

**ANALISIS CITRA *DENTAL PANORAMIC*
RADIOGRAPH (DPR) PADA TULANG MANDIBULA
UNTUK DETEKSI OSTEOPOROSIS
MENGUNAKAN METODE GLCM – SVM
MULTICLASS (*GRAY LEVEL CO- OCCURRENCE*
MATRIX – SUPPORT VECTOR MACHINE
MULTICLASS)**

SKRIPSI



**OLEH
DEASY ALFIAH ADYANTI
NIM. H72214013**

**PROGRAM STUDI MATEMATIKA
JURUSAN SAINS
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
SURABAYA
2018**

PERNYATAAN KEASLIAN

Yang bertandatangan dibawah ini:

Nama : Deasy Alfiah Adyanti

NIM : H72214013

Program Studi : Matematika

Angkatan : 2014

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul: **Analisis Citra Dental Panoramic Radiograph (DPR) Pada Tulang Mandibula Untuk Deteksi Osteoporosis Menggunakan Metode GLCM – SVM Multiclass (Gray Level Co-Occurrence Matrix – Support Vector Machine Multiclass)**. Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya akan menerima sanksi yang telah ditetapkan. Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 3 Agustus 2018



Deasy Alfiah Adyanti
NIM.H72214013

LEMBAR PENGESAHAN

**ANALISIS CITRA DENTAL PANORAMIC RADIOGRAPHI (DPR) PADA
TULANG MANDIBULA UNTUK DETEKSI OSTEOPOROSIS
MENGUNAKAN METODE GLCM – SVM MULTICLASS (GRAY LEVEL
CO-OCCURRENCE MATRIX – SUPPORT VECTOR MACHINE
MULTICLASS)**

Disusun oleh
Deasy Alfiah Adyanti
NIM.H72214013

Telah dipertahankan di depan Dewan Penguji
Pada tanggal 18 Juli 2018
Dan dinyatakan telah memenuhi syarat
untuk memperoleh gelar
Sarjana Matematika (S.Mat)

Dewan Penguji

Penguji I



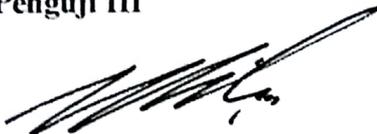
Dian C. Rini Novitasari, M.Kom
NIP.198511242014032001

Penguji II



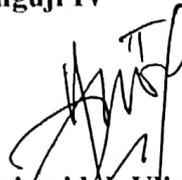
Aris Fanani, M.Kom
NIP.198701272014031002

Penguji III



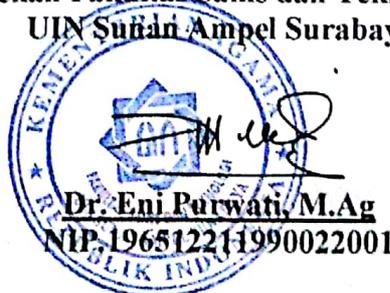
Wika Dianita Utami, M.Sc
NIP.199206102018012003

Penguji IV



Nurissaidah Ujinnuha, M.Kom
NIP.199011022014032004

Mengesahkan
Dekan Fakultas Sains dan Teknologi
UIN Sunan Ampel Surabaya





KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpus@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : DEASY ALFIAH ADYANTI
NIM : H72214013
Fakultas/Jurusan : SAINTEK / MATEMATIKA
E-mail address : H72214013@uinsby.ac.id

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Skripsi Tesis Desertasi Lain-lain (.....)

yang berjudul :

ANALISIS CITRA DENTAL PANORAMIC RADIOGRAPH (CDPR) PADA
TULANG MANDIBULA UNTUK DETEKSI OSTEOPOROSIS MENGGUNAKAN
METODE GLCM-SUM MULTICLASS (GRAY LEVEL CO-OCCURRENCE
MATRIX - SUPPORT VECTOR MACHINE MULTICLASS)

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya,

Penulis

(DEASY ALFIAH ADYANTI)

Tidak Menular (PTM) (Soepardi, 2012). Salah satu faktor yang menyebabkan tingginya angka penyakit tidak menular ini adalah karena adanya transisi epideminologi. Transisi epideminologi ditandai dengan adanya pergeseran pola penyakit mulai dari penurunan angka kejadian penyakit menular tertentu dan meningkatnya angka kejadian penyakit tidak menular (Limbong & Syahrul, 2015). Salah satu PTM yang setiap tahunnya mengalami peningkatan adalah penyakit osteoporosis (Depkes, 2007).

Osteopenia adalah keadaan kepadatan (densitas) tulang yang kurang rapat dibandingkan tulang normal pada umumnya namun tidak terlalu rendah nilainya untuk didiagnosis sebagai osteoporosis (Sihombing, Sunarya, & Atmaja, 2014). Sedangkan osteoporosis merupakan penyakit tulang yang berhubungan dengan proses penuaan dengan ciri-ciri berupa penurunan jaringan tulang, sedemikian sehingga tulang akan menjadi rapuh (Azhari dkk, 2014).

Dua penyakit ini sangat membutuhkan perhatian serius dikarenakan penyakit tersebut dapat menyebabkan patah tulang, cacat tubuh, komplikasi hingga kematian (Limbong & Syahrul, 2015). Kedua penyakit ini dapat terjadi pada semua usia, sehingga menjadi ancaman bagi kehidupan manusia. Angka prevalensi kedua penyakit ini termasuk tinggi. Dilihat dari data statistik pada tahun 2009, dari 200 juta penderita osteoporosis di seluruh dunia diperkirakan nantinya 6.3 juta manusia pada tahun 2050 akan mengalami patah tulang panggul setiap tahun yang mana lebih dari setengahnya terdapat di Asia (Tandra, 2009). Tidak hanya itu, kedua penyakit tersebut adalah jenis penyakit

yang sulit diketahui dengan kasat mata (*silent disease*) dan bersifat progresif yang artinya kedua penyakit tersebut sulit diketahui sampai adanya patah tulang (fraktur) (Kawiyana, 2009).

Beberapa usaha yang dapat dilakukan untuk pencegahan osteoporosis dan osteopenia adalah melakukan deteksi dengan melihat kondisi tulang secara aktual seperti mengukur kepadatan tulang dalam luasan (*Bone Mineral Density*). Metode yang dapat diupayakan adalah dengan mengenali suatu citra dengan menggunakan sinar X atau pemeriksaan radiologis. Namun, pemeriksaan radiologis seperti sinar rontgen (X-Ray polos) baru dapat dideteksi apabila massa tulang sudah berukuran 30% (Rukmoyo, 2017).

Deteksi osteoporosis dapat juga dengan menggunakan sinar rontgen yang sudah diberlakukan secara khusus untuk mengukur massa tulang seperti QCT (*Quantitative Computerized Tomography*) atau OCT (*Osfe Computerized Tomography*), gelombang ultrasonik, SPA (*Single Photon Absorptomer*) dengan menggunakan sinar gamma, DPA (*Dual photon Absorptometry*), DEXA (*Dual Energy X-ray Absorptometry*) atau dengan pemeriksaan *histomorfometri* tulang (Rukmoyo, 2017). Namun pemeriksaan dengan menggunakan alat-alat tersebut membutuhkan biaya yang relatif mahal dan alat-alatnya terbatas. Oleh karena itu, diperlukan pilihan alternatif deteksi selain menggunakan alat-alat tersebut.

Alternatif deteksi osteoporosis dapat dilakukan dengan citra X-Ray tulang rahang dari dental paronamik yang dianalisis teksturnya (Mulyono, 2008). Citra DPR adalah jenis citra ekstraoral yang sering digunakan dokter

gigi sebelum melakukan tindakan. Horner mengatakan bahwa citra ekstraoral merupakan alternatif deteksi osteoporosis karena memiliki hubungan antara tulang mandibula pada citra DPR dengan kerapatan massa tulang dengan cara mengukur lebar tulang korteks mandibula dan menganalisis densitas trabekula tulang mandibula (Azhari dkk, 2014).

Alternatif deteksi yang menggunakan citra DPR dapat dilakukan dengan bantuan *machine learning* dan pengolahan citra digital (Singh dkk, 2017). Sehingga adanya suatu identifikasi dini dapat diperoleh dengan cepat. Alternatif tersebut dapat digunakan untuk mencari fitur spesifik yang ada baik dengan cara mengukur lebar tulang korteks mandibula atau menganalisis *density* trabekula tulang mandibula (Sela & Sutarman, 2017). Dengan demikian resiko kesalahan penentuan osteoporosis, serta biaya diagnosis yang sangat mahal dapat dikurangi dengan adanya bantuan analisis tekstur yang diperoleh dengan bantuan komputer atau *computer aided diagnosis system*.

Penelitian-penelitian deteksi osteoporosis menggunakan sistem CAD telah dilakukan dan dipublikasikan dengan berbagai macam metode. Beberapa diantaranya penelitian yang dilakukan oleh Muthu Subash Kavitha yang mengimplementasikan *Fractal Dimension* (FD) dan GLCM untuk menganalisis tekstur pada tulang korteks mandibula dengan menggunakan citra radiografi panoramik untuk diagnosis osteoporosis wanita Korea (Kavitha, An, & An, 2014). Selain itu, Markus P Sihombing yang mengimplementasikan *threshold otsu* untuk deteksi osteopenia dan osteoporosis (Sihombing, Sunarya, & Atmaja, 2014) dan Azhari yang

mengimplementasikan analisis tekstur GLCM untuk deteksi osteoporosis melalui analisa citra radiografi panoramik pada tulang mandibula (Azhari dkk, 2014).

Dari beberapa penelitian tersebut hasil yang dilakukan oleh Muthu Subash Kavitha dan Azhari yang menerapkan metode GLCM dengan klasifikasi SVM memberikan akurasi yang cukup bagus yaitu 96.8% dan 85,71%. Tidak hanya penelitian-penelitian tersebut, beberapa penelitian lain telah menunjukkan bahwa GLCM dan SVM sangat cocok digunakan untuk mengklasifikasi citra medik seperti halnya penelitian yang dilakukan Refta Listia yang mengklasifikasi massa pada citra mammogram menggunakan GLCM dengan hasil akurasi 81.1 % dari segala arah (Listia & Harjoko, 2014), dan Fransiska Meilisa yang mendeteksi *meningioma* dan *schwannoma* dari citra *CT-Scan* menggunakan GLCM dengan hasil akurasi 85.5263% (Meilisa, 2016).

Sedangkan penelitian-penelitian dengan klasifikasi SVM dilakukan oleh Yohana Karina yang mendeteksi kelainan tulang belakang dengan SVM menghasilkan akurasi sebesar 91.87% (Karina, Magdalena, & Atmaja, 2017), Prihananto J. T. Laksono menerapkan SVM untuk klasifikasi kanker payudara dengan hasil akurasi 87.57%, (Laksono, 2007) dan Niyalatul Muna mengidentifikasi *diabetic retinopathy* dengan SVM menghasilkan keakuratan sebesar 90% (Muna, 2013).

Hal ini menunjukkan bahwa klasifikasi citra medik khususnya untuk sistem deteksi osteoporosis sangat baik jika dilakukan dengan menggunakan

SPA dengan menggunakan sinar gamma, DPA, DEXA atau dengan pemeriksaan *histomorfometri* tulang (Rukmoyo, 2017). Namun pemeriksaan dengan menggunakan alat-alat tersebut membutuhkan biaya yang relatif mahal dan alat-alatnya terbatas.

Alternatif lain yang digunakan untuk deteksi osteoporosis adalah dengan menggunakan citra X-Ray tulang rahang dari dental panoramik yang dianalisis teksturnya (Mulyono, 2008). Horner mengatakan bahwa citra DPR merupakan alternatif deteksi osteoporosis karena memiliki hubungan antara tulang mandibula pada citra DPR dengan kerapatan massa tulang (Azhari dkk, 2014) yang dilakukan dengan cara menganalisis trabekula pada tulang mandibula (Azhari dkk, 2014).

4. Gejala Klinik Osteoporosis dan Osteopenia

Pada fase awal osteoporosis dan osteopenia gejalanya tersamar (*silent disease*) dan progresif sehingga sulit diketahui sampai adanya fraktur. Gejala yang ditemui pada penderita osteoporosis dan osteopenia antara lain (Rukmoyo, 2017):

- a. Nyeri tulang belakang (*back pain*) yang menahun.
- b. Fraktur tulang akibat cedera yang ringan.

B. Citra DPR

Radiografi panoramik merupakan salah satu teknik sinar-X yang digunakan untuk melihat struktur *facial* gigi dan rahang termasuk tulang maksila dan tulang mandibula beserta struktur pendukungnya baik perkembangan gigi geligi, dan gigi impaksi (Masyrifah, 2011). Pencitraan

E. Pengelolaan Citra Digital

Dalam pengklasifikasian citra medik diperlukan teknik pengolahan citra yang terbagi menjadi tiga tahap yaitu *preprocessing*, ekstraksi fitur dan klasifikasi. Berikut adalah proses dari tahapan klasifikasi citra medik.

1. *Preprocessing* Citra DPR

DPR yang telah diperoleh tidak dapat digunakan secara langsung karena kualitas citra tersebut belum memenuhi standar pengolahan. Citra tersebut memiliki variasi intensitas yang kurang seragam akibat pencahayaan yang tidak merata dan kontras yang lemah. Citra dengan kualitas yang rendah memerlukan langkah-langkah perbaikan atau peningkatan kualitas untuk memfasilitasi pengolahan yang akan digunakan dan untuk menghindari kesulitan dalam melakukan pemisahan citra dengan latar belakang.

Oleh karena itu, perlunya langkah-langkah *preprocessing* untuk memperbaiki kualitas citra. Pada tahap ini, dilakukan proses *image enhancement* berupa pengontrasan citra *grayscale* dengan ekualisasi histogram, dan filter median.

a. *Image Enhancement*

Image Enhancement merupakan perbaikan citra pada domain spasial yang bertujuan untuk memproses citra sehingga didapatkan hasil yang lebih sesuai dibandingkan citra aslinya. Proses-proses pada domain spasial dapat dinyatakan dalam persamaan berikut (Gonzalez & Woods, 1997):

- a) Penapis Lolos-Rendah
- b) Penapis Lolos-Tinggi
- 5) Penajaman Citra (*Image Sharpening*)
- 6) Pewarnaan Semu
- 7) Koreksi Geometrik

Selanjutnya dalam proses perbaikan citra DPR, peneliti menggunakan pengembangan dari metode *histogram equalization* yaitu *adaptive histogram equalization* sebagai perbaikan citra DPR.

2. *Region of Interest* (ROI)

ROI adalah perlakuan khusus yang dilakukan pada area yang diinginkan pada saat pengolahan citra. Prinsip dari ROI adalah dengan membatasi daerah tersebut dengan daerah lainnya. Pada ROI memungkinkan adanya suatu kode berbeda pada area tertentu. Sehingga citra yang dihasilkan berkualitas lebih baik dari *background* citranya (Eliyen, 2013). Hasil ROI merupakan fitur yang sangat penting karena mendapatkan bagian yang paling diinginkan dari citra *digital*.

ROI memudahkan proses segmentasi dalam *image processing* karena fitur yang diinginkan lebih mudah dikenali. Hal ini karena pada ROI fitur objek sudah akan dibagi dalam *region-region* tertentu sesuai dengan citra objeknya.

3. Analisis Tekstur

Tekstur adalah karakteristik yang ada dalam suatu daerah yang cukup besar sehingga karakteristiknya akan berulang dalam daerah

tersebut (Ahmad, 2005). Sedangkan analisis tekstur merupakan dasar dari berbagai macam aplikasi. Aplikasi dari analisis tekstur meliputi pencitraan medik, identifikasi kualitas suatu bahan dan berbagai aplikasi lainnya. Tujuan dari analisis tekstur adalah dapat mengidentifikasi parameter-parameter dengan ciri atau karakteristik dari objek di dalam gambar atau citra tersebut.

Parameter yang diekstrak dari gambar atau citra merupakan karakteristik objek di dalam citra tersebut yang mempresentasikan bentuk atau tekstur dalam gambar atau citra. Pada analisis citra, pengukuran tekstur dikategorikan menjadi lima kategori utama yaitu: statistis, struktural, geometri, model dasar, dan pengolahan sinyal (Susanto, 2015). Untuk metode statistik analisis tekstur dijelaskan pada Subbab 4 Ekstraksi Fitur.

4. Ekstraksi Fitur

Fitur adalah informasi khusus pada citra. Dengan adanya fitur, peneliti dapat menentukan karakteristik dari sebuah citra sehingga citra tersebut dapat diklasifikasi dengan benar berdasarkan karakteristik yang didapat (Ahmad, 2005). Salah satu bentuk ekstraksi fitur yang digunakan untuk citra DPR adalah analisis tekstur. Tekstur adalah karakteristik yang ada dalam suatu daerah yang cukup besar sehingga karakteristiknya akan berulang dalam daerah tersebut.

Tekstur dapat dikatakan sebagai distribusi spasial dari derajat keabuan di dalam sekumpulan piksel-piksel yang bertetangga, sehingga

occurrence) untuk citra keabuan. Metode statistik orde dua ini disebut GLCM. Metode ini cukup baik dalam merepresentasikan tekstur citra dalam parameter-parameter terukur seperti kontras, korelasi, homogenitas, entropi dan energi (Azhari dkk, 2014).

3) Selain menggunakan matriks GLCM, terdapat metode ekstraksi fitur yang menggunakan matriks *run-length*. *Run* memiliki arti menunjukkan suatu urutan arah pencarian piksel yang memiliki nilai intensitas piksel sama yaitu dengan arah pencarian lurus dari piksel asal (Ahmad, 2005). Metode *Gray Level Run Length Matrix* (GLRLM) merupakan salah satu metode untuk mendapatkan fitur statistik orde tinggi. Nilai statistik *run-length* dapat menunjukkan tingkat kekasaran dari suatu tekstur pada arah tertentu. Tekstur yang halus cenderung lebih banyak memiliki *short runs* dengan intensitas tingkat keabuan yang mirip, sedangkan tekstur kasar memiliki lebih banyak *long run* dengan intensitas tingkat keabuan yang berbeda secara signifikan. Ekstraksi ciri GLRLM merupakan ciri statistik yang mempertimbangkan hubungan antara tiga atau lebih piksel. Pada Ekstraksi ciri GLRLM orientasi sudut yang digunakan sama dengan GLCM, yaitu sudut 0° , 45° , 90° dan 135° .

Oleh karena itu, berdasarkan ketiga orde statistik dari analisis tekstur, metode GLCM dipilih karena metode tersebut cukup baik dalam merepresentasikan tekstur citra pada parameter-parameter terukur seperti kontras, korelasi, homogenitas, entropi dan energi.

b. Matriks Kookurensi

Matriks kookurensi merupakan ketetangaan antar piksel dalam citra pada berbagai arah dan jarak (Saifudin & Fadlil, 2015). Matriks kookurensi merupakan matriks berukuran $n \times n$ dimana n merupakan derajat tingkat keabuan, dengan elemen $P(x_1, x_2)$ yang merupakan nilai peluang bersama (*join probability distribution*) dari pasangan titik-titik dengan derajat keabuan x_1 yang berlokasi pada koordinat (j, k) dengan x_2 yang berlokasi pada koordinat (m, n) . Koordinat pasangan titik-titik tersebut berjarak r dengan sudut θ (Susanto, 2015).

5. GLCM

Teknik ciri statistik orde dua berdasarkan matriks probabilitas ketetangaan antara dua piksel pada jarak dan sudut tertentu disebut sebagai GLCM (Saifudin & Fadlil, 2015). Selain definisi tersebut GLCM dapat dikatakan sebagai metode ekstraksi ciri orde kedua berdasarkan matriks kookurensi, yaitu suatu matriks ketetangaan antara setiap piksel pada citra dari berbagai arah dan jarak (Karima, 2014).

Pendekatan ini bekerja dalam dua tahapan, yaitu: pembentukan sebuah matriks kookurensi dari data citra, dilanjutkan dengan

setiap iterasi pelatihannya. Data-data yang berkontribusi atau yang paling dekat tersebut disebut dengan *support vector* (Prasetyo, 2014).

Pada dasarnya awal ide dari SVM adalah memaksimalkan batas *hyperplane* karena dengan *hyperplane* yang maksimal akan memberikan generalisasi yang lebih baik pada metode klasifikasi. Dengan adanya *hyperplane* nantinya akan menjadi pemisah dua buah kelas data *input space* yaitu +1 dan -1 (Prasetyo, 2014). *Hyperplane* dikatakan maksimal jika jarak antara *hyperplane* dengan data terdekat dari masing-masing kelas sudah optimal.

SVM merupakan penerapan SVM untuk kasus regresi. Dalam kasus regresi *output* berupa bilangan riil atau kontinu. SVM merupakan metode yang dapat mengatasi *overfitting* sehingga akan memberikan hasil yang bagus (Smola dan Schölkopf 2004). Dalam SVM adalah set data dibagi menjadi set latih dan set uji.

Pada set latih akan ditentukan suatu fungsi regresi sehingga dihasilkan pola prediksi yang mendekati target aktual. Data latih diproses menggunakan pelatihan SVM untuk memperoleh model data terbaik (Hermanianto, 2014). Pada intinya bagian terpenting dari algoritma ini adalah mencari suatu bidang yang dapat memisahkan data dengan jarak pemisah optimal dengan mengklasifikasikan data ke dalam dua kelas.

Permasalahannya, dalam dunia nyata seringkali melibatkan masalah-masalah yang *Multiclass*, sehingga SVM dimodifikasi sedemikian sehingga mampu digunakan dalam masalah-masalah klasifikasi *Multiclass*.

biner dengan k adalah jumlah kelas. Terdapat beberapa metode untuk melakukan pengujian setelah keseluruhan $\frac{k(k-1)}{2}$ model klasifikasi selesai dibangun. Salah satunya adalah metode *voting*. Di antara pasangan-pasangan itu, kelas yang paling banyak terpilih oleh sampel data tersebut merupakan kelas sampel data yang bersangkutan. Jika tidak ada kelas yang terbanyak, maka dilakukan analisis terhadap nilai fungsi tujuan sehingga diperoleh pola pengklasifikasi (Prasetyo, 2014).

3) Metode *Error Correcting Output Code* (ECOC) merupakan suatu metode prediksi SVM *Multiclass* yang diinspirasi dari pendekatan teori informasi untuk mengirimkan pesan melalui saluran yang ber-*noise*. Ide dari pendekatan ini adalah dengan menambahkan data redundan ke dalam pesan yang dikirimkan dalam bentuk *codeword* sehingga si penerima dapat mendeteksi kesalahan dalam pesan yang diterima dan bahkan penerima dapat memulihkan pesan asli jika ada sejumlah kesalahan yang kecil. Ide pendekatan tersebut dinamakan sebagai kode Hamming (Prasetyo, 2014) .

Dalam permasalahan SVM *Multiclass*, setiap kelas y_i direpresentasikan dalam string bit dengan panjang n yang disebut sebagai *codeword*. Kemudian dibentuk n

C. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data tulang rahang dari DPR di tulang mandibula untuk menentukan BMD dan untuk mendapatkan karakteristiknya dengan menggunakan analisis tekstur GLCM untuk mendapat ekstraksi fitur yang akan digunakan sebagai *input* bagi SVM *Multiclass* untuk klasifikasi osteopenia dan osteoporosis. Jumlah data citra DPR sebanyak 61 data (24 data tulang normal, 24 data tulang osteopenia, dan 13 data tulang osteoporosis) dari Laboratorium Klinik Pramita Jl. Raya Jemur Andayani 67 Surabaya.

D. Analisis Data

Data tulang rahang dari DPR sejumlah 61 data yang sudah diklasifikasi oleh ahli yang terbagi ke dalam tiga klasifikasi yaitu (24 data tulang normal, 24 data tulang osteopenia, dan 13 data tulang osteoporosis). Data dibagi menjadi dua bagian. Bagian pertama sebagai data *training* sejumlah 45 data (18 data tulang normal, 18 data tulang osteopenia, dan 9 data tulang osteoporosis), dan bagian kedua sebagai data *testing* sejumlah 16 data (6 data tulang normal, 6 data tulang osteopenia, dan 4 data tulang osteoporosis).

Dalam mencapai tujuan dalam penelitian ini, perlu dilakukan langkah-langkah analisis data dengan menggunakan tiga tahapan, yaitu proses *preprocessing*, ekstraksi fitur menggunakan GLCM dan klasifikasi menggunakan SVM *Multiclass*. Langkah awal yang dilakukan adalah perbaikan kualitas citra atau biasa disebut sebagai proses *preprocessing* karena hasil citra DPR memiliki intensitas yang berbeda. Proses ini dilakukan dengan

tahapan tahapan berikut: langkah pertama adalah *image enhancement* sebagai perbaikan citra.

Pada tahapan *image enhancement* difokuskan pada *adaptive histogram equalization* karena citra DPR memiliki penyebaran intensitas *pixel-pixel* yang berbeda. Setelah citra diproses dengan menggunakan *adaptive histogram equalization*, dilakukan proses *Region of Interest (ROI)* berupa *cropping* sebesar 80 x 100 pixel pada tulang mandibula, dengan tujuan agar citra terfokus pada tulang mandibula. Selanjutnya dilakukan analisis tekstur menggunakan GLCM untuk mendapat ekstraksi fitur yang akan digunakan sebagai *input* bagi SVM *Multiclass* untuk klasifikasi osteoporosis.

E. Pengujian dan Evaluasi

Pengujian pertama dilakukan dengan proses *image preprocessing* dengan mengambil citra DPR yang selanjutnya dilakukan analisis tekstur menggunakan GLCM untuk mendapat ekstraksi fitur yang akan digunakan sebagai *input* bagi SVM *Multiclass* untuk klasifikasi osteopenia dan osteoporosis. Setelah dilakukan klasifikasi menggunakan SVM *Multiclass*, digunakan pengukur kerja klasifikator yang meliputi kontras, korelasi, energy dan homogenitas.

Dalam mencapai tujuan penelitian ini, perlu langkah-langkah secara urut dan sistematis, adapun Gambar 3.1 dan Gambar 3.2 merupakan representasi dari diagram alir *flowchart* untuk deteksi osteoporosis dan osteopenia menggunakan metode GLCM – SVM *Multiclass* adalah sebagai berikut.

- e. Hasil fitur statistik GLCM diambil dari ciri statistik fitur *contrast*, *energy*, *correlation*, dan *homogeneity*.
- f. Matriks fitur vektor yang diperoleh dari ciri statistik fitur *contrast*, *energy*, *correlation*, dan *homogeneity*, selanjutnya digunakan sebagai inputan SVM *Multiclass*.
- g. Pembagian data yang diperoleh dari Matriks fitur vektor GLCM, data dibagi menjadi data latih dan data uji.
- h. Pemilihan kernel dan parameter SVM, karena data berupa data *nonlinear* yang didapat dari matriks fitur vektor GLCM.
- i. Pembentukan model SVM *Multiclass*
- j. Setelah didapatkan model SVM *Multiclass*, dilakukan tahap pengujian.
- k. Setelah pada tahap pengujian selesai, didapatkan model optimum dari sudut orientasi terbaik GLCM dan kernel terbaik SVM, selanjutnya ditentukan hasil klasifikasi.
- l. Klasifikasi dibagi menjadi tiga kategori yaitu normal, osteopenia dan osteoporosis.

mandibula kanan dan kiri memiliki perbedaan keseimbangan meskipun secara anatomi sama (Azhari, dkk, 2014).

Secara faktor fisiologi ramus mandibula kanan dan kiri memiliki perbedaan keseimbangan, akan tetapi keduanya memiliki selisih nilai kerapatan yang kecil sehingga keduanya memiliki keterkaitan dalam deteksi osteoporosis. Pada penelitian ini, analisis tulang mandibula diukur dalam dua region/bagian topografis tubuh, yaitu regio kanan dan kiri. Pengambilan ROI pada regio kanan sekaligus kiri tulang ramus mandibula akan diakumulasi untuk mendapatkan proporsi trabekula secara keseluruhan. Karena dengan melihat proporsi mandibula, dapat mendeteksi perubahan kualitas tulang atau kerapatan mineral tulang sebesar 94% dari pada melakukan analisa berdasarkan kortikal atau tulang-tulang yang lain.

2. *Image Pre-Processing*

Pada tahap ini citra masukan yang digunakan untuk deteksi osteoporosis adalah citra DPR dengan format bitmap (.bmp) sebanyak 61 data. Format gambar bitmap (.bmp) merupakan format gambar yang paling umum dan merupakan format standar *windows*. File dengan format bitmap cukup bagus karena format tersebut belum terkompresi dan menggunakan sistem warna RGB (*Red, Green, Blue*) yang dicampur menjadi satu.

Data dibagi menjadi dua bagian yaitu data latih dan data uji. Data latih yang digunakan pada penelitian ini sebanyak 45 data yang terdiri dari 18 data tulang normal, 18 data tulang osteopenia, dan 9 osteoporosis. Dan data uji yang digunakan sebanyak 16 yang terdiri dari 6 data tulang normal, 6 data

Citra DPR yang telah diperoleh tidak dapat digunakan secara langsung karena kualitas citra tersebut belum memenuhi standar pengolahan. Citra tersebut memiliki variasi intensitas yang kurang seragam akibat pencahayaan yang tidak merata, dan kontras yang lemah. Citra dengan kualitas yang rendah memerlukan langkah-langkah perbaikan atau peningkatan kualitas untuk memfasilitasi pengolahan yang akan digunakan. Oleh karena itu, perlunya langkah-langkah *preprocessing* untuk memperbaiki kualitas citra. Pada tahap ini, dilakukan proses *image enhancement* berupa pengontrasan citra *grayscale* dengan *adaptive histogram equalization*, dan ROI. Berikut akan dijelaskan lebih rinci mengenai tahapan *pre-processing* tersebut:

a. *Image Enhancement*

Perbaikan kualitas diperlukan karena citra DPR yang digunakan sebagai objek pembahasan mempunyai kualitas yang buruk, seperti citra memiliki *noise*, citra DPR terlalu terang, citra DPR terlalu gelap, kabur dan citra kurang tajam, dan sebagainya. Pada tahapan ini, citra DPR diperbaiki dengan menggunakan *adaptive histogram equalization*.

b. *Adaptive Histogram Equalization*

Citra DPR yang digunakan sebagai objek pembahasan mempunyai kualitas yang buruk. Oleh karena itu, proses *adaptive histogram equalization* bertujuan untuk memperoleh penyebaran histogram yang merata, sedemikian sehingga setiap derajat keabuan citra DPR memiliki jumlah *pixel* yang seragam. *Adaptive histogram*

B. Ekstraksi Fitur

Fitur adalah informasi khusus yang dimiliki sebuah citra. Adanya fitur pada peneliti dapat menentukan karakteristik dari sebuah citra sehingga citra tersebut dapat diklasifikasi dengan benar berdasarkan karakteristik yang didapat. Fitur yang difokuskan pada penelitian ini merupakan fitur mandibula dengan ukuran 100 x 80 piksel. Fitur mandibula baik kanan maupun kiri dianalisis tekstur menggunakan GLCM.

GLCM merupakan metode ekstraksi ciri statistik orde kedua dengan menggunakan matriks korelasi yang merepresentasikan hubungan ketetanggaan antar piksel dalam citra pada berbagai arah orientasi dan jarak spasial. Pada penelitian ini, matriks korelasi dibentuk dengan jarak $d = 1$ piksel dan sudut orientasi meliputi 0° , 45° , 90° dan 135° dengan menggunakan persamaan 2.15. Selanjutnya, untuk memperoleh informasi tekstur dari parameter statistik GLCM digunakan Persamaan 2.17 sampai dengan Persamaan 2.21.

Informasi tekstur dari tulang mandibula yang didapat dari proses GLCM bertujuan untuk membedakan dua wilayah yang berdekatan, atau dua wilayah yang saling tumpang tindih. Tekstur dari hasil GLCM ini digunakan untuk membedakan antara jaringan trabekula tulang yang nantinya digunakan untuk deteksi tulang normal, osteopenia, dan osteoporosis.

Fitur mandibula baik kanan maupun kiri dari 45 citra DPR digunakan sebagai data latih sebagai dasar klasifikasi SVM *Multiclass*. Pada penelitian ini fitur statistik GLCM difokuskan pada empat fitur yang meliputi kontras,

...

$$\begin{aligned}\mu_8 &= 8 * (0 + 0 + 0 + 0 + (6.1 \times 10^{-5}) + 0.00046 + 0.0036 + 0.014) \\ &= 0.1426\end{aligned}$$

Tabel 4.6 Mean pada Kolom

Baris j	μ_j
1	0.00935
2	0.36867
3	0.87181
4	1.02933
5	0.69937
6	0.42027
7	0.21438
8	0.14267
$\sum_{i=1}^L \sum_{j=1}^L j(p(i,j))$	3.75586

Menghitung nilai standar deviasi pada baris i dari hasil matriks kookurensi ramus mandibula:

$$\begin{aligned}\sigma_i &= \sqrt{\sum_{i=1}^L \sum_{j=1}^L p(i,j)(i - \mu_i)^2} \\ &= \sqrt{(0.00412 \times [1 - 3.5586]) + (0.00495 \times [2 - 3.5586]) + \dots + (0.01378 \times [8 - 3.5586])} \\ &= \sqrt{2.0335} \\ &= 1.42601\end{aligned}$$

Tabel 4.7 Simpangan Baku pada Baris i

Baris i	σ_i
1	0.03129
2	0.01526
3	0.00016
4	0
...	...
...	...
...	...
64	0.24813
$\sum_{i=1}^L \sum_{j=1}^L p(i,j)(i - \mu_i)^2$	2.0335
σ_i	1.42601

analisis tulang mandibula pada citra DPR ini membutuhkan pendekatan kernel pada fitur data awal.

Kernel yang digunakan pada penelitian ini meliputi kernel *polynomial*, RBF (*gaussian radial basis function*), *multilayer perceptron*, dan kernel *quadratic*. Berdasarkan semua data atribut yaitu hasil ekstraksi fitur menggunakan GLCM berupa kontras, korelasi, energi, dan homogenitas, dari berbagai orientasi sudut dan jarak $d = 1$ piksel, maka akan dilihat perbedaan hasil *confusion matrix* terhadap penggunaan berbagai kernel.

3. Penggunaan Kernel *Polynomial*

Terdapat beberapa percobaan yang dilakukan dalam penelitian ini, pada pengklasifikasian SVM *Multiclass* ini penggunaan kernel *polynomial* dilakukan pada hasil parameter fitur statistik dari ekstraksi fitur GLCM pada orientasi sudut $0^0, 45^0, 90^0$ dan 135^0 dan pada jarak $d = 1$ piksel. Klasifikasi dilakukan dengan menggunakan pelatihan dan pengujian terhadap citra DPR. Pelatihan yang digunakan sebanyak 75% dan pengujian yang dilakukan sebanyak 25%. Selanjutnya pengukuran kerja klasifikator SVM *Multiclass* dilakukan menggunakan empat pengukur kinerja, yaitu akurasi, sensitivitas, spesifisitas dan *precision* pada persamaan 2.31 sampai persamaan 2.34. Hasil percobaan dengan empat sudut orientasi menggunakan kernel *polynomial* dinyatakan pada Tabel 4.17.

Tabel 4.17 Confussion Matrix dengan Kernel Polynomial pada Data Uji

Sudut	Pengukur Kerja Klasifikator	Training	Testing
0°	Akurasi	75,5%	62,5%
	Sensitivitas	72,2%	55,6%
	Spesifisitas	86,8%	80%
	Precision	78%	42%
45°	Akurasi	66,67%	81,25%
	Sensitivitas	64,8%	75%
	Spesifisitas	82,7%	90%
	Precision	64,5%	88,89%
90°	Akurasi	68,89%	81,25%
	Sensitivitas	66,67%	55,56%
	Spesifisitas	83,6%	80%
	Precision	66,4%	42,3%
135°	Akurasi	80%	81,25%
	Sensitivitas	78,2%	75%
	Spesifisitas	89,2%	90%
	Precision	81,67%	88,89%

4. Penggunaan Kernel RBF

Sama seperti kernel *polynomial*, penggunaan kernel RBF dilakukan pada hasil parameter fitur statistik dari ekstraksi fitur GLCM pada orientasi sudut 0°, 45°, 90° dan 135° dan pada jarak $d = 1$ piksel. Hasil percobaan dengan empat sudut orientasi menggunakan kernel RBF dinyatakan pada Tabel 4.18.

Tabel 4.18 Confussion Matrix dengan Kernel RBF pada Data Uji

Sudut	Pengukur Kerja Klasifikator	Training	Testing
0°	Akurasi	62,2%	37,5%
	Sensitivitas	59,25%	38,89%
	Spesifisitas	80,86%	68,33%
	Precision	60,2%	38,89%
45°	Akurasi	55,56%	31,25%
	Sensitivitas	53,7%	33,33%
	Spesifisitas	77,78%	65%
	Precision	55,16%	34,76%
90°	Akurasi	60%	31,25%
	Sensitivitas	57,4%	33,33%
	Spesifisitas	79,9%	65%
	Precision	58,4%	34,76%
135°	Akurasi	64,44%	31,25%
	Sensitivitas	61,11%	50%
	Spesifisitas	81,79%	65,56%
	Precision	62,22%	33,33%

3. Berdasarkan analisis citra *dental panoramic radiograph* pada ROI ramus mandibula yang digunakan sebagai dasar *computer-aided diagnosis* sistem menggunakan GLCM dan SVM *Multiclass* telah dapat digunakan sebagai deteksi osteoporosis. Ekstraksi fitur GLCM berdasarkan kombinasi empat fitur statistik untuk mengidentifikasi nilai kepadatan mineral tulang telah menunjukkan sudut orientasi terbaik adalah 135° dengan jarak $d = 1$ piksel serta SVM *Multiclass* terbaik dibangun oleh kernel *polynomial* berderajat dua. Hasil akurasi data uji terbaik yang dihasilkan sebesar 81,25%, sensitivitas sebesar 75%, spesifisitas sebesar 90%, dan *precision* sebesar 88,89%.

B. Saran

Penelitian mengenai analisis citra DPR pada tulang mandibula untuk deteksi osteoporosis menggunakan metode GLCM – SVM *Multiclass* ini masih banyak kekurangan. Sehingga, peneliti menyarankan beberapa hal sebagai bahan perbaikan dan pengembangan kedepannya, diantaranya adalah:

1. Pengambilan ROI pada tulang mandibula sebaiknya dilakukan pada bagian kondilus mandibula, penelitian sebelumnya mengatakan bahwa kondilus mandibula mempunyai beban besar dan mengandung banyak trabekula (98,6%).
2. Penentuan ROI pada daerah ramus mandibula seharusnya merata pada setiap citra. Hal ini karena fisiologi ramus mandibula pada citra DPR tidak sama. Sehingga, sebaiknya dilakukan penentuan ROI otomatis yang dapat digunakan untuk menyamakan daerah ramus mandibula.

