

Identifikasi Kerusakan Jaringan Histologi Pada Ginjal Dengan Fitur Tekstur Menggunakan Model Fitur *Gray Level Cooccurrence Matrix (GLCM)*

Zainul Arifin*, Izzati Muhimmah**, Ika Firdianingsih***

*Magister Teknik Informatika, Universitas Islam Indonesia

**Teknik Informatika, Universitas Islam Indonesia

***Kedokteran, Universitas Islam Indonesia

*zainul.arifin@unmuhjember.ac.id, **a.n.dirgahayu@gmail.com, *** ikafidy@yahoo.com

ABSTRACT

Congestion is one type of damage that occurs in the histology of the kidney tissue, where there is excessive blood within the blood vessels of a particular area. In this research, we will design a system to detect congestion in the histology network of the kidneys using texture feature approach with gray level cooccurrence matrix (GLCM) method, as well as using vector machine support method (SVM). The subject of data used is histology image of mouse kidney tissue using H & E staining obtained at medical faculty of Islamic university of indonesia. image data used as many as 50 congestion training images and 50 normal training images with the size 256 x 256 pixels. while the test image uses an average size of 3000 x 3000 pixels. the results of the experiments performed with cluster parameters $k = 2$ to $k = 5$ show good results, with an average class accuracy rate of 80%, and the accuracy of the segment is 96%.

Keyword: *Gray level cooccurrence matrix, SVM classification, Histologi Kidney, Congestion*

1. Pendahuluan

Ginjal merupakan salah satu organ tubuh yang sangat penting bagi manusia karena organ ini bekerja sebagai alat ekskresi utama untuk zat-zat yang tidak dibutuhkan oleh tubuh lagi. Dalam melaksanakan fungsi ekskresi, ginjal mendapat tugas yang berat mengingat hampir 25% dari seluruh aliran darah mengalir ke ginjal. Besarnya aliran darah yang menuju ginjal menyebabkan keterpaparan ginjal terhadap bahan/zat-zat yang beredar dalam sirkulasi cukup tinggi. Akibatnya, bahan-bahan yang bersifat toksik akan mudah menyebabkan kerusakan jaringan ginjal dalam bentuk perubahan struktur dan fungsi ginjal. Keadaan inilah yang disebut sebagai *nefropati* toksik dan dapat mengenai glomerulus, tubulus, jaringan vaskuler, maupun jaringan *interstitial* ginjal (Alatas *et al.*, 2002).

Glomerulus dan tubulus adalah bagian dari ginjal yang mudah mengalami kelainan sehingga akan berdampak secara morfologis dan fungsional jika terjadi kerusakan. Kerusakan dapat berupa nekrosis, proliferasi sel, infiltrasi sel radang, lolosnya protein, dan makromolekul lain dalam jumlah yang besar, serta dapat terjadi atrofi, fibrosis, edema, vakuolisasi tubulus, kongesti, dan pendarahan (Adinata dkk., 2012; Anggraini, 2008; Suyanti, 2008).

Kongestif biasa disebut juga hyperemia yaitu keadaan dimana terdapat darah secara berlebihan di dalam pembuluh darah pada daerah tertentu. Atau juga biasa dikatakan adanya peningkatan volume darah pada jaringan atau bagian tubuh yang mengalami proses patologik, jika dilihat secara kasar, maka daerah jaringan atau organ yang mengalami kongestif akan tampak kelihatan merah tua (Ungu) karena bertambahnya darah pada jaringan tersebut, Ketika sebuah jaringan meningkatkan aktivitas ada penurunan baik ditandai dalam tekanan parsial oksigen dan pH, peningkatan tekanan parsial karbon dioksida, dan peningkatan suhu dan konsentrasi ion kalium.

Analisa tekstur merupakan topik yang sedang hangat dibahas dalam penelitian dibidang visi computer dan citra digital. Didalamnya terdapat 4 masalah yang fundamental, yaitu klasifikasi citra berdasarkan konten tekstur; segmentasi citra kedalam region-region texture yang homogen, tekstur sintesis untuk aplikasi grafik; dan menentukan suatu bentuk didalam sebuah tekstur (Jain, A.K, dkk, 1993). Pada awalnya klasifikasi tekstur menggunakan fitur statistic untuk ekstraksi cirinya, seperti *Level Co-occurrence matrices (GLCM)*, hidden markov model, dan Gaussian markov random field, gabor fitur, kemudian ekstraksi ciri menggunakan pendekatan fourier (FFT), serta ekstraksi ciri dengan pendekatan textons (varma, M., Zisserman, A 2009).

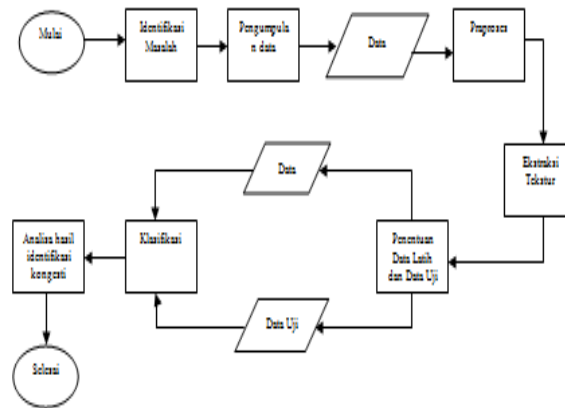
(Goudas, T dkk. 2012) mengusulkan pengklasifikasian kerusakan histologi jaringan ginjal dengan pendekatan fitur *Gray Level Co-occurrence matrices (GLCM)* dan untuk proses klasifikasi menggunakan membandingkan metode Support Vector Machine (SVM), Knn, Decision trees, Naïve Bayes, dimana citra yang dipakai 60 data gambar histologi ginjal biopsies. Terdiri dari 30 normal dan 30 ubnormal, dari hasil keempat klasifikasi diatas, akurasi yang paling baik adalah metode SVM dengan tingkat akurasi 94.701.

Penerapan *gray level cooccurrence matrix (GLCM)* untuk ekstraksi fitur pada proses klasifikasi kerusakan jaringan ginjal (Geodas, T dkk., 2012) menjadi ide dasar dalam penelitian ini. Bagaimana membandingkan metode ekstraksi fitur dengan model GLCM. Yang menjadi fokus pada penelitian ini adalah pengambilan ekstraksi cirinya (*feature extraction*) dari hasil GLCM untuk di proses ke metode SVM classifier.

2. Metode Penelitian

2.1. Kerangka Konsep

kerangka konsep penelitian ini dijelaskan pada gambar dibawah ini.



Gambar 1. Kerangka Konsep penelitian


2.2. Pengumpulan Data

Obyek penelitian ini adalah citra histologi ginjal tikus yang didapat dari fakultas kedokteran universitas islam indonesia. Data penelitian diambil sebanyak 10 citra preparat yang terkena kongesti dan masing - masing mempunyai ukuran 3000 x 3000 piksel, dimana dari 10 preparat tersebut diambil 4 citra preparat untuk dijadikan citra training dan di *crop* menjadi 256 x 256 piksel sebanyak 50 citra training.

2.3. Penyajian Data

Proses ini adalah tahap pengolahan citra histologi jaringan ginjal sehingga terbentuk segmen-segmen warna sebelum di lakukan proses fitur ekstraksi, atau lebih dikenal dengan proses *preprocessing*.

Tahapan preprocessing pada ekstraksi ciri GLCM adalah citra H&E (RGB) yang terdiri dari area kongesti dan area normal berukuran 256x256 piksel dikonversi kedalam bentuk citra Lab terlebih dahulu kemudian dari citra Lab dijadikan citra grayscale karena metode glcm bekerja pada domain grayscale. Setelah proses grayscale citra kemudian di cluster atau di kelompokkan menjadi 2 kelompok kelas, karena dalam penelitian ini hanya dibutuhkan 2 kelas yaitu kelas kongesti dan kelas normal, adapun metode untuk proses clustering penulis menggunakan metode K-Mean. adapun contoh preprocessing ini bisa dilihat prosesnya masing-masing pada gambar 1



Gambar 2 Proses pembentukan segmen kongesti dan segmen normal

Untuk detail masing - masing proses pada gambar 2 dijelaskan dibawah ini :

a) Konfersi citra format RGB kedalam citra L^*a^*b dengan rumus :

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.4125 & 0.3576 & 0.1804 \\ 0.2127 & 0.7152 & 0.0722 \\ 0.0913 & 0.1192 & 0.9502 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{1}$$

$$L^* = 116 f \left[\frac{Y}{Y_n} \right] - 16 \tag{2}$$

$$a^* = 500 \left[f \left(\frac{X}{X_n} \right) - f \left(\frac{Y}{Y_n} \right) \right] \tag{3}$$

$$b^* = 200 \left[f \left(\frac{Y}{Y_n} \right) - f \left(\frac{Z}{Z_n} \right) \right] \tag{4}$$

Proses ini bertujuan untuk dekomposisi warna jaringan histologi lebih jelas sehingga untuk proses segmentasi akan lebih jelas, dan sering digunakan untuk citra histologi H&E.

b) Segmentasi citra L^*a^*b menggunakan metode K-Mean. Adapun proses algoritma kmean (Hartigan dkk, 1979) adalah sebagai berikut :

- Tentukan jumlah *cluster*
- a. Inisialisai k sebagai pusat *cluster* (beri nilai-nilai random)
 - b. Alokasikan setiap data atau obyek ke *cluster* terdekat. Kedekatan dua obyek ditentukan berdasarkan jarak antar kedua obyek tersebut. Jarak paling dekat antara satu data dengan satu *cluster* tertentu akan menentukan suatu data masuk ke dalam *cluster* yang mana.
 - c. Hitung kembali pusat *cluster* dengan anggota *cluster* yang sekarang. Pusat *cluster* adalah rata-rata semua data atau obyek dalam *cluster*.
 - d. Tugaskan lagi setiap obyek memakai pusat *cluster* yang baru. Jika pusat *cluster* sudah tidak berubah lagi, maka proses peng-*cluster*-an selesai.
 - e. Kembali ke langkah 3 sampai pusat *cluster* tidak berubah lagi

Untuk menghitung jarak dari pusat cluster ke tiap titik anggota cluster menggunakan rumus jarak euclidian distance :

$$D_{ij} = \sqrt{\sum_{k=1}^p \{x_{ik} - x_{jk}\}^2} \tag{5}$$

dimana,

- d_{ij} = jarak obyek i dan obyek j
- p = dimensi data
- x_{ik} = koordinat dari obyek i pada dimensi k
- x_{jk} = koordinat dari obyek j pada dimensi k

Proses kmean ini bertujuan untuk mencari area cluster kongesti dan normal (selain kongesti dianggap area normal). sehingga akan terbentuk segmen-segmen berdasarkan kedekatan warnanya.

c) Konfersi citra hasil *cluster* ke dalam citra *grayscale*

Proses konfersi citra color kedalam citra grayscale menggunakan rumus sebagai berikut :


$$Gray = \frac{R + G + B}{3} \tag{6}$$

Proses ini bertujuan untuk menghitung fitur statistik glcm pada masing-masing segmen, karena *glcm* adalah domain gray level.


2.4. Ekstraksi Fitur Tekstur

Ekstraksi ciri merupakan langkah awal dalam melakukan klasifikasi dan interpretasi citra. Proses ini berkaitan dengan kuantisasi karakteristik citra ke dalam sekelompok nilai ciri yang sesuai. Dalam penelitian ini ekstraksi fitur yang digunakan adalah metode *gray level coocurrence matrix (GLCM)*.

GLCM adalah suatu matriks yang elemen-elemennya merupakan jumlah pasangan piksel yang memiliki tingkat kecerahan tertentu, di mana pasangan piksel itu terpisah dengan jarak d , dan dengan suatu sudut inklinsi θ . Dengan kata lain, matriks kookurensi adalah probabilitas munculnya gray level i dan j dari dua piksel yang terpisah pada jarak d dan sudut θ



Gambar 3. Hubungan antar piksel sebagai fungsi orientasi jarak spasial



Gambar 4. Membentuk matriks pasangan

Suatu piksel yang bertetangga yang memiliki jarak d diantara keduanya, dapat terletak di delapan arah yang berlainan, hal ini ditunjukkan pada Gambar 4.5. Sedangkan Gambar 2.6 menggambarkan bagaimana untuk menghasilkan matriks menggunakan arah 0 dan dengan jarak 1 piksel.

Setelah memperoleh matriks kookurensi tersebut, kita dapat menghitung ciri statistik orde dua yang merepresentasikan citra yang diamati. (Haralick et al) mengusulkan berbagai jenis ciri tekstural yang dapat diekstraksi dari matriks kookurensi. jika diberikan G adalah citra gray level, μ adalah nilai rata-rata dari probabilitas P . serta $\mu_x, \mu_y, \sigma_x, \sigma_y$, adalah mean dan standart deviation dari probabilitas P_x, P_y . $P_x(i)$ adalah nilai matriks ke- i dari marginal probability matriks yang dihasilkan dari jumlah baris dari $P(i, j)$

Maka untuk menghitung masing-masing fitur statistik $glcm$ (Haralick dkk. 1973) dari definisi diatas adalah sbb :

$$Correlation = \frac{\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{x X y\} X P(i, j) - \{\mu_x X \mu_y\}}{\sigma_x X \sigma_y} \tag{7}$$

$$SHD = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{i + j - \mu_x - \mu_y\}^2 X P(i, j) \tag{8}$$

$$Entropy = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i, j) X \log(P(i, j)) \tag{9}$$

$$Homogeneity = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i, j) X \log(P(i, j)) \tag{10}$$

$$Difference Entropy = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i, j) X \log(P(i, j)) \tag{11}$$

$$ASM = \sum_i \sum_j \{P(i, j)\}^2 \tag{12}$$

$$IDM = \sum_i \sum_j \frac{1}{1+(i-j)^2} P(i, j) \tag{13}$$

Untuk menghitung fitur statistik GLCM pada penelitian ini menggunakan 6 fitur statistik dari masing-masing segmen hasil dari proses cluster kmean yang sudah di konfersi ke citra grayscale. Fitur yang digunakan adalah fitur *correlation, cluster shade, contrast, entropy, homogeneity, energy*

Dari masing-masing pengukuran nilai statistik diatas akan menghasilkan satu nilai untuk tiap segmen atau cluster. Jadi nilai inilah yang nantinya dijadikan parameter untuk pembandingan pada tiap kelas yang ada pada

proses klasifikasi svm. apakah citra tersebut masuk kedalam kelas kongesti ataukah masuk kedalam kelas normal.

2.5. Svm Non Linier

Dalam masalah klasifikasi kebanyakan sampel data tidak terpisah secara linier sehingga jika digunakan SVM linier maka hasil yang diperoleh tidak optimal dan mengakibatkan hasil klasifikasi yang buruk. SVM linier dapat diubah menjadi SVM non-linier dengan menggunakan metode kernel. Metode ini bekerja dengan cara memetakan data input ke ruang *feature* yang dimensinya lebih tinggi. Diharapkan data input hasil pemetaan ke ruang *feature* akan terpisah secara linier sehingga dapat dicari *hyperplane* yang optimal.

Fungsi kernel yang sering digunakan adalah sebagai berikut :

kernel linier : $K(u, v) = uv^T$.

kernel polinomial: $K(u, v) = (1 + uv^T)^d, d \geq 2$.

kernel RBF (Radial Basis Function): $K(u, v) = \exp(-\gamma \|u - v\|^2), \gamma > 0$.

KernelGaussian: $K(u, v) = \exp\left(-\frac{\|u - v\|^2}{2\sigma^2}\right), \sigma \in \mathbb{R}$

2.6. Evaluasi Sistem

Evaluasi didalam prediksi adalah untuk mengukur efektifitas metode yang dipakai dalam menghitung prediksi. Adapun metode yang dipakai dalam penelitian ini menggunakan perhitungan tingkat akurasi. Untuk menghitung tingkat akurasi menggunakan formula sebagai berikut :

$$Akurasi\ kelas = \frac{\sum piksel\ benar}{\sum piksel} \times 100\%$$

dimana :

$\sum piksel\ benar$ = Jumlah piksel yang benar dalam melakukan klasifikasi
 $\sum piksel$ = Total jumlah piksel

$$Akurasi\ segmen = \frac{\sum segmen\ benar}{\sum segmen} \times 100\%$$

dimana :

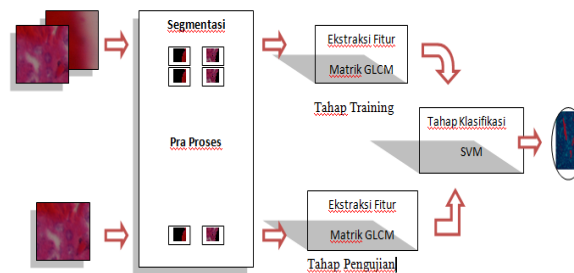
$\sum segmen\ benar$ = Jumlah segmen yang benar dalam melakukan klasifikasi
 $\sum segmen$ = Total jumlah segmen

3. Hasil Dan Pembahasan

3.1. Tahapan Ekstraksi Ciri Gray Level Cooccurrence Matriks (GLCM)

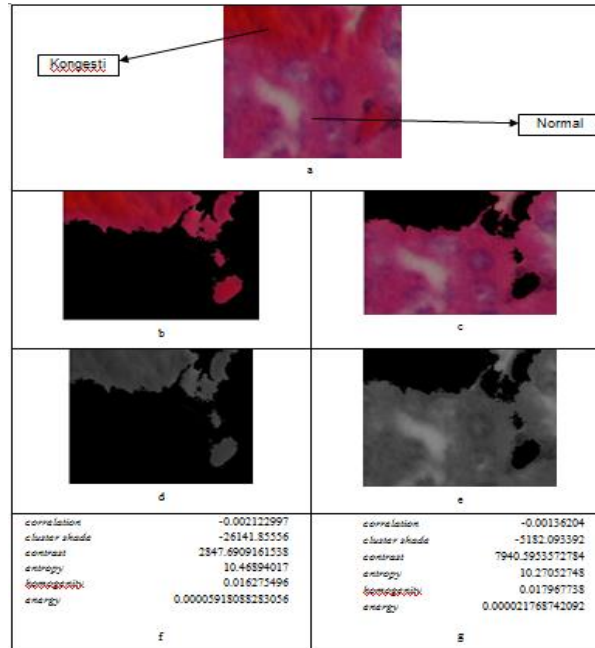
Ekstraksi ciri adalah mengambil fitur statistik pada masing-masing segmen hasil grayscale dari proses cluster kmean, hasil proses metode kmean akan terbentuk matriks indeks (Nx1) dengan baris matriks sebanyak N dan kolom matriks 1.

Untuk menghitung fitur GLCM dari sebuah citra, data matriks yang diproses harus berbentuk matriks *square* atau matiks (NxM), dimana N adalah baris pada matriks, dan M adalah kolom matriks. sehingga matriks awal yang berukuran (Nx1) harus di rubah kedalam matriks (NxM) tanpa merubah nilai piksel yang ada pada matriks. setelah sudah terbentuk matriks (NxM) maka bisa dihitung nilai fitur statistiknya untuk masing-masing segmen. alur proses secara umum klasifikasi menggunakan fitur glcm adalah sebagai berikut :



Gambar 5. Alur proses klasifikasi menggunakan fitur *glcm*

Tabel 1 Hasil perhitungan nilai statistik.a) citra normal, b) citra segmen kongesti c) citra segmen normal,d) dan e) adalah citra grayscale dari kongesti dan normal, f) nilai fitur statistik pada segmen kongesti. g) nilai fitur statistik pada segmen normal



Dari tabel diatas terlihat masing-masing nilai fitur statistik baik itu dari segment kongesti dan segmen normal. nilai fitur tersebut yang akan dipakai untuk proses klasifikasi menggunakan svm *classifier*.

3.2. Tahapan Training

Untuk proses identifikasi citra jaringan histologi ginjal yang tedapat area kongesti langkah pertama adalah proses training data citra sebagai basis data pengetahuan. pada proses ini data training sekaligus di klasifikasikan ke dalam dua kelas label, pertama adalah kelas kongesti (kelas 1) dan yang kedua adalah kelas normal (kelas 0).

Dari ujicoba yang sudah dilakukan, penulis menggunakan data citra training sebanyak 50 citra, dengan masing-masing mempunyai ukuran 256x256 piksel, dimana tiap citra train harus terdapat 2 unsur area kongesti dan area normal. untuk mengetahui hasil dari data training yang sudah dilakukan 6 ekstraksi fitur GLCM, berikut akan ditunjukkan hasil training kongesti dan normal pada tabel dibawah :

Tabel 2 Tabel fitur GLCM kelas kongesti

No	correlation	cluster shade	contrast	entropy	homogenity	energy	Kelas
1	-0.002043218	-5291.426291	2847.690916	9.742817	0.023507174	5.92E-05	1
2	9.52E-06	-210.1850657	1519.952443	9.102497	0.03215904	0.000111968	1
3	-0.00416775	-2066.186825	1533.351176	9.12324	0.030966203	0.000110716	1
4	-0.000633735	532.6889399	4006.237346	10.07282	0.019462389	4.28E-05	1
5	-0.001153471	24400.62607	7292.091895	10.64901	0.014658673	2.48E-05	1
6	0.001945348	8127.435056	4951.208224	10.30148	0.017908874	3.41E-05	1
7	0.000229954	-3.879372924	4734.095616	10.21926	0.018139403	3.71E-05	1
8	0.001220585	-12490.59647	7165.754929	10.6278	0.015682629	2.51E-05	1
9	-0.003452701	-2140.977424	7038.272655	10.63816	0.015042144	2.44E-05	1
10	-9.92E-05	-9764.03615	9176.281631	10.88701	0.013326879	1.90E-05	1
11	0.005182101	-13325.46339	8728.989068	10.84452	0.013603667	1.98E-05	1
12	-8.32E-05	-4225.13667	6713.307483	10.59176	0.015504489	2.52E-05	1
13	0.002181769	-15854.02154	7792.742806	10.72478	0.014597305	2.22E-05	1
14	-4.69E-06	-22024.2492	5378.546276	10.39423	0.017048367	3.14E-05	1
15	-0.003499403	-11086.7332	4229.543178	10.15157	0.019094507	3.94E-05	1
16	-0.00136204	-5182.093392	4701.016063	10.27053	0.017967738	3.50E-05	1
17	-1.13E-03	-8717.574399	2540.134545	9.599764	0.024716825	6.92E-05	1
18	-0.000273992	6338.498857	9425.367418	10.93384	0.012976279	1.79E-05	1
19	0.000906097	-8902.844825	7057.250914	10.63676	0.015124545	2.42E-05	1
20	0.000607654	10550.28074	8715.978561	10.85369	0.013642174	1.94E-05	1

Tabel 3 Tabel fitur GLCM kelas normal

No	correlation	cluster shade	contrast	entropy	homogenity	energy	Kelas
1	0.001385581	20711.78203	7940.595357	10.75745	0.014042137	2.18E-05	0
2	3.94E-04	-28098.31999	9253.505252	10.91861	0.012990563	1.85E-05	0
3	0.008975786	17657.2548	9141.575127	10.91018	0.013337559	1.86E-05	0
4	0.01903445	-26716.95872	6656.221418	10.58163	0.015594009	2.65E-05	0
5	0.000801863	162.8869077	3446.875248	9.938178	0.020835339	4.91E-05	0
6	0.006042781	1801.860464	5610.241739	10.42697	0.016464789	3.05E-05	0
7	0.004283887	-7044.525404	6161.458841	10.49613	0.015991771	2.83E-05	0
8	0.003068205	5109.114759	3693.990623	9.995623	0.02044267	4.62E-05	0
9	0.00607935	-3202.951552	3543.862087	9.98423	0.021237765	4.73E-05	0
10	-6.31E-03	-737.5779313	1806.129533	9.233379	0.030034074	9.98E-05	0
11	-0.001372474	408.4768898	2178.088154	9.468057	0.026548455	7.76E-05	0
12	2.69E-03	-9563.253544	4347.987205	10.10902	0.019339455	4.21E-05	0
13	-0.001981923	-9062.050571	3226.04001	9.864354	0.021889418	5.28E-05	0
14	-6.16E-03	-2846.404021	5149.518656	10.3571	0.017405974	3.19E-05	0
15	0.004204081	-16211.2692	6702.078148	10.56392	0.015864231	2.62E-05	0
16	-0.002122997	-26141.85556	6111.027027	10.46894	0.016275496	2.89E-05	0
17	0.004231453	-9938.427028	8575.459411	10.81596	0.013863766	2.02E-05	0
18	0.001367144	-6577.592147	1518.230672	9.087327	0.031989989	0.000117475	0
19	0.006033102	-12190.46157	3809.520513	10.00415	0.020486956	4.65E-05	0
20	-0.00471694	-3844.71558	2219.292007	9.466155	0.025792275	7.92E-05	0

3.3. Implementasi

Aplikasi dalam penelitian ini menggunakan Matlab, karena untuk proses komputasi pada penelitian ini sangat besar yang berhubungan dengan perhitungan matriks secara spasial.

Hasil akhir pada penelitian ini adalah menunjukkan nilai akurasi kelas kongesti atau normal dan akurasi segmen (area) kongesti atau kelas normal.

3.4. Testing (Ujicoba)

Testing data adalah proses untuk menguji seberapa besar akurasi yang dicapai. Dari ujicoba yang sudah dilakukan ada 2 akurasi yang dihasilkan. yang pertama adalah akurasi berdasarkan klasifikasi, yang kedua adalah akurasi berdasarkan segmen area kongesti yang nantinya dibandingkan dengan identifikasi ahli patologi (*Ground thruth*).

Akurasi berdasarkan klasifikasi svm, pada proses ini membandingkan citra maing-masing segmen citra testing yang sudah diambil nilai fitur GLCM nya dibandingkan dengan nilai fitur GLCM tiap segmen yang ada pada citra training dan label kelasnya, berdasarkan perhitungan svm classifier.

Sedangkan untuk akurasi area klaster atau segmen kongesti adalah membandingkan hasil segmen kongesti pada program dengan area kongesti yang sudah ditandai oleh dokter ahli. seberapa besar tingkat akurasinya berdasarkan nilai benar dan salah ketika proses identikasi kongesti.

Dalam uji coba ini akan ditunjukkan 2 skenario uji nya. skenario pertama adalah uji yang dilakukan menggunakan citra dengan ukuran 256x256 piksel dengan K=2,3,4,5 dimana sama dengan ukuran matriks citra trainingnya. sedangkan untuk skenario kedua adalah citra yang digunakan uji adalah citra seluruh preparat yang mempunyai ukuran matriks berkisar 3000x3000 piksel dengan K=2,3,4,5. jadi bisa diketahui area kongesti pada seluruh preparat.


a. Uji coba parameter K dengan citra 256 x 256 piksel

Skenario pertama akan di uji coba pengaruh nilai K klaster pada citra ukuran 256x256 sama dengan ukuran citra training. Pada skenario ini akan diujikan 4 parameter k, yaitu untuk k=2,k=3,k=4,dan k=5.




Gambar 6. Klaster k=2. (a) klaster ke-1. (b) klaster ke-2.

Pada gambar 6 menunjukkan perbedaan nilai k, untuk k=1 menunjukkan segmen kongesti, sedangkan untuk k=2 menunjukkan segmen normal. untuk segmen k=1 kemungkinan area kongesti masih terlalu lebar, dan segmen k=2 kemungkinan ada area kongesti. maka perlu dilakukan pemilihan klaster yang terbaik untuk mendapatkan area kongesti yang sesuai




Gambar 7 Klaster k=3. (a) klaster ke-1. (b) klaster ke-2 (c) klaster ke-3

Dari gambar 7 menunjukkan area segmen (a) semakin menipis area kongestinya, untuk segmen ke-2 area berkurang karena membentuk klaster baru pada gambar (c).



Gambar 8 Klaster untuk k=4 (a) klaster ke-1 (b) klaster ke-2 (c) klaster ke-3 (d) klaster ke-4



Gambar 9 Klaster untuk k=5 (a) klaster ke-1. (b) klaster ke-2. (c) klaster ke-3. (d) klaster ke-4. (e) klaster ke-5

Untuk melihat hasil segmentasinya ditunjukkan pada tabel berikut :

Tabel 4. Tabel Hasil ujicoba dari Citra ke-1, citra ke-2, citra ke-3, citra ke-4


Citra ke-1		
Citra ke-2		
Citra ke-3		
Citra ke-4		

b. Uji coba parameter K klaster pada citra Preparat

Skenario kedua akan di uji coba pengaruh nilai K klaster pada citra semua preparat yang berukuran rata-rata 3000x3000 piksel. Pada skenario ini akan diujikan 5 parameter k, yaitu untuk k=2, k=3, k=4, k=5 dan k=6. Dari uji coba yang dilakukan akan ditunjukkan untuk masing-masing klaster dan dihitung akurasi. Tabel 4.10 dan 4.11 menunjukkan hasil citra test dengan k=2 sampai dengan k=6

Hasil ujicoba pengujian citra preparat akan ditunjukkan pada tabel dibawah :

Tabel 5. Hasil ujicoba citra preparat



3.5. Pengujian Sistem

Pengujian sistem dilakukan dalam dua bagian, yaitu pengujian akurasi kelas dengan svm classifier dan akurasi segmen secara sistem terhadap hasil diagnosis pakar.

1. Pengujian Akurasi Kelas

Pengujian ini dilakukan untuk mengetahui sejauh mana akurasi sistem pada saat dijalankan, pengujian menggunakan metode svm dengan RBF dimana dataset sebanyak 50 data. Pengujian dilakukan dalam 2 skenario citra test dengan k=2 sampai dengan k=5, seperti tertuang pada tabel 6.

Tabel 6. Skenario Pengujian Dataset citra ukuran 256 x256 piksel


K	Akurasi Kelas (%)			
	Citra ke 1	Citra ke 2	Citra ke 3	Citra ke 4
2	100%	0%	50%	0%
3	66.67%	66.67%	33.33%	66.67%
4	50%	75%	50%	75%
5	80%	100%	80%	80%

Dari tabel 6 terlihat bahwa nilai akurasi kelas tertinggi pada uji citra ke-1 terjadi pada k=2 yaitu 100%, untuk citra ke-2 terjadi pada k=5 sebesar 100%, untuk citra ke-3 pada k=5 80% dan citra ke-4 terjadi pada k=5 adalah 80%.


Tabel 7. Skenario Pengujian Dataset citra ukuran 3000 x 3000 piksel

K	Akurasi Kelas (%)			
	Citra ke 1	Citra ke 2	Citra ke 3	Citra ke 4
2	50%	50%	50%	50%
3	66.67%	66.67%	66.67%	66.67%
4	75%	75%	75%	75%
5	80%	80%	80%	80%
6	83.33%	83.33%	83.33%	83.33%

Dari tabel 7 uji coba untuk 4 citra menunjukkan bahwa hasil akurasi kelas tertinggi didapat pada k=6, dengan nilai 83.33%.



Gambar 10 Grafik akurasi kelas terhadap nilai k uji coba skenario pertama



Gambar 11 Grafik akurasi kelas terhadap nilai k uji coba skenario kedua

2. Pengujian Akurasi Area (Segmen).

Pengujian ini dilakukan untuk mengetahui sejauh mana akurasi sistem pada saat dijalankan, pengujian ini membandingkan hasil segmentasi sistem dengan *ground truth* dari ahli.

Tabel 8 Hasil akurasi segmen kongesti ujicoba citra 256 x 256 untuk tiap klaster


K	Akurasi Segmen (%)			
	Citra ke 1	Citra ke 2	Citra ke 3	Citra ke 4
2	90.67%	97.51%	27.90%	16.77%
3	93.91%	97.70%	76.24%	67.20%
4	92.74%	98.06%	88.67%	87.92%
5	92.03%	97.83%	90.22%	97.16%

Dari data tersebut terlihat bahwa untuk citra ke-1 nilai akurasi terbesarnya terjadi pada k=3 yaitu 93.91%, untuk citra ke-2 terjadi pada k=4 yaitu 98.83%, untuk citra ke-3 terjadi untuk k=5 sebesar 90.22%, dan citra ke-4 terjadi untuk k=5 sebesar 97.16%.


Tabel 9 Hasil akurasi segmen kongesti ujicoba citra preparat

K	Akurasi Area Kongesti (%)			
	Citra ke 1	Citra ke 2	Citra ke 3	Citra ke 4
2	23%	55%	44%	75%
3	61.43%	95.09%	60.01%	66.38%
4	98%	95%	98%	77%
5	98%	94%	97%	96%
6	96.67%	92.57%	98.17%	96.25%

untuk akurasi area kongesti yang terlihat pada tabel 3.8 menunjukkan akurasi citra ke-1 nilai tertinggi pada k=4 dan k=5 dengan nilai 98%, untuk citra ke-2 nilai akurasi tertinggi didapat untuk k=4, citra ke-3 nilai akurasi tertinggi didapat pada k=4 dan k=6 dengan nilai 98% dan 98.17%, dan citra ke-4 nilai akurasi tertinggi adalah 96% dan 96.25% pada k=5 dan k=6. jadi pada kedua tabel diatas menunjukkan nilai akurasi tertinggi adalah untuk k=6, tetapi bisa juga digunakan k=5.



Gambar 12 Grafik akurasi area kongesti terhadap nilai k uji coba skenario pertama



Gambar 13 Grafik akurasi area kongesti terhadap nilai k uji coba skenario kedua

Dari hasil semua uji coba yang sudah dilakukan untuk skenario pertama maupun skenario kedua menunjukkan bahwa parameter k kluster sangat berpengaruh terhadap akurasi atau ketepatan prediksi.

4. Kesimpulan

Setelah melalui ujicoba dan analisa, maka dapat ditarek kesimpulan sebagai berikut :

1. Berdasarkan hasil ujicoba yang sudah dilakukan parameter k kluster pada metode GLCM berpengaruh terhadap hasil segmentasi maupun hasil klasifikasi. Nilai rata - rata akurasi kelas dan akurasi segmen tertinggi terjadi pada k=5 dan k=6 yaitu sebesar 95.91% untuk akurasi segmen, dan 83.33% untuk akurasi kelas.
2. Terdapat tipe citra tertentu yang kurang baik ketika proses segmentasi kmean, sehingga area kongesti tidak sesuai dengan *ground truth* dari ahli. citra tersebut mempunyai format warna yang berbeda dari citra uji.
3. Dari analisa uji coba yang dilakukan, jika hanya menggunakan parameter tekstur hasilnya kurang baik, apalagi pada proses identifikasi area kongesti. maka metode yang berbasis tekstur digabung parameternya dengan fitur warna, karena untuk kasus citra histologi yang banyak dominan pada perbedaan warnanya

Ucapan Terima Kasih

Penulis mengucapkan terima kasih sebesar-besarnya kepada :

1. Ibu Izzati Muhimmah
2. Ibu Ika Firdianingsih
3. Teman – teman PPT

Atas semua dukungan sehingga penulis bisa menyelesaikan penelitian ini.

Daftar Pustaka

- [1] Goudas, Theodosios & Doukas, Charalampos & Chatziioannou, Aristotle & Maglogiannis, Ilias. (2012). "Advanced characterization of microscopic Kidney biopsies utilizing image analysis techniques". Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference. 2012. 4414-7. 10.1109/EMBC.2012.6346945.

-
- [2] Gangeh, M. J., et al. "A texton-based approach for the classification of lung parenchyma in CT images." *Medical image computing and computer-assisted intervention: MICCAI... International Conference on Medical Image Computing and Computer-Assisted Intervention*. Vol. 13. No. Pt 3. 2010. Bergmeir, C., Costantini, M., Benítez, J. M., 2014. On the usefulness of cross-validation for directional forecast evaluation. *Computational Statistics and Data Analysis*.
- [3] R. M. Haralick, K. Shanmugam, and I. H. Dinstein, "Textural features for image classification," *IEEE Transactions on Systems, Man and Cybernetics*, vol.3, no.6, pp.610–621, 1973
- [4] Gonzalez, R.C. & Woods E.R. 2002. *Digital Image Processing*. Prentice Hall. 2nd Edition.
- [5] Anggraini, D.R. 2008. *Gambaran Makroskopis dan Mikroskopis Hati dan Ginjal Mencit Akibat Pemberian Plumbum Asetat*. Fakultas Kedokteran Universitas Sumatra Utara. (Thesis).
- [6] J. A. Hartigan and M. A. Wong (1979). "A K-Means Clustering Algorithm". *Applied Statistics* 28 (1): 100–108.