



TESIS

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

**Januar Adi Putra
NRP. 5115201034**

DOSEN PEMBIMBING

**Dr. Eng.Nanik Suciati, S.Kom.,M.Kom.
NIP: 197104281994122001**

**Arya Yudhi Wijaya, S.Kom.,M.Kom.
NIP: 198409042010121002**

PROGRAM MAGISTER

RUMPUN MATA KULIAH KOMPUTASI CERDAS DAN VISUALISASI

JURUSAN TEKNIK INFORMATIKA

FAKULTAS TEKNOLOGI INFORMASI

INSTITUT TEKNOLOGI SEPULUH NOPEMBER

SURABAYA

2016

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Komputer (M.Kom.)
di
Institut Teknologi Sepuluh Nopember Surabaya

oleh:
Januar Adi Putra
Nrp. 5115201034

Dengan judul :
Ekstraksi Fitur Menggunakan Discrete Wavelet Transform dan Full Neighbour Local Binary
Pattern Untuk Klasifikasi Mammogram

Tanggal Ujian : 5-1-2017
Periode Wisuda : 2016 Gasal

Disetujui oleh:

Dr. Eng. Nanik Suciati, S.Kom, M.Kom
NIP. 197104281994122001

Arya Yudhi Wijaya, S.Kom, M.Kom
NIP. 198409042010121002

Dr. Agus Zainal Arifin, S.Kom, M.Kom
NIP. 197208091995121001

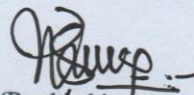
Diana Purwitasari, S.Kom, M.Sc
NIP. 197804102003122001

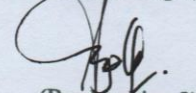
Bilqis Amaliah, S.Kom, M.Kom
NIP. 197509172001122002

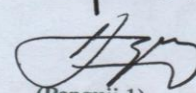
an. Direktur Program Pascasarjana
Asisten Direktur

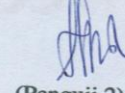
Prof. Dr. Ir. Didi Widjaja, M.Eng.
NIP. 19610211986031001

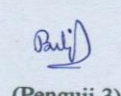



(Pembimbing 1)


(Pembimbing 2)


(Penguji 1)


(Penguji 2)


(Penguji 3)

Direktur Program Pasca Sarjana,

Prof. Ir. Djauhar Manfaat, M.Sc., Ph.D.
NIP. 196012021987011001

Ekstraksi Fitur Menggunakan *Discrete wavelet transform* dan *Full neighbor local binary pattern* Untuk Klasifikasi Mammogram

Nama Mahasiswa : Januar Adi Putra

NRP : 5115201034

Pembimbing : Dr. Eng.Nanik Suciati, S.Kom.,M.Kom.
Arya Yudhi Wijaya, S.Kom.,M.Kom.

ABSTRAK

Saat ini pendeteksian kanker payudara dengan citra mammogram telah banyak dilakukan dengan memanfaatkan pengolahan citra digital. Tahapan dari proses pendeteksian tersebut terdiri dari *preprocessing*, ekstraksi fitur, seleksi fitur dan klasifikasi. Tahapan yang memegang peranan penting untuk menghasilkan sistem deteksi yang akurat adalah tahap ekstraksi fitur. Terdapat beberapa penelitian yang telah dilakukan sebelumnya dengan mengkombinasikan berbagai metode untuk ekstraksi fitur, salah satu yang menghasilkan akurasi terbaik adalah kombinasi *wavelet* dan *local binary pattern*.. Saat ini pengembangan algoritma *local binary pattern* telah banyak dilakukan, salah satunya adalah *neighbor local binary pattern (NLBP)*. Metode tersebut memiliki perbedaan pada arah dan distribusi relasi spasial dari pixel. Meski menghasilkan akurasi yang baik, metode *NLBP* tersebut memiliki beberapa kelemahan yang sama dengan *local binary pattern* tradisional, yakni varian terhadap rotasi dan pada proses *thresholding* pixel sensitif terhadap *noise*.

Pada penelitian ini penulis mengusulkan sebuah metode ekstraksi fitur baru yang didasarkan pada *neighbor 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 neighbor local binary pattern (FNLBP)*. Metode ini nantinya akan dikombinasikan dengan *discrete wavelet transform* untuk ekstraksi fitur dari citra mammogram dengan *classifier* adalah *Backpropagation Neural Network (BPNN)*.

Berdasar ujicoba 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 neighbor local binary pattern* dapat menghasilkan akurasi yang tinggi yakni 92.70% pada saat menggunakan *discrete wavelet transform* dengan seleksi fitur f-test dengan *significant level* 0.9 dan 0.7, sedangkan akurasi terendah yang didapat adalah saat digunakan metode seleksi fitur t-test dengan nilai *significant level* 0.5 pada kombinasi *discrete wavelet transform* dan *full neighbor local binary pattern* yakni 77.08%.

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

[Halaman ini sengaja dikosongkan]

Feature Extraction using *Discrete wavelet transform* and Full Neighbor *Local binary pattern* for Mammogram Classification

Student Name : Januar Adi Putra
NRP : 5115201034
Supervisor : Dr. Eng.Nanik Suciati, S.Kom.,M.Kom.
Arya Yudhi Wijaya, S.Kom.,M.Kom.

ABSTRACT

Currently the detection of breast cancer with a mammogram image has much to do with utilizing digital *image processing*. Stages of the detection process consists of preprocessing, feature extraction, feature selection and classification. Stages which plays an important role to produce an accurate detection system is the feature extraction stage. There are several studies that have been done before by combining various methods for the extraction of features, the one that produces the best accuracy is a combination of wavelet and local binary pattern. Currently the development of *local binary pattern* algorithms have been done, one of which is a neighbor of *local binary pattern* (NLBP). Such methods have differences on the direction and distribution of spatial relationships of pixels. Although it provides good accuracy, NLBP methods have some disadvantages similar to traditional local binary pattern, which is a variant of the rotation and the thresholding of the pixels are sensitive to *noise*.

In this study, the authors propose a new feature extraction method based on local neighbor binary pattern (NLBP). This method has a difference in the direction and distribution relationships spatial pixel, where a comparison between the pixels of the process thresholding not only with neighbors on the right side only, but with all the neighbors were there on the side of the horizontal, vertical and diagonal so the 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 with a classifier 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 high accuracy that is 92.70%, this accuracy is reached when using *discrete wavelet transform* with selection feature method is f-test and the *significant level* is 0.9 and 0.7, while the lowest accuracy obtained are currently when use t-test feature selections method with a value of *significant level* is 0.5 on a combination of *discrete wavelet transform* and full local neighbor binary pattern that is 77.08%.

Keywords: *Feature extraction, local binary pattern, wavelet, mammogram classification*

[Halaman ini sengaja dikosongkan]

KATA PENGANTAR

Segala puji bagi Allah SWT sehingga buku tesis ini dapat diselesaikan dengan baik. Meski dalam menyelesaikan buku ini banyak ditemui kesulitan, namun berkat bantuan dan bimbingan berbagai pihak, akhirnya penulis berhasil menyelesaikan buku ini. Pada kesempatan ini penulis ingin mengucapkan terima kasih kepada pihak-pihak yang membantu penulis dalam penulisan buku tesis ini sebagai berikut.

1. Kepada keluarga penulis yang telah memberikan kasih sayang, pendidikan dan dorongan semasa hidup sehingga penulis dapat memperoleh capaian-capaian saat ini, semoga Allah SWT menghadiahkan surga bagi beliau berdua.
2. Bapak Dr. Waskitho Wibisono, S.Kom., M.Eng. selaku Ketua Program Magister Teknik Informatika yang telah memberi dukungan dan arahan dalam menyelesaikan permasalahan akademik.
3. Kepada Dosen Pembimbing Ibu Dr. Eng.Nanik Suciati, S.Kom.,M.Kom. dan Bapak Arya Yudhi Wijaya, S.Kom.,M.Kom yang telah dengan sabar membimbing, memberikan ilmu, meluangkan waktu dan pikiran dalam proses pengerjaan tesis ini serta membuka wawasan penulis akan luasnya ilmu pengetahuan. Terimakasih banyak atas segala kebaikan bapak dan ibu pembimbing, semoga Allah SWT senantiasa mencurahkan rahmat dan hidayah Nya kepada bapak dan ibu pembimbing.
4. Bapak Dr. Agus Zainal Arifin SKom, MKom, Ibu Diana Purwitasari, S.Kom, M.Sc, dan ibu Bilqis Amaliah,S.Kom., M.Kom.. selaku dosen penguji yang telah banyak memberikan motivasi dan saran yang mendukung terselesaikannya tesis ini.
5. Kepada seluruh dosen S2 Teknik Informatika ITS yang telah memberikan wawasan serta ilmu pengetahuan baru bagi penulis selama menempuh masa studi pascasarjana.
6. Kepada seluruh kawan-kawan S2 Teknik Informatika ITS 2015 yang telah banyak membantu. Semoga apa yang di citakan tercapai dan selalu mendapat kebahagiaan.
7. Kepada Hasa Bella yang selalu menemani dan memberikan semangat hingga terselesaikannya tesis ini.
8. Kepada teman-teman lain yang tidak bisa Penulis sebutkan satu-persatu, terima kasih atas segala bantuan, baik berupa ide, gagasan, pemikiran, atau bahkan sekedar kesediaan mendengarkan keluh kesah Penulis.

Semoga Allah SWT memberikan balasan yang setimpal dan selalu memberikan taufik serta hidayah-Nya bagi semua pihak yang telah banyak memberikan bantuan, bimbingan ataupun nasehat-nasehat. Penulis menyadari bahwa dalam laporan tesis ini masih banyak kekurangannya, karena itu masukan, saran demi perbaikan dan penerapan tesis ini dimasa mendatang tetap penulis harapkan. Semoga tesis ini dapat benar-benar bermanfaat bagi penulis khususnya lebih-lebih pada masyarakat, bangsa dan negara.

Surabaya, Januari 2017

Penulis

DAFTAR ISI

ABSTRAK	iii
ABSTRACT	v
DAFTAR ISI	ixx
DAFTAR GAMBAR	xi
DAFTAR TABEL	xiii
BAB 1 PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Perumusan Masalah	3
1.3. Tujuan	3
1.4. Manfaat	3
1.5. Kontribusi Penelitian	3
1.6. Batasan Masalah	4
BAB 2 KAJIAN PUSTAKA	5
2.1. Kanker Payudara	5
2.2. Pengolahan Citra Digital	6
2.3. 2D Discrete Wavelet	6
2.4. Local Binary Pattern	8
2.5. Backpropagation Neural Network	13
BAB 3 METODOLOGI PENELITIAN	19
3.1. Deteksi dan Pemotongan ROI	20
3.1.1 Penghapusan <i>Black Margin</i>	22
3.1.2 Supresi <i>Artifact</i> dan Pemisahan <i>Background</i>	22
3.1.3 Identifikasi Orientasi	24
3.1.4 Eliminasi Pectoral	24
3.1.5 Deteksi dan Pemotongan Mass (ROI)	25
3.2. <i>Discrete wavelet transform</i>	26
3.3. Full Neighbor Local Binary Pattern	27
3.4. Seleksi Fitur	28
3.5. Klasifikasi	30
3.6. Dataset	30
3.7. Skenario Uji Coba	31

BAB 4 UJI COBA DAN PEMBAHASAN.....	33
4.1 Implementasi	33
4.1.1 Lingkungan Implementasi.....	33
4.1.2 Tahapan Implementasi	33
4.1.3 Implementasi Pemotongan ROI	34
4.1.4 Implementasi Metode Usulan.....	42
4.1.5 Implementasi Feature Selection	43
4.1.6 Implementasi BPNN	44
4.2 Uji Coba dan Hasil	45
4.2.1 Dataset.....	45
4.2.2 Proses pemotongan ROI.....	46
4.2.3 Proses Ekstraksi Fitur.....	46
4.2.4 Uji Coba Invarian Rotasi.....	48
4.2.5 Uji Coba Seleksi Fitur	50
4.2.6 Uji Coba Klasifikasi.....	52
BAB 5 KESIMPULAN DAN SARAN.....	59
5.1 Kesimpulan.....	59
5.2 Saran.....	60
DAFTAR PUSTAKA	61

DAFTAR GAMBAR

Gambar 2.1. Citra mammogram.....	5
Gambar 2.2. Dekomposisi citra.....	7
Gambar 2.3. Proses perhitungan pixel lbp	8
Gambar 2.4. Varian lbp.....	9
Gambar 2.5. Pattern yang termasuk pola <i>uniform</i>	9
Gambar 2.6. Proses perhitungan pixel lbp	10
Gambar 2.7. Pola lbp <i>uniform</i> (p,r)=(8,1)	10
Gambar 2.8. Deskriptor pixel pada dlbp	11
Gambar 2.9. Proses perhitungan pixel dlbp	12
Gambar 2.10. Proses perbandingan pixel pada nlbp	12
Gambar 2.11. Proses perhitungan pixel pada nlbp.....	13
Gambar 3.1. Alur metodologi dan kontribusi penelitian.....	19
Gambar 3.2. Roi citra mammogram.....	20
Gambar 3.3. Alur deteksi dan cropping roi	21
Gambar 3.4. Penghapusan frame hitam	22
Gambar 3.5. Penghapusan objek dan label mengganggu.....	23
Gambar 3.6. Orientasi citra mammogram.....	24
Gambar 3.7. Tahap penghapusan pectoral muscle.....	25
Gambar 3.8. Tahap pemotongan roi.....	26
Gambar 3.9. Proses dekomposisi dwt	26
Gambar 3.10. Contoh proses thresholding pada fnlbp	27
Gambar 3.11. Hasil akhir proses thresholding pada fnlbp	27
Gambar 3.12. Proses circular pattern	28
Gambar 3.13. Hasil circular pattern	28
Gambar 3.14. Algoritma seleksi fitur dengan f-test dan t-test	29
Gambar 3.15. Metode bpnn.....	30
Gambar 3.16. Bagan jenis kanker payudara.....	31
Gambar 3.17. Citra normal.....	31
Gambar 3.18. Citra normal.....	31
Gambar 4.1. Alur deteksi dan cropping roi.....	34
Gambar 4.2. Kode program penghapusan black margin	34
Gambar 4.3. Contoh objek yang mengganggu	35
Gambar 4.4. Kode program supresi artifak	35

Gambar 4.5. Proses supresi artifak.....	36
Gambar 4.6. Proses indentifikasi orientasi payudara	37
Gambar 4.7. Kode program indentifikasi orientasi	38
Gambar 4.8. Kode program eliminasi pectoral	39
Gambar 4.9. Citra hasil deteksi letak pectoral.....	40
Gambar 4.10. Citra hasil threshold.....	41
Gambar 4.11. Citra eliminasi pectoral	41
Gambar 4.12. Kode program deteksi mass.....	41
Gambar 4.13. Kode program pemotongan mass	42
Gambar 4.14. Kode program circular pattern.....	43
Gambar 4.15. Kode program feature selection.....	44
Gambar 4.16. Kode program bpnn.....	45
Gambar 4.17. Hasil eksekusi program roi cropping.....	46
Gambar 4.18. Hasil histogram local binary pattern.....	48
Gambar 4.19. Hasil histogram <i>full neighbor local binary pattern</i>	47
Gambar 4.20. Citra mammogram awal	48
Gambar 4.21. Citra mammogram dirotasi.....	48
Gambar 4.22. Hasil histogram lbp	49
Gambar 4.23. Hasil histogram fnlbp	49
Gambar 4.24. Simulasi ekstraksi dan seleksi fitur.....	51

DAFTAR TABEL

Tabel 4.1. Hasil seleksi fitur.....	51
Tabel 4.2. Tabel pembagian data	52
Tabel 4.3. Tabel performa dwt+fmlbp	53
Tabel 4.4. Tabel performa dwt+lbp.....	54
Tabel 4.5. Tabel performa fmlbp.....	55
Tabel 4.6. Tabel performa lbp	56
Tabel 4.7. Tabel konsumsi waktu ekstraksi fitur.....	57
Tabel 4.8. Tabel konsumsi waktu klasifikasi	57

[Halaman ini sengaja dikosongkan]

BAB 1

PENDAHULUAN

Pada bab ini dijelaskan mengenai beberapa hal dasar dalam pembuatan buku tesis penelitian ini yang meliputi latar belakang, perumusan masalah, tujuan, manfaat, kontribusi penelitian, dan batasan masalah.

1.1 Latar Belakang

Kanker payudara adalah salah satu penyakit yang paling ditakuti oleh kaum wanita. 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.

Konsep dari *local binary pattern* adalah dengan membandingkan setiap pixel dengan pixel tetangga yang mengelilingi pixel tersebut. Salah satu kelebihan dari *local binary pattern* adalah sifatnya yang invarian terhadap perubahan fotometri dari objek yang sama karena merupakan ukuran intensitas relatif suatu pixel dengan intensitas pixel di sekitarnya. Saat ini pengembangan algoritma *local binary pattern* telah banyak dilakukan, Kaya dkk (2015) mengusulkan dua pengembangan baru dari *local binary pattern* yakni *neighbor local binary pattern (NLBP)* dan *directional binary pattern (dLBP)*. Dua metode baru tersebut memiliki perbedaan pada arah dan distribusi relasi spasial dari pixel.

Pada *neighbor 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* tradisional. Meski menghasilkan akurasi yang baik dua metode baru tersebut memiliki beberapa kelemahan yang sama dengan *local binary pattern* tradisional, yakni histogram yang dihasilkan sensitif terhadap rotasi dan pada proses *thresholding* pixel sensitif terhadap *noise*.

Berdasar uraian yang telah dijelaskan penulis mengusulkan sebuah metode ekstraksi fitur baru yang didasarkan pada *neighbor local binary pattern (NLBP)*. Metode ini memiliki perbedaan pada arah dan distribusi relasi spasial dari pixel, dimana perbandingan antar pixel pada proses *thresholding* 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 neighbor 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. Metode ini nantinya akan dikombinasikan dengan *discrete wavelet transform* untuk ekstraksi fitur dari citra mammogram dengan *classifier* adalah *Backpropagation Neural Network (BPNN)*.

1.2 Perumusan Masalah

Rumusan masalah yang diangkat dalam penelitian ini adalah sebagai berikut.

1. Bagaimana mengekstraksi fitur menggunakan *full neighbor local binary pattern (FNLBP)* ?
2. Bagaimana mengekstraksi fitur citra hasil dekomposisi *discrete wavelet transform* dengan *FNLBP* ?
3. Bagaimana menseleksi fitur citra mammogram dengan *two sample F-test* dan *T-test* ?
4. Bagaimana mengklasifikasikan citra mammogram menggunakan *Backpropagation Neural Network*?

1.3 Tujuan

Tujuan penelitian ini adalah melakukan klasifikasi kanker payudara pada citra mamogram menggunakan metode ekstraksi fitur baru yakni *full neighbor local binary pattern* yang insensitif terhadap *noise* dan invarian terhadap rotasi serta dikombinasi dengan *discrete wavelet transform*.

1.4 Manfaat

Penelitian ini diharapkan dapat menjadi solusi bagi tenaga medis ataupun radiologis dalam melakukan diagnosis kanker payudara secara akurat menggunakan mammogram yang memiliki banyak *noise*.

1.5 Kontribusi Penelitian

Kontribusi penelitian ini adalah menghasilkan sebuah metode ekstraksi fitur baru yang invarian terhadap rotasi dan insensitif terhadap *noise* yang disebut *FNLBP*. *FNLBP* ini nantinya akan digunakan untuk mengekstraksi fitur citra hasil dekomposisi *discrete wavelet transform*, kombinasi ini diharapkan akan meningkatkan akurasi pada klasifikasi kanker payudara menggunakan *backpropagation neural network*.

1.6 Batasan Masalah

Batasan masalah pada penelitian ini adalah:

1. Data yang digunakan adalah citra *grayscale* mammogram yang didapat dari *Mammographic Image Analysis Society* (MIAS) dan DDSM.
2. Kelas klasifikasi citra adalah normal (208 citra) dan abnormal (109 citra)
3. Jenis citra kanker payudara yang digunakan adalah tipe *mass*.


BAB 2

KAJIAN PUSTAKA

Pada bab ini dijelaskan tentang pustaka yang terkait dengan landasan penelitian. Pustaka yang terkait adalah seputar kanker payudara, pengolahan citra digital, *discrete wavelet transform*, *local binary pattern*, dan *backpropagation*.

2.1 Kanker Payudara

Kanker juga disebut *neoplasia malignan* yang merupakan jenis penyakit yang ditandai oleh kerusakan DNA sehingga tumbuh kembang sel tidak berlangsung normal. Sel kanker ini memiliki dua buah ciri khas, yaitu yang pertama adalah sel-sel kanker tidak mampu membelah dan melakukan diferensiasi dengan cara yang normal, dan kedua, sel-sel kanker memiliki kemampuan menginvasi jaringan sekitarnya serta bermetastasis ke tempat yang jauh. Di seluruh dunia jenis kanker yang paling sering ditemui meliputi kanker pada sistem reproduksi, leukemia, limfoma, kanker payudara, dan lainnya. Kanker payudara didefinisikan sebagai suatu penyakit neoplasma ganas yang berasal dari *parenchyma*. Penyakit ini oleh WHO dimasukkan ke dalam *International Classification of Diseases (ICD)* dengan kode nomer 17 (Mayer dkk & Nugroho, 2011). 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 2.1.



Gambar 2.1. Citra mammogram.

2.2 Pengolahan Citra Digital

Pengolahan citra digital adalah pemrosesan citra menjadi citra yang lain dengan kualitas yang lebih baik, yaitu pemrosesan pada usaha untuk memanipulasi. Citra yang telah menjadi gambar lain menggunakan algoritma atau teknik tertentu. Pengolahan citra mempunyai beberapa tujuan yaitu:

1. Proses memperbaiki kualitas citra agar mudah diinterpretasikan oleh manusia atau komputer.
2. Teknik pengolahan citra dengan mentransformasikan citra menjadi citra lain.
3. Pengolahan citra merupakan proses awal dari komputer vision.

Pada umumnya pengolahan citra berhubungan dengan citra-citra digital. Dalam hal ini, citra $f(x,y)$ diperoleh secara diskrit dan kemudian dikuantisasi. Maka akan diperoleh suatu citra baru yakni citra $(m,n) \rightarrow I$ dengan $m,n \in I$; di mana I adalah himpunan bilangan bulat (integer). Namun demikian, secara umum sistem pengolahan citra mengandalkan citra asal yang bernilai real dan menghasilkan bilangan real juga, meskipun secara teknis pada akhirnya citra ini didigitalkan sebelum disimpan. Ada beberapa hal yang penting didalam pengolahan citra digital, antara lain teknik-teknik pengambilan citra, model citra digital, sampling dan kuantisasi, histogram, proses filtering, perbaikan citra sampai pada pengolahan citra digital yang lebih lanjut seperti segmentasi, image clustering dan ekstraksi ciri.

2.3 Discrete Wavelet Transform


Dalam proses ekstraksi ciri dilakukan transformasi citra untuk mendapatkan informasi yang lebih jelas yang terkandung dalam citra tersebut. Transformasi atau alih ragam citra pada bagian ini adalah perubahan tuang (domain) citra ke domain lainnya. Melalui proses transformasi, citra dapat dinyatakan sebagai kombinasi linear dari sinyal dasar (*basic signals*) yang sering disebut dengan fungsi basis (Putra, 2010).

Wavelet diartikan sebagai *small wave* atau gelombang singkat. Transformasi wavelet akan mengkonversi suatu sinyal ke dalam sederetan wavelet. Gelombang singkat tersebut merupakan fungsi yang terletak pada waktu berbeda. Transformasi wavelet mampu memberikan informasi frekuensi yang muncul dan memberikan

informasi tentang skala atau durasi atau waktu. Wavelet dapat digunakan untuk menganalisa suatu bentuk gelombang (sinyal) sebagai kombinasi dari waktu (skala) dan frekuensi.

Proses transformasi pada wavelet dapat dicontohkan sebagai berikut, citra yang semula ditransformasikan dibagi (didekomposisi) menjadi empat sub-citra baru untuk menggantikannya. Setiap sub-citra berukuran sepertiga kali dari citra asli. Tiga sub-citra pada posisi kanan atas, kanan bawah, dan kiri bawah akan tampak seperti versi kasar dari citra asli karena berisi komponen frekuensi tinggi dari citra asli. Sedangkan untuk sub-citra pada posisi kiri atas tampak seperti citra asli dan lebih halus, karena berisi komponen frekuensi rendah dari citra asli. Sub-citra pada bagian kiri atas (frekuensi rendah) tersebut dibagi lagi menjadi empat sub-citra baru. Proses diulang sesuai dengan level transformasi yang digunakan. Pembagian citra ditunjukkan pada Gambar 2.2 (Santoso & Joko, 2011).

Pada citra 2 dimensi, terdapat dua cara untuk mentransformasi atau mendekomposisi nilai-nilai pixelnya, yaitu dekomposisi standar dan tak standar. Keduanya diperoleh berdasarkan transformasi wavelet 1 dimensi. Dekomposisi standar menggunakan transformasi wavelet 1 dimensi pada tiap baris citra dan kemudian pada tiap kolom. Dekomposisi tak standar diperoleh dengan mengkombinasikan pasangan transformasi baris dan transformasi kolom secara bergantian. Pada langkah pertama diterapkan transformasi wavelet 1 dimensi pada kolom, proses tersebut diulang dengan level yang diinginkan.



Gambar 2.2 Dekomposisi Citra.

Nilai pixel	Setelah Threshold	Weight
6 5 2	1 0 0	32 64 128
7 6 1	1 0 0	16 4 1
9 8 7	1 1 1	8 4 2
Pattern	= 01111100	
LBP	= 2+4+8+16+32	

Gambar 2.3 Proses perhitungan pixel LBP.


2.4 Local Binary Pattern

Operator LBP adalah salah satu deskriptor tekstur terbaik dan telah banyak digunakan dalam berbagai aplikasi. LBP telah terbukti sangat diskriminatif dan keuntungan utamanya, yaitu variasi untuk perubahan tingkat abu-abu monoton dan efisiensi komputasi, membuatnya cocok untuk tugas gambar menuntut analisis. Ide untuk menggunakan LBP untuk deskripsi wajah didukung oleh fakta wajah dapat dilihat sebagai komposisi pola mikro yang dapat dijelaskan oleh sebuah operator.

Local binary pattern (LBP) didefinisikan sebagai ukuran tekstur gray-scale invarian, berasal dari definisi umum tekstur di daerah sekitar. Operator LBP dapat dilihat sebagai pendekatan kesatuan dengan model statistik dan struktur tradisional berbeda dari analisis tekstur. 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). Contoh komputasi LBP pada 3x3 pixel ditunjukkan oleh Gambar 2.3.


Setiap pixel memiliki nilai hasil grayscale, kemudian dilakukan threshold berpusat pada titik tengah. Pixel yang memiliki nilai sama atau lebih dibandingkan dengan titik tengah diberi nilai 1 selain itu diberi nilai 0. Kemudian nilai LBP didapat dari penjumlahan dua pangkat nilai angka yang bernilai satu. Persamaan LBP dapat dilihat pada persamaan (2.1).

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad s(x) = \begin{cases} 1, & \text{if } x \geq 0; \\ 0, & \text{otherwise.} \end{cases} \quad (2.1)$$

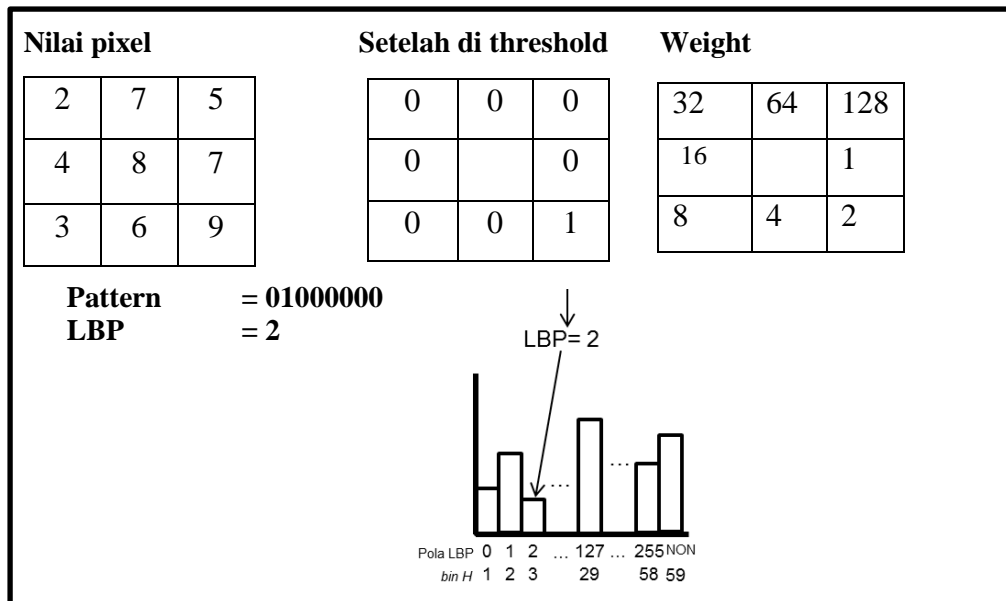


Gambar 2.4 Varian LBP.

Operator pada LBP memiliki label yang ditandai dengan P dan R. P mewakili jumlah pixel tetangga yang digunakan dalam komputasi sementara R adalah radius antara pixel titik pusat dan pixel tetangga, seperti terlihat pada Gambar 2.4. Dalam aplikasi analisis tekstur banyak diinginkan untuk memiliki fitur yang invarian atau kuat untuk rotasi gambar input. Sebagai LBP, pola (P, R) diperoleh dengan sirkuler sampel sekitar pixel pusat, rotasi gambar input memiliki dua efek: setiap lingkungan lokal diputar ke lokasi pixel lainnya, dan dalam masing-masing lingkungan, titik sampling pada lingkaran yang mengelilingi titik pusat diputar ke orientasi yang berbeda. Operator asli LBP dikembangkan menjadi LBP *uniform* (Ojala, 2002). LBP *uniform* hanya akan mengambil fitur yang memiliki nilai U maksimal 2. Maksud dari nilai U maksimal 2 ($U \geq 2$) adalah bahwa pergantian pola bit 0/1 atau 1/0 pada deret kode hanya terjadi maksimal dua kali. Misalnya pada kode 00000000 pergantian piksel 0/1 atau 1/0 tidak terjadi sehingga nilai U untuk kode tersebut adalah 0. Namun pada deret kode 01111000 terjadi dua kali pergantian bit 0/1 atau 1/0 sehingga nilai U dari kode tersebut adalah 2. Contoh kode biner yang termasuk pola *uniform* dapat dilihat pada Gambar 2.5. Jika pada LBP fitur yang dihasilkan berjumlah 256-bin histogram, maka fitur yang dihasilkan dari LBP *uniform* adalah 59-bin histogram. Ilustrasi perhitungan LBP dan pembentukan histogram LBP *uniform* ditunjukkan pada Gambar 2.6.




Gambar 2.5 Pattern yang termasuk pola *uniform*.



Gambar 2.6 Proses perhitungan pixel LBP.

Pada histogram, pola *uniform* akan diletakkan pada bin yang berbeda dan pola yang tidak *uniform* akan digabung pada bin terakhir (*bin 59*). Pola LBP *uniform* tertentu didefinisikan dengan $U_p(n,r)$. Pasangan (n,r) menunjukkan pola yang *uniform* sehingga n adalah jumlah 1-bit dalam pola (ditunjukkan nomor baris pada Gambar 2.7) dan r adalah rotasi pola (nomor kolom pada Gambar 2.7).




Gambar 2.7 Pola LBP *uniform* dengan $(P,R)=(8,1)$ (Ahonen, 2009).

Saat ini metode LBP tradisional telah banyak dikembangkan untuk menutupi kelemahan-kelemahan yang ada. Kaya dkk (2015) mengusulkan dua pengembangan baru dari *local binary pattern* yakni *directional binary pattern* (dLBP) dan *neighbor local binary pattern* (NLBP), dLBP akan dibahas pada sub bab 2.4.1 sedangkan NLBP akan dijelaskan pada sub bab 2.4.2.

2.4.1 Directional Local Binary Pattern

Pada metode ini deskriptor pada proses perbandingan untuk thresholding tidak lagi sesuai dengan box matrik, melainkan deskriptor tersebut adalah pixel tetangga dari pixel pusat (pc) yang telah ditentukan derajat kemiringannya baik itu 0° , 45° , 90° ataupun 135° . Proses perbandingan dan proses-proses selanjutnya sama dengan proses pada LBP tradisional. Deskriptor 8 tetangga, $P = \{ P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7 \}$ pada metode ini dapat dilihat pada Gambar 2.8.

Pada metode *directional local binary pattern* ukuran box matrix citra minimal adalah 9×9 pixel hal ini disebabkan karena deskriptor akan dimulai dari ujung sesuai arah yang telah ditentukan. Adapun contoh komputasi dLBP menggunakan derajat kemiringan 0° ditunjukkan pada Gambar 2.9.



Gambar 2.8 deskriptor pixel pada dLBP.

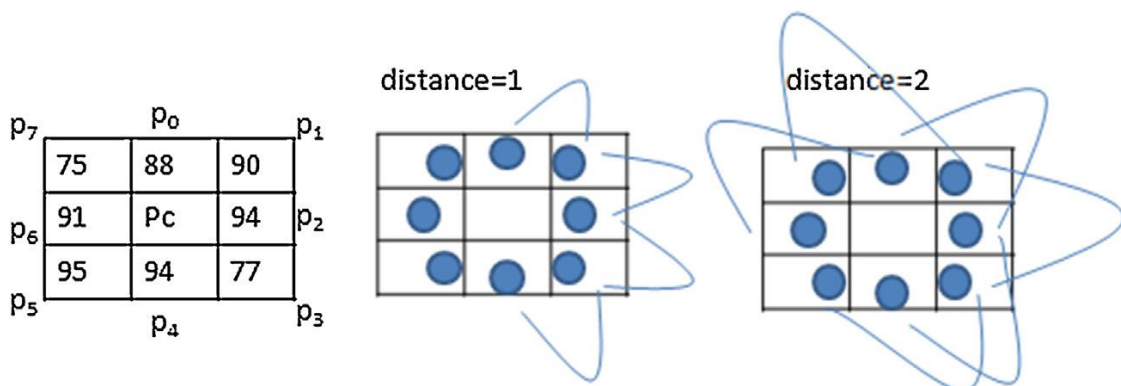
Nilai pixel									Hasil Thresholding									
129	158	150	134	150	165	162	160	169										
103	150	164	136	134	181	191	172	155										
108	141	155	155	143	157	171	167	174										
129	145	186	196	162	212	241	222	209										
119	146	177	181	210	241	255	255	217	0	0	0	0	PC	1	1	1	1	
91	129	172	157	153	165	207	253	250										
98	121	146	160	145	150	188	171	174										
103	138	134	133	146	140	143	129	146										
117	117	100	103	167	155	134	141	162										

Pattern = 11110000
dLBP = 1+2+4+8

Gambar 2.9 Proses perhitungan pixel dLBP dengan $\alpha=0^\circ$.

2.4.2 Neighbor 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 sebelah lainnya 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 2.10.



Gambar 2.10 Proses perbandingan pixel pada NLBP.

Nilai pixel				Setelah di threshold			Weight		
18	22	28	Sensitif noise	0	0	0	32	64	128
19	20	255		1		1	16		1
0	15	21		0	1	1	8	4	2
Pattern		= 11101000							
NLBP		= 1+2+4+16							

Gambar 2.11 Proses perhitungan pixel NLBP.

Meski menghasilkan akurasi yang baik NLBP melakukan proses *thresholding* dengan hanya membandingkan pixel terhadap tetangga disebelah kanannya saja sehingga akan berakibat proses *threshold* menjadi sensitif terhadap *noise*. Contoh proses *threshold* menggunakan NLBP dapat dilihat pada Gambar 2.11. Dapat dilihat pada pixel (3,1) dengan nilai 28 menghasilkan nilai *threshold* 0 padahal nilai pixel tersebut lebih besar dari pixel-pixel tetangganya ataupun dengan pixel pusat. Hal ini terjadi karena pixel tersebut hanya dibandingkan dengan *noise* yang nilainya nilai 255.

2.5 Backpropagation Neural Network

Algoritma *backpropagation* merupakan bagian dari algoritma pembelajaran terawasi yang biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyi. Algoritma ini menggunakan error keluaran untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan error ini tahap perambatan maju (*forward propagation*) harus dikerjakan terlebih dahulu. Saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi yang dapat dideferensiasikan seperti berikut (Kusumadewi, 2004):

Sigmoid pada persamaan 2.2 dan 2.3 :

$$y = f(x) = \frac{1}{1+e^{-ox}} \quad (2.2)$$

$$f(x) = \sigma f(x)[1 - f(x)] \quad (2.3)$$

Tangent sigmoid dengan Persamaan 2.4 dan 2.5:

$$y = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$

$$f(x) = [1 + f(x)][1 - f(x)] \quad (2.5)$$

Pelatihan Backpropagation dilakukan melalui langkah-langkah berikut ini :

Langkah ke-0 : Inisialisasi bobot;

Langkah ke-1 : Selama kondisi berhenti bernilai salah, kerjakan langkah 2-9;

Langkah ke-2 : Untuk setiap data training, lakukan langkah 3-8. Umpan maju (Feedforward)

Langkah ke-3 : Setiap unit input ($X_i, i = 1, \dots, n$) menerima sinyal input x_i dan menyebarkan sinyal tersebut ke seluruh unit tersembunyi.

Langkah ke-4 : Pada setiap unit tersembunyi ($Z_j, j = 1, \dots, p$), menjumlahkan sinyal-sinyal input yang sudah berbobot (termasuk biasanya) seperti terlihat pada Persamaan 2.6.

$$z_{in_j} = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (2.6)$$

Lalu menghitung sinyal *output* dari unit tersembunyi dengan menggunakan fungsi aktivasi yang telah ditentukan seperti pada Persamaan 2.7 :

$$z_j = f(z_{in_j}) \quad (2.7)$$

Sinyal *output* ini selanjutnya dikirim ke seluruh unit pada unit atas (unit *output*).

Langkah ke-5 : Tiap-tiap unit *output* ($Y, k = 1, \dots, m$), menjumlahkan bobot sinyal input dengan menggunakan Persamaan 2.8 :

$$y_{in_k} = w_{ok} + \sum_{i=1}^n z_i w_{jk} \quad (2.8)$$

Kemudian menghitung sinyal output dari unit output bersangkutan dengan menggunakan fungsi aktivasi yang telah ditentukan, seperti pada Persamaan 2.9.

$$y_k = f(y_{in_k}) \quad (2.9)$$

Sinyal *output* ini selanjutnya dikirim ke seluruh unit pada *output*.

Umpan Mundur / Propagasi Error (*Backpropagation of Error*)

Langkah ke-6 : Setiap unit output (Y_k , $K= 1, \dots, m$) menerima suatu pola target yang sesuai dengan pola input pelatihan, untuk menghitung kesalahan (error) antara target dengan output yang dihasilkan jaringan digunakan Persamaan 2.10

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (2.10)$$

Faktor δ_k digunakan untuk menghitung koreksi error (Δw_{jk}) yang nantinya akan dipakai untuk memperbaiki w_{jk} . Dimana koreksi error didapat menggunakan persamaan 2.11.

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (2.11)$$

Selain itu juga dihitung koreksi bias Δw_{0k} yang nantinya akan dipakai untuk memperbaiki w_{0k} , dimana Δw_{0k} dapat dihitung menggunakan Persamaan 2.12.

$$\Delta w_{0k} = \alpha \delta_k \quad (2.12)$$

Faktor δ_k kemudian dikirimkan ke lapisan yang berada pada langkah-7.

Langkah ke-7 : Setiap unit tersembunyi (Z_j , $j = 1, \dots, p$) menerima input delta (dari langkah ke-6) yang sudah berbobot dan digunakan Persamaan 2.13.

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (2.13)$$

Kemudian hasilnya dikalikan dengan turunan dari fungsi aktivasi yang digunakan jaringan untuk menghitung informasi kesalahan error δ_j , dimana untuk menghitung error δ_j digunakan Persamaan 2.14.

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (2.14)$$

Kemudian menghitung koreksi bobot dengan Persamaan 2.15.

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (2.15)$$

Setelah itu hitung koreksi bias (digunakan untuk memperbaiki v_{0j}) dengan Persamaan 2.16.

$$\Delta v_{0j} = \alpha \delta_j \quad (2.16)$$

Update bobot dan Bias (*Adjustment*)

Langkah ke-8 : Setiap unit output (Y_k , $k = 1, \dots, m$) memperbaiki bobot dan bias dari setiap unit tersembunyi ($j = 0, \dots, p$) seperti terlihat pada Persamaan 2.17.

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (2.17)$$

Demikian pula untuk setiap unit tersembunyi (z_j , $j = 1, \dots, p$) akan memperbaharui bobot dan bias dari setiap unit input ($i = 0, \dots, n$) seperti terlihat pada Persamaan 2.18.

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{jk} \quad (2.18)$$

Langkah ke-9 : Tes kondisi apabila error ditemukan, jika kondisi STOP telah terpenuhi maka pelatihan jaringan dapat dihentikan. Untuk memeriksa kondisi STOP biasanya digunakan kriteria MSE (*Mean Square Error*) seperti pada Persamaan 2.19.

$$mse = 0.5 \times \{(t_{k1} - y_{k1})^2 + (t_{k2} - y_{k2})^2 + \dots + (t_{kn} - y_{kn})^2\} \quad (2.19)$$

Pengujian Backpropagation

Pengujian *Backpropagation* dilakukan melalui *feedforward* adapun langkah-langkahnya adalah sebagai berikut:

Langkah-0 : inisialisasikan bobot (dari hasil pelatihan).

Langkah-1 : untuk setiap vektor input, kerjakan langkah 2 sampai 4.

Langkah-2 : untuk $i=1\dots n$:set aktivasi unit input x_i .

Langkah-3 : untuk $j=1\dots p$:

$$z_{inj} = v_{0j} + \sum_i x_i v_{ij} \quad (2.20)$$

$$z_j = f(z_{inj}) \quad (2.21)$$

Langkah-4 : untuk $k=1\dots m$:


$$y_{ink} = w_{0j} + \sum_i z_i w_{jk} \quad (2.22)$$

$$y_k = f(y_{ink}) \quad (2.23)$$

[Halaman ini sengaja dikosongkan]

BAB 3

METODOLOGI PENELITIAN



Gambar 3.1 Alur Metodologi dan Kontribusi Penelitian.

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 3.1. Tahapan penelitian yang akan dilakukan terdiri dari lima tahapan utama yakni deteksi dan pemotongan ROI yang berfungsi untuk mengambil objek penting pada citra, ekstraksi fitur yang meliputi dekomposisi citra dengan *Discrete Wavelete Transform* kemudian dilanjutkan FNLBP, seleksi fitur dengan metode statistik *T-test* dan *F-test* dan yang terakhir adalah klasifikasi dengan metode *Backpropagation*. *T-test* dan *F-test* merupakan metode statistik untuk uji perbandingan (uji komparatif), tujuan dari uji ini adalah untuk membandingkan (membedakan) apakah sebuah fitur (variabel) memiliki data yang mirip atau berbeda.


T-test dikenal dengan uji parsial, yaitu untuk menguji bagaimana pengaruh masing-masing variabel bebasnya secara sendiri-sendiri terhadap variabel terikatnya, sedangkan *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.

Backpropagation merupakan sebuah metode sistematis pada jaringan saraf tiruan dengan menggunakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh perceptron dengan banyak layer lapisan untuk mengubah bobot-bobot yang ada pada lapisan tersembunyinya. (F.Suhandi, 2009). Penjelasan tahapan metode penelitian pada Gambar 3.1 akan diterangkan secara terperinci pada subbab selanjutnya.

3.1. Deteksi dan Pemotongan ROI


Image processing terdiri dari lima tahap: akuisisi, *preprocessing*, segmentasi, *post-processing*, dan analisa. Tujuan utama dari *image processing* di instrumentasi biomedis adalah untuk mengumpulkan informasi, screening atau invertigasi, mendiagnosis, terapi dan kontrol, serta monitoring dan evaluasi (R. Adollah dkk, 2008). Segmentasi memegang peranan yang sangat penting dengan memfasilitasi penggambaran daerah yang penting dalam suatu citra atau disebut sebagai region of interest (ROI) (Mancas dkk & Shen dkk, 2005).

Segmentasi merupakan proses partisi gambar digital ke beberapa daerah dengan tujuan untuk menyederhanakan ataupun merubah representasi gambar menjadi sesuatu yang lebih bermakna dan mudah dianalisa (R. Abdollah dkk, 2008). 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 3.2.



Gambar 3.2 ROI citra mammogram.

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 3.3. Tahapan-tahapan akan dijelaskan secara terperinci pada sub-bab berikutnya.



Gambar 3.3 Alur deteksi dan *cropping* ROI.



Gambar 3.4 Penghapusan frame hitam.

3.1.1 Penghapusan *Black Margin*

Tahap ini merupakan tahap untuk menghilangkan pinggiran hitam pada citra mammogram. Frame hitam pada pinggiran citra harus dihilangkan untuk mempermudah pada proses segmentasi. Proses penghapusan black margin dapat dilihat pada Gambar 3.4. Ada tiga tahapan utama dalam penghapusan black margin ini yakni:


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

3.1.2 Supresi *Artifact* dan Pemisahan *Background*


Tahapan ini bermaksud untuk menghilangkan objek-objek dalam citra yang mengganggu proses klasifikasi. Penghapusan objek-objek tersebut menggunakan operasi morfologi dalam pengolahan citra digital. Operasi morfologi yang digunakan adalah opening dimana dengan operasi ini objek-objek kecil selain citra payudara akan dihapuskan. Proses artifact suppression ini dapat dilihat pada Gambar 3.5. 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 3.5b, kemudian semua objek dilabeli menggunakan fungsi *bwlabel* pada MATLAB.
2. Area (ukuran sebenarnya dari daerah pixel) dari semua objek pada Gambar 3.5b akan dikalkulasi menggunakan fungsi *regionprops* pada MATLAB.

3. Dari semua objek biner pada citra mammogram (Gambar 3.5a), Objek yang memiliki area terbesar (Gambar 3.5c) 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.
4. Operasi *morphological* untuk memperkecil distorsi dan menghapus pixel yang terisolasi diaplikasikan ke citra biner mammogram menggunakan fungsi *bwmorph* pada MATLAB dengan parameter 'clean'.
5. 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'.
6. Citra biner mammogram di erosi menggunakan fungsi *strel* dan *imerode*, dimana radius dari fungsi *strel* adalah $R=5$.
7. Citra biner mammogram di dilasi menggunakan fungsi *imdilation* pada MATLAB.
8. Lubang pada citra biner mammogram diisi dengan menggunakan fungsi *imfill* pada MATLAB dengan parameter 'holes'.
9. 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 3.5d.



Gambar 3.5 Penghapusan objek dan label yang mengganggu.



Gambar 3.6 Orientasi citra mammogram.

3.1.3 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 kekiri 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 3.6.

3.1.4 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 3.7. 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*.

3.1.5 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 3.8.




Gambar 3.7 Tahap penghapusan *pectoral muscle*.



Gambar 3.8 Tahap pemotongan ROI.

3.2. *Discrete wavelet transform*

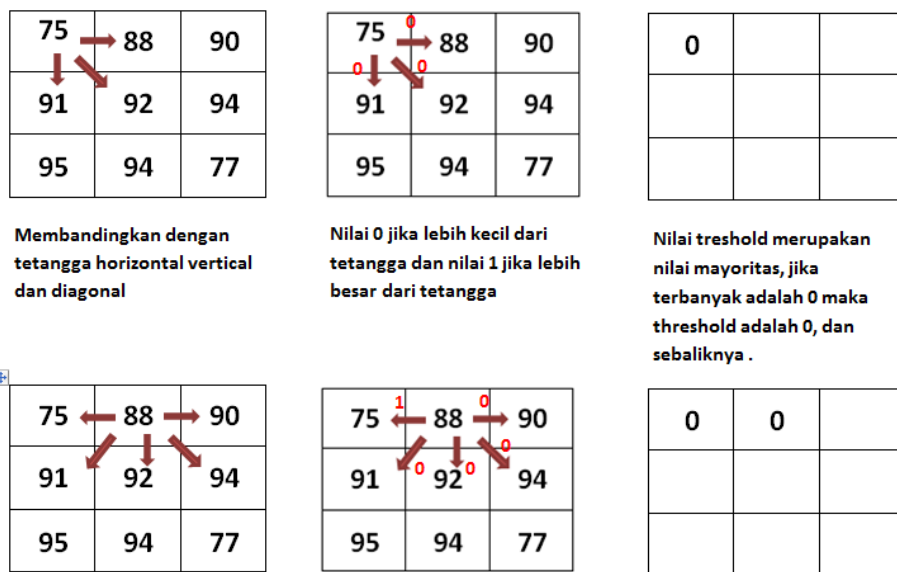
Ekstraksi fitur dari citra mamogram dilakukan dengan mengkombinasikan dua metode yakni 2D-DWT dan FNLBP. DWT dapat digunakan untuk transformasi citra, proses transformasi wavelet yang dilakukan secara konsep cukup sederhana. Citra semula yang ditransformasi dibagi (didekomposisi) menjadi 4 sub-citra 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*) 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 3.9.



Gambar 3.9 a) Proses dekomposisi DWT 2 level b) Original ROI c) Hasil DWT terhadap ROI.

3.3. 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 tetangga di bagian kanan saja melainkan dengan semua tetangga yang ada pada sisi *horizontal*, *vertical* dan *diagonal* sehingga metode tersebut disebut *full neighbor 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 3.10. Proses *thresholding* dilakukan pada semua piksel pada box matrik yang ada, sehingga menghasilkan seperti pada gambar 3.11.




Gambar 3.10 Contoh proses *thresholding* pada FNLBP.

Hasil akhir Thresholding

0	0	0
0		1
1	1	0

Gambar 3.11 hasil akhir proses *thresholding* pada FNLBP.



Gambar 3.12 Proses circular pattern.

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										

Gambar 3.13 Hasil circular pattern.

Dari Gambar 3.11 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 dilihat pada Gambar 3.12.

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 seperti pada LBP tradisional. Histogram akhir merupakan nilai terkecil dari hasil perkalian tersebut. Contoh kombinasi pattern yang didapat dapat dilihat pada Gambar 3.13.

3.4. Seleksi Fitur

Seleksi fitur adalah salah satu tahapan sebelum proses klasifikasi dilakukan. Seleksi fitur dilakukan dengan cara memilih fitur-fitur yang relevan yang mempengaruhi hasil klasifikasi. 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. 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 3.14.


```

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 v1 dan v2
2: inisialisasi α, 0 < α < 1
3: for i=1 sampai M, lakukan
4:   Kosongkan isi dari vector v1 dan v2
5:   for j=1 sampai N, lakukan
6:     if kelas_target[j]=1, then
7:       tambahkan fitur_matrik[i,j] ke v1
8:     else
9:       tambahkan fitur_matrik[i,j] ke v2
10:    end if
11:  end for
12:  h1[i] = ttest(v1, v2, α)
13:  h2[i] = vartest(v1, v2, α)
14:  for k=1 sampai 2, lakukan
15:    if hk[i] = 1, then
16:      tambahkan fitur_matrik[i, 1:N] ke fitur_terpilihk
17:    end if
18:  end for
19: end for

```

Gambar 3.14 Algoritma seleksi fitur dengan F-test dan T-test.




Gambar 3.15 Metode BPNN.

3.5. Klasifikasi


Pada tahap ini dilakukan proses klasifikasi dengan menggunakan metode *Backpropagation Neural Network* (BPNN) dengan node *hidden layer* yakni 15. Sebagai node pada input layer adalah hasil fitur-fitur yang telah diseleksi pada tahap sebelumnya yakni tahapan seleksi fitur, adapun jumlah node input layer tidak dapat ditentukan dan dipengaruhi oleh *significant level* pada t-test dan f-test. Terdapat dua node pada output layer yakni normal dan abnormal. Proses metode klasifikasi menggunakan BPNN dapat dilihat pada Gambar 3.15.

3.6. Dataset

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. Terdapat beberapa jenis kanker payudara (J. Suckling, S. Astley, dkk, 2005) berdasarkan bentuk dan penyebarannya, jenis-jenis tersebut dapat dilihat pada Gambar 3.16. Jenis kanker payudara yang digunakan sebagai ujicoba adalah tipe *mass*, hal ini dikarenakan tipe *mass* memiliki resiko teridentifikasi kanker payudara lebih tinggi daripada yang lainnya (Rana dkk, 2008). Contoh citra mammogram normal ditunjukkan pada Gambar 3.17 dan citra abnormal Gambar 3.18.



Gambar 3.16 Bagan jenis kanker payudara.



Gambar 3.17 Citra normal .



Gambar 3.18 Citra abnormal .

3.7. Skenario Uji Coba

Uji coba dilakukan akan dilakukan dengan perbandingan metode penggabungan wavelet dan LBP dengan wavelet dan FNLBP dimana data *training* dan *testing* dipilih secara random. Parameter pengujian yang digunakan adalah:

1. *Significant level* pada T-test.
2. *Significant level* pada F-test.

Performa sistem diukur berdasarkan:

1. *True Positif*, *True Negatif*, *False Positif* dan *False Negatif*.
2. Sensitivitas.

Sensitivitas adalah proporsi orang yang benar-benar sakit dalam populasi yang juga diidentifikasi sebagai orang sakit oleh tes skrining/penapisan/penapisan. Sensitivitas adalah kemungkinan kasus terdiagnosa dengan benar atau probabilitas setiap kasus yang ada teridentifikasi dengan uji skrining/penapisan/penapisan. Sensitivitas diperoleh menggunakan persamaan (3.1).

$$sensitivitas = \frac{true\ positif}{true\ positif + false\ negatif} \times 100\% \quad (3.1)$$

3. Spesifisitas.

Spesifisitas berdasarkan Kamus Epidemiologi adalah proporsi orang yang benar-benar tidak sakit dan tidak sakit pula saat diidentifikasi dengan tes skrining/penapisan/penapisan. Ini adalah ukuran dari kemungkinan benar mengidentifikasi orang tidak sakit dengan tes skrining/penapisan/penapisan (frase: angka true negatif). Spesifisitas diperoleh menggunakan persamaan (3.2).

$$spesifisitas = \frac{true\ negatif}{false\ positif + true\ negatif} \times 100\% \quad (3.2)$$

4. Akurasi klasifikasi.

Akurasi adalah ukuran seberapa dekat suatu hasil pengukuran dengan nilai yang benar atau diterima dari kuantitas besaran yang diukur. Nilai akurasi diperoleh menggunakan persamaan (3.3).

$$akurasi = \frac{true\ positif + true\ negatif}{true\ positif + true\ negatif + false\ positif + false\ negatif} \times 100\% \quad (3.3)$$

BAB 4

UJI COBA DAN PEMBAHASAN

Dalam bab ini akan dipaparkan bagaimana implementasi metode/algorithm yang diusulkan ke dalam suatu kode program yang berbasis pada Matlab dan juga pemaparan hasil penelitian yang telah dilakukan.

4.1 Implementasi

Implementasi atau penerapan dari penelitian untuk klasifikasi kanker payudara menggunakan metode ekstraksi fitur *full neighbor local binary pattern* dan *discrete wavelet transform* kedalam kode program akan dijelaskan pada sub bab ini. Adapun penjelasan lengkap tentang lingkungan implementasi serta tahapan-tahapan penting lainnya akan dihelaskan pada sub bab berikutnya.

4.1.1 Lingkungan Implementasi

Lingkungan implementasi sistem yang digunakan untuk penelitian dimulai saat pengumpulan data hingga mendapatkan hasil adalah sebagai berikut :

Processor : (a) Intel ® Core ™ i7 6700K (Quad-Core 4.0GHZ, C8MB).

Memori : 8 GB.

Sistem Operasi : *Windows 8*.

Program : MATLAB 2015.

4.1.2 Tahapan Implementasi

Tahapan implementasi penelitian yang dilakukan terdiri dari lima tahapan utama seperti yang telah dijelaskan pada Gambar 3.1 yakni deteksi dan pemotongan ROI yang berfungsi untuk mengambil objek penting pada citra, Ekstraksi fitur yang meliputi dekomposisi citra dengan DWT kemudian dilanjutkan FNLBP, Seleksi fitur dengan metode statistik t-test dan f-test serta yang terakhir adalah klasifikasi dengan metode *Backpropagation*

4.1.3 Implementasi Pemotongan ROI



Gambar 4.1. Alur deteksi dan *cropping* ROI

```
94 %crop black margin
95 - horizontalProfile = mean(I, 1) > 10; % Or whatever
96 - firstColumn = find(horizontalProfile, 1, 'first');
97 - lastColumn = find(horizontalProfile, 2, 'last');
98 - I = I(:, firstColumn:lastColumn);
99 - axes(handles.axes12);
100 - imshow(I);
```

Gambar 4.2 Kode Program Penghapusan Black Margin.

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 4.1. Untuk implementasi dalam kode program akan dijelaskan pada sub-bab berikut.

4.1.3.1 Penghapusan Black Margin

Tahap ini merupakan tahap untuk menghilangkan pinggiran hitam pada citra mammogram. Ada tiga tahapan utama dalam penghapusan *black margin* ini yakni:

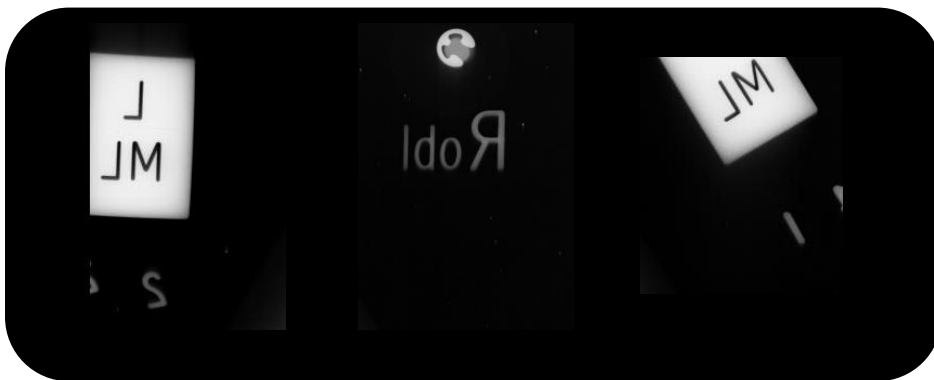
1. Cari posisi pixel pertama yang tidak berwarna hitam pada posisi horizontal.
2. Cari posisi pixel terakhir yang tidak berwarna hitam pada posisi horizontal.
3. Potong citra diantara posisi 1 dan 2 yang telah didapat.

Hasil implementasi kedalam kode program Matlab ditunjukkan Gambar 4.2. Pada baris 95 variabel *horizontalProfile* menampung pixel-pixel yang bernilai lebih dari 10 (pixel berwarna hitam), kemudian untuk mencari posisi pixel pertama dan terakhir digunakan fungsi *find* seperti terlihat pada baris 96 dan 97. Posisi piksel pertama

disimpan pada variabel *FirstColumn* sedangkan posisi akhir disimpan pada variabel *LastColumn*. Baris 98 berfungsi untuk memotong gambar diantara posisi *FirstColumn* dan *LastColumn*.

4.1.3.2 Supresi Artifak dan Pemisahan Background

Tahapan ini bermaksud untuk menghilangkan objek-objek dalam citra yang mengganggu proses klasifikasi. Contoh objek yang mengganggu untuk proses klasifikasi dapat dilihat pada Gambar 4.3. Adapun tahapan-tahapan dalam operasinya telah dijelaskan pada bab 3.1.2. Terdapat 9 tahapan untuk menghilangkan objek-objek tersebut seperti yang telah dijelaskan pada bab-bab sebelumnya. Penghapusan objek-objek tersebut menggunakan operasi morfologi dalam pengolahan citra digital, adapun implementasi 9 tahapan tersebut kedalam kode program dapat dilihat pada Gambar 4.4.




Gambar 4.3 Contoh objek yang mengganggu

```
102 %Artifact Suppression and Background Separation
103 - step1 = im2bw(I, 0.18);
104 - [Label, Total]=bwlabel(step1,8);
105 - step2=regionprops(Label,'all');
106 - [maxValue, index] = max([step2.Area]);
107 - step3 = bwareaopen(Label, maxValue);
108 - step4 = bwmorph(step3, 'clean');
109 - step5 = bwmorph(step4, 'majority');
110 - step61 = strel('disk',5);
111 - step62 = imerode(step5,step61);
112 - step7 = imdilate(step62,step61);
113 - step8 = imfill(step7,'holes');
114 - step9 = immultiply(I,step8);
115 - axes(handles.axes14);
116 - imshow(step9);
```

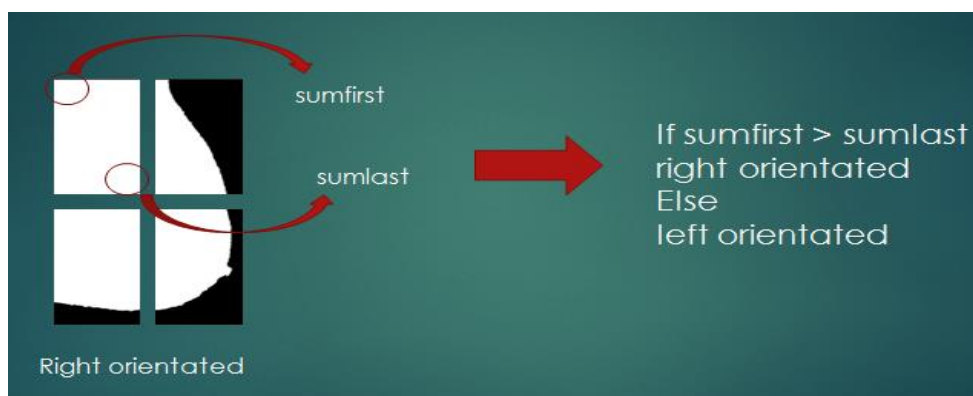
Gambar 4.4 Kode Program Supresi Artifak.

Baris 103 merupakan tahapan untuk merubah citra mammogram kedalam citra biner dengan proses *thresholding* ($T = 18$, Jawad Nagi.,dkk 2010), kemudian semua objek dilabeli menggunakan fungsi *bwlabel* seperti terlihat pada baris 104. Baris 105 digunakan untuk mengkalkulasi area (ukuran sebenarnya dari daerah pixel) hasil dari baris 104. Baris 107 merupakan tahapan ketiga yang berfungsi untuk menghapus semua objek biner pada citra mammogram kecuali objek dengan area yang terbesar. Tahapan keempat di implementasi seperti terlihat pada baris 108 sedangkan tahap kelima terlihat pada baris 109. Tahap keempat berfungsi untuk memperkecil distorsi dan menghapus pixel yang terisolasi dan tahapan kelima berfungsi untuk memperhalus *noise* yang muncul.

Tahapan selanjutnya adalah mengerosi citra biner mammogram menggunakan fungsi *strel* dan *imerode*, dimana radius dari fungsi *strel* adalah $R=5$ (Jawad Nagi.,dkk 2010), seperti terlihat pada Gambar 4.4 baris 110 dan 111. Citra biner mammogram kemudian di dilasi menggunakan fungsi *imdilation* dan lubang pada citra biner mammogram diisi dengan menggunakan fungsi *imfill*, operasi ini dapat dilihat pada baris 112 dan 113. Tahapan terakhir adalah mengalikan hasil citra biner yang dihasilkan dari tahapan 8 dengan citra original mammogram setelah penghapusan *black margin*, fungsi yang digunakan adalah *immultiply*. Hasil dari tahap supresi artefak ini dapat dilihat pada Gambar 4.5. Terlihat bahwa setelah dilakukan tahapan ini objek-objek yang mengganggu proses klasifikasi terhapuskan.



Gambar 4.5. a) Sebelum Proses Supresi Artefak. b) Setelah Proses Supresi Artefak.



Gambar 4.6 Proses Identifikasi Orientasi Payudara.

4.1.3.3 Identifikasi Orientasi

Satu citra mammogram dapat memiliki orientasi kekanan atau kekiri. Orientasi ini bergantung dari arah pengambilan citra pakah citra yang diambil merupakan citra payudara sisi kanan atau sisi kiri. Tahapan orientasi payudara ini berfungsi untuk menentukan letak *pectoral muscle* dan berfungsi untuk tahapan selanjutnya. Jika orientasi citra mammogram adalah kiri maka letak *pectoral muscle* berada disebelah sisi kanan citra tersebut, sedangkan jika orientasi citra adalah kanan maka letak *pectoral muscle* berada disebelah kiri. Cara untuk membedakan orientasi yang diimplementasikan dapat dilihat pada Gambar 4.6.

Untuk mengidentifikasi orientasi dari citra mammogram yang didapat maka sebuah citra biner mamogram akan dipotong dari kiri kekanan dan dari atas kebawah 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. Implementasi kode program tahapan identifikasi orientasi ini dapat dilihat pada Gambar 4.7.

Implementasi kode program pembagian citra mammogram menjadi empat bagian dapat dilihat pada Gambar 4.7 dari baris 120 hingga baris 131. Pemotongan citra mammogram ini dilakukan untuk mendapatkan jumlah nilai lima piksel pertama dan jumlah nilai lima piksel terakhir dari setiap bagian citra yang telah dibagi sebelumnya. Untuk menghitung jumlah nilai lima piksel pertama digunakan perulangan dan disimpan

pada variabel *sumfirst* sedangkan jumlah nilai lima piksel terakhir disimpan pada variabel *sumlast*. Implementasi kode untuk mendapatkan nilai *sumfirst* dapat dilihat pada Gambar 4.7 dari baris 133 hingga baris 141, sedangkan untuk mendapatkan nilai *sumlast* dapat dilihat pada baris 143 hingga baris 151.

Setelah nilai *sumfirst* dan *sumlast* didapat maka langkah selanjutnya adalah membandingkan dua nilai tersebut. apabila jumlah nilai pixel kolom pertama (*sumfirst*) lebih besar dari jumlah nilai pixel pada kolom terakhir (*sumlast*) maka citra tersebut memiliki orientasi payudara kekanan dan juga sebaliknya apabila jumlah nilai pixel kolom pertama (*sumfirst*) lebih kecil dari jumlah nilai pixel pada kolom terakhir (*sumlast*) maka citra tersebut memiliki orientasi payudara kekiri.

```

119 %langkah1, potong 4 bagian
120 - [rows, columns] = size(step8);
121 - topRow      = 1;
122 - bottomRow  = rows;
123 - leftColumn = 1;
124 - rightColumn = columns;
125 - setbottomRow = int16(bottomRow/2);
126 - setrightColumn = int16(rightColumn/2);
127
128 - lefttop      = step8(topRow:setbottomRow, leftColumn:setrightColumn);
129 - righttop     = step8(topRow:setbottomRow, setrightColumn:rightColumn);
130 - leftbottom  = step8(setbottomRow:bottomRow, leftColumn:setrightColumn);
131 - rightbottom = step8(setbottomRow:bottomRow, setrightColumn:rightColumn);
132
133 - sumfirst = 0;
134 - for baris=1:1
135 -     for kolom=1:5
136 -         sumfirst = sumfirst + lefttop(baris,kolom);
137 -         sumfirst = sumfirst + righttop(baris,kolom);
138 -         sumfirst = sumfirst + leftbottom(baris,kolom);
139 -         sumfirst = sumfirst + rightbottom(baris,kolom);
140 -     end
141 - end
142
143 - sumlast = 0;
144 - for baris= setbottomRow:setbottomRow
145 -     for kolom=(setrightColumn-4):setrightColumn
146 -         sumlast = sumlast + lefttop(baris,kolom);
147 -         sumlast = sumlast + righttop(baris,kolom);
148 -         sumlast = sumlast + leftbottom(baris,kolom);
149 -         sumlast = sumlast + rightbottom(baris,kolom);
150 -     end
151 - end
152
153 - langkah1 = 'left-orientated';
154 - if(sumfirst > sumlast)
155 -     langkah1 = 'right-orientated';
156 - end

```

Gambar 4.7 Kode Program Identifikasi Orientasi.

```

159 -   tf = isequal(langkah1,'right-orientated' );
160
161 -   [rows, columns] = size(step9);
162 -   pectoral = zeros(rows, columns);
163 -   pectoral = uint8(pectoral);
164 -   if (tf == 1 )
165 -       for i=1:setbottomRow
166 -           for ii=1:setrightColumn
167 -               pectoral(i,ii) = step9(i,ii);|
168 -           end
169 -       end
170 -   else
171 -       for i=1:setbottomRow
172 -           for ii=1:setrightColumn
173 -               pectoral(i,setrightColumn+ii-1)= step9(i,setrightColumn+ii-1);
174 -           end
175 -       end
176 -   end
177
178 -   t = double(176/255);
179 -   pectoralbw = im2bw(pectoral, t);
180 -   [Label,Total]=bwlabel(pectoralbw,8);|
181 -   step2=regionprops(Label,'all');
182 -   [maxValue,index] = max([step2.Area]);
183 -   pectoralbw = bwareaopen(Label, maxValue);
184 -   pectoralbw = bwmorph(pectoralbw, 'clean');
185 -   pectoralbw = bwmorph(pectoralbw, 'majority');
186 -   step61 = strel('disk',5);
187 -   pectoralbw = imerode(pectoralbw,step61);
188 -   pectoralbw = imdilate(pectoralbw,step61);
189 -   pectoralbw = imfill(pectoralbw,'holes');
190
191 -   akhir = immultiply(step9,~pectoralbw);
192 -   axes(handles.axes16);
193 -   imshow(akhir);

```


Gambar 4.8 Kode Program Eliminasi Pectoral.

4.1.3.4 Eliminasi Pectoral


Tahap ini merupakan proses untuk membuang *pectoral muscle* dari citra mammogram. *Pectoral muscle* merupakan otot dada yang terekam pada citra mammogram dan harus dihilangkan karena seringkali memiliki warna pixel yang sama dengan *mass* kanker payudara sehingga terjadi kesalahan pada tahap deteksi ROI. Implementasi tahapan eliminasi *pectoral muscle* menjadi kode program dapat dilihat pada Gambar 4.8.

Baris 161 sampai dengan baris 176 pada Gambar 4.8 berfungsi untuk membagi citra mammogram dan mengidentifikasi letak dari *pectoral muscle* pada citra. Citra mammogram dibagi menjadi empat kuadran seperti pada tahap identifikasi orientasi (kiri-atas,kanan-atas, kiri-bawah, dan kanan-bawah). 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. Kuadran yang terdapat *pectoral* didalamnya merupakan bagian yang terpenting dan tiga kuadran lainnya dirubah ke warna hitam atau diberi nilai 0 pada pixelnya. Hasil citra yang didapat pada tahap ini setelah kode program dieksekusi terlihat pada Gambar 4.9.


Selanjutnya setelah letak dari *pectoral muscle* diketahui maka akan dilakukan *threshold* pada citra mammogram hasil identifikasi seperti pada Gambar 4.9 yang akan menghasilkan citra biner seperti tampak pada Gambar 4.10. Nilai *threshold* yang digunakan adalah 176 (Vaidehi dan Subashini,2013). Proses *threshold* pada kode program dapat dilihat pada Gambar 4.8 baris 178 dan baris 179. Setelah didapat citra biner hasil *threshold* maka langkah selanjutnya adalah melakukan fungsi *multiply*. Fungsi *multiply* dilakukan pada citra invers dari hasil *threshold* terhadap citra awal mammogram setelah penghapusan artifak, pada kode program dapat dilihat pada Gambar 4.8 bari 191. Hasil akhir yang didapat pada tahapan penghilangan *pectoral muscle* ini seperti tampak pada Gambar 4.11, dimana *pectoral muscle* telah dihilangkan dan citra siap untuk dideteksi letak dari *mass* tersebut.



Gambar 4.9 Citra Hasil Deteksi Letak Pectoral.



Gambar 4.10 Citra Hasil Threshold.



Gambar 4.11 Citra Eliminasi Pectoral.

4.1.3.5 Deteksi dan Pemotongan Mass

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. Implementasi tahapan deteksi *mass* pada citra mammogram dapat dilihat pada Gambar 4.12. Proses *adjustmen* seperti terlihat pada baris 195 dengan menggunakan fungsi *imadjust* berguna untuk menyamaratakan kecerahan pada citra sehingga kecerahan tidak timpang. Setelah dilakukan fungsi *adjustment* pada citra maka langkah selanjutnya adalah proses *thresholding* seperti terlihat pada Gambar 4.12 baris 196 dengan nilai *threshold* adalah 95 (didapat dari percobaan *trial and error*). Setelah *mass* tersegmentasi maka *mass* akan dipotong sesuai dengan yang dikehendaki pada penelitian ini akan dipotong ukuran citra sebesar 128x128 pixel. Implementasi pemotongan pada kode program dapat dilihat pada Gambar 4.13 mulai dari baris 213 hingga 236.

```

195 -   usulan1 = imadjust(akhir);
196 -   usulan2 = im2bw(usulan1, 0.95);
197 -   [Label, Total]=bwlabel(usulan2,8);
198 -   ddd=regionprops(Label, 'all');
199 -   [maxValue, index] = max([ddd.Area]);
200 -   usulan3 = bwareaopen(usulan2, maxValue);

```

Gambar 4.12 Kode Program Deteksi Mass.

```

213 - [ub,uk]=size(I);
214 - if leftColumn <= 0
215 -     leftColumn = 1;
216 -     rightColumn = leftColumn + 128;
217 - else if rightColumn>uk
218 -     rightColumn = uk;
219 -     leftColumn = rightColumn- 128;
220 -     end
221 - end
222
223
224 - if topRow <= 0
225 -     topRow = 1;
226 -     bottomRow = topRow + 128;
227 - else if bottomRow>ub
228 -     bottomRow = ub;
229 -     topRow = bottomRow - 128;
230 -     end
231 - end
232
233 - roi = I(topRow:bottomRow, leftColumn:rightColumn);
234 - axes(handles.axes18);
235 - imshow(roi);
236 - end

```

Gambar 4.13 Kode Program Pemotongan Mass.

4.1.4 Implementasi Metode Usulan

Metode usulan ini memiliki perbedaan dengan *local binary pattern* tradisional 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*. 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 *FNLBP* juga mempunyai kelebihan yakni invarian terhadap rotasi hal ini dikarenakan metode usulan ini mempunyai tahapan *circular pattern*. *Circular pattern* merupakan proses untuk mendapatkan kombinasi susunan pattern dengan cara menggeser bagian kiri ke bagian paling kanan. Implementasi *circular pattern* dapat dilihat pada Gambar 4.14.


```

105 -     hasilnya1=1*hasil(1)+2*hasil(2)+4*hasil(3)+8*hasil(4)+16*hasil(5)+32*hasil(6)+64*hasil(7)+128*hasil(8);
106 -     hasilnya2=1*hasil(2)+2*hasil(3)+4*hasil(4)+8*hasil(5)+16*hasil(6)+32*hasil(7)+64*hasil(8)+128*hasil(1);
107 -     hasilnya3=1*hasil(3)+2*hasil(4)+4*hasil(5)+8*hasil(6)+16*hasil(7)+32*hasil(8)+64*hasil(1)+128*hasil(2);
108 -     hasilnya4=1*hasil(4)+2*hasil(5)+4*hasil(6)+8*hasil(7)+16*hasil(8)+32*hasil(1)+64*hasil(2)+128*hasil(3);
109 -     hasilnya5=1*hasil(5)+2*hasil(6)+4*hasil(7)+8*hasil(8)+16*hasil(1)+32*hasil(2)+64*hasil(3)+128*hasil(4);
110 -     hasilnya6=1*hasil(6)+2*hasil(7)+4*hasil(8)+8*hasil(1)+16*hasil(2)+32*hasil(3)+64*hasil(4)+128*hasil(5);
111 -     hasilnya7=1*hasil(7)+2*hasil(8)+4*hasil(1)+8*hasil(2)+16*hasil(3)+32*hasil(4)+64*hasil(5)+128*hasil(6);
112 -     hasilnya8=1*hasil(8)+2*hasil(1)+4*hasil(2)+8*hasil(3)+16*hasil(4)+32*hasil(5)+64*hasil(6)+128*hasil(7);
113 -
114 -
115 -     hasilakhir=[hasilnya1,hasilnya2,hasilnya3,hasilnya4,hasilnya5,hasilnya6,hasilnya7,hasilnya8];
116 -     hasilakhir=sort(hasilakhir);
117 -     nilai_LBP = hasilakhir(1)
118 -     fitur_LBP(1, nilai_LBP+1)=fitur_LBP(1, nilai_LBP+1)+1;
119 -     end
120 -
121 -     end

```

Gambar 4.14 Kode Program Circular Pattern.

Seperti terlihat pada Gambar 4.14 proses *circular pattern* dilakukan 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 seperti pada LBP tradisional. Histogram akhir merupakan nilai terkecil dari hasil perkalian tersebut

4.1.5 Implementasi Feature Selection

Pada penelitian ini dilakukan seleksi fitur menggunakan metode statistika yaitu *two sample t-test* dan *f-test*. *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. Implementasi algoritma pada Gambar 3.11 sehingga menjadi kode program ditunjukkan pada Gambar 4.15. Fungsi matlab yang digunakan untuk analisa hipotesa adalah `ttest2()` dan `vartest2()`.

```

98 - for i=1:M
99 -     v1 = [];
100 -     v2 = [];
101 -     for j=1:N
102 -         if target_class(1,j)==1
103 -             v1 = [v1;feature_matrix(j,i)];
104 -         else
105 -             v2 = [v2;feature_matrix(j,i)];
106 -         end
107 -     end
108 -     |
109 -     v1 = str2double(v1);
110 -     v2 = str2double(v2);
111 -
112 -     h1= ttest2(v1,v2,'Alpha',alpha);
113 -     h2= vartest2(v1,v2,'Alpha',alpha);
114 -     if h1==1
115 -         berapa=berapa+1;
116 -
117 -     end
118 -     if h2==1
119 -         berapa2=berapa2+1;
120 -
121 -     end
122 - end

```

Gambar 4.15 Kode Program Feature Selection.

Fungsi `ttest` dan `vartest` akan mengkomputasi nilai dari null hypothesis dari dua vector dengan nilai *significant level* yang berbeda. Fungsi tersebut akan mereturn sebuah nilai 0 atau 1, jika bernilai 1 maka artinya null hypothesis bernilai salah dan ditolak. Null hypothesis bernilai salah dan ditolak tersebut juga berarti bahwa data dari suatu fitur antara kelas satu dengan yang lainnya berbeda dan independent, hal ini berarti fitur tersebut dapat digunakan untuk proses klasifikasi. Ketika nilai return bernilai 0 maka null hypothesis diterima dan berarti vector pada fitur tersebut seragam dan tidak independent sehingga tidak dapat digunakan sebagai fitur klasifikasi dan akan dieliminasi.

4.1.6 Implementasi BPNN

Algoritma *backpropagation* merupakan bagian dari algoritma pembelajaran terawasi yang biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyi. Implementasi algoritma *backpropagation* dapat dilihat pada Gambar 4.16. Untuk melakukan training maka digunakan fungsi pada matlab yakni fungsi `train()` sedangkan untuk melakukan klasifikasi digunakan fungsi `sim()`. Fungsi `train()` terlihat

pada baris 270 sedangkan fungsi sim() terlihat pada baris 275. Saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi, fungsi aktivasi yang dapat digunakan adalah Sigmoid ataupun Tangent Sigmoid.

4.2 Uji Coba dan Hasil

Subbab ini menampilkan hasil pengujian metode ekstraksi fitur yang diusulkan pada penelitian ini. Uji coba dilakukan akan dilakukan dengan perbandingan metode penggabungan wavelet dan LBP dengan wavelete dan FNLBP dimana data *training* 70% dan *testing* 30% yang dipilih secara random. Pada subbab ini juga akan dijelaskan hasil uji coba seleksi fitur dengan berbagai nilai *significant level* . Performa sistem nantinya akan dibandingkan dan diukur berdasarkan hasil dari nilai sensitivitas, spesifitas dan akurasi. Kelebihan dari metode usulan yakni invarian terhadap rotasi akan dibahas pada subbab selanjutnya.

4.2.1 Dataset

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.

```
254 %BPPN
255 %pembelajaran menggunakan traingd (default = trainlm)
256
257 - net=newff(p,t',15,{'tansig' 'logsig'},'trainlm');
258 %setting nilai parameter untuk pembagian data
259 %defaultnya trainRatio 0.6, valRatio 0.2, testRatio 0.2
260
261 - net.divideParam.trainRatio=1;
262 - net.divideParam.valRatio=0;
263 - net.divideParam.testRatio=0;
264
265 %setting nilai maksimal iterasi
266 - net.trainParam.epochs = 50;
267
268 %inisialisasi
269 - net=init(net);
270 - net = train(net,p', t', 'useGPU', 'no', 'showResources', 'no');
271 % end
272 % net= train(net,p',t');
273 |
274 - coba
275 - kelas=sim(net,semuadata');
```


Gambar 4.16 Kode Program BPNN.

4.2.2 Proses pemotongan ROI

Pada citra 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. Tahapan yang dilalui seperti penjelasan pada bab-bab sebelumnya dimaksudkan agar proses pendeteksian dan pemotongan ROI menghasilkan citra yang benar-benar mempresentasikan kanker payudara. Untuk citra mammogram dengan kelas normal maka citra yang dipotong adalah bagian dari citra payudara pada posisi tengah. Pemotongan dilakukan dengan ukuran piksel 128x128, ukuran ini didapat dari ujicoba untuk mencari ukuran massa kanker payudara yang terbesar. Pemotongan juga dilakukan pada semua citra dengan ukuran yang sama agar semua citra mammogram memiliki porsi yang sama saat dilakukan proses ekstraksi fitur. Hasil eksekusi tahapan pemotongan ROI ini dapat dilihat pada Gambar 4.17.

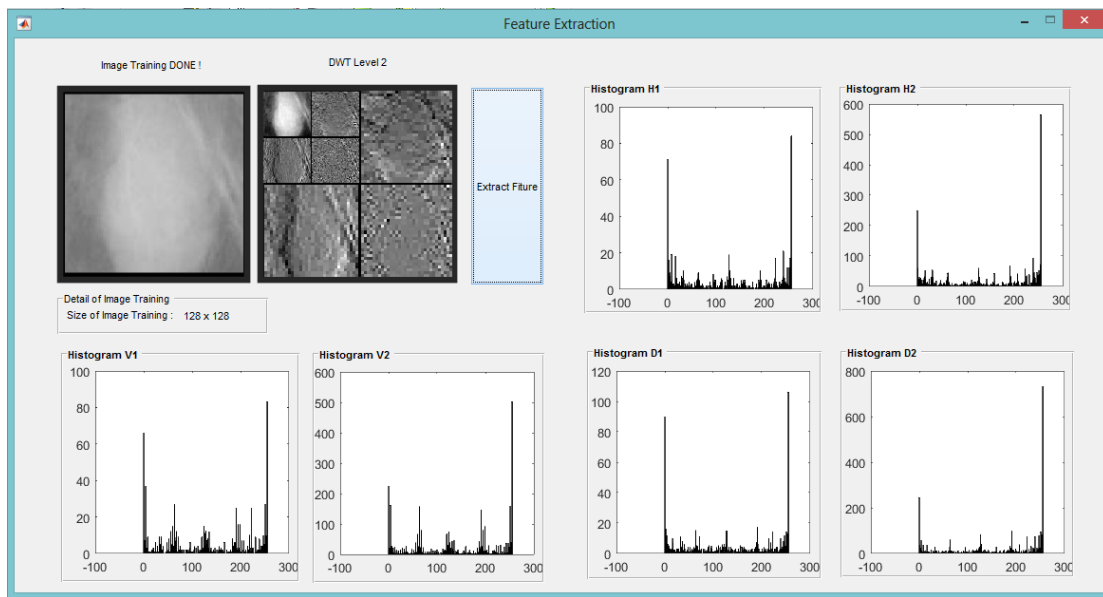
4.2.3 Proses Ekstraksi Fitur

Tahapan ekstraksi fitur merupakan tahapan penting untuk mendapatkan nilai histogram dari sebuah citra mammogram. Pada subbab ini akan dibandingkan hasil histogram dari ekstraksi fitur menggunakan *local binary pattern* tradisional dan *full neighbor local binary pattern* pada citra-citra hasil dekomposisi menggunakan *discrete wavelet transform*. *Discrete wavelete transform* secara umum merupakan dekomposisi citra pada pada frekuensi subband citra tersebut. Komponen subband transformasi wavelet dihasilkan dengan cara penurunan level dekomposisi.




Gambar 4.17 Hasil Eksekusi Program ROI Cropping

Level dekomposisi yang dilakukan pada penelitian ini adalah level 2 dimana akan menghasilkan 7 sub-citra baru. Adapun hasil histogram dari *local binary pattern* tradisional dapat dilihat pada Gambar 4.18 sedangkan hasil histogram *full neighbor local binary pattern* dapat dilihat pada Gambar 4.19. Perbedaan yang terjadi pada histogram hasil *local binary pattern* tradisional dengan metode usulan dapat mempengaruhi hasil akhir akurasi, hal ini dikarenakan jumlah fitur yang digunakan nantinya akan berbeda setelah proses featur selection.



Gambar 4.18 Hasil Histogram *Local binary pattern*.



Gambar 4.19 Hasil Histogram *Full neighbor local binary pattern*.

Terlihat pada Gambar 4.18 histogram hasil ekstraksi fitur *local binary pattern* memiliki variasi bit histogram yang terisi lebih tersebar dan banyak daripada histogram hasil ekstraksi fitur menggunakan FNLBP. Hal ini dikarenakan adanya proses sirkular pattern yang mencari nilai terkecil pada metode usulan FNLBP yang menyebabkan penumpukan bit-bit hanya terjadi pada bit-bit histogram bernilai kecil sedangkan pada LBP tradisional hal ini tidak terjadi.

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 berkaitan dengan kelebihan dari metode usulan FNLBP yang membandingkan semua tetangga dengan sisi vertikal, horizontal maupun diagonal sehingga tidak lagi sensitif terhadap *noise*. Kesensitifan terhadap *noise* menyebabkan ketimpangan antara bit 0 dan 255 dengan bit histogram lainnya. Pada kedua histogram bit nilai 0 sama-sama bernilai tinggi hal ini membuktikan bahwa citra mammogram inputan memang memiliki banyak quantum *noise*, terutama *noise* berwarna putih.

4.2.4 Uji Coba Invarian Rotasi

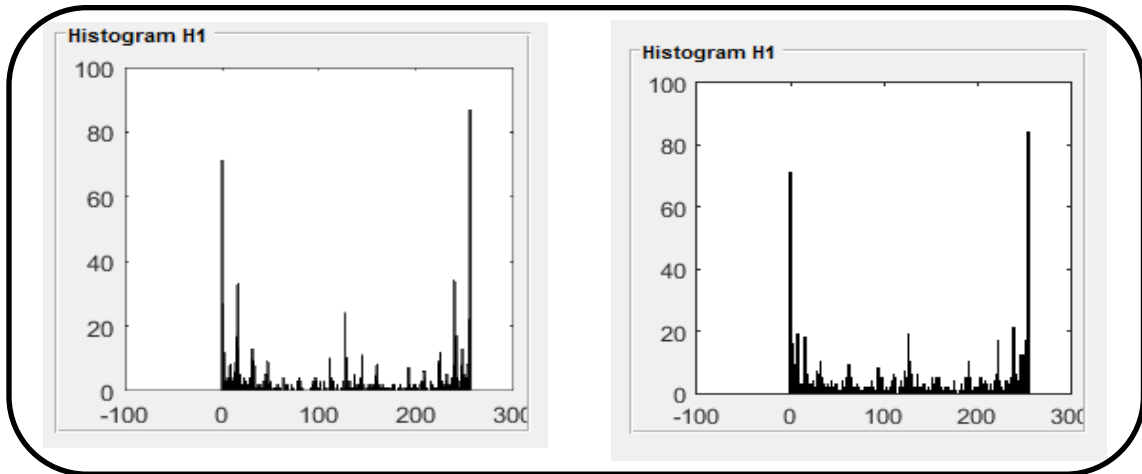
Uji coba ini dilakukan untuk melihat apakah metode usulan FNLBP mengatasi masalah dari LBP tradisional yakni varian terhadap rotasi. Varian terhadap rotasi ini berarti apabila sebuah citra mammogram yang sama akan menghasilkan nilai histogram yang berbeda apabila citra tersebut dirotasi. Varian terhadap 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 4.20 dan Gambar 4.21.




Gambar 4.20 Citra Mammogram Awal.



Gambar 4.21 Citra Mammogram Dirotasi.



Gambar 4.22 Hasil Histogram LBP.



Gambar 4.23 Hasil Histogram FNLBP.


Hasil perbandingan histogram menggunakan metode ekstraksi LBP dapat dilihat pada Gambar 4.22. Terlihat bahwa histogram hasil LBP berbeda antara satu dengan yang lain, gambar kiri pada Gambar 4.22 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 4.23. Terlihat bahwa histogram hasil FNLBP sama persis antara satu dengan yang lain, gambar kiri pada Gambar 4.23 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.

4.2.5 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 4.24 dan hasil pengujian seleksi fitur dapat dilihat pada Tabel 4.1.



Gambar 4.24 Simulasi ekstraksi dan seleksi fitur.

Tabel 4.1 Hasil Seleksi Fitur.

<i>Significant level</i>	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 4.1 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 4.1 juga dapat disimpulkan bahwa semakin tinggi nilai *significant level* maka fitur yang tereduksi 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 tereduksi 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 4.1 juga dapat terlihat bahwa hasil dataset hasil ekstraksi fitur FNLBP akan memiliki fitur lebih sedikit setelah direduksi 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.

4.2.6 Uji Coba Klasifikasi

Ujicoba klasifikasi akan dilakukan untuk mengetahui performa dari metode usulan yakni metode dwt+FNLBP. Sebelum dipaparkan hasil dan pembahasan dari ujicoba klasifikasi pada bab ini akan dijelaskan pembagian dataset untuk training dan testing serta nilai-nilai variabel inputan.

4.2.6.1 Pembagian dataset

Sebelum dilakukan ujicoba klasifikasi akan dilakukan pembagian dataset. Seperti yang telah dijelaskan sebelumnya bahwa dataset yang digunakan didapat dari dua sumber yakni MIAS dan DDSM dengan total citra mammogram adalah 317 citra, dengan 208 citra normal dan 109 citra abnormal. Untuk kepentingan klasifikasi maka dataset akan dibagi menjadi dua bagian yakni data training dan data testing dengan pembagian adalah 70% data training dan 30% data testing sehingga jumlah data citra mammogram akan menjadi seperti yang terlihat pada Tabel 4.2.

Tabel 4.2 Tabel Pembagian Data.

Penggunaan	Jumlah Citra Mammogram	
	Normal	Abnormal
Training	145	76
Testing	63	33
Jumlah	208	109

Pembagian citra seperti pada Tabel 4.2 tersebut dilakukan baik saat ujicoba metode usulan ataupun metode *local binary pattern* tradisional. Dengan pengambilan citra dilakukan secara random. Nantinya dataset digunakan untuk menguji performa dari metode usulan dengan mencari nilai Sensitivitas, spesificity dan akurasi.

4.2.6.2 Variabel input

Terdapat beberapa variabel input yang diperlukan untuk mendapatkan performansi dari metode usulan. Pada tahap deteksi dan pemotongan ROI variabel input yang berpengaruh adalah ukuran citra dimana pada penelitian ini ditentukan nilainya adalah 128x128. Pada tahapan seleksi fitur variabel inputan yang diperlukan adalah *significant level* dimana nilai dari variabel ini nantinya akan menjadi parameter uji. Pada tahapan akhir yakni klasifikasi akan digunakan metode BPNN dimana metode ini memerlukan inputan berupa nilai banyaknya *hidden layer*, pada penelitian ini *hidden layer* ditentukan dengan nilai 15 dan epoch adalah 50.

4.2.6.3 Hasil dan Pembahasan Performansi

Pengujian dilakukan dengan membandingkan metode FNLBP dan LBP tradisional dengan menggunakan *discrete wavelet transform* dan tanpa *discrete wavelet transform*. Performa metode dapat dilihat pada Tabel 4.3 sampai dengan Tabel 4.6 (R=jumlah fitur setelah diseleksi).

Tabel 4.3 Tabel Performa DWT+FNLBP.

Uji	<i>Significant level</i>	R	TP	TN	FP	FN	Sensitivitas	Spesifisitas	Akurasi (%)
T-test	0.9	213	26	55	7	8	0.76	0.89	84.37
	0.7	206	25	56	8	7	0.78	0.88	84.37
	0.5	197	20	54	13	9	0.69	0.81	77.08
	0.3	188	24	54	9	9	0.73	0.86	81.25
	0.1	175	26	56	7	7	0.79	0.89	85.42
F-test	0.9	216	29	60	4	3	0.91	0.94	92.71
	0.7	211	29	60	4	3	0.91	0.94	92.71
	0.5	207	26	50	7	13	0.67	0.88	79.17
	0.3	192	25	57	8	6	0.81	0.88	85.42
	0.1	174	26	54	7	9	0.74	0.89	83.33

Tabel 4.4 Tabel Performa DWT+LBP.

Uji	Significant level	R	TP	TN	FP	FN	Sensitivitas	Spesifisitas	Akurasi (%)
T-test	0.9	1478	21	57	12	6	0.77	0.83	81.25
	0.7	1330	22	56	11	7	0.76	0.84	81.25
	0.5	1173	17	55	16	8	0.68	0.77	75.00
	0.3	1010	17	60	16	3	0.85	0.79	80.20
	0.1	758	22	51	11	12	0.65	0.82	76.04
F-test	0.9	1443	26	54	7	9	0.74	0.89	83.33
	0.7	1226	19	59	14	4	0.83	0.81	81.25
	0.5	1021	26	48	7	15	0.63	0.87	77.08
	0.3	775	27	50	6	13	0.67	0.89	80.20
	0.1	453	1	63	32	0	1.00	0.66	66.67

Dapat dilihat pada Tabel 4.3 performa kombinasi *discrete wavelet transform* dan *full neighbor local binary pattern* menghasilkan akurasi yang cukup tinggi yakni 92.70% pada seleksi fitur f-test dengan nilai *significant level* 0.9 dan 0.7. Pada ujicoba menggunakan seleksi fitur menggunakan t-test kombinasi *discrete wavelet transform* dan *full neighbor local binary pattern* mendapatkan akurasi tertinggi 85.42% pada nilai *significant level* 0.1. Untuk nilai sensitivitas dan spesifisitas kombinasi ini menghasilkan nilai tertinggi pada rangkaian ujicoba menggunakan f-test dengan *significant level* 0.9 dan 0.7. Nilai akurasi terendah untuk kombinasi *discrete wavelet transform* dan *full neighbor local binary pattern* didapat pada saat digunakan metode seleksi fitur t-test dengan nilai *significant level* 0.5 yakni 77.08% sedangkan untuk metode seleksi fitur f-test akurasi terendah didapat pada *significant level* 0.5. Dari tabel 4.3 juga didapat fakta bahwa nilai spesifisitas dan sensitivitas berbanding lurus dengan akurasi.

Untuk kombinasi *discrete wavelet transform* dan *local binary pattern* dapat terlihat performa pada Tabel 4.4 menghasilkan akurasi tertinggi yakni 83.33% pada seleksi fitur f-test dengan nilai *significant level* 0.9. Pada ujicoba menggunakan seleksi fitur menggunakan t-test kombinasi *discrete wavelet transform* dan *local binary pattern* mendapatkan nilai tertinggi hanya pada nilai *significant level* 0.9 dan 0.7 yakni dengan akurasi 81.25. Untuk nilai sensitivitas kombinasi ini menghasilkan nilai sempurna pada ujicoba menggunakan f-test dengan *significant level* 0.1 sedangkan untuk spesifisitas tidak terdapat nilai sempurna, nilai tertinggi didapat pada saat seleksi fitur f-test dengan

nilai *significant level* 0.9 dengan nilai spesifisitas 0.89, serta seleksi fitur f-test dengan *significant level* 0.3 dengan nilai spesifisitas 0.89.

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* 0.1 yakni 66.67% sedangkan untuk metode seleksi fitur t-test akurasi terendah didapat pada *significant level* 0.5. Dari tabel 4.3 dan tabel 4.4 didapat fakta bahwa metode usulan mendapatkan nilai akurasi yang lebih tinggi daripada metode kombinasi *discrete wavelet transform* dan *local binary pattern* tradisional, hal ini berarti kombinasi *discrete wavelet transform* dan *full neighbor 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 neighbor 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 juga yakni 70% data training dan 30% data testing.

Tabel 4.5 Tabel Performa FNLBP.

Uji	<i>Significant level</i>	R	TP	TN	FP	FN	Sensitivitas	Spesifisitas	Akurasi (%)
T-test	0.9	32	12	56	21	7	0.63	0.73	70.83
	0.7	34	6	60	27	3	0.67	0.69	68.75
	0.5	34	19	51	14	12	0.61	0.78	72.91
	0.3	34	21	55	12	8	0.72	0.82	79.16
	0.1	34	10	60	23	3	0.77	0.72	72.91
F-test	0.9	36	23	58	10	5	0.82	0.85	84.37
	0.7	36	8	56	25	7	0.52	0.69	66.67
	0.5	36	21	54	12	9	0.70	0.82	78.12
	0.3	36	21	54	12	9	0.70	0.82	78.12
	0.1	36	19	56	14	7	0.73	0.80	78.12

Tabel 4.6 Tabel Performa LBP.

Uji	Significant level	R	TP	TN	FP	FN	Sensitivitas	Spesifisitas	Akurasi (%)
T-test	0.9	250	21	57	12	6	0.78	0.83	81.25
	0.7	238	22	56	11	7	0.76	0.84	81.25
	0.5	223	16	62	17	1	0.94	0.78	81.25
	0.3	205	17	60	16	3	0.85	0.79	80.20
	0.1	182	22	51	11	12	0.64	0.83	76.04
F-test	0.9	240	21	57	12	6	0.78	0.83	81.25
	0.7	219	19	59	14	4	0.83	0.81	81.25
	0.5	188	22	58	11	5	0.81	0.84	83.33
	0.3	161	22	57	11	6	0.79	0.84	82.29
	0.1	103	1	63	32	0	1.00	0.67	66.67

Dapat dilihat pada Tabel 4.5 performa metode usulan *full neighbor local binary pattern* menghasilkan akurasi yang tinggi yakni 84.37% pada seleksi fitur f-test dengan nilai significant 0.9. Pada ujicoba menggunakan seleksi fitur menggunakan t-test *full neighbor local binary pattern* mendapatkan akurasi tertinggi pada nilai *significant level* 0.3 yakni 79.16%. Untuk nilai sensitivitas metode ini tidak terdapat nilai sempurna pada semua rangkaian ujicoba sedangkan untuk spesifisitas nilai tertinggi didapat pada saat akurasi juga mendapat nilai sempurna yakni pada seleksi fitur f-test dengan nilai *significant level* 0.9. Nilai akurasi terendah untuk metode usulan *full neighbor local binary pattern* didapat pada saat digunakan metode seleksi fitur f-test dengan nilai *significant level* 0.7 yakni 66.67% sedangkan untuk metode seleksi fitur t-test akurasi terendah didapat pada *significant level* 0.7 yakni 68.75%.

Untuk metode tradisional *local binary pattern* dapat terlihat performa pada Tabel 4.6 menghasilkan akurasi yang tertinggi yakni 83.33% pada seleksi fitur f-test dengan nilai *significant level* 0.5. Pada 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, 0.7 dan 0.5 yakni dengan akurasi 81.25%. Untuk nilai sensitivitas kombinasi ini menghasilkan nilai sempurna pada saat digunakan seleksi fitur f-test dengan nilai *significant level* 0.1 sedangkan untuk spesifisitas nilai tertinggi didapat pada saat akurasi juga mendapat nilai tertinggi yakni pada seleksi fitur f-test dengan nilai *significant level* 0.5 dan 0.3 dengan nilai spesifisitas 0.84, serta seleksi fitur t-test dengan *significant level* 0.. Nilai

akurasi terendah untuk *local binary pattern* didapat pada saat digunakan metode seleksi fitur f-test dengan nilai *significant level* 0.7 yakni 66.67% . Dari tabel 4.5 dan tabel 4.6 didapat fakta bahwa metode usulan tetap mendapatkan akurasi yang lebih tinggi daripada metode *local binary pattern* tradisional meskipun tanpa dilakukan dekomposisi *discrete wavelet transform* pada citra mammogram sebelumnya.

4.2.6.4 Hasil dan Pembahasan Konsumsi Waktu

Berdasarkan hasil yang didapat dapat terlihat bahwa kombinasi *discrete wavelet transform* dan FNLBP menghasilkan akurasi yang tinggi akan tetapi kombinasi tersebut akan menghasilkan waktu eksekusi yang lebih lama. Detail konsumsi waktu ketika proses ekstraksi fitur dapat dilihat pada Tabel 4.7, sedangkan detail konsumsi proses ujicoba klasifikasi dapat dilihat pada Tabel 4.8. Dapat terlihat pada Tabel 4.8 konsumsi waktu yang dihasilkan dengan kombinasi *discrete wavelet transform* akan lebih besar baik pada FNLBP ataupun LBP tradisional. Penyebab membengkaknya waktu eksekusi adalah karena jumlah fitur yang digunakan lebih banyak karena fitur-fitur tersebut diekstraksi dari 6 buah sub citra hasil dekomposisi metode *discrete wavelet transform*.

Tabel 4.7 Tabel Konsumsi Waktu Ekstraksi.

Uji Coba	Waktu (Menit)
DWT + FNLBP	17
DWT+LBP	5
FNLBP	10
LBP	3

Tabel 4.8 Tabel Konsumsi Waktu Klasifikasi.

Uji Coba	Waktu (Menit)
DWT + FNLBP	15
DWT+LBP	105
FNLBP	2
LBP	17

[Halaman ini sengaja dikosongkan]

4. BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan aplikasi yang telah dibuat dan hasil yang didapat dari serangkaian uji coba yang telah dilakukan terhadap metode usulan *full neighbor 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. Performa metode usulan *full neighbor local binary pattern* menghasilkan akurasi yang tinggi yakni 92.70% pada saat menggunakan *discrete wavelet transform* dengan seleksi fitur f-test dengan *significant level* 0.9 dan 0.7, sedangkan akurasi terendah yang didapat adalah saat digunakan metode seleksi fitur t-test dengan nilai *significant level* 0.5 pada kombinasi *discrete wavelet transform* dan *full neighbor local binary pattern* yakni 77.08%.
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*. Jumlah fitur yang berbeda juga dapat menyebabkan waktu konsumsi klasifikasi yang berbeda dimana konsumsi waktu yang dihasilkan dengan kombinasi *discrete wavelet transform* akan lebih besar baik pada *FNLBP* ataupun *LBP* tradisional
5. Semakin tinggi nilai *significant level* maka fitur yang tereduksi 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 tereduksi akan semakin banyak dan menghasilkan fitur yang dianggap independent lebih sedikit

5.2 Saran

1. Tahapan deteksi dan pemotongan ROI diharapkan dapat ditingkatkan dan diukur keakurasiannya dengan mencari *ground truth* dari citra mammogram sebagai pembandingnya.
2. Penggunaan metode seleksi fitur dan klasifikasi dapat diganti dengan metode lain yang memungkinkan mendapatkan akurasi yang lebih baik.

DAFTAR PUSTAKA

- 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 (2004), Tumor segmentation from magnetic resonance imaging by learning via one-class support vector machine. Accepted by International Workshop on Advanced Image Technology (IWAIT04).
- 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 (2003), Fuzzy Tumor Segmentation based on Iterative Watersheds. *Faculté Polytechnique de Mons*.
- 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 *LBP Uniform* 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.

Uyun, S. & Harjoko, A (2011). Deteksi Abnormalitas Pada Citra Mammogram dengan
Gray-Level Co-Occurrence Matrix. Sriti STMIK AKAKOM. Yogyakarta.

BIOGRAFI



Januar Adi Putra, S. Kom. putra bungsu dari pasangan Bpk H.Istiadi dan Ibu R.A Suningrum lahir pada tahun 1993. Menempuh pendidikan dasar di SDN Kemayoran 01 Bangkalan, SMPN 02 Bangkalan, SMAN 02 Bangkalan, kemudian menempuh pendidikan S-1 di Universitas Jember jurusan Sistem Informasi. Semenjak studi S-1 penulis mempunyai ketertarikan dalam bidang komputasi cerdas dan visualisasi sehingga tugas akhir S-1 dan Tesis penulis selalu berkaitan dengan bidang tersebut, semasa pendidikan S-1 penulis aktif sebagai asisten dosen dan *freelance (web programmer)*. Penulis dapat dihubungi melalui email januaradi.putra@gmail.com.