

Pendeteksi Sudut Kemiringan Tulang Pada Penderita Skoliosis Menggunakan *Image Processing*

Septiana Dwika Pangestu
Fakultas Teknik Telekomunikasi dan Elektro
Telkom University Kampus Purwokerto
Purwokerto, Indonesia
septianadwikap@student.telkomunivers
ity.ac.id

Sevia Indah Purnama
Fakultas Teknik Telekomunikasi dan Elektro
Telkom University Kampus Purwokerto
Purwokerto, Indonesia
seviaindah@telkomuniversity.ac.id

Mas Aly Afandi
Fakultas Teknik Telekomunikasi dan Elektro
Telkom University Kampus Purwokerto
Purwokerto, Indonesia
alyafandi@telkomuniversity.ac.id

Abstrak — Skoliosis adalah kelainan pada tulang belakang yang ditandai dengan kelengkungan ke samping berbentuk huruf S atau C, dengan derajat keparahan bervariasi. Pengukuran kelengkungan secara manual memerlukan waktu lama dan berisiko tidak konsisten. Penelitian ini bertujuan untuk mengembangkan metode otomatis berbasis citra sinar-X menggunakan deep learning untuk mengklasifikasikan derajat kelengkungan tulang belakang secara efisien dan akurat. Model yang digunakan adalah DenseNet karena kemampuannya dalam mempertahankan fitur melalui koneksi antar lapisan yang padat. Sistem dikembangkan melalui tahapan pemrosesan citra dan pelatihan model dengan parameter seperti ukuran citra, jumlah epoch, batch size, learning rate, dan jenis optimizer. Hasil terbaik diperoleh dengan ukuran citra 224x224, batch size 32, learning rate 0,001, dan optimizer RMSprop, yang menghasilkan akurasi hingga 88,78%, presisi 84,18%, recall 87,54%, dan skor F1 84,65%. Dengan hasil tersebut, sistem ini terbukti mampu meningkatkan akurasi dan efisiensi dalam pengukuran skoliosis serta berpotensi mendukung proses diagnosis dan pengobatan secara lebih konsisten dan objektif di lingkungan klinis.

Kata kunci— Skoliosis, Pemrosesan Citra, Deep Learning, DenseNet, Deteksi Otomatis, Klasifikasi Tulang Belakang, Optimasi Model

I. PENDAHULUAN

Tulang belakang merupakan struktur utama pada tubuh manusia, terdiri dari tiga lekukan alami yang berbentuk huruf “S” dan “C”, dapat diartikan melakukan fungsi yang sangat penting bagi tubuh seperti berjalan, duduk, dan membungkuk. Tulang belakang merupakan aktivitas yang sangat penting bagi setiap manusia,[1] sebagai fungsi utama bagi tubuh tidak menutup kemungkinan bahwa tulang belakang dapat mengalami kerusakan ataupun kelainan yang membuat seluruh aktivitas manusia tidak sepenuhnya berjalan dengan baik.

Salah satu kelainan yang terjadi pada tulang belakang yaitu skoliosis, skoliosis diambil dari bahasa Yunani 'skol' yang berarti bengkok atau berputar. Keadaan ini pertama kali diperkenalkan oleh Hippocrates saat ia menemukan kelainan tulang belakang yang berputar ke arah samping. Menurutnya, kelainan postur ini merupakan bawaan dari lahir atau akibat cara tidur yang salah.[2] Definisi lain menyatakan bahwa skoliosis adalah sebuah tipe deviasi postural dari tulang belakang dengan penyebab apapun, yang dicirikan oleh adanya kurva lateral pada bidang frontal yang dapat berhubungan atau tidak berhubungan dengan rotasi korpus vertebra pada bidang aksial dan sagital.[3]

Penyakit skoliosis ini sangat banyak diderita oleh para remaja karena pada saat remajalah merupakan suatu tahap transisi dari masa kanak-kanak menuju masa dewasa, penyebab dari skoliosis ini disebabkan oleh beberapa faktor yaitu sebesar 75-85% idiopatik atau kelainan yang tidak diketahui penyebabnya dan sebesar 15-25% disebabkan oleh kelainan genetic, trauma waktu kecil, berada di suatu posisi dengan lama dan Panjang kaki kurang simetris.[4]

Melakukan pendeteksian kemiringan ini dilakukan untuk mengetahui tingkat kemiringan pada hasil rontgen penderita skoliosis guna untuk mengetahui tingkat nilai keakuratan pada pemrosesan citra gambar dengan menggunakan pengolahan citra gambar hasil x-ray lalu pengolahan gambar tersebut menggunakan DenseNet yang merupakan salah satu arsitektur arsitektur jaringan saraf konvolusional (Convolutional Neural Network, CNN) yang dirancang untuk meningkatkan efisiensi dan performa dalam pengenalan pola dan klasifikasi gambar. untuk menentukan kemiringan pada suatu tulang belakang, selain itu penulis juga melakukan analisis hasil dari pengolahan citra dengan menyesuaikan tingkat keakuratan pada citra asli. Penelitian tersebut menghasilkan sebuah

analisis kinerja dari hasil training data dan dapat melakukan pendeteksian pada kemiringan tulang belakang.

II. KAJIAN TEORI

A. Skoliosis

Tulang belakang sering dianggap sebagai tulang utama dalam tubuh manusia yang memiliki peran penting bagi tubuh dalam mendukung dan melindungi berbagai fungsi vital, tulang belakang adalah struktur tulang yang terdiri dari serangkaian vertebra yang membentang dari dasar tengkorak hingga ke panggul, selain itu tulang belakang memiliki fungsi utama bagi tubuh manusia diantaranya sebagai penopang utama tubuh, sebagai mekanisme gerak, penyongkong struktural dan lain sebagainya, oleh karena itu sebagai salah satu tulang utama pada manusia tidak menutup kemungkinan jika tulang belakang mengalami kerusakan seperti pengeroposan, keretakan dan pembungkakan.

Salah satu serangan penyakit yang sering terjadi pada tulang belakang adalah skoliosis, Skoliosis merupakan kelengkungan tulang belakang yang abnormal kearah samping, kifosis tulang belakang yang abnormal kearah kedepan, dan lordosis merupakan kelainan tulang belakang terutama bagian punggung bawah bengkak. Umumnya akibat sikap tubuh yang kurang tepat dialami oleh manusia adalah skoliosis dan kifosis atau yang sering disebut membungkuk[5].

B. Citra Digital

Citra merupakan suatu gambaran yang merepresentasikan kemiripan dari suatu objek. Citra analog tidak bisa untuk diproses atau di representasikan dalam computer secara langsung, namun lain halnya dengan citra digital yang dapat diolah langsung oleh computer hal ini disebabkan karena pada citra yang di hasilkan oleh peralatan digital terdapat sistem sampling dan kuantisasi. Sistem sampling merupakan sebuah sistem yang mengubah citra kontinu menjadi citra digital dengan cara membagi citra analog menjadi M baris dan N, semakin besar nilai M dan N maka semakin halus citra digital yang dihasilkan. Pertemuan baris dan kolom di sebut dengan piksel. Sedangkan sistem kuantisasi merupakan sebuah sistem yang melakukan proses perubahan intensitas analog ke intensitas diskrit, sehingga pada proses ini memungkinkan dibuat untuk gradasi warna sesuai dengan kebutuhan. Kedua sistem ini lah yang bertugas untuk memotong-motong citra menjadi M baris dan N kolom (proses sampling) serta menentukan besar intensitas yang terdapat di titik tersebut (proses kuantisasi), sehingga menghasilkan resolusi citra yang di inginkan.[6]

C. Citra Digital

Hasil sampling dan kuantisasi dari sebuah citra merupakan bilangan real yang membentuk sebuah matriks M baris dan N kolom. Berarti dapat di artikan menjadi $M \times N$. Pada gambar 2.3 menjelaskan bahwa sebuah citra digital diwakili oleh matriks terdiri dari M baris dan N kolom, dimana perpotongan antara baris dan kolom disebut piksel. Dengan artian piksel mempunyai dua parameter, yaitu koordinat dan intensitas atau warna. Nilai yang

terdapat pada koordinat (x,y) adalah $f(x,y)$, yaitu besar intensitas atau warna dari piksel di titik itu.[6]

D. Deep Learning

Kecerdasan buatan yang berkembang pesat pada tahun ini sangat berpengaruh bagi kehidupan manusia, dengan hadirnya kecerdasan buatan ini permasalahan di masa lalu akan terselesaikan oleh kecerdasan buatan. Bagian dari kecerdasan buatan dan pembelajaran mesin ini merupakan sebuah pengembangan jaringan syaraf multi-layer dengan menyediakan tugas-tugas presisi seperti pengenalan objek, pengenalan ucapan, dan terjemahan ucapan. Representasi sederhana yang digunakan model deep learning memungkinkan komputerisasi dapat membuat konsep ataupun pola yang lebih kompleks seperti halnya ditunjukkan pada gambar 2.7 berbeda dari teknik pembelajaran mesin tradisional karena secara konsep otomatis melakukan representasi data sebagai contoh video, gambar dan teks tanpa memperkenalkan aturan kode atau pengetahuan domain manusia.[7]

E. DenseNet

Jaringan konvolusi padat (DenseNet) merupakan penghubung pada lapisan ke setiap lapisan lainnya dengan cara feedforward. Dalam jaringan konvolusi lapisan-L tradisional, ada koneksi L-1 pada setiap lapisan layer dan lapisan selanjutnya, akan tetapi pada jaringan tersebut mempunyai koneksi langsung $L(L+1)/2$. DenseNet memiliki beberapa keunggulan yang menarik. Ini mengurangi masalah gradien, meningkatkan ekspansi fungsi, mempromosikan penggunaan kembali fungsi, dan sangat mengurangi jumlah parameter.[6]

F. Convolutional Neural Network

CNN merupakan sebuah jaringan saraf tiruan yang berkerja menggunakan operasi matematika yang dapat menggantikan operasi multiplikasi matriks-matriks pada setiap layer. Selain itu metode CNN juga memiliki hasil yang signifikan, karena metode ini meniru system pengenalan citra yang dilakukan pengolahan citra manusia dan CNN menjadi salah satu metode paling populer dan banyak digunakan untuk penelitian[8].

G. Transfer Learning

Transfer learning adalah teknik yang memanfaatkan model jaringan saraf yang sudah dilatih sebelumnya sebagai dasar untuk menyelesaikan tugas baru. Proses pelatihan lanjutan dengan metode ini jauh lebih efisien dibandingkan melatih jaringan dari awal, karena bobot awal model tidak diinisialisasi secara acak, melainkan sudah membawa pengetahuan dari pelatihan sebelumnya.


Keunggulan utama dari transfer learning adalah kemampuannya mentransfer fitur yang telah dipelajari ke dalam konteks permasalahan baru, bahkan dengan ketersediaan data pelatihan yang terbatas. Meskipun proses fine-tuning umumnya lebih kompleks dan memakan waktu dibandingkan teknik ekstraksi fitur langsung, hasilnya seringkali lebih akurat. Hal ini karena model tidak lagi harus belajar dari nol, melainkan cukup menyesuaikan

representasi fitur yang sudah dipahami dengan karakteristik data baru yang digunakan.[9]

H. METODE

A. Diagram Alir Pengerjaan

Penelitian ini bertujuan untuk merancang dan mengembangkan sistem klasifikasi Deteksi Kemiringan Tulang Belakang pada penderita Skoliosis dengan menggunakan arsitektur DenseNet. Proses penelitian dapat dilihat pada diagram alir berikut:



GAMBAR 1
(DIAGRAM ALIR PENELITIAN)

Setelah sistem klasifikasi dirancang, proses pelatihan machine learning dilakukan dengan menggunakan dataset yang telah dikumpulkan dengan membagi 70% data latih dan 30% data uji. Model yang telah dilatih kemudian diuji untuk mengevaluasi akurasi hasilnya berdasarkan confusion matrix. Jika hasil yang diperoleh belum memenuhi tingkat akurasi yang diharapkan, proses pelatihan dan pengujian akan diulang dengan penyesuaian parameter atau metode. Apabila hasilnya sudah cukup akurat, analisis lebih lanjut dilakukan berdasarkan parameter confusion matrix dengan membandingkan 4 skema untuk mendapatkan pemahaman yang lebih dalam mengenai performa model. Dengan demikian, penelitian ini dapat memberikan solusi yang optimal dalam sistem klasifikasi yang dikembangkan.

B. Diagram Alir Sistem

Penelitian dilakukan perancangan aplikasi pendeteksian kemiringan tulang penderit skoliosis menggunakan program yang dirancang melalui perangkat lunak MATLAB R2024a.




GAMBAR 2
(DIAGRAM ALIR SISTEM)

Perancangan sistem ini dibagi menjadi 2 proses yaitu proses latih yaitu mengasihkan data latih yang berupa citra yang telah diketahui fitur ciri dan proses uji untuk mendapatkan citra yang nantinya akan digunakan pada saat proses klasifikasi.

C. Pre-Processing

Merupakan pemrosesan awal pada pengolahan citra yang bertujuan untuk meningkatkan kualitas citra yang diperoleh, pemrosesan pada tahap pre-processing ini berupa cropping maupun resize yang akan berpengaruh untuk menentukan ukuran piksel untuk melakukan proses selanjutnya, proses pre-processing dijelaskan dalam diagram alir berikut:




GAMBAR 3
(DIAGRAM ALIR PRE-PROCESSING)

Pada diagram alir di atas dijelaskan Proses pre-processing berpengaruh pada kualitas citra yang diperoleh bermula pada melakukan input citra gambar lalu dilakukan proses perubahan warna pada citra yang bermula RGB atau Red Green Blue akan di ubah menjadi Grayscale hal ini bertujuan untuk mempermudah dalam pemilihan piksel dalam pemrosesan citra, lalu proses selanjutnya adalah resize dan cropping untuk mendapatkan ukuran piksel yang sesuai agar mudah dalam melakukan ekstraksi ciri.

D. Klasifikasi

Pada gambar 3.3 yaitu tahap klasifikasi citra menggunakan arsitektur DenseNet yang terdiri dari dua tahap utama: proses pelatihan data (training) dan proses klasifikasi pada antarmuka pengguna (GUI). Tahap pertama mencakup pengolahan citra sebagai data latih melalui beberapa langkah, termasuk input citra, pre-processing, dan pelatihan model. Data yang telah dilatih kemudian digunakan dalam tahap kedua, yaitu proses

klasifikasi pada GUI, di mana pengguna dapat menginput citra baru dan memperoleh hasil klasifikasi secara otomatis.



GAMBAR 4
(DIAGRAM ALIR KLASIFIKASI)

Setelah proses pelatihan selesai dan model telah terbentuk, sistem dapat digunakan untuk melakukan klasifikasi citra melalui GUI. Pengguna hanya perlu menginput citra dan file model yang telah dilatih, kemudian sistem akan melakukan klasifikasi secara otomatis dan menampilkan nilai hasil klasifikasi. Dengan demikian, penelitian ini menghasilkan sistem yang dapat memproses citra secara efisien dan memberikan hasil klasifikasi yang akurat serta mudah digunakan oleh pengguna melalui antarmuka yang interaktif.

E. Pengujian Fungsional Aplikasi

Gambar 3.4 berikut menampilkan antarmuka pengguna grafis (GUI) untuk sistem deteksi kemiringan tulang belakang berbasis citra X-ray. Sistem ini dirancang untuk mempermudah proses klasifikasi kemiringan tulang belakang menggunakan metode machine learning. Dalam GUI ini, pengguna dapat mengunggah citra X-ray, memuat model yang telah dilatih, dan melakukan klasifikasi secara otomatis untuk mendapatkan hasil deteksi tingkat kemiringan tulang belakang.



GAMBAR 5
(TAMPILAN GUI)

GUI ini terdiri dari beberapa elemen sesuai yang ditunjukkan dengan masing-masing nomor sebagai berikut:

- Nomor 1: “Push Button” Unggah untuk menampilkan finder dan unggah citra.
- Nomor 2: “Static Text” Untuk menampilkan lokasi citra yang telah di unggah.
- Nomor 3: “Axes” Untuk menampilkan image yang telah di unggah.
- Nomor 4: “Push Button” Unggah Net untuk menampilkan finder dan unggah file net.
- Nomor 5: “Klasifikasi” Untuk melakukan klasifikasi citra yang telah di unggah.
- Nomor 6: “Static Text” menampilkan angka persentase keakuratan.

Pengujian ini menandakan bahwa integrasi antara interface dan model klasifikasi berjalan dengan baik, tanpa adanya kendala dalam menampilkan input maupun output dari proses klasifikasi.

I. HASIL DAN PEMBAHASAN

Pada bab ini menjelaskan terkait pengujian dari sitem yang dirancang yaitu deteksi kemiringan tulang belakang pada penderita skoliosis dengan menggunakan arsitektur DenseNet, adapun hasil yang akan di bahas pada bab ini yaitu pengujian terhadap nilai akurasi dan loss. Pengujian sistem dengan menggunakan dataset sebanyak 537 citra dibagi menjadi 70% untuk training data dan sebanyak 30% untuk testing. Adapaun pengujian yang akan di bahas pada bab ini sebagai berikut:

- Pengujian untuk menentukan ukuran yang terbaik dengan perbandingan ukuran 128x128, 224x224 dan 256x256.
- Pengujian berdasarkan jumlah epochs untuk menentukan epochs terbaik dengan membandingkan 16, 32 dan 64 epochs
- Pengujian berdasarkan optimizer yang digunakan untuk menentukan optimizer terbaik dengan membandingkan 3 optimier yaitu optimizer adam, sgd, dan rmsprop
- Pengujian berdasarkan learning rate untuk menentukan learning rate terbaik dengan membandingkan 3 learning rate yaitu 1e-2, 1e-3, dan 1e-4
- Pengujian berdasarkan Batch size untuk menentukan Batch size terbaik dengan membandingkan 3 ukuran batch size yaitu 8, 16, dan 32.
- Pengujian menggunakan GUI untuk mendeteksi sudut kemiringan

A. Skema Pengujian Berdasarkan Ukuran Citra

Dalam uji coba ini, penulis melakukan pengujian untuk menentukan ukuran gambar yang optimal dengan membandingkan tiga dimensi citra, yaitu 128x128,

224x224, dan 256x256. Pengujian dilakukan menggunakan pengaturan parameter

sebagai berikut:

- Optimizer: Adam
- Epoch: 16

- Batch size: 8
- Learning rate: $1e-4$

Setelah dilakukan pengujian menggunakan berbagai ukuran gambar yaitu 128×128 , 224×224 dan 256×256 , hasil yang diperoleh dibandingkan menggunakan confusion matrix dengan berbagai perhitungan yaitu akurasi, loss, presisi, recall dan F1-score. Pengujian ini bertujuan untuk menentukan ukuran gambar yang paling optimal untuk digunakan dalam model.

TABEL 1
(HASIL PENGUJIAN BERDASARKAN UKURAN CITRA)

Ukuran Citra	Akurasi	Loss	Presisi	Recall	F1-Score
128×128	85.05%	0.5908	82.64%	81.80%	81.84%
224×224	83.18%	0.4671	79.37%	78.68%	79.01%
256×256	85.05%	0.52796	79.90%	80.96%	80.01%

Berdasarkan hasil pengujian pada tabel 4.1 ini, ukuran gambar 224×224 menunjukkan performa terbaik dengan nilai validation loss terendah sebesar 0.4671, meskipun akurasi (83.18%) dan F1-score (79.01) sedikit lebih rendah dibandingkan ukuran 128×128 dan 256×256 . Loss yang rendah menandakan bahwa kemampuan generalisasi model yang lebih baik pada data validasi, sehingga yang penting untuk memastikan performa stabil pada data baru. Selain itu, ukuran 224×224 juga menawarkan keseimbangan antara resolusi gambar dan efisiensi pada pengolahan citra, di mana ukuran yang lebih kecil dapat menyebabkan hilangnya detail penting, sedangkan ukuran yang lebih besar cenderung meningkatkan kebutuhan pengolahan citra tanpa memberikan peningkatan performa yang signifikan.

Meskipun hasil pengujian menunjukkan bahwa ukuran citra 128×128 dan 256×256 memiliki nilai akurasi yang tinggi, ukuran 224×224 dipilih sebagai konfigurasi utama dalam penelitian ini. [21] Penggunaan ukuran input yang sesuai dengan desain awal model berperan penting dalam memastikan kompatibilitas penuh antar layer serta mendukung proses konvergensi yang stabil selama pelatihan. Selain itu, dari hasil pengujian yang dilakukan, ukuran 224×224 menunjukkan nilai loss terendah (0.4671) dibandingkan dengan ukuran lain meskipun nilai akurasinya sedikit lebih rendah. Nilai loss yang rendah mengindikasikan bahwa model memiliki kemampuan generalisasi yang lebih baik terhadap data baru, yang sangat penting dalam konteks pengujian klinis atau data dunia nyata.

Dari perspektif efisiensi komputasi, ukuran citra 224×224 juga berada pada titik kompromi yang ideal. Ukuran yang terlalu kecil seperti 128×128 dapat menyebabkan hilangnya detail morfologis penting pada citra X-ray, sementara ukuran yang lebih besar seperti 256×256 akan meningkatkan waktu pelatihan dan konsumsi memori tanpa memberikan peningkatan performa yang signifikan.

Dengan demikian, keputusan untuk memilih ukuran 224×224 bukan semata-mata karena hasil akurasi tertinggi, melainkan berdasarkan keseimbangan antara performa

model (loss dan F1-score), efisiensi komputasi, serta kesesuaian arsitektur pretrained.

B. Skema Pengujian Untuk Menentukan Nilai Epoch Terbaik

Dalam uji coba ini, penulis melakukan pengujian untuk menentukan jumlah epochs yang optimal dengan membandingkan tiga konfigurasi, yaitu 16, 32, dan 64 epochs. Pengujian menggunakan pengaturan parameter sebagai berikut:

- Optimizer: Adam
- Ukuran gambar: 224×224
- Batch size: 8
- Learning rate: $1e-4$

Pengujian berdasarkan jumlah epoch terhadap performa model yang dilatih dilakukan dengan membandingkan jumlah epoch yaitu sebesar 16, 32, dan 64 epochs, hasil yang diperoleh dibandingkan berdasarkan confusion matrix seperti akurasi, loss, presisi, recall dan F1-score. Selain itu pengujian pada skema ini bertujuan untuk mendapatkan hasil yang optimal untuk digunakan dalam model.

TABEL 2
(HASIL PENGUJIAN BERDASARKAN NILAI EPOCH)

Epochs	Akurasi	Loss	Presisi	Recall	F1-Score
16	79.44%	0.4431	75.33%	74.75%	74.97%
32	75.70%	0.35633	67.01%	72.79%	69.06%
64	72.90%	0.34918	67.52%	70.14%	68.39%

Pada tabel 4.2 di jelaskan bahwa jumlah epoch terbaik untuk model ini adalah 16 epoch. Meskipun validation loss pada 16 epoch lebih tinggi dibandingkan 32 atau 64 epoch, akurasi, precision, recall, dan F1-score yang dihasilkan jauh lebih baik dibandingkan jumlah epoch lainnya. Validation loss yang lebih rendah pada epoch lebih tinggi (32 dan 64) kemungkinan besar disebabkan oleh overfitting, yang terlihat dari penurunan metrik evaluasi lainnya. Oleh karena itu, dengan mempertimbangkan performa keseluruhan, 16 epoch dipilih sebagai konfigurasi yang menghasilkan hasil terbaik, karena memberikan keseimbangan antara akurasi, F1-score, dan stabilitas model.

C. Skema Pengujian Untuk Menentukan Optimizer Terbaik

Dalam uji coba ini, penulis melakukan pengujian untuk menentukan optimizer yang optimal dengan membandingkan tiga optimizer, yaitu adam, sgdm, dan rmsprop. Pengujian menggunakan pengaturan parameter sebagai berikut:

- Epoch: 16
- Ukuran gambar: 224×224
- Batch size: 8
- Learning rate: $1e-4$

Untuk mengetahui pengaruh jenis optimizer terhadap performa model, dilakukan pengujian menggunakan beberapa optimizer seperti sgdm, adam, dan rmsprop yang digunakan dalam deep learning. hasil pengujian dibandingkan berdasarkan confusion matrix seperti akurasi, loss, presisi, recall, dan F1-score untuk menentukan optimizer yang paling optimal.

TABEL 3
(HASIL PENGUJIAN BERDASARKAN OPTIMIZER)

Optimizer	Akurasi	Loss	Presisi	Recall	F1-Score
adam	82.24%	0.51745	72.14%	79.59%	72.71%
sgdm	77.57%	0.66337	65.58%	71.60%	67.37%
rmsprop	88.78%	0.37033	84.18%	87.54%	84.65%

Berdasarkan hasil training pada tabel, pengujian dilakukan menggunakan tiga optimizer berbeda: Adam, SGDM (*Stochastic Gradient Descent with Momentum*), dan RMSprop. Optimizer RMSprop memberikan hasil terbaik dengan akurasi tertinggi sebesar 88.785%, precision 84.184, recall 87.541, dan F1-score 84.649, serta nilai validation loss terendah yaitu 0.37033. Hal ini menunjukkan bahwa RMSprop tidak hanya memberikan performa yang tinggi dalam aspek prediksi, tetapi juga memiliki kemampuan generalisasi yang baik karena nilai validation loss-nya lebih rendah dibandingkan optimizer lainnya. Dengan mempertimbangkan semua angka, RMSprop adalah optimizer terbaik untuk penelitian ini, karena memberikan keseimbangan antara akurasi, F1-score, dan kemampuan generalisasi.

D. Skema Pengujian Untuk Menentukan Nilai Learning Rate Terbaik

Dalam uji coba ini, penulis melakukan pengujian untuk menentukan Learning rate yang optimal dengan membandingkan tiga nilai Learning rate, yaitu $1e-2$, $1e-3$, dan $1e-4$. Pengujian menggunakan pengaturan parameter sebagai berikut:

- Epoch: 16
- Ukuran gambar: 224x224
- Batch size: 8
- Optimizer: rmsprop

Untuk mendapatkan hasil yang optimal dilakukan pengujian menggunakan parameter yang telah ditentukan, untuk mendapatkan hasil yang optimal pada skema pengujian ini membandingkan parameter Learning rate yaitu $1e-2$, $1e-3$ dan $1e-4$ berdasarkan pada confusion matrix diantaranya yaitu akurasi, loss, presisi, recall, dan F1-score.

TABEL 4
(HASIL PENGUJIAN BERDASARKAN NILAI LEARNING RATE)

Learning Rate	Akurasi	Loss	Presisi	Recall	F1-Score
0.01	61.68%	0.93757	33.33%	61.68%	76.30%
0.001	37.38%	0.89166	38.76%	54.29%	37.34%
0.0001	85.98%	0.6094	77.67%	89.71%	79.54%

Berdasarkan hasil pengujian dengan tiga nilai learning rate yang berbeda, yaitu 0.01, 0.001, dan 0.0001, nilai learning rate 0.0001 memberikan hasil terbaik dengan akurasi tertinggi sebesar 85.981%, precision 77.671, recall 89.712, dan F1-score 79.54. Selain itu, nilai validation loss sebesar 0.6094 pada learning rate ini lebih rendah dibandingkan learning rate lainnya, menunjukkan kemampuan generalisasi model yang lebih baik. Sebaliknya, learning rate 0.01 menghasilkan akurasi sebesar 61.682% dengan F1-score 76.301, tetapi precision yang sangat rendah (33.333) mengindikasikan model mengalami kesulitan dalam membuat prediksi yang akurat. Validation loss untuk learning rate ini juga tinggi (0.93757), menandakan bahwa model tidak dapat mempelajari pola data secara optimal. Sementara itu, learning rate 0.001 memiliki performa terburuk dengan akurasi 37.383%, F1-score 37.338, dan validation loss sebesar 0.89166, yang menunjukkan bahwa model gagal melakukan konvergensi.

E. Skema Pengujian Untuk Menentukan Nilai Batch Size Terbaik

Dalam uji coba ini, penulis melakukan pengujian untuk menentukan Batch size yang optimal dengan membandingkan tiga nilai ukuran batch size, yaitu 8, 16, dan 32. Pengujian menggunakan pengaturan parameter sebagai berikut:

- Epoch: 16
- Ukuran gambar: 224x224
- Optimizer: rmsprop
- Learning Rate: $1e-4$

Setelah dilakukan pengujian dengan membandingkan ukuran batch size yaitu 8, 16 dan 32 berdasarkan confusion matrix seperti akurasi, loss, presisi, recall dan F1-score. Pengujian ini bertujuan untuk memnentukan nilai ukuran batch size yang paling optimal.

TABEL 4
(HASIL PENGUJIAN BERDASARKAN NILAI BATCH SIZE)

Batch Size	Akurasi	Loss	Presisi	Recall	F1-Score
8	78.51%	0.53611	68.05%	73.46%	70.09%
16	83.18%	0.49407	76.63%	77.81%	77.16%
32	86.92%	0.39404	78.89%	87.96%	82.04%

Berdasarkan hasil pengujian dengan tiga ukuran batch size yang berbeda, yaitu 8, 16, dan 32, batch size 32 memberikan hasil terbaik. Pada batch size ini, model mencapai akurasi tertinggi sebesar 86.916%, precision 78.894, recall 87.956, dan F1-score 82.039. Selain itu, nilai validation loss sebesar 0.39404 adalah yang terendah dibandingkan dengan batch size lainnya, yang menunjukkan bahwa model memiliki kemampuan generalisasi yang baik.

Sebaliknya, batch size 8 menghasilkan akurasi yang lebih rendah sebesar 78.505%, precision 68.049, recall 73.456, dan F1-score 70.082, dengan validation loss tertinggi sebesar 0.53611. Hal ini mengindikasikan bahwa model kurang optimal dalam proses pembelajaran dengan ukuran batch yang kecil. Batch size 16 menunjukkan

performa yang lebih baik dibandingkan batch size 8, dengan akurasi 83.178%, F1-score 77.157, dan validation loss 0.49407, tetapi masih kalah dibandingkan batch size 32.

Dengan mempertimbangkan seluruh metrik evaluasi, batch size 32 adalah yang paling optimal untuk digunakan. Batch size ini memungkinkan model untuk mempelajari pola data lebih efektif tanpa kehilangan kemampuan generalisasi, seperti terlihat dari tingginya akurasi, F1-score, dan rendahnya nilai validation loss

F. Skema Pengujian Untuk Menentukan Sudut Kemiringan

Pengujian dalam penelitian ini dilakukan dengan menetapkan kategori pengujian berdasarkan nilai akurasi yang diperoleh pada masing-masing rentang sudut kemiringan, yaitu antara 0° – 25° , 25° – 45° , dan lebih dari atau sama dengan 45° . Setiap kategori diuji untuk mengetahui seberapa baik model mampu mengenali dan mengklasifikasikan citra pada rentang kemiringan tertentu. Dalam proses evaluasi ini, digunakan file model berformat .net yang memiliki performa terbaik, yakni model yang sebelumnya telah menunjukkan hasil akurasi tertinggi dari seluruh percobaan yang dilakukan dengan berbagai konfigurasi. Pemilihan model terbaik ini didasarkan pada kinerja keseluruhan dalam proses pelatihan dan validasi, sehingga diharapkan mampu memberikan hasil pengujian yang optimal dalam setiap kategori sudut yang diuji.

TABEL 4
(HASIL PENGUJIAN AKURASI SUDUT)

No	Sudut Kemiringan		
	0° – 25° Akurasi (%)	25° – 45° Akurasi (%)	$\geq 45^{\circ}$ Akurasi (%)
1	55.84	79.13	97.86
2	66.92	30.23	20.34
3	59.60	90.41	30.47
4	83.65	56.74	98.05
5	87.13	81.53	96.07
6	88.07	96.22	87.17
7	98.15	20.12	93.64
8	97.03	20.33	63.53
9	84.42	67.08	83.40
10	85.49	66.90	99.67
11	99.02	73.80	98.34
12	78.02	10.02	57.14
13	79.39	66.80	98.30
14	76.46	30.56	98.70
15	86.52	98.91	99.45

Tabel di atas menunjukkan hasil evaluasi akurasi model klasifikasi skoliosis terhadap tiga kelas sudut kemiringan, yaitu 0° – 25° , 25° – 45° , dan $\geq 45^{\circ}$, yang masing-masing diuji sebanyak 15 kali pengujian. Hasil ini menunjukkan adanya fluktuasi performa model terhadap masing-masing kelas, terutama pada kelas menengah (25° – 45°) yang secara konsisten menunjukkan ketidakstabilan akurasi dibandingkan dua kelas lainnya. Pada kelas 0° – 25° , akurasi berkisar antara 55.84% hingga 99.02%, dengan sebagian besar nilai berada di atas 80%, menunjukkan bahwa model

cukup mampu mengenali citra pada kategori skoliosis ringan. Hal yang serupa juga tampak pada kelas $\geq 45^{\circ}$, di mana akurasi cenderung tinggi dan stabil, berkisar antara 20.34% hingga 99.67%, dan sebagian besar hasil berada di atas 90%. Hal ini dapat dijelaskan oleh fakta bahwa kelas ini memiliki jumlah data yang paling banyak dalam pelatihan, yaitu sebanyak 317 citra, sehingga model dapat belajar lebih baik dan menghasilkan prediksi yang akurat pada kelas ini.

Namun, berbeda dengan kedua kelas tersebut, akurasi pada kelas 25° – 45° sangat bervariasi dan menunjukkan ketidak konsistenan yang mencolok, dengan nilai terendah mencapai 10.02% dan tertinggi 98.91%. Fluktuasi ini menunjukkan bahwa model mengalami kesulitan dalam mengklasifikasikan citra skoliosis sedang secara konsisten. Salah satu kemungkinan penyebabnya adalah jumlah data pelatihan untuk kelas ini yang paling sedikit (80 citra), sehingga representasi fitur dari kategori ini kurang terwakili dalam proses pembelajaran model. Hal ini juga diperburuk oleh kemungkinan kemiripan visual antara citra dari kelas menengah dengan dua kelas lainnya, yang dapat menyebabkan tumpang tindih dalam ruang fitur dan menurunkan akurasi klasifikasi.

Secara umum, performa terbaik dicapai pada beberapa pengujian seperti pada baris ke-11 dan ke-15, di mana ketiga kelas memperoleh akurasi tinggi secara bersamaan (misalnya, baris ke-15: 86.52%, 98.91%, dan 99.45%). Namun demikian, performa yang sangat rendah pada kelas 25° – 45° dalam beberapa pengujian menunjukkan bahwa model masih perlu dilakukan optimasi. Strategi yang dapat dipertimbangkan untuk memperbaiki performa ini meliputi penyeimbangan jumlah data antar kelas, teknik augmentasi khusus untuk kelas minoritas, atau penerapan metode class weighting saat pelatihan. Dengan demikian, model tidak hanya unggul pada kelas mayoritas, tetapi juga mampu mempertahankan performa tinggi dan stabil pada seluruh kelas yang diuji. Analisis ini menunjukkan pentingnya keseimbangan data dalam pelatihan model deep learning untuk klasifikasi medis yang sensitif seperti skoliosis, agar hasil yang diperoleh lebih andal dan representatif.

J. KESIMPULAN

A. Kesimpulan

Hasil dari skenario pengujian dan program yang telah penulis lakukan untuk melakukan pendeteksian kemiringan tulang belakang dengan menggunakan DenseNet201 didapatkan Kesimpulan sebagai berikut:

1. Penulis berhasil merancang sistem untuk mendeteksi kemiringan pada penderita *scoliosis* dengan 3 kelas yaitu kemiringan 0 – 25 , 25 – 45 dan >45 dengan menggunakan arsitektur DenseNet dengan citra hasil rontgen tulang belakang manusia untuk di lakukan klasifikasi, aplikasi figure di matlab berisikan beberapa fitur diantaranya: tombol untuk unggah, axes untuk menampilkan image, tombol untuk unggah data hasil train, dan tombol klasifikasi untuk melakukan klasifikasi image sesuai dengan image yang di unggah

dan berdasarkan file train data citra rongten telah di unggah.

2. Pengujian Tingkat akurasi penulis melakukan hasil analisis berdasarkan data train yang di latih dengan mencari parameter-parameter yang paling optimal lalu penulis analisis berdasarkan confusion matrix, pengujiannya di antaranya: pengujian skema ukuran citra, pengujian untuk menentukan nilai epoch terbaik, pengujian untuk menentukan optimizer terbaik, pengujian nilai batch terbaik dan pengujian fungsional aplikasi, pada pengujian ini penulis mendapatkan hasil yang paling optimal yaitu pada ukuran citra 224x224, nilai epoch 16, optimizer rmsprop, dan batch size 32.
3. Analisis hasil dari hasil 4 pengujian tersebut penulis analisis berdasarkan parameter akurasi, loss, presisi, recall dan f1-score dengan menentukan hasil yang terbaik untuk di jadikan data train pada aplikasi.

B. Saran

Adapun saran untuk penulis selanjutnya jika akan menggunakan topik ini sebagai berikut:

1. Untuk meningkatkan performa model, disarankan menggunakan dataset yang lebih besar dan lebih bervariasi, khususnya dalam hal distribusi data untuk masing-masing kelas kemiringan tulang belakang. Semakin besar dan bervariasi dataset yang digunakan, semakin baik model dapat mengenali pola-pola dari berbagai kondisi.
2. Untuk pengembangan lanjutan dapat menggunakan arsitektur lainnya agar dapat mendapatkan hasil yang lebih baik lagi.
3. Dalam pengembangan aplikasi, disarankan untuk menggunakan MATLAB dengan fitur *App Designer* sebagai pengganti GUIDE. *App Designer* menyediakan antarmuka yang lebih modern dan komponen yang lebih fleksibel untuk mendukung pengembangan aplikasi berbasis GUI, sehingga dapat memberikan pengalaman pengguna yang lebih baik.

REFERENSI

- [1] H. Eka, "Macam-Macam Gangguan Tulang Belakang dan Penyebabnya."
- [2] R. R. Rinaldi and A. B. Sriwarno, "DAILY MILWAUKEE BRACE SEBAGAI PRODUK PENYANGGA TULANG BELAKANG PADA PASIEN SKOLIOSIS (Studi Kasus Orthosis Milwaukee)," *Jurnal Tingkat Sarjana Senirupa dan Desain*, 2018.
- [3] P. J. A. L. S. and A. E., "REHABILITASI MEDIK PADA SKOLIOSIS," *Jurnal Biomedik*, 2019.
- [4] W. S and F. A., "HUBUNGAN CITRA DIRI DENGAN KEPERCAYAAN DIRI KLIEN YANG MENGALAMI GANGGUAN SKOLIOSIS DI MASYARAKAT SKOLIOSIS INDONESIA," *Journal of Social Work and Social Service*, vol. 1, pp. 107–126, 2020.

[5] C. Liang Suryabi, "PERANCANGAN MEDIA PEMBELAJARAN INTERAKTIF TENTANG SIKAP TUBUH YANG BENAR."

[6] A. Faizin, A. T. Arsanto, M. Lutfi, and A. R. Musa, "DEEP PRE-TRAINED MODEL MENGGUNAKAN ARSITEKTUR DENSENET UNTUK IDENTIFIKASI PENYAKIT DAUN PADI," 2022.

[7] A. Faizin, A. T. Arsanto, M. Lutfi, and A. R. Musa, "DEEP PRE-TRAINED MODEL MENGGUNAKAN ARSITEKTUR DENSENET UNTUK IDENTIFIKASI PENYAKIT DAUN PADI," 2022.

[8] K. M. Sandi, A. Prima Yudha, N. Dimas Aryanto, and M. A. Farabi, "Klasifikasi sampah menggunakan Convolutional Neural Network," *Indonesian Journal of Data and Science (IJODAS)*, vol. 3, no. 2, pp. 72–81, 2022.

[9] D. M. Wonohadidjojo, "Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih," *Ultimatics : Jurnal Teknik Informatika*, vol. 13, no. 1, p. 51, 2021.