

LAPORAN KEMAJUAN
PENELITIAN FUNDAMENTAL



DETEKSI DAN KUANTIFIKASI RETAK PERMUKAAN JALAN MENGGUNAKAN
METODE PENGOLAHAN CITRA DIGITAL DENGAN PENDEKATAN TEKNIK
MULTISKALA DAN KECERDASAN BUATAN

Tahun ke-2 dari 2 tahun

Oleh:

Slamet Riyadi, S.T., M.Sc., Ph.D. (NIDN 0509087801)
Sri Atmaja Putra JNNR, S.T., M.Sc.Eng., Ph.D. (NIDN 0515047801)
Noor Akhmad Setiawan, S.T., M.T., Ph.D. (NIDN 0007067503)

UNIVERSITAS MUHAMMADIYAH YOGYAKARTA

AGUSTUS 2016

HALAMAN PENGESAHAN

Judul : Deteksi dan Kuantifikasi Retak Permukaan Jalan Menggunakan Metode Pengolahan Citra Digital dengan Pendekatan Teknik Multiskala dan Kecerdasan Buatan

Peneliti/Pelaksana

Nama Lengkap : SLAMET RIYADI Ph.D
Perguruan Tinggi : Universitas Muhammadiyah Yogyakarta
NIDN : 0509087801
Jabatan Fungsional : Lektor
Program Studi : Teknik Informatika
Nomor HP : 08157917000
Alamat surel (e-mail) : riyadi@umy.ac.id

Anggota (1)

Nama Lengkap : SRI ATMAJA PUTRA J N N R S.T., M.Sc.Eng, Ph.D
NIDN : 0515047801
Perguruan Tinggi : Universitas Muhammadiyah Yogyakarta

Anggota (2)

Nama Lengkap : NOOR AKHMAD SETIAWAN S.T, M.T, Ph.D
NIDN : 0007067503
Perguruan Tinggi : Universitas Gadjah Mada
Institusi Mitra (jika ada) : -
Nama Institusi Mitra : -
Alamat : -
Penanggung Jawab : -
Tahun Pelaksanaan : Tahun ke 2 dari rencana 2 tahun
Biaya Tahun Berjalan : Rp 60.000.000,00
Biaya Keseluruhan : Rp 143.500.000,00

Mengetahui,
Dekan Fakultas Teknik



[Signature]
(Jazau Ikhsan, ST, MT, PhD)
NIP/NIK 19720524199804123037

Yogyakarta, 7 - 9 - 2016
Ketua,

(SLAMET RIYADI Ph.D)
NIP/NIK 19780809200104123048

DAFTAR ISI

HALAMAN PENGESAHAN	v
DAFTAR ISI	vi
RINGKASAN	vii
BAB I PENDAHULUAN	1
BAB II TINJAUAN PUSTAKA	3
2.1 Kajian Terdahulu	3
2.2 Support Vector Machine (SVM)	4
2.3 k-Fold Cross Validation	8
BAB III METODE PENELITIAN	9
3.1 Peta Jalan Penelitian	9
3.2 Rincian Metode Penelitian Tahun Kedua (2016)	10
BAB IV HASIL DAN PEMBAHASAN	13
4.1 Hasil pengumpulan data	13
4.2 Pra-pengolahan	14
4.3 Ekstraksi Ciri	15
4.3.1 Sum of Histogram	15
4.3.2 Black White Area	17
4.3.3 Sum of Histogram Oriented Gradient	19
4.4 Klasifikasi dan Validasi	20
4.4.1 Hasil Pengujian Parameter <i>Constraint</i>	21
4.4.2 Hasil klasifikasi dan Validasi	21
BAB V KESIMPULAN DAN RENCANA BERIKUTNYA	34
5.1 Kesimpulan	34
5.2 Ketercapaian luaran	34
5.3 Rencana kegiatan berikutnya	34
DAFTAR PUSTAKA	35
LAMPIRAN-LAMPIRAN	37

RINGKASAN

Pemeriksaan kondisi permukaan jalan dilakukan untuk mengetahui adanya retak atau tidak, mengklasifikasi jenis retak dan mengkuantifikasi retak tersebut. Secara konvensional, pemeriksaan dilakukan secara manual dimana petugas survei berjalan sambil memeriksa keberadaan retak dan mencatat serta menandai lokasi tersebut. Cara ini kurang efektif karena memerlukan waktu lama, tenaga kerja banyak, kurang tepat akibat subjektivitas dan faktor kelelahan serta berbahaya apabila pemeriksaan dilakukan pada jalan raya dengan kepadatan tinggi. Untuk mengatasi hal tersebut, peneliti memanfaatkan kemajuan teknologi kamera dan komputer untuk merekam kondisi permukaan jalan dan mengolah citra digital yang diperoleh dalam rangka mendeteksi keberadaan retak, mengklasifikasi dan mengkuantifikasinya. Metode pengolahan citra yang telah dibuat oleh para peneliti belum bisa direalisasikan dalam produk komersial karena belum memberikan hasil pemeriksaan yang optimal pada berbagai kondisi jalan, sensitif terhadap cahaya sekitar dan waktu komputasi lama. Penelitian tahun kedua ini melanjutkan penelitian tahun pertama, yaitu bertujuan untuk mengklasifikasi citra retak dan tidak retak menggunakan pendekatan kecerdasan buatan dengan metode *support vector machine* (SVM). Penelitian dilaksanakan dalam beberapa tahapan utama yaitu 1) pengumpulan data video retak permukaan jalan raya, 2) klasifikasi retak secara manual oleh pakar, 3) pra-pengolahan citra dan pengestrakan sifat retak (*sum of histogram, black white area, sum histogram of oriented gradient*), dan 4) klasifikasi retak menggunakan teknik SVM. Penelitian telah berhasil menerapkan metode SVM untuk mengklasifikasi citra retak dan tidak retak. Dengan menggunakan teknik *6-fold cross validation*, metode SVM telah diuji pada 120 citra dan menghasilkan akurasi klasifikasi retak 91,67%. Akurasi terbaik diperoleh pada model masukan SVM gabungan dari ketiga ciri yang diekstrak. Luaran yang dicapai adalah satu artikel seminar nasional dan satu seminar internasional (keduanya telah disubmit dan sedang direview), serta draft artikel jurnal internasional bereputasi.

BAB I PENDAHULUAN

Untuk menjamin keselamatan dan kenyamanan berkendara, jalan perlu dipelihara secara terus menerus. Pemeliharaan jalan diawali dengan pemeriksaan permukaan jalan secara berkala untuk mengetahui ada tidaknya kerusakan. Menurut Federal Highway Administration Amerika Serikat, kerusakan permukaan jalan dikategorikan menjadi lima, yaitu retak, tambalan dan lubang, deformasi permukaan, cacat permukaan dan kerusakan lain (Federal Highway Administration US, 2003). Penelitian ini hanya fokus pada pemeriksaan kerusakan berupa retak permukaan, yaitu untuk mendeteksi adanya retak permukaan, menentukan jenis retak dan mengkuantifikasi retak tersebut.

Secara konvensional, pemeriksaan retak permukaan dilakukan secara manual dimana petugas survei akan berjalan, mencatat lokasi dan luasan retak serta menandainya. Metode ini kurang efektif karena memerlukan waktu yang lama, tenaga kerja yang banyak dan kurang tepat akibat subjektivitas dan faktor kelelahan. Dalam aspek keselamatan, metode konvensional juga berbahaya bagi petugas khususnya bila pemeriksaan dilakukan pada jalan raya dengan kepadatan kendaraan yang tinggi.

Seiring dengan kemajuan teknologi kamera dan komputer, pemeriksaan retak secara visual menggunakan mata mulai digantikan dengan metode pengolahan citra digital. Melalui metode ini, kondisi permukaan jalan direkam menggunakan kamera video yang dirakit sedemikian hingga pada kendaraan survei. Hasil rekaman video permukaan jalan diolah menggunakan berbagai macam teknik pengolahan citra digital untuk mendeteksi adanya retak, menentukan jenis retak maupun menghitung luasan retak. Proses pengolahan citra bisa dilakukan secara masa nyata atau di laboratorium. Metode deteksi berbasis pengolahan citra digital mendapat sambutan sangat positif dari peneliti dan praktisi karena berpeluang besar mengatasi berbagai permasalahan metode konvensional. Disamping itu, metode ini juga relatif murah sehingga lebih mungkin direalisasikan dan diproduksi secara massal.

Penelitian tentang penggunaan metode pengolahan citra digital untuk pemeriksaan permukaan jalan telah dimulai sejak dekade 1990 hingga sekarang dengan hasil yang menjanjikan. Meskipun begitu, berbagai metode yang telah dihasilkan oleh peneliti baru dijumpai terbatas pada tahap diseminasi dalam seminar atau jurnal ilmiah tapi belum populer sebagai produk komersial. Hal ini dikarenakan metode yang ada belum memberikan hasil

pemeriksaan yang optimal pada berbagai kondisi jalan, sensitif terhadap cahaya sekitar dan waktu komputasi yang masih lama. Berdasarkan referensi yang ada, metode-metode yang telah diusulkan hanya fokus pada penentuan adanya retak atau tidak, sedangkan penentuan jenis retak dan berapa luasan letak tidak banyak diteliti. Kenyataan ini memberikan peluang yang lebar bagi peneliti untuk melakukan penelitian yang mendalam sehingga diperoleh hasil yang lebih baik dan sesuai kebutuhan.

Berdasarkan uraian di atas, penelitian ini bertujuan untuk menemukan metode baru deteksi retak permukaan jalan raya yang tangguh diimplementasikan pada berbagai jalan, tidak sensitif terhadap perubahan cahaya dan waktu komputasi cukup singkat. Pendekatan yang dilakukan merupakan gabungan dari pendekatan pemodelan multiskala dan pelatihan. Pemodelan multiskala dipilih karena dikenal tangguh terhadap gangguan pada citra dan tidak rentan terhadap perubahan tingkat keabuan (Zhang et al., 2013). Proses penentuan dan klasifikasi akan dilaksanakan dengan teknik pelatihan menggunakan *support vector machine* (SVM).

Penelitian tahun pertama telah menghasilkan kontribusi pada pembangunan teknik filtering untuk memperbaiki kualitas citra dan ekstraksi ciri dengan pendekatan multiskala pyramidal Gaussian. Selanjutnya, penelitian tahun kedua fokus pada pembangunan metode klasifikasi retak dan tidak retak dengan menggunakan metode SVM.

TARGET LUARAN

No	Luaran	Kuatitas	Waktu
1	Publikasi seminar nasional/internasional	1	Agustus 2016
2	Publikasi jurnal internasional (submitted)	1	Nopember 2016

BAB II TINJAUAN PUSTAKA

2.1 Kajian Terdahulu


Metode pengolahan citra digital untuk pemeriksaan kualitas permukaan jalan yang telah dihasilkan para peneliti dapat dirangkum menjadi lima kategori, yaitu metode dengan pendekatan analisis histogram, morfologi, pelatihan, penapisan dan pemodelan (Chambon & Moliard, 2011). Pendekatan analisis histogram berdasar pada asumsi bahwa distribusi tingkat keabuan antara citra retak dan permukaan jalan adalah terpisah. Pendekatan diwujudkan melalui teknik ambang batas (*thresholding*) baik secara lokal maupun adaptif (Chambon & Moliard, 2013; Teomete et al., 2005; Elbehiery et al., 2005). Pendekatan ini sederhana dan tidak memerlukan waktu pengolahan citra yang lama, akan tetapi akurasi pendeteksian cukup rendah. Ini terjadi karena secara fakta, distribusi tingkat keabuan citra retak dan permukaan jalan tidak secara jelas terpisah, berbeda dengan asumsi yang diambil oleh pendekatan ini.

Pendekatan kedua adalah menggunakan teknik morfologi (Coster, 2001; Ito et al., 2002; Iyer & Sinha, 2005). Pendekatan ini dilakukan dengan melakukan rekayasa terhadap tingkat keabuan citra sehingga perbedaan antara retak dan permukaan semakin jelas dan ciri-ciri yang khas bisa diekstrak untuk melakukan klasifikasi. Hasil pendekatan ini lebih baik dibanding pendekatan pertama akan tetapi sangat tergantung dengan pemilihan parameter rekayasa yang digunakan. Pendekatan ketiga bertumpu pada teknik pelatihan dan percobaan dengan menggunakan teknik jaringan syaraf tiruan (Liu et al., 2002; Saar et al, 2010). Pendekatan ini menghasilkan akurasi yang sama atau lebih tinggi dibanding dengan pendekatan kedua. Kekurangan utama pendekatan pelatihan adalah waktu komputasi yang diperlukan lama dan tidak bisa betul-betul secara masa nyata. Yang keempat, metode dilakukan dengan menggunakan berbagai teknik penapisan seperti wavelet dan Gabor untuk memperoleh ciri yang khas dari retak (Umesa et al, 2009; Zalama 2013). Pendekatan kelima dilakukan melalui pembuatan model

retak dan permukaan (Nguyen et al., 2009). Termasuk dalam pendekatan pemodelan adalah analisis multiskala untuk memperoleh sifat lokal dan sifat global yang menjadi ciri khusus retak dan permukaan. Dua pendekatan terakhir ini menghasilkan akurasi relatif tinggi dibandingkan dengan pendekatan-pendekatan sebelumnya.

2.2 Support Vector Machine (SVM)

Klasifikasi data adalah proses mengelompokkan sejumlah data kedalam grup tertentu berdasarkan properti atau nilai data tersebut. Salah satu metode klasifikasi data adalah *Support Vector Machine (SVM)*. Menurut Santoso (2007) SVM adalah suatu teknik untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi.



Gambar 2.1 *Support Vector Machine*

Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari hyperplane terbaik yang berfungsi sebagai pemisah dua buah *class* pada *input space*. Seperti pada gambar 2.14 beberapa *pattern* yang merupakan anggota dari dua buah *class*: +1 dan -1. *Pattern* yang tergabung pada class -1 disimbolkan dengan warna merah (kotak), sedangkan *pattern* pada class +1, disimbolkan dengan warna kuning (lingkaran). Problem klasifikasi dapat diterjemahkan dengan usaha menemukan garis (*hyperplane*) yang memisahkan antara kedua $\vec{x}_i \in \mathfrak{R}^d$ kelompok tersebut. Berbagai alternatif garis pemisah (*discrimination boundaries*) ditunjukkan pada gambar 2.1 (a). *Hyperplane* pemisah terbaik antara kedua *class*

dapat ditemukan dengan mengukur *margin hyperplane* tersebut dan mencari titik maksimalnya. Margin adalah jarak antara hyperplane tersebut dengan pattern terdekat dari masing-masing class. Pattern yang paling dekat ini disebut sebagai *support vector*. Garis solid pada gambar 2.1 (b) menunjukkan hyperplane yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua *class*, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah support vector. Usaha untuk mencari lokasi hyperplane ini merupakan inti dari proses pembelajaran pada SVM.

Data yang tersedia dinotasikan sebagai x_i sedangkan label masing-masing dinotasikan untuk $i = 1, 2, \dots, l$, adalah y_i banyaknya data. Diasumsikan kedua *class* -1 dan +1 dapat terpisah secara sempurna oleh hyperplane,

yang didefinisikan

$$\vec{w} \cdot \vec{x} + b = 0 \quad (1)$$

Pattern x_i yang termasuk *class* -1 (sampel negatif) dapat dirumuskan sebagai *pattern* yang memenuhi pertidaksamaan

$$\vec{w} \cdot \vec{x}_i + b \leq -1 \quad (2)$$

Sedangkan pattern x_i yang termasuk *class* +1 (sampel positif)

$$\vec{w} \cdot \vec{x}_i + b \geq +1 \quad (3)$$

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara *hyperplane* dan titik terdekatnya, yaitu $1/\|\vec{w}\|$. Hal ini dapat dirumuskan sebagai Quadratic Programming (QP) problem, yaitu mencari titik minimal persamaan (4), dengan memperhatikan *constraint* persamaan (5).

$$\min_{\vec{w}} \tau(\vec{w}) = \frac{1}{2} \|\vec{w}\|^2 \quad (4)$$

$$y_i (\vec{x}_i \cdot \vec{w} + b) - 1 \geq 0, \quad \forall i \quad (5)$$

Problem ini dapat dipecahkan dengan berbagai teknik komputasi, diantaranya *Lagrange Multiplier*.

$$L(\vec{w}, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l \alpha_i (y_i (\vec{x}_i \cdot \vec{w} + b) - 1) \quad (6)$$

α_i adalah Lagrange Multipliers, yang bernilai nol atau ($\alpha_i \geq 0$) positif. Nilai optimal dari persamaan (6) dapat dihitung dengan meminimalkan L terhadap w dan b , dan α_i memaksimalkan L terhadap α_i . Dengan memperhatikan sifat bahwa α_i pada titik optimal gradient $L=0$, persamaan (6) dapat dimodifikasi sebagai maksimalisasi problem yang hanya mengandung α_i saja, sebagaimana α_i persamaan (7) di bawah.

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \alpha_i \alpha_j y_i y_j \bar{x}_i \cdot \bar{x}_j \quad (7)$$

$$\alpha_i \geq 0 \quad (i = 1, 2, \dots, l) \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (8)$$

Dari hasil perhitungan ini diperoleh α_i yang kebanyakan bernilai positif. Data yang berkorelasi dengan a yang positif inilah yang disebut sebagai support vector. Penjelasan di atas berdasarkan asumsi bahwa kedua belah class dapat terpisah secara sempurna oleh hyperplane. Akan tetapi, umumnya dua buah class pada input space tidak dapat terpisah secara sempurna. Hal ini menyebabkan *constraint* pada persamaan (5) tidak dapat terpenuhi, sehingga optimisasi tidak dapat dilakukan. Untuk mengatasi masalah ini, SVM dirumuskan ulang dengan memperkenalkan teknik *softmargin*. Dalam *softmargin*, persamaan (5) dimodifikasi dengan

memasukan slack variable ξ_i ($\xi_i > 0$) sbb.

$$y_i(\bar{x}_i \cdot \bar{w} + b) \geq 1 - \xi_i, \quad \forall i \quad (9)$$

Dengan demikian persamaan (4) diubah menjadi:

$$\min_{\bar{w}} \tau(\bar{w}, \xi) = \frac{1}{2} \|\bar{w}\|^2 + C \sum_{i=1}^l \xi_i \quad (10)$$

Paramater C dipilih untuk mengontrol tradeoff antara margin dan error klasifikasi ξ . Nilai C yang besar berarti akan memberikan penalti yang lebih besar terhadap error klasifikasi tersebut.


Pada umumnya masalah dalam domain dunia nyata (*real world problem*) jarang yang bersifat linear separable. Kebanyakan bersifat *non linear*. Untuk menyelesaikan problem *non linear*, SVM dimodifikasi dengan memasukkan fungsi *Kernel*. Dalam *non linear SVM*, pertama-tama data x dipetakan oleh fungsi F ke

ruang vektor yang berdimensi lebih tinggi. Pada ruang vektor yang baru ini, hyperplane yang memisahkan kedua class tersebut dapat dikonstruksikan. Hal ini sejalan dengan teori Cover yang menyatakan “*Jika suatu transformasi bersifat non linear dan dimensi dari feature space cukup tinggi, maka data pada input space dapat dipetakan ke feature space yang baru, dimana pattern-pattern tersebut pada probabilitas tinggi dapat dipisahkan secara linear*”.

Pemetaan ini dilakukan dengan menjaga topologi data, dalam artian dua data yang berjarak dekat pada *input space* akan berjarak dekat juga pada feature space, sebaliknya dua data yang berjarak jauh pada input space akan juga berjarak jauh pada feature space. Selanjutnya proses pembelajaran pada SVM dalam menemukan titik-titik support vector, hanya bergantung pada *dot product* dari data yang sudah ditransformasikan pada ruang baru yang berdimensi lebih tinggi. Karena umumnya transformasi F ini tidak diketahui, dan sangat sulit untuk difahami secara mudah, maka perhitungan dot product tersebut sesuai teori Mercer dapat digantikan dengan fungsi kernel yang mendefinisikan secara implisit transformasi Hal ini disebut sebagai *Kernel Trick* yang dirumuskan Kernel trick memberikan berbagai kemudahan, karena dalam proses pembelajaran SVM, untuk menentukan support vector, kita hanya cukup mengetahui fungsi kernel yang dipakai, dan tidak perlu mengetahui wujud dari fungsi non linear F . Berbagai jenis fungsi kernel dikenal.

Salah satu Kernel Trick yang banyak digunakan *Radial Basis Function* (RBF). Menurut penelitian durgesh (2009), RBF merupakan kernel trick yang lebih baik dibandingkan *Polynomial* dan *Sigmoid*. RBF dapat memetakan data sebagai titik pada dimensi yang lebih tinggi, memiliki sedikit parameter sehingga tuning lebih mudah, dan proses komputasi dan metode numerik yang lebih mudah.

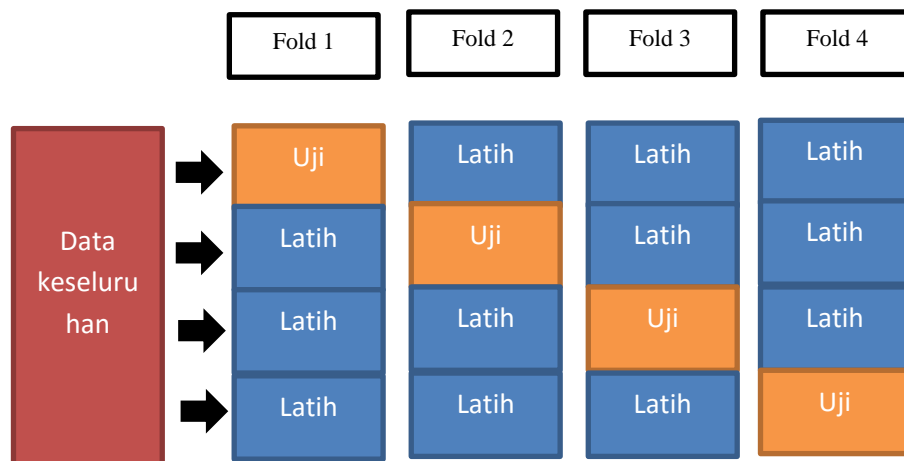
$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2), \gamma > 0$$



Gambar 2.2 Hasil kernel RBF

2.3 k-Fold Cross Validation

Cross Validation merupakan salah satu teknik untuk menilai/memvalidasi keakuratan sebuah model yang dibangun berdasarkan dataset tertentu. Pembuatan model biasanya bertujuan untuk melakukan prediksi maupun klasifikasi terhadap suatu data baru yang boleh jadi belum pernah muncul di dalam dataset. Data yang digunakan dalam proses pembangunan model disebut data latih/training, sedangkan data yang akan digunakan untuk memvalidasi model disebut sebagai data uji/test. Salah satu metode cross-validation yang populer adalah *K-Fold Cross Validation*. Dalam teknik ini dataset dibagi menjadi sejumlah K-buah partisi secara acak. Kemudian dilakukan sejumlah K-kali eksperimen, dimana masing-masing eksperimen menggunakan data partisi ke-K sebagai data testing dan memanfaatkan sisa partisi lainnya sebagai data training. Sebagai gambaran 4-Fold Cross-Validation ditunjukkan pada gambar 2.3. Untuk mendapatkan nilai akurasi ataupun ukuran penilaian lainnya dari hasil eksperimen yang dilakukan, dapat diambil nilai rata-rata dari seluruh eksperimen tersebut.

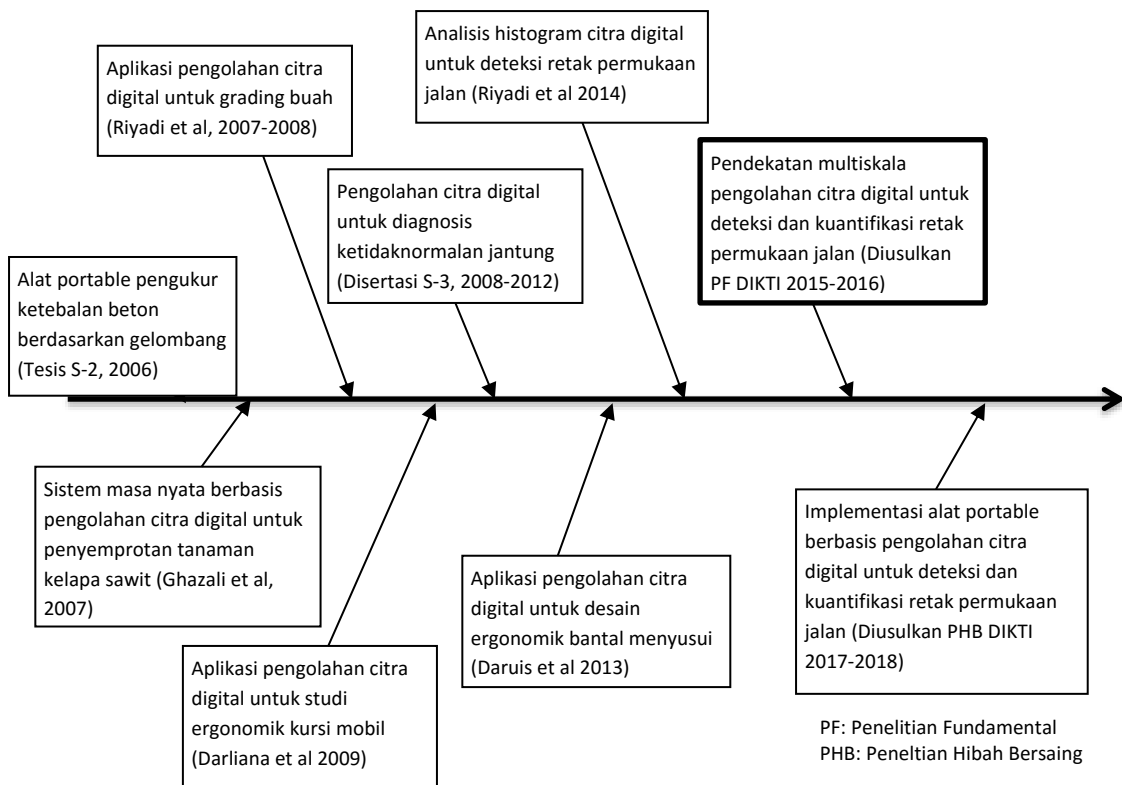


Gambar 2.3 Data set pada K-Fold Cross Validation

BAB III METODE PENELITIAN

3.1 Peta Jalan Penelitian

Penelitian tentang pembuatan alat pengujian tidak merusak (*non destructive testing*) permukaan jalan telah dimulai sejak 2006 yang ketika itu berbasis pada gelombang permukaan. Karena aplikasi pengolahan citra digital sangat populer dan prospektif, penelitian dilanjutkan dengan pembuatan metode dan implementasi pengolahan citra digital untuk berbagai aplikasi pada rentang waktu 2007 – 2013 sebagaimana dirangkum dalam diagram tulang ikan (*fishbone diagram*) pada Gambar 3.1. Studi pembuatan berbagai metode pengolahan citra digital ini menjadi bekal dan dasar untuk pembuatan metode dengan aplikasi deteksi retak permukaan jalan.



Gambar 3.1 *Fishbone diagram* peta jalan penelitian penerapan pengolahan citra digital untuk evaluasi permukaan jalan

Pada tahun 2014, peneliti telah melaksanakan pembuatan metode berbasis pengolahan citra digital dengan analisis histogram untuk mendeteksi retak permukaan jalan. Hasil penelitian ini akan menjadi awal dari pembuatan metode pengolahan citra digital yang lebih maju, kuat dan tidak rentan gangguan, yaitu dengan menggunakan pendekatan multiskala sebagaimana diajukan dalam proposal Penelitian Fundamental DIKTI ini untuk kegiatan penelitian 2015 - 2016. Hasil yang dicapai dari Penelitian Fundamental ini akan disempurnakan dan diimplementasikan dengan sebuah alat *portable* untuk pengujian masa nyata di permukaan jalan melalui pengajuan skema Penelitian Hibah Bersaing DIKTI 2017 – 2018.

Penelitian tahun kedua (2016) akan dilaksanakan dalam beberapa tahapan utama yaitu 1) pengumpulan data retak permukaan, 2) klasifikasi retak secara manual oleh pakar, 3) pembuatan metode pengekstrakan sifat retak dengan pendekatan multiskala, dan 4) klasifikasi retak menggunakan teknik SVM. Diagram alir tahapan penelitian tersebut ditunjukkan pada Gambar 3.2.

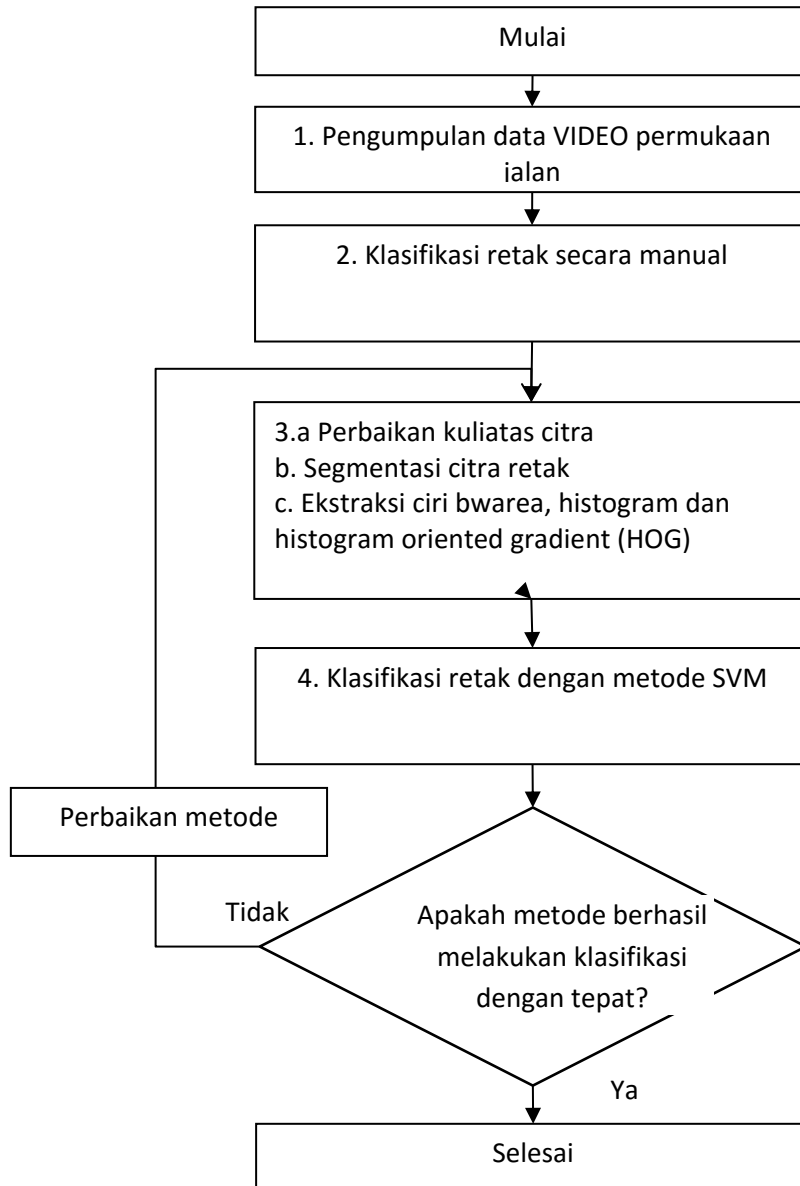
3.2 Rincian Metode Penelitian Tahun Kedua (2016)

Penjelasan rinci tahapan penelitian yang dilakukan pada tahun kedua adalah sebagai berikut:

1. Pengumpulan data video retak permukaan

Pengumpulan data retak permukaan jalan dilaksanakan dengan menggunakan perekam video. Perekam video dipasang pada kendaraan survei, bisa berupa mobil atau motor. Perekam dipasang sedemikian hingga pada posisi tegak lurus dengan permukaan jalan.

Pengambilan citra dilakukan di dua lokasi, yaitu Jalan Wates, Ambarketawang, Sleman dan jalan di Pengasih, Kulon Progo. Dua lokasi ini dipilih karena pada keduanya terdapat bagian jalan yang retak dan tidak retak. Perekaman video dilakukan dengan kendaraan pada kecepatan 10 km/jam, 20 km/jam dan 30 km/jam.



Gambar 3.2 Diagram alir tahapan penelitian tahun kedua



Gambar 3.3 Perekam video yang dipasang pada sepeda motor

2. Klasifikasi retak secara manual oleh pakar

Citra permukaan jalan yang telah diperoleh akan diklasifikasikan menjadi citra retak dan citra tidak retak. Klasifikasi dilakukan oleh anggota peneliti dari Program Studi Teknik Sipil UMY yang sudah berpengalaman dalam penentuan retak permukaan jalan. Hasil klasifikasi retak secara manual akan menjadi kebenaran rujukan (*ground-truth*) untuk keperluan penghitungan akurasi deteksi dan validasi metode yang dibuat.

3. Pengolahan citra

a. Pra-pengolahan citra

Tahapan ini bertujuan untuk mempersiapkan citra sebelum diolah lebih lanjut melalui pengecilan ukuran citra, konversi dari RGB ke grayscale.

b. Ekstraksi ciri

Ekstraksi ciri adalah tahapan pengambilan ciri unik dan khas yang merepresentasikan bagian retak. Berdasarkan penelitian tahun pertama, *ciri sum of histogram*, luasan area hitam-putih (*bwarea*) dan *sum of histogram of oriented gradient* (HOG) efektif menjadi ciri retak. Tiga ciri inilah yang akan diekstrak dari citra data.

4. Pembuatan metode untuk klasifikasi retak

Metode yang digunakan untuk mengklasifikasi retak adalah metode SVM. Metode ini terdiri dari dua tahapan, yaitu tahap latih dan uji. Pada tahap latih, ciri-ciri retak akan dijadikan sebagai masukan SVM dan SVM akan mengenali ciri-ciri tersebut serta menghasilkan hyperplane kuantifikasi retak. Hyperplane ini akan menjadi dasar tahapan uji dengan menggunakan data uji lainnya. Tahapan uji-latih akan menggunakan metode *6-fold cross validation*, dimana seperenam data pertama digunakan sebagai data latih, sedangkan lima perenam data lainnya digunakan sebagai data uji. Latih dan uji diulang-ulang dengan menggunakan seperenam data kedua, dan seterusnya.


BAB IV HASIL DAN PEMBAHASAN

4.1 Hasil pengumpulan data

Pengambilan data permukaan jalan dilakukan di Jl. Wates, Pengasih, Wates, Kabupaten Kulonprogo, menggunakan kendaraan sepeda motor dengan tiga kecepatan yang berbeda, yaitu 10 km/jam, 20 km/jam dan 30 km/jam. Pengambilan data pada kecepatan motor 10 km/jam menghasilkan video tampak jelas dan detail, pada kecepatan motor 20 km/jam menghasilkan video tampak blur dan pada kecepatan motor 30 km/jam menghasilkan video tampak blur dan bergelombang. Video yang dihasilkan kemudian diolah menjadi 60 citra retak dan 60 citra tidak retak dimana contohnya diperlihatkan pada Gambar 4.1.



(a)



(b)




(c)

Gambar 4.1 Contoh citra retak dan tidak retak hasil pengambilan data pada kecepatan (a) 10 km/jam; (b) 20 km/jam dan (c) 30 km/jam

4.2 Pra-pengolahan

a. Pengecilan ukuran citra


Citra yang diperoleh dari video pengumpulan data memiliki ukuran 1920x1080. Untuk mempercepat proses komputasi dan menjadikan ukuran citra seragam, ukuran citra dirubah menjadi 640x480 sebagaimana diperlihatkan pada Gambar 4.2. Proses pengecilan ukuran ini tidak berpengaruh terhadap informasi citra secara signifikan.



Gambar 4.2 Pengecilan ukuran citra untuk meringankan proses komputasi: Citra retak (a) ukuran 1920x1080 dan (c) ukuran 640x480; Citra tidak retak (b) ukuran 1920x1080 dan (d) ukuran 640x480

b. Konversi ke *grayscale*

Citra yang diperoleh dari hasil video pengambilan data merupakan jenis citra warna RGB. Dalam penelitian ini, informasi warna RGB tidak diperlukan dalam proses ekstraksi ciri untuk membedakan citra retak dan tidak retak. Oleh karena itu, jenis citra warna RGB diubah menjadi jenis citra grayscale. Perubahan jenis citra ke *grayscale* juga bertujuan untuk mempermudah dan mempercepat proses komputasi karena grayscale hanya memiliki satu komponen nilai intensitas. Gambar 4.3 (a) dan (b) adalah contoh hasil konversi citra RGB Gambar 4.2 (c) dan (d). Terlihat tidak ada perbedaan signifikan antara citra RGB dan grayscale karena permukaan jalan cenderung berwarna hitam, putih atau kelabu.



Gambar 4.3 Contoh konversi citra menjadi jenis grayscale (a) citra retak dan (b) citra tidak retak


4.3 Ekstraksi Ciri

Ekstraksi ciri adalah tahapan untuk mengekstrak ciri-ciri untuk membedakan antara citra retak dan tidak retak. Tiga ciri telah diekstrak, yaitu *sum of histogram*, *black white area* dan *sum histogram of oriented gradient*.


4.3.1 Sum of Histogram

Histogram merupakan representasi penyebaran nilai intensitas citra grayscale. Hasil histogram dari citra grayscale Gambar 4.3 diperlihatkan pada Gambar 4.4 (a) untuk citra retak dan (b) untuk citra tidak retak. Keberadaan retak yang berwarna hitam menjadikan histogram lebih dominan berada di sebelah kiri dibanding histogram citra tidak retak. Atas dasar inilah,

ciri sum of histogram dipilih dan dihitung sebagai ciri untuk membedakan citra retak dan tidak retak. Penghitungan sum of histogram dimulai dari histogram bin 0 hingga bin 165 (bertanda garis merah). Citra retak menghasilkan nilai sum of histogram lebih tinggi dibanding citra tidak retak meskipun perbedaannya tidak sangat signifikan, sebagaimana ditunjukkan pada Gambar 4.5.




Gambar 4.4 Histogram citra (a) retak dan (b) tidak retak



Gambar 4.5 Scatter plot histogram citra retak (segitiga merah) dan tidak retak (lingkaran hitam)


4.3.2 Black White Area

Ekstraksi ciri *black white area* (bwarea) diawali dengan segmentasi antara area retak dan area permukaan jalan. Segmentasi dilakukan melalui tiga tahapan, yaitu *thresholding*, *median filter* dan *morphological closing*. *Thresholding* dilakukan untuk merubah gambar *grayscale* menjadi bentuk biner dengan parameter 0.4 dengan skala normalisasi derajat keabuan 0-1. Contoh citra biner hasil *thresholding* citra grayscale diperlihatkan pada Gambar 4.6. Area retak berwarna hitam, sedangkan area permukaan atau bukan retak berwarna putih.




(a) (b)
Gambar 4.6 Citra biner hasil *thresholding* untuk citra (a) retak dan (b) tidak retak

Apabila diperhatikan dengan teliti, Gambar 4.6 (a) dan (b) terlihat masih terdapat titik-titik hitam yang sebenarnya bukan area retak sehingga bisa mengakibatkan kesalahan penghitungan black white area. Untuk mengatasinya, *median filter* diimplementasikan untuk mengurangi titik-titik hitam tersebut dan berhasil menghasilkan citra yang lebih bersih sebagaimana diperlihatkan pada Gambar 4.7. Median filter mampu mengurangi titik-titik hitam karena kemampuannya mengganti titik tengah sekelompok piksel dengan nilai median dari kelompok tersebut.



Gambar 4.7 Citra hasil median filter

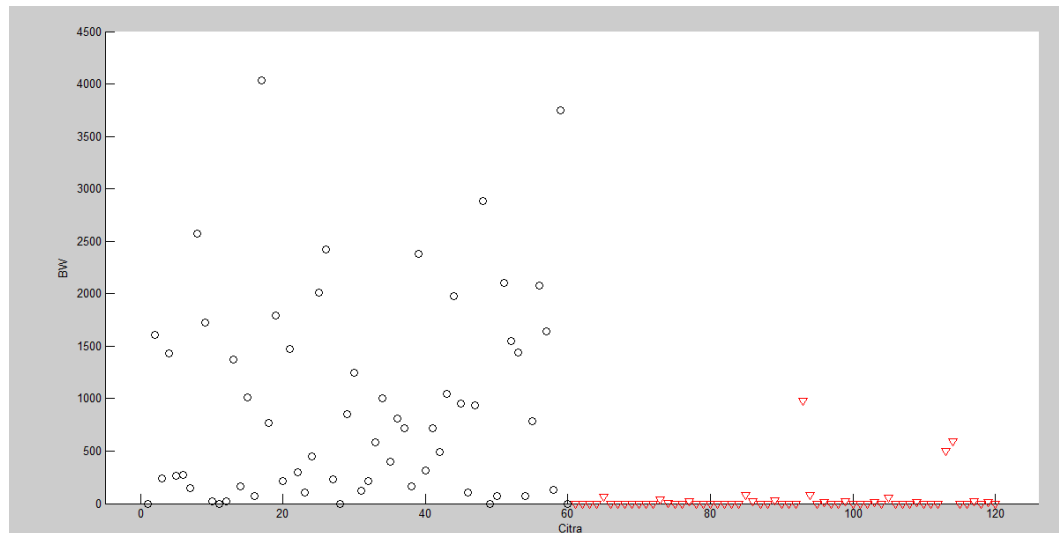
Berdasarkan Gambar 4.7, meskipun hasil median filter sudah cukup bersih, tapi masih dijumpai titik-titik hitam dan garis yang malah terputus. Untuk memperbaikinya, teknik morphological closing diterapkan pada citra. Teknik ini menerapkan proses dilasi dan erosi pada sekelompok piksel sehingga bisa menghilangkan titik-titik yang sendirian atau menyambungkan titik-titik terputus yang berdekatan, sebagaimana diperlihatkan pada Gambar 4.8.



Gambar 4.8 Hasil morphological closing pada (a) citra retak dan (b) citra tidak retak

Setelah area retak berhasil disegmentasi dengan baik, bwarea dihitung dengan menjumlahkan piksel hitam dari setiap citra. Citra retak memiliki bwarea lebih tinggi dibandingkan citra tidak retak, karena citra retak memiliki area hitam sedangkan citra tidak retak hampir keseluruhannya adalah putih. Terlihat pada hasil scatter plot bwarea dari 120 data Gambar 4.9 dimana titik-titik bulat hitam yang mewakili bwarea citra retak memiliki


nilai lebih tinggi daripada titik-titik segitiga merah yang mewakili bwarea citra tidak retak. Gambar ini menunjukkan bahwa nilai bwarea menjadi ciri yang bisa membedakan antara citra retak dan tidak retak, meskipun beberapa citra terlihat tidak memenuhi ciri tersebut.



Gambar 4.9 Hasil scatter plot bwarea. Keterangan: bulat hitam = citra retak; segitiga merah = tidak retak

4.3.3 Sum of Histogram Oriented Gradient

Histogram Oriented Gradient (HOG) merepresentasikan citra retak berdasarkan gradientnya karena citra retak memiliki gradient yang lebih tinggi pada daerah retak. HOG descriptor merupakan kumpulan nilai pada sebuah citra dari perhitungan gradient dan magnitude yang telah dinormalisasi. Visualisasi HOG pada Matlab 7.2 tidak bisa dilakukan sehingga hanya diperoleh kumpulan nilai HOG descriptor yang kemudian dijumlahkan menjadi Sum of HOG sebagaimana diperlihatkan pada Gambar 4.10. Gambar tersebut menunjukkan perbedaan signifikan antara nilai sum of HOG citra retak dan tidak retak.



Gambar 4.10 Hasil scatter plot sum of HOG. Keterangan: bulat hitam = citra retak; segitiga merah = tidak retak

4.4 Klasifikasi dan Validasi

Dalam penelitian ini klasifikasi dan validasi dilakukan secara bersamaan. Klasifikasi menggunakan SVM dan validasi menggunakan metode *6-Fold Cross Validation*. Proses klasifikasi dan validasi terdapat dua tahapan yaitu tahapan latih dan uji. Data yang digunakan dalam penelitian ini 120 citra dari hasil sampling video dengan variasi kecepatan 10 km/jam, 20 km/jam, 30 km/jam dengan masing-masing sebanyak 40 citra yang terdiri dari 20 citra retak dan 20 citra tidak retak. *Kernel trick* yang digunakan dalam SVM adalah *Radial Basis Function*. RBF digunakan karena dapat memetakan data sebagai titik pada dimensi yang lebih tinggi, memiliki sedikit parameter sehingga tuning lebih mudah, serta proses komputasi numerik yang lebih mudah.

Setiap ekstraksi ciri mempunyai properti masing masing terhadap citra retak dan tidak retak. Sum of HOG menjelaskan berapa total besarnya gradient dalam gambar. Nilai bwarea menjelaskan berapa banyak kumpulan piksel yang menunjukkan piksel hitam sebagai retak. Nilai *Sum of Histogram* menunjukkan berapa banyak intensitas piksel dengan batasan skala keabuan tertentu.

Pemilihan model dan parameter sangat penting dalam algoritma SVM. Untuk mengoptimalkannya, dalam penelitian ini parameter yang diperhatikan adalah *Constraint* (C). Parameter ini sangat berpengaruh pada bentuk hyperplane dan kebolehjadian misklasifikasi data. Semakin besar nilai C maka akan lebih sedikit mentolerir misklasifikasi.

4.4.1 Hasil Pengujian Parameter *Constraint*

Empat model masukan SVM digunakan dalam penelitian ini, yaitu hanya menggunakan dua jenis ekstraksi ciri: Sum of HOG & BW Area; Sum of Histogram & Sum of HOG; BW Area & Sum of Histogram, serta yang terakhir adalah menggabungkan tiga ekstraksi ciri Sum of HOG, BW Area, & Sum of Histogram sekaligus. Pada model gabungan tiga ciri, parameter *Constraint* (C) dapat diisi dengan nilai tak terhingga. Dengan nilai ini, hasil latih dan uji tidak didapati misklasifikasi data atau sangat akurat. Sedangkan pada model gabungan dua ciri, nilai maksimum C yang dapat diterapkan adalah 1×10^3 . Nilai-nilai optimal C dalam dilihat dalam Tabel 4.1.

Tabel 4.1 Parameter C optimal pada masing-masing model


Ekstraksi ciri	Sum of Histogram & Sum of HOG	BW Are & Sum of Histogram	BW Area & Sum of HOG	BW Area, Sum of Histogram, & Sum of HOG
<i>Constraint</i>	1×10^3	1×10^3	1×10^3	∞

4.4.2 Hasil klasifikasi dan Validasi


1. Fold 1

Pada *fold* ke-1, data latih adalah citra ke-21 sampai citra ke 120, sedangkan data uji adalah citra ke-1 sampai citra ke-20. Berikut merupakan hasil hyperplane dari proses latih ditunjukkan pada Gambar 4.11 (a) *Sum of Histogram & BW Area* (b) *Sum of HOG & BW Area* (c) *Sum of Histogram & Sum of HOG* (d) *Sum of HOG, BW Area & Sum of Histogram*. Gambar 4.11 (a), (b) dan (c) memperlihatkan bahwa masih terdapat misklasifikasi data pada


model masukan dua ciri sehingga data retak dan tidak retak belum terpisah secara sempurna, sedangkan model masukan tiga ciri Gambar 4.11 (d) dapat memisahkan tanpa adanya misklasifikasi.



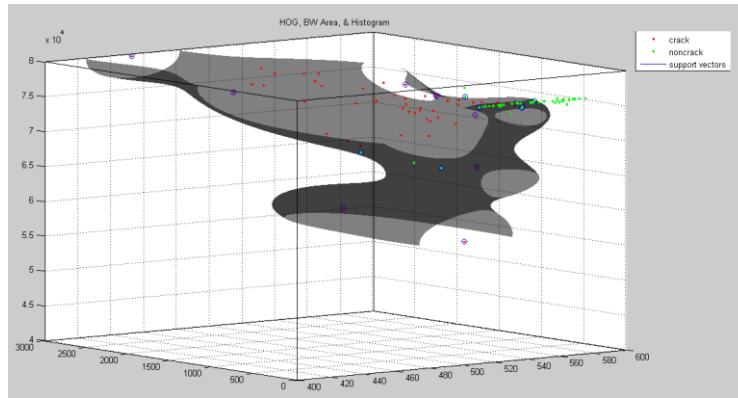
(a)



(b)



(c)



(d)

Gambar 4.11 Hasil hyperplane proses latih Fold-1 dengan model masukan (a) *Sum of Histogram & BW Area*, (b) *Sum of HOG & BW Area*, (c) *Sum of Histogram & Sum of HOG*, (d) *Sum of HOG, BW Area & Sum of Histogram*


Hasil pemodelan latih ini akan digunakan untuk proses uji dimana data yang baru akan dipetakan kedalamnya. Hasil pemetaan data uji ini akan menentukan letak data apakah terdapat pada area retak atau area tidak retak berdasarkan model latih. Hasil uji diperoleh akurasi klasifikasi citra retak dan tidak retak setiap model SVM ditunjukkan pada Tabel 4.2.

Tabel 4.2 Hasil akurasi data uji Fold-1


Ekstraksi Ciri	Sum of Histogram & Sum of HOG	BW Are & Sum of Histogram	BW Area & Sum of HOG	BW Area, Sum of Histogram, & Sum of HOG
Akurasi	70%	80%	90%	90%

2. Fold 2


Pada *fold* ke-2 data latih adalah citra ke-1 sampai citra ke-20 dan citra ke-41 sampai citra ke-120, sedangkan data uji adalah citra ke-21 sampai citra ke-40. Gambar 4.12 berikut merupakan hasil hyperplane dari proses latih, sedangkan Tabel 4.3 adalah hasil akurasi klasifikasi retak dan tidak retak. Terlihat akurasi pada Fold-2 lebih besar disetiap model masukan dibandingkan dengan Fold-1 terdahulu. Bahkan, pada model masukan tiga ciri, akurasi sempurna 100% diperoleh.




(a)



(b)



(c)



(d)


Gambar 4.12 Hasil hyperplane proses latih Fold-2 dengan model masukan (a) *Sum of Histogram & BW Area*, (b) *Sum of HOG & BW Area*, (c) *Sum of Histogram & Sum of HOG*, (d) *Sum of HOG, BW Area & Sum of Histogram*

Tabel 4.3 Hasil akurasi data uji Fold-2


Ekstraksi Ciri	Sum of Histogram & Sum of HOG	BW Are & Sum of Histogram	BW Area & Sum of HOG	BW Area, Sum of Histogram, & Sum of HOG
Akurasi	75%	85%	95%	100%

3. Fold 3

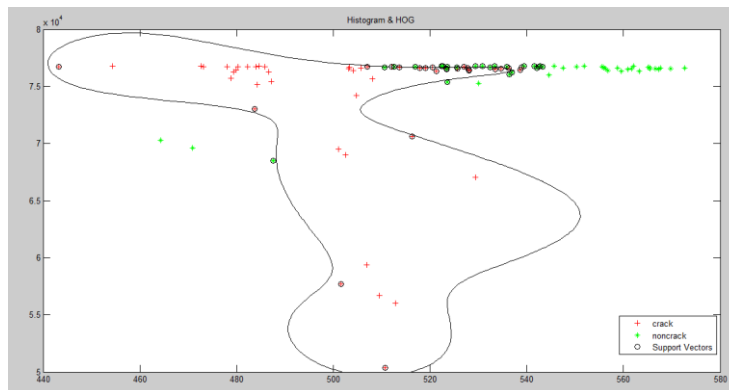
Pada Fold ke-3, data latih adalah citra ke-1 sampai citra ke-40 dan citra ke-61 sampai citra ke-120, sedangkan data uji adalah citra ke-41 sampai citra ke-60. Hasil hyperplane proses latih ditunjukkan pada Gambar 4.13 sedangkan hasil akurasi klasifikasi retak ditunjukkan dalam Tabel 4.4. Model tiga ciri kembali menghasilkan klasifikasi sempurna 100% dan model dua ciri lainnya juga mengalami kenaikan.



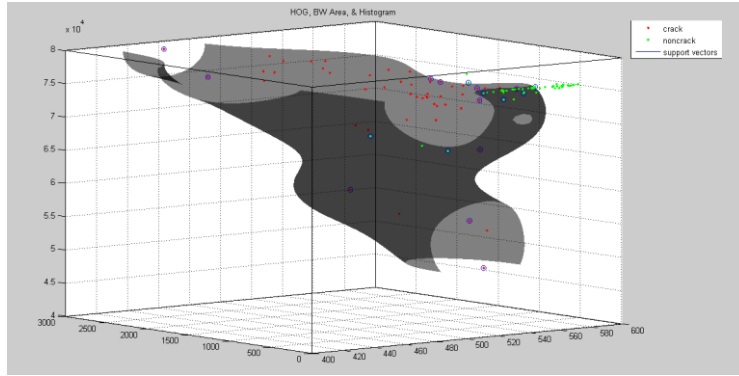
(a)



(b)



(c)



(d)


Gambar 4.13 Hasil hyperplane proses latih Fold-3 dengan model masukan (a) *Sum of Histogram & BW Area*, (b) *Sum of HOG & BW Area*, (c) *Sum of Histogram & Sum of HOG*, (d) *Sum of HOG, BW Area & Sum of Histogram*

Tabel 4.4 Hasil akurasi data uji Fold-3


Ekstraksi Ciri	Sum of Histogram & Sum of HOG	BW Area & Sum of Histogram	BW Area & Sum of HOG	BW Area, Sum of Histogram, & Sum of HOG
Akurasi	90%	95%	90%	100%

4. Fold 4


Pada fold ke-4, data latih adalah citra ke-1 sampai citra ke-60 dan citra ke-81 sampai citra ke-120, sedangkan data uji adalah citra ke-61 sampai citra ke-80. Hasil hyperplane proses latih ditunjukkan pada Gambar 4.14 sedangkan hasil akurasi klasifikasi ditunjukkan dalam Tabel 4.5.




(a)



(b)



(c)



(d)


Gambar 4.14 Hasil hyperplane proses latih Fold-4 dengan model masukan (a) *Sum of Histogram & BW Area*, (b) *Sum of HOG & BW Area*, (c) *Sum of Histogram & Sum of HOG*, (d) *Sum of HOG, BW Area & Sum of Histogram*

Tabel 4.5 Hasil akurasi data uji Fold-4


Ekstraksi Ciri	Sum of Histogram & Sum of HOG	BW Area & Sum of Histogram	BW Area & Sum of HOG	BW Area, Sum of Histogram, & Sum of HOG
Akurasi	95%	80%	95%	85%

5. Fold 5


Pada fold ke-5, data latih adalah citra ke-1 sampai citra ke-80 dan citra ke-101 sampai citra ke-120, sedangkan data uji adalah citra ke-81 sampai citra ke-100. Hyperplane hasil latih diperlihatkan pada Gambar 4.15 dan akurasi klasifikasi ditunjukkan dalam Tabel 4.6.




(a)



(b)



(c)



(d)


Gambar 4.15 Hasil hyperplane proses latih Fold-5 dengan model masukan (a) *Sum of Histogram & BW Area*, (b) *Sum of HOG & BW Area*, (c) *Sum of Histogram & Sum of HOG*, (d) *Sum of HOG, BW Area & Sum of Histogram*

Tabel 4.6 Hasil akurasi data uji Fold-5


Ekstraksi Ciri	Sum of Histogram & Sum of HOG	BW Are & Sum of Histogram	BW Area & Sum of HOG	BW Area, Sum of Histogram, & Sum of HOG
Akurasi	80%	85%	95%	100%

6. Fold 6


Pada fold ke-6, data latih adalah citra ke-1 sampai citra ke-100, sedangkan data uji adalah citra ke-101 sampai citra ke-120. Hyperlane hasil latih ditunjukkan pada Gambar 4.16 dan akurasi klasifikasi diperlihatkan dalam Tabel 4.7.




(a)



(b)



(c)



(d)

Gambar 4.16 Hasil hyperplane proses latih Fold-6 dengan model masukan (a) *Sum of Histogram & BW Area*, (b) *Sum of HOG & BW Area*, (c) *Sum of Histogram & Sum of HOG*, (d) *Sum of HOG, BW Area & Sum of Histogram*

Tabel 4.7 Hasil akurasi data uji Fold-6

Ekstraksi Ciri	Sum of Histogram & Sum of HOG	BW Are & Sum of Histogram	BW Area & Sum of HOG	BW Area, Sum of Histogram, & Sum of HOG
Akurasi	80%	90%	80%	85%

Secara lengkap prosentasi akurasi keseluruhan ditunjukkan pada Tabel 4.8. Masing masing model merupakan kombinasi dari ketiga ekstraksi ciri, yaitu dengan dua ekstraksi ciri menghasilkan tiga model dan dengan sekaligus tiga ekstraksi ciri menghasilkan satu model. Pada tahap uji dari setiap fold, secara umum model dengan tiga ekstraksi ciri sekaligus menghasilkan akurasi yang lebih baik dibandingkan hanya menggunakan dua ekstraksi ciri seperti ditunjukkan pada Tabel 4.8.

Tabel 4.8 Hasil akurasi keseluruhan data uji Fold-1 hingga Fold-6

Ekstraksi CrossVal	SHOG & SHist	BW & SHist	BW & SHOG	SHOG, BW, & SHist
Fold-1	70	80	90	90
Fold-2	75	85	95	100
Fold-3	90	95	90	100
Fold-4	95	80	95	85
Fold-5	80	85	95	100
Fold-6	80	90	80	85
Rerata	81.66667	85.83333	90.83333	91.66667

BAB V KESIMPULAN DAN RENCANA BERIKUTNYA

5.1 Kesimpulan

- a. Penelitian telah mencapai tujuan dimana metode SVM telah berhasil diterapkan sebagai metode baru dalam klasifikasi retak dan tidak retak citra permukaan jalan raya.
- b. Metode telah diuji dengan teknik *6-fold cross validation* dan menghasilkan akurasi rata-rata klasifikasi retak dan tidak retak sebesar 91,67%.
- c. Model masukan SVM gabungan tiga ciri sum of histogram, BW area dan sum of HOG menghasilkan akurasi lebih tinggi dibandingkan gabungan dua ciri yang diekstrak.

5.2 Ketercapaian luaran

No	Luaran	Status
1	Publikasi seminar nasional	Artikel berjudul “Perbaikan Kualitas Citra Permukaan Jalan Raya Menggunakan Metode Pyramida Gaussian” telah disubmit dan proses review dalam Konferensi Nasional Teknologi Informasi dan Aplikasinya (KNTIA), Universitas Sriwijaya, 8 Oktober 2016
2	Publikasi seminar internasional	Artikel berjudul “Detection of Pavement Surface Crack Based on Image Processing using Wavelet Features Extraction Technique” telah disubmit dan proses review dalam International Conference on Soft Computing and Computational Mathematics, Kuala Lumpur, 15-16 Desember 2016
2	Publikasi jurnal internasional (submitted)	Draft sedang disempurnakan.

5.3 Rencana kegiatan berikutnya

- a. Presentasi artikel di Konferensi Nasional Teknologi Informasi dan Aplikasinya (KNTIA), Universitas Sriwijaya, 8 Oktober 2016
- b. Presentasi artikel di dalam International Conference on Soft Computing and Computational Mathematics, Kuala Lumpur, 15-16 Desember 2016
- c. Penyelesaian draft artikel untuk disubmit ke jurnal internasional bereputasi (hingga November 2016)
- d. Penyusunan laporan hasil, laporan akhir dan poster (Desember 2016)

DAFTAR PUSTAKA

- A. Ito, Y. Aoki, and S. Hashimoto, "Accurate extraction and measurement of fine cracks from concrete block surface image," in Proceedings of the Annual Conference of the Industrial Electronics Society, vol. 3, pp. 2202–2207, 2002.
- E. Teomete, V. R. Amin, H. Ceylan, and O. Smadi, "Digital image processing for pavement distress analyses," in Proceedings of the Mid-Continent Transportation Research Symposium, p. 13, 2005.
- Federal Highway Administration – US Department of Transportation. 2003. Distress Identification Manual for Long-Term Pavement Program. Publication No. FHWA-RD-03-031
- H. Elbehery, A. Hefnawy, and M. Elewa, "Surface defects detection for ceramic tiles using image processing and morphological techniques," in Proceedings of the World Academy of Science, Engineering and Technology (PWASET '05), vol. 5, pp. 158–162, 2005.
- Jinjun Zhang, Kuang Liu, Chuntao Luo, Aditi Chattopadhyay, "Crack initiation and fatigue life prediction on aluminum lug joints using statistical volume element-based multiscale modeling", Journal of Intelligent Material Systems and Structures, ISSN 1045-389X, 11/2013, Volume 24, Issue 17, pp. 2097 - 2109
- Liu, S.W; Huang, Jin H; Sung, J.C; Lee, C.C, "Detection of cracks using neural networks and computational mechanics", Computer Methods in Applied Mechanics and Engineering, ISSN 0045-7825, 2002, Volume 191, Issue 25, pp. 2831 – 2845
- M. Coster and J.-L. Chermant, "Image analysis and mathematical morphology for civil engineering materials," Cement and Concrete Composites, vol. 23, no. 2, pp. 133–151, 2001.
- S. Iyer and S. K. Sinha, "A robust approach for automatic detection and segmentation of cracks in underground pipeline images," Image and Vision Computing, vol. 23, no. 10, pp. 921– 933, 2005.
- Saar, T; Saar, T; Talvik, O; Talvik, O, "Automatic Asphalt pavement crack detection and classification using Neural Networks", 12th Biennial Baltic Electronics Conference 2010, pp. 345 – 348
- Sylvie Chambon and Jean-Marc Moliard. 2011. Automatic road pavement assessment with image processing: review and comparison. International Journal of Geophysics Vol. 2011.
- T. S. Nguyen, M. Avila, S. Begot, F. Duculty, and J.-C. Bardet, "Automatic detection and classification of defect on road pavement using anisotropy measure," in Proceedings of the European Signal Processing Conference, pp. 617–621, 2009.

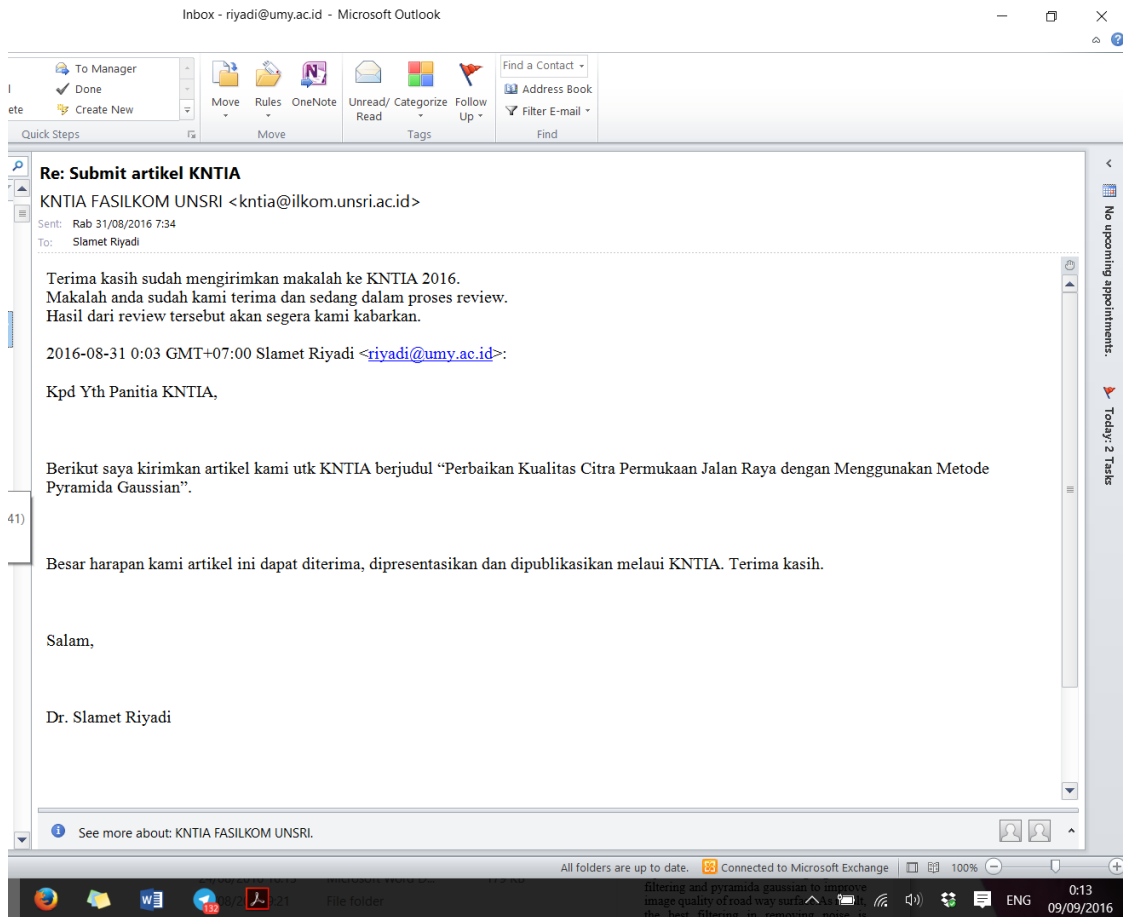
Umesha, P.K; Ravichandran, R; Sivasubramanian, K, 2009, "Crack Detection and Quantification in Beams Using Wavelets", Computer-Aided Civil and Infrastructure Engineering, Volume 24, Issue 8, p. 593

Zalama, Eduardo; Gómez-García-Bermejo, Jaime; Medina, Roberto; Llamas, José, 2013, "Road Crack Detection Using Visual Features Extracted by Gabor Filter", Computer-Aided Civil and Infrastructure Engineering, ISSN 1093-9687, 05/2014, Volume 29, Issue 5, pp. 342 – 3

LAMPIRAN-LAMPIRAN

- a. Bukti submit artikel ke KNTIA 2016 Universitas Sriwijaya, Palembang, dan artikelnya
- b. Bukti submit artikel ke ICSCCM 2016, Kuala Lumpur, dan artikelnya
- c. Draft awal artikel jurnal

a. Bukti submit artikel ke KNTIA 2016 Universitas Sriwijaya, Palembang, dan artikelnya



Perbaikan Kualitas Citra Permukaan Jalan Raya Menggunakan Metode Pyramida Gaussian

Slamet Riyadi¹, Rizqi Yuda Pradana², Cahya Damarjati³

Abstract— Detection of pavement surface crack is very important to ensure users' convenient and safety. Instead of conventional method by visual inspection, the use of image processing technology makes the detection easy and fast. However, the image processing technology yielded low accuracy rate due to the low quality of the surface image. Therefore, the objective of this research is to enhance the quality of image using pyramidal Gaussian method. This method combines two approaches, those are Gaussian low pass filter and pyramidal multi scale approach. The process of image enhancement involved pre-processing task, implementation of pyramidal Gaussian method and several filtering methods for comparison, and filter performance evaluation using some statistical parameters. The result showed that the proposed method performed the best general performance and ability to suppress the noise.

Intisari— Keretakan permukaan jalan raya mengganggu kenyamanan dan mengancam keselamatan pengguna jalan sehingga deteksi retak sangatlah penting. Selain cara konvensional melalui pengamatan visual, deteksi retak dapat dilakukan dengan mudah dan cepat menggunakan metode pengolahan citra digital. Metode pengolahan citra untuk deteksi retak masih kurang akurat disebabkan salahsatunya adalah kualitas citra yang kurang baik. Oleh karena itu, penelitian ini bertujuan untuk memperbaiki kualitas citra permukaan jalan dengan metode *pyramida Gaussian*. Metode ini merupakan gabungan dua pendekatan, yaitu pendekatan filter *low pass* Gaussian dan pendekatan multi skala piramida. Perbaikan citra dilaksanakan melalui tahapan pra-pengolahan citra, penerapan metode *pyramida Gaussian* dan beberapa filter pembanding, serta uji efektivitas filter dengan mengevaluasi parameter *mean square error*, *structural content* dan *peak signal to noise ratio*. Berdasarkan evaluasi parameter-parameter tersebut, metode *pyramida gaussian* memperlihatkan kinerja secara umum yang sangat baik dan juga paling mampu menghilangkan derau.

Kata Kunci— Pengolahan Citra, Deteksi Retak Jalan Raya, Perbaikan Citra, Multi skala piramida, Gaussian, MSE, PSNR

I. PENDAHULUAN

Jalan raya sebagai sarana transportasi darat yang membentuk jaringan transportasi untuk menghubungkan daerah-daerah. Seiring bertambahnya waktu maka jalan raya dapat terjadi suatu kerusakan sehingga mengganggu kenyamanan juga mengancam keselamatan pada pengguna jalan tersebut.

^{1, 3} Dosen, Program Studi Teknik Informatika Fakultas Teknik Universtas Muhammadiyah Yogyakarta Jl. Lingkar Selatan, Kasihan, Bantul Yogyakarta 55183 INDONESIA (email:riyadi@umy.ac.id¹; cahya.damarjati@umy.ac.id³)

² Mahasiswa, Program Studi Teknik Elektro Fakultas Teknik Universtas Muhammadiyah Yogyakarta Jl. Lingkar Selatan, Kasihan, Bantul Yogyakarta 55183 INDONESIA

Penelitian mengenai deteksi retak permukaan jalan raya sudah dilakukan sebelumnya [1] dengan menggunakan metode SVM [2], *Continous Wavelet Transform* [3], Kombinasi Teknik *Thresholding*, *Median Filter* dan *Morphological Closing* [4], dan penggunaan *Artificial Intelligence* [5]. Fakta tersebut menunjukkan bahwa penelitian tentang deteksi retak permukaan jalan raya itu penting.

Kualitas citra yang digunakan untuk deteksi retak permukaan dengan metode tersebut juga harus diperhatikan. Penelitian terkait perbaikan citra juga sudah dilakukan sebelumnya menggunakan *Brightness Preserving* [6], *Quadrants Dynamic Histogram Equalization* [7] [8], *Equal Area Dualistic Sub-Image Histogram Equalization* [9], *Contrast Limited Adaptive Histogram Equalization* [10], *Median Filtering*, *Gaussian Filtering* [11] dan *Pyramida Gaussian* [12].

Tujuan penelitian dalam artikel ini adalah menerapkan filter *pyramida Gaussian* untuk memperbaiki kualitas citra permukaan jalan dan membandingkan kinerja filter tersebut dengan beberapa filter lain, yaitu *contrast limited adaptive histogram equalization* (CLAHE), *histogram equalization* (HE), *median filtering*, dan *gaussian filtering* dalam meningkatkan kualitas citra permukaan jalan raya. Beberapa parameter digunakan untuk mengetahui filter mana yang memiliki kemampuan paling baik dalam memperbaiki kualitas citra.

II. METODOLOGI

Tahapan penelitian yang akan dilaksanakan disajikan di Diagram Alir pada Gbr.1 Urutan prosesnya adalah:

1. Studi Literatur

Studi literatur adalah mempelajari tentang pemrograman menggunakan matlab dan tentang citra digital dari beberapa referensi. Referensi yang digunakan berupa buku, paper, jurnal dan penelitian – penelitian yang berkaitan dengan topik penelitian.

2. Pengambilan Data

Pengambilan data ini dilakukan pada pukul 10.00 WIB dijalan wates kulonprogo, Yogyakarta dengan posisi kamera tegak lurus 90⁰ dengan permukaan jalan dan ketinggian kamera dengan permukaan jalan adalah 1 meter. Data yang diambil terdiri dari beberapa variasi permukaan jalan.

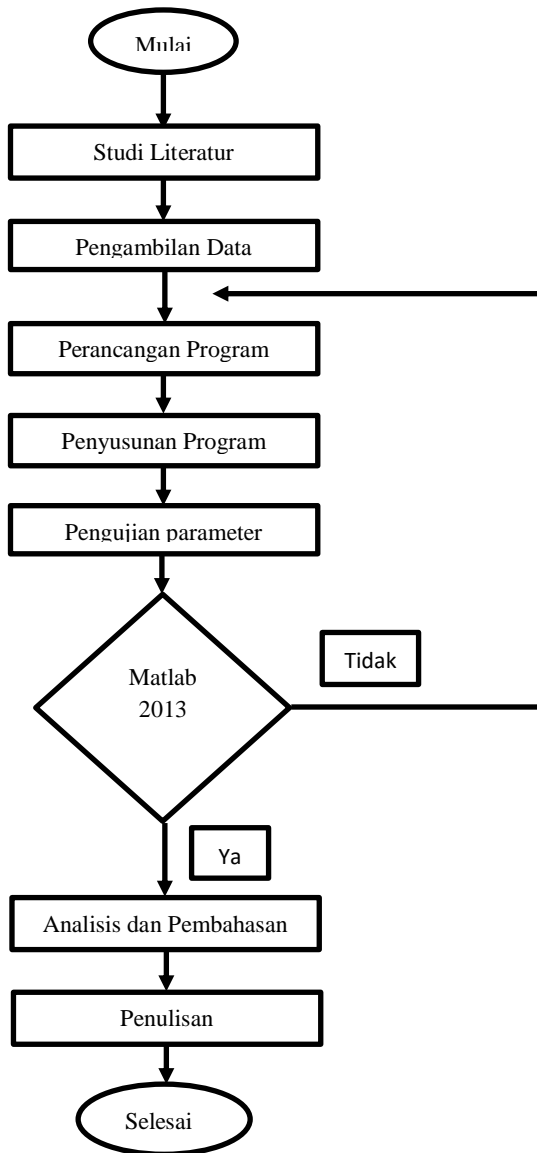
3. Perancangan Program

a. *Imresize*

Fungsi *imresize* adalah mengubah ukuran dimensi citra tanpa mengurangi informasi dari citra tersebut. Pada penelitian ini *imresize* digunakan untuk menyetarakan ukuran citra input.

b. Konversi ke grayscale

Citra diolah menggunakan algoritma grayscale untuk mengubah citra warna menjadi aras keabuan. Konversi ini bertujuan agar proses komputasi piksel menjadi lebih sederhana.



Gbr.1 Diagram alir tahapan penelitian

c. *Histogram Equalization*

Ekualisasi histogram merupakan metode untuk memperbaiki kualitas citra dengan mengubah sebaran tingkat keabuan citra. Hal ini dimaksudkan agar sebaran tingkat keabuan lebih merata dibandingkan dengan citra aslinya. Distribusi ulang terhadap histogram awal dilakukan dengan memetakan setiap nilai piksel pada histogram awal menjadi nilai piksel baru.

d. *Contrast Limited Adaptive Histogram Equalization*

CLAHE dapat digunakan sebagai alternatif pengganti ekualisasi histogram. CLAHE beroperasi pada daerah kecil di citra yang disebut blok. Setiap blok ditingkatkan nilai kontrasnya, sehingga histogram dari wilayah sekitar cocok

untuk histogram tertentu. Setelah melakukan pemerataan, CLAHE menggabungkan blok tetangga menggunakan interpolasi bilinear untuk menghilangkan batas-batas artifisial. CLAHE juga dapat digunakan untuk menghindari derau yang ada pada citra dengan membatasi kontras pada daerah homogen.

e. *Median Filter*

Median filter ini dilakukan dengan cara mencari nilai tengah dari nilai pixel tetangga yang mempengaruhi pixel tengah. Teknik ini bekerja dengan cara mengisi nilai dari setiap pixel dengan nilai median tetangganya. Proses pemilihan median ini diawali dengan terlebih dahulu mengurutkan nilai-nilai pixel tetangga

f. *Filter Gaussian*

Filter ini adalah salah satu filter linier dengan nilai pembobotan untuk setiap anggotanya dipilih berdasarkan bentuk fungsi Gaussian. Filter ini sangat baik untuk menghilangkan derau yang bersifat sebaran normal.

g. *Filter Gaussian*

Filter ini dipilih sebagai filter penghalusan berdasarkan pertimbangan bahwa filter ini mempunyai pusat kernel. Filter Gaussian sangat baik untuk menghilangkan noise yang bersifat sebaran normal, yang banyak di jumpai pada sebaran citra hasil proses digitasi menggunakan kamera karena merupakan fenomena alamiah akibat sifat pantulan cahaya dan kepekaan sensor cahaya pada kamera itu sendiri.

h. *Pyramida Gaussian*

Citra hasil pengambilan gambar menggunakan kamera yang dijadikan input adalah citra yang memiliki banyak derau, hal ini karena citra hasil pengambilan menggunakan kamera banyak dipengaruhi oleh banyak faktor derau antaralain intensitas cahaya. Citra yang mempunyai derau adalah sebuah sinyal digital yang tercampur sinyal - sinyal pengganggu. Filter gaussian adalah metode filter yang merupakan low pass filter yaitu filter yang melewatkan sinyal frekuensi lemah dan membuang frekuensi tinggi.

4. **Pengujian Parameter**


Pengujian kemampuan filter ini melalui parameter *mean square error* (MSE), *peak signal to noise ratio* (PSNR), dan *structural content* (SC).

III. **HASIL DAN PEMBAHASAN**

Total citra yang digunakan dalam penelitian ini adalah 100 citra. Berikut ini adalah proses-proses filtering yang dilakukan


1. ***Histogram Equalization***

Hasil dari citra yang telah melalui proses histogram equalization akan menghasilkan histogram yang lebih baik.



Gbr.2 Citra dan Histogram Sebelum HE

Perbedaan sebelum dan sesudah filtering dengan metode ini dapat dilihat di Gbr. 2 dan Gbr. 3. Sebelum filtering, kontras citra tinggi di rentang 100 sampai 200. Setelah melakukan filtering, kontras citra tinggi di rentang 0 sampai 250.




Gbr.3 Citra dan Histogram hasil dari HE


2. *Contrast Limited Adaptive Histogram Equalization*

Contrast limited adaptive histogram equalization dimana pada proses ini peningkatan kualitas citra dilakukandengan cara meratakan histogram setiap region lokal sehingga kontras citra meningkat.

Perbedaan sebelum dan sesudah proses CLAHE dapat dilihat di Gbr. 4 dan Gbr. 5. Sebelum CLAHE, kontras citra tinggi di rentang 100 sampai 200. Setelah melakukan CLAHE, kontras citra naik dari poin 0 dan memuncak di 150 kemudian menurun sampai titik bawah di bawah di poin 250.



Gbr.4 Citra dan Histogram Sebelum CLAHE




Gbr.5 Citra dan Histogram Hasil dari CLAHE

3. *Median Filter*

Metode filter pada penelitian ini disetiap kernel 3 atau 3x3 piksel di urutkan nilai pikselnya kemudian diambil nilai tengahnya. Sehingga terjadi citra baru yang lebih halus dari citra aslinya karena median filter memiliki kemampuan untuk menghilangkan noise paper n salt noise.

Gbr. 6 menunjukkan perbedaan citra grayscale sebelum sebelum proses *Median Filter* (citra kiri) dengan sesudah proses *Median Filter* (kanan).




Gbr.6 Citra Grayscale Sebelum dan Sesudah *Median Filtering*

4. *Gaussian Filter*

Gaussian Filter merupakan filter yang mampu menghaluskan citra, dan tentu saja dengan perannya sebagai filter maka gaussian bisa digunakan untuk menyaring citra dari derau menapis derau pada citra yang menghasilkan citra baru dengan kualitas lebih halus.

Gbr. 7 menunjukkan perbedaan citra grayscale sebelum sebelum proses proses *Gaussian Filter* (citra kiri) dengan sesudah proses *Gaussian Filter* (kanan), citra hasil Gaussian terlihat agak blur dibandingkan dengan citra aslinya.




Gbr.7 Citra Grayscale Sebelum dan Sesudah *Gaussian Filtering*

5. *Metode Pyramida Gaussian*

Pada penelitian ini digunakan 5 level pyramid, hal ini dikarenakan untuk mencari level berapa yang paling efektif menghasilkan kualitas citra terbaik.

Gbr. 8 menampilkan citra hasil proses filtering menggunakan *Pyramida Gaussian*. Citra paling kiri adalah hasil PG level 1, kemudian kanannya citra hasil PG level 2, dan seterusnya paling kanan adalah citra hasil PG level 5. Disebut piramid karena dari level bawah sampai atas, citra yang dihasilkan semakin kecil. Gambar juga semakin blur karena didalamnya terdapat proses *Gaussian*.




Gbr.8 Citra Hasil Metode *Pyramid Gaussian* Level 1 Sampai 5

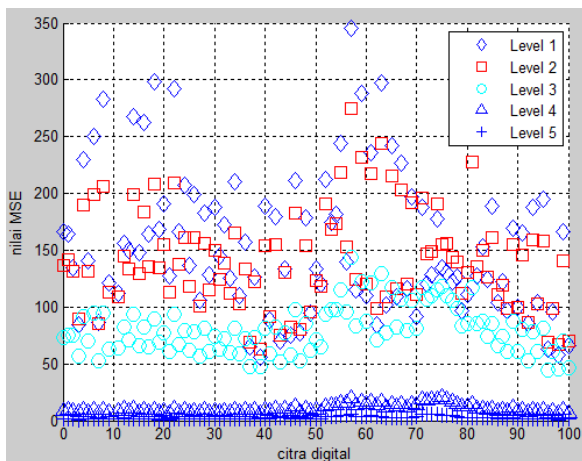
Dari kelima proses filtering yang telah dijelaskan diatas, Pengujian dilakukan dengan parameter berikut ini:

1. Mean Square Error

MSE merupakan perbedaan setiap piksel citra. semakin kecil nilai MSE maka menunjukkan bahwa filter tersebut mampu mengurangi derau paling baik.



Gbr. 9 Parameter MSE untuk CLAHE, HE, *Median Filter* dan *Gaussian Filter*




Gbr. 10 Parameter MSE untuk *Pyramida Gaussian*

Gbr. 9 menunjukkan bahwa nilai MSE paling kecil adalah yang menggunakan *Gaussian Filter*, tepatnya di kisaran 100. Jika menggunakan *Pyramida Gaussian* di Gbr. 10, nilai MSE bisa lebih kecil dari *Gaussian Filter*. *Pyramida Gaussian* level


5 mempunyai nilai paling kecil mendekati 0. Maka filtering terbaik dalam mengurai derau paling baik menggunakan *Pyramida Gaussian*.

2. Structural Content

SC merupakan parameter untuk mengukur tingkat keserupaan antara citra yang telah difilter dengan citra asli. Jika nilai SC mendekati angka 1 maka filter tersebut memiliki kemampuan yang baik dalam mempertahankan informasi citra.



Gbr. 11 Parameter SC untuk CLAHE, HE, *Median Filter* dan *Gaussian Filter*



Gbr. 12 Parameter SC untuk *Pyramida Gaussian*


Gbr. 11 menampilkan hasil pengujian SC yang paling mendekati nilai 1 adalah *Histogram Equalization*. Di Gbr. 12, hasil pengujian untuk *Pyramida Gaussian* terlihat semakin menjauhi nilai 1. Maka, filter yang paling baik dalam mempertahankan informasi citra adalah *Histogram Equalization*.

3. Peak Signal to Noise Ratio


Untuk mengukur kualitas citra secara umum dapat menggunakan parameter PSNR. Semakin tinggi nilai parameter PSNR maka filter tersebut memiliki kemampuan yang baik dalam meningkatkan kualitas citra.

Gbr. 13 menunjukkan bahwa angka paling tinggi adalah yang menggunakan *Gaussian Filter* di angka 18. Gbr. 14 menunjukkan bahwa *Pyramida Gaussian* level 5 menempati nilai paling tinggi di angka 55. Maka, filter yang paling baik

dalam meningkatkan kualitas citra secara umum adalah *Pyramida Gaussian* level 5.



Gbr. 13 Parameter PSNR untuk CLAHE, HE, Median Filter dan Gaussian Filter



Gbr. 14 Parameter PSNR untuk *Pyramida Gaussian*

IV. KESIMPULAN

Berdasarkan uji efektivitas filter dengan menggunakan parameter statistik MSE, SC dan PSNR, metode *Pyramida Gaussian* memperlihatkan kemampuan terbaik dalam peningkatan kualitas citra secara umum dan menghilangkan derau, apabila dibandingkan dengan beberapa filter yang dicoba, yaitu CLAHE, HE, median dan Gaussian.

REFERENSI

- [1] S. Chambon dan J.-M. MarcMoliard, "Automatic Road Pavement Assessment with Image Processing: Review and Comparison," *International Journal of Geophysics*, vol. 2011, 2011.
- [2] A. G. C. S. Marques, Automatic Road Pavement Crack Detection using SVM, Lisboa: Instituto Superior Técnico, 2012.
- [3] P. Subirats, J. Dumoulin, V. Legeay dan D. Barba, "AUTOMATION OF PAVEMENT SURFACE CRACK DETECTION USING THE CONTINUOUS WAVELET

- TRANSFORM," dalam *2006 International Conference on Image Processing*, 2006.
- [4] S. Riyadi, R. A. Azra, R. Syahputra dan T. K. Hariadi, "Deteksi Retak Permukaan Jalan Raya Berbasis Pengolahan Citra dengan Menggunakan Kombinasi Teknik Thresholding, Median Filter dan Morphological Closing," dalam *Simposium Nasional Teknologi Terapan (SNTT) 2014*, 2014.
- [5] H. Rababaah, ASPHALT PAVEMENT CRACK CLASSIFICATION: A COMPARATIVE STUDY OF THREE AI APPROACHES: MULTILAYER PERCEPTRON, GENETIC ALGORITHMS, AND SELF-ORGANIZING MAPS, South Bend, 2005.
- [6] C. H. Ooi dan N. A. M. Isa, "Adaptive Contrast Enhancement Methods with Brightness Preserving," *IEEE Transactions on Consumer Electronics*, vol. 56, no. 4, 2010.
- [7] C. H. Ooi dan N. A. M. Isa, "Quadrants Dynamic Histogram Equalization for Contrast Enhancement," *IEEE Transactions on Consumer Electronics*, vol. 56, no. 4, 2010.
- [8] H. Ibrahim dan N. S. P. Kong, "Brightness Preserving Dynamic Histogram Equalization for Image Contrast Enhancement," *IEEE Transactions on Consumer Electronics*, vol. 53, no. 4, p. 1752, 2007.
- [9] Y. Wang, Q. Chen dan B. Zhang, "IMAGE ENHANCEMENT BASED ON EQUAL AREA DUALISTIC SUB-IMAGE HISTOGRAM EQUALIZATION METHOD," *IEEE Transactions on Consumer Electronics*, vol. 45, no. 1, p. 68, 1999.
- [10] F. K. Pertiwi, D. Saepudin dan A. Rizal, ANALISIS CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION (CLAHE) DAN REGION GROWING DALAM DETEKSI GEJALA KANKER PAYUDARA PADA CITRA MAMMOGRAM, Bandung: Universitas Telkom, 2011.
- [11] B. Yuwono, "IMAGE SMOOTHING MENGGUNAKAN MEAN FILTERING, MEDIAN FILTERING, MODUS FILTERING DAN GAUSSIAN FILTERING," *Telematika*, vol. 7, no. 1, 2010.
- [12] S. Riyadi, A. Sugiarto, S. A. Putra dan N. A. Setiawan, "Analysis of Digital Image Using Pyramidal Gaussian Method to Detect Pavement Crack," *Advanced Science Letters*, vol. 21, no. 11, pp. 3565-3568, 2015.

b. Bukti submit artikel ke ICSCCM 2016, Kuala Lumpur, dan artikelnya

www.icsccm.com/cms/page.php?nextaction=viewsubmissionstatus

Most Visited Empire Getting Started Problem loading page Review Form Response

The 3rd International Conference on Soft Computing and Computational Mathematics (ICSCCM 2016)
15-16 December 2016, Kuala Lumpur, Malaysia

Submission Status

Submission Title	Corresponding Author	Submission Status
Detection of Pavement Surface Crack Based on Image Processing Using Wavelet Features Extraction Technique	Slamet Riyadi	Submitted

General Information

Submission Title:	Detection of Pavement Surface Crack Based on Image Processing Using Wavelet Features Extraction Technique
Author(s)	
Atuhor 1	
First/ Given Name:	Slamet
Last/ Family Name:	Riyadi
Organization:	Department of Information Technology, Faculty of Engineering Universitas Muhammadiyah Yogyakarta Yogyakarta, Indonesia.
Country:	Indonesia
Email:	nyadi@umy.ac.id
Atuhor 2	
First/ Given Name:	Fiddin Yusufida
Last/ Family Name:	Alfa
Organization:	Department of Information Technology, Faculty of Engineering Universitas Muhammadiyah Yogyakarta Yogyakarta, Indonesia.
Country:	Indonesia
Email:	fiddinyusfida@gmail.com

Home
Call for Paper
Paper Submission
Technical Committee
Venue and Travel
Paper Format
Conference Program
Registration
Payment
Invited Speakers
ICSCCM 2015
ICSCCM 2015 PIX
ICSCCM 2013
ICSCCM 2013 PIX
Contact Us

Detection of Pavement Surface Crack Based on Image Processing using Wavelet Features Extraction Technique

Slamet Riyadi¹, Fiddin Yusufida A'la², Chayadi Oktomy³, Kamarul Hawari Ghazali⁴

Department of Information Technology, Faculty of Engineering
Universitas Muhammadiyah Yogyakarta
Yogyakarta, Indonesia.

Affiliation: Faculty of Electrical and Electronics Engineering, University Malaysia Pahang.

¹riyadi@umy.ac.id, ²fiddinyusfida@gmail.com, ³chayadions@ft.umy.ac.id

Abstract Evaluation of road pavement is an important part of maintaining its quality. In a traditional way, human checks the asphalt by walking along the road. This traditional method it is less efficient because it requires substantial costs, takes a long time, exposed to safety issues such as the high intensity of vehicle passing by, the subjective factor, and the fatigue factor. With digital image processing technique, pavement evaluation will be safer for surveyor. Pavement's cracks are captured on a picture and then processed with some algorithm. This paper explains the principle of Discrete Wavelet Transform (DWT). The image is filtered by the low-pass filter and a high-pass filter and decomposed into four sub-bands to perform feature extraction to extract unique features of the picture. These extracted features are then applied to classification method using linear discriminant analysis (LDA), and the accuracy is about 92.8%.

Keywords: crack detection, feature extraction, image processing, discrete wavelet transform.

1. Introduction

The primary infrastructure used to deliver necessities like food and clothes are ground transportation. Therefore, the road becomes an important function not only to connect one place to another but also has a role in the development of a region. Roads material have a certain lifespan and durability. There are many factors affecting road damage. Such as material quality, natural factors, and overload usage. These conditions could disrupt and endanger road users. Accidents often occur because the driver cannot control vehicle while anticipating the damage of the road. According to the Bina Marga Roads Manual No.03/MN/B/1983, the road damage is classified into cracking, distortion, surface effects (disintegration), polish aggregate, bleeding & flushing, and utility planting. This research only focused on the examination to detect a presence of cracks, regardless of the fracturing.

Currently, examination of the road still uses the traditional way of manual observation using sensory vision. This traditional method it is less valuable because it needs substantial costs, takes a long time, exposed to safety issues such as the high intensity of vehicle passing by, the subjective factor, and the fatigue factor [1]. Automated pavement crack detection has undoubtedly improved the

assessment process of road pavement condition [2].

The Federal Highway Administration (FHWA), Road Inventory Program (RIP) for the National Park Service (NPS), collects roadway condition data on asphalt paved surface. The FHWA RIP is implemented based on the premise that an accurate pavement surface condition assessment can be accomplished using automated crack detection technology as applied to digital images [3].

Photogrammetric approach considered to be very effective in the detection of cracks but on other hands, there is a lack in this study because the camera was used has unique specifications at relatively expensive and complicated operation [4]. The cracks are well detected using continuous wavelet transform with more or less noise according to the texture, but there is some noise due to a high texture [5]. Based on the problems discussed above, research is needed to find the new method that can detect cracks with a more affordable, reliable, and simple operation device. The method used to detect the presence of cracks on the road is wavelet feature extraction. Selected features briefly characterise the statistical properties of the proposed features. All the features extracted from the database can be represented in a vector, usually called feature vector [6].

2. Methodology

Figure 1 shows the procedure of detection process for pavement's surface cracks. First to get the images data, we have to make data acquisition. Then the data was resized and converted to grayscale image mode. After that, we processed the image and extracted the feature using statistical properties extraction. **This study used mean and standard deviation values as statistical properties extraction.** Finally, linear discriminant was applied to the images to classify them as "crack" or "non-crack". Discriminant lines make images separated by its class. This result then compared to visual initialization images to get the percentage of accuracy.




Figure 5. CA transformation result
(a) crack images (b) non-crack images.

2.4 Statistical Feature Extraction

Feature extraction is the process that raises the unique characteristics of an object in the form of value that will be used for analysis. Coefficient approximation (CA) is component that represents the original image which has been filtered by using a low-pass filter (LL). Next, coefficient approximation (CA) was processed and computed further using basic statistical properties. The computed statistical properties are; x_1 represents mean computed using equation (1) and x_2 represents standard deviation computed using equation (2).

$$\mu = \frac{1}{N} \sum_{i=1}^N X_1 \quad (1)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}_1)^2} \quad (2)$$

2.5 Linear Classification

Classification method used in this research is Linear Discriminant Analysis (LDA). Linear Discriminant Analysis is a method used in statistics, pattern recognition and machine learning to find a linear combination of the characteristic or separating two or more classes of objects or events. Classification is divided into two classes, namely “crack” and “non-crack”. Having these distinct features, crack detection is made simple and thus there is no need for a complex classifier [9]. This classification method uses two inputs, namely the values of feature extraction results in the previous step. Equation of linear discriminant analysis that we used is as follows

$$Y = K + L(1)*X_1 + L(2)*X_2 \quad (3)$$

In the case of mean-STD feature extraction, it is as shown in Figure 6.




Figure 6. Scatter plot feature extraction (sum-std) and its linear discriminant line

A total of 56 testing images were classified by quality into good, middle, and low. This qualification based on manual perception. Good quality images are images that can be

processed properly and produce a right decision according to manual classification. This good image has to crack that easy to detect because of high contrast between object and background. The sample of good images is shown in Figure 7




Figure 7. Good quality images (a) crack, (b) non-crack

Middle-quality images have cracked that less obvious, so it is difficult to recognise because have almost the same colour between object and background and non-crack images displays a less smooth. The sample of middle-quality images is shown in Figure 8



Figure 8. Middle quality images (a) crack, (b) non-crack

Bad quality images are images that can't be processed properly and produce a false decision according to manual classification. This image isn't clear with the same colour between object and background, so it's difficult recognised. The sample of bad quality images is shown in Figure 9



Figure 9. Bad quality images (a) crack, (b) non-crack

3. Result

In this case, a total 30 images consist of crack and non-crack classes were used for training to determine the discriminant function and another 56 images were used for testing. The images for training (crack and non-crack) were classified and used as a reference for expert visual labelling. Next, the rest of images were classified using the linear discriminant function obtained in training session shown in equation (3).

$$y = -74.5443 + 0.2691 * x_1 + (-0.2699) * x_2 \quad (3)$$

To discriminate the image as crack or non-crack, we implemented the following rules base:

If $y \leq 0$ then image = crack, else
image = non-crack

These images were tested using linear discriminant analysis. The result of tested images is shown in Figure 7.

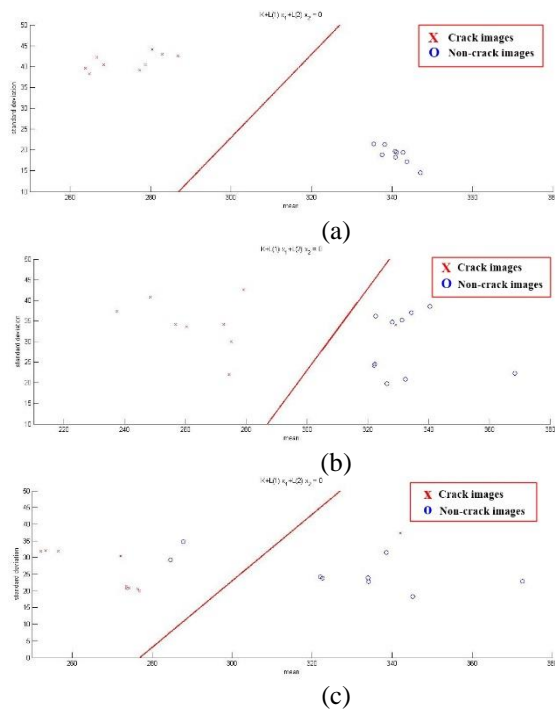


Figure 7. Scatter plot of tested images by quality, (a) good, (b) middle, (c) low

Scatter plot result quality images are shown in Figure 7 with “x” as crack images and “o” as non-crack. From scattering plot result can be observed that both of crack and non-crack images separated by red lines linear equation. It’s mean that testing on good quality images Figure 7(a) scores up to 100% accuracy. Scatter plot of middle-quality images Figure 7(b) can be observed that some images cross the red lines equation, scores up to 94.7% accuracy. Scatter plot of bad quality images Figure 7(c) can be observed that some images cross the red lines. This type crack and non-crack images difficult to distinguish from the background scores up to 94.7% accuracy. The classification results of 56 testing images filtered by quality; good, middle, and low is shown in Table 1.

Table 1. Result of pavement cracks detection

Images Quality	Images		Error	Accuracy
	Crack	Non-crack		
Good	9	9	0	100 %
Middle	9	10	1	94.7 %
Low	10	9	3	84.2 %

4. Conclusion

Based on this study, we can conclude that the use of wavelet transforms and feature extraction to perform pavement surface crack detection based on image processing has successfully extracted features to detect road image. A mean value and standard deviation (STD) value can be used properly to create a pavement surface crack detection. The system developed in this study can detect pavement crack with 92.85% optimal accuracy. Read error occurs due to the lighting intensity, while data acquisition affects the image feature extraction.

5. References

- [1] H. Rababaah, Asphalt Pavement Crack Classification: A Comparative Study of Three AI Approaches: Multilayer Perceptron, genetic Algorithms, and Self-Organizing Maps, India: Department of Computer and Information Sciences, 2005.
- [2] Y. O. Adu-Gyamfi and N. Attah-Okine, "Multi-resolution Information Mining and a Computer Vision Approach to Pavement Condition Distress Analysis," CAIT-UTC-009, 2014.
- [3] F. H. Administration, Pavement Distress Identification Manual, America: National Park Service, 2006-2009.
- [4] T. C. L. ., C. P. M. Mustaffar, "Automated Pavement Imaging Program (APIP) for Pavement Cracks Classification and Quantification – A Photogrammetric Approach," Remote Sensing and Spatial Information Sciences, vol. XXXVII, p. B4, 2008.
- [5] P. Subirats, J. Dumoulin, V. Legeay and D. Barba, "Automation of Pavement Surface Crack Detection Using the Continuous Wavelet Transform," ICIP, Vols. 1-4244-0481-9, p. 3040, 2006.
- [6] A. G. C. S. Marques, Automatic Road Pavement Crack Detection using SVM, Lisbon: Electrical and Computer Engineering, Universidade Tecnica de Lisboa, 2012.
- [7] R. C. Gonzalez and R. E. Woods, Digital Image Processing, New Jersey: Prentice Hall, 2002.
- [8] P. Darma, Citra Digital dan Ekstraksi Fitur, Yogyakarta: Graha Ilmu, 2010.
- [9] S. Riyadi, I. Asnor Juraiza, M. Mohd Marzuki and H. Aini, "Wavelet-Based Feature Extraction Technique for Fruit Shape Classification," in Proceeding of the 5th International Symposium on Mechatronics and its Applications (ISMA08), Amman, Jordan, 2008.

c. Draft awal artikel jurnal

Image-Based Detection of Road Surface Crack using Non-Linear Support Vector Machine Classification Method

Slamet Riyadi¹, Dede M. Muafiq², Etik Irijanti¹

¹Department of Information Technology, ²Department of Electrical Engineering
Faculty of Engineering, Universitas Muhammadiyah Yogyakarta, Indonesia

Abstract

Condition of road surface is regularly monitored to detect the presence of crack. Nowadays, the monitoring was done manually by officer using visual inspection on surface along the road. This conventional method needs extensive labor and time, as well as subjective due to human inspection. This paper presents the development of an image processing technique to detect the presence of road surface crack using non-linear support vector machine (SVM). The methodology involved the collection of road surface images, manual classification between crack and non-crack images by an expert, image pre-processing to enhance the image quality, extraction of features which represent surface cracks and classification between crack and non-crack using SVM technique. Some features such as histogram of image intensity, histogram of oriented gradient and black-white area were extracted and used to be inputs of SVM training and testing. The SVM classification method was tested on 110 images of road surface which consist of 25 crack images and 75 non-crack ones, and produced more than 98% of accuracy. The result showed that the proposed method is able to perform the detection of road surface crack accurately.

Keywords: SVM, non-linear, Cracks, Classification

1. Introduction

Measurement and evaluation for early monitoring of the road pavement damage level has not been done, one of them is the classification of cracked and not cracked. The method commonly used is the traditional method to look directly by eyes and then record or take a photo image manually on some sides of highway were analyzed.

Characteristics of highway image obtained various kinds as there are variations luminance, sharpness, noise, crack weight and median strip causing more difficult to classifying into cracked and not cracked, so we need a reliable method to resolve the issue.

The data collection method in this study using a video camera placed on the motorcycle by a certain distance, over the motorcycle passing highway then the camera will continue to record video condition of the road pavement. Video recordings will be sampled by the frame needed to obtain images in the form of images, then the image is processed to perform feature extraction and then classified using non-linear Support

Vector Machine. Data classification with Support Vector Machine is used because Support Vector Machine can classify data non-linearly and support multiple features that are can be increasing classification accuracy.

2. Feature Extraction

Feature or characteristic is a unique characteristic of an object. Feature divided into two feature "natural" part of the image, such as brightness and edges of objects. While the "artificial" is a feature that was obtained with certain operations on the image, for example, gray level histogram (Gualtieri et al, 1985). So the feature extraction is the process to get the distinctive characteristics that distinguish an object from other objects (Son, 2010).

2.1 BW area

Estimates the area of all of the on pixels in an image by summing the areas of each pixel in the image. The area of an individual pixel is determined by looking at its 2-by-2 neighborhood. There are six different patterns, each representing a different area:

- Patterns with zero on pixels (area = 0)
- Patterns with one on pixel (area = 1/4)
- Patterns with two adjacent on pixels (area = 1/2)
- Patterns with two diagonal on pixels (area = 3/4)
- Patterns with three on pixels (area = 7/8)
- Patterns with all four on pixels (area = 1)

2.2 Histogram

Histogram is a graph that indicates the number of occurrences of each gray level in an image. On a dark image, the histogram of gray levels clustered in the lower part. At a uniform image, the histogram of gray levels clustered in the upper part. On an image with a significant contrast, gray level histogram will spread. (Sianipar, 2013).

2.3 Histogram Oriented Gradient

The essential thought behind the histogram of oriented gradients descriptor is that local object appearance and shape within an image can be described by the distribution of intensity gradients or edge directions. The image is divided into small connected regions called cells, and for the pixels within each cell, a histogram of gradient directions is compiled. The descriptor is then the concatenation of these histograms. For improved accuracy, the local histograms can be contrast-normalized by calculating a measure of the intensity across a larger region of the image, called a block, and then using this value to normalize all cells within the block. This normalization results in better invariance to changes in illumination and shadowing.

3. Support Vector Machine

In machine learning, Support Vector Machine are supervised learning models with associated learning algorithms that analyze data and recognize patterns, used for classification and regression analysis. Given a set of training examples, each marked for belonging to one of two categories, an SVM training algorithm builds a model that assigns new examples into one category or the

other, making it a non-probabilistic binary linear classifier. An SVM model is a representation of the examples as points in space, mapped so that the examples of the separate categories are divided by a clear gap that is as wide as possible. New examples are then mapped into that same space and predicted to belong to a category based on which side of the gap they fall on. Given some training data \mathcal{D} , a set of n points of the form

$$\mathcal{D} = \{(\mathbf{x}_i, y_i) \mid \mathbf{x}_i \in \mathbb{R}^P, y_i \in \{-1, 1\}\}_{i=1}^n$$

here the y_i is either 1 or -1, indicating the class to which the point \mathbf{x}_i belongs. Each \mathbf{x}_i is a P -dimensional real vector. We want to find the maximum-margin hyperplane that divides the points having $y_i = 1$ from those having $y_i = -1$. Any hyperplane can be written as the set of points \mathbf{x} satisfying

$$\mathbf{w} \cdot \mathbf{x} - b = 0, \text{ where } \cdot \text{ denotes the dot product and } \mathbf{w} \text{ the (not necessarily normalized) normal vector to the hyperplane.}$$

The parameter $\frac{b}{\|\mathbf{w}\|}$ determines the offset of the hyperplane from the origin along the normal vector \mathbf{w} .

3.1 Kernel Selection of SVM

Popular kernel functions, RBF is the main kernel function because of following reasons:

1. The RBF kernel nonlinearly maps samples into a higher dimensional space unlike to linear kernel.
2. The RBF kernel has less hyperparameters than the polynomial kernel.
3. The RBF kernel has less numerical difficulties.

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2), \gamma > 0$$




Figure 1 . Non-Linear SVM using kernel

3.2 Model Selection of SVM

Model selection is also an important issue in SVM. Recently, SVM have shown good performance in data classification. Its success depends on the tuning of several parameters which affect the missclassified data. We often call this parameter tuning procedure as the model selection. The basic in SVM is the parameter C or maximum of constraint. In matlab called boxconstrain, in this study using $10(\exp)n$ for find highest boxconstrain include infinite boxconstrain possibility, infinite boxconstrain causing hayperplane to sparate two classes with zero missclassified.

4. Method

Road pavement crack detection using four main stage there are data acquisition, data enhancement, feature extraction, and classification. In classification using Non-Linear Support Vector Machine using Radial Basis Function which training data and testing data with cross multiple feature and k-fold cross validation.

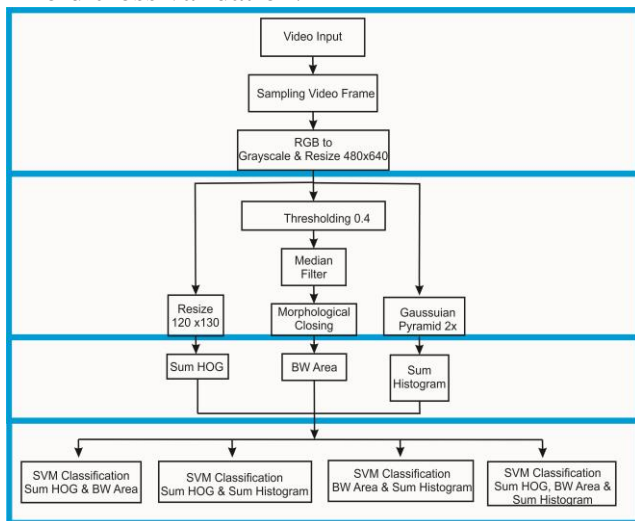


Figure 2 . Method Diagram

5. Result of Experiments

The experiments using three feature extraction. Between three feature have different properties value in extracting crack imag characteristic, those are Sum HOG describe how much total magnitude gradient in image, BW area describe how much pixel indicating as crack, sum Histogram discribe how much total of cetain intensity. The basic parameter in SVM is C, in matlab called

boxconstrain, in this study using $10(\exp)n$ for find highest boxconstrain include infinite boxconstrain possibility. There are four time experiments one way just using two kind of feature extraction there are Sum HOG&BW Area, Sum Histogram & Sum HOG, BW Area&Sum Histogram; another way with directly combine three feature Sum of HOG, BW Area, & Sum of Histogram. When using plotting data shown as figure 3,4, and 5 those are using two feature on training stage there some missclassified data, in other way using directly three feature shown in figure result zero missclassified that shown SVM are robust to against unrelevant feature and adding some feature causing more space to be constructed causing posible to apply infinity boxconstrain then perform hyperplane wich sparate data clearly with zero missclassified that means if training data and testing data are similarity accuracy will be 100%, but in real training and testing data not usally same but close. In this study using k-fold cross validation to validation system shown as figure 6, in table 1 shown using three feature directly get more accuracy rather than just using two feature.




Figure 3 . BW Area & Histogram Feature




Figure 4 . BW Area & HOG Feature




Figure 5 . HOG & Histogram Feature




Figure 6 . HOG, BW Area, & Histogram Feature

Test 3	70	100	95	100
Test 4	70	100	95	100
Test 5	70	95	95	100
Test 6	70	85	85	85
Average	70	93.333 33	92.5	95.833 33333

6. Conclusion

In this paper, shown that classification with non-linear SVM using RBF kernel and apply three feature Sum of HOG, BW Area, & Sum of Histogram possible to apply infinity C to perform zero missclassified in training data and then in testing stage adding with more accuracy.

References

Pratt, William K., *Digital Image Processing*, New York, John Wiley & Sons, Inc., 1991, p. 634.

Cristianini, Nello; and Shawe-Taylor, John; *An Introduction to Support Vector Machines and other kernel-based learning methods*, Cambridge University Press, 2000. [ISBN 0-521-78019-5 \(\[1\] SVM Book\)](#)

Kecman, Vojislav; *Learning and Soft Computing — Support Vector Machines, Neural Networks, Fuzzy Logic Systems*, The MIT Press, Cambridge, MA, 2001.

Schölkopf, Bernhard; Burges, Christopher J. C.; and Smola, Alexander J. (editors); *Advances in Kernel Methods: Support Vector Learning*, MIT Press, Cambridge, MA, 1999. [ISBN 0-262-19416-3](#).

Steinwart, Ingo; and Christmann, Andreas; *Support Vector Machines*, Springer-Verlag, New York, 2008. [ISBN 978-0-387-77241-7 \(\[6\] SVM Book\)](#)

Catanzaro, Bryan; Sundaram, Narayanan; and Keutzer, Kurt; *Fast Support Vector Machine Training and Classification on Graphics Processors*, in *International Conference on Machine Learning*, 2008.

Campbell, Colin; and Ying, Yiming; *Learning with Support Vector Machines*, 2011, Morgan and Claypool. [ISBN 978-1-60845-616-1](#).

Table 1. 2-Fold Cross Validation

Feature \ CrossVal	SHOG & SHist	BW & Hist	BW & SHOG	SHOG, BW, & SHist
Test 1	83.333 3	86.666 7	85	90
Test 2	75	90	88.333 3	93.333 3
Average	79.166 65	88.333 35	86.666 65	91.666 65

Table 2. 4-Fold Cross Validation

Feature \ CrossVal	SHOG & SHist	BW & SHist	BW & SHOG	SHOG, BW, & SHist
Test 1	76.666 7	93.333 3	86.6667	86.666 7
Test 2	70	93.333 3	93.3333	100
Test 3	70	86.666 7	96.6667	90
Test 4	63.333 3	86.666 7	90	90
Average	70	90	91.6666 8	91.666 675

Table 3. 6-Fold Cross Validation

Feature \ CrossVal	SHOG & SHist	BW & SHist	BW & SHOG	SHOG, BW, & SHist
Test 1	70	95	90	90
Test 2	70	85	95	100

