

Convolutional Neural Network dalam Analisis Citra Medis

D Gunawan^{*1}, H Setiawan²

¹Universitas Atma Jaya Yogyakarta

²Universitas Ma Chung

E-mail: dannygunawan24@gmail.com¹, hendry.setiawan@machung.ac.id²

Abstrak. Penggunaan *deep learning* dapat diaplikasikan di berbagai bidang seperti pendidikan, bisnis, pertanian, pertambangan, *internet of things* (IoT), keamanan *cyber*, perkiraan cuaca, dan medis. Dalam dunia medis penggunaan *deep learning* telah berkembang pesat, menjadi sebuah pilihan yang menjanjikan dalam menganalisis citra medis metode yang digunakan adalah *convolutional neural network* (CNN). Para peneliti terdahulu telah mendapatkan hasil yang memuaskan di semua sub bidang analisis citra medis, seperti klasifikasi, deteksi, segmentasi, dan peningkatan citra. Dengan keberhasilan ini para peneliti menemukan sebuah model yang dapat mendiagnosis dan mendeteksi secara otomatis, yang dapat membantu para ahli di bidangnya dan menunjukkan bahwa teknologi *deep learning* akan sangat bermanfaat bagi kemajuan analisis citra medis.

Kata kunci: Convolutional Neural network, Deep Learning, Analisis Citra Medis

Abstract. *The use of deep learning can be applied in various fields such as education, business, agriculture, mining, internet of things (IoT), cyber security, weather forecasting, and medical. In the medical world, the use of deep learning has grown rapidly, becoming a promising option in analysing medical images. The method used is convolutional neural network (CNN). Previous researchers have obtained satisfactory results in all sub-fields of medical image analysis, such as classification, detection, segmentation, and image enhancement. With this success the researchers found a model that can diagnose and detect automatically, which can help experts in the field and show that deep learning technology will be very useful for advances in medical image analysis.*

Keywords: Convolutional Neural Network, Deep Learning, Medical image analysis

1. Pendahuluan

Deep learning [1] merupakan bidang yang banyak digunakan di beberapa penelitian mulai dari *computer vision* [2], *speech recognition* [3], dan *natural language processing* (NLP) [4]. Metode *deep learning* sangat cocok digunakan saat data tersebut memiliki jumlah data yang banyak. *Deep learning* merupakan tren yang berkembang dalam analisis data dan masuk dalam salah satu dari 10 terobosan teknologi [5]. *Deep learning* adalah peningkatan jaringan syaraf tiruan, yang memiliki lapisan lebih banyak sehingga mendapatkan tingkat ekstraksi yang lebih tinggi dan lebih baik dalam prediksi [1]. Penggunaan *deep learning* dapat

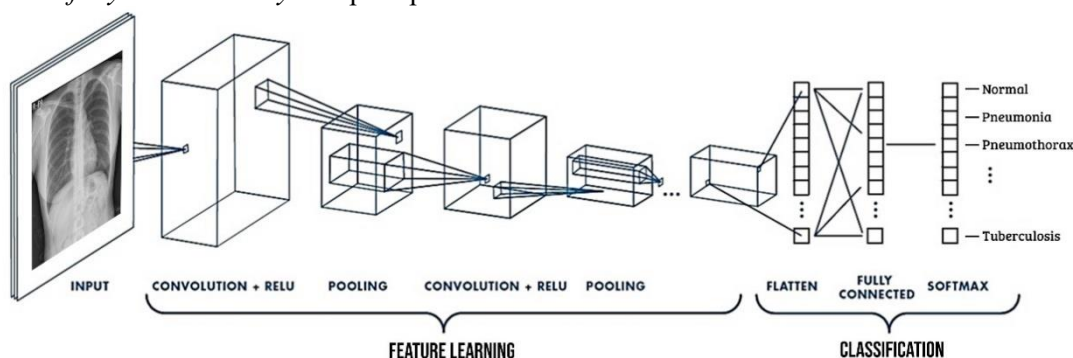
diaplikasikan diberbagai bidang seperti pendidikan [6], bisnis [7], pertanian [8], pertambangan [9], *internet of things* (IoT) [10], keamanan *cyber* [11], [12], perkiraan cuaca [13], medis [14], dll.

Dalam dunia medis membutuhkan ketepatan dalam menangani sebuah masalah agar dapat mencegah kehilangan nyawa dari seseorang. Dalam bidang medis menggunakan citra telah menjadi metode diagnostik dalam praktik klinis sejak lama. Ada banyak citra medis yang dapat dimanfaatkan dalam bidang medis, seperti *Magnetic Resonance Imaging* (MRI), *Computer Tomography* (CT), *ultrasounds*, *X-Rays*, *histology*, dan *positron emission tomography* (PET) yang masing-masing memiliki kegunaannya tersendiri. Secara tradisional, citra medis akan dipelajari oleh para ahli sebelum didiagnosis, tetapi masih terdapat keterbatasan seperti kurangnya para ahli di lapangan dan biaya konsultasi yang tinggi merupakan permasalahan tersendiri. Dengan memanfaatkan teknologi dalam bidang medis dapat menjadi sebuah solusi, yaitu dengan menggunakan *deep learning*. Dengan *deep learning* citra medis dapat dianalisis untuk membantu para ahli radiologi dan dokter dalam proses diagnosis dan pengobatan yang lebih efektif. Salah satu metode *deep learning* yang dapat dipakai dalam analisis citra medis adalah *convolutional neural network* (CNN).

CNN merupakan salah satu cara yang paling efisien untuk klasifikasi dalam *computer vision* [15]. Menurut Ansari, et. al [16], metode berbasis CNN mencapai sukses besar dalam pengenalan citra. CNN bisa mengekstrak fitur komponen dan mendapatkan informasi lebih banyak dari citra [17]. Salah satu penelitian yang menggunakan CNN dalam analisis citra medis, Kumar, et. al [18], menganalisis *Chest X-Ray* (CXR) atau *computer tomography* (CT) untuk mengklasifikasikan dan mendeteksi yang nantinya digunakan untuk diagnosis Covid-19. Qayyum, et. al [19] menjelaskan tentang sistem *content based medical image retrieval* (CBMIR) dengan menggunakan CNN yang dilatih untuk klasifikasi citra medis. Ulasan mengenai *deep learning* dalam analisis citra medis yang dilakukan oleh Shen, et. al [20] membahas tentang analisis citra dengan bantuan komputer dan menjelaskan tentang dasar-dasar *deep learning* beserta penjelasan mengenai deteksi, segmentasi, dan diagnosis medis. Dalam makalah ini, disajikan teknik analisis citra medis dengan memanfaatkan *deep learning* dengan teknik *convolutional neural network* yang mencakup beberapa metode yang populer dalam analisis citra medis, seperti klasifikasi, deteksi, segmentasi, dan peningkatan citra.


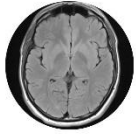
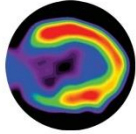
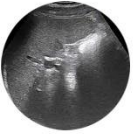


2. Metode

Convolutional Neural Network (CNN) adalah metode *deep learning* yang banyak digunakan dalam *computer vision*, seperti klasifikasi [21], deteksi [22], dan segmentasi [23]. CNN belajar mengekstrak fitur dari citra dengan mengulang pembelajaran dan kemudian menghasilkan *feature map*. Struktur CNN berisi lapisan *input*, lapisan tersembunyi dan lapisan *output*. Jenis CNN yang umum digunakan mirip dengan *multilayer perceptron* (MLP) yang mencakup dari beberapa *convolutional layer*, *pooling layer*, dan terakhir merupakan *fully connected layer* seperti pada Gambar 1.



Gambar 1. Struktur CNN

CNN dikelompokkan menjadi dua bagian besar seperti pada Gambar 1 di atas. Terdapat bagian *feature learning* dan bagian *classification*. *Feature learning* bagian untuk mengekstrak fitur penting dari sebuah *input* sedangkan *classification* yang berhubungan dengan *output* setelah melakukan proses *learning*. Dalam menganalisis citra medis menggunakan metode CNN ada tipologi modalitas pencitraan medis umum yang digunakan untuk bagian tubuh yang berbeda yang dihasilkan dalam pengaturan radiologi dan laboratorium ditunjukkan pada Gambar 2.

					
Computer Tomography	Magnetic Resonance Imaging (MRI)	Positron Emission Tomography (PET)	Ultrasound	X-Rays	Histology
<ol style="list-style-type: none"> 1. Abdomen 2. Appendix 3. Bladder 4. Brain 5. Chest 6. Kidney 7. Cervix 8. Breast 	<ol style="list-style-type: none"> 1. Neuroimaging 2. Cardiovascular 3. Liver 4. Functional 5. Oncology 6. Phase contrast 	<ol style="list-style-type: none"> 1. Cardiology 2. Infected Tissues 3. Small Animal Imaging 4. Neuroimaging 5. Oncology 6. Musculoskeletal 7. Pharmacokinetics 	<ol style="list-style-type: none"> 1. Transrectal 2. Breast 3. Doppler 4. Abdominal 5. Transabdominal 6. Cranial 7. Gallbladder 8. Spleen 	<ol style="list-style-type: none"> 1. Radiography 2. Mammography 3. Fluoroscopy 4. Contrast Radiography 5. Arthrography 6. Discography 7. Dexa Scan 	<ol style="list-style-type: none"> 1. Epithelium 2. Endothelium 3. Mesenchyme 4. Blood Cells 5. Neurons 6. Germ Cell 7. Placenta

Gambar 2. Tipologi Modalitas Citra Medis [24]

Gambar 2 merupakan beberapa contoh dari citra medis, seperti *Computer Tomography* (CT), *Magnetic Resonance Imaging* (MRI), *Positron Emission Tomography* (PET), *Ultrasounds*, *X-Rays*, dan *histology*.

Arsitektur CNN pertama, yaitu LeNet-5 yang dikembangkan oleh LeCun, et. al [1] untuk mengenali angka tulisan tangan dan berhasil mengenali pola citra input tanpa pra-pemrosesan. Namun, karena kurangnya data pelatihan dan daya komputasi yang memadai, model ini gagal dalam mengatasi masalah yang kompleks. Pada tahun 2012, Krizhevsky, et. al [25] pertama kali mengusulkan AlexNet dan meningkatkan kemampuan CNN dengan cara menambahkan beberapa lapisan atau kedalamannya. Dengan begitu secara signifikan meningkatkan akurasi pada tugas klasifikasi. AlexNet menawarkan beberapa solusi baru untuk meningkatkan kinerja dari CNN mulai dari fungsi aktivasi ReLU, *dropout*, dan *augmentation* yang kemudian banyak digunakan. Beberapa arsitektur telah dikembangkan dan ditingkatkan lebih lanjut dengan menambah lapisan yang lebih dalam seperti ResNet [26], VGGNet [27], dan GoogLeNet [28].

2.1. Convolutional Layer

Convolutional layer merupakan lapisan pertama yang menerima input citra yang dimasukkan ke dalam arsitektur. Convolutional layer digunakan untuk ekstraksi fitur dan terdiri dari filter yang membagi vektor *input* menjadi blok-blok kecil [11]. Hasil dari operasi konvolusi merupakan *feature maps* yang digunakan untuk *input layer* berikutnya. *Feature maps* merupakan hasil perkalian array dua dimensi antara filter dengan *array input* yang diterapkan beberapa kali ke lokasi berbeda dari *input array*. Dalam menghasilkan suatu *output* ada parameter yang mempengaruhi seperti, *stride* dan *zero padding*.

Stride adalah sebuah parameter yang menentukan berapa jumlah pergeseran sebuah filter. Jika nilai *stride* adalah dua, maka filter akan bergeser sebanyak dua piksel secara horizontal lalu vertikal. *Zero padding* adalah sebuah parameter untuk menentukan jumlah pixel berisi angka nol. Citra *input* akan diisi dengan angka nol di sepanjang tepi sehingga ukuran *output* sama dengan ukuran masukan asli [29]. Contoh penggunaan *zero padding* dapat dilihat pada Gambar 3 di bawah ini.

0	0	0	0	0	0	0	0
0							0
0							0
0							0
0							0
0							0
0							0
0	0	0	0	0	0	0	0

Gambar 3. Contoh penggunaan *zero padding* pada *input* citra [29]


Gambar 3 di atas merupakan penambahan *zero padding* dengan nilai 1. Ukuran asli dari *input* citra adalah 5x5 setelah ditambahkan *zero padding* ukuran citra menjadi 7x7 dengan bertujuan untuk mengekstraksi *feature* lebih banyak dan dapat meningkatkan performa dari model. *Convolutional layer* diikuti dengan *pooling layer* untuk mengurangi jumlah operasi karena jumlah parameter meningkat saat jaringan memproses lebih banyak kernel [29].

2.2. Activation Function

Fungsi aktivasi sebagai salah satu parameter penting dalam arsitektur *deep learning* yang menentukan *output*, akurasi, dan efisiensi model pelatihan [11]. Fungsi aktivasi membuat keputusan apakah akan mengaktifkan *neuron* dengan mengacu pada *input* tertentu atau tidak dengan membuat *output* yang sesuai. Ada beberapa contoh fungsi aktivasi, seperti Sigmoid, Tanh, ReLU, Leaky ReLU, Parametrized ReLU, Exponential Linear Unit, Swish, and SoftMax [30]. Fungsi aktivasi yang umum digunakan, yaitu ReLU. ReLU merupakan fungsi yang mengerjakan *thresholding* dengan nilai nol terhadap nilai piksel pada *input* citra. Fungsi aktivasi ini membuat nilai piksel yang kurang dari nol pada citra akan dijadikan nol.

2.3. Pooling Layer

Pooling layer adalah proses mereduksi *input* secara spasial atau mengurangi jumlah parameter dengan operasi *down sampling*. Dimensi dari setiap *feature map* akan berkurang tetapi menyimpan informasi yang paling penting [16]. *Pooling layer* memiliki fungsi untuk mempercepat operasi dan meningkatkan kinerja seluruh *convolutional layer* [11]. Terdapat dua metode dalam *pooling layer*, yaitu *max pooling* dan *average pooling* seperti pada Gambar 4 di bawah.



Gambar 4. *Pooling Layer*

Seperti pada Gambar 4 di atas metode *max pooling* adalah memilih nilai terbesar dari proses konvolusi sedangkan *average pooling* menjumlahkan nilai rata-rata dari hasil proses konvolusi.

2.4. Fully Connected Layer

Fully connected layer adalah struktur dasar dalam *neural network* yang merupakan sebuah lapisan di mana semua *neuron* terhubung semua. Lapisan ini biasanya diimplementasikan di akhir jaringan [31]. Lapisan ini menggunakan fungsi aktivasi *softmax* di lapisan *output* untuk tujuan klasifikasi. Fungsi aktivasi *softmax* untuk menyelesaikan *multi-class neural network learning* dan masalah klasifikasi gambar dengan sekumpulan piksel sebagai input [16]. *Output* dari *softmax* dapat mewakili distribusi sebuah kelas. *Softmax* menghitung semua probabilitas dari label dengan nilai antara 0 dan 1, jika semua dijumlah maka akan bernilai 1. Lapisan ini meringkas semua fitur yang telah diekstraksi oleh *feature extraction layer* atau dalam proses *feature learning*. Perbandingan antara *fully connected layer* dan *feature extraction layer* adalah neuron di *feature extraction layer* terhubung hanya ke daerah tertentu pada *input*. Sedangkan pada *fully connected layer* memiliki neuron secara keseluruhan yang terhubung.

2.5. Evaluasi

Ada banyak cara untuk mengevaluasi model yang sudah dibuat dengan menggunakan ukuran kinerja yang berbeda, seperti *confusion matrix*, *accuracy*, *recall*, *precision*, *sensitivity*, *specificity*, *F1 score*, dan *dice coefficient*. *Confusion matrix* memberikan keterangan antara perbandingan hasil prediksi yang dilakukan oleh model dengan hasil sebenarnya. Gambar 5 di bawah merupakan *confusion matrix*.

		Actual Class	
		Positive	Negative
Predicted Class	Positive	TP (True Positive)	FN (False Positive)
	Negative	FP (False Negative)	TN (True Negative)

Gambar 5. *Confusion Matrix*

Berikut untuk menghitung beberapa *performance metric*.

$$Accuracy = \frac{TP+TN}{TP+FN+FP+TN} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$Sensitivity = \frac{TP}{TP+FN} \quad (4)$$

$$Specificity = \frac{TN}{TN+FP} \quad (5)$$

$$F1\ Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (6)$$


$$Dice\ Coefficient = \frac{2 \times |P \cap GT|}{|P| + |GT|} \quad (7)$$

3. Hasil dan Pembahasan

3.1. Klasifikasi

Klasifikasi citra adalah salah satu bidang yang paling banyak diteliti dalam penggunaan *deep learning* dalam analisis citra medis. Tugas klasifikasi pada intinya melibatkan pemberian *input* dengan dua label

atau lebih dari sekumpulan kelas yang telah ditentukan sebelumnya. Contoh klasifikasi seperti pada Gambar 6.



Gambar 6. Contoh Penggunaan X-Ray untuk Klasifikasi [32]

Gambar 6 (a) Citra rontgen dada Covid-19, (b) Citra rontgen dada normal, (c) Citra rontgen dada pneumonia. Gambar 5 di atas merupakan contoh dataset yang digunakan untuk klasifikasi dalam Sun, et. al [32] dengan menyajikan sebuah metode berbasis *intelligent global optimization algorithm* yang berbasis pada *biogeography-based optimization* di mana secara otomatis mengoptimalkan nilai *hyperparameters* model sesuai dengan tujuan klasifikasi yang berbeda. Hong, et. al [33] mengusulkan metode klasifikasi multi kelas dari penyakit paru-paru dengan menggunakan CNN dan *Chest X-ray* sebagai *input*. Untuk meningkatkan performa, dilakukan *preprocessing* dengan *center crop* dengan tetap menjaga aspek rasio 1:1. Model yang digunakan EfficientNet B7 dan metode Multi GAP (*Global Average Pooling*). Huang, et. al [34] menjelaskan sebuah model *Convolutional Neural Network Based on Complex Networks* (CNNBCN) dengan fungsi aktivasi yang dimodifikasi untuk klasifikasi citra MR tumor otak. Marques, et. al [35] mengusulkan arsitektur EfficientNet and *10-fold stratified cross-validation* untuk diagnosis Covid-19 secara otomatis.

Hubungan antara resiko kanker dan *schizophrenia* masih didebatkan secara luas. Karena itu Kopylov, et. al [36] meneliti tentang fenotipe kanker yang berbeda, seperti payudara, ovarium, ginjal, dan prostat dan pasien dengan *schizophrenia*. Model yang digunakan adalah 1DCNN dan *augmentation*. Badža and Barjaktarovi'c [37] melakukan klasifikasi tumor otak dengan menggunakan citra MRI. Metode yang digunakan adalah CNN dengan pendekatan dua metode *10 cross validation* dan dua database lalu menguji generalisasi, melalui metode *K-Fold subject-wise* untuk database citra yang digunakan. Ramesh, et. al [38] membuat sebuah model dengan menggunakan CNN dengan tujuan dapat menggeneralisasi klasifikasi AF di seluruh modalitas EKG dan PPG. Ullah, et. al [21] memberikan gambaran tentang klasifikasi dari leukemia dengan model yang berbasis *convolutional neural network* (CNN) dengan menggunakan modul *Efficient Channel Attention* (ECA) arsitektur VGG16.


Table 1. Klasifikasi Citra Medis Menggunakan CNN

<i>Application</i>	<i>Method</i>	<i>Dataset</i>	<i>Number of images/classes</i>	<i>Accuracy</i>
Classification of Lung Diseases.	Convolutional Neural Network [33]	The U.S. National Institutes of Health (NIH Dataset) dan Soonchunhyang University Hospital (SCH Dataset)	NIH Dataset: 3 kelas, 10.000 citra. SCH Dataset: 4 kelas 51.866 citra.	96.10%
Covid-19 Detection via Chest X-ray images	Momentum Factor Biogeography	Kaggle	3 kelas, 6.939 Chest CT Images	OA LeNet-5 (MF-BBO): 91.28%

Application	Method	Dataset	Number of images/classes	Accuracy
	Convolutional Neural Network [32]			OA VGG-16 (MF-BBO): 94.37% OA ResNet-18 (MF-BBO): 92.27 95.49%
Brain Tumor Image Classification	Convolutional Neural Network Based on Complex Networks [34]	Nanfeng Hospital and General Hospital	708 Meningioma images, 1426 glioma images, and 930 pituitary tumor images	
Automated medical diagnosis of Covid-19	Convolutional Neural Network [35]	Kaggle dan GitHub	3 Kelas, Normal 500 citra, Pneumonia 504 citra, Covid-19 504 citra.	Binary Class: 99.62% Multi Class: 96.70%
Proteomics And Metabolomics for Determination of Comorbidity Between Cancer and Schizophrenia	Convolutional Neural Network [36]	-	2 Kelas, Proteome 337 citra, Metabolome 337 citra.	90% untuk membedakan patologi. 94% untuk subtype yang berbeda.
Classification of Brain Tumors	Convolutional Neural Network [37]	Nanfeng Hospital dan General Hospital	708 Meningioma images, 1426 glioma images, and 930 pituitary tumor images.	96.56%
Atrial Fibrillation Classification with Smart Wearables Using Short-Term Heart Rate Variability	Convolutional Neural Network [38]	MIT-BIH Normal Sinus Rhythm (ECG) MIT-BIH Atrial Fibrillation (ECG) MIT-BIH Arrhythmia (ECG) UMass-DB (PPG)	MIT-BIH Normal Sinus Rhythm 18 recording MIT-BIH Atrial Fibrillation 23 recording MIT-BIH Arrhythmia 48 recording	ECG: 95.50% PPG: 95.10%
Acute Lymphoblastic Leukemia Classification	Convolutional Neural Network - Efficient Channel Attention [21]	C-NMC 2019	2 Kelas: Healthy 3389 citra, Cancer 7272 citra	91.1%

3.2. Deteksi

Tugas deteksi menggabungkan proses klasifikasi dengan lokalisasi, yaitu menemukan objek yang diinginkan dalam citra. Deteksi kelainan pada citra medis adalah proses mengidentifikasi jenis penyakit tertentu. Secara tradisional, para ahli klinis mendeteksi kelainan, tetapi membutuhkan banyak usaha para ahli dan memakan waktu. Contoh dari deteksi seperti pada Gambar 7 di bawah.



Gambar 7. Contoh untuk Mendeteksi Pneumonia [39]

Gambar 7 (a) *Healthy*, (b) *Bacterial*, (c) *Viral*. Gambar 6 merupakan contoh dataset yang digunakan untuk deteksi pneumonia yang dilakukan oleh Fernandes, et. al [39] dengan menggambarkan bagaimana cara mendeteksi pneumonia dengan CNN dan optimasi *Bayesian*. Mendapatkan hasil yang menjanjikan untuk deteksi pneumonia mendapatkan akurasi sebesar 96.40%. Yao, et. al [40] mengembangkan sebuah model

untuk mendeteksi pneumonia dengan menggunakan citra *X-ray* paru-paru berdasarkan CNN - Pneumonia Yolo (PYolo). Zhou, et. al [41] membuat model untuk mendeteksi kerusakan dini pada paru-paru dengan pendekatan *computed tomography* (CT). Sriporn, et. al [42] mengevaluasi arsitektur yang populer untuk mengklasifikasikan citra, yaitu MobileNet, DenseNet-121, dan ResNet-50, dan membandingkan 7 *optimizer* agar model CNN lebih efisien. Bertujuan untuk mendeteksi penyakit paru-paru. Cha, et. al [43] mengevaluasi arsitektur ResNet-152, DenseNet121, ResNet18 untuk mendeteksi pneumonia. Setelah menggabungkan vektor fitur yang diekstraksi dari model sebelumnya lalu menerapkan *attention mechanism* untuk mendeteksi.

Dalam satu tahun terakhir dunia dilanda oleh pandemi Covid-19, dengan mendeteksi dini Covid-19 maka dapat membantu memerangi wabah. Dengan memanfaatkan citra medis berupa rontgen dada dapat digunakan sebagai deteksi dini Covid-19. Seperti yang dilakukan oleh Elbishlawi, et. al [44] menjelaskan penggunaan *convolutional neural network* untuk mendeteksi Covid-19 yang berbasis arsitektur disebut CORONA-Net. Kumar, et. al [18] mengusulkan SARS-Net yang menggabungkan *Graph Convolutional Networks* dan *Convolutional Neural Networks* untuk mendeteksi Covid-19. Pranav, et. al [45] mengevaluasi dari ketiga arsitektur untuk deteksi Covid-19, yaitu ResNet50, VGG19, dan DenseNet121. Arsitektur DenseNet121 berhasil tampil lebih baik dibandingkan dengan jaringan lainnya.

Okolo, et. al [46] mengevaluasi 11 arsitektur CNN untuk mencari arsitektur paling efisien yang terbukti lebih akurat. Dalam penelitian ini bertujuan untuk mendeteksi Covid-19 berdasarkan rontgen dada. Arsitektur terbaik adalah EfficientNetB4 dan Xception masing-masing mencapai akurasi 98.04% dan 98.00%. Awan, et. al [47] menerangkan penggunaan *deep transfer learning* (DTL) dalam *convolutional neural network* (CNN) untuk mendeteksi Covid-19, tiga arsitektur yang digunakan, yaitu InceptionV3, ResNet50, dan VGG19.

Farooq, et. al [48] mengusulkan arsitektur *convolutional neural network* dengan 9 lapisan buatan sendiri menghasilkan model yang akurat dan efisien dengan akurasi sebesar 98.5% untuk mendeteksi dini Covid-19. Penelitian lain yang dilakukan oleh Lella dan Pja [49] mendeteksi Covid-19 dengan menggunakan suara yang dihasilkan seperti suara/ucapan, batuk kering, dan nafas. Model yang diusulkan adalah menerapkan *multi-feature channels* seperti *De-noising Auto Encoder* (DAE), *Gamma-tone Frequency Cepstral Coefficients* (GFCC), dan *Improved Multi-frequency Cepstral Coefficients* (IMFCC) berhasil meningkatkan kinerja sistem untuk diagnosis penyakit Covid-19.


Table 2. Deteksi Citra Medis Menggunakan CNN

<i>Application</i>	<i>Method</i>	<i>Dataset</i>	<i>Number of images/classes</i>	<i>Accuracy</i>
Predict Lung Disease	Convolutional Neural Network [42]	National Institutes of Health Clinical Center-America's Research Hospital	1000 normal lung images and 1500 lung disease images	98.97%
Detecting Pneumonia	Convolutional Neural Network - Pneumonia Yolo (PYolo) [40]	Radiological Society of North America (RSNA)	6000 chest X-ray images	81%
Pneumonia Detection in Chest X-ray Images	Convolutional Neural Network [43]	Guangzhou Women and Children's Medical Center	2 kelas, 5.840 chest X-ray images	96.63%
Estimation For Pediatric Pneumonia Detection and Diagnosis	Bayesian Convolutional Neural Network [39]	ChestX-ray14	3.883 citra pneumonia 1.349 citra normal	96.40% for pneumonia detection 95.70% for pneumonia type classification
Diagnosing Covid-19 from X-ray Images	Convolutional Neural Network – CORONA-Net [44]	COVIDx	3 kelas, 13.962 citra	95.84%
Covid-19 Detection from Chest X-Rays	SARS-Net [18]	COVIDx	3 kelas, 13.975 citra	97.60%

Application	Method	Dataset	Number of images/classes	Accuracy
Detection and Identification of COVID -19	Convolutional Neural Network [45]	IEEE802.3 dan Covid-19 radiography	3 kelas, 6609 citra	-
Covid-19 Detection	Convolutional Neural Network [46]	Create	3 kelas, 2905 citra	98.04%
Detection of Covid-19 in Chest X-ray Images	Deep Transfer Learning (DTL) method using Convolutional Neural Network (CNN) [47]	Kaggle, Coronavirus chest x-ray images, Chest X-Ray images (Pneumonia)	2 kelas klasifikasi: 354 citra Covid-19, 354 citra Normal 3 kelas klasifikasi: 354 citra Covid-19, 354 citra Normal, 355 citra Pneumonia	2 kelas: 100% 3 kelas: InceptionV3 97.00%, ResNet50 98.55%, Vgg19 98.55%
Early Detection of Covid-19 Using Chest X-ray Images	Customized CNN [48]	Kaggle Covid-19 Radiography Database Covid-19 Chest X-ray Dataset by Joseph Paul Cohen	2 kelas, 400 citra COVID19, 400 citra normal	98.5%
Automatic diagnosis of Covid-19 disease	Multi Channeled Deep Convolutional Neural Network [49]	Cambridge University	5 kelas, 1539 audio	95.45%

3.3. Segmentasi

Semantic segmentation adalah tugas untuk membagi citra menjadi beberapa bagian yang bermakna semantik, dan untuk mengklasifikasikan setiap bagian ke dalam salah satu kelas yang telah ditentukan sebelumnya. Contoh dari segmentasi dapat dilihat pada Gambar 8 di bawah.



Gambar 8. Contoh Segmentasi [14]

Gambar 8 (a) Citra CT original, (b) Hasil segmentasi, (c) Hasil segmentasi yang di usul. Gambar 7 di atas hasil penelitian Meng, et. al [14]. Menjelaskan bahwa segmentasi untuk tumor hati dan hati merupakan cabang penting dari diagnosis citra medis. Dengan menggunakan dua tahap untuk segmentasi hati dan tumor, yaitu lokalisasi hati di mana jaringan membagi wilayah hati selanjutnya pada tahap segmentasi tumor ini berdasarkan hasil segmentasi hati di mana model CNN dirancang untuk mengidentifikasi tumor hati secara akurat dengan menggunakan fitur 2D dan fitur 3D. Model juga menerapkan *attention mechanism* untuk meningkatkan kinerja segmentasi tumor. Model yang diusulkan diuji dengan menggunakan dataset public, yaitu *Liver Tumor Segmentation Challenge* (LiTS). Menunjukkan hasil *dice coefficient* untuk segmentasi hati adalah 0.967, dan *dice coefficient* untuk segmentasi tumor adalah 0.725.

Baldeon-Calisto and Lai-Yuen [50] memberikan gambaran tentang segmentasi citra medis yang mampu secara otomatis beradaptasi dengan kumpulan data baru sambil meminimalkan ukuran jaringan. Arsitektur yang diusulkan adalah *Multi-objective Adaptive Convolutional Neural Network* (AdaResU-Net) dengan menggunakan *hyperparameter* yang dipilih dari algoritma *evolutioner multiobjektif* (MEA)

mencapai kinerja segmentasi citra medis yang lebih baik dengan lebih sedikit 30% jumlah parameter yang dapat dilatih. Boulares, et. al [51] menjelaskan bagaimana sinyal *Phonocardiogram* (PCG) untuk membantu dalam diagnosis awal berbagai penyakit jantung. Model yang diusulkan menggunakan 4 tahap *preprocessing*, yaitu *noise filtering*, *automatic heart cycle segmentation*, *mel-frequency spectrum images*, dan *segment selection by clustering*. Dengan dataset PASCAL model mendapatkan akurasi sebesar 87% sedangkan untuk dataset PhysioNet model mencapai hasil yang sangat baik dalam akurasi, yaitu sebesar 97%.

Bonechi, et. al [23] menyajikan bahwa segmentasi otomatis aorta sangat membantu dalam dunia medis, memungkinkan diagnosis yang lebih cepat. Dengan menggunakan CNN dan dua arsitektur yang berbeda, U-Net dan LinkNet dengan *encoder* yang berbeda, ResNet 34 dan Inception ResNetV2. Jalali, et. al [52] menggambarkan bahwa segmentasi citra CT paru-paru adalah proses kunci dalam banyak aplikasi seperti deteksi kanker paru-paru. Mengusulkan sebuah arsitektur U-Net yang dimodifikasi di mana *encoder*-nya diganti dengan arsitektur *pre-trained* ResNet-34 (Res BCDU-Net). Dalam arsitektur juga digunakan BConvLSTM (*Bidirectional Convolutional Long Short-term Memory*) mendapatkan *dice coefficient* sebesar 97.31%.


Dayananda, et. al [53] mengusulkan ekstraksi fitur *multi-scale* berbasis *global attention-based* dengan menggunakan arsitektur U-SegNet untuk mencapai segmentasi jaringan otak dari *magnetic resonance image* (MRI). Metode yang diusulkan menyempurnakan ekstraksi fitur dan meningkatkan kekuatan representasi dari CNN dengan begitu hasil yang didapatkan untuk akurasi segmentasi sebesar 94.81% untuk *cerebrospinal fluid* (CSF), 95,54% untuk *gray matter* (GM), dan 96,33% untuk *white matter* (WM). Dengan begitu model yang diusulkan dapat mencapai segmentasi otomatis yang handal dan tepat dari citra MRI otak. An and Liu [54] menyajikan solusi untuk algoritma segmentasi citra medis berdasarkan mekanisme *feedback* pada CNN. Metode yang diusulkan mendapatkan hasil segmentasi citra medis yang akurat dan memiliki kemampuan segmentasi adaptif yang sangat tinggi untuk berbagai citra medis.

Banerjee, et. al [55], pendekatan berbasis CNN dengan arsitektur *Light-convolution Dense Selection U-Net* (LDS U-Net) untuk mengidentifikasi dan segmentasi fitur tulang lateral dari gambar *ultrasound* tulang belakang. Model dibandingkan dengan Basic U-Net, Attention U-Net, dan MultiResUNet hasil penelitian menunjukkan model yang diusulkan, yaitu LDS U-Net memberikan kinerja segmentasi yang lebih baik dibandingkan dengan model lainnya. LDS U-Net memerlukan jumlah parameter yang lebih sedikit dan memori yang lebih sedikit, cocok untuk proses penyaringan scoliosis tanpa biaya komputasi yang tinggi.

Jha, et. al [56] dalam meningkatkan kinerja U-Net pada tugas segmentasi maka diusulkan arsitektur baru, yaitu DoubleU-Net. Arsitektur ini merupakan kombinasi dari dua arsitektur U-Net yang ditumpuk satu sama lain. U-Net pertama menggunakan VGG-19 yang telah dilatih sebelumnya sebagai *encoder*, yang telah mempelajari fitur dari ImageNet. Untuk menghasilkan lebih banyak informasi semantik secara efisien maka menambahkan U-Net lain di bagian bawah dan mengadopsi *Atrous Spatial Pyramid Pooling* (ASPP). Hasil yang didapatkan menunjukkan bahwa DoubleU-Net dapat digunakan sebagai dasar yang kuat untuk segmentasi citra medis.

3.4. Image Enhancement

Image Enhancement adalah proses peningkatan kualitas gambar melalui berbagai proses seperti *denoising*, *super-resolusi*, dan peningkatan kontras. Dengan meningkatkan kualitas gambar, tugas seperti klasifikasi, deteksi, dan segmentasi dapat diselesaikan dengan lebih akurat. Contoh dari *contrast enhancement* dapat dilihat pada Gambar 9 di bawah.



Gambar 9. Hasil *Contrast Enhancement* [57]

Gambar 9 merupakan penelitian oleh Wu, et. al [57] yang menjelaskan bagaimana *convolutional neural network* (CNN) dapat meningkatkan gambar MR dengan tambahan metode *contrast enhancement* (CE). Dengan mengadopsi strategi *preprocessing* dan menggunakan U-Net sebagai segmentasi. Dietze, et. al [58] mengusulkan *convolutional neural network* (CNN) digabungkan dengan metode *fast filtered back projection* (FBP) untuk meningkatkan kualitas gambar yang dapat memberikan konstruksi ulang SPECT. Gao, et. al [59] menyajikan sebuah solusi untuk menghilangkan *noise* yang ada pada *digital breast tomosynthesis* (DBT) agar tidak mengaburkan tanda-tanda halus kanker payudara seperti *microcalcifications* (MCs). Ryu, et. al [60] mendemonstrasikan sebuah model baru yang disebut *DeepRegularizer* untuk meningkatkan resolusi dari 3D RI *maps* dalam ODT. Gondara [61] menunjukkan bahwa penggunaan data pelatihan kecil tetap bisa mendapatkan kinerja *denoising* yang baik. Dengan menggunakan *denoising autoencoder* yang dibuat dengan lapisan *convolutional* dapat digunakan untuk *denoising* citra medis yang efisien. Jung, et. al [62] memperkenalkan sebuah metode yang dapat meningkatkan citra *magnetic resonance* (MR) untuk memvisualisasikan *perivascular spaces* (PVS). Hasil yang didapat menunjukkan bahwa DCDenseNet dengan 6 *block* menunjukkan kinerja yang terbaik dibandingkan DCDenseNet dengan 4 *block*. Jifara, et. al [63] merancang *feed forward denoising convolutional neural network* dengan menggunakan data yang kecil serta pendekatan *residual* untuk pembelajaran dan normalisasi *batch*. Hasil menunjukkan kinerja model *denoising* citra medis yang diusulkan lebih baik dari pada teknik *denoising* citra medis yang ada baik dalam *peak signal to noise ratio* (PSNR) dan *structural similarity* (SSIM).

4. Kesimpulan

Dalam beberapa tahun terakhir, penggunaan *deep learning* untuk analisis citra medis telah berkembang pesat. Dengan peningkatan daya komputasi serta arsitektur *deep learning* yang lebih baik diharapkan mendapat kinerja yang lebih tinggi dan akurat. Namun, sebelum sistem otomatis yang dibuat untuk mengerjakan berbagai tugas dalam bidang medis, peneliti mengalami beberapa tantangan. Seperti kurangnya data dan tidak seimbang data, masalah ini sering menjadi hambatan dalam penelitian. Solusi yang cocok untuk masalah tersebut adalah *augmentation* data. Dengan metode *deep learning* berbasis *convolutional neural network* para peneliti terdahulu telah mendapatkan hasil yang memuaskan di semua sub bidang analisis citra medis, seperti klasifikasi, deteksi, segmentasi, dan peningkatan citra. Dengan keberhasilan ini para peneliti menemukan sebuah model yang dapat mendiagnosis dan mendeteksi secara

otomatis, yang dapat membantu para ahli di bidangnya dan menunjukkan bahwa teknologi *deep learning* akan sangat bermanfaat bagi kemajuan analisis citra medis.

Referensi

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [2] S. Hossain, S. Umer, V. Asari, and R. K. Rout, "A Unified Framework of Deep Learning-Based Facial Expression Recognition System for Diversified Applications," *Appl. Sci.*, vol. 11, no. 19, p. 9174, Oct. 2021, doi: 10.3390/app11199174.
- [3] A. Alsobhani, H. M. A. ALabboodi, and H. Mahdi, "Speech Recognition using Convolution Deep Neural Networks," *J. Phys. Conf. Ser.*, vol. 1973, no. 1, p. 012166, Aug. 2021, doi: 10.1088/1742-6596/1973/1/012166.
- [4] P. M. Nadkarni, L. Ohno-Machado, and W. W. Chapman, "Natural language processing: an introduction," *J. Am. Med. Informatics Assoc.*, vol. 18, no. 5, pp. 544–551, Sep. 2011, doi: 10.1136/amiajnl-2011-000464.
- [5] H. Greenspan, B. van Ginneken, and R. M. Summers, "Guest Editorial Deep Learning in Medical Imaging: Overview and Future Promise of an Exciting New Technique," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1153–1159, May 2016, doi: 10.1109/TMI.2016.2553401.
- [6] L. Aguiar-Castillo, A. Clavijo-Rodriguez, L. Hernández-López, P. De Saa-Pérez, and R. Pérez-Jiménez, "Gamification and deep learning approaches in higher education," *J. Hosp. Leis. Sport Tour. Educ.*, vol. 29, no. xxxx, p. 100290, Nov. 2021, doi: 10.1016/j.jhlste.2020.100290.
- [7] M. Stevenson, C. Mues, and C. Bravo, "The value of text for small business default prediction: A Deep Learning approach," *Eur. J. Oper. Res.*, vol. 295, no. 2, pp. 758–771, Dec. 2021, doi: 10.1016/j.ejor.2021.03.008.
- [8] J. Sun, X. He, X. Ge, X. Wu, J. Shen, and Y. Song, "Detection of Key Organs in Tomato Based on Deep Migration Learning in a Complex Background," *Agriculture*, vol. 8, no. 12, p. 196, Dec. 2018, doi: 10.3390/agriculture8120196.
- [9] J. Xu *et al.*, "Cutting Pattern Identification for Coal Mining Shearer through Sound Signals Based on a Convolutional Neural Network," *Symmetry (Basel)*, vol. 10, no. 12, p. 736, Dec. 2018, doi: 10.3390/sym10120736.
- [10] T. Lin, "Deep Learning for IoT," in *2020 IEEE 39th International Performance Computing and Communications Conference (IPCCC)*, Nov. 2020, pp. 1–4, doi: 10.1109/IPCCC50635.2020.9391558.
- [11] N. Q. Do, A. Selamat, O. Krejcar, T. Yokoi, and H. Fujita, "Phishing Webpage Classification via Deep Learning-Based Algorithms: An Empirical Study," *Appl. Sci.*, vol. 11, no. 19, p. 9210, Oct. 2021, doi: 10.3390/app11199210.
- [12] A. Anand, S. Rani, D. Anand, H. M. Aljahdali, and D. Kerr, "An Efficient CNN-Based Deep Learning Model to Detect Malware Attacks (CNN-DMA) in 5G-IoT Healthcare Applications," *Sensors*, vol. 21, no. 19, p. 6346, Sep. 2021, doi: 10.3390/s21196346.
- [13] P. Hewage, M. Trovati, E. Pereira, and A. Behera, "Deep learning - based effective fine - grained weather forecasting model," *Pattern Anal. Appl.*, vol. 24, no. 1, pp. 343–366, 2021, doi: 10.1007/s10044-020-00898-1.
- [14] L. Meng, Q. Zhang, and S. Bu, "Two-Stage Liver and Tumor Segmentation Algorithm Based on Convolutional Neural Network," *Diagnostics*, vol. 11, no. 10, p. 1806, Sep. 2021, doi: 10.3390/diagnostics11101806.
- [15] L. Chipindu, W. Mupangwa, J. Mtsilizah, I. Nyagumbo, and M. Zaman-Allah, "Maize Kernel Abortion Recognition and Classification Using Binary Classification Machine Learning Algorithms and Deep Convolutional Neural Networks," *AI*, vol. 1, no. 3, pp. 361–375, Aug. 2020, doi:

- 10.3390/ai1030024.
- [16] M. F. Ansari, P. Kasprowski, and M. Obetkal, "Gaze Tracking Using an Unmodified Web Camera and Convolutional Neural Network," *Appl. Sci.*, vol. 11, no. 19, p. 9068, Sep. 2021, doi: 10.3390/app11199068.
- [17] H. Li, J. Hu, J. Yu, N. Yu, and Q. Wu, "UFaceNet: Research on Multi-Task Face Recognition Algorithm Based on CNN," *Algorithms*, vol. 14, no. 9, p. 268, Sep. 2021, doi: 10.3390/a14090268.
- [18] A. Kumar, A. R. Tripathi, S. C. Satapathy, and Y.-D. Zhang, "SARS-Net: Covid-19 detection from chest x-rays by combining graph convolutional network and convolutional neural network," *Pattern Recognit.*, vol. 122, p. 108255, Feb. 2022, doi: 10.1016/j.patcog.2021.108255.
- [19] A. Qayyum, S. M. Anwar, M. Awais, and M. Majid, "Medical image retrieval using deep convolutional neural network," *Neurocomputing*, vol. 266, pp. 8–20, Nov. 2017, doi: 10.1016/j.neucom.2017.05.025.
- [20] D. Shen, G. Wu, and H.-I. Suk, "Deep Learning in Medical Image Analysis," *Annu. Rev. Biomed. Eng.*, vol. 19, no. 1, pp. 221–248, Jun. 2017, doi: 10.1146/annurev-bioeng-071516-044442.
- [21] M. Zakir Ullah *et al.*, "An Attention-Based Convolutional Neural Network for Acute Lymphoblastic Leukemia Classification," *Appl. Sci.*, vol. 11, no. 22, p. 10662, Nov. 2021, doi: 10.3390/app112210662.
- [22] G. Ackall, M. Elmzoudi, R. Yuan, and C. Chen, "An Exploration into the Detection of Covid-19 from Chest X-ray Scans Using the xRGM-NET Convolutional Neural Network," *Technologies*, vol. 9, no. 4, p. 98, Dec. 2021, doi: 10.3390/technologies9040098.
- [23] S. Bonechi *et al.*, "Segmentation of Aorta 3D CT Images Based on 2D Convolutional Neural Networks," *Electronics*, vol. 10, no. 20, p. 2559, Oct. 2021, doi: 10.3390/electronics10202559.
- [24] S. M. Anwar, M. Majid, A. Qayyum, M. Awais, M. Alnowami, and M. K. Khan, "Medical Image Analysis using Convolutional Neural Networks: A Review," *J. Med. Syst.*, vol. 42, no. 11, p. 226, Nov. 2018, doi: 10.1007/s10916-018-1088-1.
- [25] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Neural Inf. Process. Syst. Conf.*, 2012.
- [26] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," 2016, doi: 10.1002/chin.200650130.
- [27] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, Sep. 2014, [Online]. Available: <http://arxiv.org/abs/1409.1556>.
- [28] C. Szegedy *et al.*, "Going Deeper with Convolutions," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 07-12-June, pp. 1–9, Sep. 2014, doi: 10.1109/CVPR.2015.7298594.
- [29] E. A. Moscoso Alcantara, M. D. Bong, and T. Saito, "Structural Response Prediction for Damage Identification Using Wavelet Spectra in Convolutional Neural Network," *Sensors*, vol. 21, no. 20, p. 6795, Oct. 2021, doi: 10.3390/s21206795.
- [30] S. Sharma, S. Sharma, and A. Athaiya, "ACTIVATION FUNCTIONS IN NEURAL NETWORKS," *Int. J. Eng. Appl. Sci. Technol.*, vol. 04, no. 12, pp. 310–316, May 2020, doi: 10.33564/IJEAST.2020.v04i12.054.
- [31] S. Liu, H. Ji, and M. C. Wang, "Nonpooling Convolutional Neural Network Forecasting for Seasonal Time Series With Trends," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 31, no. 8, pp. 2879–2888, Aug. 2020, doi: 10.1109/TNNLS.2019.2934110.
- [32] J. Sun, X. Li, C. Tang, S. H. Wang, and Y. D. Zhang, "MFBCNNC: Momentum factor biogeography convolutional neural network for Covid-19 detection via chest X-ray images[Formula presented]," *Knowledge-Based Syst.*, vol. 232, p. 107494, 2021, doi: 10.1016/j.knosys.2021.107494.
- [33] M. Hong, B. Rim, H. Lee, H. Jang, J. Oh, and S. Choi, "Multi-Class Classification of Lung Diseases Using CNN Models," *Appl. Sci.*, vol. 11, no. 19, p. 9289, Oct. 2021, doi: 10.3390/app11199289.

- [34] Z. Huang *et al.*, “Convolutional Neural Network Based on Complex Networks for Brain Tumor Image Classification With a Modified Activation Function,” *IEEE Access*, vol. 8, pp. 89281–89290, 2020, doi: 10.1109/ACCESS.2020.2993618.
- [35] G. Marques, D. Agarwal, and I. de la Torre Díez, “Automated medical diagnosis of Covid-19 through EfficientNet convolutional neural network,” *Appl. Soft Comput.*, vol. 96, p. 106691, Nov. 2020, doi: 10.1016/j.asoc.2020.106691.
- [36] A. T. Kopylov *et al.*, “Convolutional neural network in proteomics and metabolomics for determination of comorbidity between cancer and schizophrenia,” *J. Biomed. Inform.*, vol. 122, p. 103890, Oct. 2021, doi: 10.1016/j.jbi.2021.103890.
- [37] M. M. Badža and M. Č. Barjaktarović, “Classification of Brain Tumors from MRI Images Using a Convolutional Neural Network,” *Appl. Sci.*, vol. 10, no. 6, p. 1999, Mar. 2020, doi: 10.3390/app10061999.
- [38] J. Ramesh, Z. Solatidehkordi, R. Aburukba, and A. Sagahyoon, “Atrial Fibrillation Classification with Smart Wearables Using Short-Term Heart Rate Variability and Deep Convolutional Neural Networks,” *Sensors*, vol. 21, no. 21, p. 7233, Oct. 2021, doi: 10.3390/s21217233.
- [39] V. Fernandes, G. B. Junior, A. C. de Paiva, A. C. Silva, and M. Gattass, “Bayesian convolutional neural network estimation for pediatric pneumonia detection and diagnosis,” *Comput. Methods Programs Biomed.*, vol. 208, p. 106259, 2021, doi: 10.1016/j.cmpb.2021.106259.
- [40] S. Yao, Y. Chen, X. Tian, R. Jiang, and S. Ma, “An Improved Algorithm for Detecting Pneumonia Based on YOLOv3,” *Appl. Sci.*, vol. 10, no. 5, p. 1818, Mar. 2020, doi: 10.3390/app10051818.
- [41] Y. Zhou, Y. Lu, and Z. Pei, “Accurate diagnosis of early lung cancer based on the convolutional neural network model of the embedded medical system,” *Microprocess. Microsyst.*, vol. 81, no. December 2020, p. 103754, 2021, doi: 10.1016/j.micpro.2020.103754.
- [42] K. Sriporn, C.-F. Tsai, C.-E. Tsai, and P. Wang, “Analyzing Lung Disease Using Highly Effective Deep Learning Techniques,” *Healthcare*, vol. 8, no. 2, p. 107, Apr. 2020, doi: 10.3390/healthcare8020107.
- [43] S.-M. Cha, S.-S. Lee, and B. Ko, “Attention-Based Transfer Learning for Efficient Pneumonia Detection in Chest X-ray Images,” *Appl. Sci.*, vol. 11, no. 3, p. 1242, Jan. 2021, doi: 10.3390/app11031242.
- [44] S. Elbishlawi, M. H. Abdelpakey, M. S. Shehata, and M. M. Mohamed, “CORONA-Net: Diagnosing Covid-19 from X-ray Images Using Re-Initialization and Classification Networks,” *J. Imaging*, vol. 7, no. 5, p. 81, Apr. 2021, doi: 10.3390/jimaging7050081.
- [45] J. V. Pranav, R. Anand, T. Shanthi, K. Manju, S. Veni, and S. Nagarjun, “Detection and identification of COVID -19 based on chest medical image by using convolutional neural networks,” *Int. J. Intell. Networks*, vol. 1, no. November, pp. 112–118, 2020, doi: 10.1016/j.ijin.2020.12.002.
- [46] G. I. Okolo, S. Katsigiannis, T. Althobaiti, and N. Ramzan, “On the Use of Deep Learning for Imaging-Based Covid-19 Detection Using Chest X-rays,” *Sensors*, vol. 21, no. 17, p. 5702, Aug. 2021, doi: 10.3390/s21175702.
- [47] M. J. Awan, M. H. Bilal, A. Yasin, H. Nobanee, N. S. Khan, and A. M. Zain, “Detection of covid-19 in chest x-ray images: A big data enabled deep learning approach,” *Int. J. Environ. Res. Public Health*, vol. 18, no. 19, 2021, doi: 10.3390/ijerph181910147.
- [48] M. S. Farooq *et al.*, “An Effective Convolutional Neural Network Model for the Early Detection of Covid-19 Using Chest X-ray Images,” *Appl. Sci.*, vol. 11, no. 21, p. 10301, Nov. 2021, doi: 10.3390/app112110301.
- [49] K. K. Lella and A. Pja, “Automatic diagnosis of Covid-19 disease using deep convolutional neural network with multi-feature channel from respiratory sound data: Cough, voice, and breath,” *Alexandria Eng. J.*, vol. 61, no. 2, pp. 1319–1334, 2022, doi: 10.1016/j.aej.2021.06.024.
- [50] M. Baldeon-Calisto and S. K. Lai-Yuen, “AdaResU-Net: Multiobjective adaptive convolutional

- neural network for medical image segmentation,” *Neurocomputing*, vol. 392, no. xxxx, pp. 325–340, Jun. 2020, doi: 10.1016/j.neucom.2019.01.110.
- [51] M. Boulares, R. Alotaibi, A. AlMansour, and A. Barnawi, “Cardiovascular Disease Recognition Based on Heartbeat Segmentation and Selection Process,” *Int. J. Environ. Res. Public Health*, vol. 18, no. 20, p. 10952, Oct. 2021, doi: 10.3390/ijerph182010952.
- [52] Y. Jalali, M. Fateh, M. Rezvani, V. Abolghasemi, and M. H. Anisi, “ResBCDU-Net: A Deep Learning Framework for Lung CT Image Segmentation,” *Sensors*, vol. 21, no. 1, p. 268, Jan. 2021, doi: 10.3390/s21010268.
- [53] C. Dayananda, J. Choi, and B. Lee, “Multi-Scale Squeeze U-SegNet with Multi Global Attention for Brain MRI Segmentation,” *Sensors*, vol. 21, no. 10, p. 3363, May 2021, doi: 10.3390/s21103363.
- [54] A. Feng-Ping and L. Zhi-Wen, “Medical image segmentation algorithm based on feedback mechanism convolutional neural network,” *Biomed. Signal Process. Control*, vol. 53, p. 101589, Aug. 2019, doi: 10.1016/j.bspc.2019.101589.
- [55] S. Banerjee *et al.*, “Light-Convolution Dense Selection U-Net (LDS U-Net) for Ultrasound Lateral Bony Feature Segmentation,” *Appl. Sci.*, vol. 11, no. 21, p. 10180, Oct. 2021, doi: 10.3390/app112110180.
- [56] D. Jha, M. A. Riegler, D. Johansen, P. Halvorsen, and H. D. Johansen, “DoubleU-Net: A Deep Convolutional Neural Network for Medical Image Segmentation,” in *2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS)*, Jul. 2020, pp. 558–564, doi: 10.1109/CBMS49503.2020.00111.
- [57] H.-T. Wu, K. Zheng, Q. Huang, and J. Hu, “Contrast Enhancement of Multiple Tissues in MR Brain Images With Reversibility,” *IEEE Signal Process. Lett.*, vol. 28, pp. 160–164, 2021, doi: 10.1109/LSP.2020.3048840.
- [58] M. M. A. Dietze, W. Branderhorst, B. Kunnen, M. A. Viergever, and H. W. A. M. de Jong, “Accelerated SPECT image reconstruction with FBP and an image enhancement convolutional neural network,” *EJNMMI Phys.*, vol. 6, no. 1, p. 14, Dec. 2019, doi: 10.1186/s40658-019-0252-0.
- [59] M. Gao, J. A. Fessler, and H.-P. Chan, “Deep Convolutional Neural Network With Adversarial Training for Denoising Digital Breast Tomosynthesis Images,” *IEEE Trans. Med. Imaging*, vol. 40, no. 7, pp. 1805–1816, Jul. 2021, doi: 10.1109/TMI.2021.3066896.
- [60] D. Ryu *et al.*, “DeepRegularizer: Rapid Resolution Enhancement of Tomographic Imaging Using Deep Learning,” *IEEE Trans. Med. Imaging*, vol. 40, no. 5, pp. 1508–1518, May 2021, doi: 10.1109/TMI.2021.3058373.
- [61] L. Gondara, “Medical Image Denoising Using Convolutional Denoising Autoencoders,” in *2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW)*, Dec. 2016, vol. 0, pp. 241–246, doi: 10.1109/ICDMW.2016.0041.
- [62] E. Jung, P. Chikontwe, X. Zong, W. Lin, D. Shen, and S. H. Park, “Enhancement of Perivascular Spaces Using Densely Connected Deep Convolutional Neural Network,” *IEEE Access*, vol. 7, pp. 18382–18391, 2019, doi: 10.1109/ACCESS.2019.2896911.
- [63] W. Jifara, F. Jiang, S. Rho, M. Cheng, and S. Liu, “Medical image denoising using convolutional neural network: a residual learning approach,” *J. Supercomput.*, vol. 75, no. 2, pp. 704–718, Feb. 2019, doi: 10.1007/s11227-017-2080-0.