

EKTRAKSI FITUR MENGGUNAKAN DISCRETE WAVELET TRANSFORM DAN FULL NEIGHBOUR LOCAL BINARY PATTERN UNTUK KLASIFIKASI MAMMOGRAM

Januar Adi Putra¹, Nanik Suciati², Arya Yudhi Wijaya³
Jurusan Teknik Informatika, Fakultas Teknologi Informasi,
Institut Teknologi Sepuluh Nopember (ITS)
Email: januaradi.putra@gmail.com¹, naniksuciati@gmail.com², arya@cs.its.ac.id³

Abstrak

Local binary pattern adalah sebuah kode biner yang menggambarkan pola tekstur lokal. Hal ini dibangun dengan lingkungan batas dengan nilai abu-abu dari pusatnya. *Local binary pattern tradisional* memiliki beberapa kelemahan yakni varian terhadap rotasi dan pada saat proses thresholding pixel sensitif terhadap noise. Pada penelitian ini diusulkan sebuah metode ekstraksi fitur baru untuk mengatasi masalah tersebut, metode tersebut disebut *full neighbour local binary pattern* (fnlbp). Metode ini nantinya akan dikombinasikan dengan discrete wavelet transform untuk ekstraksi fitur dari citra mammogram dengan metode klasifikasi adalah Backpropagation Neural Network (BPNN). Berdasar uji coba yang telah dilakukan metode usulan mendapatkan rata-rata akurasi yang lebih baik daripada metode local binary pattern tradisional baik yang dikombinasi dengan discrete wavelet transform ataupun tidak. Performa metode usulan full neighbour local binary pattern dapat menghasilkan akurasi yang sempurna yakni 100% baik pada saat menggunakan discrete wavelet transform ataupun tidak, sedangkan akurasi terendah yang didapat adalah 90.49%.

Kata Kunci: Ekstraksi fitur, *local binary pattern*, *wavelet*, klasifikasi mammogram.

Abstract

Traditional local binary pattern have some disadvantages which is a variant of the rotation and during the thresholding process the pixel is sensitive to noise. At this study the authors proposed a new method of features extraction to solve that problem and this method called full neighbor local binary pattern (fnlbp). This method will be combined with discrete wavelet transform to extract the features of

the mammogram image and the classification method is Backpropagation Neural Network (BPNN). Based on experiments the result of proposed method in an average accuracy is better than traditional methods of local binary pattern which combined with discrete wavelet transform or not. The performance of the proposed method of full neighbor local binary pattern can produce perfect accuracy that is 100%, this accuracy is reached when using discrete wavelet transform or not, while the lowest accuracy obtained is 90.49%.

Keywords: News document, categorization, multi-label, Ontology, domain-specific.

I. PENDAHULUAN

Salah satu metode yang paling efektif untuk mendeteksi dan mengidentifikasi kanker payudara adalah melalui pemeriksaan mammografi dengan menggunakan sinar X. Citra yang dihasilkan dari sinar X tersebut disebut mammogram. Analisa terhadap citra mammografi yang sebelumnya dilakukan oleh radiologis secara manual dapat digantikan dengan teknologi terbaru dengan memanfaatkan pengolahan citra digital, sehingga hasil yang didapatkan tidak lagi bersifat subyektif dan dapat mengatasi radiologis yang merasa tidak yakin dengan hasil analisisnya (Uyun & Harjoko, 2011).

Terdapat beberapa penelitian yang telah dilakukan sebelumnya dengan memanfaatkan pengolahan citra digital, yaitu analisa multiresolusi berbasis *wavelet*. Dhawan dkk (1996) menggunakan *wavelet decomposition* pada citra *gray-level* untuk klasifikasi citra mammogram dan diperoleh nilai akurasi 81%. Liu dkk (2001) menggunakan fitur statistik berbasis *wavelet* dan *binary tree* sebagai *classifier* mendapatkan akurasi 84.2% pada

klasifikasi mammogram. Rashed dkk (2007) menggunakan beberapa tipe *Daubechies wavelets* pada klasifikasi mammogram, diperoleh akurasi klasifikasi 87.06%. Buciu dkk (2011) menggunakan filter gabor berbasis *wavelet* untuk fitur ekstraksi, PCA untuk fitur seleksi (*dimension reduction*) dan *support vector machine* sebagai *classifier* untuk mengklasifikasikan citra mammogram sebagai *normal-abnormal* (performa klasifikasi 79%) dan *benign-malignant* (performa klasifikasi 78%). Sanae dkk (2015) menggunakan *wavelet decomposition* pada citra mammogram dan dikombinasikan dengan ekstraksi fitur *local binary pattern* mendapatkan akurasi klasifikasi sebesar 93%. Berdasar hasil studi literatur yang dilakukan, dapat terlihat kombinasi *wavelet* dengan teknik pengolahan citra yang lain menghasilkan akurasi yang cukup tinggi dimana kombinasi *wavelet* dan *local binary pattern* merupakan kombinasi yang terbaik.

Saat ini pengembangan algoritma *local binary pattern* telah banyak dilakukan, Kaya dkk (2015) mengusulkan dua pengembangan baru dari *local binary pattern* yakni *neighbour local binary pattern (nlbp)* dan *directional binary pattern (dlbp)*. Dua metode baru tersebut memiliki perbedaan pada arah dan distribusi relasi spasial dari pixel. Pada *neighbour local binary pattern* histogram dibentuk dengan membandingkan pixel-pixel yang ada diantara pixel tengah, sedangkan pada *directional binary pattern* histogram dibentuk dengan membandingkan pixel tengah dengan pixel yang ada pada arah yang telah ditentukan. Dua metode pengembangan *local binary pattern* tersebut telah diuji dengan berbagai citra tekstur dengan *classifier* adalah *Artificial Neural Network (ANN)*. Dari hasil uji yang telah dilakukan terbukti dua metode pengembangan tersebut menghasilkan akurasi yang lebih baik dari *local binary pattern* yang tradisional. Meski menghasilkan akurasi yang baik dua metode baru tersebut memiliki beberapa kelemahan yang sama dengan *local binary pattern* tradisional, yakni histogram yang dihasilkan *sensitiv* terhadap rotasi dan pada proses *thresholding* pixel sensitif terhadap noise.


Berdasar uraian yang telah dijelaskan sebelumnya, penelitian ini mengusulkan sebuah metode ekstraksi fitur baru yang didasarkan pada *neighbour local binary pattern (nlbp)*. Metode ini memiliki perbedaan pada arah dan distribusi relasi spasial dari pixel, dimana perbandingan antar pixel pada proses *trhesholding* tidak hanya dengan

tetangga di bagian kanan saja melainkan dengan semua tetangga yang ada pada sisi *horizontal*, *vertical* dan *diagonal* sehingga metode tersebut disebut *full neighbour local binary pattern (fulbp)*. Dengan melakukan perbandingan pixel dengan semua tetangga maka proses *thresholding* akan lebih insensitif terhadap noise yang akan menyebabkan proses *thresholding* tersebut lebih akurat dan akurasi pun akan meningkat. Metode ini nantinya akan dikombinasikan dengan *discrete wavelet transform* untuk ekstraksi fitur dari citra mammogram dengan *classifier* adalah *Backpropagation Neural Network (BPNN)*.

II. KAJIAN LITERATUR

II.1 Kanker Payudara

Terdapat beberapa cara untuk mendeteksi dini kanker payudara, salah satunya adalah mendeteksi dan mengidentifikasi melalui pemeriksaan sinar x. Citra yang dihasilkan dari sinar x tersebut disebut mammogram. Citra mammogram hasil sinar x dapat dilihat pada Gambar 1.



Gambar 1. Citra mammogram


II.2 Local Binary Pattern

Secara sederhana, LBP adalah sebuah kode biner yang menggambarkan pola tekstur lokal. Hal ini dibangun dengan lingkungan batas dengan nilai abu-abu dari pusatnya (Ahonen, Hadid, & Pietikainen, 2004).

II.3 Neighbour Local Binary Pattern

Deskriptor pada metode ini tergantung pada hubungan 8 tetangga, $P = \{ P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7 \}$, dengan satu sama lain, sekitar pixel. Dalam proses perbandingannya, nilai setiap pixel tetangga tertentu dibandingkan dengan pixel sebelumnya untuk menentukan *thresholding* bernilai 1 atau 0, sedangkan proses-proses selanjutnya sama seperti LBP tradisional. Selain itu, pada nLBP perbandingan

dapat dilakukan tidak hanya dengan tetangga berurutan akan tetapi dapat juga dilakukan dalam tetangga yang didefinisikan oleh parameter jarak, d . Proses perbandingan tersebut dapat dilihat pada Gambar 2.



Gambar 2. Proses perbandingan pixel pada nlbp.

III. METODE PENELITIAN


Pada bab ini memaparkan tentang metodologi penelitian yang digunakan pada penelitian ini serta kontribusi dari yang diajukan. Ilustrasi alur metodologi penelitian dan kontribusi dapat dilihat pada Gambar 3.

III.1 Deteksi dan Pematongan ROI

Pada mammogram bagian yang paling merepresentasikan kanker adalah region yang mengandung *mass* sehingga sebelum klasifikasi dilakukan maka citra mammogram akan di preprocessing untuk mendeteksi letak *mass* tersebut. Contoh ROI pada citra mammogram ditunjukkan Gambar 4. Ada beberapa tahapan dalam mendeteksi dan segmentasi ROI pada citra mammogram. Tujuan dari tahap ini adalah mendapatkan titik kanker pada citra mammogram (*mass*) yang dapat mengindikasikan seseorang mengidap kanker payudara atau tidak. Tahapan dari deteksi dan segmentasi *mass* tersebut dapat dilihat pada Gambar 5. Tahapan-tahapan akan dijelaskan secara terperinci pada sub-bab berikutnya.

3.1.1 Penghapusan Black Margin


Proses Tahap ini merupakan tahap untuk menghilangkan pinggiran hitam pada citra mammogram. Frame hitam pada pinggiran citra harus dihilangkan untuk mempermudah pada proses segmentasi.



Gambar 4. ROI citra mammogram.

Proses penghapusan black margin dapat dilihat pada Gambar 6. Ada tiga tahapan utama dalam penghapusan black margin ini yakni:

1. Mencari posisi pixel pertama yang tidak berwarna hitam pada posisi horizontal.
2. Mencari posisi pixel terakhir yang tidak berwarna hitam pada posisi horizontal.
3. Memotong citra diantara posisi 1 dan 2 yang telah didapat.




Gambar 6. Penghapusan frame hitam.

3.1.2 Supresi Artifact dan Pemisahan Background

Proses Tahapan ini bermaksud untuk menghilangkan objek-objek dalam citra yang mengganggu proses klasifikasi. Proses artifact suppression ini dapat dilihat pada Gambar 7. Adapun tahapan-tahapan dalam operasinya adalah sebagai berikut:


1. Citra mammogram akan dirubah kedalam citra biner dengan proses *thresholding* ($T = 18$) seperti terlihat pada Gambar 7b, kemudian semua objek dilabeli menggunakan fungsi *bwlabel* pada MATLAB.



Gambar 5. Alur deteksi dan *cropping* ROI

- Area (ukuran sebenarnya dari daerah pixel) dari semua objek pada Gambar 7b akan dikalkulasi menggunakan fungsi *regionprops* pada MATLAB
- Dari semua objek biner pada citra mammogram (Gambar 7a), Objek yang memiliki area terbesar (Gambar 7c) pada setiap citra akan dipilih menggunakan fungsi *bwareopen* pada MATLAB. Proses *morphological* ini menghapus semua objek biner pada citra mammogram kecuali objek dengan area yang terbesar.
- Operasi *morphological* untuk memperkecil distorsi dan menghapus pixel yang terisolasi diaplikasikan ke citra biner mammogram menggunakan fungsi *bwmorph* pada MATLAB dengan parameter *'clean'*.
- Operasi *morphological* yang lain diaplikasikan pada citra biner mammogram untuk memperhalus noise yang muncul, operasi yang digunakan adalah fungsi *bwmorph* pada MATLAB dengan parameter *'majority'*.
- Citra biner mammogram di erosi menggunakan fungsi *strel* dan *imerode*, dimana radius dari fungsi *strel* adalah $R=5$.
- Citra biner mammogram di dilasi menggunakan fungsi *imdilation* pada MATLAB.
- Lubang pada citra biner mammogram diisi dengan menggunakan fungsi *imfill* pada MATLAB dengan parameter *'holes'*.
- Hasil citra biner yang dihasilkan dari step 8 dikalikan dengan citra original mammogram setelah penghapusan *black margin*, fungsi yang

digunakan adalah *immultiply* pada MATLAB dan akan menghasilkan citra seperti pada Gambar 7d.




Gambar 7. Penghapusan objek mengganggu.

III.1.3 Identifikasi Orientasi

Tahapan orientasi payudara ini berfungsi untuk menentukan letak *pectoral muscle* dan berfungsi untuk tahapan selanjutnya. Untuk menentukan sebuah citra mammogram memiliki orientasi payudara kekanan atau ke kiri maka sebuah citra biner mammogram akan dipotong dari kiri kekanan dan dari atas ke bawah sehingga citra biner mammogram akan menjadi empat bagian sama rata yaitu bagian kiri, kanan, atas dan bawah. Kemudian jumlah dari lima nilai kolom pertama dan terakhir pada citra biner yang telah dibagi empat tersebut dikalkulasi, apabila jumlah nilai pixel kolom pertama lebih besar dari

jumlah nilai pixel pada kolom terakhir maka citra tersebut memiliki orientasi payudara kekanan dan juga sebaliknya. Orientasi citra mammogram ditunjukkan oleh gambar 8.



Gambar 8. Orientasi citra mammogram.

III.1.4 Eliminasi Pectoral

Tahap ini merupakan proses untuk membuang *pectoral muscle* dari citra mamogram. *Pectoral muscle* harus dihilangkan karena seringkali memiliki warna pixel yang sama dengan *mass* kanker payudara sehingga seringkali menurunkan akurasi pada tahap deteksi ROI. Langkah tahap ini dapat dilihat pada Gambar 9. Adapun tahapan penghapusan *pectoral muscle* ini adalah sebagai berikut:

1. Citra mammogram dibagi menjadi empat kuadran seperti pada tahap identifikasi orientasi (kiri-atas, kanan-atas, kiri-bawah, dan kanan-bawah).
2. Jika citra mammogram adalah orientasi kanan maka *pectoral* pasti berada pada kuadran kiri-

atas, sedangkan jika orientasi kiri maka *pectoral* berada pada kuadran kanan-atas.


3. Kuadran yang terdapat *pectoral* didalamnya merupakan bagian yang terpenting dan tiga kuadran lainnya dirubah ke warna hitam atau diberi nilai 0 pada pixelnya.
4. *Threshold* citra mammogram dari tahap 3 dengan nilai $t=176$ untuk mendapatkan citra biner.
5. Lakukan fungsi *invers* pada citra biner mammogram.
6. Gunakan fungsi *multiply* pada citra *invers* terhadap citra awal mammogram setelah penghapusan *artifact*.

III.1.5 Deteksi dan Pemotongan Mass (ROI)

Tahapan deteksi dan pemotongan merupakan tahap akhir dari tahap deteksi ROI, pada tahap ini dilakukan proses *thresholding* dan operasi morfologi *opening* agar menghilangkan bintik-bintik selain *mass*. Setelah *mass* tersegmentasi maka *mass* akan dipotong sesuai dengan yang dikehendaki pada penelitian ini akan dipotong ukuran citra sebesar 128x128 pixel. Adapun tahapan dapat dilihat pada Gambar 10.

III.2 Discrete Wavelet Transform


Setelah Ekstraksi fitur dari citra mamogram



Gambar 10. Tahap pemotongan ROI.

dilakukan dengan mengkombinasikan dua metode yakni 2D-DWT dan fnLBP. DWT dapat digunakan untuk transformasi citra, proses transformasi wavelet yang dilakukan secara konsep cukup sederhana. Citra semula yang ditransformasi dibagi (didekomposisi) menjadi 4 sub-citra baru untuk menggantikannya. Setiap sub-citra berukuran $\frac{1}{4}$ kali dari citra asli. Sub-citra pada posisi atas kanan, bawah kiri, dan bawah kanan akan tampak seperti versi kasar dari citra asli karena berisi komponen frekuensi tinggi dari citra asli. Sedangkan untuk 1 sub-citra atas kiri tampak seperti citra asli dan tampak lebih halus (*smooth*)

Proses thresholding dilakukan pada semua piksel pada box matrik yang ada, sehingga menghasilkan seperti pada gambar 13. Dari Gambar 13 dapat dilihat bahwa pattern yang terbentuk dari proses thresholding adalah 10110000. Setelah proses thresholding selesai maka langkah selanjutnya adalah melakukan *circular pattern*. *Circular pattern* merupakan proses untuk mendapatkan kombinasi susunan pattern dengan cara menggeser bagian kiri ke bagian paling kanan, proses *circular pattern* dapat




Gambar 11. a) Proses dekomposisi DWT 2 level b) Original ROI c) Hasil DWT terhadap ROI.

karena berisi komponen frekuensi rendah dari citra asli. *Discrete wavelete transform* yang dilakukan pada penelitian ini adalah level 2 dimana akan menghasilkan 7 sub-citra baru. Tahapan DWT pada penelitian ini dapat dilihat pada Gambar 11.

III.3 Full Neighbor Local Binary Pattern

Metode ini memiliki perbedaan pada arah dan distribusi relasi spasial dari pixel, dimana perbandingan antar pixel pada proses *trhesholding* tidak hanya dengan semua tetangga di bagian kanan saja melainkan dengan semua tetangga yang ada pada sisi *horizontal*, *vertical* dan *diagonal* sehingga metode tersebut disebut *full neighbour local binary pattern (fnlbp)*. Dengan melakukan perbandingan pixel dengan semua tetangga maka proses *thresholding* akan lebih insensitif terhadap noise yang akan menyebabkan proses *thresholding* tersebut lebih akurat dan akurasi pun akan meningkat. Setelah dilakukan perbandingan maka nilai treshold merupakan nilai mayoritas, jika terbanyak adalah 0 maka threshold adalah 0, dan sebaliknya. Adapun langkah dari proses perbandingan pada fnLBP ini ditunjukkan pada Gambar 12.

dilihat pada Gambar 14.



Gambar 12. Contoh proses thresholding pada fnlbp.

hasil akhir thresholding

0	0	0
0		1
1	1	0

Gambar 13. hasil akhir proses thresholding.

Proses *circular pattern* dilakukan terus hingga posisi kembali seperti pattern awal, proses ini akan menghasilkan 8 kombinasi pattern baru. Setelah didapat kombinasi-kombinasi yang lain maka langkah terakhir adalah mengalikan dengan bobot



Gambar 14. Proses circular pattern.

seperti pada LBP tradisional. Histogram akhir merupakan nilai terkecil dari hasil perkalian tersebut. Contoh kombinasi pattern yang didapat dapat dilihat pada Gambar 15.

III.4 Seleksi Fitur

Pada penelitian ini dilakukan seleksi fitur menggunakan metode statistika yaitu *two sample t-test* dan *f-test*. *T-test* dikenal dengan uji parsial, yaitu untuk menguji bagaimana pengaruh masing-masing variabel bebasnya secara sendiri-sendiri terhadap variabel terikatnya. Uji ini dapat dilakukan dengan membandingkan *t* hitung dengan *t* tabel atau dengan melihat kolom signifikansi pada masing-masing *t* hitung. *F-test* dikenal dengan Uji serentak atau uji Model/Uji Anova, yaitu uji untuk melihat bagaimanakah pengaruh semua variabel bebasnya secara bersama-sama terhadap variabel terikatnya. *T-test* ataupun *f-test* berfungsi untuk menghasilkan hipotesa apakah sebuah fitur suatu kelas tersebut significant terhadap fitur yang sama pada kelas lainnya. Jika model signifikan maka model tidak bisa digunakan untuk klasifikasi, sebaliknya jika non/tidak signifikan maka model regresi bisa digunakan untuk proses klasifikasi. Untuk algoritma *t-test* dan *f-test* dapat dilihat pada Gambar 16.

IV. HASIL DAN PEMBAHASAN

Kombinasi pattern :	Weight	Hasil :										
1.10110000	<table border="1"> <tr><td>32</td><td>64</td><td>128</td></tr> <tr><td>16</td><td></td><td>1</td></tr> <tr><td>8</td><td>4</td><td>2</td></tr> </table>	32	64	128	16		1	8	4	2	1. 1+4+8	=13 Terkecil
32		64	128									
16			1									
8		4	2									
2.01100001		2. 2+4+128	=134									
3.11000010		3. 1+2+128	=131									
4.10000101		4. 1+32+128	=161									
5.00001011		5. 16+64+128	=208									
6.00010110	6. 8+32+64	=104										
7.00101100	7. 4+16+32	=52										
8.01011000	8. 1+8+16	=26										

Variabel dibutuhkan : fitur_matrik[1:M, 1:N], kelas_target[1:N],
 α : significant level
 Variabel output : fitur_terpilih₁[1:R, 1:N] dan fitur_terpilih₂[1:R, 1:N]

R: Jumlah total dari fitur yang terpilih
 Fungsi ttest() dan vartest() akan mengkomputasi nilai dari null hypothesis dari dua vector dengan nilai *significant level* yang berbeda. Untuk masing-masing two sample t dan f-test dilakukan.

- 1: deklarasi dua vector kosong v_1 dan v_2
- 2: inisialisasi α , $0 < \alpha < 1$
- 3: for $i=1$ sampai M, lakukan
- 4: Kosongkan isi dari vector v_1 dan v_2
- 5: for $j=1$ sampai N, lakukan
- 6: if kelas_target[j]=1, then
- 7: tambahkan fitur_matrik[i,j] ke v_1
- 8: else
- 9: tambahkan fitur_matrik[i,j] ke v_2
- 10: end if
- 11: end for
- 12: $h_1[i] = ttest(v_1, v_2, \alpha)$
- 13: $h_2[i] = vartest(v_1, v_2, \alpha)$
- 14: for $k=1$ sampai 2, lakukan
- 15: if $h_k[i] = 1$, then
- 16: tambahkan fitur_matrik[i, 1:N] ke fitur_terpilih_k
- 17: end if
- 18: end for
- 19: end for

Dalam bab ini akan dipaparkan hasil serta pembahasan penelitian yang telah dilakukan.


IV.1 Dataset Uji Coba

Data yang digunakan pada penelitian ini adalah citra yang diperoleh dari database Mammographic Image Analysis Society (MIAS) dan DDSM. Data MIAS didapat melalui website <http://peipa.essex.ac.uk/pix/mias>, sedangkan data DDSM didapat dari <http://marathon.csee.usf.edu/Mammography/Database.html>. Dengan jumlah data citra mammogram adalah 317 citra, dengan 208 citra normal dan 109 citra abnormal.

IV.2 Uji Coba Invarian Rotasi

Uji coba ini dilakukan untuk melihat apakah metode usulan fnlbp mengatasi masalah dari lbp


tradisional yakni varian terhadap rotasi. Varian terhadap rotasi akan menyebabkan kesulitan pada saat ekstraksi fitur hal ini dikarenakan semua gambar harus memiliki posisi kemiringan citra yang sama antar satu dengan yang lain, hal ini tentunya akan mengkonsumsi waktu pengerjaan yang lebih lama. Uji coba dilakukan dengan menggunakan dua citra yang sama tetapi dengan tingkat rotasi yang berbeda seperti terlihat pada Gambar 17a dan Gambar 17b.




Gambar 17. Citra Mammogram . a)Awal. b)rotasi.

Hasil perbandingan histogram menggunakan metode ekstraksi lbp dapat dilihat pada Gambar 18. Terlihat bahwa histogram hasil lbp berbeda antara satu dengan yang lain, gambar kiri pada Gambar 18 adalah histogram citra mammogram awal sedangkan gambar kanan merupakan histogram citra mammogram setelah dirotasi. Perbedaan yang terjadi pada hasil histogram mengindikasikan bahwa metode lbp varian terhadap rotasi, sehingga metode lbp tidak cocok untuk digunakan pada dataset citra yang berukuran besar dan memiliki tingkat rotasi yang berbeda-beda.

Hasil perbandingan histogram menggunakan metode ekstraksi fnlbp dapat dilihat pada Gambar 19. Terlihat bahwa histogram hasil fnlbp sama persis antara satu dengan yang lain, gambar kiri pada Gambar 19 adalah histogram citra mammogram awal sedangkan gambar kanan merupakan histogram citra mammogram setelah dirotasi. Hasil histogram yang sama pada hasil ekstraksi menggunakan fnlbp mengindikasikan bahwa metode fnlbp invarian terhadap rotasi, sehingga rotasi yang berbeda-beda tidak akan berpengaruh terhadap hasil histogram. Metode yang invarian terhadap rotasi cocok untuk digunakan pada dataset citra yang memiliki tingkat rotasi yang berbeda-beda sehingga akan menghemat waktu penelitian.



Gambar 18. Hasil Histogram lbp.




Gambar 19. Hasil Histogram fnlbp.

IV.3 Uji Coba Seleksi Fitur

Seleksi fitur digunakan untuk mengurangi dimensi data dan fitur-fitur yang tidak relevan. Seleksi fitur juga digunakan untuk meningkatkan efektifitas dan efisiensi kinerja dari algoritma klasifikasi. Metode seleksi fitur yang digunakan adalah f-test dan t-test dan parameter yang berpengaruh pada dua metode tersebut adalah significant level. Uji coba juga dilakukan pada tahapan seleksi fitur dengan cara merubah-ubah nilai parameter *significant level*, hal ini dimaksudkan untuk mengetahui hubungan variabel significant level dengan hasil seleksi fitur yang ada. Nilai significant level yang menjadi parameter uji adalah 0.1, 0.3, 0.5, 0.7, 0.9.

Adapun f-test dan t-test akan dilakukan dan dibandingkan pada dataset hasil dari ekstraksi fitur metode penggabungan wavelet dan lbp dengan wavelet dan fnlbp. Setiap satu citra mammogram akan menghasilkan 7 sub citra hasil dekomposisi *discrete wavelet transform* dan yang akan digunakan untuk proses ekstraksi fitur adalah 6 sub citra yakni dekomposisi horizontal level 1 dan 2, dekomposisi vertical level 1 dan 2, serta dekomposisi diagonal level 1 dan 2. Satu buah subcitra akan menghasilkan satu buah histogram hasil ekstraksi fitur lbp ataupun fnlbp, sedangkan satu histogram terdiri dari 256 fitur sehingga 6 sub citra akan menghasilkan 1536 fitur. Simulasi ekstraksi data citra mammogram hingga

menjadi fitur dapat dilihat pada Gambar 20 dan hasil pengujian seleksi fitur dapat dilihat pada Tabel 1.



Gambar 20. Simulasi ekstraksi dan seleksi fitur.

Tabel 1. Hasil Seleksi Fitur.

Significant level	Jumlah Fitur LBP (R)		Jumlah Fitur FNLBP (R)	
	T-test	F-test	T-test	F-test
0.1	758	453	175	174
0.3	1010	775	188	192
0.5	1173	1021	197	207
0.7	1330	1226	206	211
0.9	1478	1443	213	216

Dapat terlihat dalam Tabel 1 jumlah fitur terkecil dihasilkan oleh metode seleksi fitur F-test pada data hasil ekstraksi menggunakan fnlbp dengan nilai significant level 0.1 yakni 174, sedangkan jumlah fitur terbanyak dihasilkan oleh metode seleksi fitur T-test pada data hasil ekstraksi menggunakan lbp dengan nilai significant level 0.9 yakni 1478.

Berdasarkan hasil yang didapat seperti pada Tabel 1 juga dapat disimpulkan bahwa semakin tinggi nilai significant level maka fitur yang terseleksi akan semakin kecil sehingga hasil akhir fitur akan mendekati fitur awal sebelum dilakukan seleksi fitur, begitu pula sebaliknya semakin rendah nilai significant level maka fitur yang terseleksi akan semakin banyak dan menghasilkan fitur yang dianggap independent lebih sedikit. Penyebab significant level berbanding terbalik dengan hasil seleksi fitur adalah karena significant level digunakan sebagai pembanding untuk menentukan sebuah fitur dianggap independent atau tidak sehingga jika nilai significant level lebih besar maka peluang sebuah fitur dianggap independent akan semakin kecil.

Dari Tabel 1 juga dapat terlihat bahwa hasil dataset hasil ekstraksi fitur fnlbp akan memiliki fitur lebih sedikit setelah di seleksi daripada dataset hasil ekstraksi fitur lbp, hal ini disebabkan karena persebaran histogram hasil ekstraksi fitur local binary pattern memiliki variasi bit histogram yang terisi lebih tersebar dan banyak daripada histogram hasil ekstraksi fitur menggunakan fnlbp. Penjelasan dan perbandingan tentang analisa histogram lbp dan fnlbp telah dijelaskan pada sub bab sebelumnya yakni subbab ekstraksi fitur.

IV.4 Uji Coba Klasifikasi

Pengujian dilakukan dengan membandingkan metode fnlbp dan lbp tradisional dengan menggunakan discrete wavelet transform, tanpa discrete wavelet transform serta pada koefisien level

Tabel 2. Tabel Performa DWT+fnlbp.

Uji	Significant Level	R	TP	TN	FP	FN	Sensitivity	Specifisity	Akurasi (%)
T-test	0.9	213	76	145	0	0	1.00	1.00	100.00
	0.7	206	69	145	7	0	1.00	0.95	96.83
	0.5	197	76	145	0	0	1.00	1.00	100.00
	0.3	188	74	145	2	0	1.00	0.98	99.09
	0.1	175	76	145	0	0	1.00	1.00	100.00
F-test	0.9	216	75	145	1	0	1.00	0.99	99.54
	0.7	211	76	145	0	0	1.00	1.00	100.00
	0.5	207	55	145	21	0	1.00	0.87	90.49
	0.3	192	72	145	4	0	1.00	0.97	98.19
	0.1	174	69	145	7	0	1.00	0.95	96.83

Tabel 3. Tabel Performa DWT+lbp.

Uji	Significant Level	R	TP	TN	FP	FN	Sensitivity	Specificity	Akurasi (%)
T-test	0.9	1478	72	145	4	0	1.00	0.97	98.19
	0.7	1330	72	145	4	0	1.00	0.97	98.19
	0.5	1173	57	145	19	0	1.00	0.88	91.40
	0.3	1010	47	145	29	0	1.00	0.83	86.87
	0.1	758	75	145	1	0	1.00	0.99	99.54
F-test	0.9	1443	32	145	44	0	1.00	0.76	80.09
	0.7	1226	57	145	19	0	1.00	0.88	91.40
	0.5	1021	76	145	0	0	1.00	1.00	100.00
	0.3	775	54	145	22	0	1.00	0.86	90.04
	0.1	453	68	145	8	0	1.00	0.94	96.38

satu dan duanya saja. Performa metode dapat dilihat pada Tabel 2 sampai dengan Tabel 5.

Dapat dilihat pada Tabel 2 performa kombinasi discrete wavelet transform dan full neighbour local binary pattern menghasilkan akurasi yang sempurna yakni 100% pada seleksi fitur t-test dengan nilai significant level 0.9, 0.5 dan 0.1. Pada ujicoba menggunakan seleksi fitur menggunakan f-test kombinasi discrete wavelet transform dan full neighbour local binary pattern mendapatkan akurasi sempurna hanya pada nilai significant level 0.7.

Untuk nilai sensitivitas kombinasi ini menghasilkan nilai sempurna pada semua rangkaian ujicoba sedangkan untuk spesifisitas nilai sempurna didapat pada saat akurasi juga mendapat nilai sempurna yakni pada seleksi fitur t-test dengan nilai significant level 0.9, 0.5 dan 0.1, serta seleksi fitur f-test dengan significant level 0.7. Nilai akurasi terendah untuk kombinasi discrete wavelet transform dan full neighbour local binary pattern didapat pada saat digunakan metode seleksi fitur f-test dengan nilai significant level 0.5 yakni 90.49% sedangkan untuk metode seleksi fitur t-test akurasi terendah didapat pada significant level 0.7. Dari tabel 2 juga didapat fakta bahwa nilai spesifisitas berbanding lurus dengan akurasi sedangkan sensitivitas tidak.

Untuk kombinasi discrete wavelet transform dan local binary pattern dapat terlihat performa pada Tabel 3 menghasilkan akurasi yang sempurna yakni 100% pada seleksi fitur f-test dengan nilai significant level 0.5. Pada ujicoba menggunakan seleksi fitur

menggunakan t-test kombinasi discrete wavelet transform dan local binary pattern tidak terdapat akurasi sempurna nilai tertinggi hanya pada nilai significant level 0.1 yakni dengan akurasi 99.54. Untuk nilai sensitivitas kombinasi ini menghasilkan nilai sempurna pada semua rangkaian ujicoba sedangkan untuk spesifisitas nilai sempurna didapat pada saat akurasi juga mendapat nilai sempurna yakni pada seleksi fitur t-test dengan nilai significant level 0.1 dengan nilai spesifisitas 0.99, serta seleksi fitur f-test dengan significant level 0.5 dengan nilai spesifisitas 1.00.

Nilai akurasi terendah untuk kombinasi discrete wavelet transform dan local binary pattern didapat pada saat digunakan metode seleksi fitur f-test dengan nilai significant level 0.9 yakni 80.09% sedangkan untuk metode seleksi fitur t-test akurasi terendah didapat pada significant level 0.3. Dari tabel 2 dan tabel 3 didapat fakta bahwa metode usulan mendapatkan rata-rata akurasi yang lebih baik daripada metode kombinasi discrete wavelet transform dan local binary pattern tradisional, hal ini berarti kombinasi discrete wavelet transform dan full neighbour local binary pattern lebih cocok untuk digunakan pada klasifikasi mammogram. Setelah dilakukan ujicoba untuk mendapatkan dan membandingkan performa dari metode usulan yakni kombinasi discrete wavelet transform dan full neighbour local binary pattern dengan kombinasi discrete wavelet transform dan local binary pattern tradisional, langkah selanjutnya adalah menguji metode terhadap citra mammogram tanpa dilakukan

dekomposisi citra menggunakan discrete wavelet transform terlebih dahulu. Untuk data latih dan data training yang digunakan adalah sama dengan data ujicoba sebelumnya dengan pembagian yang sama

Untuk metode tradisional local binary pattern dapat terlihat performa pada Tabel 5 menghasilkan akurasi yang tertinggi yakni 93.21% pada seleksi fitur f-test dengan nilai significant level 0.1. Pada

Tabel 4. Tabel Performa fnlbp.

Uji	Significant Level	R	TP	TN	FP	FN	Sensitivity	Specificity	Akurasi (%)
T-test	0.9	32	72	145	4	0	1.00	0.97	98.19
	0.7	34	75	145	1	0	1.00	0.99	99.54
	0.5	34	73	145	3	0	1.00	0.97	98.64
	0.3	34	73	145	3	0	1.00	0.97	98.64
	0.1	34	76	145	0	0	1.00	1.00	100.00
F-test	0.9	36	75	145	1	0	1.00	0.99	99.54
	0.7	36	57	145	19	0	1.00	0.88	91.40
	0.5	36	73	145	3	0	1.00	0.97	98.64
	0.3	36	67	145	9	0	1.00	0.94	95.92
	0.1	36	68	145	8	0	1.00	0.94	96.38

juga yakni 70% data training dan 30% data testing.

Dapat dilihat pada Tabel 4 performa metode usulan full neighbour local binary pattern menghasilkan akurasi yang sempurna yakni 100% pada seleksi fitur t-test dengan nilai significant 0.1. Pada ujicoba menggunakan seleksi fitur menggunakan f-test full neighbour local binary pattern mendapatkan akurasi tertinggi pada nilai

significant level 0.9 yakni 99.54%. Untuk nilai sensitivitas metode usulan ini menghasilkan nilai sempurna pada semua rangkaian ujicoba sedangkan untuk spesifisitas nilai sempurna didapat pada saat akurasi juga mendapat nilai sempurna yakni pada seleksi fitur t-test dengan nilai significant level 0.1, serta seleksi fitur f-test dengan significant level 0.9 mendapat nilai spesifisitas 0.99. Nilai akurasi terendah untuk metode usulan full neighbour local binary pattern didapat pada saat digunakan metode seleksi fitur f-test dengan nilai significant level 0.7 yakni 91.40% sedangkan untuk metode seleksi fitur t-test akurasi terendah didapat pada significant level 0.5 dan 0.3 yakni 98.64%.

ujicoba menggunakan seleksi fitur menggunakan t-test metode tradisional local binary pattern tidak terdapat akurasi sempurna, nilai tertinggi hanya pada nilai significant level 0.9 yakni dengan akurasi 92.76. Untuk nilai sensitivitas kombinasi ini menghasilkan nilai sempurna pada semua rangkaian ujicoba sedangkan untuk spesifisitas nilai sempurna didapat pada saat akurasi juga mendapat nilai sempurna yakni pada seleksi fitur t-test dengan nilai significant level 0.9 dengan nilai spesifisitas 0.90, serta seleksi fitur f-test dengan significant level 0.1 dengan nilai spesifisitas 0.90. Nilai akurasi terendah untuk local binary pattern didapat pada saat digunakan metode seleksi fitur t-test dengan nilai significant level 0.3 yakni 74.20% . Dari tabel 4 dan tabel 5 didapat fakta bahwa metode usulan tetap mendapatkan rata-rata akurasi yang lebih baik daripada metode local binary pattern tradisional meskipun tanpa dilakukan dekomposisi discrete wavelet transform pada citra mammogram sebelumnya

Tabel 5. Tabel Performa lbp.

Uji	Significant Level	R	TP	TN	FP	FN	Sensitivity	Specificity	Akurasi (%)
T-test	0.9	250	60	145	16	0	1.00	0.90	92.76
	0.7	238	56	145	20	0	1.00	0.87	90.95
	0.5	223	54	145	22	0	1.00	0.86	90.04
	0.3	205	19	145	57	0	1.00	0.71	74.20
	0.1	182	25	145	51	0	1.00	0.73	76.92
F-test	0.9	240	59	145	17	0	1.00	0.89	92.30
	0.7	219	57	145	19	0	1.00	0.88	91.40
	0.5	188	59	145	17	0	1.00	0.89	92.30
	0.3	161	32	145	44	0	1.00	0.76	80.09
	0.1	103	61	145	15	0	1.00	0.90	93.21

V. KESIMPULAN

Metode Berdasarkan aplikasi yang telah dibuat dan hasil yang didapat dari serangkaian uji coba yang telah dilakukan terhadap metode usulan full neighbour local binary pattern (*fnlbp*) dan local binary pattern (*lbp*) tradisional, maka dapat ditarik kesimpulan atas penelitian ini sebagai berikut:

1. Metode usulan mendapatkan rata-rata akurasi yang lebih baik daripada metode *local binary pattern* tradisional baik yang dikombinasi dengan discrete wavelet transform ataupun tidak.
2. Pada histogram hasil ekstraksi *lbp* dapat terlihat bahwa kecenderungan nilai bit histogram yang tinggi adalah 0 dan 255 sedangkan pada histogram hasil *fnlbp* persebaran bit tinggi cukup merata, hal ini membuktikan metode usulan *fnlbp* yang membandingkan semua tetangga dengan sisi vertikal, horizontal maupun diagonal tidak sensitif terhadap noise.
3. Hasil ujicoba pada dua citra yang dirotasi menghasilkan histogram yang sama pada hasil ekstraksi menggunakan *fnlbp* mengindikasikan bahwa metode *fnlbp* invarian terhadap rotasi, sehingga rotasi yang berbeda-beda tidak akan berpengaruh terhadap hasil histogram
4. Dataset hasil ekstraksi fitur *fnlbp* akan memiliki fitur lebih sedikit setelah di seleksi daripada

dataset hasil ekstraksi fitur *lbp*, hal ini disebabkan karena persebaran histogram hasil ekstraksi fitur *lbp* memiliki variasi bit histogram yang terisi lebih tersebar dan banyak daripada histogram hasil ekstraksi fitur menggunakan *fnlbp*.

5. Semakin tinggi nilai significant level maka fitur yang terseleksi akan semakin kecil sehingga hasil akhir fitur akan mendekati fitur awal sebelum dilakukan seleksi fitur, begitu pula sebaliknya semakin rendah nilai significant level maka fitur yang terseleksi akan semakin banyak dan menghasilkan fitur yang dianggap independent lebih sedikit

REFERENSI

- A. Dhawan et al (1996), Analysis of mammographic microcalcifications using greylevel image structure features, IEEE Trans. Med. Imaging 15 (3) 246–259
- Buciu, A. Gacsadi (2011), Directional features for automatic tumor classification of mammogram images, Biomed. Signal Process. Control 6 (4) 370–378.
- E.A. Rashed, I.A. Ismail, S.I. Zaki (2007), Multiresolution mammogram analysis in multilevel decomposition, Pattern Recognit. Lett. 28 (2) 286–292.

- F.Suhandi Krisna (2009), Prediksi Harga Saham dengan Pendekatan Artificial Neural Network menggunakan Algoritma Backpropagation.
- Jianguo Zhang, Kai-Kuang Ma, Meng Hwa Er, Vincent Chong, "Tumor segmentation from magnetic resonance imaging by learning via one-class support vector machine".
- Kaya.Y, Ertugrul.O.F, Taekin.R (2015), Two Novel Local Binary Pattern Descriptor for Texture Analysis, Applied Soft Computing 34 728-735
- Kusumadewi, Sri, 2004, "*Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB & EXCEL LINK*", Graha Ilmu, Yogyakarta
- Matei Mancas, Bernard Gosselin, "Fuzzy Tumor Segmentation based on Iterative Watersheds".
- Mayer., Welsh dan Kowalak, (2011:13). Buku Ajar Patofisiologi. Jakarta: EGC.
- Nugroho, (2011:122). Asuhan Keperawatan. Yogyakarta: Nuha Medika.
- Putra, Darma, (2010) 'Pengolahan Citra Digital'. Yogyakarta, Penerbit Andi
- R. Adollah, M.Y. Mashor, N.F. Mohd Nasir, H. Rosline, H. Mahsin, H. Adilah (2008), "Blood Cell Image Segmentation: A Review", Biomed, Proceedings 21, pp. 141–144, 2008
- Sanae.B, Mounir A.K, Youssef.F (2015), A Hybrid Feature Extraction Scheme Based on DWT and Uniform LBP for Digital Mammograms Classification. International Review on Computer and Software.
- Shan Shen, William Sandham, Malcolm Granat, Annette Sterr (2005), "MRI Fuzzy Segmentation of Brain Tissue Using Neighborhood Attraction With Neural-Network Optimization", IEEE transactions on information technology in biomedicine, vol. 9, no. 3.
- Santoso, Alb. Joko (2011), Wavelet, Diktat Kuliah Pengolahan Citra, Magister Teknik Informatika, Universitas Atmajaya Yogyakarta
- S. Liu, C.F. Babbs, E.J. Delp (2001), Multiresolution detection of spiculated lesions in digital mammograms, IEEE Trans. Image Process. 10 (6) 874–884.
- T. Ahonen, A. Hadid dan M. Pietikainen (2004), "Face Recognition with Local Binary Patterns," Machine Vision Group, Infotech Oulu.
- Yun, S. & Harjoko, A (2011). Deteksi Abnormalitas Pada Citra Mammogram dengan Gray-Level Co-Occurrence Matrix