

Convolutional Neural Network untuk Pendeteksian Patah Tulang Femur pada Citra Ultrasonik *B-Mode*

Rika Rokhana^{1,4}, Joko Priambodo¹, Tita Karlita¹, I Made Gede Sunarya¹, Eko Mulyanto Yuniarno^{2,3}, I Ketut Eddy Purnama^{2,3}, Mauridhi Hery Purnomo^{2,3}

Abstract— The bone fracture detection using X-rays or CT-scan produces accurate images but has harmful effect radiation. This paper presented the use of ultrasonic waves (US) as an alternative to substitute those two instruments. This study used femur bovine and chicken bones in conditions with and without meat. The fractures are artificially made on transverse and oblique patterns. The scanning US probe produces two-dimensional (2D) B-mode images. Fracture detection is done using five variations of the Convolutional Neural Network (CNN) architectural design, i.e., CNN1–CNN5. The results showed that the CNN4 is the best design of bone contour recognition and bone fracture classification compared to the other tested designs, with 95.3% accuracy, 95% sensitivity, and 96% specificity. The comparison with the Support Vector Machine (SVM) and k-NN classification methods indicate that CNN has superior performance in accuracy, sensitivity, and specificity.

Intisari— Pendeteksian patah tulang dengan X-ray atau CT-scan menghasilkan gambar yang akurat tetapi memiliki efek negatif radiasi yang berbahaya. Makalah ini memaparkan penggunaan gelombang ultrasonik (US) sebagai alternatif pengganti kedua instrumen tersebut. Makalah ini menggunakan tulang femur sapi dan ayam dalam kondisi dengan dan tanpa daging, dengan patahan dibuat secara manual dengan pola patah *transverse* dan *oblique*. Pemindaian *probe* US menghasilkan citra *B-mode* dua dimensi. Pendeteksian tulang patah dilakukan menggunakan lima variasi desain arsitektur *Convolutional Neural Network* (CNN), yaitu CNN1–CNN5. Hasil uji coba menunjukkan bahwa desain arsitektur CNN4 memberikan hasil pengenalan kontur tulang dan klasifikasi tulang patah yang paling bagus dibandingkan desain arsitektur lain yang diuji, dengan akurasi 95,3%, sensitivitas 95%, dan *specificity* 96%. Hasil perbandingan dengan metode klasifikasi *Support Vector Machine* (SVM) dan *k-Neural Network* (k-NN) menunjukkan

bahwa CNN memiliki unjuk kerja yang lebih unggul baik dalam hal akurasi, sensitivitas, maupun *specificity*.

Kata Kunci— Citra ultrasonik *B-mode*, *Convolutional Neural Network*, lapisan konvolusi, tulang femur.

I. PENDAHULUAN

Kasus patah tulang merupakan hal yang sering ditemukan di dalam kehidupan sehari-hari, dapat dikarenakan kecelakaan lalu lintas, kecelakaan kerja, kecelakaan olahraga, maupun karena penyakit atau bencana alam [1], [2]. Apabila patah yang terjadi adalah patah tulang tertutup, maka penanganan yang tepat memerlukan pendeteksian kondisi tulang yang cepat dan akurat terlebih dahulu [3].

Pendeteksian patah tulang tertutup secara konvensional dilakukan dengan menggunakan foto Rontgen (*X-rays*) [4], [5]. Sedangkan *CT-scan* sering digunakan pada kasus patah tulang yang kompleks yang memerlukan visualisasi tiga dimensi (3D) [6]. Kedua instrumen tersebut telah memberikan hasil yang sangat akurat dalam mendeteksi kondisi permukaan tulang dan deteksi terjadinya patah tulang [7]. Namun, kedua instrumen tersebut memiliki kelemahan dengan adanya efek negatif radiasi sinar X dan ionisasi yang tidak dianjurkan dipergunakan pada pasien anak kecil/bayi, wanita hamil, dan pada beberapa pasien khusus, yang dapat memicu timbulnya penyakit yang lain [7], [8]. Oleh karena itu, dibutuhkan adanya peralatan deteksi patah tulang yang aman tanpa efek radiasi untuk berbagai kategori pasien dan peralatan tersebut harus mudah dalam pengoperasian.

Untuk mengatasi kelemahan *X-rays* dan *CT-scan* tersebut, gelombang ultrasonik (US) dapat digunakan sebagai *modality* utama dalam pendeteksian patah tulang. Gelombang US dengan frekuensi di atas 20 KHz memiliki daya tembus jaringan yang cukup besar dan dalam dunia kedokteran telah dipergunakan untuk tiga hal, yaitu pengobatan, destruktif, dan diagnosis. Dan berdasarkan karakteristiknya, gelombang US paling sering dipergunakan pada jaringan biologis yang lunak [9]. Sedangkan penggunaan gelombang US untuk mendeteksi jaringan yang keras, seperti tulang, belum banyak dipergunakan.

Hasil pemindaian *probe* US sering disajikan dalam bentuk citra dua dimensi (2D), berdasarkan amplitudanya (citra *A-mode*) atau intensitas pikselnya (citra *B-mode*). Citra *B-mode* memiliki kualitas yang rendah dan dipenuhi *speckle* pada seluruh bidang citranya. Pada beberapa kasus, *speckle* ini sangat membantu dalam memisahkan organ/jaringan lunak yang satu dengan yang lain, seperti pada pendeteksian janin [10], segmentasi pembuluh darah [11], [12], pendeteksian penyakit jantung [13], mata [14], kanker payudara [15], [16],

¹ Mahasiswa, Departemen Teknik Elektro, Institut Teknologi Sepuluh Nopember, Gedung B, Kampus ITS, Sukolilo, Surabaya, 60111 (telp:+6231-599 4251; fax: +6231-593 1237; e-mail: rika16@, joko@, tita16@, made.sunarya16@ {mhs.ee.its.ac.id})

² Dosen, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Gedung B, Kampus ITS, Sukolilo, Surabaya, 60111 (telp:+6231-599 4251; fax: +6231-593 1237; e-mail: ekomulyanto@, ketut@, hery@ {ee.its.ac.id})

³ Dosen, Departemen Teknik Komputer, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Gedung B, Kampus ITS, Sukolilo, Surabaya, 60111 (telp:+6231-599 4251; fax: +6231-593 1237; e-mail: ekomulyanto@, ketut@, hery@ {ee.its.ac.id})

⁴ Dosen, Departemen Teknik Elektro, Politeknik Elektronika Negeri Surabaya, Kampus PENS, Sukolilo, Surabaya, 60111 (telp:+6231-594 7280; fax: +6231-594 6114; e-mail: rika@pens.ac.id)

dan penyakit prostat [17] maupun jaringan lain dalam tubuh [18]-[20].

Namun, dalam penggunaan gelombang US untuk mendeteksi kontur tulang dan terjadinya patah tulang, keberadaan *speckle noise* dapat mengganggu dan mengurangi akurasi hasil deteksi. Hal inilah yang menjadi kelemahan gelombang US dalam menggantikan fungsi *X-rays* maupun *CT-scan* dalam pendeteksian patah tulang. Banyak penelitian telah dilakukan untuk menghilangkan *speckle noise* dan mendapatkan citra kontur tulang yang akurat. Pada [21] telah didapatkan *outer bone contour* dari citra US *B-mode* dengan menggunakan *local phase symmetry* dan *quadratic polynomial fitting*. Kemudian telah berhasil dilakukan juga segmentasi tulang dari citra US berdasar *local phase* dan *invariant intensity* pada pasien patah tulang radius distal dan panggul, dengan akurasi kesalahan penentuan lokasi patah sebesar 0,6 mm [22]. Segmentasi tulang pada citra US juga dilakukan menggunakan metode yang lain seperti transformasi *Ridgelet M-band* dengan unjuk kerja yang lebih baik dalam menghilangkan *speckle* dan peningkatan *gain* 5–17% dibandingkan metode yang sudah ada [23].

Penggunaan fungsi *fuzzy-connectedness* pada citra US janin berhasil memprediksi kontur dan ukuran tulang janin [24]. Implementasi metode *Cobbs* pada citra US telah dipergunakan pula untuk mendeteksi terjadinya skoliosis pada tulang belakang [25]. Juga telah dilakukan segmentasi tulang dengan menggunakan kombinasi berbagai macam filter, seperti Wiener, Gaussian, dan *wavelet* untuk *bone-musculoskeletal ultrasonography* [26], [27].

Makalah ini memaparkan alternatif lain untuk mendeteksi kontur tulang dan mengidentifikasi terjadinya patah tulang tertutup dengan menggunakan metode *Convolutional Neural Network* (CNN) pada citra US. Secara singkat, makalah ini memiliki kontribusi utama sebagai berikut.

- Mendapatkan *dataset* citra US *B-mode* 2D dari pemindaian *probe* US secara langsung pada tulang femur sapi dan tulang ayam (tulang dalam kondisi dengan dan tanpa jaringan lunak/daging).
- Melakukan analisis berbagai desain arsitektur CNN untuk mendapatkan arsitektur CNN yang paling tepat dalam melakukan pengenalan (rekognisi) fitur permukaan tulang sekaligus melakukan klasifikasi patah tulang.

Makalah ini disajikan dengan susunan sebagai berikut. Bagian I merupakan pendahuluan, bagian II menyajikan algoritme dalam CNN, bagian III memaparkan tentang akuisisi data dan metode penelitian yang diusulkan, bagian IV berisi tentang hasil eksperimen dan analisis data, sedangkan kesimpulan disajikan pada bagian V.

II. CONVOLUTIONAL NEURAL NETWORK

Proses deteksi dan pengenalan sering menggunakan metode-metode *classifier* seperti *Hidden Markov Model* [28], *Support Vector Machine* (SVM) [29], *Artificial Neural Network* [30], atau metode kombinasi *Adaptive Boost* [31]. Sejalan dengan perkembangan perangkat keras yang mendukung pengolahan *big data* dan komputasi tingkat tinggi, berkembanglah metode *Deep Learning* (DL). DL adalah

sebuah bidang keilmuan baru dalam bidang *Machine Learning* yang menyajikan komposisi transformasi data nonlinear. Salah satu jenis DL adalah *Deep Neural Network* (DNN), dengan kelebihan yaitu dapat memiliki lapisan lebih dari dua.

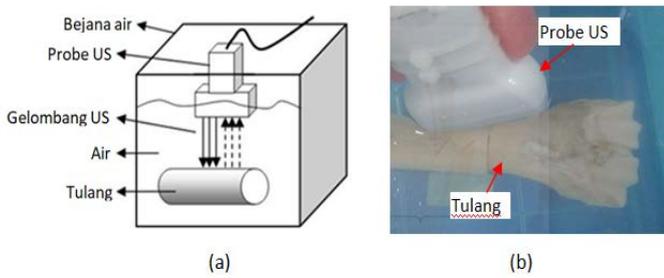
CNN termasuk dalam jenis DNN karena memiliki jaringan yang dalam dan berlapis-lapis. CNN adalah *supervised-feed forward DL*, yang merupakan pengembangan dari *Multilayer Perceptron* (MLP) dan didesain untuk mengolah data berdimensi besar sehingga banyak diaplikasikan pada data citra/visual [32]-[34].

Penggunaan CNN dalam pengenalan dan klasifikasi data mulai berkembang pesat sejak berlangsungnya kompetisi *ImageNet Large-Scale Visual Recognition Challenge* pada tahun 2010. Setelah itu mulai dikenal beberapa arsitektur CNN seperti *Alexnet* yang memiliki arsitektur delapan lapisan [35], *GoogLeNet* memiliki 22 lapisan [36], dan *Resnet* yang memiliki 100 lapisan lebih [37].

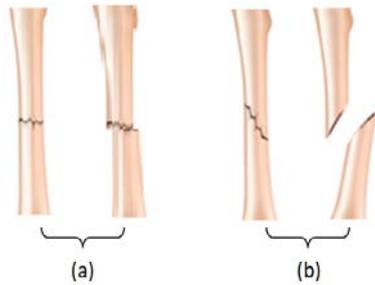
Secara garis besar, terdapat tiga lapisan dalam arsitektur CNN berdasarkan fungsinya, yaitu *Convolutional Layer* (CONV), *Subsampling Layer* (SUBS), dan *Fully Connected Layer* (FC). Arsitektur CNN biasanya terdiri atas beberapa pasang lapisan CONV dan SUBS, diikuti oleh lapisan FC. Lapisan CONV bertanggung jawab untuk mendeteksi fitur lokal tertentu di semua lokasi citra masukan dan berperan sebagai lapisan penghubung yang mengubah data masukan menjadi *feature map* yang sudah dikonvolusi dengan filter. Lapisan SUBS berfungsi mengurangi dimensi *feature map* dengan cara memilih nilai piksel berdasar aturan tertentu untuk menjadi keluaran. Algoritme yang sering digunakan dalam lapisan SUBS adalah operasi *max pooling*. Lapisan FC berfungsi membedakan antar kelas dan melakukan transformasi nonlinear untuk memperoleh nilai keluaran. Biasanya lapisan CONV dan SUBS termasuk bagian *feature learning* sedangkan FC adalah bagian klasifikasi.

Selain ukuran filter dan ukuran *kernel*, pada lapisan CONV terdapat parameter *stride* dan *zero-padding* (ZP). *Stride* adalah parameter yang menentukan jumlah pergeseran filter. Jika nilai *stride* adalah 1, maka filter konvolusi akan bergeser sebanyak 1 piksel secara horizontal diikuti dengan pergeseran vertikal 1 piksel. Semakin kecil *stride*, semakin detail informasi yang dapat diperoleh dari sebuah masukan, meskipun hal tersebut menimbulkan efek pada proses komputasi yang lebih berat.

Keluaran sebuah lapisan CONV akan menjadi masukan dari lapisan CONV berikutnya. Pada kondisi yang masih orisinal, dimensi keluaran selalu lebih kecil daripada dimensi masukannya, sehingga menyebabkan banyak informasi yang terbuang (kecuali pada pemakaian filter 1x1 dengan *stride* 1). Untuk mengatasi hal tersebut, digunakanlah ZP. ZP adalah parameter yang menentukan jumlah piksel (berisi nilai 0) yang akan ditambahkan di setiap sisi masukan lapisan CONV. ZP berfungsi sebagai manipulator agar dimensi keluaran lapisan CONV memiliki ukuran yang sama seperti dimensi masukannya. Penambahan parameter ZP menyebabkan unjuk kerja CNN dapat ditingkatkan, dengan menggunakan lapisan CONV lebih dalam lagi sehingga semakin banyak fitur yang dapat diekstraksi. Hal inilah yang membuat CNN semakin banyak dipergunakan dalam proses ekstraksi dan identifikasi data berdimensi banyak.



Gbr. 1(a) Skema akuisisi data; (b) Contoh akuisisi data pada tulang patah *transverse pattern*.



Gbr. 2(a) Patah tipe *transverse*; (b) Patah tipe *oblique*.

Ada satu parameter lagi yang sering ditambahkan di dalam CNN, yaitu fungsi drop-out (DO). DO adalah metode yang digunakan untuk mengurangi *overfitting* sehingga diperoleh hasil klasifikasi yang lebih akurat. Biasanya *overfitting* terjadi karena jumlah data pelatihan yang sangat besar. Pada proses pelatihan, parameter DO akan meniadakan fungsi aktivasi secara acak dengan probabilitas tertentu. Sedangkan pada saat pengujian, semua fungsi aktivasi akan dipakai, tetapi DO akan memberikan pembobotan (penyekalaan) dengan angka tertentu. Dalam banyak kasus, penambahan DO akan efektif mencegah *overfitting* karena mengurangi korelasi antara neuron-neuron.

III. AKUISISI DATA DAN METODE YANG DIUSULKAN

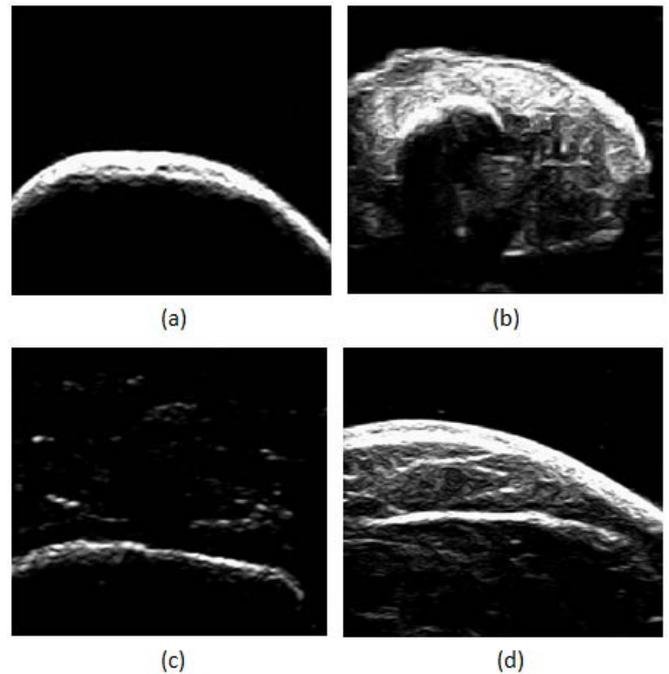
A. Akuisisi Data

Pada makalah ini digunakan probe US tipe *L15-7 L40H US-5 Teleded Ultrasound-OEM Electronics System* dan program *Echo Wave II 3.5.0* untuk mengolah dan menampilkan hasil pemindaian dalam citra *B-mode* 2D. Pengambilan data citra US dilakukan pada frekuensi 10 MHz dengan menempatkan *probe* US di atas objek tulang. Untuk memastikan bahwa gelombang US dapat bekerja dengan baik, *probe* US dan tulang ditempatkan dalam bejana berisi air bersih, seperti ditunjukkan pada Gbr. 1.

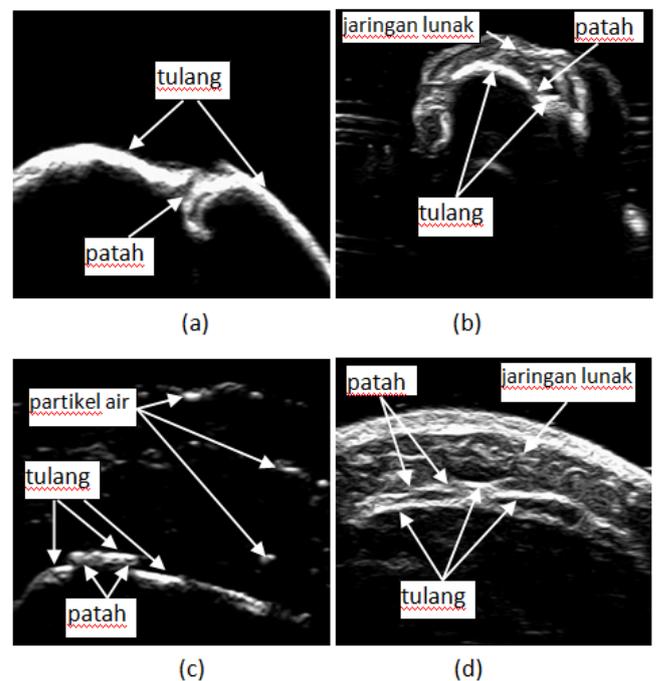
Objek tulang yang digunakan adalah tulang femur sapi dan ayam, dengan dan tanpa daging. Pada objek tulang dengan daging, tulang dilepas terlebih dahulu dari dagingnya untuk dilakukan proses patahan buatan yang terukur, baru daging direkatkan lagi ke tulang dengan bantuan *gel-US*. Tulang yang patah diperoleh secara buatan dengan pola *transverse* dan *oblique pattern* pada area *diaphysis* tulang, seperti ditunjukkan pada Gbr. 2.

Citra hasil pemindaian *probe* US disimpan dalam bentuk video dan setelah melewati pemrosesan awal, data disimpan

dalam bentuk *.jpg*. Satu *file* video dipisahkan menjadi 200 *file* gambar. Pada setiap tulang dilakukan pengambilan data dalam kondisi tulang normal, tulang dengan patah *transverse*, dan tulang dengan patah *oblique*, dengan dan tanpa daging.



Gbr. 3 Citra US *B-mode* 2D hasil pemindaian pada tulang femur sapi dan ayam yang tidak patah; (a) tulang saja; (b) tulang ayam dengan daging; (c) tulang saja tetapi pada media air terdapat gelembung udara; (d) tulang sapi yang dilapisi daging.



Gbr. 4 Citra US *B-mode* 2D dengan tiap baris (a)–(b) dan (c)–(d) adalah tulang ayam patah; (a) tulang femur ayam dengan patahan; (b) tulang femur ayam patah yang dilapisi dengan daging; (c) tulang femur sapi dengan patahan di dalam air yang kurang bersih dan ada gelembung udara; (d) tulang femur sapi yang patah dan dilapisi daging.

Pada setiap titik pengambilan data, proses pemindaian dilakukan dua kali, karena meskipun titik yang dipindai sama, proses pemindaian dapat menghasilkan citra yang berbeda. Hal ini disebabkan citra US sangat dipengaruhi oleh posisi dan orientasi *probe* saat proses pemindaian terhadap objek. Contoh citra hasil pindai *probe* US ditunjukkan pada Gbr. 3 (untuk tulang normal tanpa patahan) dan Gbr. 4 (tulang patah).

Terlihat dari gambar tersebut, meskipun tulang yang dipindai sama, tetapi visualisasi tulang yang patah dalam citra *B-mode* dapat berbeda. Pemindaian US terhadap dua buah femur sapi dan dua buah femur ayam (diameter berbeda) menghasilkan 9.600 data citra. Sebanyak 50% dari data tersebut digunakan sebagai data pelatihan untuk masing-masing kategori dan 50% lainnya digunakan untuk data pengujian.

B. Metodologi

Identifikasi citra *B-mode* sebagai tulang patah atau tulang tidak patah dilakukan dengan menggunakan algoritme CNN. CNN yang digunakan memiliki arsitektur utama sebagai berikut: lapisan CONV dilengkapi dengan lapisan aktivasi *Rectified Linear Unit* (ReLU); lapisan SUBS menggunakan *max pooling*; dan lapisan FC dengan fungsi aktivasi *softmax*. Metode CNN terdiri atas dua tahap. Tahap pertama merupakan tahap pelatihan dengan metode *backpropagation*, Sedangkan tahap kedua merupakan tahap klasifikasi citra menggunakan *feedforward*. Pada tahap pelatihan, parameter yang harus diatur yaitu jumlah *epoch*, ukuran *batch*, dan tipe *optimizer* (pada makalah ini dipergunakan *Adam optimizer*). Sedangkan pada tahap klasifikasi dipergunakan metode *feedforward* dengan bobot dan *bias* yang diperbarui. Pada beberapa kasus, perlu ditambahkan parameter *dropout* dalam arsitektur CNN untuk mencegah *overfitting*.

Masukan awal sistem adalah citra US *B-mode*, yang merupakan vektor berdimensi tinggi. Biasanya diperlukan langkah praproses terlebih dahulu untuk mengondisikan citra dan memfokuskan objek yang akan diklasifikasi. Praproses yang dilakukan adalah dengan melakukan *cropping* pada data hasil pemisahan video, sehingga data *.jpg* yang akan diproses difokuskan pada citra tulang saja.

Jika I adalah citra US *B-mode*, yang memiliki m_1 fitur dengan ukuran $m_2 \times m_3$, maka dapat dituliskan seperti (1).

$$I_{i,j} : \{1, \dots, m_2\} \times \{1, \dots, m_3\}. \quad (1)$$

Jika lapisan CONV, l , memiliki fitur masukan sejumlah m_1^{l-1} dari keluaran lapisan sebelumnya, dengan masing-masing berukuran $m_2^{l-1} \times m_3^{l-1}$, maka l akan memiliki keluaran sejumlah m_1^l fitur dengan ukuran $m_2^l \times m_3^l$. Fitur ke- i dalam lapisan l , Y_i^l , dapat dihitung menggunakan (2).

$$Y_i^l = B_i^l + \sum_{j=1}^{m_1^{l-1}} K_{i,j}^l * Y_j^{l-1} \quad (2)$$

dengan B_i^l adalah matriks *bias*, $K_{i,j}^l$ adalah filter yang berkaitan dengan fitur ke- j pada lapisan $(l-1)$ dan fitur ke- i pada lapisan l , dengan ukuran filter $(2h_1^l + 1) \times (2h_2^l + 1)$, sehingga K dapat dituliskan seperti (3).

$$K = \begin{bmatrix} K_{-h_1, -h_2} & \dots & K_{-h_1, h_2} \\ \dots & K_{0,0} & \dots \\ K_{h_1, -h_2} & \dots & K_{h_1, h_2} \end{bmatrix}. \quad (3)$$

Ukuran fitur keluaran pada lapisan l dapat dihitung menggunakan (4) dan (5).

$$m_2^l = m_2^{l-1} - 2h_1^l \quad (4)$$

$$m_3^l = m_3^{l-1} - 2h_2^l. \quad (5)$$

Pada desain CNN ini, fungsi aktivasi dirancang mempergunakan ReLU. Fungsi aktivasi ReLU mampu mempercepat konvergensi dari proses pelatihan dengan meningkatkan *sparsity* dari jaringan. Dengan menggunakan asumsi bahwa ukuran masukan dan keluaran lapisan l adalah sama, $m_1^l = m_1^{l-1}$, $m_2^l = m_2^{l-1}$, $m_3^l = m_3^{l-1}$, dan jika g_i adalah koefisien *gain*, maka korelasi tersebut dapat disederhanakan mengikuti (6).

$$Y_i^l = g_i f(Y_i^{l-1}) \quad (6)$$

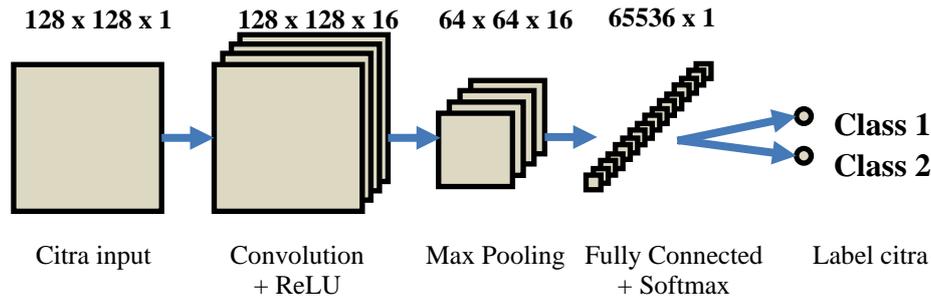
$$Y_i^l = \max(0, Y_i^{l-1}) \quad (7)$$

Pada lapisan CONV dilakukan proses konvolusi terhadap citra masukan menggunakan filter atau *kernel* tertentu untuk menghasilkan sejumlah fitur keluaran. Proses pelatihan yang pada CNN berfungsi untuk melakukan optimasi matriks filter sehingga mampu menghasilkan fitur-fitur yang paling relevan dalam proses klasifikasi citra yang diinginkan. Fitur-fitur keluaran ini memiliki dimensi yang cukup besar yang dapat memperberat komputasi. Untuk mengurangi kompleksitas komputasi dan mendapatkan satu set hierarkis fitur citra, pada makalah ini digunakan lapisan SUBS yang ditempatkan setelah lapisan CONV, dengan menggunakan algoritme *max-pooling*. *Max-pooling* berfungsi untuk memperbaiki translasi *invariance* karena dapat mengurangi ukuran *feature map* dengan memilih respons fitur terbesar.

Kemudian dilakukan normalisasi untuk menyederhanakan perhitungan, meningkatkan *robustness* sistem, dan menghindari kesalahan dalam inialisasi pembobotan, dengan mengikuti (8). Jika C, μ adalah parameter *setting*, maka

$$Y_i^l = \frac{Y_i^{l-1}}{C + \mu \sum_{j=1}^{m_1^{l-1}} (Y_j^{l-1})^2}. \quad (8)$$

Lapisan terakhir dalam CNN adalah FC, yang berfungsi melakukan klasifikasi berdasarkan fitur yang diperoleh pada perhitungan lapisan sebelumnya. Apabila pada lapisan CONV dipergunakan ReLU sebagai fungsi aktivasi, maka pada lapisan FC digunakan fungsi *softmax* sebagai fungsi aktivasinya. Fungsi *softmax* dipilih karena dapat mengurangi kemungkinan nilai *error* yang dihasilkan oleh fungsi objektif *cross-entropy*. Pada makalah ini digunakan fungsi objektif *cross-entropy* karena permasalahan yang hendak diselesaikan adalah klasifikasi. Misalkan l adalah lapisan FC dengan ukuran $m_2^{l-1} \times m_3^{l-1}$ dan jumlah fitur masukan m_1^{l-1} , maka lapisan l pada unit ke- i akan menghitung $y_i^l = f(z_i^l)$ dengan z_i^l dihitung mengikuti (9).



Gbr. 5 Visualisasi arsitektur CNN1.

$$z_i^l = \sum_{j=1}^{m_1^{l-1}} \sum_{r=1}^{m_2^{l-1}} \sum_{s=1}^{m_3^{l-1}} w_{i,j,r,s}^l (Y_j^{l-1})_{r,s} \quad (9)$$

dengan $w_{i,j,r,s}^l$ menunjukkan bobot yang menghubungkan unit ke- j pada posisi (r, s) dalam lapisan $(l - 1)$ dan unit ke- i pada lapisan l .

Penelitian ini dilakukan dengan menggunakan lima variasi arsitektur CNN untuk mendapatkan arsitektur yang paling tepat dalam mendeteksi adanya patah pada dataset citra *B-mode* tulang maupun citra *B-mode* tulang dengan daging. Komputasi dilakukan dengan menggunakan GPU GTX 1080RAM 2 x 8 GB 2400 MHz DDR4 untuk mempersingkat waktu kompilasi program CNN.

Desain arsitektur disajikan pada Tabel I. CNN1 adalah arsitektur dasar dari metode CNN. Gbr. 5 menunjukkan visualisasi arsitektur CNN1. Desain dasar ini dapat dikembangkan menjadi arsitektur CNN2 atau CNN3. CNN2 dapat dikembangkan lagi menjadi CNN4 sedangkan CNN3 dapat dikembangkan menjadi CNN5.

TABEL I
KONFIGURASI ARSITEKTUR CNN YANG DIUJI

CNN1	CNN2	CNN3	CNN4	CNN5
CONV	CONV	CONV	CONV	CONV
			ReLU	ReLU
ReLU	ReLU	ReLU	CONV	CONV
			ReLU	ReLU
Max POOL				
FC	FC	FC	FC	FC
SOFT Max				

Arsitektur CNN didesain seperti itu dengan tujuan untuk mendapatkan pengaruh lapisan CONV dan fungsi aktivasinya dalam mendapatkan nilai akurasi klasifikasi. Perbandingan dapat dilakukan antar desain tersebut secara individual (CNN1, CNN2, CNN3, CNN4, CNN5) maupun antar kelompok desain untuk mendapatkan tipe desain yang paling tepat dalam mengklasifikasi data citra US *B-mode*.

IV. HASIL EXPERIMEN DAN ANALISIS DATA

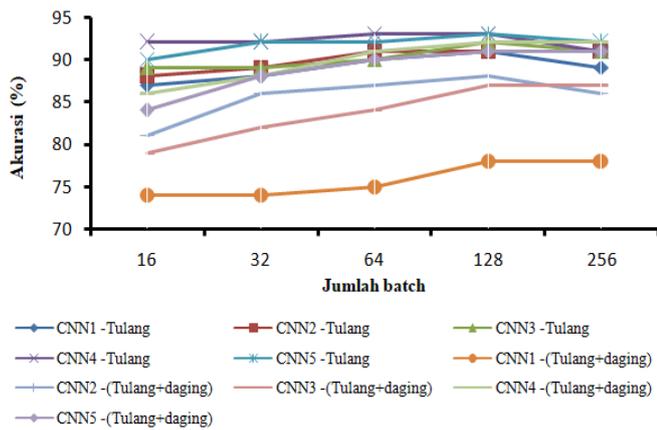
Dataset citra US diujicobakan pada berbagai variasi arsitektur CNN seperti dalam Tabel I. Hasil uji coba disajikan dalam Gbr. 6 sampai Gbr. 8. Dilakukan perbandingan terhadap beberapa parameter CNN untuk mendapatkan nilai parameter yang optimal. Parameter yang perlu diatur pada CNN antara lain adalah besar *epoch* atau banyak iterasi, ukuran *batch* citra yang menentukan banyak citra yang digunakan pada satu kali proses pelatihan, banyak filter atau *output map* konvolusi, ukuran *stride* pada proses konvolusi, ukuran *kernel* konvolusi, dan ukuran *kernel pooling*.

Perbandingan dilakukan dengan cara satu parameter menjadi variabel dan parameter yang lain diberikan nilai yang sama untuk kelima macam arsitektur CNN. Parameter yang dibandingkan adalah besar *epoch*, *batch*, waktu pengujian, pengaruh DO, dan akurasi klasifikasi. Sedangkan parameter-parameter yang lain diatur pada nilai yang sama yaitu banyak filter adalah 16, dengan *Stride* 1 x 1, *kernel* 3 x 3, ukuran *kernel pooling* 2 x 2, dan menggunakan fungsi optimasi *Adam optimizer*. Citra yang digunakan sebagai masukan dari CNN merupakan citra *grayscale* (keabuan) yang di-*crop* sehingga berukuran 128 x 128 piksel.

A. Pengaruh Jumlah Batch

Pada pengujian ini, nilai *epoch* diatur sebesar 50 tanpa lapisan DO. Hasil pengujian ditunjukkan pada Gbr. 6. Terlihat bahwa unjuk kerja terbaik dengan akurasi tertinggi dicapai pada nilai 93%, diperoleh bila *batch* yang dimasukkan adalah sebesar 128 menggunakan desain arsitektur CNN4 dan CNN5 pada dataset citra tulang. Akurasi terendah sebesar 74% diperoleh bila dataset yang diuji adalah citra tulang dengan daging menggunakan arsitektur CNN1 dengan jumlah *batch* 16 dan *batch* 32.

Grafik CNN1 juga menjadi kurva yang tidak normal, sebagai *error* pada desain CNN, yang menunjukkan bahwa arsitektur dasar CNN (CNN1) tidak mampu melakukan klasifikasi dengan baik pada dataset yang kompleks. Pada kelompok arsitektur 1 (CNN1 – CNN2 – CNN4) maupun kelompok arsitektur 2 (CNN1 – CNN3 – CNN5), akurasi memiliki kecenderungan semakin baik (meningkat) bila jumlah *batch* ditambah hingga *batch* sebesar 128, setelah itu akurasi mencapai kondisi *steady state*, tidak ada perubahan meskipun jumlah *batch* dinaikkan. Fenomena ini terjadi baik pada dataset citra tulang maupun citra tulang dengan daging.

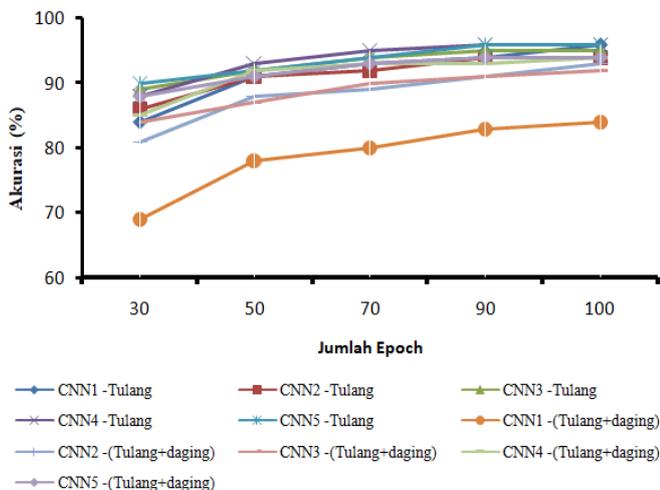


Gbr. 6 Tingkat akurasi klasifikasi tulang patah bila jumlah batch bervariasi.

Secara umum, pengenalan citra tulang menghasilkan akurasi yang lebih tinggi dibandingkan pengenalan citra tulang dengan daging untuk semua desain arsitektur CNN, dengan nilai maksimal pada *batch* 128.

B. Pengaruh Jumlah Epoch

Uji coba desain yang kedua dilakukan dengan membuat nilai *batch* konstan pada 128, tanpa lapisan DO, dan jumlah *epoch* variabel. Hasil uji coba ditunjukkan pada Gbr. 7. Terlihat bahwa semakin besar *epoch*, semakin tinggi akurasi yang diperoleh. Arsitektur CNN4 dan CNN5 memberikan nilai akurasi yang sama, yaitu akurasi 95% pada *epoch* 90 dan 100, dan merupakan nilai akurasi tertinggi pada *dataset* citra tulang.



Gbr. 7 Tingkat akurasi bila jumlah *epoch* bervariasi.

Sedangkan pada citra tulang dengan daging, akurasi tertinggi, sebesar 94%, diberikan oleh arsitektur CNN5 dengan jumlah *epoch* 100. Untuk keseluruhan desain CNN yang diuji coba, CNN1 memberikan unjuk kerja paling rendah saat melakukan pengenalan pada citra tulang dengan daging, yang menghasilkan akurasi 69% pada *epoch* 30.

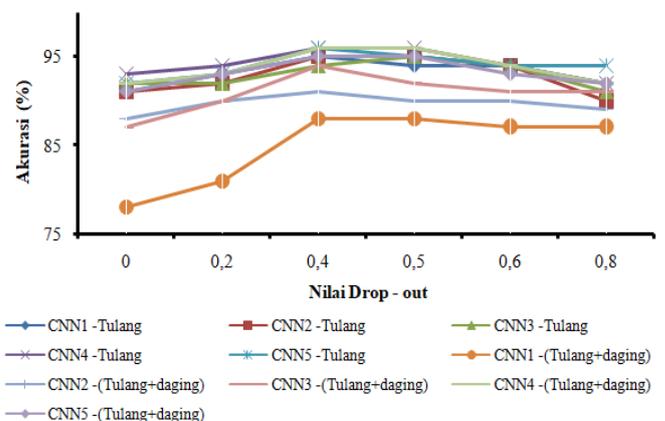
Oleh karena itu, dapat disimpulkan bahwa akurasi tertinggi, sebesar 95%, diperoleh pada *dataset* citra yang sederhana (citra tulang saja) dengan jumlah *epoch* 90. Terdapat

kecenderungan yang sama untuk semua desain arsitektur, bahwa setelah mencapai nilai akurasi maksimal, nilai akurasi akan stagnan meskipun jumlah *epoch* ditingkatkan terus. Pada *dataset* citra *B-mode* tulang, diperlukan desain arsitektur CNN minimal memiliki tiga lapisan CONV.

C. Pengaruh Lapisan Drop-Out

Dari dua uji coba yang dilakukan terhadap jumlah *epoch* dan *batch* tersebut, terlihat bahwa akurasi maksimal diperoleh pada *range* 93%-95%. Berdasarkan teori, penambahan lapisan DO diyakini dapat meningkatkan nilai akurasi. Uji coba berikut diberikan dengan menambahkan lapisan DO pada proses ekstraksi fitur untuk mengetahui tingkat signifikansi parameter DO memengaruhi akurasi sistem. Lapisan DO disisipkan sebelum lapisan FC.

Untuk keperluan ujicoba ini, *epoch* diatur pada nilai 50, *batch* pada 128, dan parameter lain seperti yang telah ditetapkan di awal uji coba. Nilai DO divariasikan pada *range* 0-0,8. Hasil uji coba disajikan pada Gbr. 8.



Gbr. 8 Pengaruh parameter DO pada tingkat akurasi deteksi patah tulang.

Dari gambar tersebut terlihat bahwa penambahan lapisan DO sampai nilai DO tertentu mengakibatkan peningkatan nilai akurasi untuk semua desain arsitektur CNN yang diuji coba. Peningkatan akurasi sangat terlihat pada penambahan DO dari nilai 0 hingga 0,4 untuk semua arsitektur yang diuji. Pada *range* ini, unjuk kerja terbaik dilakukan oleh arsitektur CNN1 untuk *dataset* citra tulang dengan daging, yaitu akurasi meningkat dari 78% menjadi 88% (peningkatan 12,8%). Sedangkan arsitektur yang lain dengan *dataset* tulang maupun tulang dengan daging, mengalami peningkatan akurasi pada *range* 2,2%-8% apabila diberikan lapisan DO dari 0 hingga 0,4.

Pada pemberian DO sebesar 0,5, seluruh desain arsitektur memberikan nilai akurasi maksimal, yaitu CNN4 dan CNN5 memberikan akurasi 95% pada proses pengenalan citra tulang saja. Ketika nilai DO diperbesar, unjuk kerja CNN mengalami penurunan tingkat akurasi, sehingga dapat disimpulkan bahwa nilai optimal DO dalam proses pengenalan tulang patah pada *dataset* citra *B-mode* adalah sebesar 0,5.

Dengan mengabaikan kurva yang dihasilkan CNN1 pada *dataset* citra tulang dengan daging (kurva ini diasumsikan sebagai *error*), terlihat pada Gbr. 8 bahwa pengaruh DO

terhadap akurasi sistem mengikuti kurva parabola dengan nilai maksimal 0,5.

D. Waktu Komputasi

Apabila Gbr. 6 sampai Gbr. 8 diamati, terlihat bahwa akurasi yang dihasilkan bervariasi antara 69% hingga 95%, dengan rata-rata akurasi yang dapat dicapai CNN sebesar 90,1%. Berikut adalah uji coba yang dilakukan untuk mengetahui efisiensi arsitektur, dilihat dari kecepatan komputasi masing-masing arsitektur CNN dengan target akurasi yang telah ditentukan.

Parameter-parameter ditetapkan sama seperti uji coba yang telah dilakukan sebelumnya dan dengan penambahan parameter berikut untuk semua arsitektur yang diuji, yaitu: *epoch* diatur pada 50, *batch* 128, dan penambahan DO sebesar 0,5. Hasil uji coba disajikan pada Tabel II.

TABEL II
WAKTU UNTUK MENCAPAI TINGKAT AKURASI YANG DITENTUKAN

Desain Arsitektur	Dataset	Waktu kompilasi (detik)		
		Akurasi 60%	Akurasi 75%	Akurasi 90%
CNN1	Tulang	1.508,2	2.492,4	2.865,0
	Tulang+Daging	4.215,5	5.645,0	-
CNN2	Tulang	1.687,5	2.632,5	3.019,5
	Tulang+Daging	2.868,5	3.392,5	3.675,0
CNN3	Tulang	1.650,0	2.707,2	2.964,2
	Tulang+Daging	2.872,0	3.308,0	3.745,5
CNN4	Tulang	1.594,2	2.487,5	2.882,5
	Tulang+Daging	2.582,0	3.018,2	3.316,5
CNN5	Tulang	1.608,2	2.490,5	2.916,2
	Tulang+Daging	2.616,5	3.172,5	3.395,0

Terlihat bahwa desain CNN4 menghasilkan waktu rata-rata paling cepat untuk mencapai akurasi keluaran yang ditetapkan.

CNN1 memiliki kelebihan dalam hal waktu komputasi *dataset* tulang tanpa daging karena pada *dataset* tersebut citra sangat jelas, fitur yang harus diekstraksi lebih sedikit dibandingkan *dataset* citra yang lain sehingga proses klasifikasi dapat dilakukan dengan cepat. Sedangkan pada *dataset* citra tulang dengan daging, arsitektur CNN1 memerlukan waktu paling lama, karena desainnya yang paling sederhana, sehingga memerlukan waktu dalam ekstraksi fitur yang banyak.

Untuk *dataset* citra tulang dengan daging, arsitektur CNN4 memberikan hasil terbaik. Hal tersebut menunjukkan bahwa pada citra dengan fitur yang banyak, memang diperlukan proses pemfilteran yang lebih besar. Terlihat juga bila yang diuji coba adalah *dataset* yang kompleks dan persentase akurasi dinaikkan, maka arsitektur CNN yang sederhana tidak mampu mencapai tingkat akurasi tersebut (CNN1 pada akurasi 90%).

E. Analisis Unjuk Kerja CNN

Dari 4.800 *dataset* yang diuji, terdapat 3.200 citra tulang patah dan 1.600 citra tulang tidak patah. Berdasarkan hasil pengujian yang telah dilakukan, dapat dibuat *confusion matrix* untuk klasifikasi tulang patah atau tidak, seperti disajikan pada Tabel III. Hasil pengujian menunjukkan bahwa CNN1

menghasilkan kesalahan paling besar dalam mendeteksi tulang patah, sedangkan yang paling baik dalam melakukan klasifikasi tulang patah adalah arsitektur CNN4.

TABEL III
CONFUSION MATRIX DETEKSI TULANG PATAH

		Data aktual		Total Prediksi	
		Patah	Tidak patah		
Prediksi	CNN1	Patah	2.384	409	2.793
		Tidak patah	816	1.191	2.007
	CNN2	Patah	2.617	373	2.990
		Tidak patah	583	1.227	1.810
	CNN3	Patah	2.658	345	3.003
		Tidak patah	542	1.255	1.797
	CNN4	Patah	3.040	64	3.104
		Tidak patah	160	1.536	1.696
	CNN5	Patah	2.975	86	3.061
		Tidak patah	225	1.514	1.739

Dengan menggunakan (10)–(12), akurasi, sensitivitas, dan *specificity* dari masing-masing desain arsitektur CNN1–CNN5 dalam mengklasifikasi citra US dari tulang femur sapi dan tulang femur ayam ke dalam kelas tulang patah dan tidak patah disajikan dalam Tabel IV.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{10}$$

$$Sensitivitas = \frac{TP}{TP + FN} \tag{11}$$

$$Specificity = \frac{TN}{TN + FP} \tag{12}$$

dengan *TP* adalah *true positive*, *TN* adalah *true negative*, *FP* adalah *false positive*, dan *FN* adalah *false negative*.

TABEL IV
ANALISA KINERJA SISTEM PADA KLASIFIKASI TULANG PATAH

Arsitektur	Akurasi (%)	Sensitivitas (%)	Specificity (%)
CNN1	74,5	74,5	74,4
CNN2	80,0	82,0	77,0
CNN3	81,5	83,0	78,0
CNN4	95,3	95,0	96,0
CNN5	93,5	93,0	95,0

Berdasarkan hasil pada Tabel IV, dapat disimpulkan bahwa konfigurasi CNN4 menunjukkan hasil yang paling baik dalam mengklasifikasikan citra *B-mode* menjadi tulang patah atau tidak. Sedangkan CNN1 memberikan akurasi, sensitivitas, dan *specificity* yang paling buruk di antara semua desain arsitektur yang diuji coba.

F. Perbandingan dengan Metode Klasifikasi yang Lain

Uji coba berikut dilakukan untuk membandingkan unjuk kerja desain CNN4 (sebagai desain CNN terbaik yang sudah terbukti) dengan metode klasifikasi yang lain, yaitu *k-Neural Network* (*k-NN*) dan SVM. Untuk *k-NN*, *dataset* citra US *B-mode* diuji coba dengan menggunakan parameter *k* sebesar 5. Sedangkan pada metode SVM, *dataset* diuji coba menggunakan *linear kernel*. Pengujian dilakukan untuk

mengklasifikasi *dataset* citra US dalam kelas tulang patah atau tidak. Data masukan untuk *classifier* k-NN dan SVM adalah nilai intensitas *grayscale* dari setiap piksel citra pada *dataset*. Hasil pengujian disajikan dalam Tabel V.

TABEL V
PERBANDINGAN UNJUK KERJA METODE CNN – SVM –KNN PADA
KLASIFIKASI TULANG PATAH

Metode	Akurasi (%)	Sensitivitas (%)	Specificity (%)	Waktu komputasi (detik)
CNN4	95,3	95,0	96,0	3.358,5
k-NN (k=5)	92,1	91,8	90,0	2.534,0
SVM (linear)	92,6	92,5	93,7	2.325,5

Didapatkan bahwa ketiga metode memiliki unjuk kerja kinerja yang baik, dengan tingkat akurasi, sensitivitas, dan *specificity*-nya di atas 90% semua. Metode CNN4 menghasilkan unjuk kerja yang paling tinggi, dengan waktu kompilasi yang sedikit lebih lama daripada kedua metode perbandingan. Hal ini menunjukkan bahwa metode CNN dapat diimplementasikan untuk melakukan klasifikasi citra US pada tulang dan jaringan hidup lainnya, dengan unjuk kerja yang bagus.

V. KESIMPULAN

Dari hasil pengujian dan analisis yang telah dilakukan, dapat disimpulkan bahwa algoritme CNN dapat dipergunakan dengan baik dalam klasifikasi citra US *B-mode* 2D untuk memisahkan kontur tulang dari jaringan lain dan kemudian menentukan terjadi patah tulang atau tidak. Citra sederhana pada tulang saja (tanpa daging) dapat diklasifikasikan dengan menggunakan arsitektur CNN yang sederhana (CNN1), dengan akurasi yang cukup tinggi (87%–91%). Namun, bila citra merupakan hasil pemindaian pada tulang dengan daging (objek mendekati kondisi real pada lengan manusia) diperlukan arsitektur CNN yang lebih kompleks. Untuk kasus tersebut, arsitektur CNN4 memberikan hasil terbaik dengan akurasi 95,3%, sensitivitas 95%, dan *specificity* sebesar 96% dengan menggunakan *batch* 128, *epoch* 100, dan penambahan lapisan DO 0,5.

Pada klasifikasi dengan kelas yang kecil seperti pada makalah ini, ketiga metode (CNN, SVM, dan k-NN) memberikan unjuk kerja akurasi, sensitivitas, dan *specificity* yang hampir sama, yaitu di atas 90%, dengan CNN memberikan hasil yang paling tinggi. Keunggulan CNN dibandingkan metode klasifikasi yang lain semakin terlihat apabila dipergunakan untuk melakukan klasifikasi pada citra dengan kelas-kelas yang lebih banyak/besar. Ke depan, penelitian akan dikembangkan dalam hal penggunaan CNN untuk melakukan pengendalian dan klasifikasi citra US *B-mode* tiga dimensi sehingga kelas klasifikasi dapat diperbanyak, tidak sekadar mengetahui tulang patah atau tidak, tetapi juga dapat diklasifikasikan tipe dari patah tersebut.

UCAPAN TERIMA KASIH

Terima kasih yang sebesar-besarnya disampaikan kepada Kementerian Keuangan Republik Indonesia, karena penelitian

ini berlangsung atas pendanaan dari skema beasiswa BUDI – DN. Ucapan terima kasih juga disampaikan kepada Rarasmaya Indraswari atas diskusi yang intens tentang *Convolutional Neural Network*, yang sangat membantu dalam pelaksanaan penelitian ini.

REFERENSI

- [1] S.N. Sya'ban, W. Fatmaningrum, dan S. Bayusentono, "The Profile of Fracture in Patients Under 17 Years of Age at RSUD Dr. Soetomo in the Period of 2013-2014," *J of Orthopaedic and Traumatology Surabaya*, Vol. 6, No. 1, hal. 21–32, 2017.
- [2] V.C. Sagarin, M. Manjas, dan R. Rasyid, "Distribusi Fraktur Femur yang Dirawat di Rumah Sakit Dr. M. Djamil, Padang (2010-2012)," *J Kesehatan Andalas*, Vol. 6, No. 3, hal. 586–589, 2017.
- [3] K.O. Handool, S.M. Ibrahim, U. Kaka, M.A. Omar, dan J. Abu, "Optimization of a Closed Rat Tibial Fracture Model," *J of Experimental Orthopaedics*, Vol. 5, No. 13, hal. 1–9, 2018.
- [4] Y. Cao, H. Wang, M. Moradi, P. Prasanna, dan T.F. Syeda-Mahmood, "Fracture Detection in X-ray Images Through Stacked Random Forests Feature Fusion," *Proc. Intl. Symposium on Biomedical Imaging (ISBI)*, 2015, hal. 801–805.
- [5] Z. Wei dan Z. Liming, "Study On Recognition Of The Fracture Injure Site Based On X-ray Images," *Intl. Congress on Image and Signal Processing*, 2010, hal. 1947–1950.
- [6] V. Cnudde dan M.N. Boone, "High-resolution X-Ray Computed Tomography in Geosciences: A Review of the Current Technology and Applications," *Earth-Science Reviews*, Vol. 123, hal. 1–17, 2013.
- [7] N. Umadevi dan S.N. Geethalakshmi, "Multiple Classification System for Fracture Detection in Human Bone X-Ray Images," *Proc. Intl. Conf. on Computing, Communication and Networking Technologies (ICCCNT 2012)*, 2012, hal. 1–8.
- [8] Z. Zhekova-Maradzheva, B. Velchovska, A. Uzunov, E. Ivanova, D. Petrova, M. Yordanova, dan G. Valchev, "The Effect of X-ray Radiation on the Human Body - Pro and Cons. Radiation Protection in Medical Imaging and Radiotherapy," *Scripta Scientifica Salutis Publicae*, Vol. 2, No. 1, hal. 161–165, 2016.
- [9] M. Rafati, M. Arabfard, M.R. Zadeh, dan M. Maghsoudloo, "Assessment of Noise Reduction in Ultrasound Images of Common Carotid and Brachial Arteries," *IET Computer Vision*, Vol. 10, No. 1, hal. 1–8, 2016.
- [10] M.A. Maraci, C.P. Bridge, R. Napolitano, A. Papageorghiou, dan J.A. Noble, "A Framework for Analysis of Linear Ultrasound Videos to Detect Fetal Presentation and Heartbeat," *Medical Image Analysis*, Vol. 37, hal. 22–36, 2017.
- [11] S. Fekkes, A.E.S. Swillens, H.H.G. Hansen, A.E.C.M. Saris, M.M. Nillesen, F. Iannaccone, P. Segers, dan C.L. De Korte, "Semi-3D Strain Imaging of an Atherosclerotic Carotid Artery by Multi-Cross-Sectional Radial Strain Estimations Using Simulated Multi-Angle Plane Wave Ultrasound," *Proc. IEEE Intl. Ultrasonics Symposium*, 2014, hal. 519–522.
- [12] I.M.G. Sunarya, E.M. Yuniarno, M.H. Purnomo, dan T.A. Sardjono, "Carotid Artery B-Mode Ultrasound Image Segmentation based on Morphology, Geometry, and Gradient Direction," *Intl. Workshop on Pattern Recognition-SPIE*, 2017, Vol. 10443, hal. 001–5.
- [13] F.P. Li, M. Rajchl, J.A. White, A. Goela, dan T.M. Peters, "Ultrasound Guidance for Beating Heart Mitral Valve Repair Augmented by Synthetic Dynamic CT," *IEEE Transactions on Medical Imaging*, Vol. 34, No. 10, hal. 2025–2035, 2015.
- [14] T. Matéo, A. Chang, Y. Mo, P. Pisella, dan F. Ossant, "Axial Ultrasound B-Scans of the Entire Eye with a 20-MHz Linear Array : Correction of Crystalline Lens Phase Aberration by Applying Fermat's Principle," *IEEE Transaction on Medical Imaging*, Vol. 33, No. 11, hal. 2149–2166, 2014.
- [15] A. Koch, M. Genser, F. Stiller, R. Lerch, dan H. Ermert, "A New 3D-Tomographic Ultrasound Imaging Concept for Breast Cancer and Rheumatoid Arthritis Diagnostics Avoiding Water Bath Techniques," *IEEE Ultrasound Symposium*, 2013, hal. 655–658.

- [16] L. Medina-valdés, M. Pérez-liva, J. Camacho, J.M. Udías, dan J.L. Herraiz, "Multi-Modal Ultrasound Imaging for Breast Cancer Detection," *Physics Procedia*, Vol. 63, hal. 134–140, 2015.
- [17] R. Preet, S. Gupta, dan U.R. Acharya, "Segmentation of Prostate Contours for Automated Diagnosis Using Ultrasound Images: A Survey," *J of Computational Science*, Vol. 21, hal. 223–231, 2017.
- [18] B. Sciolla, P. Delachartre, L. Cowell, T. Dambry, dan B. Guibert, "Improved Boundary Segmentation of Skin Lesions in High-Frequency 3D Ultrasound," *Computers in Biology and Medicine*, Vol. 87, hal. 302–310, 2017.
- [19] W. Qiu, Y. Chen, J. Kishimoto, S. De Ribaupierre, B. Chiu, A. Fenster, B.K. Menon, dan J. Yuan, "Longitudinal Analysis of Pre-Term Neonatal Cerebral Ventricles From 3D Ultrasound Images Using Spatial-Temporal Deformable Registration," *IEEE Transaction on Medical Imaging*, Vol. 36, No. 4, hal. 1016–1026, 2017.
- [20] M. Marsousi, K.N. Plataniotis, dan S. Stergiopoulos, "An Automated Approach for Kidney Segmentation in Three-Dimensional Ultrasound Images," *J of Biomedical and Health Informatics*, Vol. 21, No. 4, hal. 1–15, 2017.
- [21] T. Karlita, E.M. Yuniarno, I.K.E. Purnama, dan M.H. Purnomo, "Automatic Bone Outer Contour Extraction from B-Modes Ultrasound Images Based on Local Phase Symmetry and Quadratic Polynomial Fitting," *Int.l Workshop on Pattern Recognition-SPIE*, 2017, vol. 10443, hal. 10.1–6.
- [22] I. Hacıhaliloglu, R. Abugharbieh, A.J. Hodgson, R.N. Rohling dan P. Guy, "Automatic Bone Localization and Fracture Detection from Volumetric Ultrasound Images Using 3-D Local Phase Features," *Ultrasound in Medicine and Biology*, Vol. 38, No. 1, hal. 128–144, 2012.
- [23] D. Gupta, R.S. Anand, dan B. Tyagi, "Despeckling of Ultrasound Images of Bone Fracture Using M-Band Ridgelet Transform," *Optik (Elsevier)*, Vol. 125, No. 3, hal. 1417–1422, 2014.
- [24] S. Rueda, C.L. Knight, A.T. Papageorghiou, dan J.A. Noble, "Feature-Based Fuzzy Connectedness Segmentation of Ultrasound Images with an Object Completion Step," *Medical Image Analysis*, Vol. 26, No. 1, hal. 30–46, 2015.
- [25] C.J. Cheung, G. Zhou, S. Law, K. Lai, W. Jiang, dan Y. Zheng, "Freehand Three-Dimensional Ultrasound System for Assessment of Scoliosis," *J of Orthopaedic Translation*, Vol. 3, No. 3, hal. 123–133, 2015.
- [26] M. Aventaggiato, F. Conversano, P. Pisani, E. Casciaro, R. Franchini, A. Lay-ekuakille, M. Muratore, dan S. Casciaro, "Validation of an Automatic Segmentation Method to Detect Vertebral Interfaces in Ultrasound Images," *IET Science, Measurement and Technology*, Vol. 10, hal. 18–27, 2016.
- [27] M. Matsuzaki, "The Latest Technology of Musculoskeletal Ultrasonography: Iterative Revolution," *J of Medical Ultrasonics*, Vol. 44, No. 3, hal. 223–226, 2017.
- [28] P. Ambrosini, I. Smal, D. Ruijters, W.J. Niessen, A. Moelker, dan T. Van Walsum, "A Hidden Markov Model for 3D Catheter Tip Tracking with 2D X-Ray Catheterization Sequence and 3D Rotational Angiography," *IEEE Transaction on Medical Imaging*, Vol. 36, No. 3, hal. 757–768, 2017.
- [29] R. Rokhana dan S. Anggraini, "Classification of Biomedical Data of Thermoacoustic Tomography to Detect Physiological Abnormalities in the Body Tissues," *Proc. Intl. Electronics Symposium*, 2017, hal. 60–65.
- [30] N. Tamami, P.S. Wardana, R. Rokhana, dan H. Hermawan, "Neural Network Classification of Supraspinatus Muscle Electromyography Feature Signal," *Proc. Intl. Electronics Symposium on Engineering Technology and Applications*, 2017, hal. 223–228.
- [31] Y. Yamasari, S.M.S. Nugroho, D.F. Suyatno, dan M.H. Purnomo, "Meta-Algoritme Adaptive Boosting untuk Meningkatkan Kinerja Metode Klasifikasi pada Prestasi Belajar Mahasiswa," *JNTETI*, Vol. 6, No. 3, hal. 333–341, 2017.
- [32] Y. Kristian, I.K.E. Purnama, E.H. Sutanto, L. Zaman, E.I. Setiawan, dan M.H. Purnomo, "Klasifikasi Nyeri pada Video Ekspresi Wajah Bayi Menggunakan DCNN Autoencoder dan LSTM," *JNTETI*, Vol. 7, No. 3, hal. 308–316, 2018.
- [33] A. Nasuha, T.A. Sardjono, dan M.H. Purnomo, "Pengenalan Viseme Dinamis Bahasa Indonesia Menggunakan Convolutional Neural Network," *JNTETI*, Vol. 7, No. 3, hal. 258–265, 2018.
- [34] S.E. Limantoro, Y. Kristian, dan D.D. Purwanto, "Pemanfaatan Deep Learning pada Video Dash Cam untuk Deteksi Pengendara Sepeda Motor," *JNTETI*, Vol. 7, No. 2, hal. 3–9, 2018.
- [35] A. Krizhevsky, I. Sutskever, dan G.E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Proc. Intl. Conf. on Neural Information Processing Systems*, 2012, hal. 1097–1105.
- [36] C. Szegedy, S. Reed, P. Sermanet, V. Vanhoucke, dan A. Rabinovich, "Going Deeper with Convolutions," *Proc. of IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2015, hal. 1–12.
- [37] K. He, X. Zhang, S. Ren, dan J. Sun, "Deep Residual Learning for Image Recognition," *Proc. of IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2016, hal. 770–778.