

Prediksi Penyakit Batu Ginjal dengan Menerapkan Convolutional Neural Network

Bagus Satrio Waluyo Petro¹, Sri Mulyono², Vani Aulia Pramesti^{*3}

Program Studi Teknik Informatika, Fakultas Teknologi Industri, Universitas Islam Sultan Agung
Jl. Kaligawe Raya No.Km.4, 50112, Jawa Tengah, Indonesia

Email: ¹bagusswp@unissula.ac.id, ²sri.m@unissula.ac.id, ³vaniauliapramesti@std.unissula.ac.id

Abstract. Prediction of Kidney Stone Disease by Applying Convolutional Neural Network. Kidney stones are a health problem that requires intensive treatment. If the disease is not treated quickly, it can lead to impaired kidney function and complications to other organs. Computerized Tomography Scan (CT Scan) with high resolution is used to scan the human body for disease diagnosis. The doctor will explain the diagnosis within a few days or one week. This research aims to create a prediction model for the classification of kidney stone disease through CT Scan images by applying the Convolutional Neural Network (CNN) method of DenseNet-121 architecture and deployment using Streamlit. The results of the model in this study with the application of CNN DenseNet-121 architecture are accuracy 98.18%, precision 96.36%, recall 100%, and F1-score 98.14%.

Keywords: classification, CNN, DenseNet-121, deep learning, kidney stone

Abstrak. Batu ginjal merupakan masalah kesehatan yang membutuhkan perawatan intensif. Akibat yang diperoleh jika penyakit ini tidak dapat ditangani secara cepat dapat menyebabkan gangguan fungsi ginjal hingga komplikasi ke organ lainnya. Computerized Tomography Scan (CT Scan) dengan resolusi tinggi digunakan sebagai scan tubuh manusia untuk diagnosis penyakit. Diagnosis akan dijelaskan oleh dokter dalam kurun waktu beberapa hari atau satu minggu. Tujuan pada penelitian ini adalah membuat model prediksi untuk klasifikasi penyakit batu ginjal melalui citra CT Scan dengan penerapan metode Convolutional Neural Network (CNN) arsitektur DenseNet-121 dan deployment menggunakan streamlit. Hasil model pada penelitian ini dengan penerapan CNN arsitektur DenseNet-121 yaitu accuracy 98,18%, precision 96,36%, recall 100%, F1-score 98,14%.

Kata Kunci: klasifikasi, CNN, DenseNet-121, deep learning, batu ginjal

1. Pendahuluan

Batu ginjal yaitu massa keras yang menumpuk dan terbentuk di organ ginjal, ureter, kandung kemih, saluran kemih, dan uretra [1]. Penderita penyakit batu ginjal harus segera dapat ditangani karena jika tidak, dapat menyebabkan nyeri parah, gangguan fungsi ginjal, dan komplikasi. Penyakit batu ginjal dapat disebabkan oleh banyak faktor, termasuk gaya hidup yang tidak sehat dan pola makan yang tidak sehat [2].

Tes pencitraan, pemeriksaan fisik, dan riwayat medis adalah langkah pertama dalam diagnosis batu ginjal. *Computer Tomografi Scan* (CT scan) resolusi tinggi CT dapat dilakukan dari ginjal ke kandung kemih untuk melihat ukuran dan bentuk batu ginjal. *Computerized Tomography Kidney-Ureter-Bladder* (CT-KUB) adalah alat diagnostik yang dapat diterima untuk penyakit batu saluran kemih yang dicurigai, dengan ukuran dan lokasi batu ureter sebagai prediktor yang signifikan untuk intervensi darurat [3]. Dokter atau ahli radiologi dapat secara manual menganalisis gambar CT dan membutuhkan waktu yang lama dan rentan terhadap kesalahan individu [4].

Perkembangan kecerdasan buatan dalam beberapa tahun terakhir telah membuka peluang baru untuk sistem deteksi penyakit berbasis citra medis yang lebih baik. Memanfaatkan teknologi *deep learning* dapat membantu dokter dan ahli radiologi membuat diagnosis dan pengobatan yang lebih baik dengan menganalisis gambar medis. Salah satu metode yang dapat digunakan dalam sebuah teknik *deep learning* kemudian tepat untuk analisis gambar medis adalah *Convolutional Neural Network* (CNN) [5]. Metode yang paling efektif adalah metode *Convolutional Neural Network*. Hasil model yang telah dilatih dengan data citra menggunakan metode CNN dapat digunakan untuk mendeteksi penyakit batu ginjal melalui citra CT Scan dan meningkatkan akurasi klasifikasi *computer vision* [6].

Metode *Convolutional Neural Network* (CNN) adalah jenis kerangka kerja jaringan saraf tiruan yang dimaksudkan untuk mengolah dan menganalisis data berbentuk *grid*, seperti gambar. CNN memiliki kemampuan untuk mengenali pola dan fitur dalam data melalui lapisan konvolusi, yang memungkinkan model untuk belajar secara efektif tentang struktur dan detail visual. Ini memungkinkan CNN untuk mengolah data besar seperti gambar dan video. Cara gambar manusia bekerja terinspirasi oleh pendekatan CNN, informasi diproses secara hierarki dari elemen sederhana, seperti garis dan sudut hingga elemen yang lebih kompleks, seperti wajah atau objek [7].

Densely Connected Convolutional Network (DenseNet) untuk meningkatkan kinerja dalam pengolahan gambar. Arsitektur jaringan saraf konvolusional DenseNet-121 menghubungkan setiap lapisan dengan semua lapisan jaringan yang lebih dalam misalnya, lapisan pertama terhubung dengan lapisan kedua, ketiga, keempat, dan seterusnya [8]. Metode ini dimaksudkan untuk memaksimalkan alur data antara lapisan dan jaringan. Melatih model CNN dengan menggunakan arsitektur DenseNet-121 pada dataset citra *CT Scan* yang besar dan bervariasi, deteksi ini dapat belajar untuk mengenali pola-pola karakteristik yang terkait dengan keberadaan batu ginjal dalam citra.

Dalam penelitian ini, metode *Convolutional Neural Network* (CNN) dengan arsitektur DenseNet-121 digunakan untuk mengklasifikasikan penyakit batu ginjal dan penyakit ginjal normal melalui citra *CT scan*. Pada penelitian ini menggunakan *library* Tensorflow untuk melatih model dengan data yang ada yang kemudian model di *load* ke dalam aplikasi berbasis web untuk mempermudah *user* atau dokter menggunakan model klasifikasi. Pada penelitian ini dengan menggunakan metode CNN arsitektur DenseNet-121 yang *deployment* dengan *streamlit* diharapkan mampu memudahkan diagnosis dan hasil sehingga pasien mendapatkan perawatan yang lebih lanjut.

2. Tinjauan Pustaka

Di bidang *deep learning*, *Convolutional Neural Network* (CNN) menjadi sangat populer dan metode ini tidak mengubah kualitas gambar tetapi mengubah dimensinya [7]. Klasifikasi tambahan menggunakan CNN dengan metode pembelajaran *transfer*. Keunggulan metode ini adalah kemampuan untuk melakukan pra-pelatihan menggunakan informasi yang telah dipelajari dari model CNN yang telah dilatih sebelumnya. Informasi ini kemudian dapat disesuaikan dan diterapkan pada tugas klasifikasi yang baru. Teknik ini tidak hanya dapat meningkatkan kinerja model secara keseluruhan, tetapi juga dapat mengurangi waktu yang diperlukan untuk pelatihan model dan menghasilkan kinerja yang lebih baik [9].

Penelitian yang dilakukan sebelumnya [10] menggunakan CNN arsitektur Alexnet untuk mengklasifikasikan penyakit mata. Penelitian ini menunjukkan klasifikasi penyakit mata normal, katarak, glaucoma, dan penyakit retina. Klasifikasi dilakukan dalam tiga tahap. Pertama, *preprocessing* dilakukan untuk menghasilkan ukuran gambar 224x224 px. Kemudian, fitur seperti lapisan konvolusi, lapisan *pooling*, dan lapisan penuh terhubung diekstraksi. Pada tahap ketiga, metode *Convolutional Neural Network* digunakan dengan 150 epoch. Hasilnya, metode ini menghasilkan model dengan akurasi sebesar 98,37%.

Penelitian sebelumnya juga menggunakan metode *Convolutional Neural Network* (CNN) [11]. Tujuan dari penelitian ini adalah untuk memahami bagaimana algoritma CNN mendeteksi penyakit ginjal berdasarkan gambar medis yang digunakan. Arsitektur AlexNet digunakan untuk membangun model dalam penelitian ini. Bahasa pemrograman python digunakan untuk melakukan penelitian ini, yang akan diimplementasikan ke sistem berbasis web yang menggunakan *framework* flask. Semua jenis penyakit ginjal dapat dideteksi dengan sistem ini. Data tersebut mencakup empat kategori penyakit, yaitu ginjal normal, kista ginjal, tumor ginjal, dan batu ginjal. Studi ini mencapai akurasi total *F1-score* sebesar 68%.

Penelitian sebelumnya [12] dalam penelitian tersebut menerapkan algoritma *Convolutional Neural Network* (CNN) meliputi beberapa layer tradisional tanpa menggunakan arsitektur tambahan. CNN digunakan pada penelitian ini untuk melakukan layer ekstraksi fitur pada citra input dan sampai dengan layer klasifikasi. Data yang diimplementasikan sebagai pelatihan data pada penelitian tersebut yaitu 2.338 citra ginjal normal dan 2.390 citra batu ginjal yang diperoleh dari data publik (Kaggle) dan data primer rumah sakit. Penelitian tersebut

diterapkan dengan dua uji analisis yaitu *testing* yang pertama dengan augmentasi data publik dari kaggle dan pengujian kedua dengan augmentasi data primer rumah sakit. Dari penelitian yang dilakukan mendapatkan hasil validasi augmentasi data publik dari kaggle pada batu ginjal diperoleh tingkat akurasi *cross validation* yaitu sebesar 99,69%. Sedangkan validasi augmentasi data primer rumah sakit pada batu ginjal diperoleh tingkat akurasi *cross validation* yaitu sebesar 45,43%.

Pada penelitian sebelumnya mengklasifikasikan berbagai penyakit kanker kulit, seperti karsinoma sel badal, nevi melanositik, keratosis jinak, dan melanoma. Metode CNN-SVM digunakan untuk mengklasifikasikan penyakit kanker kulit. Penelitian ini menggunakan metode *Convolutional Neural Network* sebagai ekstraksi fitur. Dengan menggunakan arsitektur VGG-19 dan ResNet-50, dan menggunakan kernel linear optimasi *random* dan nilai *grid*, penelitian ini menemukan *patch preprocessing* VGG-19 dengan skor akurasi 65,33%, *recall* 65,33%, ketepatan 68,51%, dan *F1-score* 65,77% [13].

3. Metodologi Penelitian

3.1 Pre-processing

Pra-pemrosesan data juga dikenal sebagai pemrosesan awal data adalah serangkaian langkah atau tahapan yang dilakukan pada data mentah sebelum digunakan untuk analisis atau pengembangan model. Tujuan utama dari pra-pemrosesan data adalah untuk meningkatkan kualitas data, menjamin hasil analisis akurat, dan memperbaiki masalah serta kesalahan yang mungkin muncul pada data mentah [14]. Tujuan dari tahap *preprocessing* analisis gambar adalah untuk meningkatkan dan mengoptimalkan hasil pelatihan, yang pada akhirnya akan menghasilkan hasil akhir yang lebih akurat [15].


Saat melakukan pra-pemrosesan data gambar, beberapa transformasi umum dilakukan menggunakan operasi matriks. Semua transformasi ini, termasuk *shear* atau geser, rotasi, *zoom*, translasi, dan penskalaan dapat digambarkan sebagai matriks transformasi yang diterapkan pada koordinat piksel gambar. Data citra CT scan ini digunakan untuk *training* data dan *testing*. Dataset berupa citra medis batu ginjal yang diperoleh melalui situs Kaggle. Dataset meliputi kondisi ginjal normal dan ginjal dengan batu ginjal. Untuk total data yang akan digunakan yaitu 2.642. Pada Tabel 1 menunjukkan jumlah data yang digunakan pada penelitian ini. Terdiri dari kelas data yaitu data latih, data uji, dan data validasi.

Tabel 1. Dataset

No	Nama Data	Data Ginjal Normal (Jumlah)	Data Batu Ginjal (Jumlah)	Total Data
1.	Data Latih	1.101	1.101	2.202
2.	Data Uji	110	110	220
3.	Data Validasi	110	110	220
Total				2.642


3.2 Convolutional Neural Network Arsitektur DenseNet-121

Desain CNN yang diperlihatkan Gambar 1 merupakan konsep dari keseluruhan CNN yang dibagi menjadi tiga bagian utama yakni *input*, pembelajaran fitur, dan klasifikasi. Proses *input* yaitu dari gambar digital, setelah melakukan proses pembelajaran fitur untuk memproses gambar, diterapkan model konvolusi, yang memperoleh nilai matriks yang ada di dalam gambar. Proses *trigger* menerapkan *Rectified Linear Unit* (ReLU) kemudian proses konvolusi dan aktifkan ReLU. Proses *pooling* adalah pengumpulan data saat semua vektor dibuat satu dan mendapatkan nilai tertinggi dari satu gambar. CNN mempunyai banyak lapisan, digunakan sebagai langkah proses penyaringan untuk setiap proses pencitraan digital.



Gambar 1. Arsitektur CNN [16]


DenseNet memecahkan masalah dengan menyediakan jalur langsung untuk aliran bertahap melalui tiap-tiap lapisan yang terhubung secara padat. DenseNet menggunakan apa yang disebut dengan *dense blocks* yang diperlihatkan Gambar 2. Dalam setiap *dense blocks*, setiap lapisan menerima *input* dari semua lapisan sebelumnya.



Gambar 2. Dense Blocks [17]

3.3 Training Model

Pada Gambar 3 diperlihatkan langkah-langkah dan proses untuk melakukan *training model*. Lapisan konvolusi adalah salah satu lapisan yang paling penting dalam *Convolutional Neural Network* (CNN) karena bertanggung jawab untuk mengekstraksi fitur-fitur penting dari data gambar. Conv2D digunakan untuk melakukan operasi konvolusi pada data *input*. Operasi konvolusi ini dilakukan dengan menggunakan *filter* atau kernel untuk memindai gambar dan mengekstraksi pola-pola visual yang relevan. Setiap kernel dalam lapisan konvolusi memiliki bobot yang dipelajari selama proses pelatihan model. Operasi konvolusi ini dilakukan dengan memindai gambar dengan kernel atau *filter* untuk mengekstraksi pola visual yang relevan. Selama proses pelatihan model, setiap kernel dalam lapisan konvolusi memiliki bobot yang dipelajari. Nilai rata-rata dari setiap *feature map* diambil oleh *Global Average Pooling* (GAP). Dengan kata lain, *Global Average Pooling* menghasilkan satu nilai rata-rata yang menggambarkan semua data dalam setiap *feature map*. *Mini-batch* (memperbarui bobot model) digunakan untuk normalisasi *batch* dalam proses pelatihan jaringan saraf. Proses ini menghitung varian dan rata-rata dari setiap *mini-batch*, dan kemudian menggunakan nilai-nilai ini untuk menormalkan *input* dari setiap lapisan.



Gambar 3. Training Model

3.3.1 Rectified Linear Unit (ReLU)

Fungsi aktivasi yang ada pada Persamaan 1 membantu model memahami pola data yang kompleks dengan menunjukkan *output* sebagai input itu sendiri jika inputnya positif dan nol jika inputnya negatif.

$$f(x) = \max(0, x) \quad (1)$$

3.3.2 Dense

Dense layer adalah bagian dari jaringan saraf di mana semua neuron terhubung dengan neuron di lapis sebelumnya, seperti jaringan lengkap yang menghubungkan setiap titik dengan setiap titik lainnya. Pada bagian akhir jaringan, lapis ini biasanya digunakan untuk menggabungkan semua informasi yang telah dipelajari dari lapis sebelumnya dan menghasilkan *output* akhir. Setelah lapisan konvolusi jaringan saraf menghitung fitur-fitur citra, lapisan sebelumnya dapat dianggap lebih seperti penerjemah dari fitur-fitur tersebut yang mencoba memprediksi sesuatu yang lebih spesifik dan nyata dalam *output*. Oleh karena itu, memproses semua fitur yang dihasilkan pada lapisan sebelumnya dan mengintegrasikannya secara koheren ke dalam representasi yang digunakan untuk klasifikasi atau prediksi. Selain itu, setiap neuron pada *dense layer* ini memiliki satu set koneksi lengkap dengan neuron pada lapisan sebelumnya, sehingga memiliki potensi untuk mendeteksi bentuk-bentuk yang kompleks. *Dense layer* adalah lapisan terakhir dalam barisan lapisan yang menerima output dari proses konvolusi dan memberikan ukuran dan skor *output* untuk kelas yang berbeda dalam klasifikasi. Tanpa *dense*

layer, CNN tidak akan dapat mencapai *output* yang diperlukan untuk aplikasi target seperti prediksi atau klasifikasi.

3.3.4 Hyper Parameter Tuning

Dalam penelitian ini, beberapa percobaan dilakukan untuk melakukan *hyper parameter tuning* guna memperoleh parameter terbaik dalam membangun performa model. Percobaan tersebut melibatkan pengaturan *batch size* dengan nilai 16, 32, dan 64, serta pengaturan *patience* pada *early stopping* dengan nilai 3 dan 5. Setelah parameter diatur, performa model dievaluasi menggunakan *confusion matrix* untuk menilai hasil akhir. Pada penelitian ini menggunakan *hyper parameter tuning batch size 32 dengan early stopping 5 patience*. Mengacu ke Tabel 2 merupakan hasil dari sejumlah eksperimen yang dilakukan dalam penelitian ini. Menghasilkan parameter terbaik, yang memiliki ukuran *batch 32* dan *patience early stopping 5*. hasil ini digunakan untuk membangun model klasifikasi pada penelitian.

Tabel 2. Hyper Parameter Tuning

No	Parameter	Confusion Matrix	
1	Batch size 16 Patience 3	TP = 105	Accuracy = 97,27%
		TN = 109	Precision = 95,61%
		FP = 5	Recall = 99,09%
		FN = 1	F1-Score = 97,32%
2	Batch size 32 Patience 3	TP = 105	Accuracy = 95%
		TN = 104	Precision = 95,41%
		FP = 5	Recall = 94,54%
		FN = 6	F1-Score = 94,97%
3	Batch size 64 Patience 3	TP = 103	Accuracy = 95,90%
		TN = 108	Precision = 93,91%
		FP = 7	Recall = 98,18%
		FN = 2	F1-Score = 96%
4	Batch size 16 Patience 5	TP = 105	Accuracy = 97,72%
		TN = 110	Precision = 95,65%
		FP = 5	Recall = 100%
		FN = 0	F1-Score = 97,77%
5	Batch size 32 Patience 5	TP = 106	Accuracy = 98,18%
		TN = 110	Precision = 96,49%
		FP = 4	Recall = 100%
		FN = 0	F1-Score = 98,21%
6	Batch size 64 Patience 5	TP = 101	Accuracy = 95,90%
		TN = 110	Precision = 92,43%
		FP = 9	Recall = 100%
		FN = 0	F1-Score = 96,06%

3.3.5 Evaluasi Model

Setelah pelatihan selesai dilakukan, evaluasi model pada set validasi untuk mengukur kemampuan model terhadap data yang tidak digunakan semasa pelatihan. Untuk menjalankan evaluasi model menggunakan matriks akurasi, *precision*, *recall*, dan *F1-score* perlu menghitung jumlah prediksi yang benar dari model terhadap total jumlah data pengujian. Evaluasi model juga dilakukan dengan membandingkan nilai hasil dari *accuracy* dan *loss* pada *set training* dan validasi diperlihatkan pada Persamaan 2, Persamaan 3, Persamaan 4, dan Persamaan 5.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2)$$

$$precision = \frac{TP}{TP + FP} \times 100\% \quad (3)$$


$$recall = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

$$F1 - score = 2 \times \frac{precision \times recall}{precision + recall} \times 100\% \quad (5)$$


4. Hasil dan Diskusi

Gambar 4 menunjukkan hasil akurasi pelatihan dan validasi model. Garis biru menunjukkan hasil pelatihan model, dan garis merah menunjukkan hasil validasi model. Pada grafik tersebut, nilai akurasi masing-masing epoch pelatihan dan validasi model meningkat, meskipun ada beberapa epoch yang mengalami sedikit penurunan yang tidak signifikan, dan kemungkinan besar akan terjadi peningkatan.

Gambar 5 menunjukkan grafik hasil hilang dari pelatihan dan validasi model. Garis biru menunjukkan hasil kehilangan pembelajaran model, dan garis merah menunjukkan hasil kehilangan validasi model. Pada grafik tersebut, nilai kehilangan setiap periode pelatihan dan validasi model mengalami penurunan, meskipun ada beberapa periode yang mengalami sedikit peningkatan, tetapi tidak signifikan dan cenderung kembali naik, peningkatan nilai kehilangan secara konsisten dan signifikan. Nilai *training loss* sedikit lebih rendah dibandingkan dengan *validation loss*. Meskipun terdapat selisih sebesar 1,45%, perbedaan ini masih dalam batas dan tidak menunjukkan perbedaan yang signifikan.




Gambar 4. Accuracy Training dan Validation



Gambar 5. Loss Training dan Validation


Pada Gambar 6 menunjukkan prediksi yaitu ginjal normal. Implementasi *testing* tersebut menggunakan data kondisi ginjal normal. Dari hasil tersebut klasifikasi penyakit batu ginjal model mampu generalisasi terhadap data *testing* dengan baik. Hasil prediksi yang menunjukkan ginjal dengan batu ginjal ditunjukkan pada Gambar 7. Kesimpulan ini menunjukkan bahwa klasifikasi penyakit batu ginjal model dapat digeneralisasi dengan baik terhadap data tes.

Klasifikasi Penyakit Batu Ginjal




Gambar 6. Hasil Prediksi Ginjal Normal

Klasifikasi Penyakit Batu Ginjal



Gambar 7. Hasil Prediksi Batu Ginjal

Gambar 8 menunjukkan hasil *confusion matrix* dengan model yang sudah ada menggunakan data testing. Jumlah *true positive* 106 (normal) dan jumlah *true negative* 110 (batu ginjal). Nilai *false positive* 4 dan *false negative* bernilai 0. Hasil *accuracy* sebesar 98,18%, hasil *precision* 96,36%, hasil *recall* 100% dan hasil *F1-score* 98,14%.



Gambar 8. Evaluasi Model Menggunakan *Confusion Matrix*

Arsitektur DenseNet-121 memberikan peningkatan yang relevan dalam akurasi model CNN karena masing-masing lapisan dalam blok yang sama terhubung ke masing-masing lapisan sebelumnya, dengan konsep *connectivity*. Semua ekstraksi fitur lapisan yang sebelumnya tidak diabaikan dan diuji oleh DenseNet-121. Fitur ini juga digunakan di lapisan model berikutnya untuk memberikan informasi yang lebih rinci. Hal ini dimungkinkan dengan mengintegrasikan fitur-fitur dari setiap lapisan sebelumnya. Hal ini memungkinkan DenseNet-121 untuk menjadi lebih bervariasi dengan data multi-varian. Struktur ini mendukung kemampuan model untuk menganalisis berbagai pola dalam data yang kompleks. Hal ini membatasi kemungkinan *overfitting*, yang sangat bermasalah ketika tidak ada banyak data. DenseNet-121 sangat ideal untuk aplikasi yang datanya tidak terlalu banyak karena dirancang untuk sangat menghemat parameter dengan tetap mempertahankan kinerja tinggi.

Tabel 3. Hasil *Training Model*

	Training	Validation
Accuracy	97,73%	98,18%
Loss	7,19%	8,64%

Hasil model pada Tabel 3 dalam nilai *accuracy* menunjukkan nilai *validation accuracy* lebih tinggi dari nilai *training accuracy*. Nilai *training loss* sedikit lebih rendah daripada nilai *validation loss*, meskipun ada perbedaan selisih 1,45% namun dengan angka tersebut tidak menunjukkan perbedaan yang jauh. Melihat dari hasil *training*, model belajar dengan baik dan model menunjukkan tidak mengalami *overfitting*.

5. Kesimpulan dan Saran

5.1 Kesimpulan

Berdasarkan hasil dan analisis yang dilakukan dalam penelitian ini, dapat disimpulkan bahwa model *Convolutional Neural Network* (CNN) yang dibangun dengan arsitektur DenseNet-121 sangat baik dalam mengklasifikasikan penyakit batu ginjal. DenseNet-121 memiliki keunggulan dalam penggunaan kembali fitur atau penggunaan kembali fitur yang memungkinkan model untuk belajar representasi fitur yang lebih luas. Selain itu, arsitektur ini memecahkan masalah *vanishing gradient* yang sangat umum di jaringan yang sangat dalam. Teknik pra-pemrosesan data seperti augmentasi gambar sangat penting untuk meningkatkan kinerja model. Augmentasi gambar membantu meningkatkan keragaman dataset dan mencegah *overfitting*.

Hasil penelitian menunjukkan bahwa model memiliki akurasi pelatihan dan akurasi validasi yang dapat digeneralisasi dengan baik. Dalam penelitian ini, hasil *confusion matrix* menunjukkan akurasi 98,18%, *precision* 96,36%, *recall* 100%, dan *F1-score* 98,14%. Oleh karena itu, metode CNN dengan arsitektur DenseNet-121 terbukti berhasil dalam klasifikasi penyakit batu ginjal. Ini juga merupakan kemajuan besar dalam bidang diagnosis medis berbasis AI. Untuk membuat klasifikasi lebih mudah bagi *user* atau dokter, *deployment* dapat dilakukan dengan mudah.

5.2 Saran

Penelitian selanjutnya dapat pengembangan lebih lanjut untuk *deployment* aplikasi web dengan *hosting* atau *cloud*.

Referensi

- [1] E. Hadibrata dan Suharmanto, "Faktor-Faktor Yang Berhubungan Dengan Terjadinya Batu Ginjal," *Jurnal Penelitian Perawat Profesional*, vol. 4, no. 3, pp. 1041–1046, 2022. [Online]. Available: <http://jurnal.globalhealthsciencegroup.com/index.php/JPPP>.
- [2] P. M. Ferraro, M. Bargagli, A. Trinchieri, G. Gambaro, dan D. G. Assimos, "Re: Risk of Kidney Stones: Influence of Dietary Factors, Dietary Patterns, and Vegetarian-Vegan Diets," *Journal of Urology*, vol. 204, no. 3, p. 612, 2020, doi: 10.1097/JU.0000000000001173.01.
- [3] M. Aljawad, F. A. Alaithan, B. S. Bukhamsin, dan A. A. Alawami, "Assessing the Diagnostic Performance of CT in Suspected Urinary Stones: A Retrospective Analysis," *Cureus*, vol. 15, no. 4, 2023, doi: 10.7759/cureus.37699.
- [4] A. Hasby Bik, F. Tri Anggraeny, dan E. Yulia Puspaningrum, "Klasifikasi penyakit ginjal menggunakan algoritma hibrida CNN-ELM," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 3, pp. 3836–3844, 2024, doi: 10.36040/jati.v8i3.9807.
- [5] D. Gunawan dan H. Setiawan, "Convolutional Neural Network dalam Analisis Citra Medis," *Konstelasi Konvergensi Teknologi dan Sistem Informasi*, vol. 2, no. 2, pp. 376–390, 2022, doi: 10.24002/konstelasi.v2i2.5367.
- [6] L. Chipindu, W. Mupangwa, J. Mtsilizah, I. Nyagumbo, dan 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, 2020, doi: 10.3390/ai1030024.
- [7] Y. Omori, "Image Augmentation for Eye Contact Detection Based on Combination of Pre-trained Alex-Net CNN and SVM," *Journal of Computers*, vol. 15, no. 3, pp. 85–97, 2020, doi: 10.17706/jcp.15.3.85-97.
- [8] A. S. Vellaichamy, A. Swaminathan, C. Varun, dan K. S., "Multiple Plant Leaf Disease Classification Using Densenet-121 Architecture," *International Journal of Electrical Engineering and Technology*, vol. 12, no. 5, pp. 38–57, 2021, doi: 10.34218/ijeet.12.5.2021.005.

- [9] S. Gulavnai dan R. Patil, "Deep Learning for Image Based Mango Leaf Disease Detection," *International Journal of Recent Technology and Engineering*, vol. 8, no. 3S3, pp. 54–56, 2019, doi: 10.35940/ijrte.c1030.1183s319.
- [10] F. N. Cahya, N. Hardi, D. Riana, dan S. Hadiyanti, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," *Sistemasi*, vol. 10, no. 3, p. 618, 2021, doi: 10.32520/stmsi.v10i3.1248.
- [11] F. A. A. Harahap, R. M. Sinaga, K. Arifin, dan K. S., "Implementation of Convolutional Neural Network for Detecting Kidney Disease," *Teknologi Informasi, Komputer dan Aplikasi*, vol. 4, no. 2, pp. 212–219, 2022. [Online]. Available: <http://jtika.if.unram.ac.id/index.php/JTIKA/>.
- [12] N. Sulaksono et al., "Jurnal Imejing Diagnostik," *Jurnal Imejing Diagnostik*, vol. 6, p. 103, 2020. [Online]. Available: <http://ejournal.poltekkes-smg.ac.id/ojs/index.php/jimed/index>
- [13] R. Yohannes and M. E. Al Rivan, "Klasifikasi jenis kanker kulit menggunakan CNN-SVM," *Jurnal Algoritme*, vol. 2, no. 2, pp. 133–144, 2022, doi: 10.35957/algoritme.v2i2.2363.
- [14] P. Rahayu et al., "Data preprocessing in data mining," in *Buku Ajar Data Mining*, 1st ed., Yogyakarta, Indonesia: Penerbit Universitas Gadjah Mada, 2024, chap. 2, pp. 45–60.
- [15] A. S. J. Putra, I. M. I. Subroto, and B. S. W. Poetro, "Identifikasi kematangan buah jeruk medan menggunakan K-nearest neighbor berbasis metrik RGB," *Jurnal Transistor Elektro dan Informatika (TRANSISTOR EI)*, vol. 5, no. 3, p. 50112, 2023. [Online]. Available: <http://jurnal.unissula.ac.id/online/index.php/EI>.
- [16] S. Satwikayana, S. Adi Wibowo, and N. Vendyansyah, "Sistem presensi mahasiswa otomatis pada zoom meeting menggunakan face recognition dengan metode convolutional neural network berbasis web," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 5, no. 2, pp. 785–793, 2021, doi: 10.36040/jati.v5i2.3762.
- [17] U. Khultsum and G. Taufik, "Komparasi kinerja DenseNet 121 dan MobileNet untuk klasifikasi citra penyakit daun kentang," *JURIKOM (Jurnal Riset Komputer)*, vol. 10, no. 2, p. 558, 2023, doi: 10.30865/jurikom.v10i2.6047.