



# Deteksi osteoporosis pada citra radiograf panoramik dental menggunakan algoritme J48 dan learning vector quantization

## *Osteoporosis detection on the dental panoramic radiographic images using J48 algorithm and learning vector quantization*

Enny Itje Sela<sup>\*)</sup>

Program Studi Informatika, Universitas Teknologi Yogyakarta  
Jl. Siliwangi, Ring Road Utara, Jombor, Sleman, Daerah Istimewa Yogyakarta 55285, Indonesia

---

**Cara sitasi:** E. I. Sela, "Deteksi osteoporosis pada citra radiograf panoramik dental menggunakan algoritme J48 dan learning vector quantization," *Jurnal Teknologi dan Sistem Komputer*, vol. 9, no. 4, pp. 211-217, 2021. doi: [10.14710/jtsiskom.2021.14197](https://doi.org/10.14710/jtsiskom.2021.14197), [Online].

---

**Abstract** - Osteoporosis is one type of disease that is not easily detected. This disease can cause fractures for the sufferer. Early detection of osteoporosis is crucial to prevent fractures. This study aims to detect osteoporosis through features extracted from cortical bone and trabeculae in dental panoramic images. The results of the selected feature extraction are trained using an artificial neural network. Based on the study results, the dominant features for osteoporosis detection are radio morphometric index and morphological features. The J48 and Learning Vector Quantization (LVQ) accuracy, sensitivity, and specificity are 83.88 %, 78.57 %, and 100 %, respectively.

**Keywords** – osteoporosis; dental panoramic; radio morphometry index; texture analysis; J48; LVQ

**Abstrak** – Osteoporosis merupakan salah satu jenis penyakit yang tidak mudah terdeteksi. Penyakit ini dapat menyebabkan patah tulang bagi penderitanya. Deteksi dini osteoporosis sangat penting untuk mencegah patah tulang. Penelitian ini bertujuan untuk melakukan deteksi osteoporosis melalui fitur-fitur yang diekstrak pada tulang kortikal dan trabekula pada citra panoramik dental. Hasil ekstraksi fitur tersebut dilatih menggunakan jaringan syaraf tiruan. Berdasarkan hasil penelitian, fitur yang dominan untuk deteksi osteoporosis adalah fitur indeks morfometri radio (IRM) dan morfologi. Tingkat akurasi pengujian menggunakan LVQ dapat mendeteksi penyakit osteoporosis, dengan tingkat akurasi mencapai 83,33 %, sensitivitas sebesar 78,57 %, dan spesifisitas mencapai 100 %.

**Kata kunci** – osteoporosis; dental panoramik; indeks radio morfometri; analisis tekstur; J48; LVQ

### I. PENDAHULUAN

Osteoporosis merupakan salah satu jenis penyakit yang tidak mudah terdeteksi secara visual. Penyakit ini juga ditandai dengan tulang yang keropos karena kehilangan zat kalsium. Penderita osteoporosis akan sadar menderita penyakit osteoporosis setelah mereka mengalami patah tulang. Patah tulang sangat jarang menyebabkan kematian, namun dengan kejadian tersebut, penderita akan mengalami kesulitan dalam melakukan aktivitas, yang selanjutnya akan berdampak pada masalah sosial dan ekonomi. Deteksi dini osteoporosis di negara berkembang, masih sangat sulit dan mahal. Padahal dengan deteksi dini tersebut, osteoporosis bisa dicegah [1]. Dual Energy X-Ray Absorptiometry (DEXA) merupakan peralatan yang menjadi *gold standar* untuk memeriksa osteoporosis, namun tidak semua rumah sakit menyediakan alat ini.

Ketika tubuh membutuhkan kalsium, maka tubuh akan mengambil dari tulang rahang terlebih dahulu. Hal tersebut menyebabkan tulang rahang lebih rapuh dibanding yang lain. Citra dental sendiri terdiri dari citra panoramik dan periapikal. Deteksi osteoporosis dengan memanfaatkan citra gigi telah dilakukan oleh peneliti, baik citra periapikal [2]-[4] atau citra panoramik [1], [5]-[7]. Bagian citra panoramik yang digunakan untuk memeriksa osteoporosis adalah tulang kortikal dan tulang trabekula, sedangkan citra periapikal gigi memanfaatkan tulang trabekula. Oleh karena itu, citra *radiograf panoramik dental* (RPD) atau citra panoramik memiliki potensi yang lebih besar untuk mendeteksi osteoporosis dibandingkan citra periapikal [8].

Beragam arsitektur dan algoritme diterapkan untuk deteksi osteoporosis ini. Lee dkk. [1] melakukan studi menggunakan *deep learning* untuk mendeteksi osteoporosis pada ribuan data citra panoramik. Arsitektur *deep learning* yang digunakan adalah single DCNN kolom tunggal (SC-DCNN), DCNN kolom tunggal dengan augmentasi (SC-DCNN-Augment), dan DCNN multikolom (MC-DCNN). Kajian tersebut menyatakan bahwa arsitektur SC-DCNN-Augment

---

<sup>\*)</sup> Penulis korespondensi (Enny Itje Sela)  
Email: [ennysela@uty.ac.id](mailto:ennysela@uty.ac.id)

dapat digunakan untuk mendeteksi osteoporosis dengan hasil yang lebih baik daripada arsitektur yang lain.

Popic dkk. [5] melakukan perbandingan dari berbagai fitur indeks *radiomorfometri mandibular cortical width* (MCW), *panoramic mandibular index* (PMI), dan *mandibular cortical index* (MCI) untuk memeriksa nilai kepadatan tulang belakang pada 146 wanita. Kurva *receiver operating characteristic* (ROC) digunakan untuk melakukan analisis kelas osteopenia dan osteoporosis.

Hwang dkk. [6] menggunakan metode pohon keputusan dan SVM untuk mengidentifikasi osteoporosis berdasarkan fitur morfologi strut, dimensi fraktal, dan analisis tekstur *gray-level co-occurrence matrix* (GLCM) pada 454 citra panoramik. Hasil kajian menunjukkan bahwa kombinasi fitur morfologi strut dengan SVM mendapatkan hasil yang paling baik. Salah satu faktor akurasi yang tinggi dapat dicapai karena jumlah citra radiograf relatif banyak (ratusan hingga ribuan) sehingga model dapat menemukan solusi yang optimal.

Gungor dkk. [7] melakukan evaluasi pada 26 kelas osteoporosis, 33 kelas osteopenia, dan 31 kelas normal menggunakan citra tulang rahang menggunakan analisis korelasi. Fitur yang digunakan adalah indeks radio morfometri, analisis histogram, dan dimensi fraktal. Hasil kajian tersebut menunjukkan bahwa ketiga fitur tersebut berpengaruh terhadap terjadinya osteoporosis.

Kajian tersebut di atas tidak melakukan seleksi fitur yang relevan untuk mengenali osteoporosis, meskipun banyak parameter fitur yang telah dihasilkan. Pemilihan fitur sangat penting karena melakukan pengenalan pola pada fitur yang tidak relevan dapat menghasilkan bias dan waktu komputasi relatif lebih lama [2]. Kajian ini bertujuan melakukan diagnosis osteoporosis menggunakan citra panoramik pada data yang relatif lebih sedikit dibandingkan penelitian sebelumnya. Data tersebut akan diekstrak menggunakan tiga jenis fitur, yaitu indeks radio morfometri (IRM), analisis tekstur, dan morfologi. Gabungan ketiga fitur tersebut akan diolah agar fitur yang dominan atau relevan untuk deteksi osteoporosis. Proses deteksi dilakukan menggunakan jaringan saraf tiruan *learning vector quantization* (LVQ).

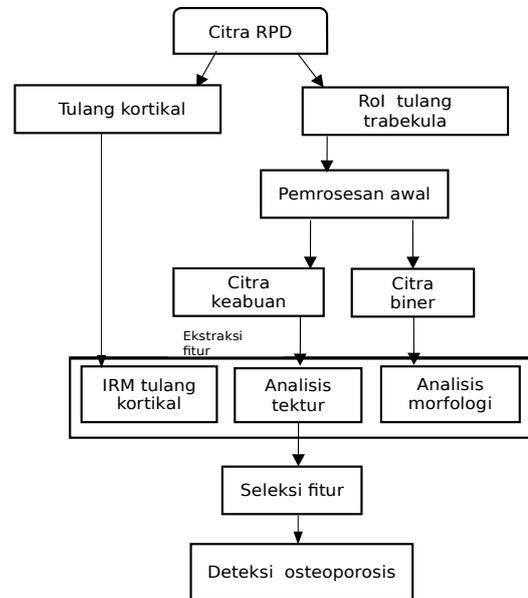
## II. METODE PENELITIAN

### A. Data

Penelitian ini melibatkan wanita menopause etnis Jawa di Indonesia, dengan usia subjek antara 40 dan 57 tahun ( $50.0 \pm 4.3$ ). Citra RPD diambil dari [9], [10] dan terdiri dari 80 citra dalam format JPG dengan ukuran  $1024 \times 1024$  piksel. Data kepadatan tulang (*bone mineral density*, BMD) pada tulang femoral neck dan tulang lumbar spine diperoleh dari Departemen Radiologi Rumah Sakit Umum Pusat (RSUP) Dr. Sardjito menggunakan DEXA. Spesifikasi DEXA adalah 76kV, 1.5mA yang dilakukan selama 1 menit 14 detik (neck femur), dan 1 menit 27 detik (tulang belakang).

**Tabel 1.** Rincian data penelitian

Jumlah	Osteoporosis	Normal	Total
Data latih	26	36	62
Data uji	14	4	18
Total	40	40	80



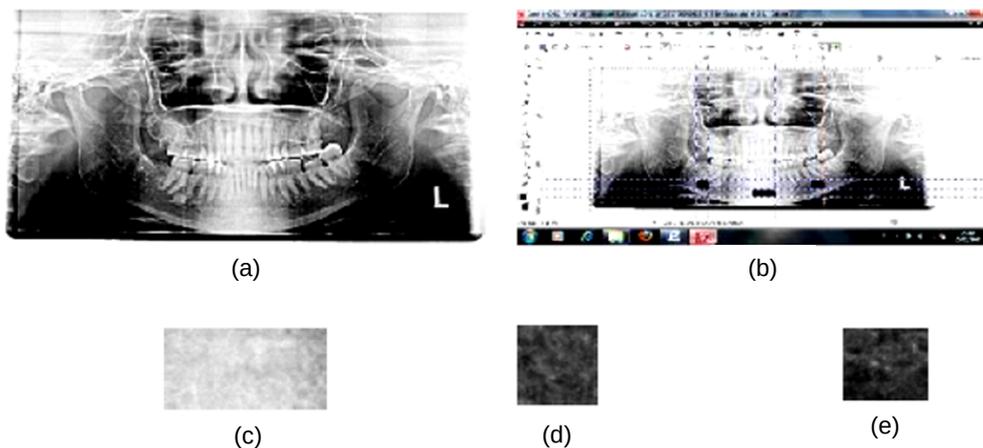
**Gambar 1.** Model yang diusulkan

Hasil DEXA dikelompokkan menjadi normal (N) dan osteoporosis (OP). Dari data-data tersebut, 40 data dikelompokkan pada kelas normal dan 40 kelas osteoporosis. Data-data tersebut dibagi menjadi data latih sebanyak 62 (terdiri atas 36 kelas normal, 26 kelas osteoporosis) dan data uji sebanyak 18 (terdiri atas 4 data normal, 14 data osteoporosis). Rincian pembagian data dapat dilihat pada Tabel 1. Kelas normal dan osteoporosis pada citra RPD dapat dibedakan dari IRM, fitur tekstur, dan morfologi.

### B. Model yang diusulkan

Gambar 1 menunjukkan rancangan model yang diusulkan pada penelitian ini. Data citra RPD sebagai masukan akan diproses pada dua bagian, yaitu tulang kortikal dan tulang trabekula. Bagian tulang kortikal akan diekstrak fitur indeks radio morfometri (IRM), sedangkan pada tulang trabekula akan dilakukan ekstraksi fitur tekstur dan morfologi. Untuk melakukan kedua ekstraksi fitur tersebut, *region of interest* (RoI) diambil pada area trabekula dengan format citra berwarna dan dilakukan pemrosesan awal menjadi citra keabuan untuk ekstraksi fitur tekstur dan citra biner untuk ekstraksi fitur morfologi porus.

Ketiga jenis fitur tersebut digabungkan dan dicari fitur yang dominan atau fitur yang penting karena tidak semua fitur berperan untuk deteksi osteoporosis. Seleksi fitur dilakukan dengan memanfaatkan algoritme J48 untuk membentuk pohon keputusan. Fitur-fitur yang



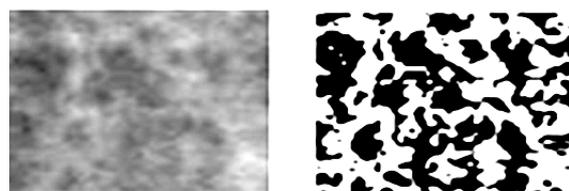
**Gambar 2.** Bagian citra: a) citra radiograf panoramik dental, b) pemilihan RoI, c) citra RoI anterior, d) citra RoI posterior kanan, dan e) citra RoI posterior kiri

terseleksi digunakan untuk deteksi osteoporosis menggunakan jaringan saraf LVQ.

**Gambar 2** memperlihatkan bagian-bagian citra yang digunakan untuk melakukan analisis deteksi osteoporosis. Sumber awal citra RPD diperlihatkan pada **Gambar 2a**. RoI tidak diperlukan untuk memperoleh IRM pada bagian kortikal. Pengukuran IRM tersebut dilakukan oleh 2 pengamat dalam interval 1 minggu menggunakan pengukuran radiografi digital DBSWin4.5, Durr Dental. Empat fitur IRM dapat diperoleh dari citra RPD pada bagian tulang kortikal, yaitu *metal index (MI)*, *panoramic mandibular index (PMI)*, *gonion index (GI)*, dan *antegonial index (AI)*. **Gambar 2b** memperlihatkan bagian tulang kortikal yang diukur IRM. Proses pemotongan citra RPD awal untuk mendapatkan RoI dilakukan menggunakan perangkat lunak Adobe Photoshop dan dilakukan pada tulang trabekula anterior dengan ukuran 28x64 piksel (**Gambar 2c**), posterior kiri (**Gambar 2d**), dan posterior kanan masing-masing berukuran 64x64 piksel (**Gambar 2e**).

Pemrosesan awal dilakukan untuk meningkatkan kualitas citra RoI pada trabekula, dengan cara mengurangi derau menggunakan filter tophat-bothat. Setelah proses ini, format citra pada RoI yang semula merupakan citra berwarna, akan diubah menjadi format keabuan dan biner. Dari citra keabuan, proses ekstraksi fitur dapat dilakukan menggunakan metode analisis tekstur. Pada citra biner, proses ekstraksi fitur dilakukan menggunakan operasi morfologi pada bagian porus. Hasil citra keabuan dan biner dapat dilihat **Gambar 3**.

**Tabel 2** menunjukkan proses analisis morfologi pada citra biner untuk mendapatkan fitur porositas, ukuran, dan orientasi porus yang mencakup segmentasi, operasi penutupan, dan pengisian porus. Dari langkah ekstraksi morfologi, masing-masing RoI menghasilkan enam fitur morfologi, yaitu porositas (*Por*), pori kecil (*JK*), pori besar (*JB*), pori vertikal (*V*), pori horizontal (*H*), dan pori miring (*M*). Dengan demikian, dalam analisis morfologi, suatu citra akan memiliki 18 fitur, yaitu *OAntPor* (porositas di anterior), *OkiPor* (porositas di posterior kiri), *OkaPor* (porositas bagian posterior kanan), *OAntJK* (pori kecil di anterior), *OkiJK* (pori



**Gambar 3.** Citra RoI keabuan dan biner

**Tabel 2.** Morfologi porus pada kelas normal dan osteoporosis [11]

Kegiatan	Normal	Osteoporosis
RoI		
Segmentasi		
Closing		
Filling		
Orientasi porus		

kecil di posterior kiri), *OKaJK* (pori kecil di posterior kanan), *OAntJB* (pori besar di anterior), *OKaJB* (pori besar di posterior kanan), *OKiJB* (pori besar di posterior kiri), *OAnt* (pori horizontal di anterior), *OkiH* (pori horizontal di posterior kiri), *OkaH* (pori horizontal di posterior kanan), *OAntV* (pori vertikal pada posterior besar), *OKiV* (pori vertikal pada posterior kiri), *OkaV* (pori vertikal pada posterior kanan), *OAntO* (pori miring

pada anterior), *OkiO* (pori miring pada posterior besar), dan *OkaO* (pori miring di posterior kanan).

Analisis tekstur diperoleh dari citra keabuan dan digunakan untuk mendapatkan karakteristik objek yang memiliki pola pengulangan nilai intensitas piksel yang berdekatan. Metode analisis tekstur adalah statistik orde pertama, yang terdiri dari rerata, deviasi standar, entropi, variansi, dan statistik orde kedua terdiri dari *gray level co-occurrence matrix* (GLCM). Pengukuran tekstur pada orde pertama didasarkan pada nilai piksel citra asli dan tidak mempertimbangkan hubungan ketetanggaan piksel. Pada GLCM, hubungan antarpasangan piksel pada citra asli akan diperhatikan [12].

Analisis tekstur yang digunakan dalam penelitian ini adalah empat fitur, yaitu energi, kontras, korelasi, dan homogenitas. Fitur energi (E) menyatakan distribusi intensitas piksel terhadap jangkauan nilai derajat keabuan, seperti dinyatakan dalam (1). Nilai  $x$  adalah derajat keabuan citra dan  $p(x)$  menyatakan probabilitas kemunculan  $x$  dan  $L$  menyatakan derajat keabuan maksimal pada citra. Citra seragam dengan sebuah nilai derajat keabuan akan memiliki energi maksimum, yaitu 1.

$$E = \sum_{x=0}^{L-1} x \cdot p(x) \quad (1)$$

Kontras (C) menunjukkan ukuran elemen sebaran dari matriks citra seperti dinyatakan dalam (2). Simbol  $i, j$  menyatakan koordinat piksel pada matriks GLCM dan  $P_{ij}$  merupakan nilai piksel (derajat keabuan) pada koordinat  $i, j$  matriks GLCM. Jika lokasinya jauh dari diagonal utama, maka kontrasnya besar. Secara visual, nilai kontras adalah ukuran variasi antara derajat abu-abu suatu area.

$$C = \sum_{i,j} P_{ij} (i-j)^2 \quad (2)$$

Korelasi (*Cor*) menunjukkan besarnya ketergantungan linier dari keabuan citra sehingga dapat memberikan gambaran struktur linier pada citra seperti dinyatakan dalam (3). Simbol  $\mu_i$ ,  $\mu_j$ ,  $\sigma_i$  dan  $\sigma_j$  masing-masing adalah rata-rata dan standar deviasi pada kolom  $i$  dan  $j$ . Korelasi adalah 1 atau -1 untuk gambar yang berkorelasi positif atau negatif sempurna. Homogenitas (*H*) menunjukkan distribusi elemen matriks dalam GLCM ke diagonal GLCM, seperti dinyatakan dalam (4). Nilai *H* berada pada interval 0 dan 1.

$$Cor = \sum_{i,j=0}^{L-1} \frac{(i-\mu_i)(j-\mu_j)P_{ij}}{\sigma_i\sigma_j} \quad (3)$$

$$H = \sum_{i,j=0}^{L-1} \frac{P_{ij}}{1+(i-j)^2} \quad (4)$$

Semua citra RPD akan diekstrak menggunakan tiga metode ekstraksi fitur. Masing-masing citra mempunyai 34 fitur, yaitu 4 fitur IRM, 12 fitur tekstur, dan 18 fitur morfologi. Fitur yang berhasil diekstrak ini, selanjutnya disimpan dalam matriks berukuran 62 baris dan 34 kolom.

Seleksi fitur ini memiliki dua manfaat, yaitu mengurangi waktu pelatihan dan meningkatkan performansi prediksi. Dalam mereduksi fitur, dipilih fitur-fitur yang paling relevan untuk prediksi. Salah satu metode seleksi fitur yang bisa digunakan adalah pohon keputusan (*decision tree*) [2]. Setiap simpul cabang dalam pohon keputusan mewakili pilihan di antara beberapa alternatif. Pohon keputusan menghasilkan aturan dimulai dengan simpul akar. Dari simpul ini, pengguna membagi setiap simpul secara rekursif algoritme pembelajaran pohon keputusan seperti [13]. Simpul daun mewakili kelas normal atau osteoporosis. Dalam kajian ini, pohon keputusan diperoleh menggunakan algoritme J48, seperti yang telah dilakukan pada [2].

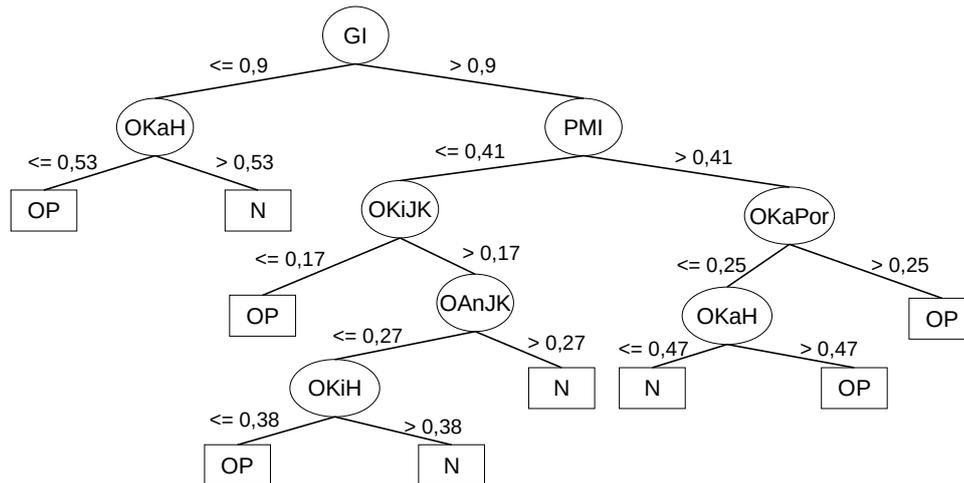
Metode jaringan syaraf tiruan LVQ dilakukan untuk melatih fitur yang relevan hasil seleksi menggunakan pohon keputusan seperti [14]. LVQ digunakan untuk melakukan pelatihan pada lapisan kompetitif yang diawasi. Lapisan ini secara otomatis akan belajar mengklasifikasikan vektor masukan. Jika beberapa vektor masukan memiliki jarak yang sangat dekat, maka vektor masukan tersebut akan dikelompokkan dalam kelas yang sama. Metode pengukuran jarak yang digunakan adalah jarak Euclidian. Pada penelitian ini vektor masukan pada LVQ adalah fitur hasil seleksi (7 fitur), sedangkan keluaran pada LVQ adalah 2, sesuai dengan banyaknya kelas yang akan diprediksi.

### III. HASIL DAN PEMBAHASAN

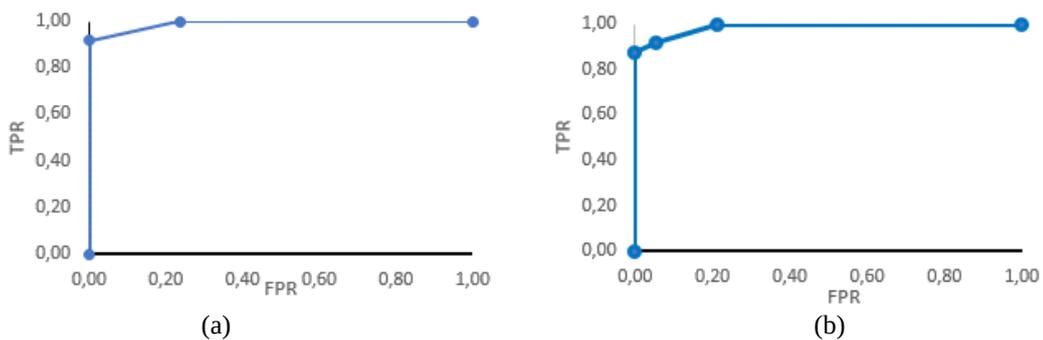
Metode pohon keputusan menghasilkan fitur-fitur yang relevan, dengan menghilangkan fitur-fitur yang dianggap tidak penting. Gambar 4 menunjukkan bahwa tujuh node atau simpul yang muncul pada pohon merupakan simpul yang relevan untuk dijadikan sebagai fitur masukan untuk deteksi osteoporosis, yaitu fitur *GI*, *OkaH*, *PMI*, *OkiJK*, *OkaPor*, *OanJK*, dan *OkiH*.

Dari matriks konfusi di Tabel 3, dapat diperoleh nilai akurasi, spesifisitas, sensitifitas, dan presisi. Akurasi pohon keputusan sebesar 96,77 % menunjukkan bahwa 60 dari 62 data dapat diprediksi dengan benar. Nilai spesifisitas menunjukkan bahwa model pohon keputusan dengan algoritme J48 dapat memprediksi secara tepat kelas normal sebesar 94,74 % (36 dari 38 data normal). Nilai presisi (nilai prediksi positif) menyatakan bahwa data yang diklasifikasikan menderita penyakit osteoporosis sebanyak 92,31 % atau sebanyak 24 dari 26 data osteoporosis dinyatakan benar menderita osteoporosis. Nilai sensitifitas mencapai 100 % yang menunjukkan bahwa dari 24 pasien yang menderita osteoporosis, semua diklasifikasikan sebagai penderita osteoporosis oleh model.

Penelitian ini juga mengukur nilai *area under curve* (AUC) yang divisualisasikan menggunakan kurva *receiver operation characterictic* (ROC) seperti ditunjukkan dalam Gambar 5. Tabel 4 menunjukkan perubahan hubungan sensitifitas dan presisi pada nilai ambang tertentu. Nilai rata-rata pengukuran AUC adalah sebesar 0,9941. Nilai AUC ini sangat tinggi yang



**Gambar 4.** Seleksi fitur menggunakan pohon keputusan



**Gambar 5.** ROC seleksi fitur: a) kelas Osteoporosis dan b) kelas Normal

menunjukkan bahwa model tersebut sangat baik jika digunakan untuk deteksi osteoporosis [15].

Tujuh fitur yang relevan selanjutnya dilatih menggunakan jaringan saraf tiruan LVQ. Arsitektur LVQ adalah 7 node ( $X_1, X_2, \dots, X_7$ ) pada lapisan masukan dan 2 node ( $Y_1, Y_2$ ) pada lapisan luaran. Parameter yang digunakan untuk pembelajaran adalah kecepatan pembelajaran ( $\alpha$ ) 0,1 dan nilai minimum  $\alpha$  0,0001. Hasil pelatihan terhadap 62 data latih dapat dilihat pada Tabel 5. Nilai akurasi, spesifisitas dan sensitivitas pelatihan sebesar 93,55 %; 94,44 % dan 92,31 %. Tingkat akurasi tersebut menunjukkan bahwa 58 dari 62 data pasien dapat diprediksi dengan benar pada pelatihan dengan LVQ. Persentase spesifisitas menyatakan hasil pelatihan LVQ dapat memprediksi secara tepat 34 dari 36 data kelas normal, sedangkan tingkat sensitivitas menunjukkan 24 dari 26 data pasien osteoporosis dapat diprediksi dengan benar.

Hasil pengujian terhadap 18 data uji ditunjukkan pada Tabel 6 dengan tingkat akurasi mencapai 83,33 %, sensitivitas sebesar 78,57 %, dan spesifisitas mencapai 100,00%. Tingkat akurasi tersebut menunjukkan bahwa 15 dari 18 data pasien dapat diprediksi dengan benar pada pengujian. Persentase spesifisitas menyatakan hasil pengujian LVQ dapat memprediksi secara tepat semua data pada kelas normal, sedangkan tingkat sensitivitas menunjukkan 11 dari 14 data pasien osteoporosis dapat diprediksi dengan benar.

**Tabel 3.** Matriks konfusi seleksi fitur

Prediksi \ Fakta	OP	N	Total
OP	24	2	26
N	0	36	36
Total	24	38	62

Keterangan: OP = Osteoporosis, N = Normal

**Tabel 4.** Hasil klasifikasi berdasarkan nilai ambang

Nilai ambang	TP	FN	FP	TN	FPR	TPR
<b>Osteoporosis</b>						
0	0	24	0	38	0,00	0,00
0,25	22	2	0	36	0,00	0,92
0,5	24	0	9	29	0,24	1,00
1,0	24	0	38	0	1,00	1,00
<b>Normal</b>						
0	0	24	0	38	0,00	0,00
0,25	21	3	0	38	0,00	0,88
0,3	22	2	2	36	0,05	0,92
0,5	24	0	8	30	0,21	1,00
1,0	24	0	38	0	1,00	1,00

Keterangan: TP = True Positive, FN = False Negative, FP = False Positive, TN = True Negative, FPR = False Positive Rate, TPR = True Positive Rate

**Tabel 5.** Matriks konfusi proses pelatihan

Prediksi \ Fakta	OP	N	Total
OP	24	2	26
N	2	34	36
Total	26	36	62

Keterangan: OP = Osteoporosis, N = Normal

Osteoporosis adalah penyakit metabolik yang ditandai dengan penurunan kepadatan tulang dan peningkatan porositas. Hal ini mengakibatkan penurunan massa tulang trabekula dan kortikal [15]. Hasil seleksi fitur pada kajian ini menunjukkan bahwa pengukuran IRM, analisis tekstur, dan fitur morfologi mempunyai peran yang penting untuk deteksi osteoporosis dengan fitur terpenting adalah IRM pada fitur GI. Hasil ini hampir sejalan dengan [7] dan [9], yang mengukur korelasi antara IRM dengan osteoporosis menggunakan uji korelasi, sedangkan dalam [10] dinyatakan bahwa sebagian besar parameter tekstur trabekula pada penelitian tersebut tidak menunjukkan korelasi yang signifikan dengan nilai densitas massa tulang.

Pada deteksi osteoporosis menggunakan fitur *mandibular cortical degree* (MCD) dalam [16] menghasilkan nilai AUC maksimal sebesar 0,901, menggunakan fitur IRM, dimensi fraktal, dan analisis histogram. Hasil penelitian tersebut juga menunjukkan bahwa osteoporosis berpengaruh secara signifikan terhadap fitur IRM, dimensi fraktal, dan histogram.

Akurasi pada proses pengujian dengan metode yang diusulkan ini lebih rendah jika dibandingkan [1] dan [6]. Namun, hasil AUC-nya lebih baik daripada [5]. Beberapa hal yang diperkirakan menyebabkan perbedaan hasil akurasi tersebut adalah perbedaan jumlah data yang signifikan dan metode pengenalan pola yang digunakan dalam kajian-kajian tersebut.

#### IV. KESIMPULAN

Fitur-fitur yang relevan berhasil diperoleh dengan menggunakan pohon keputusan, yaitu fitur *GI*, *OkaH*, *PMI*, *OkiJK*, *OkaPor*, *OanJK*, dan *OkiH*. Kombinasi metode J48 dan LVQ yang diusulkan dapat digunakan sebagai salah satu alternatif untuk deteksi osteoporosis dengan akurasi pengujian sebesar 83,33 %. Penelitian berikutnya perlu dikembangkan menggunakan model lain yang dapat mengolah data dalam jumlah lebih banyak dan menghasilkan akurasi yang lebih baik.

#### DAFTAR PUSTAKA

- [1] J.-S. Lee, S. Adhikari, L. Liu, H.-G. Jeong, H. Kim, and S.-J. Yoon, "Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study," *Dentomaxillofacial Radiology*, vol. 48, 20170344, 2018. doi: [10.1259/dmfr.20170344](https://doi.org/10.1259/dmfr.20170344)
- [2] E. I. Sela and R. Pulungan, "Osteoporosis identification based on the validated trabecular

**Tabel 6.** Matriks konfusi proses pengujian

Prediksi \ Fakta	OP	N	Total
OP	11	0	11
N	3	4	7
Total	14	4	18

Keterangan: OP = Osteoporosis, N = Normal

- area on digital dental radiographic images," *Procedia Computer Science*, vol. 157, pp. 2820289, 2019. doi: [10.1016/j.procs.2019.08.168](https://doi.org/10.1016/j.procs.2019.08.168)
- [3] E. I. Sela, R. Pulungan, R. Widyaningrum, and R. R. Shantiningsih, "Method for automated selection of the trabecular area in digital periapical radiographic images using morphological operations," *Healthcare Informatics Research*, vol. 25, no. 3, pp. 193-200, 2019. doi: [10.4258/hir.2019.25.3.193](https://doi.org/10.4258/hir.2019.25.3.193)
- [4] R. Widyaningrum, S. Lestari, and F. Jie, "Image analysis of periapical radiograph for bone mineral density prediction," *International Journal of Electrical and Computer Engineering*, vol. 8, no. 4, pp. 2083-2090, 2018. doi: [10.11591/ijece.v8i4.pp2083-2090](https://doi.org/10.11591/ijece.v8i4.pp2083-2090)
- [5] B. Popić et al., "The Radiomorphometric Indices of the Mandible as a Screening Method for Early Detection of Osteoporosis in Postmenopausal Women," *Collegium antropologicum*, vol. 45, no. 1, pp. 31-37, 2021. doi: [10.5671/ca.45.1.4](https://doi.org/10.5671/ca.45.1.4)
- [6] J. J. Hwang et al., "Strut analysis for osteoporosis detection model using dental panoramic radiography," *Dentomaxillofacial Radiology*, vol. 46, 20170006, 2017. doi: [10.1259/dmfr.20170006](https://doi.org/10.1259/dmfr.20170006)
- [7] E. Güngör, D. Yildirim, and R. Çevik, "Evaluation of osteoporosis in jaw bones using cone beam CT and dual-energy X-ray absorptiometry," *Journal of Oral Science*, vol. 58, no. 2, pp. 185-194, 2016. doi: [10.2334/josnusd.15-0609](https://doi.org/10.2334/josnusd.15-0609)
- [8] L. Khojastepour, M. Hasani, M. Ghasemi, A. Mehdizadeh, and F. Tajeripour, "Mandibular trabecular bone analysis using local binary pattern for osteoporosis diagnosis," *Journal of Biomedical Physics and Engineering*, vol. 9, no. 1, pp. 81-88, 2019. doi: [10.31661/jbpe.v9i1Feb.743](https://doi.org/10.31661/jbpe.v9i1Feb.743)
- [9] R. Widyaningrum, N. Kertia, and A. Harjoko, "The relationship between bone mass density and radiomorphometric index on menopausal women from Javanese ethnic in Indonesia: a pilot study," in *the International Conference on Biomedical Engineering and Medical Applications*, Yogyakarta, Indonesai, Jan. 2012, pp. 96-99.
- [10] R. Widyaningrum and S. Lestari, "The correlation between mandible trabecular texture parameter on panoramic radiograph with bone mass density," in *the International Symposium Advanced Clinical Approach for the Prevention of Dental Caries and Implicated Diseases*, Yogyakarta, Indonesia, Nov. 2013, pp. 17-19.
- [11] E. I. Sela, S. Hartati, A. Harjoko, R. Wardoyo, and M. Mudjosemedi, "Feature selection of the combination of porous trabecular with

- anthropometric features for osteoporosis screening,” *International Journal of Electrical and Computer Engineering*, vol. 5, no. 1, pp. 78-83, 2015. doi: [10.11591/ijece.v5i1.pp78-83](https://doi.org/10.11591/ijece.v5i1.pp78-83)
- [12] R. A. Syifa, K. Adi, and C. E. Widodo, “Analisis tekstur citra mikroskopis kanker paru menggunakan metode gray level co-occurrence matrix (GLCM) dan transformasi wavelet dengan klasifikasi Naive Bayes,” *Youngster Physics Journal*, vol. 5, no. 4, pp. 457–462, 2016.
- [13] F. J. Kaunang, “Penerapan algoritma J48 decision tree untuk analisis tingkat kemiskinan di Indonesia,” *CogITO Smart Journal*, vol. 4, no. 2, pp. 348-357, 2019. doi: [10.31154/cogito.v4i2.141.348-357](https://doi.org/10.31154/cogito.v4i2.141.348-357)
- [14] R. Hamidi, M. T. Furqon, and B. Rahayudi, “Implementasi learning vector quantization (LVQ) untuk klasifikasi kualitas air sungai,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 12, pp. 1758–1763, 2017.
- [15] K.-S. Lee, S.-K. Jung, J.-J. Ryu, S.-W. Shin, and J. Choi, “Evaluation of Transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs,” *Journal of Clinical Medicine*, vol. 9, no. 2, 392, 2020. doi: [10.3390/jcm9020392](https://doi.org/10.3390/jcm9020392)
- [16] C. Muramatsu *et al.*, “Quantitative assessment of mandibular cortical erosion on dental panoramic radiographs for screening osteoporosis,” *International Journal of Computer Assisted Radiology and Surgery*, vol. 11, no. 11, pp. 2021–2032, 2016. doi: [10.1007/s11548-016-1438-8](https://doi.org/10.1007/s11548-016-1438-8)



©2021. This open-access article is distributed under the terms and conditions of the [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).