

Penggunaan Jaringan Fungsi Basis Radial Termodifikasi untuk Analisis Sefalometri

Luky Agus H¹, Farida², Rinci Kembang H³, Tutul Indriyani⁴
Teknik Informatika, Institut Teknologi Adhi Tama Surabaya^{1,2,3,4}
lukyagushermanto74@gmail.com

ABSTRACT

Orthodontic treatment is choice to manipulated human 'face' bone, such that gets goods jaw model. Someone who want to undergo orthodontic treatment needs cephalometric analysis . From that analysis, we can get information about patient's condition which is able to be saved in computer database and digital videography that is used by dentist for orthodontic treatment strategy. Modification radial basis function network is radial basis function network that uses new EM-based training algorithm in that learning process. We do hope by using New EM-based training algorithm, we can get the weight faster than usual. This paper proposes about cephalometric analysis using modification radial basis function network. We will analyze cephalography. From cephalometric analysis, we can get information for orthodontic treatment strategy.

Keywords: cephalometric Analysis, Radial Basis Function Network, Orthodontic Treatment

ABSTRAK

Perawatan orthodontic merupakan pilihan untuk dapat memanipulasi jaringan tulang keras sehingga didapat bentuk rahang seperti yang diinginkan dan dimungkinkan. Seorang pasien yang melakukan perawatan orthodontic, terlebih dahulu harus menjalani analisis sefalometri. Karena dengan adanya analisa akan didapatkan informasi tentang kondisi pasien yang bisa disimpan dalam bentuk computer database dan digital videography yang dapat digunakan dokter gigi untuk strategi perawatan orthodontic.

Jaringan fungsi basis radial yang dimodifikasi, yaitu jaringan fungsi basis radial yang proses pembelajarannya menggunakan algoritma new EM-based training. Dengan algoritma new EM-based training diharapkan proses mendapatkan pembobot dalam pembelajaran menjadi lebih cepat. Penelitian ini mengusulkan tentang analisis sefalometri dengan menggunakan jaringan fungsi basis radial yang dimodifikasi. Adapun analisa akan dilakukan pada foto sefalometri. Dari analisa tersebut maka akan didapatkan informasi untuk strategi perawatan orthodontic.

Kata kunci : Analisis Sefalometri, Jaringan Fungsi Basis Radial, Perawatan Orthodontic

PENDAHULUAN

Estetika di dalam *orthodontic* menurut sebagai besar dokter gigi pada umumnya adalah bagaimana menciptakan senyuman yang indah. Senyuman yang indah menawan hanya bisa diciptakan dari wajah indah. Salah satu yang mempengaruhi wajah adalah gigi-geligi beraturan dan gigi yang indah. Dengan kemajuan di bidang teknologi *orthodontic* bisa membantu memperbaiki penampilan wajah [1]. Dari aspek estika wajah berperan dalam meningkatkan rasa percaya diri seseorang. Perawatan yang mengutamakan perbaikan estetika yang berkaitan dengan fungsi pengunyahan bila perlu dilakukan dengan mengkombinasikan perawatan dento-maksilo-fasial dan bedah ortognatik. Pada kasus yang lebih mengutamakan perbaikan estetika wajah dapat dilakukan dengan bedah ortognatik dan bedah plastic [2]. Dalam perawatan *dento-maksilo-fasial*, radio sefalometrik merupakan sarana penting untuk mengukur, mengevaluasi dan menganalisa bentuk dan profil wajah. Radio sefalometrik merupakan salah satu sarana diagnostik dan perawatan yang sangat berperan dalam upaya peningkatan dan pengembangan bidang


ortodonsia [2]. Melalui bantuan perangkat komputer penggunaan radiografi sefalometri akan semakin bermanfaat dan mudah dimanipulasinya.

Orthodontic treatment di Indonesia saat ini sedang mengalami kemajuan pesat seiring dengan tumbuhnya dental mainded di masyarakat kita. Analisa sefalometri yang benar sangat menentukan keberhasilan sebuah perawatan ortho. Penggunaan komputer sebagai media pembantu dalam segala bidang termasuk bidang kedokteran gigi telah menjadi sebuah keharusan untuk meningkatkan kemungkinan keberhasilan sebuah perawatan gigi[3]. Jaringan fungsi basis radial merupakan modifikasi dari jaringan feedforward [4]. Pada tahun 1996, U. Pietruschka dan R. Brause telah mengusulkan penggunaan jaringan fungsi basis radial untuk proses kontrol pada industri karet. Jaringan fungsi basis radial juga telah digunakan untuk pengenalan suara perintah yang terbatas [5], pengenalan wajah [6,7], konversi suara spectra [8] dan registrasi elastik dari gambar medis [9].

Tinjauan Pustaka

Jaringan Fungsi Basis Radial

Jaringan Fungsi Basis Radial adalah jaringan yang memiliki dua lapisan yang bentuk *output unit* -nya berupa kombinasi linier dari fungsi basis yang dihitung dari *hidden unit* [6]. Gambar dibawah ini adalah gambar topologi Jaringan Fungsi Basis Radial.



Gambar 1. Topologi Jaringan Fungsi Basis Radial

Tahap Clustering Data

Pada tahap ini, data dikelompokkan berdasarkan kedekatan tertentu atau data di clusterkan, misalkan dengan kedekatan warna antara dua pixel, kedekatan antara dua nilai titik dan sebagainya. Penentuan *cluster* secara mandiri akan menghasilkan pusat pada kelompok data. Jumlah *kelompok* menentukan banyaknya *hidden unit* yang digunakan.

Dalam rangka penentuan *pusat*, ada dua cara yang bisa ditempuh. Cara yang sederhana dan mudah yaitu dengan menentukan *pusat* secara random dari kelompok data. Kemudian langkah yang lebih rumit, tetapi akan menghasilkan lebih baik yaitu dengan algoritma *clustering*. Bagian ini merupakan tahapan *unsupervised*.

Tahap perbaikan pembobot

Jaringan syaraf tiruan akan menyimpan pengetahuannya pada bobot *neuron-neuron*-nya. Pada tahap pelatihan berikutnya berfungsi untuk mendapatkan nilai nilai bobot *neuron-neuron*-nya. Pada tahap ini, ada rangkaian tahapan perhitungan yang digunakan untuk memperbaharui pembobot. Pada tahap ini juga dibutuhkan training beserta targetnya. Bagian ini merupakan bagian yang bersifat terawasi atau *supervised*. Tahapannya adalah sebagai berikut:

Penentuan sinyal pada *input ke hidden layer* dan menghitung berapa nilai fungsi aktivasinya pada setiap *hidden layer*. Dengan menggunakan perhitungan

$$\varphi(\|x_m - t_j\|) = \exp(-\|x_m - t_j\|^2 / \sigma^2) \dots\dots\dots (1)$$

Dimana: m = 1,2,3,.. sesuai dengan jumlah *training pattern*
 j = 1,2,3,.. sesuai dengan jumlah *hidden unit*
 X vektor *input*
 t vektor data yang dianggap *center*

Menyusun matriks, *Gaussian* dari perhitungan langkah 1.

$$G = \begin{bmatrix} \varphi_{11} & \varphi_{12} & \dots & \varphi_{1C} \\ \varphi_{21} & \varphi_{22} & \dots & \varphi_{2C} \\ \dots & \dots & \dots & \dots \\ \varphi_{M1} & \varphi_{M2} & \dots & \varphi_{MC} \end{bmatrix} \dots\dots\dots (2)$$

dimana : M vektor *input* ke M
 C *hidden unit* ke C
 Kolom terakhir biasanya diisi bias.

Menghitung nilai bobot yang baru (W) dengan hitungan mengalikan *pseudoinverse* dari matrik G, dengan vektor target (d) dari *data training*. Rumusnya:

$$W = (G^T G)^{-1} G^T d \dots\dots\dots (3)$$

Untuk menghitung nilai *output* dari jaringan, digunakan rumus:

$$y(x) = \sum_{i=1}^2 w_i G(\|x - t_i\|) + b \dots\dots\dots (4)$$

dimana b nilai bobot bias $G(x) = \varphi(x)$

Algoritma Ekspektasi Maksimisasi

Algoritma *Expectation Maximization* (EM) adalah suatu metode untuk estimasi maximum likelihood dari parameter untuk data yang tidak lengkap [10]. Dalam rumus asli algoritma EM, model dasar yang dinyatakan dalam hubungan Y dan $Z = \{Y, V\}$, dimana Y disebut data yang tidak lengkap, V data yang hilang, dan himpunan kombinasi Z disebut data yang lengkap. Tujuan dari algoritma adalah menemukan himpunan parameter, yang mana akan memaksimalkan kemungkinan dari nilai yang diobservasi Y. Maksimisasi dilaksanakan dalam kaitan dengan distribusi gabungan Y dan Z [11].

Pada *training* 2 layer *feedforward networks* dengan menggunakan pendekatan *EM-based*. Dengan mempertimbangkan jaringan fungsi basis radial dengan G *Gaussian unit* yang mendekati satu dimensi pemetaan $g(x) : R \rightarrow R$ sebagai berikut:

$$\bar{g}(x) = \sum_{i=1}^G \lambda_i o_i(x) \dots\dots\dots (5)$$

dimana i adalah indeks dari unit-unit fungsi basis radial, λ_i amplitudo dan $o_i(x)$ adalah fungsi aktivasi dari setiap unit, yang diberikan oleh :

$$o_i(x) = \exp\left(-\frac{(x - \mu_i)^2}{2\sigma_i^2}\right) \dots\dots\dots (6)$$

Masalah *training* berisi dalam estimasi amplitudo, λ_i , pusat μ_i dan *variance* σ_i^2 dari model fungsi basis radial yang diberikan oleh himpunan *input* dan berkorespondensi *noisy output* (x_k, y_k) . Observasi *noisy* mempunyai karakteristik model berikut:

$$y_k = \sum_i g_i(x_k; \theta_i) + e_k \dots\dots\dots(7)$$

dimana $g_i(x_k, \theta_i) = \lambda_i o_i(x_k)$, dan biasanya, mengasumsikan bahwa e_k adalah *zero-mean white Gaussian Noisy* dari variance σ^2 . Maka *log-likelihood* dari parameter diberikan oleh:

$$L(\theta; x, y) = K - \frac{1}{2\sigma^2} \sum_k \left(y_k - \sum_i g_i(x_k, \theta_i) \right)^2 \dots\dots\dots(8)$$

dimana K adalah kostanta yang dapat diabaikan untuk proses estimasi, $\theta = \{\theta_1, \dots, \theta_G\}$ dan $\theta_i = (\lambda_i, \mu_i, \sigma_i)$.

Prosedur perhitungan yang lebih efisien untuk memperoleh estimasi *maximum likelihood* adalah berbasis pada algoritma EM. Sebuah pilihan baik untuk data hilang atau data tidak lengkap dari ini algoritma perlu untuk menyederhanakan maksimisasi dari *likelihood*. Bagian seleksi yang berguna untuk masalah ini yang telah diusulkan dengan data lengkap diperoleh dari dekomposisi setiap observasi komponen sinyal G [3], menurut

$$z_{k,i} = g_i(x_k, \theta_i) + e_{k,i}, i = 1..G \dots\dots\dots(9)$$

dimana residual $e_{k,i}$ diperoleh dari dekomposisi *residual total* $e_k = y_k - \sum_i g_i(x_k; \theta_i)$

kedalam komponen G, yaitu

$$e_{k,i} = t_i e_k \quad i = 1, \dots, G \quad \forall k \dots\dots\dots(10)$$

Ini menunjukkan bahwa *decoupling variables* t_i dapat sembarang konstanta, batasan jumlahan 1 [3]. Sebuah dekomposisi dari persamaan residual antara semua *neuron-neuron* diusulkan

$$t_i = \frac{1}{G}, i = 1..G \dots\dots\dots(11)$$

yang terakhir persamaan (11) mendekomposisi residual algoritma EM ini, untuk *training 2 layer feedforward networks*, dapat disimpulkan sebagai berikut:

E-step: for $i=1..G$ hitung


$$\hat{z}_{k,i} = g_i(x_k, \theta_i) + t_i \left(y_k - \sum_{j=1}^G g_j(x_k; \theta_j) \right) \dots\dots\dots(12)$$

M-Step: for $i=1..G$ evaluasi

$$\{\lambda_i, \mu_i, \sigma_i^2\} = \arg \min_{\theta_i} \sum_k (\hat{z}_{k,i} - g_i(x_k; \theta_i))^2 \dots\dots\dots(13)$$

Dimana iterasi notasi indeks telah dihilangkan. Pencatatan masalah dari *training global* sebuah jaringan fungsi basis radial dengan G *neuron* telah dipecahkan kedalam G masalah yang lebih sederhana dari *training* sebuah *neuron* tunggal.

Analisis Sefalometri



Gambar 2. Ukuran Lateral cephalometric: (1) SNA, (2) SNB,(3) ANB, (4) SN-MP, (5) SN-PP, (6) MP-PP, (7) SN□PNS, (8) SV□A,(9) SV□B, (10) N-ANS, (11) ANS-Me, (12) UIP-SN, (13) LIP-MP, (14)PP□U1, (15) SN□U6, (16) SV□U1, (17) overjet, and (18) overbite.

Cephalometry adalah suatu alat penting di dalam hasil diagnosa berkenaan dengan *orthodontic*, perencanaan perawatan, evaluasi ramalan

dan hasil perawatan pertumbuhan. Sumber kesalahan yang utama di dalam analisa *cephalometric* meliputi film radiografis perbesaran, penyusutan, mengukur, merekam dan hal menonjol identifikasi. Analisa *cephalometric computer-aided* lebih cepat di dalam analisa dan didapatnya data dibanding metoda konvensional.

Pembahasan

Secara umum perangkat lunak untuk analisis sefalometri mempunyai struktur sebagai berikut:



Gambar 3. Blok sistem perangkat lunak untuk analisis sefalometri

Preprocessing

Pada tahap ini dilakukan proses proses pendeteksian tepi. Tujuan dari proses ini adalah untuk meningkatkan penampakan garis batas suatu daerah atau objek didalam citra. Untuk mendeteksi tepi gambar dilakukan dengan menggunakan algoritma *Sobel*. Setelah dilakukan proses deteksi tepi langkah selanjutnya dalam *preprocessing* ini adalah menghilangkan *noise* dari gambar. Proses menghilangkan *noise* pada pada gambar sefalometri dilakukan dengan menggunakan *median filtering*, dilanjutkan dengan menyederhanakan gambar sefalometri menjadi gambar hitam putih dengan menggunakan operasi *threshold*.

Ekstraksi (Binerisasi)

Setelah objek-objek yang ada berhasil disederhanakan pada tahap sebelumnya, tahap berikutnya adalah mengekstraksi ciri-ciri tertentu dari setiap objek. Pada tahap ini gambar dibagi menjadi baris sebanyak M dan kolom sebanyak N yang akan didapatkan matrik berukuran M x N. Pada tahap ini dilakukan pembentukan matrik-matrik yang nantinya digunakan pada tahap klasifikasi. Matrik ini nanti akan digunakan untuk proses training. Matriks-matriks ini diperoleh dengan cara mengganti warna hitam dengan angka 1 dan putih dengan angka 0. Dari matrik-matrik ini nantinya digunakan untuk identifikasi bagian-bagian dari sefalometri.

Klasifikasi

Sebelum melakukan analisis sefalometri maka matriks-matriks hasil ekstraksi yang telah diperoleh akan dilakukan proses *training*. Pada proses *training* akan diperoleh ciri-ciri titik yang digunakan pada proses analisis sefalometri. Ciri-ciri titik tersebut akan disimpan dalam bentuk matriks pembobot. Proses *training* dilakukan dengan menggunakan jaringan syaraf tiruan Jaringan Fungsi Basis Radial yang dimodifikasi. Modifikasi Jaringan Fungsi Basis Radial dilakukan agar proses pencarian pembobot agar lebih cepat. Modifikasi ini dilakukan dengan menambahkan algoritma *Expectation Maximization*. Setelah diperoleh ciri-ciri titik maka akan bisa dilakukan prediksi sudut-sudut dan jarak antar titik tertentu yang nantinya digunakan pada analisis sefalometri. Metode analisis sefalometri yang digunakan adalah metode Steiner. Berikut ini adalah jarak dan sudut yang digunakan dalam metode Steiner:

Tabel 1. Norma dan variabel dari analisis Steiner

Sudut SNA	82	(derajat)
Sudut SNB	80	(derajat)
Sudut ANB	2	(derajat)
SND	76-77	(derajat)

Sudut GoGn-SN	32	(derajat)
Sudut bidang oklusal ke SN	14,5	(derajat)
Sudut Intersisal	130-131	(derajat)
I ke NA	4	mm

Sudut I ke NA	22	(derajat)
I ke NB	4	(derajat)
Sudut I ke NB	25	(derajat)
I ke GoGn	93	(derajat)

Daftar Pustaka

- [1] Santoro, M, et al, *Comparison of measurements made on digital and Plaster Models*, American Journal of Orthodontics and Dentofacial Orthopedics, Volume 124, 2002
- [2] Neil Alldrin, Andrew Smith and Doug Turnbull, *Classifying Facial Expression With Radial Basis Function Networks Using Gradiendt Descent and K-means*, University of California , 2003.
- [3] Weinsiea, Feder, *Multi Channel Signal Separation by Decor relation*, IEEE, 1993
- [4] Dan W. Patterson, *Artificial Neural Network Theory and Applications*, John Wiley and Sons, Inc. 1995.
- [5] Juan Carlos Macera and Nipesh Shah, *Voice Command Recognition Using Radial Basis Function Neural Networks*, University of Nevada Reno, 2001.
- [6] Meng Joo Er, Shiqian Wu, Juwei Lu and Hock Lye Toh, *Face Recognition With Radial Basis Function (RBF) Neural Networks*, Transaction On Neural Networks, 2002.
- [7] Su Hongtao, David Dagan Feng and Zhao Rong-chun, *Face Recognition Using Multi-Feature and Radial Basis Function Networks*, Auastralian Computer Society, 2003.
- [8] Carlo Drioli, *Radial Basis Function Networks For Conversion Of Sound Spectra*, Workshop on Digital Audio Effects, 1999.
- [9] Mike Fornefett, Kalr Rohr, and H. Siegfried Stiehl, *Elastic Registration of Medical Images Using Radial Basis Functions with Compact Support*, IEEE Computer Society, pp 402-407, 1999.
- [10] Marcelino Lazar, Ignacio Santamaria and Carlos Pantaleon, *A New EM-Based Traning Algorithm For RBF Networks*, Elsiwier.com/locate, Neural Networks 16, 2002
- [11] Moody, J. and C.J. Darken, *"Fast learning in networks of locally tuned processing units"*, *Neural Computations*, vol. 1, No. 2, pp. 281-294, 1989