Jurnal Vocational Teknik Elektronika dan Informatika
http://ejournal.unp.ac.id/index.php/voteknika/index
Vol. 11, No. 3, September 2023 **P- ISSN: 2302-3295, E-ISSN : 2716-3989**

Klasifikasi Analisis Tekstur Citra Radiografi Panoramik Gigi Untuk Deteksi Menggunakan Metode *K-Nearest Neighbor* (KNN)

Yudhi Diputra[1*], Syafrijon[2], Emilham Mirshad[3]
[1,2,3]Universitas Negeri Padang, Indonesia
Jl. Prof. Dr. Hamka Kampus UNP, Air Tawar Padang, Indonesia
**Corresponding author* e-mail : yudhi.dp@ft.unp.ac.id

ABSTRAK

Osteoporosis merupakan salah satu penyakit yang berkaitan dengan proses penuaan (degeneratif) yang diindikasikan dengan terjadinya penurunan kerapatan yang cepat dan penipisan jaringan tulang sehingga terjadi penurunan kekuatan mekanik tulang dalam mendukung aktivitas sehari-hari. Teknik yang banyak dikembangkan untuk pengukuran yang berkaitan dengan massa tulang, serta dianggap sebagai *gold standard* adalah *Dual Energi X-ray Absorptiometry* (DXA). Beberapa penelitian sebelumnya memberikan peluang pemanfaatan citra radiografi panoramik gigi untuk analisis kerapatan trabekula tulang mandibula. Hasil ini digunakan sebagai sarana dekteksi dini kondisi *Bone Mineral Density* (BMD). Penelitian ini bertujuan melakukan klasifikasi terhadap hasil analisis tekstur menggunakan prinsip *Grey Level Co-occurence Matrix* (GLCM) pada citra panoramik gigi. Dari metode GLCM diperoleh ekstraksi fitur yang selanjutnya dijadikan input bagi *K-Nearest Neighbor* (KNN) untuk melakukan klasifikasi. Uji coba dilakukan menggunakan data BMD vertebra lumbar dan citra panoramik gigi 23 sampel wanita berusia antara 52 – 73 tahun yang telah memasuki masa *postmenopause*. Hasil klasifikasi kelas normal dan osteoporosis menggunakan KNN (9 data latih dan 14 data uji) memberikan pengenalan paling baik dengan akurasi 78,57%, sensitivitas (tingkat benar positif) 100% dan spesifisitas (tingkat benar negatif) 66,67%. Pengenalan paling baik didapatkan menggunakan fitur *contrast*, *energy*, dan *homogeneity* dan kombinasi ketiganya sebagai input bagi klasifikasi KNN.

Kata kunci : Osteoporosis, citra radiografi panoramik, analisis tekstur, *Grey Level Co-occurrence Matrix* (GLCM), *K-Nearest Neighbor* (KNN).

ABSTRACT

Osteoporosis is a degenerative disease which is characterized by a rapid decrease in bone density resulting in a decrease in the mechanical strength of the bones to support daily activities. The gold standard for bone mass measurement is Dual Energy X-ray Absorptiometry (DXA). Several previous studies provided the opportunity to utilize dental panoramic radiographic images for analysis of mandibular trabecular bone density. These results are used as an early detection tool for Bone Mineral Density (BMD) conditions. This research tries to use the feature extraction results of texture analysis using Grey Level Co-occurrence Matrix (GLCM) on dental panoramic images as input for K-Nearest Neighbor (KNN) to carry out classification. The trial was conducted using lumbar vertebral BMD data and dental panoramic images from 23 samples of women aged between 52-73 years who had entered the postmenopausal period. Classification results of normal and osteoporosis using KNN (9 training data and 14 test data) gave the best recognition with an accuracy of 78.57%, a sensitivity of 100% and a specificity of 66.67%. The best recognition is obtained by using contrast, energy, and homogeneity features and their combination as input for KNN classification.

Keywords: *Osteoporosis, dental panoramic radiograph, texture analysis, Grey Level Co-occurrence Matrix (GLCM), K-Nearest Neighbor (KNN)* .

I. PENDAHULUAN

Osteoporosis ialah salah satu gangguan degeneratif yang terkait dengan proses penuaan, ditandai oleh penurunan cepat dalam kerapatan tulang dan penipisan jaringan tulang, mengakibatkan menurunnya kemampuan tulang untuk secara mekanik mendukung aktivitas sehari-hari secara normal. Menurut definisi global, osteoporosis adalah kondisi penyakit pada sistem tulang di mana terjadi penurunan massa tulang yang signifikan dan perubahan pada struktur mikroskopis jaringan tulang, yang berakibat pada peningkatan kerapuhan tulang serta risiko yang lebih tinggi untuk mengalami patah tulang [1].

Gold standar pada pengukuran kerapatan mineral tulang (BMD) adalah *Dual Energi X-ray Absorptiometry* (DXA) [1], meskipun di Indonesia dan pada negara berkembang, pengujian dengan perangkat DXA masih terbatas pada kota-kota besar sehingga menyulitkan akses masyarakat untuk melakukan pengujian BMD [1], [2].

Konsultasi ataupun perawatan kondisi mulut dan gigi pasien yang berpotensi mengalami osteoporosis umumnya meningkat seiring bertambahnya usia. Citra radiografi panoramik merupakan suatu penggambaran secara ekstra-oral dimana dimungkinkan susunan semua gigi diproyeksikan pada satu bidang citra. Pada bidang biomedik, citra radiografi panoramik telah dimanfaatkan untuk berbagai hal seperti penentuan restotasi gigi [3], penentuan usia [4] dan penentuan nilai kerapatan massa tulang [2], [5]–[8]. Pemanfaatan citra radiografi panoramik gigi menunjukan hubungan antara lebar korteks atau trabekula tulang mandibula dengan BMD [2]. Pada wanita yang mengalami osteoporosis setelah menopause, terjadi penurunan jumlah struktur trabekula akibat penurunan hormon estrogen yang berperan dalam mengatur penyerapan kalsium ke dalam tulang [1]. Dengan teknik analisis tekstur, perubahan bentuk arsitektur tulang trabekula akibat osteoporosis mempunyai potensi untuk dianalisis.

Klasifikasi hasil analisis tekstur dapat dilakukan menggunakan teknik *machine learning* yang telah banyak dimanfaatkan di dunia medis, salah satunya dengan metode *K-Nearest Neighbor*. Penggunaan metode *K-Nearest Neighbor* yang telah dilakukan diantaranya dalam klasifikasi Pneumonia, klasifikasi gagal jantung, klasifikasi umur, diagnosa karies gigi dan identifikasi wajah [4], [9]–[12].

Pada penelitian ini akan dikembangkan klasifikasi ekstraksi fitur G*rey Level Co-occurrence Matrix* (GLCM) menggunakan metode *K-Nearest Neighbor* (KNN) untuk penentuan osteoporsis. Uji coba dilakukan menggunakan data BMD vertebra lumbar dan citra panoramik gigi 23 sampel wanita berusia antara 52 – 73 tahun yang telah memasuki masa *postmenopause*. Hasil akhir dari penelitian ini diharapkan dapat digunakan sebagai alternatif berupa *computer aided diagnosis* bagi dokter gigi untuk memberikan informasi dini tentang terjadinya osteoporosis pada pasien.

Analisis Tekstur

Tekstur merupakan karakteristik penting untuk interpretasi citra digital secara otomatis atau semi otomatis. Karakteristik tersebut digunakan dalam proses identifikasi objek. Secara umum tekstur mengacu pada repetisi elemen-elemen tekstur dasar yang disebut dengan primitif atau *texel* (*texture element*). Suatu *texel* terdiri dari beberapa *pixel* dengan aturan posisi tertentu. Tekstur pada perhitungan citra ditentukan oleh perbedaan tingkat keabuan (*contrast*), penentuan ukuran area tempat terjadinya perubahan (window) dan arahnya.

Pada pengolahan citra digital untuk menganalisis tekstur pada suatu area, ada tiga pendekatan yang bisa digunakan [2], yaitu pendekatan struktural, statistik dan spektral. Pendekatan statistik dilakukan dengan mempertimbangkan bahwa intensitas dibangkitkan oleh medan acak dua dimensi. Pada metode ini, tekstur didefinisikan secara tak langsung melalui sifat-sifat non deterministik yang mengatur distribusi dan hubungan ketetanggaan antar nilai derajat keabuan dalam citra. Pendekatan secara statistik dapat dibagi menjadi tiga yakni metode statistik orde pertama yang tidak memperhitungkan hubungan *pixel* berdekatan, metode statistik orde kedua yang perhitungannya berdasarkan hubungan antara dua *pixel* pada citra dan metode statistik orde tiga atau lebih yang memperhitungkan hubungan antara tiga *pixel* atau lebih.

Grey Level Co-occurrence Matrix (GLCM)

Metode *Grey Level Co-occurrence Matrix* (GLCM) juga dikenal sebagai *Grey Tone Spatial Dependency Matrix*, diperkenalkan pertama kali oleh Haralick et all. pada tahun 1973 [13]. GLCM didefinisikan sebagai suatu histogram dua dimensi dari level keabuan sepasang *pixel* yang berjarak tetap dan terhubung secara spasial [14]. GLCM juga dapat didefinisikan sebagai suatu tabulasi dari seberapa sering kombinasi berbeda dari nilai level keabuan *pixel* terjadi pada suatu citra.

Matriks kookurensi dibentuk berdasarkan pada jumlah kejadian satu level nilai *pixel* bertetangga dengan satu level nilai *pixel* lain dalam jarak (δ) dan orientasi sudut (θ) tertentu. Orientasi θ dinyatakan dalam empat arah sudut dengan interval sudut 45°, yaitu 0°, 45°, 90°, dan 135°. Sedangkan jarak antar *pixel* biasanya ditetapkan sebesar 1 *pixel*, 2 *pixel*, 3 *pixel* dan seterusnya. Matriks kookurensi adalah matriks bujursangkar dengan jumlah elemen

sebanyak kuadrat jumlah level intensitas *pixel* pada citra. Setiap titik (i,j) pada matriks kookurensi berorientasi berisi peluang kejadian *pixel* bernilai i bertetangga dengan *pixel* bernilai j pada jarak δ serta orientasi sudut θ.

Dalam matriks ko-okurensi yang terbentuk, terdapat 14 ciri tekstur (fitur) yang dapat digunakan sebagai dasar pengklasifikasian yang diusulkan oleh Harralick [13]. Pada penelitian ini, akan dievaluasi 4 fitur sebagai dasar klasifikasi. Fitur "*Enery*" dan "*Contrast*" dipilih berdasarkan hasil penelitian sebelumnya yang menyatakan fitur tersebut merupakan parameter yang paling efisien untuk membedakan pola tekstur [14]. Fitur "*Correlasion*" dan "*Homogeneity*" ditambahkan untuk melengkapi fitur sebelumnya. Fitur-fitur tersebut dapat dinyatakan dengan persamaan berikut:

$$Contrast = \sum_i \sum_j (i-j)^2 P_d(i,j) \quad (1)$$

$$Energy = \sum_i \sum_j P_d^2(i,j) \quad (2)$$

$$Homogeneity = \sum_i \sum_j \frac{P_d(i,j)}{1+|i-j|} \quad (3)$$

$$Correlation = \sum_i \sum_j \frac{ijP_d(i,j)-\mu_x\mu_y}{\sigma_x\sigma_y} \quad (4)$$

$$P_d(i,j) = \frac{V(i,j)}{\sum_{i,j=0}^{N-1} V(i,j)} \quad (5)$$

Dimana $P_d(i,j), \mu,$ dan σ secara berututan mewakili matriks kookurensi, rata-rata $P_d(i,j)$ dan variansi $P_d(i,j)$.

K-Nearest Neighbor (KNN)

Klasifikasi dengan *K-Nearest Neighbor* (KNN) adalah sebuah metode untuk melakukan klasifikasi pada objek atau kumpulan data berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek tersebut [3], [9], [15]. Data pembelajaran diproyeksikan ke ruang berdimensi banyak, yang masing-masing dimensi mewakili fitur dari data. Ruang dimensi dibagi menjadi bagian-bagian berdasarkan klasifikasi data pembelajaran. Nilai k yang terbaik untuk algoritma ini tergantung pada kondisi data dan umumnya nilai k yang tinggi akan mengurangi efek noise pada klasifikasi, tetapi membuat batasan antara setiap klasifikasi menjadi lebih buram. Nilai k yang bagus dapat dipilih dengan optimis parameter, misalnya dengan menggunakan cross-validation. Kasus khusus untuk klasifikasi diprediksikan berdasarkan data pembelajaran yang paling dekat (misal, k = 1) yang biasanya disebut algoritma *nearest neighbor* [9]. Algoritma KNN dengan perhitungan jarak *Euclidean Distance* merupakan salah satu metode KNN yang umum digunakan dalam penelitian, dinyatakan dalam persamaan berikut:

$$d(x,y) = \sqrt{\sum_{i=1}^{n}(x_i - y_i)^2} \quad (6)$$

Dimana $d(x,y)$ adalah jarak antara data x ke daya y, x_i adalah data testing ke-i, y_i adalah data training ke-i dan n adalah dimensi data.

II. METODE

Prosedur Klasifikasi

Perbandingan akan dilakukan antara klasifikasi osteoporosis yang diidentifikasi melalui analisis tekstur citra radiografi panoramik gigi dengan hasil klasifikasi kerapatan mineral tulang menggunakan teknik DXA, seperti ditunjukkan Gambar 1. Dimana klasifikasi dari hasil analisis citra kemudian dibandingkan dengan hasil pengujian DXA untuk mengetahui keakurasian dari sistem yang diteliti.

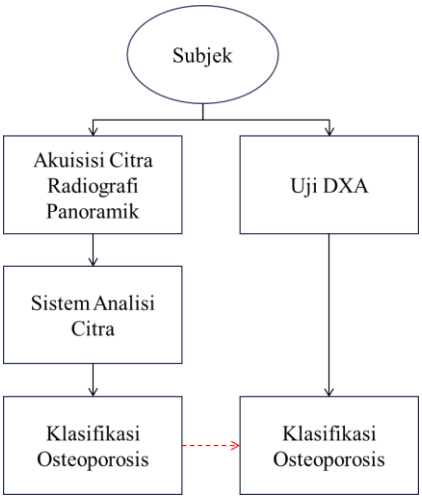

Gambar 1. Sistem penentuan osteoporosis dari citra radiografi panoramik gigi

Pendekatan statistik digunakan dalam analisis tekstur dengan mengevaluasi area yang telah ditentukan secara manual (ROI) pada citra panoramik subjek, seperti yang ditunjukkan dalam Gambar 2. Citra hasil *cropping* dari ROI akan ditingkatkan kualitas citranya menggunakan ekualisasi histogram sehingga antara objek dan latar dapat dipisahkan. Citra yang telah diperbaiki kualitasnya akan menjalani analisis tekstur menggunakan metode *Grey Level Co-occurrence Matrix* (GLCM) dengan maksud untuk mengekstraksi fitur *contrast*, *correlation*, *energy*, dan *homogeneity* yang akan digunakan sebagai input untuk algoritma *K-Nearest Neighbor* (KNN) dalam proses klasifikasi osteoporosis.

P-ISSN: 2302-3295

Gambar 2. *Region of interest* Condilus Mandibula

Dari citra panoramik sampel berukuran 2840 x 1532 *pixel* dan resolusi 72 dpi dilakukan cropping pada area condilus mandibula kiri dan kanan dengan ukuran ROI 80x80 *pixel* dengan 256 derajat keabuan (Gambar 2). Peningkatan citra ROI dengan ekualisasi histogram memberikan intensitas citra yang seimbang pada ROI kiri dan kanan, seperti ditunjukkan Tabel 1.

Tabel 1. Citra ROI setelah ditingkatkan.

ROI	Sebelum Peningkatan	Setelah Peningkatan
Kiri	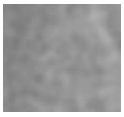	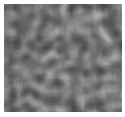
Kanan		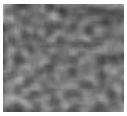

Ekstraksi fitur dari GLCM pada citra menggambarkan bahwa pemisahan yang paling optimal antara kelas normal dan osteoporosis terjadi ketika fitur diekstraksi dengan jarak δ = 1 dan orientasi sudut yang diperhatikan adalah sudut 0°, 45°, 90°, dan 135°.

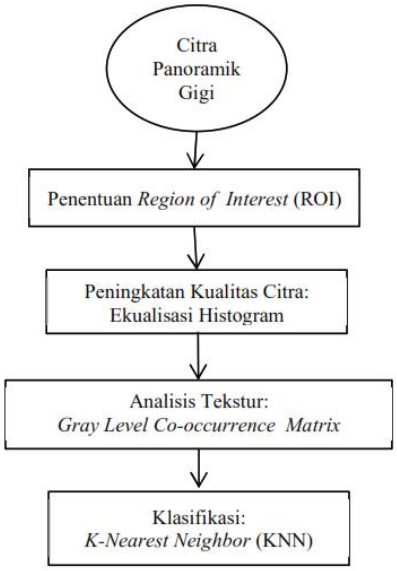

Gambar 3. Algoritma klasifikasi osteoporosis dengan metode KNN

Klasifikasi menggunakan KNN dilakukan dengan variasi nilai k, yaitu, 1, 3 dan 5 dilakukan mendapatkan sistem yang memiliki akurasi paling baik dalam penentuan kelas osteoporosis dari citra radiografi panoramik, dengan mengikuti algoritma klasifikasi pada Gambar 3.

Parameter akurasi, sensitivitas, spesifisitas dan matriks konfusi (*confusion matrix*) digunakan untuk menguji metode dan sistem yang dirancang. Nilai akurasi klasifikasi, sensitivitas dan spesifisitas dapat didefinisikan menggunakan elemen-elemen matriks konfusi dua kelas (Tabel.2) sebagai berikut:

$$\text{Akurasi (\%)} = \frac{TP+TN}{TP+TN+FP+FN} x100 \quad (7)$$

$$\text{Sensitivitas (\%)} = \frac{TP}{TP+FN} x100 \quad (8)$$

$$\text{Spesifisitas (\%)} = \frac{TN}{FP+TN} x\ 100 \quad (9)$$

Tabel 2. Matriks konfusi dua kelas

Aktual	Prediksi	
	Normal	**Osteoporosis**
Normal	*True Positif* (TP)	*False Negatif* (FN)
Osteoporosis	*False Positif* (FP)	*True Negatif* (TN)

III. HASIL DAN PEMBAHASAN

Hasil ekstraksi fitur dijadikan sebagai input berupa input tunggal fitur *contrast, correlation, energy dan homogeneity* serta kombinasi dari 2, 3, dan 4 fitur dengan total 12 model yang ditabulasikan pada Tabel 3.

Tabel 3. Model kombinasi ekstraksi fitur

Model	Jumlah Fitur	Kombinasi Fitur
A	1	*Contrast*
B	1	*Correlation*
C	1	*Energy*
D	1	*Homogeneity*
E	2	*Contrast, Correlation*
F	2	*Contrast, Energy*
G	2	*Correlation, Energy*
H	3	*Contrast, Correlation, Energy*
I	3	*Contrast, Energy, Homogeneity*
J	3	*Correlation, Energy, Homogeneity*
K	3	*Contrast, Correlation, Homogeneity*
L	4	*Contrast, Correlation, Energy, Homogeneity*

Hasil klasifikasi osteoporosis data ekstraksi fitur dengan metode KNN (k=1, k=3, k=5) ditabulasikan pada dalam matriks konfusi, akurasi, sensitivitas dan spesifisitas (Tabel 3, 4 dan 5).

Tabel 4. Matriks konfusi sistem klasifikasi KNN (k=1)

Model	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifitas (%)
A	9	0	3	2	64,29	81,82	0
B	8	2	1	3	71,43	72,73	66,67
C	11	0	3	0	71,43	81,82	33,33
D	10	0	3	1	57,14	72,73	0
E	9	1	2	2	57,14	72,73	0
F	10	0	3	1	64,29	81,82	0
G	9	1	2	2	57,14	72,73	0
H	10	1	2	1	64,29	81,82	0
I	9	1	2	2	64,29	81,82	0
J	10	1	2	1	57,14	72,73	0
K	10	2	1	1	57,14	72,73	0
L	10	2	1	1	57,14	72,73	0

Hasil pengujian klasifikasi KNN dengan k=1 (Tabel 4.) menunjukkan bahwa input berupa fitur *correlation* dan energy mempunyai nilai akurasi terbaik sebesar 71,43%. Pengenalan paling baik terhadap kelas normal ditunjukkan dengan nilai sensitivitas paling besar yaitu 81,82% yang ditunjukkan oleh input fitur contrast, energy, kombinasi fitur . Sedangkan fitur yang paling baik untuk pengenalan kelas osteoporosis adalah fitur correlation dengan spesifisitas 66,67%. Dari hasil klasifikasi juga terlihat bahwa kombinasi fitur sebagai input proses klasifikasi tidak memberikan akurasi dan kemampuan pengenalan yang lebih baik dibanding input fitur tunggal.

Tabel 5. Matriks konfusi sistem klasifikasi KNN (k=3)

Model	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifitas (%)
A	9	0	3	2	64,29	81,82	0
B	8	2	1	3	71,43	72,73	66,67
C	9	0	3	2	64,29	81,82	0
D	9	0	3	2	64,29	81,82	0
E	9	1	2	2	71,43	81,82	33,33
F	9	0	3	2	64,29	81,82	0
G	9	1	2	2	71,43	81,82	33,33
H	9	1	2	2	71,43	81,82	33,33
I	8	0	3	3	57,14	72,73	0
J	9	1	2	2	71,43	81,82	33,33
K	9	1	2	2	71,43	81,82	33,33
L	9	1	2	2	71,43	81,82	33,33

Dengan menggunakan nilai k=3 (Tabel 5.), terlihat capaian akurasi terbaik masih sebesar 71,43% dengan input tunggal fitur *correlation* serta input kombinasi fitur model E, G, H, J, K, dan L. Pengenalan paling baik terhadap kelas normal ditunjukkan dengan nilai sensitivitas paling besar yaitu 81,82% yang ditunjukkan oleh hampir semua input tunggal ataupun kombinasi kecuali input *correlation* dan kombinasi model I. Sedangkan fitur yang paling baik untuk pengenalan kelas osteoporosis adalah fitur *correlation* dengan spesifisitas 66,67%. Kombinasi fitur sebagai input proses klasifikasi tidak memberikan akurasi dan kemampuan pengenalan yang lebih baik dibanding input fitur tunggal.

Tabel 6. Matriks konfusi sistem klasifikasi KNN (k=5)

Model	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifitas (%)
A	11	0	3	0	78,57	100	0
B	9	1	2	2	71,43	81,82	33,33
C	11	0	3	0	78,57	100	0
D	11	0	3	0	78,57	100	0
E	9	1	2	2	71,43	81,82	33,33
F	11	0	3	0	78,57	100	0
G	9	0	3	2	71,43	81,82	0
H	9	0	3	2	64,29	81,82	0
I	11	0	3	0	78,57	100	0
J	10	0	3	1	71,43	90,91	0
K	10	0	3	1	71,43	90,91	0
L	10	0	3	1	71,43	90,91	0

Klasifikasi KNN dengan k=5 (Tabel 6.) menunjukan nilai tertinggi untuk akurasi hingga 78,57% dan sensitivitas hingga 100% untuk input fitur *contrast*, *energy*, *homogeneity*, kombinasi model F, dan I. Nilai spesifitas terbaik diberikan oleh input fitur *contrast* dan kombinasi model E dengan nilai pengenalan 33,33%. Fitur *contrast*, *energy* dan *homogeneity* pada klasifikasi KNN dengan k=5 menjadi fitur yang mempengaruhi nilai akurasi dan sensitivitas sistem klasifikasi pada penelitian ini.

Dari hasil klasifikasi KNN dengan variasi k=1, k=3 dan k=5 nilai akurasi terbaik (78,57 %) didapatkan dengan menggunakan nilai k=5 dan input fitur tunggal *contrast*, *energy*, *homogeneity* dan input kombinasi fitur model F (*contrast*, *energy*) dan model I (*contrast*, *energy*, *homogeneity*), seperti ditunjukkan dari grafik pada Gambar 4. Hal ini menunjukkan fitur *contrast*, *energy* dan *homogeneity* dari citra radiografi panoramik gigi berkaitan erat dengan kondisi kerapatan massa tulang pasien yang nantinya akan menentukan kondisi tulang pasien pada kondisi normal atau telah mengalami osteoporosis.

P-ISSN: 2302-3295

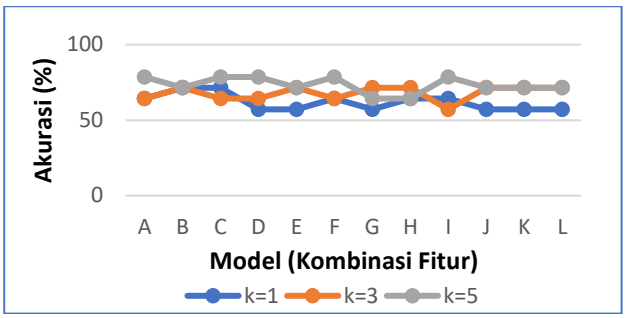

Gambar 4. Performansi akurasi terhadap berbagai model input fitur

Kemampuan pengenalan kerapatan tulang normal atau sensitivitas paling baik didapatkan sebesar 100% pada algoritma klasifikasi KNN dengan k=5 dengan input fitur contrast, energy, homogeneity (model A, C, D) dan kombinasi fitur tersebut (model F dan I). Hal ini lebih baik dibandingkan nilai maksimum sensitivitas yang dapat dicapai apabila menggunakan nilai k=1 dan k=3, yaitu 81,82%, seperti terlihat pada Gambar 5.

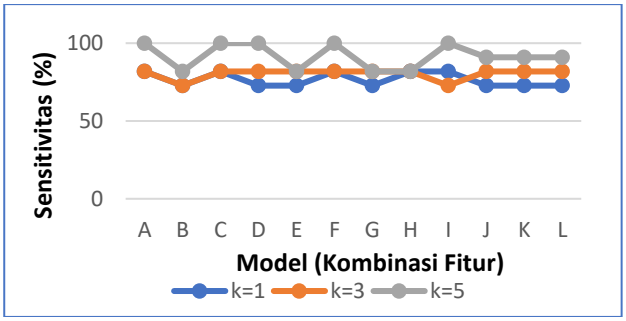

Gambar 5. Performansi sensitivitas terhadap berbagai model input fitur

Kemampuan pengenalan osteoporosis atau spesifisitas paling baik ditunjukkan oleh input menggunakan fitur *correlation* (model B) baik dengan k=1 dan k=3 (66,67%) maupun dengan k=5 (33,33%). Dari grafik hasil pengenalan (Gambar 6.), terlihat bahwa nilai rata-rata spesifisitas masih rendah.

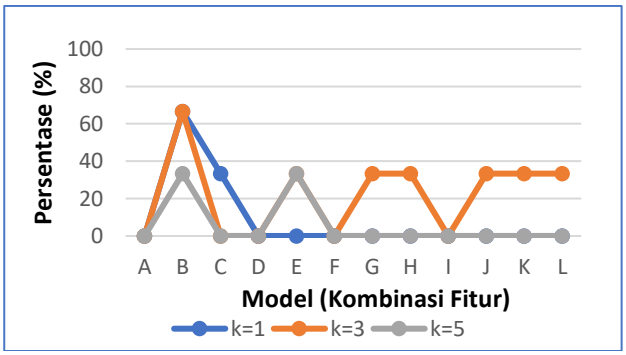

Gambar 6. Performansi spesifisitas terhadap berbagai model input fitur

Rendahnya kemampuan pengenalan sampel osteoporosis dapat disebabkan jumlah data latih yang dari kelas osteoporosis yang sedikit, sehingga proses pembelajaran algoritma menjadi terbatas

IV. KESIMPULAN

Dari hasil penelitian dapat disimpulkan bahwa klasifikasi ekstraksi fitur G*rey Level Co-occurrence Matrix* (GLCM) menggunakan metode *K-Nearest Neighbor* (KNN) untuk penentuan osteoporsis dapat digunakan sebagai suatu *computer-aided diagnosis* memanfaatkan citra radiografi panoramic gigi. Pengenalan kerapatan mineral tulang menggunakan algoritma K-Nearest Neighbor paling baik pada k=5 dengan input fitur *contrast*, *energy* dan *homogeneity* serta kombinasinya. Tingkat akurasi terbaik didapatkan sebesar 78,57%, sensitivitas sebesar 100% dan spesifisitas sebesar 66%.

DAFTAR PUSTAKA

[1] WHO Technical Report Series, *Prevention and management of osteoporosis : report of a WHO Scientific Group.*, vol. 921. World Health Organization, 2003.

[2] Suprijanto, E. Juliastuti, Y. Diputra, and M. Mayantasari, *Dental Panoramic Image Analysis on Mandibular Bone for Osteoporosis Early Detection, Proceedings 3rd International Conference on ICA, Bali, Indonesia*, pp. 138-143, August, 2013.

[3] R. Abdalla-Aslan, T. Yeshua, D. Kabla, I. Leichter, and C. Nadler, "An Artificial Intelligence System using Machine-Learning for Automatic Detection and Classification of Dental Restorations in Panoramic Radiography," *Oral Surg Oral Med Oral Pathol Oral Radiol*, vol. 130, no. 5, pp. 593–602, Nov. 2020, doi: 10.1016/j.oooo.2020.05.012.

[4] W. R. Wulandari, S. A. Wibowo, and D. Fahmi Oscandar, "Klasifikasi Umur Berdasarkan Citra Dental Panoramic Radiograph Dengan Metode Statistical Analysis of Structural Information dan Adaboosts," e-Proceedings of Engineering, vol. 6, No.2, pp. 4216-4222, Agustus, 2019.

[5] K. Horner and H. Devlin, "The Relationships Between Two Indices of Mandibular Bone Quality and Bone Mineral Density Measured by Dual Energy X-Ray Absorptiometry," Dentomaxillofacial Radiology, vol.27, pp. 17-21, 1998.

[6] P. D. Allen *et al.*, "Detecting reduced bone mineral density from dental radiographs using statistical shape models," *IEEE Transactions on Information Technology in Biomedicine*, vol. 11, no. 6, pp. 601–610, Nov. 2007, doi: 10.1109/TITB.2006.888704.

[7] P. C. A. Watanabe, J. P. M. Issa, S. A. C. Monteiro, M. M. Iyomasa, S. C. H. Regalo, and

S. Siessere, "Morphodigital Study of the Mandibular Trabecular Bone in Panoramic Radiographs," International Journal of Morphology, vol.25, no.4, pp.875-880, 2007.

[8] A. Z. Arifin, A. Asano, A. Taguchi, T. Nakamoto, M. Ohtsuka, and K. Tanimoto, "Computer-aided system for measuring the mandibular cortical width on panoramic radiographs in osteoporosis diagnosis," in *Medical Imaging 2005: Image Processing*, SPIE, Apr. 2005, pp. 813–821. doi: 10.1117/12.594458.

[9] C. Wijaya, H. Irsyad, and W. Widhiarso, "Klasifikasi Pneumonia Menggunakan Metode K-Nearest Neighbor Dengan Ekstraksi GLCM," Jurnal Algoritme, Vol.1, No.1, pp. 33-44, Oktober, 2020.

[10] R. Yunus, U. Ulfa, and M. D. Safitri, "Application of the K-Nearest Neighbors (K-NN) Algorithm for Classification of Heart Failure," Journal of Applied Inteligence System, Vol.6, No.1, pp. 1-9, 2021.

[11] J. Elektronik, I. K. Udayana, D. Reness, N. A1, and B. Jimbaran, "Klasifikasi Citra Rontgen Gigi Berdasarkan Analisis Tekstur Untuk Diagnosis Karies Gigi Manusia Menggunakan Metode SVM," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 9, no. 1, pp. 141–150, 2020.

[12] N. Kadek Ayu Wirdiani, P. Hridayami, N. Putu Ayu Widiari, K. Diva Rismawan, P. Bagus Candradinatha, and I. Putu Deva Jayantha, "Face Identification Based on K-Nearest Neighbor," *Scientific Journal of Informatics*, vol. 6, no. 2, pp. 2407–7658, 2019, [Online]. Available: http://journal.unnes.ac.id/nju/index.php/sji

[13] R. M. Haralick, Shanmugam K, and Dinstein Its'hak, "Textural Features for Image Classification," *IEEE Trans Syst Man Cybern*, vol. SMC-3, No.6, no. November 1973, pp. 610–621, 1973.

[14] D. Gadkari, "Image Quality Analysis Using GLCM," *MSc Thesis*, *University of Central Florida*, Orlando, Florida,2000.

[15] S. Martha, W. Andani, and S. W. Rizki, "Perbandingan Metode k-Nearest Neighbor, Regresi Logistik Biner, dan Pohon Klasifikasi pada Analisis Kelayakan Pemberian Kredit," *Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 10, no. 2, pp. 262–273, Nov. 2022, doi: 10.34312/euler.v10i2.16751.