

IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK UNTUK MENDETEKSI PENYAKIT GINJAL

IMPLEMENTATION OF CONVOLUTIONAL NEURAL NETWORK FOR DETECTING KIDNEY DISEASE

Fahri Aulia Alfarisi Harahap, Ronaldo Mardianson Sinaga, Khusnul Arifin, Kana Saputra S

^[1] Prodi Ilmu Komputer, Fakultas Ilmu Pengetahuan Alam, Universitas Negeri Medan
Jl. Wiliam Iskandar / Pasar V, Medan, Sumatera Utara, INDONESIA

Email: fahriauliaalfarisiharahap07@gmail.com, ronaldomardianson@gmail.com, khusnularifin42@mhs.unimed.ac.id, kanasaputras@unimed.ac.id

Abstract

There are several types of kidney disease, such as kidney cancer, tumors, etc. Kidney disease can be detected early, to find out what type of disease the patient has. In the world of artificial intelligence, there is a term called Convolutional Neural Network (CNN) which is often used in image data processing. CNN is a category of artificial neural network which is effective in performing image recognition and classification of image data. The purpose of this research is to find out how to apply the CNN algorithm in detecting kidney disease based on existing image data. This research was developed using the Python programming language and will be implemented into a web-based system. The results obtained from this research are the formation of a web-based system, which this website can be used to detect types of kidney disease based on the input images performed. This kidney disease classification website has been successfully created using the Flask Framework with the API from Google Colab which produces the h5 model and Visual Studio Code. Websites can be run on all types of computer operating systems. Image training data using a CNN algorithm derived from 9334 data trains and 3110 data validations. In this case, 4 classes of data image are used, namely cyst kidney data, normal kidney data, tumor kidney data and stone kidney data. It was found that the accuracy of the f1 score was 68%.

Keywords: Convolutional Neural Network, Kidney Disease, Artificial Neural Network

1. PENDAHULUAN

Ginjal merupakan salah satu organ tubuh manusia yang berada di bagian bawah tulang rusuk belakang tubuh manusia. Walaupun ukurannya hanya satu kepalan tangan, ginjal merupakan organ tubuh yang sangat penting. Fungsi utama dari ginjal dalam tubuh adalah untuk membersihkan darah dari senyawa-senyawa beracun pada tubuh sebelum yang akhirnya akan dialirkan ke seluruh tubuh. Setelah itu, senyawa-senyawa beracun tersebut akan dibuang melalui urin. ginjal juga berperan menghasilkan berbagai hormon yang dapat memproduksi sel darah merah *eritropoietin* dan vitamin D untuk menjaga kesehatan tulang. Sel darah merah *eritropoietin* juga berfungsi untuk mengatur tekanan darah pada tubuh manusia.

Seperti organ yang ada didalam tubuh yang lain, ginjal juga bisa mengalami kanker. Kanker ginjal adalah penyebab kematian paling umum ke-16 di dunia. Penyakit lainnya yang dapat terjadi pada ginjal adalah tumor ginjal. Tumor ginjal merupakan tumor *urogenitalia* nomor tiga terbanyak setelah tumor

prostat dan tumor kandung kemih. Tumor ginjal dapat berasal dari tumor primer di ginjal atau pun merupakan tumor sekunder yang berasal dari metastasis keganasan di tempat lain. Statistik data menunjukkan bahwa insiden kanker ginjal dua kali lebih banyak dialami oleh pria dibandingkan oleh wanita dan 59% kasus kanker ginjal terjadi di negara-negara berkembang. Untuk tingkat tertinggi terlihat di Amerika Utara dan Eropa dan terendah terlihat di Asia dan Afrika [1].

Deep learning merupakan salah satu cabang dari *artificial intelligence*. Model *deep learning* dapat mempelajari komputasinya sendiri dengan menggunakan otaknya sendiri. *Deep learning* dirancang untuk terus menganalisis dan mempelajari data layaknya otak pada manusia dalam mengambil keputusan. Agar kemampuan deep learning semakin pintar, maka deep learning menggunakan algoritma *Artificial Neural Network* (ANN) yang terpisah dari jaringan biologis otak manusia [2].

Salah satu jenis *neural network* yang biasa digunakan pada data citra adalah *Convolutional Neural*

Network (CNN). Berdasarkan dalamnya tingkat jaringan dari maka *Convolutional Neural Network* termasuk kedalam jenis *deep neural network* dan sering digunakan dalam data citra. Ada dua metode yang dimiliki oleh *Convolutional Neural Network*, yaitu klasifikasi menggunakan *feedforward* dan tahap pembelajaran menggunakan *backpropagation* [2].

Pada klasifikasi data citra, *Convolutional Neural Network* mendapat inputan data citra untuk diproses ke dalam model dan diklasifikasi ke kategori yang sudah ditentukan. Terdapat perbedaan antara *Convolutional Neural Network* dan *Artificial Neural Network*, yaitu pada arsitektur tambahan di *Convolutional Neural Network* yang dioptimalkan untuk fitur yang ada pada masukan data citra. Ada beberapa komponen utama yang ada dalam model *Convolutional Neural Network* yaitu adalah *convolutional layer*, *pooling layer*, *fully connected layer* dan *dropout*.

2. TINJAUAN PUSTAKA


2.1 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah kategori dari JST (Jaringan Syaraf Tiruan) yang efektif dalam melakukan pengenalan citra dan klasifikasi data citra. Pada operasi matrix pengolahan citra, operasi diterapkan kepada matrix gambar (Dalam bentuk RGB). Operasi melibatkan mengalikan nilai-nilai sel yang sesuai dengan baris dan kolom tertentu, dari matriks gambar, dengan nilai sel yang sesuai dalam matriks filter [3].

Algoritma *Convolutional Neural Network* berdasarkan pada proses biologis konektivitas antara neuron menyerupai organisasi korteks visual hewan. *Convolutional Neural Network* menggunakan praproses yang lebih sedikit dibandingkan dengan algoritma klasifikasi citra lain. *Convolutional Neural Network* mempelajari filter yang dalam algoritma gambar biasa. *Convolutional Neural Network* sudah banyak digunakan dalam aplikasi pengenalan gambar dan video, sistem pemberi rekomendasi, dan klasifikasi gambar [4].

Secara umum tahapan klasifikasi citra di algoritma *Convolutional Neural Network* dibagi menjadi dua bagian besar yaitu *feature extractor* dan *classification/fully connected (ANN)*. Dimana tahap *feature extractor* berperan melakukan ekstraksi dari sebuah citra (image) menjadi sebuah fitur berupa angka-angka yang akan merepresentasikan citra tersebut. Input berupa citra dan output berupa *features*. Selanjutnya *features* yang dihasilkan dari

tahap *feature extractor* ini masih berbentuk array multidimensi, sehingga sebelum masuk sebagai input ke tahap *classification/fully connected (ANN)* untuk dilakukan klasifikasi, perlu di-flatten terlebih dahulu yaitu mengubah bentuk array multidimensi tersebut kedalam sebuah vector (array satu dimensi) [5].



Gambar 1. Tahapan Klasifikasi Citra Pada CNN

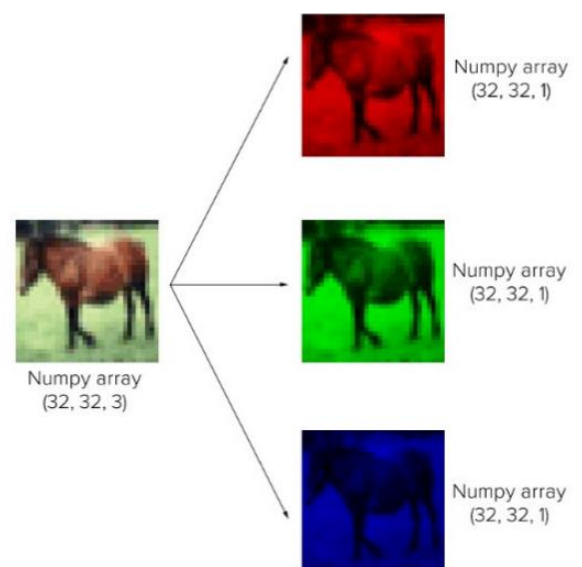
2.2 Cara Kerja Convolutional Neural Network

Secara umum arsitektur *Convolutional Neural Network* terdiri dari beberapa layers, dimulai dari *Input Layer*, *Convolutional Layer*, Fungsi Aktivasi ReLU, *Pooling Layer*, *Flatten Layer*, *Fully Connected Layer (ANN)*, Fungsi Aktivasi Softmax dan *Dropout*. Masing-masing dari layer tersebut memiliki perannya tersendiri dalam klasifikasi citra [5].

Penjelasan mengenai cara kerja *Convolutional Neural Network*:

a. Input Layer


Input layer adalah mewakili data citra inputan ke dalam model *Convolutional Neural Network*. Sebagai contoh data citra yang digunakan sebagai input berukuran 32x32 piksel dan data citra tersebut berjenis RGB (*Red, Green, Blue*), maka citra inputan ini berupa array multidimensi dengan ukuran 32x32x3, (angka 3 adalah jumlah *channel* yaitu *Red, Green, Blue*).



Gambar 2. Contoh Citra Input Layer dengan ukuran 32 x 32

b. Convolutional Layer


Convolutional Layer adalah fondasi dari Convolutional Neural Network, yaitu berupa filter atau kernel yang pada awalnya memiliki bobot acak, dan bobot ini akan diperbarui saat melakukan training. Filter ini akan digeser dan dikalikan keseluruhan bagian data citra, bergerak dari sudut kiri ke atas ke kanan bawah. Tujuan Convolutional layer adalah untuk melakukan ekstraksi fitur dari citra input seperti tepi, sudut, tekstur. Output dari proses ini biasanya disebut *feature map*.



Gambar 3. Cara Kerja Convolutional Layer

c. Fungsi Aktivasi: ReLU


Fungsi Aktivasi ReLU atau Rectified Linear Unit dipakai setelah melakukan proses konvolusi atau sebelum melakukan pooling dan dipakai di setiap node di hidden layer. ReLU merupakan lapisan aktivasi dengan fungsi $f(x) = \max(0, x)$ yang membuat seluruh nilai piksel berkurang dari nol pada suatu citra akan jadi nol. Tujuan dari Fungsi Aktivasi ReLU adalah untuk mengutasi linearitas yang terjadi dari proses konvolusi sehingga Convolutional Neural Network lebih mudah mencapai nilai Optimum.



Gambar 4. Grafik Aktivasi ReLU

d. Pooling Layer

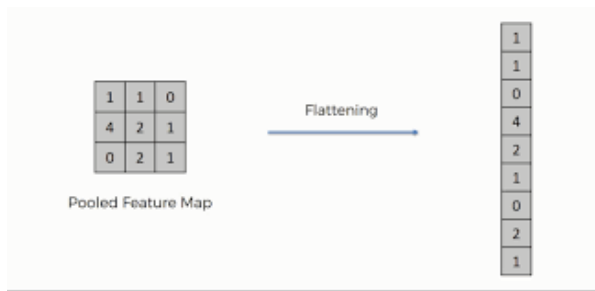
Pooling Layer adalah sebuah filter dengan ukuran tertentu yang bergeser pada seluruh daerah feature map. Pooling yang sering digunakan adalah *Max Pooling* dan *Average Pooling*. Tujuan dari pooling layer adalah mereduksi / melakukan downsampling feature map, sehingga bias mempercepat komputasi karena bobot yang harus diperbaharui semakin sedikit.



Gambar 5. Visualisasi Pooling Layer

e. Flatten Layer


Flatten Layer adalah tahapan yang akan dilalui sebelum tahap *Fully Connected Layer*, Features map yang dihasilkan dari tahap *feature extractor* masih berbentuk data array multidimensi, karena itu perlunya dilakukan *Flatten*, yaitu proses membentuk ulang fitur dengan cara me-reshape feature map menjadi vector array satu dimensi agar bisa digunakan untuk proses selanjutnya yaitu *fully connected layer*.



Gambar 6. Visualisasi Flatten Layer

f. Fully Connected Layer

Fully Connected Layer terdiri dari layer masukan, layer tersembunyi (hidden layer) dan layer keluaran, jika diperhatikan layer-layer yang ada sama seperti di Artificial Neural Network. Fully connected layer semua node / neuron dari layer yang sebelumnya terhubung menyeluruh dengan layer selanjutnya. Di setiap layer tersembunyi terdapat fungsi aktivasi. Tujuan utama dari fully connected layer ialah mengolah data sehingga bisa dilakukan klasifikasi citra. Keluaran dari tahap ini yaitu probabilitas terhadap kategori apabila menggunakan aktivasi softmax untuk output layer.




Gambar 7. Visualisasi Fully Connected Layer

g. Fungsi Aktivasi Softmax

Fungsi Aktivasi Softmax sering dipakai dalam kasus klasifikasi citra yang lebih dari 2 kelas, posisinya berada di layer keluaran di tahap *fully connected / classification*. Tujuan dari penggunaan aktivasi softmax ini adalah menghitung probabilitas dari setiap kelas target dari semua kelas target yang ada, Kelebihan menggunakan aktivasi ini adalah


rentang probabilitas keluarannya dengan nilai 0 hingga 1.



Gambar 8. Grafik Aktivasi Softmax

h. Dropout Regularization

Dropout Regularization adalah suatu teknik regulasi untuk mengurangi agar model tidak overfitting, dimana beberapa neuron akan dipilih secara acak dan tidak akan digunakan untuk training. Neuron-neuron ini dibuang secara acak. Hal ini mengakibatkan kontribusi neuron yang dibuang akan diberhentikan sementara dan bobot baru juga tidak diterapkan pada neuron pada saat melakukan proses backpropagation. Selain itu proses ini juga dapat mempercepat proses pelatihan.[5]



Gambar 9. Visualisasi Dropout Regularization

2.3 Segmentasi Citra

Segmentasi citra adalah proses membagi citra digital menjadi banyak segmen yang tidak tumpang tindih (non-overlapping). Dalam konteks citra digital, area tersegmentasi adalah sekelompok piksel yang berdekatan atau terkait. Segmentasi citra dapat dilakukan dengan beberapa pendekatan. Ada tiga pendekatan:


- Pendekatan batas
 Pendekatan ini dilakukan untuk menjaga batas-batas yang ada antar wilayah.
- Pendekatan tepi
 Pendekatan tepi dilakukan untuk mengidentifikasi piksel tepi dan menghubungkan piksel-piksel batas yang diinginkan.

- Pendekatan kewilayahan (regional approach), pendekatan kewilayahan, bertujuan untuk membagi citra ke dalam wilayah-wilayah sehingga dapat diperoleh range yang sesuai dengan yang diinginkan.

Proses segmentasi digunakan dalam banyak penerapan, meskipun metode yang digunakan sangat banyak dan bervariasi, semuanya memiliki tujuan sama yaitu untuk mendapatkan representasi sederhana yang berguna dari suatu citra. Terdapat berbagai macam metode dalam melakukan segmentasi, cukup sulit untuk menentukan metode yang komprehensif, oleh karena itu pemilihan metode bergantung pada pendekatan yang akan digunakan dan fitur yang ingin diperoleh dari citra.

2.4 Thresholding

Thresholding adalah suatu segmentasi citra pada *image processing*. Metode adalah cara untuk membuat gambar biner dari gambar skala abu-abu atau penuh. Ini biasanya dilakukan untuk memisahkan "objek" atau piksel *foreground* dari piksel latar belakang. Metode ini merupakan salah satu metode segmentasi citra yang memisahkan antara objek dengan *background* dalam suatu citra berdasarkan perbedaan tingkat kecerahan atau gelap terangnya. Region citra yang cenderung gelap akan dibuat semakin gelap (hitam sempurna dengan nilai intensitas sebesar 0), sedangkan region citra yang cenderung terang akan dibuat semakin terang (putih sempurna dengan nilai intensitas sebesar 1). Oleh karena itu, keluaran dari proses segmentasi dengan metode thresholding adalah berupa citra biner dengan nilai intensitas piksel sebesar 0 atau 1 [6].



Gambar 10. Visualisasi Thresholding

2.5 Computed Tomography Scan

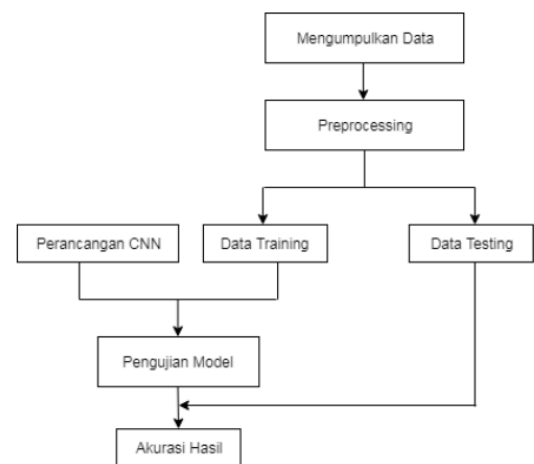
Computed Tomography Scan pemeriksaan *thorax yang* bertujuan untuk melihat letak dan luas massa mediastinum, serta melihat kelainan yang terjadi pada mediastinum lainnya. Selain itu digunakan juga untuk menunjukkan nodus limfatikus yang membesar sewaktu menentukan stadium pasien dengan penyakit neoplastic, terutama kasus tumor dan limfoma paru dan ginjal. *Computed Tomography Scan thorax* juga berguna untuk menentukan luas dari carcinoma

(tumor) yang terdapat pada paru-paru maupun pada mediastinum. Pemeriksaan *Computed Tomography Scan thorax* banyak dilakukan khususnya pada kasus tumor paru sehingga diagnosis yang didapatkan lebih akurat dari pemeriksaan konvensional biasa karena dapat menentukan letak dan luas dari tumor tersebut dengan tepat.

3. METODE PENELITIAN

Penelitian ini dikembangkan dengan sebuah program menggunakan bahasa pemrograman python. Program yang dikembangkan akan mengimplementasikan algoritma Convolutional Neural Network yang dapat bekerja secara offline tanpa harus terhubung ke internet. Program yang dikembangkan juga program berbasis web. Program ini akan meminta pengguna untuk memasukkan data citra ginjal yang sudah dilakukan pra-proses (proses *Computed Tomography*) terlebih dahulu, lalu hasil prediksi akan keluar apakah ginjal tersebut normal atau mempunyai penyakit.

Tahapan penelitian dapat dilihat pada Gambar




Gambar 11. Tahapan Penelitian


3.1 Dataset

Pada pengumpulan dataset citra ginjal, data diambil dari website kaggle, dataset yang digunakan dapat diunduh pada tautan berikut : <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>. Digunakan 9334 data citra ginjal untuk melakukan train dan digunakan 3112 data citra ginjal untuk validasi, data tersebut mempunyai 4 kelas, yaitu kelas kista,


kelas normal, kelas batu dan kelas tumor.




Gambar 12. Dataset Ginjal Kista



Gambar 13. Dataset Ginjal Normal




Gambar 14. Dataset Ginjal Batu



Gambar 15. Dataset Ginjal Tumor

3.3 Proses Klasifikasi

Pada proses klasifikasi, *user* akan menggunakan jaringan yang didapatkan dari proses pelatihan. *Input* berupa citra akan diklasifikasi oleh jaringan sehingga didapatkan termasuk kelas manakah citra tersebut. Proses ini diimplementasi pada halaman pengolahan citra. *Flowchart* proses klasifikasi ditunjukkan gambar 16 [7].



Gambar 16. Alur Proses Klasifikasi

3.4 Pengujian

Setelah data training selesai di implementasi, maka data testing berupa gambar akan di panggil untuk menguji coba hasil training. Hasil akhir dari testing adalah berupa prediksi gambar sesuai dengan jenis obyek pada gambar. Hasil keluaran testing akan dibandingkan kembali dengan hasil sebenarnya

untuk mengukur seberapa besar tingkat akurasi fitur prediksi [3].

4. HASIL DAN PEMBAHASAN

4.1 Identifikasi Alat

Dibawah ini, akan diidentifikasi terhadap alat-alat yang dipergunakan untuk melakukan implementasi CNN pada penelitian ini.

TABEL I. Identifikasi Alat

Alat	Deskripsi
Bahasa Pemrograman	Python 3.7
Aplikasi	Google Colab, Visual Studio Code
Library	Tensorflow, Keras, Numpy, Matplotlib, Flask, Bootstrap 4
Epoch	50

4.2 Arsitektur Convolutional Neural Network

Arsitektur Convolutional Neural Network yang digunakan pada penelitian adalah arsitektur model Alexnet.

```

Model: "sequential_1"
Layer (type)                Output Shape                Param #
-----
conv2d_3 (Conv2D)           (None, 149, 149, 32)       416
max_pooling2d_3 (MaxPooling2 (None, 37, 37, 32)       0
conv2d_4 (Conv2D)           (None, 36, 36, 64)         8256
max_pooling2d_4 (MaxPooling2 (None, 9, 9, 64)         0
conv2d_5 (Conv2D)           (None, 8, 8, 128)          32896
max_pooling2d_5 (MaxPooling2 (None, 2, 2, 128)       0
flatten_1 (Flatten)         (None, 512)                 0
dropout_1 (Dropout)         (None, 512)                 0
dense_2 (Dense)             (None, 128)                 65664
dense_3 (Dense)             (None, 4)                   516
-----
Total params: 107,748
Trainable params: 107,748
Non-trainable params: 0
    
```

Gambar 17. Model Alexnet

Dan didapat grafik hasil training sebagai berikut

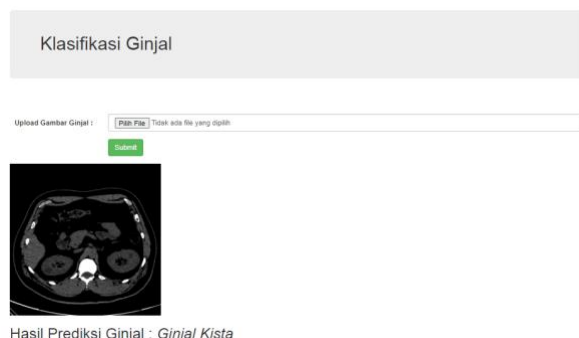


Gambar 18. Grafik Training

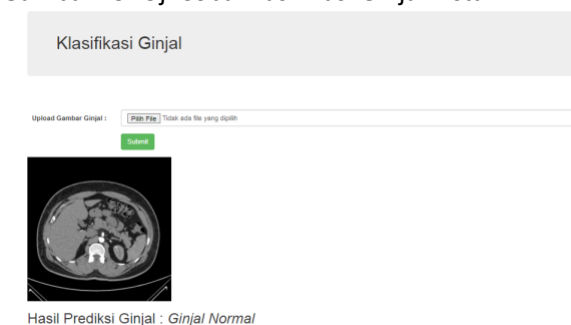
Dari grafik hasil train data tersebut didapat bahwa hasil train dengan akurasi rata-rata yang didapat adalah berkisar diantara 70% hingga 75%.

4.3 Implementasi dan Uji Coba

Pada tahap ini dilakukan klasifikasi terhadap citra ginjal untuk mengetahui hasil deteksi yang ditampilkan oleh web. Akan digunakan masing-masing 1 data acak dari tiap kelas dalam melakukan uji berikut. Hasil uji coba dengan website akan ditampilkan sebagai berikut :



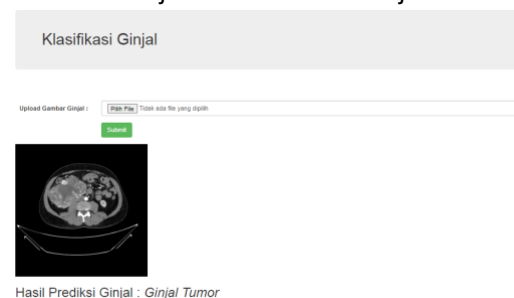
Gambar 19. Uji Coba Klasifikasi Ginjal Kista



Gambar 20. Uji Coba Klasifikasi Ginjal Normal

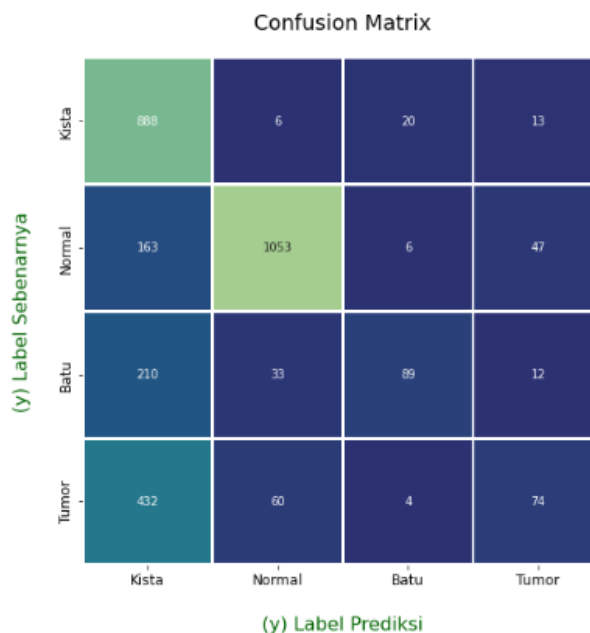


Gambar 21. Uji Coba Klasifikasi Ginjal Batu



Gambar 22. Uji Coba Klasifikasi Ginjal Tumor

Dari hasil uji data testing, didapat hasil *confusion matrix* dan *Classification Report* sebagai berikut :



Gambar 23. Confusion Matrix Model

	precision	recall	f1-score	support
Cyst	0.52	0.96	0.68	927
Normal	0.91	0.83	0.87	1269
Stone	0.75	0.26	0.38	344
Tumor	0.51	0.13	0.21	570
accuracy			0.68	3110
macro avg	0.67	0.54	0.53	3110
weighted avg	0.70	0.68	0.64	3110

Gambar 24. Classification Report

Berdasarkan confusion matrix di atas didapat kesimpulan bahwa citra ginjal yang paling mudah untuk dideteksi adalah citra ginjal normal dan citra ginjal kista, sedangkan untuk citra ginjal batu dan citra ginjal tumor cukup sulit untuk dideteksi dikarenakan data citranya sangat mirip dengan data citra kista. Dari hasil Classification Report didapatkan bahwa nilai akurasi f1 skor dari keseluruhan adalah sebesar 68%.

5. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Website klasifikasi penyakit ginjal ini sudah berhasil dibuat menggunakan Framework Flask dengan API dari google colab yang menghasilkan model h5 dan Visual Studio Code. Website dapat dijalankan pada semua jenis sistem operasi komputer. Data Pelatihan citra dengan algoritma *convolutional neural network* yang berasal dari 9334 data train dan 3110 data

validasi. Proses *preprocessing* yang dilakukan pada citra adalah dengan melakukan perubahan ukuran citra agar berukuran sama yaitu menjadi 150x150 pixel dan menggunakan tipe gambar yang telah di scan menjadi scan computed tomography. Model dapat mengklasifikasi citra yang diujikan dengan baik untuk ginjal normal dan ginjal kista, tetapi untuk ginjal tumor dan ginjal batu terkadang bisa terjadi salah klasifikasi yang dikarenakan citra ginjal batu dan ginjal tumor sangat mirip dengan ginjal kista. Hasil dari final *test accuracy* yang diperoleh dari keseluruhan proses pelatihan yaitu sebesar 75,17% dengan nilai akurasi f1 skornya adalah 68%.

5.2 Saran

Pengembangan lebih lanjut dapat dilakukan untuk membuat model yang lebih baik lagi, serta versi aplikasi mobile untuk penelitian ini dan juga melakukan penyempurnaan terhadap website klasifikasi penyakit ginjal yang telah dibuat. Selain itu bisa juga menambahkan kelas baru dalam dataset dan menambah jumlah dataset untuk memberikan hasil akurasi yang lebih maksimal .

6. DAFTAR PUSTAKA

- [1] J. Melisa, A. Monoarfa, and F. Tjandra, "Profil penderita karsinoma sel ginjal (renal cell carcinoma)," *J. e-Clinic*, vol. 4, no. 2, 2016.
- [2] M. R. D. Septian, A. A. A. Paliwang, M. Cahyanti, and E. R. Swedia, "Penyakit Tanaman Apel Dari Citra Daun Dengan Convolutional Neural Network," *Sebatik*, vol. 24, no. 2, pp. 207–212, 2020, doi: 10.46984/sebatik.v24i2.1060.
- [3] H. Dhika, N. R. Kurnianda, P. Irfansyah, and W. Ananta, "Model Prediksi Jenis Hewan dengan Metode Convolution Neural Network," vol. 9, pp. 31–40, 2020.
- [4] E. Rasywir, R. Sinaga, and Y. Pratama, "Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode Convolutional Neural Network (CNN)," *Paradig. - J. Komput. dan Inform.*, vol. 22, no. 2, pp. 117–123, 2020, doi: 10.31294/p.v22i2.8907.
- [5] M. R. R. Allaam, "KLASIFIKASI GENUS TANAMAN ANGGREK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) Program Studi Sarjana Informatika Fakultas Informatika Universitas Telkom Bandung," vol. 8, no. 2, pp. 3147–3179, 2021.
- [6] A. B. Prasetyo and M. Y. Sobari, "Threshold Pada Pengolahan Citra Digital," pp. 2–5.
- [7] D. Irfansyah, M. Mustikasari, and A. Suroso, "Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi," *J. Inform. J. Pengemb. IT*, vol. 6, no. 2, pp. 87–92, 2021, [Online]. Available: <http://ejournal.poltektegal.ac.id/index.php/informatika/article/view/2802>