

Sistem Pengukuran Lebar Cortical Bone Berbasis Active Shape Model pada Citra Panorama Gigi

Gede Wirya Wardhana, Agus Zainal Arifin, Dini Adni Navastara, Hudan Studiawan
Email : agusza@cs.its.ac.id, wirya_it04@yahoo.com
Jurusan Teknik Informatika, Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya

Abstrak

Active Shape Model (ASM) adalah suatu metode yang dapat digunakan untuk mendapatkan tepi dari suatu objek dalam suatu citra. Dengan menempatkan titik-titik yang disebut sebagai *landmark point* sebagai representasi kontur, ASM dapat menemukan bentuk umum dari suatu objek dalam citra.

Paper ini mengusulkan suatu sistem yang mampu secara otomatis mengukur lebar *cortical bone* dengan menggunakan metode berbasis ASM. Pengukuran dilakukan pada *boundary* hasil *fitting* antara model statistik yang dihasilkan oleh metode ASM dengan objek dalam citra. Dalam paper ini juga diteliti berapa jumlah yang optimal titik-titik sampel dalam membentuk suatu shape dari objek *cortical bone*.

Dalam uji coba terhadap 100 citra panorama gigi diperoleh jumlah titik yang optimal dalam *training set* adalah 50 titik. Sedangkan perbandingan hasil pengukuran dengan sistem ini terhadap hasil pengukuran secara manual mampu mencapai korelasi 90 %.

Keyword: *Active Shape Model (ASM)*, Pengukuran Lebar Cortical Bone, Citra Panorama Gigi.

1. Pendahuluan

Pengukuran lebar *cortical bone* sangat berguna untuk diagnosa penyakit terutama penyakit yang berhubungan dengan kerapuhan tulang. Pengukuran yang dilakukan secara umum adalah pengukuran secara manual. Pengukuran lebar *cortical bone* secara manual sangat rentan terhadap *intra observer* dan *inter observer error*[1]. *Error* yang dimaksud adalah perbedaan hasil pengukuran oleh seseorang dapat berbeda dengan orang yang lain. Demikian pula hasil pengukuran seseorang pada saat yang berbeda, sangat mungkin berbeda juga. Hal ini secara manusiawi disebabkan persepsi dari seseorang terhadap tepi suatu citra dapat berubah setiap saat. Ketida-konsistenan tersebut sangat berkaitan dengan situasi dan kondisi dari *observer* pada saat pengukuran yang menyebabkan pengukuran lebar *cortical bone* tersebut berbeda-beda.

Di sisi lain, kebutuhan untuk menganalisa perubahan morfologi pada citra dental panorama gigi sangat dibutuhkan untuk membantu pada dokter mendiagnosa

berbagai penyakit, termasuk diantaranya osteoporosis. Agus [1] dan Devlin [2] telah melakukan membuat suatu sistem semi otomatis yang cukup efektif mengukur lebar *cortical bone*. Namun demikian pengukuran secara otomatis penuh dan tidak bergantung kepada *user* sangat dibutuhkan guna menanggulangi kelemahan-kelemahan yang dimiliki oleh pengukuran *cortical bone* secara manual.

Paper ini mengusulkan suatu sistem yang mampu secara otomatis mengukur lebar *cortical bone* dengan menggunakan metode berbasis *Active Shape Models (ASM)*. Metode ini menitikberatkan pada penggunaan titik-titik pada tepi objek citra yang akan diukur lebarnya. Titik-titik tersebut akan mengalami proses penyesuaian bentuk atau proses *aligning shape* yang bertujuan untuk mengurangi variasi jarak antar titik dalam shape. Kumpulan *shape* yang mengalami proses *aligning* ini akan dicari model statistiknya yang mana nantinya model inilah yang digunakan untuk mencari tepi dari objek *cortical bone*. Jumlah titik sampel atau yang disebut *landmark point* sangat menentukan tingkat akurasi pengukuran. Karena itu riset ini juga berusaha memberikan rekomendasi jumlah titik yang paling optimal dalam mengukur *cortical bone*.

2. Active Shape Model (ASM)

Active Shape Model adalah suatu metode berbasis komputer yang digunakan untuk mencari suatu batas objek dalam suatu citra [3]. ASM sebenarnya menggunakan informasi yang nyata atau informasi yang sesungguhnya tentang bentuk objek yang dicari. Dalam ASM, pada setiap objek atau struktur citra direpresentasikan dengan suatu kumpulan titik-titik.


Setiap titik ditempatkan dengan cara yang sama pada setiap *training set* pada objek dalam citra, dan ini diselesaikan secara manual. Kumpulan titik-titik ini disejajarkan atau diatur secara otomatis untuk meminimalkan variasi jarak dari posisi diantara titik-titik yang ekuivalen. Dengan menguji secara statistik dari posisi titik yang telah dilabeli maka didapatkan suatu *Point Distribution Model (PDM)*. Model ini menunjukkan rata-rata posisi dari titik-titik tersebut, dan memiliki suatu

parameter jumlah yang berfungsi untuk mengontrol suatu *mode of variations* yang ditemukan pada *training set*.

ASM adalah suatu model statistik yang menjelaskan “seperti apa bentuk obyek tersebut” dalam artian *shape* [6]. ASM dibuat melalui training citra sampel yang batas-batas dari objek dalam image tersebut telah disusun oleh *user*. Setelah citra mengalami proses *training*, ASM akan dapat digunakan untuk menempatkan model ke dalam objek yang terdapat dalam citra yang baru dengan mencocokkan modelnya, yang menjabarkan perkiraan *shape* dan *appearance* dari citra baru tersebut.

ASM merupakan tipe model *template* yang dapat berubah atau *deformable template model* yang tidak hanya memaparkan satu *shape* objek baku tapi juga memaparkan cara mencari bentuk umum dari objek dalam sample citra. ASM memiliki suatu keuntungan yang sangat penting dibandingkan dengan metode lain untuk menempatkan suatu object dalam image karena ASM secara spesifik mangacu pada objek untuk mendapatkan variasi dari objek tersebut melalui suatu *training*.

ASM terdiri atas dua komponen terpisah yang memaparkan *shape* dari suatu objek. *Shape* objek dijelaskan dengan *mean* dari *Point Distribution Model (PDM)*, dimana PDM tersebut dihasilkan melalui analisa statistik dari *object shape* yang telah diproses melalui proses *training*. Kontur dalam dari tiap *training images* dijelaskan sebagai suatu kumpulan *landmark point* berjumlah *n* yang secara manual ditandai oleh pengguna. Setiap kontur dapat digambarkan sebagai suatu vektor x ($x=[x_1, y_1, x_2, y_2, \dots, x_n, y_n]$) dimana (x_i, y_i) adalah posisi *landmark point* ke-*i* dalam kontur tersebut. Kontur *training* akan dilakukan suatu penyesuaian atau *aligned* dengan melakukan *scaling*, *rotation* dan *translation*. Kemudian, untuk menjelaskan inti dari cara ini dalam rangka merubah bentuk dari *shape*, *Principal Component Analysis (PCA)* akan diterapkan dengan menggunakan deviasi dari setiap vektor dalam *training shape* dari *main shape* vektor \bar{x} . PDM merepresentasikan *shape* dalam bentuk *mean shape* dan kumpulan *mode of variation* linear yang menggambarkan satu variasi dari *training images*.



Gambar 1. tahapan proses dalam sistem pengukuran lebar cortical bone berbasis *active shape model*.


2.1. Pelabelan *Training set*

Pelabelan model suatu *shape* sangat penting. Setiap titik merepresentasikan sebagian atau keseluruhan dari objek dalam *image*. Metode ini bekerja dengan melihat kecenderungan bahwa tiap titik atau *point* yang telah diisikan bergerak bersama-sama dalam *shape* yang berubah-ubah. Jika pelabelan tidak benar dengan penempatan sebagian titik pada *training shape*, maka metode ini akan gagal untuk mendapatkan variasi dari *shape* dalam *training set*. Gambar 2 memperlihatkan suatu peletakan titik pada objek transistor.

Sebelum pelabelan bentuk dari *training set* didefinisikan, jumlah titik-titik yang cukup dan dapat mewakili bentuk objek dalam suatu citra. Disini setiap *training set* ditempatkan suatu titik secara manual oleh *user*. Ini penting untuk menjamin bahwa peletakan titik-titik tersebut dilakukan secara akurat.

$$x_i = [x_{i0}, y_{i0}, x_{i1}, y_{i1}, \dots, x_{in-1}, y_{in-1}]^T, \quad (1)$$

dimana, $1 \leq i \leq N$.



Gambar 2. Contoh Pelabelan titik-titik pada batas-batas pada *training transistor*

2.2. Penyesuaian Bentuk (*Aligning Shapes*)

Dalam ASM metode pemodelan bekerja dengan melakukan pengujian secara statistik terhadap koordinat titik yang telah diberikan label dalam *training set*. Dalam rangka untuk membandingkan titik-titik yang equivalent dari bentuk yang berbeda, maka hal tersebut harus disesuaikan dengan memperhatikan sumber-sumber koordinat. Disini digunakan suatu penyesuaian dengan penskalaan, rotasi, dan translasi *training set* sehingga hasil penyesuaian didapatkan secepat mungkin. Disini juga dilakukan minimisasi jumlah bobot jarak diantara titik-titik yang ekuivalen pada bentuk-bentuk yang berbeda.

Dinotasikan suatu x_i yang merupakan vektor yang mendeskripsikan titik-titik sejumlah *n* dari bentuk ke - *i*

$$x_i = [x_{i0}, y_{i0}, x_{i1}, y_{i1}, \dots, x_{in-1}, y_{in-1}]^T, \quad (1)$$

dimana $1 \leq i \leq N$

$$E_j = (x_i - M[s_j, \theta_j][x_j] - t_j)^T W (x_i - M[s_j, \theta_j][x_j] - t_j), \quad (2)$$

dimana $M[s, \theta]$ $[x]$ adalah rotasi θ dan skala *s*. misal diberikan 2 bentuk objek yang sama, x_i dan x_j . Disini dapat digunakan θ_j , dan s_j dan translasi (t_{x_j}, t_{y_j}) yang memetakan x_i pada $M[s_j, \theta_j][x_j]$ dan t_j sehingga untuk meminimasi bobot adalah

$$M[s, \theta] \begin{bmatrix} x_{jk} \\ y_{jk} \end{bmatrix} = \begin{bmatrix} (s \cos \theta)x_{jk} - (s \sin \theta)y_{jk} \\ (s \sin \theta)x_{jk} + (s \cos \theta)y_{jk} \end{bmatrix} \quad (3)$$

dimana

$$t_j = (t_{xj}, t_{yj}, \dots, t_{xj}, t_{yj})^T \quad (4)$$

dan W adalah matriks diagonal dari bobot untuk setiap titik.

Bobot ditentukan untuk menandakan bahwa suatu titik signifikan yang artinya titik tersebut adalah yang paling stabil diantara kumpulan titik yang lainnya. Disini bobot dinotasikan sebagai suatu matriks bobot yang di definisikan sebagai berikut :

$$w_k = \left(\sum_{i=0}^{n-1} V_{R_{kl}} \right)^{-1} \quad (5)$$

R_{kl} adalah jarak antara titik-titik k dan l adalah bentuk; $V_{R_{kl}}$ adalah varian dalam jarak dalam suatu bentuk objek; sehingga dapat ditentukan suatu bobot, w_k untuk titik ke-k dengan

Jika suatu titik cenderung untuk berpindah ke sebagian besar daerah bentuk objek, maka jumlah varian akan semakin besar, dan bobot yang semakin kecil akan di dapatkan. Begitu juga sebaliknya jika suatu titik cenderung untuk tidak berpindah maka jumlah varian akan kecil dan bobotnya akan semakin besar sehingga untuk mencocokkan titik-titik tersebut dengan bentuk-bentuk yang berbeda akan menjadi lebih mudah. Berikut adalah langkah-langkah penyesuaian atau pengaturan bentuk pada suatu kumpulan *shape* yang berjumlah N :

1. Rotasikan, skalakan, dan translasikan setiap *shape* untuk penyesuaian dengan *shape* pertama dalam kumpulan *shape* tersebut.
2. Ulangi :
 - a. Hitung *mean shape* dari *shape* yang telah disesuaikan atau diatur.
 - b. Normalisasi orientasi, skala dan titik asal dari mean yang telah didapatkan ke arah dan *shape* yang sesuai.
 - c. Ulang penyesuaian atau pengaturan *shape* tersebut untuk setiap *shape* dengan mean yang telah didapatkan sebelumnya.
3. Iterasi selesai sampai proses mendapatkan hasil *shape* yang konvergen.[4]

Normalisasi mean ke skala dan posisi yang sesuai dalam setiap iterasi adalah untuk meyakinkan bahwa algoritma tersebut konvergen. Tanpa melakukan ini ada suatu efek konstrain $4(N-1)$ dalam variable $4N$ (θ , s , t_x , t_y untuk setiap N bentuk) dan algoritma ini memiliki kondisi yang buruk dimana mean akan menyusut, rotasi, atau batasnya menjadi tidak terbatas. Konstrain pada posisi dan skala dari mean mengikuti persamaan yang memiliki solusi unik. Begitu juga mean diskalakan, dirotasi dan

ditranslasi sehingga mean dapat dicocokkan dengan bentuk pertama atau pada pengaturan bentuk yang telah ditentukan, seperti memilih asal dari titik pusat gravitasi. Memilih orientasi adalah seperti memilih bagian tertentu dari bentuk yaitu bagian atas bentuk, dan skala seperti suatu jarak diantara dua titik pada satu bentuk objek. Sebagai catatan normalisasi mean dari bentuk dan kemudian penyesuaiannya untuk pencocokan adalah tidak sama dengan normalisasi pada setiap bentuk individual. Jika setiap bentuk dinormalisasi dalam skala dengan mengatur jarak diantara dua titik dalam satu unit, korelasi buatan dipaksa ke dalam kumpulan bentuk untuk mengubah model. Bagaimanapun juga, jika setiap bentuk disesuaikan atau di atur dengan mean, setiap bentuk tersebut akan memiliki skala yang sama untuk mean tersebut. Dalam kasus ini posisi titik penanda akan di pilih mean yang paling cocok sehingga dapat menghasilkan model yang lebih baik.[3]

Dinotasikan mean vektor sebagai \bar{x} , dan diferensial vektor antara vektor x_i dan \bar{x} sebagai dx_i , maka dapat dituliskan

$$dx = x - \bar{x} \quad \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (6)$$

kovarian matrik dari penanda atau landmarks dari tiap-tiap bentuk dapat dituliskan dengan

$$S_x = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T \quad (7)$$

$$Sp_k = \lambda_k p_k, \quad \lambda_k \geq \lambda_{k+1}$$

Direpresentasikan deferensial dx_i sebagai kombinasi linear dari *principal component* yang dapat dituliskan dengan

$$dx_i = b_{i0}p_0 + b_{i1}p_1 + \dots + b_{i2n-1}p_{2n-1} \quad (8)$$

diamana p_l adalah vektor ke-l dari *principal component axis* atau vektor dan b_{il} adalah skalar dari bobot p_l kemudian kita normalisasikan menjadi suatu *unit length* $p_l^T p_l = 1$.

$$p_l^T p_m = \begin{cases} 1 & l = m \\ 0 & l \neq m \end{cases} \quad (9)$$

secara ekuivalen dapat ditulis

$$x_i = \bar{x} + dx_i \quad \text{dan} \quad dx_i = P b_i, \quad \text{dimana} \\ b_i = [b_{i0} \ b_{i1} \ \dots \ b_{i2n-1}]^T \quad \text{dan} \quad P = [p_0 \ p_1 \ \dots \ p_{2n-1}]$$

Ini menghasilkan $x_i = \bar{x} + P b_i$, dan b_i dapat dituliskan sebagai $b_i = P^{-1}(x_i - \bar{x})$. Dengan P sebagai matrik orthogonal maka $P^{-1} = P^T$ dan $b_i = P^T(x_i - \bar{x})$.

2.3 Point Distribution Model Dalam Image Search

Setelah menghasilkan model yang fleksibel, model tersebut akan digunakan untuk pencarian citra atau *image* untuk mencari contoh baru dari model objek dalam *image*. [5] Ini melibatkan pencarian *shape* dan *pose parameters* yang menyebabkan model tepat dengan struktur dari citra. Model yang telah di hasilkan dapat didefinisikan dengan

$$X = M[s, \theta][x] + X_c, \quad (10)$$

dimana


$$X_c = (X_c, Y_c, X_c, Y_c, \dots, X_c, Y_c)^T$$

$M[s, \theta]$ adalah rotasi oleh θ dan *scaling* oleh s , dan (X_c, Y_c) adalah posisi dari pusat model.

Disini akan dijelaskan metode iteratif untuk mencari X yang sesuai dengan memberikan suatu pendekatan yang tinggi. Ini dapat diaplikasikan jika tidak ada pengetahuan yang penting dalam lokasi yang diekspektasikan dari objek. Dalam praktiknya, *starting value* dari X tidak harus terlalu dekat dengan solusi akhir, jadi untuk beberapa praktik metode ini dapat digunakan. [3]


2.4 Perhitungan Suggested Movement Untuk Tiap Titik

Diberikan suatu nilai estimasi awal dari posisi untuk kumpulan titik-titik yang dicoba untuk dicocokkan (*fitting*) pada suatu objek citra atau *image* dan disesuaikan untuk mencari kumpulan *adjustments* yang akan menggerakkan setiap-setiap point ke arah posisi yang lebih baik.



Gambar 3. Bagian dari object image dengan perkiraan model yang akan dicocokkan (*fitting*)


Ketika model *points* merepresentasikan batas dari objek sesuai dengan Gambar 3, titik-titik ini akan bergerak menuju batas dari objek pada citra. Ada banyak sekali pendekatan yang dapat digunakan. Dalam contoh ini digunakan suatu *adjustment* sepanjang batas model yang bergerak ke arah batas citra yang terkuat, dengan *magnitude* yang proporsional ke arah *edge* yang lebih kuat seperti yang diperlihatkan pada Gambar 4.



Gambar 4. Perkiraan pergerakan titik sepanjang batas normal kearah batas image yang terkuat.

Pendekatan alternatif adalah menghasilkan suatu citra yang potensial, yang dimungkinkan untuk tiap *model point*. Kemiripan untuk tiap titik dalam *image*. *Adjustment* untuk tiap-tiap posisi titik bisa didapatkan dari gradient dari citra pada estimasi dari titik tersebut. *Adjustmen* ini dapat dinotasikan sebagai :

$$dX = (dX_0, dY_0, \dots, dX_{n-1}, dY_{n-1})^T \quad (11)$$



Gambar 5 : Adjustmen dari tiap titik

2.5 Perhitungan Perbahan Pose dan Shape Parameters

Posisi awal dari point-point atau titik-titik dalam *image* dinotasikan dengan :

$$X = M[s, \theta][x] + X_c. \quad (12)$$

Untuk menghitung *residual adjustmen* dx dalam model koordinat lokal maka dapat dinotasikan sebagai :

$$M(s(1+ds), (\theta+d\theta))[x+dx] + (X_c+dX_c) = (X+dX) \quad (13)$$

Sehingga

$$M(s(1+ds), \theta+d\theta)[x+dx] = (M(s, \theta)[x] + dX)(X_c + dX_c) \quad (14)$$

dan selama

$$M^{-1}(s, \theta)[] = M(s^{-1}, -\theta)[] \quad (15)$$

maka didapatkan

$$dx = M((s(1+ds))^{-1}, -(\theta+d\theta))[y] - x, \quad (16)$$

dimana $y = M(s, \theta)[x] + dX - dX_c$.

Persamaan (13) memberikan cara untuk menghitung perkiraan pergerakan pada titik-titik x dalam model koordinat local. Pergerakan ini tidak secara umum konsisten terhadap *shape model*. Dalam rangka untuk menerapkan *shape constrains*, ditransformasikan dx ke dalam ruang model parameter, yaitu db , yaitu perubahan model parameter yang digunakan untuk melakukan *adjustmeny* terhadap model *points* mendekati dx dimana dapat dinotasikan sebagai

$$\bar{x} = \bar{x} + Pb \quad (14)$$

dan akan dicari db sehingga

$$x + dx \approx \bar{x} + P(db) \quad (15)$$

Selama hanya ada $t < 2n$, *mode of variation* berlaku dan dx dapat berpindah atau bergerak sehingga titik dalam $2n$ memiliki derajat yang berbeda. Disini akan hanya dicapai suatu perkiraan untuk persyaratan deformasi.

Pengurangan persamaan (14) dengan persamaan (15) menjadikan

$$dx \approx P(db) \quad (16)$$

sehingga

$$db = P^T dx \quad (17)$$

selama $P^T = P^{-1}$ sebagai kolom dari P satu sama lain orthogonal.

Ini bisa dilihat bahwa persamaan (17) ekuivalen untuk menggunakan *least-squares approximation* untuk menghitung *shape parameter adjustment*, db.

2.6 Pembaharuan Pose dan Shape Parameters

Persamaan (13) menjelaskan cara untuk menghitung perubahan *pose variables* dan *adjustments*, dX_c , dY_c , $d\theta$, dan ds , dengan *shape parameters* db yang digunakan untuk meningkatkan pencocokan antar model objek dan citra. Di sini diterapkan suatu persamaan untuk memperbaharui parameter dalam suatu skema iteratif.

$$X_c \rightarrow X_c + w_t dX_c \quad (18)$$

$$Y_c \rightarrow Y_c + w_t dY_c \quad (19)$$


$$\theta \rightarrow \theta + w_\theta d\theta \quad (20)$$

$$s \rightarrow s(1+w_s ds) \quad (21)$$


$$b \rightarrow b + W_b db, \quad (22)$$

3. Hasil Dan Evaluasi.

Setelah uji coba dilakukan dilakukan pada 100 *cortical bone* bagian kanan dan kiri yang merupakan *region of interest* dari citra panorama gigi, hasil dari ujicoba pengukuran lebar *cortical bone* dengan metode ASM ini kemudian akan dianalisa korelasinya antara pengukuran manual dengan pengukuran lebar *cortical bone* berbasis ASM.




Gambar 6. Hasil Pelabelan



Gambar 7. Kumpulan *shape* yang belum mengalami proses *aligning*



Gambar 8. Kumpulan *shape* yang Telah mengalami proses *aligning*



Gambar 9. Inisialisasi awal dan hasil *fitting* dengan *training set* yang memiliki 50 titik.

3.1 Evaluasi Kinerja Pembuatan Model Statistik pada Training set

Gambar 6 memperlihatkan kumpulan *shape* yang belum mengalami proses *aligning* sedangkan Gambar 7 merupakan kumpulan *shape* yang telah mengalami proses *aligning*. Terlihat pada Gambar 7 bahwa kumpulan *shape* yang telah mengalami proses *aligning* memiliki kumpulan *shape* yang lebih rapat dan teratur dibandingkan dengan yang belum mengalami proses *aligning*. Suatu model *shape* yang baik adalah model *shape* yang dapat menangkap sebanyak mungkin variasi-variasi bentuk dan kontur yang terwakili dalam titik-titik di dalamnya. Semakin banyak jumlah citra dan jumlah titik yang digunakan dalam proses pembuatan suatu model *shape* dalam *training set* maka kemampuan suatu model untuk mencari suatu tepi dari objek akan semakin baik.

3.2 Evaluasi Kinerja Pengukuran Lebar Cortical Bone Berbasis Active Shape Model (ASM).

Setelah uji coba pengukuran lebar *cortical bone* terhadap 100 citra panorama gigi dilakukan, akan dilakukan evaluasi kinerja terhadap pengukuran lebar *cortical bone* dengan data pengukuran manual. Dimana yang diukur disini adalah korelasi pengukuran lebar *cortical bone* berbasis ASM terhadap pengukuran manual. Tabel 1 memperlihatkan selisih rata-rata antara pengukuran lebar *cortical bone* berbasis ASM dengan pengukuran lebar *cortical bone* secara manual yaitu untuk *Training set* dengan 10 titik memiliki selisih rata-rata 0.45 milimeter di *cortical bone* bagian kanan, dan 0.58

milimeter di *cortical bone* bagian kiri, untuk *Training set* dengan 25 titik memiliki selisih rata-rata 0.40 milimeter untuk *cortical bone* bagian kanan dan 0.45 milimeter untuk bagian kiri sedangkan untuk *Training set* dengan 50 titik memiliki selisih rata-rata 0.04 milimeter untuk *cortical bone* bagian kanan dan 0.33 milimeter untuk *cortical bone* bagian kiri, untuk 70 titik memiliki selisih rata-rata 0.04 milimeter untuk *cortical bone* bagian kanan dan 0,22 untuk *cortical bone* bagian kiri. Terlihat pada Tabel 1 bahwa semakin banyak jumlah titik yang digunakan dalam *Training set* maka pengukuran lebar *cortical bone* berbasis ASM akan mendekati pengukuran secara manual.

Tabel 2 memperlihatkan bahwa antara pengukuran lebar *cortical bone* berbasis ASM dengan pengukuran lebar secara manual memiliki korelasi 43 % dengan *Training set* yang memiliki 10 titik, 56 % dengan *Training set* yang memiliki 25 titik, 90% dengan *Training set* yang memiliki 50 titik dan 92 % dengan *Training set* yang memiliki 70 titik. Dari Tabel 5.3 terlihat bahwa semakin banyak jumlah titik yang digunakan dalam *Training set* maka pengukuran lebar *cortical bone* berbasis ASM akan semakin mendekati lebar hasil pengukuran manual. Tabel 2 juga memperlihatkan bahwa semakin banyak jumlah titik yang digunakan dalam *Training set* maka persentase korelasinya akan semakin tinggi. Peningkatan persentase korelasi ini disebabkan oleh semakin banyaknya keterwakilan kontur yang direpresentasikan oleh titik-titik yang dimasukkan pada saat proses peletakan titik.

Dari Tabel 2 dapat dilihat bahwa antara jumlah titik 25 dan 50 titik terjadi peningkatan korelasi yang signifikan. Namun antara 50 titik dan 70 titik memiliki selisih korelasi yang lebih kecil daripada selisih korelasi antara 25 titik dengan 50 titik. Sehingga dapat dikatakan bahwa jumlah titik 50 dalam *Training set* sudah cukup mewakili kontur dengan baik dan korelasi yang dihasilkan sudah cukup tinggi. Ini dikarenakan apabila seorang pengguna memasukkan jumlah titik yang lebih tinggi hanya akan dapat menghasilkan korelasi dengan kenaikan yang tidak terlalu signifikan dan tentunya akan memberatkan seorang pengguna dalam membuat suatu *Training set*. Selain itu akan memakan waktu yang cukup lama dalam pembuatan *Training set* dan kontur yang dihasilkan terlalu detail.

Tabel 1. Selisih Rata-rata Pengukuran Lebar Cortical Bone Terhadap Pengukuran Manual dalam milimeter

Jumlah Titik	Selisih Rata -Rata (mm)	
	Kanan	Kiri
10	0.45	0.58
25	0.40	0.45
50	0.04	0.33
70	0.04	0.22

Tabel 2. Korelasi Pengukuran Lebar Cortical Bone dengan Metode ASM dengan Pengukuran Manual

Jumlah Titik	Korelasi
10	43 %
25	56%
50	90 %
70	92%

4. Kesimpulan

Pembentukan suatu model *shape* dapat dilakukan melalui menempatkan titik-titik di sepanjang kontur dari objek dalam citra dimana nantinya titik-titik tersebut akan melalui proses *aligning training set*, pencarian model statistik untuk mendapatkan model statistik dan pada akhirnya digunakan untuk melakukan *fitting* antara model statistik dan objek dari citra.

Persentase korelasi pengukuran lebar *cortical bone* berbasis ASM terhadap pengukuran manual yaitu pada *training set* dengan 10 titik memiliki korelasi 43 % pada *training set* 25 titik memiliki korelasi 56 % , pada *training set* dengan jumlah titik 50 memiliki korelasi 90 % dan *training set* dengan jumlah titik 70 memiliki korelasi 92 %.

Jumlah titik yang digunakan dalam proses pembentukan *shape* memiliki pengaruh pada korelasi terhadap pengukuran manual karena titik-titik ini merepresentasikan kontur dari objek dalam citra tersebut sehingga untuk menempatkan titik-titik tersebut harus dilakukan oleh seseorang yang bisa membaca kontur dari objek tersebut terutama citra radiograph.

Tepi dari objek yang tidak jelas akan sangat mempengaruhi dari proses *fitting* antara model statistik dengan objek dari citra.

5. Referensi

- [1]. Agus Zainal Arifin, A. Asano, A. Taguchi, T. Nakamoto, M. Ohtsuka, M. Tsuda, Y. Kudo, and K. Tanimoto, *Computer-aided system for measuring the mandibular cortical width on dental panoramic radiographs in identifying postmenopausal women with low bone mineral density*, Osteoporosis International, 17, 5, 753-759 (2006).
- [2]. H.Devlin, P.D. Allen, J.Graham, R.Jacobs, K. Karayianni, C.Lindh, P.F. van der Stelt, E.Harrison, J.E.Adams, S. Pavitt, K. Horner, *Automated osteoporosis risk assessment by dentists : A new Pathway to diagnosis*. Bone 2007. Vol. 40. Pp 835-842.
- [3]. T. Cootes, C. Taylor, D. Cooper, J. Graham, *Active Shape Models – Their Training and Application*. *Computer Vision and Image Understanding*, January 1995, Vol. 61, No. 1, pp. 38-59.
- [4]. G. Hamarneh, R. Abu-Gharbieh, T. Gustavsson, *Review Active Shape Models – Part I: Modeling Shape and Gray Level Variations*. Department of Signals and Systems,

Imaging and Image Analysis Group, Chalmers University of Technology, Goteborg, Sweden, 1998.

- [5]. G. Hamarneh, R. Abu-Gharbieh, T. Gustavsson, *Review Active Shape Models – Part II : Image Search and Classification*. Department of Signals and Systems, Imaging and Image Analysis Group, Chalmers University of Technology, Goteborg, Sweden, 1998.
- [6]. Smith, Paul P. Christopher, J. Taylor. *Vertebral Shape : Automatic Measurement with Active Shape Models*. Departments of Medical Biophysics and Diagnostic Radiology, University of Manchester, 1998.