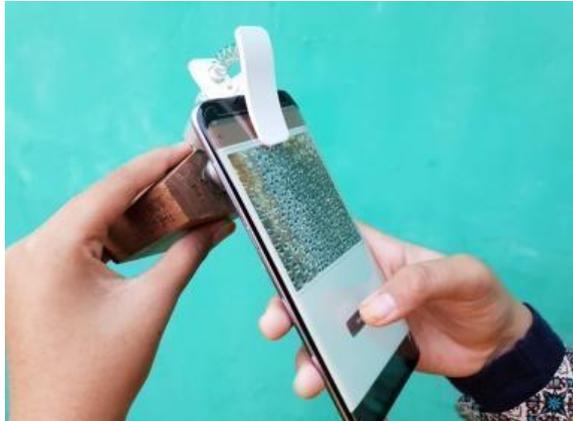
Pengambilan gambar dilakukan menggunakan kamera smartphone Samsung Galaxy S9, resolusi kamera 12 Mega piksel, dengan ekuivalen *focal length* sebesar 26mm pada sistem kamera film 35mm. Kemudian ditambahkan sebuah lup di depan lensa kamera untuk mendapatkan perbesaran gambar sebesar 60 kali, selanjutnya hasil foto dari kamera dipotong pada bagian tepi sehingga diperoleh ukuran sebesar 1000 × 1000 piksel dengan ekuivalen pembesaran 3.5 kali, sehingga total pembesaran sekitar 210 kali. Lup yang dipergunakan pada penelitian seperti yang

diperlihatkan pada gambar 2, berupa sebuah lup dengan pembesaran 60 kali dan sebuah lampu LED berwarna putih yang ditenagai baterai.



Gambar 2. Alat yang digunakan untuk mengambil data. (Shenzhen Dowdon Tech Co., Ltd.)

Proses pengambilan foto dilakukan menggunakan tangan dan tanpa bantuan tripod dan alat bantu fotografi lainnya, seperti diperlihatkan pada Gambar 3. Pengkondisian pencahayaan yang mengandalkan LED warna putih yang diarahkan ke objek. Tujuannya untuk portabilitas, fleksibilitas, dan aksesibilitas yang baik yang ingin dicapai dari sistem pendeteksi kayu otomatis yang ingin dibangun.



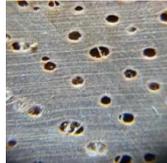
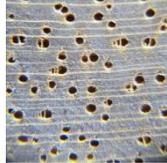
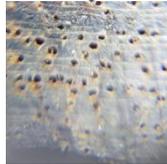
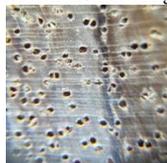
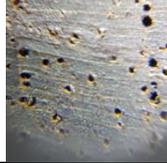
Gambar 3. cara pengambilan foto untuk dataset

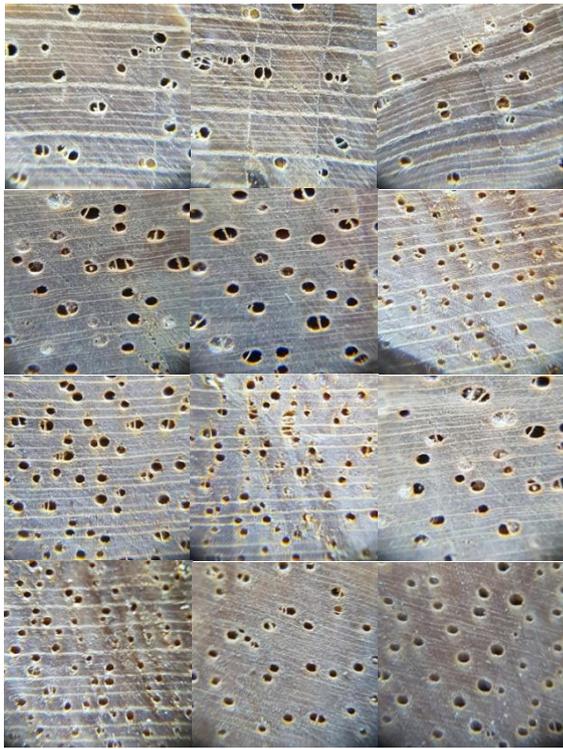
Jenis kayu yang diklasifikasi adalah sebanyak 7 spesies, seperti yang diperlihatkan pada tabel 1. Kayu ini termasuk kedalam jenis kayu komersial.

Pengambilan foto dengan cara seperti dijelaskan pada paragraf diatas dapat menghasilkan gambar yang menampilkan bentuk pembuluh dan serat kayu dengan cukup baik, hanya saja foto yang dihasilkan rawan terhadap *blur*, dan variasi pencahayaan, sehingga sulit mendapatkan gambar yang baik dan konsisten, hal ini menyebabkan penurunan kualitas dataset. Pada Gambar 4 dan

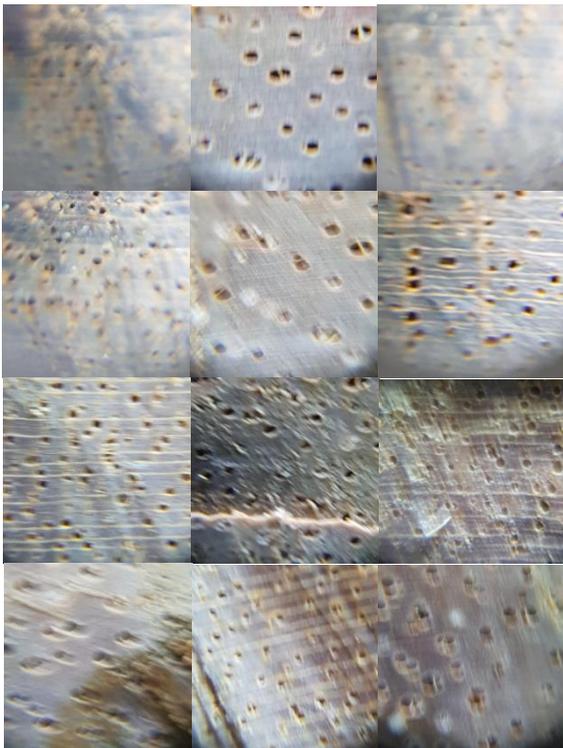
Gambar 5 diperlihatkan beberapa foto hasil pengambilan gambar dengan setup seperti yang dijelaskan diatas, Gambar 4 memperlihatkan foto dengan ketajaman yang baik dan pencahayaan yang merata, kemudian Gambar 5 memperlihatkan foto yang kurang baik, beberapa foto terlihat blur, sebagian terlihat shake, dan sebagian lainnya pencahayaannya tidak merata.

Tabel 1. Jenis Kayu yang diklasifikasi

Kode	Species	Suku	Nama Dagang
10754	Serianthes minahassa Merr.	Mimosoideae	Bowoi
			
14246	Albissia chinensis Merr. syn.	Leguminosae	Sengon/Batai
			
6867	Artocarpus kemando Miq.	Moraceae	Terap
			
6940	Scaphium macropodum J. B.	Sterculiaceae	Kembang semangkok
			
713	Sloetia elongata Kds	Moraceae	Tembinis/Tempinis
			
7781	Shorea kunstleri King	Dipterocarpaceae	Bangkirai
			
906	Toona sureni Merr	Meliaceae	Surian
			



Gambar 4. Contoh foto dataset yang cukup baik.



Gambar 5. Contoh foto dataset yang kurang baik.

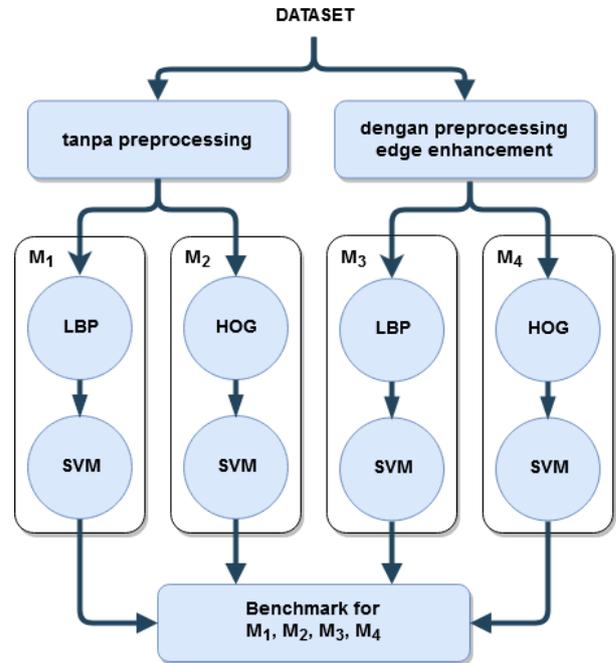
Kualitas dataset akan berdampak kepada performa akurasi identifikasi. Pada seksi pengumpulan dataset disebutkan bahwa pengambilan foto yang dilakukan seperti demikian akan rawan menghasilkan foto yang kurang baik seperti foto blur, shake, dan pencahayaan yang tidak merata.

Oleh sebab itu pada tulisan ini dilakukan penelitian untuk meningkatkan kualitas gambar, dengan menguatkan batas tepian objek pada gambar.

Metoda penguatan batas tepian menggunakan konvolusi dengan kernel filter edge enhancement, kemudian pengujian performa dilakukan menggunakan machine learning, dengan dua buah metoda fitur deskriptor yaitu Local Binary Pattern (LBP) dan Histogram of Oriented Gradients (HOG), dan algoritma klasifikasi menggunakan Support Vector Machine (SVM).

LBP dan HOG digunakan untuk mendapatkan fitur tekstur dan objek pada gambar. Dataset kayu di-*preprocessing* menggunakan filter edge enhancement. Dengan penguatan batas-batas tepian objek diharapkan bentuk serat dan pembuluh kayu menjadi lebih terungkap saat proses ekstraksi fitur.

Alur proses penelitian dibagi menjadi dua bagian, yaitu data latih dan data uji. Pada bagian yang pertama dilakukan training dan testing dataset secara langsung, kemudian pada bagian kedua ditambahkan proses preprocessing pada dataset sebelum dilakukan training dan testing. Gambar alur proses penelitian diperlihatkan pada gambar 6.



Gambar 6. Alur proses sistem.

Kemudian pada kedua bagian tersebut dilakukan ekstraksi fitur menggunakan metode HOG dan LBP, histogram hasil dari HOG dan LBP kemudian diklasifikasi menggunakan SVM untuk

menguji performa sebelum dan sesudah dilakukan preprocessing dengan filter edge enhancement pada dataset kayu.

Proses pemfilteran gambar adalah sebuah teknik untuk memodifikasi gambar, sebagai contoh kita dapat memfilter gambar untuk menguatkan atau menghilangkan fitur tertentu. Pemfilteran adalah sebuah operasi lingkungan, dimana nilai dari setiap piksel gambar output ditentukan dengan menerapkan algoritma tertentu pada nilai-nilai piksel di lingkungan piksel input. Lingkungan piksel adalah sekumpulan piksel yang lokasinya relatif terhadap piksel tersebut.

Pemfilteran linier adalah pemfilteran dimana nilai piksel output adalah kombinasi linier dari nilai piksel di lingkungan piksel input. Terdapat dua cara untuk menerapkan filter linier pada gambar input, yaitu menggunakan operasi korelasi, yang kedua operasi konvolusi.

Pada operasi korelasi, nilai piksel output dihitung sebagai jumlah tertimbang dari piksel-piksel di lingkungan piksel input. Matriks bobot disebut kernel atau disebut sebagai filter.

Operasi konvolusi mirip dengan operasi korelasi, hanya saja pada operasi konvolusi, matriks bobot diputar 180° sebelum dihitung dengan piksel input. Jika komposisi matriks simetris maka operasi korelasi maupun operasi konvolusi akan menghasilkan nilai output yang sama.

Sebagai contoh, misalnya matriks A adalah gambar

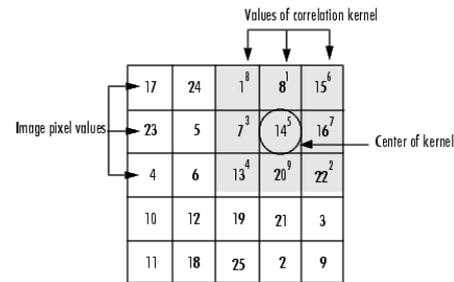
$$A = \begin{bmatrix} 17 & 24 & 1 & 8 & 15 \\ 23 & 5 & 7 & 14 & 16 \\ 4 & 6 & 13 & 20 & 22 \\ 10 & 12 & 19 & 21 & 3 \\ 11 & 18 & 25 & 2 & 9 \end{bmatrix}$$

dan matriks kernel filter adalah h

$$h = \begin{bmatrix} 8 & 1 & 6 \\ 3 & 5 & 7 \\ 4 & 9 & 2 \end{bmatrix}$$

maka, operasi korelasi matriks kernel filter h terhadap matriks gambar input A adalah seperti pada gambar 7

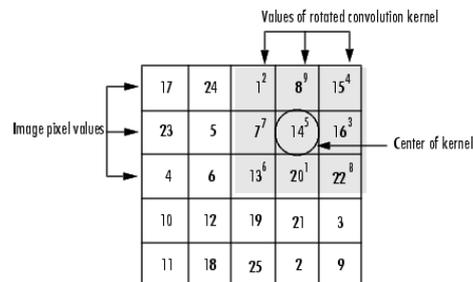
$$1 \cdot 8 + 8 \cdot 1 + 15 \cdot 6 + 7 \cdot 3 + 14 \cdot 5 + 16 \cdot 7 + 13 \cdot 4 + 20 \cdot 9 + 22 \cdot 2 = 585$$



Gambar 7. Proses korelasi matriks filter h terhadap matriks gambar input A . (MathWorks 2002)

Dan operasi konvolusi matriks filter h terhadap matriks gambar input A adalah seperti pada gambar 8

$$1 \cdot 2 + 8 \cdot 9 + 15 \cdot 4 + 7 \cdot 7 + 14 \cdot 5 + 16 \cdot 3 + 13 \cdot 6 + 20 \cdot 1 + 22 \cdot 8 = 575$$



Gambar 8. Proses konvolusi matriks filter h terhadap matriks gambar input A . (MathWorks 2002)

Deskripsi matematik untuk konvolusi dengan kernel filter K dari sebuah gambar dengan ukuran $N \times M$ diperlihatkan pada persamaan 1.

$$C(x, y) = 1/k \sum_{i=-N/2}^{N/2} \sum_{j=-M/2}^{M/2} K(i, j) I(x - i, y - j) \quad (1)$$

Untuk menghindari amplifikasi data *sum of product* biasanya *output* diskalakan dengan $1/k$, dimana k adalah jumlah dari nilai koefisien kernel. Formula untuk menghitung nilai k diperlihatkan pada persamaan 2.

$$k = \sum_{i=-N/2}^{N/2} \sum_{j=-M/2}^{M/2} K(i, j) \quad (2)$$

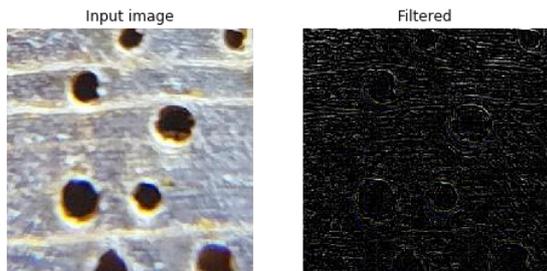
Tepian mewakili diskontinuitas intensitas suatu objek dalam sebuah gambar. Pada pemrosesan gambar digital tingkat tinggi seperti pengenalan objek, segmentasi, dan penglihatan robot biasanya bergantung pada keakuratan deteksi tepian. Menambahkan produk dari tepian gambar yang terdeteksi dan penskalaan konstan k ke gambar asli berguna sebagai penguat tepian gambar untuk memperbaiki persepsi visual (Zubair 2014).

Lima jenis filter untuk menguatkan batas tepian digunakan pada penelitian ini yaitu: *outline*, *sharpen*, *edge*, *left sobel*, dan *emboss*. Konfigurasi nilai matriks dari kelima kernel ini diperlihatkan pada Gambar 9.

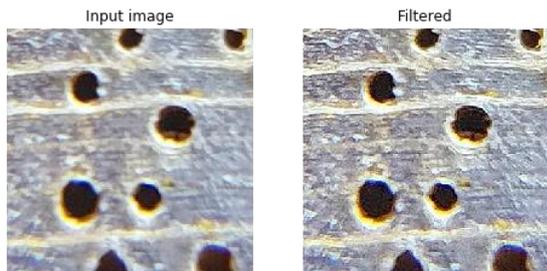
emboss	left sobel																		
<table border="1"> <tr><td>-2</td><td>-1</td><td>0</td></tr> <tr><td>-1</td><td>1</td><td>1</td></tr> <tr><td>0</td><td>1</td><td>2</td></tr> </table>	-2	-1	0	-1	1	1	0	1	2	<table border="1"> <tr><td>1</td><td>0</td><td>-1</td></tr> <tr><td>2</td><td>0</td><td>-2</td></tr> <tr><td>1</td><td>0</td><td>-1</td></tr> </table>	1	0	-1	2	0	-2	1	0	-1
-2	-1	0																	
-1	1	1																	
0	1	2																	
1	0	-1																	
2	0	-2																	
1	0	-1																	
outline	sharpen																		
<table border="1"> <tr><td>-1</td><td>-1</td><td>-1</td></tr> <tr><td>-1</td><td>8</td><td>-1</td></tr> <tr><td>-1</td><td>-1</td><td>-1</td></tr> </table>	-1	-1	-1	-1	8	-1	-1	-1	-1	<table border="1"> <tr><td>0</td><td>-1</td><td>0</td></tr> <tr><td>-1</td><td>5</td><td>-1</td></tr> <tr><td>0</td><td>-1</td><td>0</td></tr> </table>	0	-1	0	-1	5	-1	0	-1	0
-1	-1	-1																	
-1	8	-1																	
-1	-1	-1																	
0	-1	0																	
-1	5	-1																	
0	-1	0																	
	edge																		
	<table border="1"> <tr><td>0</td><td>-1</td><td>0</td></tr> <tr><td>-1</td><td>4</td><td>-1</td></tr> <tr><td>0</td><td>-1</td><td>0</td></tr> </table>	0	-1	0	-1	4	-1	0	-1	0									
0	-1	0																	
-1	4	-1																	
0	-1	0																	

Gambar 9. Konfigurasi nilai matriks kelima kernel edge enhancement.

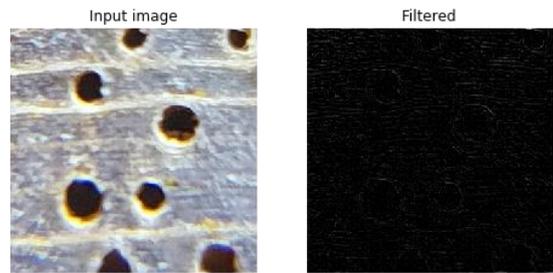
Hasil proses konvolusi dengan kelima filter edge enhancement diperlihatkan pada Gambar 10 sampai dengan Gambar 14.



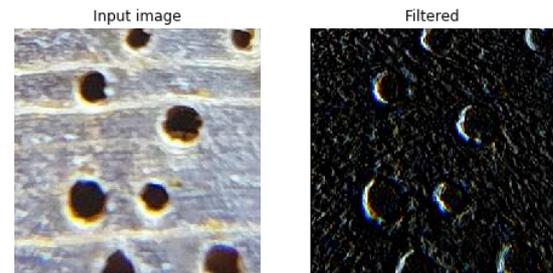
Gambar 10. hasil konvolusi dengan filter outline



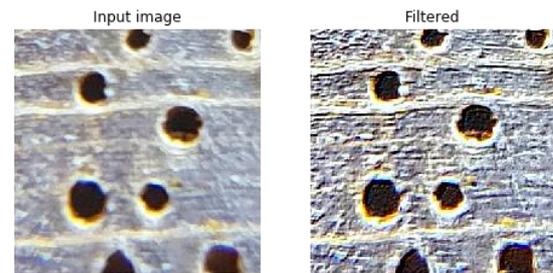
Gambar 11. hasil konvolusi dengan filter sharpen



Gambar 12. hasil konvolusi dengan filter edge



Gambar 13. hasil konvolusi dengan filter left sobel



Gambar 14. hasil konvolusi dengan filter emboss

Ekstraksi fitur adalah sebuah proses penggalan informasi yang terkandung dalam sebuah gambar, tujuannya untuk mengenali objek atau fitur yang terkandung didalam gambar. Informasi atau fitur yang terungkap dapat digunakan untuk mengenali objek atau digunakan untuk mengelompokkan gambar. Terdapat banyak metoda ekstraksi fitur yang dikembangkan. Pada penelitian ini akan digunakan deskriptor visual LBP dan HOG untuk menggali informasi yang terkandung didalam dataset foto penampang kayu cross-section.

LBP adalah jenis deskriptor visual yang digunakan untuk mendeskripsikan karakteristik tekstur permukaan dari sebuah gambar. Pola tekstur kemudian dirangkum menjadi sebuah histogram. Keteraturan pola tekstur suatu permukaan dapat diamati berdasarkan sebaran histogram nilai LBP (Prakasa 2016).

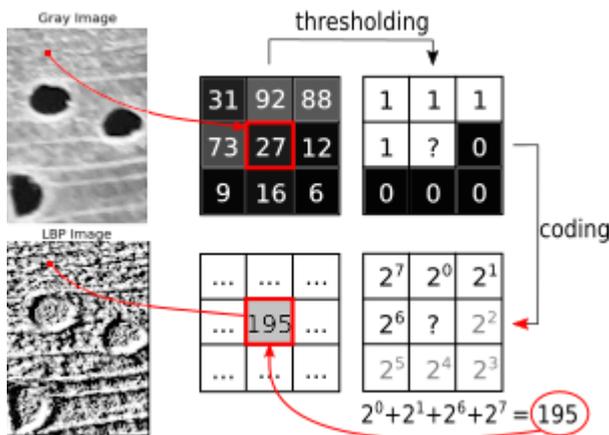
LBP bekerja dengan menguatkan perbedaan intensitas sebuah piksel g_c terhadap piksel-piksel

tetangganya $P(P = 0; \dots; P = 1)$ dalam radius R untuk menghasilkan pola kode biner, formula matematis untuk LBP ditunjukkan oleh persamaan 3 dan persamaan 4.

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p \quad (3)$$

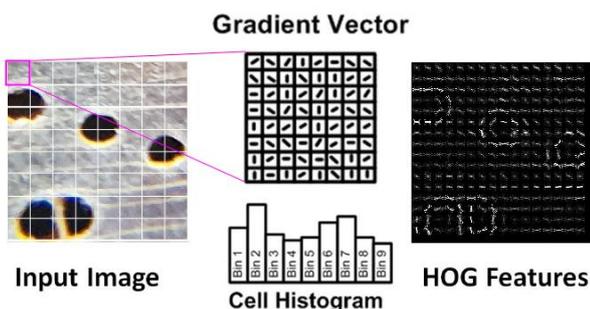
$$s(x) = \begin{cases} 1, & \text{if } x \geq 0 \\ 0, & \text{if } x < 0 \end{cases} \quad (4)$$

Pada Gambar 15 diilustrasikan proses ekstraksi tekstur gambar oleh LBP.



Gambar 15. Contoh kalkulasi piksel LBP

HOG adalah sebuah deskriptor visual yang menghitung kemunculan orientasi gradien pada sebuah porsi kecil dari gambar. Pada HOG gambar di lokalisasi menjadi porsi-porsi kecil yang dinamakan sel, dari setiap sel tersebut dihitung kemunculan orientasi gradiennya. Kemudian arah-arah dan magnitudo setiap gradien yang terjadi didalam sel dikompilasi ke dalam histogram, keseluruhan sel adalah gabungan dari histogram ini. Proses ekstraksi gradien HOG diperlihatkan pada Gambar 16. Metoda HOG dipopulerkan oleh Navneet Dalal dan Bill Triggs (Dalal and Triggs 2010) berdasarkan konsep yang dikembangkan oleh Robert K. Mc. Connell dan Mitsubishi Electric Research Labs.



Gambar 16. Ilustrasi kalkulasi HOG.

Metoda ini mempunyai keunggulan penting karena operasi dilakukan pada lokal sel, maka HOG menjadi invarian terhadap transformasi geometri dan fotometri.

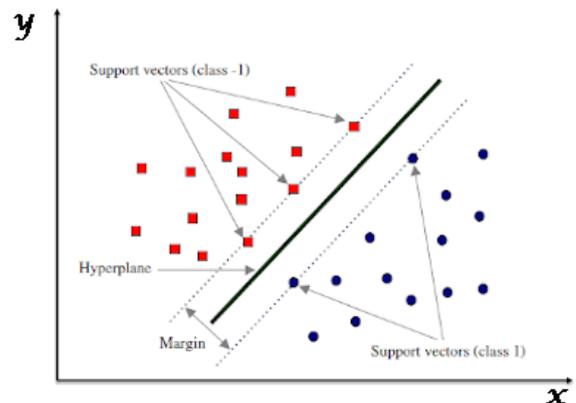
Formula untuk menghitung magnitudo g dan arah gradien θ adalah seperti diperlihatkan pada persamaan 5 dan persamaan 6 berikut:

$$g = \sqrt{g_x^2 + g_y^2} \quad (5)$$

$$\theta = \arctan \frac{g_y}{g_x} \quad (6)$$

g_x adalah gradien horizontal, dan g_y adalah gradien vertikal

SVM adalah sebuah algoritma supervised machine learning untuk melakukan klasifikasi maupun regresi, meskipun sebagian besar digunakan dalam masalah klasifikasi. SVM memplot setiap item data sebagai titik dalam ruang n -dimensi, yang mana n adalah jumlah fitur yang dimiliki dengan nilai setiap fitur menjadi nilai koordinat tertentu. Kemudian, dilakukan klasifikasi dengan menentukan hyper-plane untuk membedakan dua kelas, seperti diperlihatkan pada gambar 17.



Gambar 17. Ilustrasi klasifikasi SVM.

Jarak antara titik data terdekat antar kelas disebut support vectors. Menentukan hyper-plane yang tepat dengan mencari nilai margin yang tinggi, bertujuan agar didapatkan *robustness* yang baik. Jika kita memilih hyper-plane yang memiliki margin rendah maka kemungkinan kesalahan klasifikasi makin besar pula.

HASIL DAN PEMBAHASAN

Hasil klasifikasi diukur menggunakan *confusion matrix*. *Confusion matrix* adalah tabel yang sering digunakan untuk menggambarkan kinerja model klasifikasi pada satu set data uji yang nilai sebenarnya diketahui.

Jumlah prediksi yang benar dan salah dirangkum dengan nilai-nilai hitung dan dipecah oleh masing-masing kelas. *Confusion matrix* menunjukkan kesalahan yang dibuat oleh model klasifikasi ketika membuat prediksi. Ini memberi kita wawasan tidak hanya tentang kesalahan yang dibuat oleh *classifier* tetapi lebih penting lagi jenis kesalahan yang dibuat.

Tabel 2 hingga Tabel 7 memperlihatkan performa klasifikasi saat berbagai filter *egde enhancement* digunakan pada fitur deskriptor LBP. Kemudian Tabel 8 hingga Tabel 13 memperlihatkan performa klasifikasi saat berbagai filter *egde enhancement* digunakan pada fitur deskriptor HOG.

Tabel 2. Performa LBP untuk masing-masing spesies kayu tanpa preprocessing

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	94	60	100	75
Sengon/ Batai	87	20	67	31
Terap	91	70	70	70
Kembang semangkok	96	100	77	87
Tembinis/Tempinis	94	80	80	80
Bangkirai	90	100	59	74
Surian	96	90	82	86

Akurasi keseluruhan spesies = 74.29%

Tabel 3. Performa LBP untuk masing-masing spesies kayu dengan konvolusi menggunakan sharpening

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	86	0	0	0
Sengon/ Batai	84	0	0	0
Terap	86	0	0	0
Kembang semangkok	73	100	34	51
Tembinis/Tempinis	86	100	50	67
Bangkirai	79	40	31	35
Surian	96	70	100	82

Akurasi keseluruhan spesies = 44.29%

Tabel 4. Performa LBP untuk masing-masing spesies kayu dengan konvolusi menggunakan emboss

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	83	10	25	14
Sengon/ Batai	84	0	0	0
Terap	93	100	67	80
Kembang semangkok	100	100	100	100
Tembinis/Tempinis	89	70	58	64
Bangkirai	86	50	50	50

Surian	86	90	50	64
--------	----	----	----	----

Akurasi keseluruhan = 60%

Tabel 5. Performa LBP untuk masing-masing spesies kayu dengan konvolusi menggunakan edge

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	83	0	0	0
Sengon/ Batai	86	10	50	17
Terap	80	30	30	30
Kembang semangkok	67	100	30	47
Tembinis/Tempinis	90	60	67	63
Bangkirai	87	10	100	18
Surian	90	80	62	70

Akurasi keseluruhan spesies = 41.43%

Tabel 6. Performa LBP untuk masing-masing spesies kayu dengan konvolusi menggunakan outline

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	81	0	0	0
Sengon/ Batai	83	10	25	14
Terap	60	100	26	42
Kembang semangkok	96	70	100	82
Tembinis/Tempinis	93	50	100	67
Bangkirai	87	10	100	18
Surian	97	100	83	91

Akurasi keseluruhan spesies = 48.57%

Tabel 7. Performa LBP untuk masing-masing spesies kayu dengan konvolusi menggunakan left sobel

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	67	60	24	34
Sengon/ Batai	84	0	0	0
Terap	84	10	33	15
Kembang semangkok	86	0	0	0
Tembinis/Tempinis	96	10	77	87
Bangkirai	66	70	25	37
Surian	86	0	0	0

Akurasi keseluruhan spesies = 34.29%

Tabel 8. Performa HOG untuk masing-masing spesies kayu tanpa preprocessing

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	99	90	100	95
Sengon/ Batai	93	90	69	78
Terap	97	90	90	90
Kembang semangkok	97	80	100	89
Tembinis/Tempinis	97	80	100	89
Bangkirai	99	100	91	95
Surian	99	100	91	95

Akurasi keseluruhan spesies = 90%

Tabel 9. Performa HOG untuk masing-masing spesies kayu dengan konvolusi menggunakan sharpening

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	99	100	91	95
Sengon/ Batai	97	90	90	90
Terap	99	90	100	95
Kembang semangkok	99	90	100	95

Tembinis/Tempinis	97	80	100	89
Bangkirai	99	100	91	95
Surian	97	100	83	91

Akurasi keseluruhan spesies = 92.86%

Tabel 10. Performa HOG untuk masing-masing spesies kayu dengan konvolusi menggunakan emboss

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	96	90	82	86
Sengon/ Batai	94	80	80	80
Terap	99	90	100	95
Kembang semangkok	99	90	100	95
Tembinis/Tempinis	99	90	100	95
Bangkirai	99	100	91	95
Surian	99	100	91	95

Akurasi keseluruhan spesies = 91.43%

Tabel 11. Performa HOG untuk masing-masing spesies kayu dengan konvolusi menggunakan edge

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	100	100	100	100
Sengon/ Batai	97	100	83	91
Terap	99	90	100	95
Kembang semangkok	99	90	100	95
Tembinis/Tempinis	100	100	100	100
Bangkirai	100	100	100	100
Surian	100	100	100	100

Akurasi keseluruhan spesies = 97.14%

Tabel 12. Performa HOG untuk masing-masing spesies kayu dengan konvolusi menggunakan outline

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	100	100	100	100
Sengon/ Batai	97	100	83	91
Terap	99	90	100	95
Kembang semangkok	99	90	100	95
Tembinis/Tempinis	100	100	100	100
Bangkirai	100	100	100	100
Surian	100	100	100	100

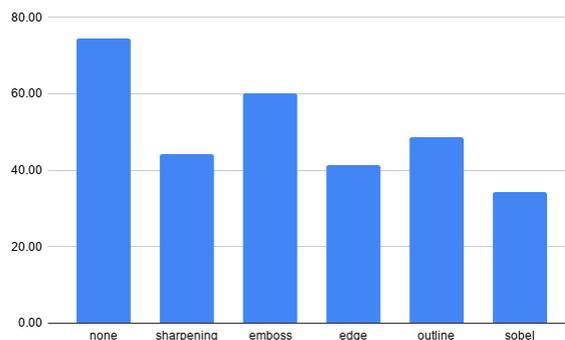
Akurasi keseluruhan spesies = 97.14%

Tabel 13. Performa HOG untuk masing-masing spesies kayudengan konvolusi menggunakan left sobel

Nama Dagang	akurasi [%]	recall [%]	precision [%]	f-1 [%]
Bowoi	100	100	100	100
Sengon/ Batai	96	90	82	86
Terap	97	90	90	90
Kembang semangkok	99	90	100	95
Tembinis/Tempinis	99	90	100	95
Bangkirai	100	100	100	100
Surian	99	100	90	95

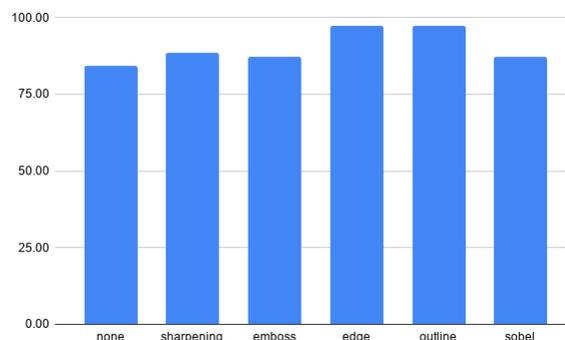
Akurasi keseluruhan spesies = 94.29%

Pada Gambar 18 diperlihatkan chart perbandingan akurasi yang didapat LBP sebelum dan sesudah preprocessing filter edge enhancement.



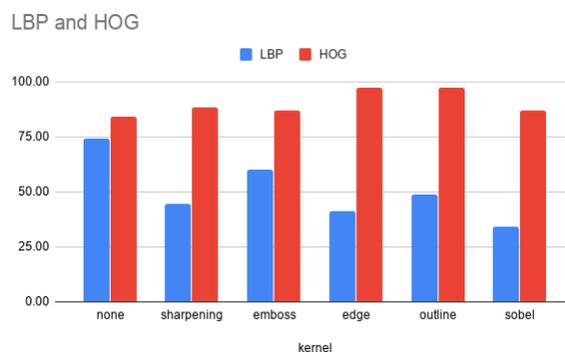
Gambar 18. chart akurasi klasifikasi menggunakan fitur deskriptor LBP dengan penerapan beberapa kernel filter

Pada Gambar 19 diperlihatkan chart perbandingan akurasi yang didapat HOG sebelum dan sesudah preprocessing filter edge enhancement.



Gambar 19. chart akurasi klasifikasi menggunakan fitur deskriptor HOG dengan penerapan beberapa kernel filter

Pada Gambar 20 diperlihatkan chart perbandingan akurasi yang didapat masing-masing jenis filter preprocessing untuk LBP dan HOG.



Gambar 20. perbandingan chart akurasi fitur deskriptor LBP dengan fitur deskriptor HOG pada setiap jenis filter edge enhancement

Dari Gambar 18 terlihat pada deskriptor LBP, akurasi klasifikasi menurun untuk keseluruhan

jenis filter *edge enhancement*. Kernel *left sobel* memperlihatkan penurunan tertinggi sebesar -40%, sedangkan kernel *emboss* memperlihatkan penurunan terendah yaitu sebesar -14.29%.

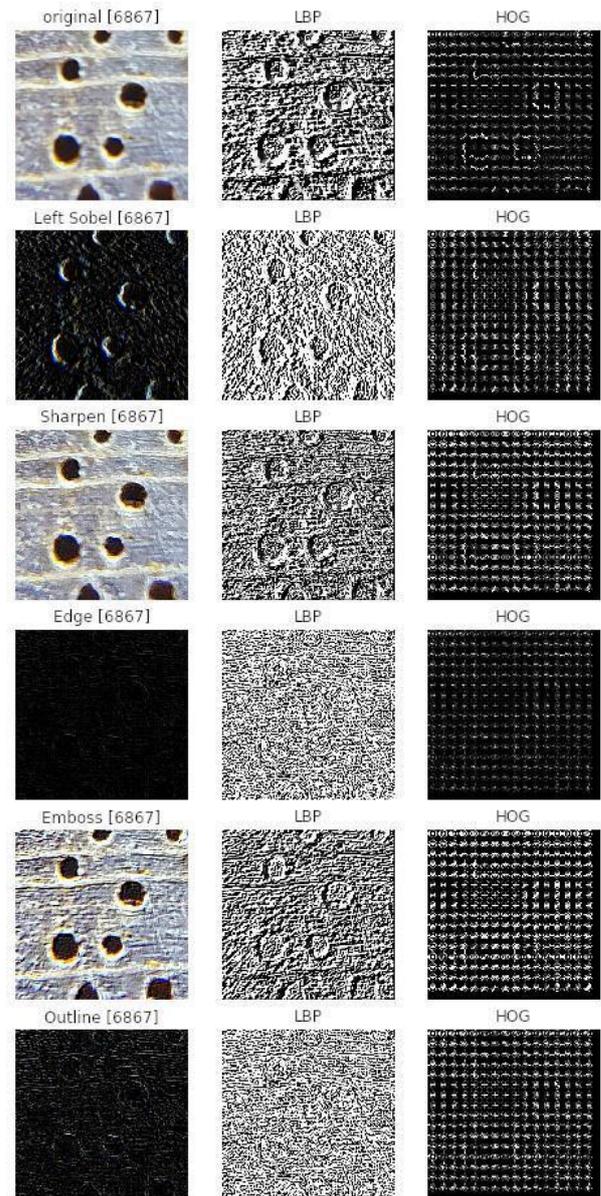
Dari Gambar 19 terlihat pada deskriptor HOG, akurasi meningkat untuk keseluruhan jenis filter *edge enhancement*. Peningkatan tertinggi didapat oleh kernel *edge* dan kernel *outline* yaitu sebesar +7.14%, sedangkan peningkatan terendahnya didapat oleh kernel *emboss* yaitu sebesar +1.43%.

Dari Gambar 20 terlihat bahwa hasil yang didapat LBP dan HOG saat dilakukan *preprocessing* penguatan batas tepian memperlihatkan hasil yang berbeda, dimana LBP memperlihatkan penurunan tingkat akurasi, sebaliknya pada HOG memperlihatkan peningkatan.

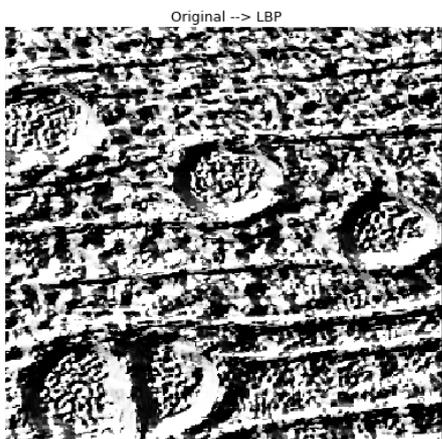
Visualisasi tekstur LBP dan visualisasi distribusi gradien dan magnitudo HOG ditunjukkan pada Gambar 21 yang memperlihatkan perbandingan contoh spesies kayu terap [6867] dengan kelima jenis filter *edge enhancement*.

Gambar 22 dan Gambar 23 memperlihatkan perbandingan hasil tekstur LBP sebelum dan setelah *preprocessing* secara lebih detail. Bentuk tekstur setelah dilakukan *preprocessing* secara umum terlihat menjadi lebih datar dan homogen dibanding tanpa dilakukan *preprocessing*.

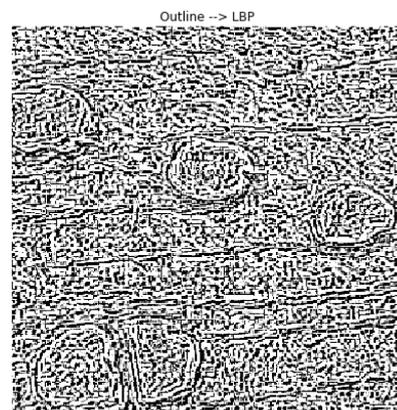
Gambar 24 dan Gambar 25 memperlihatkan perbandingan sebaran dan magnitudo gradien HOG secara lebih detail. Nilai magnitudo gradien pada setiap sel terlihat lebih besar, dan variasi gradien pada setiap sel terlihat lebih kaya. Gradien pada setiap selnya yang lebih kaya menyebabkan bentuk objek pori dan serat kayu terlihat menjadi lebih samar.



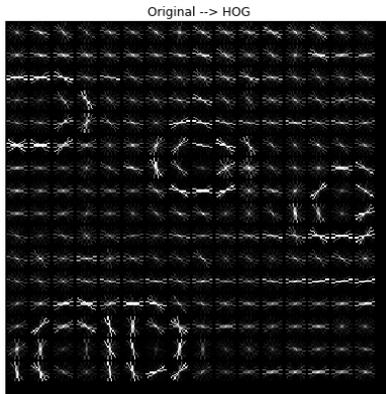
Gambar 21. Perbandingan hasil ekstraksi fitur LBP dan HOG sebelum dan sesudah preprocessing menggunakan lima jenis filter *edge enhancement* pada sampel kayu terap [6867].



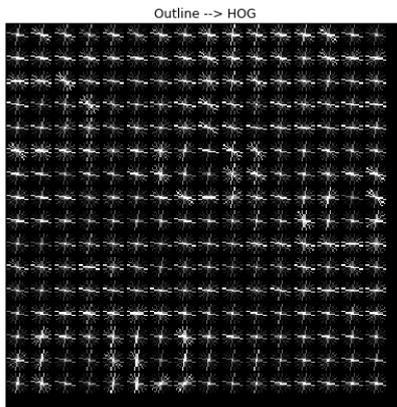
Gambar 22. Tekstur LBP tanpa *preprocessing* pada sampel kayu bowoi [10754].



Gambar 23. Tekstur LBP dengan *preprocessing outline* pada sampel kayu bowoi [10754].



Gambar 24. Visualisasi gradien HOG tanpa *preprocessing* pada sampel kayu bowoi [10754].



Gambar 25. Visualisasi gradien HOG dengan *preprocessing outline* pada sampel kayu bowoi [10754].

KESIMPULAN

Kesimpulan dari penelitian ini terdapat hasil yang berbeda dari penerapan *preprocessing* filter edge enhancement pada LBP dan HOG. *Preprocessing* edge enhancement dapat meningkatkan performa klasifikasi pada HOG, tetapi menurunkan performa akurasi pada LBP. Nilai peningkatan akurasi pada HOG yang tertinggi dicapai oleh filter *edge* dan filter *outline* sebesar +7.14% dengan nilai akurasi sebesar 97.14%.

Secara visual terlihat bahwa objek serat dan pori-pori kayu pada tekstur LBP setelah dilakukan *preprocessing* lebih samar dibandingkan sebelum dilakukan proses *preprocessing*. Sedangkan sebaran orientasi gradien pada HOG setelah dilakukan *preprocessing* terlihat lebih kaya

dibandingkan sebelum dilakukan *preprocessing*. Metoda penguatan batas tepian objek terbukti dapat menguatkan pengenalan objek pada HOG.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Pusat Penelitian Hasil Hutan (P3HH) Kementerian Lingkungan Hidup dan Kehutanan atas penyediaan sampel kayu dalam rangka kegiatan Insinas Kemitraan Kementerian Ristek Dikti pada tahun 2017 hingga 2018. Ucapan terima kasih juga ditujukan kepada fasilitas High Performance Computer (HPC) Lembaga Ilmu Pengetahuan Indonesia dalam menyimpan data-data kayu hasil kegiatan Insinas.

DAFTAR PUSTAKA

- Dalal, N. and Triggs, B. 2010. Histograms of Oriented Gradients for Human Detection To cite this version : HAL Id : inria-00548512 Histograms of Oriented Gradients for Human Detection. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition* , pp. 886–893.
- FORDA 2013. 75 Persen Jenis Kayu di Indonesia Sudah Teridentifikasi.
- Gunawan, A., G.R. et al. 2014. Identifikasi Jenis Kayu Menggunakan Support Vector Machine Berbasis Data Citra Wood Type Identification Using Support Vector Machine Based on Image Data. *Journal Ilmu Komputer Agri Informatika* 3, pp. 1–8.
- Hadiwidjaja, M.L. et al. 2019. Developing Wood Identification System by Local Binary Pattern and Hough Transform Method. *Journal of Physics: Conference Series* 1192(1). doi: 10.1088/1742-6596/1192/1/012053.
- Hoadley, R.B. 2000. *Understanding Wood: A Craftman's Guide to Wood Technology*. 1st ed. Sinitky, D. ed. Newtown: James Childs.
- MathWorks 2002. *Image Processing Toolbox For Use with M ATLAB. Computation, Visualization, Programming*.
- Prakasa, E. 2016. Ekstraksi Ciri Tekstur dengan Menggunakan Local Binary Pattern Texture Feature Extraction by Using Local Binary Pattern. *Jurnal INKOM* 9(2), pp. 45–48.
- Ravindran, P. et al. 2018. Classification of CITES-listed and other neotropical Meliaceae wood images using convolutional neural networks. *Plant Methods* 14(1), pp. 1–10. doi: 10.1186/s13007-018-0292-9.
- Salma et al. 2019. Wood Identification on Microscopic Image with Daubechies Wavelet Method and Local Binary Pattern. *2018 International Conference on Computer, Control, Informatics and its Applications: Recent Challenges in Machine Learning for Computing Applications, IC3INA 2018 - Proceeding* , pp. 23–27. doi: 10.1109/IC3INA.2018.8629529.

- Shenzhen Dowdon Tech Co., L. [no date]. China 60X Universal Mobile Phone Clip LED Microscope Magnifier with UV Currency Detector Flashlight - China Mobile Phone Magnifier, 60X Magnifier.
- Sugiarto, B. et al. 2018. Wood identification based on histogram of oriented gradient (HOG) feature and support vector machine (SVM) classifier. *Proceedings - 2017 2nd International Conferences on Information Technology, Information Systems and Electrical Engineering, ICITISEE 2017* 2018-Janua, pp. 337–341. doi: 10.1109/ICITISEE.2017.8285523.
- Tang, X.J. et al. 2018. MyWood-ID: Automated macroscopic wood identification system using smartphone and macro-lens. *ACM International Conference Proceeding Series* , pp. 37–43. doi: 10.1145/3293475.3293493.
- Zubair, A.R. 2014. Image Edge Detection and Image Edge Enhancement: Numerical Experiment on High Pass Spatial Filtering. *International Journal of Computer and Information Technology* 03(04), pp. 772–781.