

PENERAPAN ACTIVE CONTOUR MODEL PADA PENGOLAHAN CITRA UNTUK DETEKSI KERUSAKAN JALAN (APPLICATION OF ACTIVE CONTOUR MODEL ON IMAGE PROCESSING FOR DETECTION OF ROAD DAMAGE)

Yuslena Sari¹⁾, Andreyan Rizky Baskara²⁾, Puguh Budi Prakoso³⁾, Muhammad Arif Rahman⁴⁾

^{1),2),4)}Program Studi Teknologi Informasi, Universitas Lambung Mangkurat

³⁾Program Studi Teknik Sipil, Universitas Lambung Mangkurat

^{1),2),3)4)}Jl. Brig. Hasan Basry Kayu Tangi, Banjarmasin, Kalimantan Selatan 70123

e-mail: ¹⁾yuzlena@ulm.ac.id, ²⁾andreyan.baskara@ulm.ac.id, ³⁾puguh.prakoso@ulm.ac.id, ⁴⁾m.arifrahman10@gmail.com

Diterima: 14 Juni 2020 ; direvisi: 26 November 2021; disetujui: 29 November 2021.

ABSTRAK

Kerusakan pada permukaan jalan seperti jalan berlubang sering kali mengganggu pada transportasi darat, bahkan dapat menyebabkan kecelakaan. Dengan adanya deteksi jenis kerusakan jalan secara otomatis, dapat mempermudah proses klasifikasi jenis kerusakan jalan dengan menggunakan citra dari hasil klasifikasi sistem yang selanjutnya dapat digunakan sebagai informasi pendukung pada perhitungan perbaikan jalan. Pada penelitian ini untuk identifikasi citra kerusakan jalan digunakan teknik segmentasi active contour model berbasis level set kemudian diklasifikasikan dengan metode support vector machine. Berdasarkan hasil pengujian, dengan menggunakan 58 data set dengan 12 jenis kerusakan jalan, didapatkan hasil akurasi dari metode ini adalah sebesar 87,93%.

Kata Kunci: *active contour, jenis kerusakan jalan, pengolahan citra digital, support vector machine.*

ABSTRACT

Road damage is a serious problem because it often occurs everywhere. Damage to the road surface, such as potholes, often disrupts land transportation, and can even cause accidents. With the automatic detection of road damage types, it can simplify the process of classifying the types of road damage by using images from the results of the classification system which can be used as supporting information in calculating road repairs. In this study, to identify road damage types by images, the active contour model segmentation technique is used based on the level set and then classified by the support vector machine method. Based on the test results, using 58 data sets with 12 types of road damage, the accuracy of this method is 87.93%.

Key words: *active contour, road damage type, digital image processing, support vector machine*

PENDAHULUAN

Kerusakan jalan yang sering terjadi saat ini merupakan permasalahan yang kompleks dan sangat merugikan pengguna jalan saat berkendara seperti waktu tempuh yang lama, kemacetan, kecelakaan lalu lintas dan sebagainya (Mohan dan Poobal 2018). Jalan dalam hal ini merupakan prasarana transportasi darat yang mencakup semua bagian jalan, termasuk maupun bagian pelengkap dan peralatan yang ditujukan untuk lalu lintas yang berada di permukaan tanah.

Kondisi jalan yang sering dilalui oleh kendaraan dengan volume lalu lintas yang tinggi dapat mengurangi kualitas permukaan jalan, sehingga terjadi kerusakan jalan. Menurut Manual Pemeliharaan Kerusakan Jalan Bina Marga No. 03/MN/B/1983 jenis kerusakan jalan meliputi (Yudaningrum dan Ikhwanudin 2017):

1. Retak (*cracking*).
2. Distorsi.
3. Cacat permukaan (*disintegration*).
4. Pengausan (*polished aggregate*).
5. Kegemukan (*bleeding or flushing*).
6. Penurunan dalam penanaman utilitas.

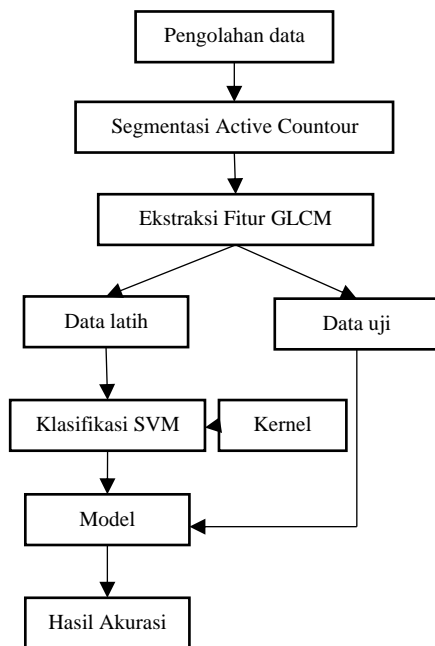
Kantor Dinas Pekerjaan Umum (DPU) menjelaskan faktor penyebab lamanya proses perbaikan jalan karena proses pencatatan dalam kondisi kerusakan jalan masih dilakukan secara manual. Proses pendeteksian dan pencatatan secara manual oleh tenaga manusia bisa memakan waktu 1-2 minggu per 1 km pencatatan jalan, belum lagi tingkat akurasi yang rendah. Pengenalan otomatis citra kerusakan jalan selalu menjadi masalah klasik di bidang rekayasa informasi lalu lintas dan pengenalan pola, dan telah menarik perhatian luas bagi para peneliti terkait. Penelitian tentang pengenalan otomatis citra kerusakan perkerasan jalan di dunia terutama berfokus pada perangkat keras sistem akuisisi citra perkerasan, namun pengolahan gambar 2D kerusakan perkerasan telah menjadi topik penelitian yang menantang, yang terdiri dari 3 aspek: segmentasi, ekstraksi fitur, dan klasifikasi (Wang dkk. 2019). Algoritma tunggal sulit untuk diterapkan pada

deteksi jenis kerusakan jalan, karena deteksi kerusakan jalan memiliki masalah yang kompleks seperti: (1) kontras yang rendah antara retakan dan perkerasan di sekitarnya; (2) intensitas ketidakhomogenan di sepanjang retakan; dan (3) kemungkinan bayangan dan gangguan lainnya dengan intensitas yang sama dengan retakan. Beberapa sistem hibrida dirancang dalam bidang ini untuk memasukkan manfaat dari berbagai algoritma (Zou dkk. 2012; M. Zhang, Cao, dan Zhao 2017). (Zou dkk. 2012) telah mengeksplorasi deteksi retakan otomatis untuk citra perkerasan, menggunakan algoritma penghilangan bayangan geodesik untuk menghilangkan bayangan, pemungutan suara tensor untuk mendapatkan peta probabilitas retak, dan model grafik untuk mewakili benih dari peta sampel. Penelitian Zhang, dkk dan Sari, dkk (Sari, Prakoso, dan Baskara 2019; D. Zhang dkk. 2017) telah mengusulkan pendekatan kasar ke halus yang efisien dan andal untuk deteksi retak perkerasan aspal, yang mengintegrasikan metode thresholding adaptif, wilayah kepercayaan, dan algoritme pengembangan wilayah baru. Fungsi energi ACM (Nguyen, Kam, dan Cheng 2018; Basuki dan Ramadijanti 2017; Chambon dan Moliard 2011) ditetapkan berdasarkan karakteristik retakan (intensitas, tepi, tekstur, dll.), ACM dapat dianggap sebagai kerangka umum dan fleksibel. Secara umum, masalah yang ada dalam metode tersebut di atas dapat diselesaikan sampai batas tertentu dengan ACM. Prasanna dkk (Prasanna dkk. 2012) merancang algoritma klasifikasi berbasis histogram dan menggunakannya bersama dengan SVM untuk mendeteksi retakan pada permukaan dek beton; hasil pada data jembatan menyoroti perlunya meningkatkan akurasi prediksi praktis. Nhat-Duc Hoang¹ dan Quoc-Lam Nguyen (Hoang dan Nguyen 2018) membandingkan algoritma klasifikasi menggunakan machine learning, hasil menunjukkan bahwa SVM telah mencapai tingkat akurasi klasifikasi tertinggi (87,50%), diikuti oleh Jaringan Syaraf Tiruan (84,25%), dan Random Forest (70%). Gavilan dkk (Gavilán dkk. 2011) membuat system deteksi retakan jalan menggunakan Support Vector Machine (SVM), hasilnya classifier berbasis SVM linier dapat membedakan antara 10 jenis

perkerasan yang muncul di jalan-jalan Spanyol. Metode berbasis SVM yang memperhitungkan informasi piksel ketetangaan baru-baru ini diperkenalkan oleh Ai et al [18]. Terinspirasi oleh keberhasilan ACM untuk tugas segmentasi citra dan SVM pada metode klasifikasi maka diusulkan deteksi jenis kerusakan jalan menggunakan ACM bersama metode klasifikasi SVM.

METODOLOGI

Penelitian ini telah dilakukan langkah-langkah klasifikasi kerusakan jalan sebagai berikut.



Gambar 1. Alur klasifikasi kerusakan jalan jalan

Gambar 1. adalah alur atau langkah-langkah dalam klasifikasi kerusakan jalan. Data primer yang telah diambil akan diolah terlebih dahulu dengan persamaan ukuran 256x256 piksel. Data kemudian di segmentasi dengan *Active Counter* untuk mendapatkan area citra jalan rusak, setelah segmentasi kemudian ekstraksi fitur untuk mendapatkan ciri dari piksel – piksel pada citra. Data set yang diperoleh dari ekstraksi fitur akan dibagi menjadi data latih dan data uji. Data latih digunakan untuk mendapatkan model klasifikasi. Metode klasifikasi menggunakan SVM dengan modifikasi kernel. Setelah model

didapatkan dengan kernel yang tepat maka data latih digunakan untuk melihat hasil akurasi dari model yang diterapkan. Alur detail dari alur klasifikasi kerusakan jalan dapat diuraikan sebagai berikut.

Pengambilan Data

Penelitian ini dilakukan di daerah Sungai Lulut Jalan Martapura Lama Kabupaten Banjar. Adapun apa yang dilakukan dalam penelitian ini meliputi:

1. Pengambilan data di jalan Martapura Lama
2. Data yang diambil adalah data citra dengan melakukan observasi secara langsung ke lapangan.
3. Citra jalan yang diambil adalah kerusakan jalan daerah Jalan Martapura Lama.
4. Citra kerusakan jalan yang diteliti ada 12 jenis kerusakan jalan.

Adapun *hardware* (perangkat keras) seperti:

1. Komputer atau laptop, dengan spesifikasi minimum Core i5, RAM 4 GB.
2. Kamera ponsel Samsung A3 2015 8 MP.
3. Kabel data.

Sedangkan *software* (perangkat lunak) yang digunakan seperti:

1. Microsoft Excell
2. Microsoft Windows yang mendukung Matlab R2018a
3. Matlab R2018a


Pengolahan Data

Data citra yang telah diperoleh sebanyak 186 citra. Proses dilakukan menggunakan aplikasi Matlab R2018a. Proses data akan dibuat dengan memberikan gambaran tentang penerapan metode *active contour* untuk segmentasi, untuk ekstraksi fitur menggunakan *Grey Level Co-occurrence Matrix (GLCM)*, sedangkan untuk metode klasifikasinya menggunakan SVM diterapkan untuk akurasi data citra kerusakan jalan.

Dalam pengolahan data ini dibagi dua bagian, yaitu memproses data latih terlebih dahulu dan kemudian melakukan pengolahan data uji. Adapun tahapan bagaimana proses dilakukan pada citra kerusakan jalan sehingga hasil yang diinginkan sesuai dengan tujuan penelitian, tahapannya sebagai berikut:

1. Mengelompokkan data citra kerusakan jalan menjadi data latih dan data uji. Sampel data citra dibagi sesuai dengan kategori jenis kerusakan jalan yang terjadi. Ada 12

jenis data kerusakan jalan berdasarkan kategori yang digunakan untuk proses pengolahan data sebagaimana ditunjukkan pada gambar 2 di bawah ini:



Gambar 2. Jenis-jenis citra kerusakan jalan

2. Pemrosesan data citra berupa tahap pengkodean menggunakan aplikasi Matlab R2018a.

Proses Segmentasi

Pada pemrosesan citra, data yang telah diolah dipisah untuk menjadi data uji dan data latih. Data latih digunakan untuk melatih metode untuk mendapatkan model. Tahap proses data dimulai dari menkonversi citra RGB ke *grayscale*.

Sebelum segmentasi, data di set dengan ukuran 256 x 256 piksel terlebih dahulu. *Active contour* adalah berupa kurva yang dinamis yang dapat bergerak karena pengaruh internal dan *external force*, yang mana kurva tersebut akan menuju pada tepi dari obyek yang diinginkan.

Langkah pertama dilakukan adalah dengan melakukan inisialisasi kurva yang dekat dengan obyek, kemudian kurva tersebut bergerak menuju tepi dari obyek tersebut. Bentuk dari kurva akan menyesuaikan dengan sendirinya dengan bentuk dari tepi obyek itu, walaupun bentuk dari tepi tersebut tidak beraturan. Kurva akan berhenti mengembang bergerak jika kurva tersebut telah membungkus mengelilingi obyek tersebut. Tujuan dari *active contour* adalah membentuk sebuah model *active contour* dengan waktu dan biaya yang minimal dalam melakukan segmentasi, dan

dapat bekerja dengan baik tanpa adanya informasi dari image tersebut sehingga dapat melakukan segmentasi terhadap obyek yang diharapkan, sedangkan obyek yang lain akan dibuang (Tyagi 2018).

Formulasi *active contour* dirumuskan seperti pada persamaan (1)

$$F_1(C) + F_2(C) = \int_C |\mu_0 - c_1|^2 dx dy + \int_C |\mu_0 - c_1|^2 dx dy \quad (1)$$

Pada kasus yang sederhana, C_0 adalah minimizer dari *fitting term*.

$$\inf_C \{F_1(C) + F_2(C)\} \approx 0 \approx F_1(C_0) + F_2(C_0) \quad (2)$$

Pada *active contour without edge*, akan meminimalkan *fitting term* dan menambahkan beberapa regulasi term, seperti panjang dari kurva C dan luas dari region didalam C .

$$F(c_1, c_2, C) = \mu \cdot \text{Length}(C) + \nu \cdot \text{Area}(\text{inside}(C)) + \int_C |\mu_0(x, y) - c_1|^2 dx dy + \int_C |\mu_0(x, y) - c_2|^2 dx dy \quad (3)$$

Dimana panjang kurva dirumuskan:

$$\text{Panjang busurnya: } \int_C \sqrt{1 + (y_1)^2} dx \quad (4)$$

Luas area dirumuskan :

$$L = \frac{1}{2} \int_C (x dy - y dx) = \frac{1}{2} \int_C (x y_1 - y) dx \quad (5)$$

Jadi formulasi *active contour*


$$F(c_1, c_2, C) = \int_C \sqrt{1 + (y_1)^2} dx + \frac{1}{2} \int_C (x y_1 - y) dx + \int_C |\mu_0(x, y) - c_1|^2 dx dy + \int_C |\mu_0(x, y) - c_2|^2 dx dy \quad (6)$$

Hasil dari kontur akhir, beberapa titik dari *crack* juga terdeteksi. Dengan demikian, beberapa perbaikan dapat dilakukan lebih lanjut untuk mencapai hasil yang memuaskan. Biasanya pasca pengolahan dilakukan berdasarkan luas wilayah suatu wilayah. Ambang batas ukuran area diatur ke 300 dalam penelitian ini. Jika ukuran area lebih kecil dari ambang batas, area tersebut dianggap Metode *level set* (Hao dkk. 2017). Metode *level set* merupakan metode numerik umum untuk perubahan digaris depan yang digunakan dalam evolusi permukaan serta perubahan topologi. Dalam *level set* ini, masalah diidentifikasi dalam dimensi yang lebih tinggi. *Level set* berfungsi seperti ini:

$$z = \phi(x, y, t = 0) \quad (7)$$

Kolom (x, y) berisi kontur, dan $z = \text{signed}$. Nilai transformasi jarak (nilai negatif jika kontur ditutup, dan nilai positif jika berada di luar kontur). Memindahkan kontur berarti memindahkan tugas pengaturan *level set*, ϕ

(x,y,t) ke atas maupun ke bawah. Seperti gambar 5. di bawah ini.



Gambar 3. Transformasi gerakan pada level set

Kontur ini didefinisikan sebagai zero level set. Zero level set yang diatur setiap saat adalah permukaan level set yang diiris (berwarna merah). Seiring waktu, level set permukaan selalu berubah pada zero level set baru dapat dibentuk dan didefinisikan sebagai suatu kontur baru. Untuk menggerakkan permukaan pada level set adalah sebagai berikut:


1. Mendefinisikan medan kecepatan F , yang menjelaskan perpindahan *contour* terhadap waktu. Ini juga tergantung aplikasi yang digunakan terutama yang fisik seperti waktu, posisi, normal, *curvature*, *image gradient magnitude*.
2. Membangun *initial value* untuk fungsi level set yaitu $\phi(x, y, t = 0)$, yang tergantung pula terhadap posisi awal dari *contour*.
3. Mengatur nilai terhadap waktu, yaitu *contour* pada saat t didefinisikan oleh $\phi(x(t), y(t), t) = 0$

sebagai *noisy* yang secara otomatis dihilangkan.

Code proses segmentasi:

```
mask = zeros(size(imgInput));
mask(25:end-25,25:end-25) = 1;
bw =
activecontour(imgInput,mask,300);
```

Gambar 3 menunjukkan hasil dari *active contour* (b) citra kerusakan jalan (a).



Gambar 4. Proses *active contour*

Proses Ekstraksi Fitur

Proses selanjutnya adalah ekstraksi fitur dengan metode untuk pengambilan matriks GLCM dengan menggunakan *graycomatrix*

$$\text{GLCM} = \text{graycomatrix}(\text{imgAC}, \text{'Offset'}, [0 \ 2; -2 \ 2; -2 \ 0; -2 \ -2]);$$

Data-data yang diperlukan pada tabel ekstraksi untuk *output* yaitu *contrast*, *correlation*, *dissimilarity*, *energy*, dan *entropy* ditunjukkan pada gambar 4.

	0	45	90	135
Contrast	1.8424	2.0089	1.4055	1.9286
Correlation	0.7047	0.6772	0.7747	0.6901
Dissimilarity	0.8158	0.8802	0.6566	0.8426
Energy	0.0970	0.0921	0.1104	0.0934
Entropy	2.8628	2.9109	2.7319	2.8926

Gambar 5. Hasil GLCM

Pembagian Data

Proses klasifikasi perlu pembelajaran terlebih dahulu untuk mendapatkan model klasifikasi. Pembelajaran pada komputer memerlukan data latih. Data latih digunakan untuk menemukan model yang sesuai dengan data agar menghasilkan akurasi yang baik. Dari data set yang telah diperoleh perlu dibagi menjadi data latih dan data uji. Data uji digunakan pada model yang telah didapatkan dari pelatihan data latih. Total data pada penelitian ini adalah 186 data citra dengan pembagian data latih sebanyak 128 data citra dan data uji sebanyak 58 data citra.

Klasifikasi SVM

Support Vector Machine (SVM) merupakan pembelajaran yang menggunakan hipotesis bentuk sebuah fungsi linier dalam ruang fitur dimensi tinggi, pada teori optimisasi

yang dilatih dengan sebuah algoritma pembelajaran. Teori belajar statistik berdasar teori optimasi implementasi learning bias. SVM merupakan seperangkat metode pembelajaran mesin pada teori statistik Vladimir Vapnik (Kartal dan Cebi 2013). Metode SVM adalah salah satu metode yang digunakan untuk memilih variabel dan proses klasifikasi data (Umadevi dan Marseline 2018). Teknik pemecahan masalah menggunakan metode SVM dilakukan dengan menentukan suatu hyperplane terbaik. Hyperplane adalah sebuah fungsi untuk pemisah antar dua kelas.

SVM dapat melakukan proses generalisasi untuk menentukan pola tertentu berdasarkan data uji dan data latih. SVM juga cepat dalam menyelesaikan problem karena memiliki struktur yang sederhana.

SVM akan diterapkan terlebih dahulu pada data latih dengan modifikasi kernel C dan gamma untuk merancang model klasifikasi untuk diterapkan pada data citra kerusakan jalan. Setelah didapatkan kernel yang sesuai maka model tersebut akan diterapkan untuk data uji untuk mendapatkan hasil akurasi.

HASIL DAN ANALISIS

Dari proses pengolahan ke klasifikasi citra kerusakan jalan, total data sebanyak 186 data dengan total data latih yang digunakan adalah sebanyak 128 citra data latih sedangkan total data uji yang digunakan adalah sebanyak 58 data uji. Pelabelan data dapat dilihat pada tabel 1.


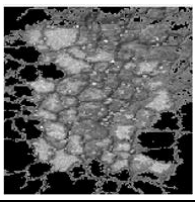

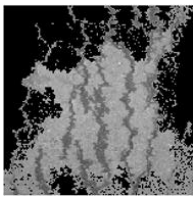

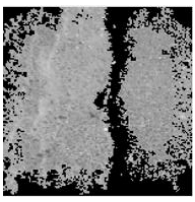

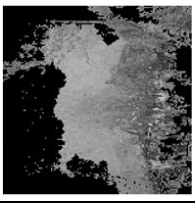

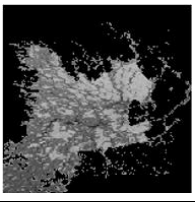

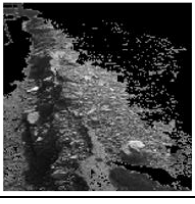

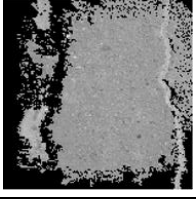
Tabel 1. Label Jenis Kerusakan Jalan


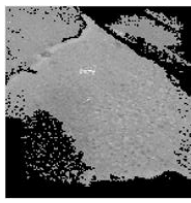

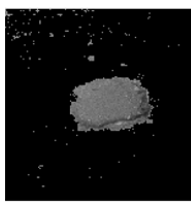

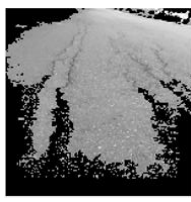



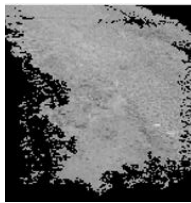
Jenis Kerusakan	Label
Retak kulit buaya (<i>Alligator Cracking</i>)	A
Keriting (<i>Corrugation</i>)	B
Amblas (<i>Depression</i>)	C
Edge Cracking	D
Joint Reflection Cracking	E
Penurunan bahu pada jalan (<i>Lane</i>)	F
Retak memanjang dan melintang (<i>Longitudinal & Transverse Cracks</i>)	G
Tambalan pada galian utilitas	H
Lubang (<i>Potholes</i>)	I
Alur (<i>Rutting</i>)	J
Sungkur (<i>Shoving</i>)	K
Pelepasan butir (<i>Weathering / Raveling</i>)	L

Hasil Segmentasi

Sampel hasil *active contour* dari setiap label dapat dilihat pada tabel 2 berikut:

Tabel 2. Hasil Segmentasi dengan *Active Contour*

Label	Citra Asli	Hasil Segmentasi
A		
B		
C		
D		
E		
F		
G		

Label	Citra Asli	Hasil Segmnetasi
H		
I		
J		
K		
L		

Hasil Klasifikasi

Klasifikasi menggunakan metode SVM. dengan setingan nilai $c=100$ dan $\gamma=1$. Dari 58 data set uji, terdapat 7 data yang error atau hasil klasifikasi dari metode SVM yang diterapkan tidak sesuai dengan *ground truth* atau hasil pelabelan sebenarnya yang dilihat dengan mata manusia. Contohnya data 1 hasil dari klasifikasi metode diusulkan adalah retak kulit buaya (*Alligator Cracking*) atau label A berbeda dengan label sebenarnya (*ground truth*) yaitu *Keriting (Corrugation)*. Kesalahan klasifikasi menggunakan metode yang diusulkan lebih banyak pada label A atau retak kulit buaya (*Alligator Cracking*)

Hasil data set yang memiliki hasil berbeda antara *ground truth* dan hasil klasifikasi dapat dilihat pada tabel 3 berikut:

Tabel 3. Hasil klasifikasi yang tidak sesuai dengan *Ground Truth*

No	Hasil Klasifikasi	<i>Ground Truth</i>
1	A	B
2	J	C
3	A	F
4	B	G
5	A	I
6	A	I
7	A	L

Hasil Evaluasi

Evaluasi digunakan menentukan akurasi dan hasil klasifikasi dengan menghitung data uji dan data latih oleh kelas. Metode evaluasi kinerja SVM yang digunakan dalam penelitian ini adalah *classification accuracy*, *classification accuracy* merupakan ukuran suatu ketepatan dari kejadian-kejadian yang diinginkan. Adapun persamaan dari *classification accuracy* terdapat pada persamaan 8.

$$\text{Classification Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \quad (8)$$

Persamaan 8 menggunakan nilai yang ditentukan pada *confusion* matriks, *confusion* matriks ialah klasifikasi sesungguhnya dan untuk memprediksi sebuah sistem klasifikasi.

Adapun pengertian dari istilah pada Persamaan 8 untuk proses evaluasi menggunakan *confusion* matriks 2x2, sebagai berikut:

1. TP = jumlah nilai positif yang terklasifikasi positif.
2. TN = jumlah nilai negatif yang terklasifikasi negatif.
3. FP = nilai negatif yang terklasifikasi positif.
4. FN = nilai positif yang terklasifikasi negatif.

Pada kasus klasifikasi 3 kelas, proses evaluasi menggunakan *confusion matriks* 3x3. Adapun *confusion* matriks 3x3 ditunjukkan pada Tabel 4.

Tabel 4. *Confusion* matriks 3x3

<i>Confusion</i> Matriks		<i>Predicted Class</i>		
		Truth1	Truth2	Truth3
<i>Actual Class</i>	Pred1	$C_{1,1}$	$C_{1,2}$	$C_{1,3}$
	Pred2	$C_{2,1}$	$C_{2,2}$	$C_{2,3}$
	Pred3	$C_{3,1}$	$C_{3,2}$	$C_{3,3}$

Pengertian dari istilah pada Persamaan 17 juga digunakan untuk proses evaluasi

menggunakan confusion matriks 3x3, sebagai berikut:

1. $TP = C1,1 + C1,2 + C1,3$
2. $TN = (C1,1 + C2,2) + (C1,1 + C3,3) + (C2,2 + C3,3)$
3. $FP = (C2,1 + C3,1) + (C1,2 + C3,2) + (C1,3 + C2,3)$
4. $FN = (C1,2 + C1,3) + (C2,1 + C2,3) + (C3,1 + C3,2)$

Jumlah nilai data benar (*Pred*) merupakan data uji kelas yang menggunakan klasifikasi dan hasilnya sama dengan kelas data sesungguhnya (*Truth*). Sedangkan nilai prediksi total adalah jumlah total catatan oleh kelas atau dari semua data uji yang dilakukan.

Dari seluruh hasil pada pengujian sistem maka klasifikasi yang didapatkan untuk proses pengujian akurasi dengan tiap-tiap jenis kerusakan jalan yang dirincikan pada sebuah Tabel 5. berikut:

Tabel 5. Hasil seluruh pengujian sistem

Data Sebenarnya (<i>ground truth</i>)	Hasil Sistem											
	A	B	C	D	E	F	G	H	I	J	K	L
A	5	0	0	0	0	0	0	0	0	0	0	0
B	1	4	0	0	0	0	0	0	0	0	0	0
C	0	0	4	0	0	0	0	0	0	1	0	0
D	0	0	0	4	0	0	0	0	0	0	0	0
E	0	0	0	0	5	0	0	0	0	0	0	0
F	1	0	0	0	0	3	0	0	0	0	0	0
G	0	1	0	0	0	0	4	0	0	0	0	0
H	0	0	0	0	0	0	0	5	0	0	0	0
I	2	0	0	0	0	0	0	0	3	0	0	0
J	0	0	0	0	0	0	0	0	0	5	0	0
K	0	0	0	0	0	0	0	0	0	0	5	0
L	1	0	0	0	0	0	0	0	0	0	0	4

Tabel 5 dapat dilihat perbandingan data sebenarnya atau *ground truth* (warna hijau) berbanding dengan hasil klasifikasi (warna biru) dari sistem dengan metode yang diusulkan memiliki hasil data sebanyak 51 (warna kuning) data bernilai benar antara hasil sistem sesuai dengan *ground truth*. Data *error* atau data sebenarnya/*ground truth* berbeda dengan hasil sistem metode diusulkan berjumlah 7 data (warna merah). Rincian hasil akurasi tiap label disajikan pada Tabel 6.

Tabel 6. Rincian hasil akurasi tiap label

No	Jenis Kerusakan	Label	Akurasi
1	Retak kulit buaya	A	50%
2	Keriting	B	75%
3	Ambblas	C	100%
4	Edge Cracking	D	100%
5	Joint Reflection Cracking	E	100%
6	Penurunan bahu pada jalan	F	100%
7	Retak memanjang dan melintang	G	100%
8	Tambalan pada galian utilitas	H	100%
9	Lubang	I	100%
10	Alur	J	83,33%
11	Sungkur	K	100%
12	Pelepasan butir	L	100%

Akurasi rendah terdapat pada label A atau jenis retak buaya. Hasil seluruh pengujian sistem dapat dilanjutkan untuk proses pengujian akurasi, sehingga tingkat keakuratan dari sistem bisa dihitung sebagai berikut:

$$\begin{aligned}
 \text{Classification Accuracy} &= \frac{TP}{\text{Total Dataset}} \times 100 \% \\
 &= \frac{51}{58} \times 100 \% \\
 &= 87,93\%
 \end{aligned}$$

Perhitungan di atas didapat tingkat keakuratan hasil klasifikasi SVM menggunakan ekstraksi fitur GLCM dan segmentasi *active contour* adalah 87,93%.

Hasil pengujian pada aplikasi deteksi jenis kerusakan jalan menggunakan ACM dan metode SVM, diperoleh kesimpulan bahwa dari pengujian yang didapat hasil dengan akurasi sebesar 87,93% maka, dapat dikatakan dari aplikasi yang telah dibuat mampu dan dapat digunakan dalam menentukan klasifikasi jenis kerusakan jalan yang telah dipilih. Sehingga dari aplikasi yang telah dibuat dapat mempermudah proses klasifikasi jenis kerusakan jalan dengan menggunakan citra dan dari hasil klasifikasi sistem nantinya bisa digunakan sebagai informasi pendukung untuk perhitungan perbaikan jalan.

KESIMPULAN DAN SARAN

Kesimpulan

Kesimpulan dari penelitian ini sebagai berikut:

1. Analisis kinerja metode yang diusulkan diukur dengan *confusion* Hasil akurasi dari pengujian sebesar 87,93%. Hasil tersebut dapat diartikan bahwa metode segmentasi *active* contour dengan klasifikasi SVM dapat diterapkan pada klasifikasi jalan rusak berbasis pengolahan citra digital.
2. Kesalahan klasifikasi terbanyak terjadi pada retak kulit buaya (*Alligator Cracking*) yaitu sebanyak 5 data. Pola dari retak buaya memiliki ciri kemiripan dengan pola kerusakan jalan yang lain seperti Keriting (*Corrugation*), Penurunan bahu pada jalan (*Lane*), Retak memanjang dan melintang (Longitudinal & Transverse Cracks), Pelepasan butir (*Weathring / Raveling*) menurut metode yang diusulkan.

Saran

Saran untuk pengembangan penelitian dengan menggunakan metode-metode lain sehingga proses segmentasi ataupun ekstraksi fitur dapat memberikan hasil yang lebih baik pada klasifikasi.

DAFTAR PUSTAKA

- Basuki, Achmad, dan Nana Ramadijanti. 2017. "Improving auto level method for enhancement of underwater images." *2016 International Conference on Knowledge Creation and Intelligent Computing, KCIC 2016*, 120–25. <https://doi.org/10.1109/KCIC.2016.7883635>.
- Chambon, Sylvie, dan Jean Marc Moliard. 2011. "Automatic road pavement assessment with image processing: Review and comparison." *International Journal of Geophysics* 2011. <https://doi.org/10.1155/2011/989354>.
- Gavilán, Miguel, David Balcones, Oscar Marcos, David F. Llorca, Miguel A. Sotelo, Ignacio Parra, Manuel Ocaña, Pedro Aliseda, Pedro Yarza, dan Alejandro Amírola. 2011. "Adaptive road crack detection system by pavement classification." *Sensors* 11 (10): 9628–57. <https://doi.org/10.3390/s111009628>.
- Hao, Ming, Caifeng Lu, Guoqing Wang, dan Wei Wang. 2017. "An improved neuron segmentation model for crack detection-image segmentation model." *Cybernetics and Information Technologies* 17 (2): 119–33. <https://doi.org/10.1515/cait-2017-0021>.
- Hoang, Nhat Duc, dan Quoc Lam Nguyen. 2018. "Automatic Recognition of Asphalt Pavement Cracks Based on Image Processing and Machine Learning Approaches: A Comparative Study on Classifier Performance." *Mathematical Problems in Engineering* 2018. <https://doi.org/10.1155/2018/6290498>.
- Kartal, Hasan Basri, dan Ferhan Cebi. 2013. "Support Vector Machines for Multi-Attribute ABC Analysis." *International Journal of Machine Learning and Computing* 3 (1): 154–57. <https://doi.org/10.7763/ijmlc.2013.v3.292>.
- Mohan, Arun, dan Sumathi Poobal. 2018. "Crack detection using image processing: A critical review and analysis." *Alexandria Engineering Journal*. <https://doi.org/10.1016/j.aej.2017.01.020>.
- Nguyen, H. N., T. Y. Kam, dan P. Y. Cheng. 2018. "Automatic crack detection from 2D images using a crack measure-based B-spline level set model." *Multidimensional Systems and Signal Processing*. <https://doi.org/10.1007/s11045-016-0461-9>.
- Prasanna, Prateek, Kristin Dana, Nenad Gucunski, dan Basily Basily. 2012. "Computer-vision based crack detection and analysis." *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2012* 8345: 834542. <https://doi.org/10.1117/12.915384>.
- Sari, Y, P B Prakoso, dan A R Baskara. 2019. "Road Crack Detection using Support Vector Machine (SVM) and OTSU Algorithm." In *2019 6th International Conference on Electric Vehicular Technology (ICEVT)*, 349–54. <https://doi.org/10.1109/ICEVT48285.2019.8993969>.
- Tyagi, Vipin. 2018. *Understanding Digital Image Processing. Understanding Digital Image Processing*. <https://doi.org/10.1201/9781315123905>.
- Umadevi, S., dan K. S.Jeen Marseline. 2018. "A survey on data mining classification algorithms." *Proceedings of IEEE International Conference on Signal Processing and Communication, ICSPC 2017* 2018-Janua (July): 264–68. <https://doi.org/10.1109/CSPC.2017.8305851>.
- Wang, Weixing, Mengfei Wang, Hongxia Li, Heng

- Zhao, Kevin Wang, Changtao He, Jun Wang, Sifan Zheng, dan Jiabin Chen. 2019. "Pavement crack image acquisition methods and crack extraction algorithms: A review." *Journal of Traffic and Transportation Engineering (English Edition)* 6 (6): 535–56. <https://doi.org/10.1016/j.jtte.2019.10.001>.
- Yudaningrum, Farida, dan Ikhwanudin Ikhwanudin. 2017. "Identifikasi Jenis Kerusakan Jalan (Studi Kasus Ruas Jalan Kedungmundu-Meteseh)." *Teknika* 12 (2): 16–23. <https://doi.org/10.26623/teknika.v12i2.638>.
- Zhang, Dejin, Qingquan Li, Ying Chen, Min Cao, Li He, dan Bailing Zhang. 2017. "An efficient and reliable coarse-to-fine approach for asphalt pavement crack detection." *Image and Vision Computing*. <https://doi.org/10.1016/j.imavis.2016.11.018>.
- Zhang, Mingyuan, Tianzhuo Cao, dan Xuefeng Zhao. 2017. "Applying sensor-based technology to improve construction safety management." *Sensors (Switzerland)* 17 (8). <https://doi.org/10.3390/s17081841>.
- Zou, Qin, Yu Cao, Qingquan Li, Qingzhou Mao, dan Song Wang. 2012. "CrackTree: Automatic crack detection from pavement images." *Pattern Recognition Letters* 33 (3): 227–38. <https://doi.org/10.1016/j.patrec.2011.11.004>.