

**KLASIFIKASI PENYAKIT BATU GINJAL MENGGUNAKAN
ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) DAN
SUPPROT VECTOR MACHINE (SVM)**

(Skripsi)

Oleh

**YUNA MEISA PUTRI
NPM 2117051041**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

**KLASIFIKASI PENYAKIT BATU GINJAL MENGGUNAKAN
ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) DAN
SUPPROT VECTOR MACHINE (SVM)**

Oleh

**YUNA MEISA PUTRI
NPM 2117051041**

(Skripsi)

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA ILMU KOMPUTER**

**Pada
Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRAK

KLASIFIKASI PENYAKIT BATU GINJAL MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) DAN *SUPPORT VECTOR MACHINE* (SVM)

Oleh

YUNA MEISA PUTRI

Batu ginjal merupakan salah satu penyakit serius yang dapat mengganggu fungsi ginjal dan menimbulkan komplikasi, sehingga deteksi dini menjadi sangat penting. Penelitian ini mengembangkan model klasifikasi citra medis untuk membedakan ginjal normal dan ginjal dengan batu ginjal menggunakan pendekatan *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM). *Dataset* berupa citra *CT Scan* diperoleh dari Kaggle dan diproses melalui tahap segmentasi, *cropping*, *resize*, serta augmentasi untuk meningkatkan kualitas data. Model CNN dirancang sebagai *deep learning classifier*, sedangkan SVM menggunakan fitur *Histogram of Oriented Gradients* (HOG) dengan beberapa kernel. Evaluasi dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *f1-score* pada data validasi dan uji. Hasil penelitian menunjukkan bahwa CNN mencapai akurasi 97% pada data validasi dan 94% pada data uji dengan *precision*, *recall*, dan *f1-score* yang seimbang dikedua kelas. Sementara itu, SVM dengan kernel sigmoid menghasilkan akurasi 73% pada validasi dan 67% pada data uji, namun masih lemah dalam mendeteksi kelas *Kidney_stone*. Secara keseluruhan, model CNN terbukti lebih unggul dibandingkan SVM dalam menangani variasi citra medis, sehingga memiliki potensi besar sebagai sistem pendukung diagnosis batu ginjal secara otomatis.

Kata Kunci : *Convolutional Neural Network*, *Support Vector Machine*, Batu Ginjal.

ABSTRACT

CLASSIFICATION OF KIDNEY STONE DISEASE USING CONVOLUTIONAL NEURAL NETWORK (CNN) AND SUPPORT VECTOR MACHINE (SVM) ALGORITHMS

By

YUNA MEISA PUTRI

Kidney stones are a serious medical condition that can impair kidney function and lead to complications, making early detection highly important. This study develops a medical image classification model to distinguish between normal kidneys and kidneys with stones using Convolutional Neural Network (CNN) and Support Vector Machine (SVM) approaches. The dataset, consisting of CT Scan images, was obtained from Kaggle and processed through segmentation, cropping, resizing, and augmentation to improve data quality. CNN was designed as a deep learning classifier, while SVM utilized Histogram of Oriented Gradients (HOG) features with multiple kernels. The evaluation was conducted using accuracy, precision, recall, and f1-score metrics on validation and test data. The results show that CNN achieved 97% accuracy on validation data and 94% accuracy on test data, with balanced precision, recall, and f1-score for both classes. Meanwhile, SVM with the sigmoid kernel achieved 73% accuracy on validation and 67% accuracy on test data, but performed poorly in detecting the Kidney_stone class. Overall, CNN outperformed SVM in handling variations of medical images, demonstrating strong potential as an automated decision-support system for kidney stone diagnosis.

Keywords : Convolutional Neural Network, Support Vector Machine, Kidney Stone.

Judul Skripsi : **KLASIFIKASI PENYAKIT BATU GINJAL
MENGUNAKAN ALGORITMA
CONVOLUTIONAL NEURAL NETWORK
(CNN) DAN SUPPORT VECTOR MACHINE
(SVM)**

Nama Mahasiswa : **Yuna Meisa Putri**

Nomor Pokok Mahasiswa : **2117051041**

Program Studi : **S1 Ilmu Komputer**

Jurusan : **Ilmu Komputer**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



MENYETUJUI

Komisi Pembimbing

an. seljur

a.k

Dr. rer. nat. Akmal Junaidi, M.Sc.
NIP. 197101291997021001

Dewi Asiah Shofiana, S.Komp., M.Kom.
NIP. 199509292020122030

MENGETAHUI

Ketua Jurusan Ilmu Komputer

Ketua Program Studi S1 Ilmu Komputer

Dwi Sakethi, S.Si. M.Kom.
NIP. 196806111998021001


Tristiyanto, S.Kom., M.I.S., Ph.D.
NIP. 198104142005011001

MENGESAHKAN

1. Tim Penguji


Ketua Penguji : **Dr. rer. nat. Akmal Junaidi, M.Sc.**

gh.





Sekretaris
Penguji : **Dewi Asiah Shofiana, S.Komp., M.Kom.**

an.




Penguji Utama : **Prof. Admi Syarif, Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 197110012005011002



Tanggal Lulus Ujian Skripsi : 23 September 2025

PERNYATAAN

Saya yang bertanda tangan di bawah ini :

Nama : Yuna Meisa Putri

NPM : 2117051041

Menyatakan bahwa skripsi saya dengan judul "**KLASIFIKASI PENYAKIT BATU GINJAL MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK (CNN)* DAN *SUPPROT VECTOR MACHINE (SVM)***" merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil penjiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang telah saya terima.

Bandar Lampung, 7 Oktober 2025



Yuna Meisa Putri

NPM. 2117051041

RIWAYAT HIDUP



Penulis lahir di Dayamurni, Tulang Bawang Barat pada tanggal 10 Mei 2003. Anak pertama dari tiga bersaudara, dari Bapak Yusmadi dan Ibu Erlina Wati. Penulis menyelesaikan pendidikan di SDN 3 Dayamurni pada Tahun 2015. Kemudian menyelesaikan pendidikan menengah pertama di SMPN 1 Tulang Bawang Udik pada Tahun 2018 dan lulus dari pendidikan menengah atas di SMAN 1 Tumijajar pada Tahun 2021. Pada Tahun 2021 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SNMPTN. Selama menjadi mahasiswa, penulis melakukan beberapa kegiatan antara lain.

1. Menjadi Anggota Bidang Kaderisasi Himpunan Mahasiswa Jurusan Ilmu Komputer (HIMAKOM) Periode 2022/2023.
2. Menjadi Anggota Bidang Kaderisasi Himpunan Mahasiswa Jurusan Ilmu Komputer (HIMAKOM) Periode 2023/2024.
3. Melakukan Kerja Praktik di Bidang Hubungan Masyarakat Polda Lampung Periode 2023/2024.
4. Mengikuti Kuliah Kerja Nyata (KKN) pada periode II Tahun 2024 di Desa Cempaka Nuban Kecamatan Batang Hari Nuban Kabupaten Lampung Timur.
5. Menjad Asisten Dosen pada mata kuliah Pengenalan Pola Semester Ganjil Tahun Ajaran 2024/2025.

MOTTO

“Karena sesungguhnya sesudah kesulitan itu ada kemudahan”

(QS. Al-Insyirah : 5)

“Jadikan hinaan sebagai tamparan untuk bangkit menjadi lebih baik”

(Ayah dan Ibu)

PERSEMBAHAN

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Alhamdulillah Rabbil 'Alamin

Puji dan syukur tercurahkan kepada Allah Subhanahu Wa Ta'ala atas segala Rahmat dan Karunia-Nya sehingga dapat menyelesaikan skripsi ini. Shalawat serta salam selalu tercurahkan Kepada Nabi Muhammad SAW.

Kupersembahkan karya ini kepada :

Keluarga Tercinta

Ayah, Ibu, dan Adik-adikku

Yang senantiasa memberikan yang terbaik dan melantunkan do'a yang selalu menyertaiku. Kuucapkan pula terima kasih sebesar-besarnya kepada Ayah dan Ibu karena telah mendidik dan membesarkanku dengan cara yang dipenuhi kasih sayang, dukungan dan pengorbanan. Kupersembahkan semua ini untuk kalian, tanpa kalian semua ini tidak akan mungkin terwujud. Setiap langkah yang kuambil adalah hasil dari cinta dan kerja keras kalian.

Seluruh Keluarga Besar Ilmu Komputer 2021

yang selalu memberikan semangat dan dukungan.

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

tempat menimba ilmu untuk menjadi bekal hidup dunia dan akhirat.

SANWACANA

Alhamdulillah Rabbil'Alamin. Segala puji dan syukur penulis panjatkan kehadirat Allah Subhanahu Wa Ta'ala yang telah memberikan nikmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi ini. Sholawat serta salam penulis sanjungkan kepada Baginda Nabi Muhammad Shallallahu'Alaihi Wasallam yang penulis harapkan syafaatnya di hari akhir kelak.

Skripsi yang berjudul "Klasifikasi Penyakit Batu Ginjal Menggunakan Algoritma *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM)" ini disusun sebagai salah satu syarat untuk memperoleh gelar sarjana Ilmu Komputer Universitas Lampung. Selesaiannya skripsi ini tidak terlepas dari bantuan, bimbingan dan dukungan dari berbagai pihak. Oleh karena itu, ucapan terima kasih ditujukan kepada:

1. Allah Subhanahu Wa Ta'ala yang telah memberikan nikmat kesehatan dan kemampuan untuk menyelesaikan skripsi ini.
2. Ayahanda tercinta Yusmadi, Ibunda tercinta Erlina Wati, Adikku Melly Saputri dan Akbar Okta Saputra serta Keluarga besar yang selalu memberikan do'a, kasih sayang dan dukungan.
3. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan FMIPA Universitas Lampung.
4. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
5. Ibu Yunda Heningtyas, M.Kom. selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.

6. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D. selaku Ketua Program Studi S1 Ilmu Komputer
7. Bapak Dr. Aristoteles, S.Si., M.Si. sebagai Dosen Pembimbing Akademik yang telah memberikan arahan, ide, motivasi dan dukungan akademik penulis.
8. Bapak Dr. rer. nat Akmal Junaidi, M.Sc. sebagai Dosen Pembimbing Utama yang telah memberikan arahan, ide, motivasi, kritik serta saran kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik.
9. Ibu Dewi Asiah Shofiana, S.Komp., M.Kom. sebagai Dosen Pembimbing 2 yang telah memberikan arahan, ide, motivasi, kritik serta saran kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik.
10. Bapak Prof. Admi Syarif, Ph.D sebagai Dosen Pembahas yang telah memberikan masukan yang bermanfaat dalam perbaikan skripsi ini.
11. Ibu Ade Nora Maela, Bang Zainuddin, Mas Nofal dan Mas Sam yang telah membantu segala urusan administrasi penulis di Jurusan Ilmu Komputer.
12. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan ilmu dan pengalaman dalam hidup untuk menjadi lebih baik.
13. Keluarga grup whatsapp Kontrakan Rempongzz dan Sahabat Jannah yang telah menemani masa-masa awal sampai akhir perkuliahan, selalu memberikan dukungan dan doa kepada penulis.
14. Keluarga Besar Ilmu Komputer 2021 yang tidak bisa penulis sebutkan satu persatu.

Bandar Lampung, 7 Oktober 2025



Yuna Meisa Putri

NPM. 2117051041

DAFTAR ISI

	Halaman
DAFTAR TABEL.....	xv
DAFTAR GAMBAR	xvi
DAFTAR KODE PROGRAM	xvii
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian	4
II. TINJAUAN PUSTAKA	6
2.1 Klasifikasi	6
2.2 Batu Ginjal	6
2.3 Penelitian Terdahulu.....	7
2.4 <i>Deep Learning</i>	10
2.5 <i>Convolutional Neural Network (CNN)</i>	11
2.5.1 <i>Convolutional Layer</i>	12
2.5.2 ReLU	13
2.5.3 <i>Pooling Layer</i>	13
2.5.4 <i>Fully Connected Layer</i>	14

2.6	<i>Support Vector Machine (SVM)</i>	15
2.6.1	<i>Histogram Of Oriented Gradients (HOG)</i>	17
2.7	<i>CT Scan dan MRI</i>	18
2.8	<i>Confusion Matrix</i>	20
2.8.1	<i>Accuracy (Akurasi)</i>	21
2.8.2	<i>Precision (Presisi)</i>	21
2.8.3	<i>Recall</i>	21
2.8.4	<i>F1-Score</i>	21
2.8.5	<i>Macro Average</i>	21
2.8.6	<i>Weighted Average</i>	22
III.	METODOLOGI PENELITIAN.....	23
3.1	Waktu dan Tempat Penelitian.....	23
3.2	Data Penelitian	23
3.3	Alat Pendukung.....	24
3.3.1	Perangkat Keras (<i>Hardware</i>).....	24
3.3.2	Perangkat Lunak (<i>Software</i>).....	24
3.4	Alur Kerja Penelitian.....	28
3.4.1	Input Data.....	28
3.4.2	<i>Preprocessing</i> Data.....	28
3.4.3	<i>Training</i> Model	30
3.4.4	<i>Testing</i> Model.....	31
3.4.5	Evaluasi Model.....	31
IV.	HASIL DAN PEMBAHASAN.....	32
4.1	Deskripsi Umum <i>Dataset</i>	32
4.2	<i>Preprocessing</i> Data	33
4.2.1	Segmentasi	33

4.2.2	<i>Cropping dan Resize Citra</i>	35
4.2.3	Augmentasi Data.....	36
4.2.4	<i>Split Data</i>	38
4.3	<i>Training Model</i>	39
4.3.1	<i>Training Model CNN</i>	39
4.3.2	<i>Training Model SVM</i>	41
4.4	<i>Testing Model</i>	44
4.4.1	<i>Testing Model CNN</i>	44
4.4.2	<i>Testing Model SVM</i>	45
4.5	Evaluasi Model.....	47
4.5.1	Evaluasi Model CNN	47
4.5.2	Evaluasi Model SVM.....	52
4.6	<i>Analisis Misclassification</i>	58
V.	SIMPULAN DAN SARAN.....	62
5.1	Simpulan	62
5.2	Saran.....	63
	DAFTAR PUSTAKA	64
	LAMPIRAN.....	71

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu.....	8
2. <i>Confusion Matrix</i>	20
3. Kategori <i>Dataset</i>	24
4. <i>Classification Report</i> Model CNN pada data <i>validation</i>	50
5. <i>Classification Report</i> Model CNN pada data <i>test</i>	52
6. Akurasi Training dan Validasi untuk setiap kernel.....	53
7. <i>Classification Report</i> Model SVM untuk data <i>validation</i>	55
8. <i>Classification Report</i> Model SVM untuk data <i>test</i>	57
9. Jumlah <i>Misclassification</i> Citra.....	59

DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur CNN (Phung & Rhee, 2019).	11
2. Contoh <i>Max Pooling</i> (Zafaret al, 2022)	14
3. Ilustrasi <i>Linear SVM</i> Sumber (Barui et al., 2018b).....	15
4. Citra <i>CT Scan</i> dari Kaggle	19
5. Alur Penelitian.....	29
6. Perbandingan Citra Sebelum dan Sesudah Disegmentasi.	34
7. Hasil <i>Cropping</i> dan <i>Resize Image</i>	36
8. Contoh Citra Augmentasi	37
9. Grafik Akurasi CNN	47
10. Grafik <i>Loss</i> CNN	48
11. <i>Confusion Matrix Validation</i> CNN.....	50
12. <i>Confusion Matrix</i> Data <i>Test</i> CNN	51
13. <i>Confusion Matrix</i> SVM untuk Data <i>validation</i>	54
14. <i>Confusion Matrix</i> SVM untuk Data <i>Test</i>	56
15. Citra Batu Ginjal yang Mengalami <i>Misclassification</i>	60
16. Citra Ginjal Normal yang Mengalami <i>Misclassification</i>	60

DAFTAR KODE PROGRAM

Kode Progam	Halaman
1. Segmentasi	33
2. Ekstraksi Fitur Segmentasi.....	34
3. <i>Cropping</i> dan <i>Resize Image</i>	35
4. Augmentasi.....	36
5. <i>Split</i> Data.....	38
6. Model CNN.....	40
7. Klasifikasi Biner.....	40
8. Kompilasi Model.....	41
9. Ekstraksi fitur HOG	42
10. <i>Grid Search</i>	43
11. <i>Load</i> Data Uji.....	45
12. Evaluasi Model CNN	45
13. Ekstrak fitur HOG untuk Data Uji	46

I. PENDAHULUAN

1.1 Latar Belakang

Penyakit batu ginjal merupakan salah satu masalah kesehatan serius yang dapat mengganggu fungsi ginjal dan menyebabkan komplikasi seperti nyeri akut, infeksi, hingga gagal ginjal. Deteksi dini dan diagnosis yang tepat sangat penting untuk memastikan penanganan medis yang efektif. Saat ini, metode diagnosis batu ginjal secara manual melalui analisis citra medis seperti *CT scan* dan MRI banyak digunakan. Seiring dengan kemajuan teknologi, pendekatan berbasis kecerdasan buatan *Artificial Intelligence* (AI) menjadi alternatif yang potensial, terutama melalui integrasi algoritma *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM).

Meskipun *CT Scan* dianggap sebagai standar emas (*gold standard*) dalam mendeteksi batu ginjal, sensitivitas 94-97% dan spesifisitas 96-100% proses diagnosis berbasis visual tidak lepas dari tantangan (Modi & Lin, 2024). Interpretasi citra medis sangat bergantung pada pengalaman dan keahlian dokter, serta dapat dipengaruhi oleh ukuran, jumlah maupun lokasi batu ginjal. Penelitian yang dilakukan oleh (Tzou et al., 2018) menunjukkan bahwa adanya perbedaan yang signifikan antara hasil pembacaan citra oleh dokter radiologi dan urolog. Tingkat kesesuaian ukuran batu hanya sekitar 63% pada kasus batu tunggal, tetapi turun drastis menjadi 32% pada kasus batu multiple. Bahkan lebih dari 33% laporan radiologi menunjukkan ketidakjelasan ukuran atau perbedaan pengukuran yang dapat memengaruhi keputusan klinis. Hal ini menandakan bahwa eksplorasi visual dokter dalam mendiagnosis citra CT

Scan masih menghadapi keterbatasan sehingga berpotensi menimbulkan perbedaan diagnosis antar tenaga medis.

Selain itu, aspek visualisasi citra medis juga memiliki keterbatasan. Sebagian besar laporan radiologi hanya mendeskripsikan ukuran batu berdasarkan potongan aksial, padahal pada potongan koronal sering kali ditemukan dimensi maksimal yang lebih akurat. Namun demikian, laporan ukuran maksimal dari pandangan koronal hanya dilaporkan kurang dari 20% kasus (Tzou et al., 2018). Kondisi ini menunjukkan bahwa dokter terkadang masih mengandalkan estimasi visual tanpa melakukan eksplorasi citra secara menyeluruh antar interpretasi pembaca citra, tetapi juga berpotensi memengaruhi pemilihan terapi yang paling tepat bagi pasien. Oleh sebab itu, keterbatasan dalam eksplorasi visual citra medis memperkuat urgensi pengembangan sistem berbasis kecerdasan buatan yang mampu memberikan analisis secara lebih konsisten, objektif dan akurat.

Dalam konteks tersebut, penerapan AI menjadi semakin relevan. CNN dikenal sebagai algoritma yang unggul dalam analisis citra karena kemampuannya dalam mengekstraksi fitur kompleks secara otomatis. Namun, CNN memiliki keterbatasan dalam hal klasifikasi presisi tinggi, terutama pada *dataset* yang tidak seimbang atau memiliki *noise*. Di sisi lain, SVM adalah algoritma klasifikasi yang tangguh dalam menangani dimensi tinggi dan memiliki margin klasifikasi yang optimal. Kombinasi CNN dan SVM menawarkan potensi untuk mengatasi kelemahan masing-masing algoritma, di mana CNN berfungsi sebagai ekstraktor fitur, dan SVM bertindak sebagai pengklasifikasi berbasis *margin*. Pendekatan ini telah diaplikasikan dalam berbagai studi untuk meningkatkan akurasi diagnosis berbasis citra medis, termasuk untuk klasifikasi penyakit ginjal (Reddy et al., 2023).

CNN adalah algoritma yang dikenal efektif dalam mengekstraksi fitur dari citra medis, sedangkan SVM unggul dalam tugas klasifikasi, bahkan pada *dataset* dengan dimensi tinggi. Kombinasi kedua metode ini memungkinkan pengelolaan data yang lebih efisien dan akurat. Studi oleh (Gill et al., 2023) menggunakan DenseNet201 untuk klasifikasi penyakit ginjal berbasis gambar X-ray, dengan akurasi awal pada beberapa tahap mencapai kisaran 70%-80%, menunjukkan perlunya optimalisasi model. Sementara itu, (George & HB, 2022) menggunakan ResNet-50 untuk ekstraksi fitur dan SVM sebagai pengklasifikasi, menghasilkan akurasi yang beragam tergantung pada kualitas *preprocessing* data. Dalam studi lain, (Navaneeth & Suchetha, 2020) melaporkan bahwa akurasi model awal hanya mencapai 76% sebelum optimalisasi dilakukan melalui algoritma *dynamic pooling* dan *pruning* fitur.

Namun demikian, penerapan CNN dan SVM dalam klasifikasi batu ginjal tidak lepas dari tantangan, termasuk kebutuhan akan *dataset* besar yang representatif, proses komputasi yang kompleks, dan kendala dalam interpretasi hasil yang dapat diandalkan dalam konteks klinis. Meskipun demikian, dengan perkembangan teknologi komputasi dan meningkatnya ketersediaan data medis, CNN dan SVM terus menunjukkan potensi sebagai alat diagnostik yang andal, efisien, dan dapat diterapkan dalam skala luas. Solusi berbasis AI ini tidak hanya mempercepat proses diagnosis, tetapi juga memungkinkan deteksi dini yang lebih akurat, sehingga meningkatkan efisiensi dan efektivitas perawatan pasien secara keseluruhan.

1.2 Rumusan Masalah

Berdasarkan uraian pada latar belakang, maka rumusan yang didapat yaitu:

- a. Bagaimana mengimplementasikan algoritma *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM) untuk klasifikasi batu ginjal berdasarkan citra medis?

- b. Bagaimana metode CNN dan SVM dalam memberikan akurasi dan diagnosis dari hasil klasifikasi batu ginjal?

1.3 Batasan Masalah

Batasan masalah dari penelitian ini yaitu :

- a. Penelitian hanya fokus pada klasifikasi penyakit batu ginjal dan *dataset* harus melalui tahap segmentasi dan *cropping*.
- b. Penelitian ini akan fokus pada analisis *dataset CT scan* untuk deteksi batu ginjal yang terdapat di Kaggle dengan judul “*Kidney Stones MRI and CT Scans*”.
- c. Model yang diterapkan adalah *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM), dan tidak membandingkan performa dengan metode *deep learning* lainnya.

1.4 Tujuan Penelitian

Adapun tujuan yang ingin dicapai dari penelitian ini adalah sebagai berikut:

- a. Menerapkan metode *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM) untuk melakukan klasifikasi penyakit batu ginjal.
- b. Menganalisa hasil tingkat klasifikasi batu ginjal dari *CT Scan* menggunakan metrik evaluasi seperti akurasi, *precision*, *recall*, dan *F1-score*.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini yaitu:

- a. Memberikan rujukan untuk pengembangan sistem pendukung keputusan medis menggunakan model *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM) dalam klasifikasi batu ginjal berdasarkan citra *CT Scan*.

- b. Memberikan kontribusi ilmiah mengenai penerapan metode *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM) untuk klasifikasi batu ginjal berbasis citra *CT Scan*.
- c. Bagi praktiksi medis, model klasifikasi ini dapat digunakan sebagai alternatif interpretasi hasil diagnosa awal sehingga dapat membantu pihak rumah sakit atau instansi medis untuk tidak lanjut yang tepat.

II. TINJAUAN PUSTAKA

2.1 Klasifikasi

Klasifikasi adalah proses pengelompokan atau pemetaan data ke dalam kategori atau kelas tertentu berdasarkan karakteristik yang telah dipelajari sebelumnya. Dalam *machine learning* dan kecerdasan buatan, klasifikasi merupakan salah satu tugas utama dimana model dilatih untuk mengenali pola dalam data dan kemudian mengelompokkan data baru ke dalam kategori yang sesuai (Deshmukh, 2023).

Dalam pengolahan citra dan *computer vision*, klasifikasi sering diterapkan untuk mengenali objek dalam gambar, seperti identifikasi diagnosis penyakit dari citra medis, dan sebagainya. Salah satu metode yang paling efektif dalam tugas ini adalah *Convolutional Neural Network* (CNN), yang bekerja dengan mengekstraksi fitur dari gambar secara otomatis dan mengelompokkannya ke dalam kategori tertentu. CNN telah digunakan dalam berbagai aplikasi, seperti deteksi kanker dari citra MRI dan pengenalan objek dalam kendaraan otonom (Heru et al., 2022).

2.2 Batu Ginjal

Batu ginjal atau *nefrolitiasis*, adalah endapan keras yang terbentuk di ginjal akibat pengendapan mineral dan garam dalam urin. Proses ini terjadi ketika urin menjadi terlalu pekat, sehingga memungkinkan mineral seperti kalsium oksalat, kalsium fosfat dan asam urat untuk mengkristal dan membentuk batu. Faktor risiko utama meliputi dehidrasi, pola makan tinggi oksalat dan protein, obesitas serta gangguan metabolisme seperti diabetes dan hipertensi. Studi terbaru menunjukkan bahwa *neutrophil extracellular traps* (NETs) berperan dalam pembentukan batu ginjal

dengan memicu peradangan dan meningkatkan endapan mineral di ginjal (Ning et al., 2024).

Pengelolaan batu ginjal melibatkan strategi *preventing* dan terapeutik, termasuk peningkatan asupan cairan, modifikasi diet, dan terapi farmakologis. Dalam kasus yang lebih kompleks, prosedur medis seperti litoripsi gelombang kejut *Extracorporeal Shock Wave Lithotripsy* (ESWL) dan *ureteroskopi* fleksibel digunakan untuk menghancurkan atau mengangkat batu ginjal. Penelitian terbaru menunjukkan bahwa kombinasi teknik tekanan negatif dengan ureteroskopi fleksibel dalam mode rawat jalan efektif dalam menghilangkan batu ginjal berukuran kecil dengan tingkat komplikasi yang rendah (Ma et al., 2024). Selain itu, studi antropometri menemukan bahwa tipe tubuh tertentu lebih rentan terhadap pembentukan batu ginjal, menyoroti pentingnya pendekatan yang dipersonalisasi dalam pencegahan (Konjengbam et al., 2024).

2.3 Penelitian Terdahulu

Penelitian terkait klasifikasi penyakit batu ginjal menggunakan citra medis menjadi salah satu fokus utama dalam bidang medis dan teknologi kecerdasan buatan. Deteksi dini dan klasifikasi yang akurat sangat penting untuk menentukan langkah pengobatan yang tepat dan mencegah komplikasi lebih lanjut. Seiring dengan kemajuan teknologi, berbagai pendekatan telah dilakukan, mulai dari metode berbasis fitur hingga teknik *deep learning* yang lebih canggih. Studi tentang klasifikasi batu ginjal secara otomatis semakin berkembang secara global, sementara di Indonesia penelitian terkait masih dalam tahap eksplorasi dengan keterbatasan akses terhadap *dataset* yang besar dan berkualitas tinggi. Penelitian terdahulu dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terdahulu

Peneliti	Judul	Data	Metode	Hasil
Gill et al. (2023)	<i>Kidney Disease Classification Using Machine Learning Approach on DenseNet201 Model using X-ray Images</i>	500 citra x-ray	DenseNet201	Akurasi mencapai 70%-80%
George & Hb (2022)	<i>ResNet-50 and SVM for Kidney Stone Classification</i>	1500 citra batu ginjal	ResNet-50 + SVM	Akurasi mencapai 86,2%
Dwivedi & Singhal (2022)	<i>Classification and Segmentation of MRI Brain Images using Support Vector Machine and Fuzzy C-means Clustering</i>	800 citra MRI	CNN, Dynamic Pooling, SVM	Akurasi mencapai 76% sampai 88%
(Chen et al., 2024)	<i>Comprehensive 3D Analysis of the Renal System and Stones: Segmenting and Registering Non-Contrast and Contrast Computed Tomography Images</i>	1392 CT scan (464 pasien, 2014–2022)	3D U-Net, ResU-Net, Swin UNETR.	Swin UNETR terbaik untuk ginjal (Dice 95,21%), ResU-Net terbaik untuk batu ginjal (Dice 87,69%)

Pada Tabel 1, penelitian berjudul “*Kidney Disease Classification Using Machine Learning Approach on DenseNet201 Model using X-ray Images*” (Gill et al., 2023) menggunakan model DenseNet201 untuk klasifikasi penyakit ginjal berdasarkan citra X-ray. Penelitian ini menggunakan

dataset 500 citra dan mencapai akurasi antara 70%-80% tergantung pada parameter model yang digunakan. Hasil penelitian menunjukkan bahwa optimalisasi model sangat diperlukan untuk meningkatkan akurasi klasifikasi.

Pada Tabel 1, studi yang dilakukan oleh (George & HB, 2022) yang berjudul “*ResNet-50 and SVM for Kidney Stone Classification*”, mereka menerapkan arsitektur ResNet-50 untuk ekstraksi fitur dan SVM sebagai model klasifikasi utama. Dengan menggunakan *dataset* 1500 citra batu ginjal, penelitian ini memperoleh akurasi maksimal sebesar 86,2%. Studi ini menekankan bahwa *preprocessing* data yang baik serta pemilihan parameter model sangat berpengaruh terhadap performa akhir sistem klasifikasi.

Pada Tabel 1 jurnal yang berjudul “*Classification and Segmentation of MRI Brain Images using Support Vector Machine and Fuzzy C-means Clustering*” juga melakukan penelitian dengan pendekatan yang berbeda, yaitu dengan mengoptimalkan model CNN melalui teknik *dynamic pooling* dan *pruning* fitur sebelum diklasifikasikan menggunakan SVM. Dengan *dataset* sebanyak 800 citra, akurasi awal model hanya mencapai 76%, namun setelah optimalisasi meningkat hingga 88%. Hal ini menunjukkan bahwa pendekatan optimalisasi sangat berperan dalam meningkatkan performa model (Dwivedi & Singhal, 2022).

Pada Tabel 1 jurnal studi yang dilakukan oleh (Chen et al., 2024) berjudul “*Comprehensive 3D Analysis of the Renal System and Stones: Segmenting and Registering Non-Contrast and Contrast Computed Tomography Images*” mengusulkan model *ensemble* yang mengintegrasikan *segmentation* dan *registration* untuk membangun rekonstruksi 3D ginjal beserta batu ginjalnya. *Dataset* penelitian ini terdiri dari 1392 *CT scan* milik 464 pasien dengan tiga fase (NCT, CTC, dan CTE). Hasil eksperimen menunjukkan bahwa *Swin UNETR* mencapai nilai *Dice*

tertinggi pada segmentasi ginjal (95,21%), sedangkan ResU-Net unggul untuk segmentasi batu ginjal dengan *Dice score* 87,69%. Studi ini menegaskan bahwa kombinasi segmentasi multi-model dan registrasi spasial antar-fase *CT Scan* sangat membantu dalam menghasilkan visualisasi anatomi ginjal yang lebih lengkap, sehingga berguna untuk diagnosis maupun perencanaan pra-operasi.

Secara keseluruhan, penelitian terdahulu menunjukkan bahwa kombinasi CNN dan SVM memiliki potensi besar dalam meningkatkan akurasi klasifikasi batu ginjal. Namun, tantangan utama yang masih dihadapi adalah keterbatasan dataset berkualitas tinggi, kompleksitas komputasi, serta kebutuhan akan optimasi model agar dapat diterapkan secara klinis dengan akurasi tinggi. Penelitian lebih lanjut diperlukan untuk mengatasi keterbatasan ini dan meningkatkan efektivitas model dalam diagnosis batu ginjal secara otomatis.


2.4 Deep Learning

Deep learning adalah cabang dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis-lapis (*deep neural networks*) untuk mengekstrak fitur dan pola dari data secara otomatis. Teknologi ini berkembang pesat sejak diperkenalkannya kembali konsep jaringan saraf yang lebih dalam pada tahun 2006. *Deep learning* mampu menangani data dalam berbagai bentuk seperti citra, teks, dan suara dengan akurasi tinggi, menjadikannya dasar bagi banyak aplikasi modern seperti pengenalan wajah, pemrosesan bahasa alami, dan kendaraan otonom. Salah satu tonggak penting dalam *deep learning* adalah pengembangan *Convolutional Neural Networks* (CNN) yang digunakan untuk klasifikasi gambar, serta *Recurrent Neural Networks* (RNN) yang diterapkan dalam analisis data berbasis urutan. Dalam pertanian presisi, *deep learning* digunakan untuk mendeteksi penyakit tanaman melalui citra satelit dan analisis spektrum cahaya. Selain itu, kombinasi *deep learning* dengan

teknik *machine learning* lainnya telah membantu meningkatkan efisiensi dalam berbagai sektor industri (Raj et al., 2024).

2.5 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah algoritma *deep learning* yang dirancang khusus untuk memproses data berbentuk *grid*, seperti gambar dan video. CNN bekerja dengan cara mengekstrak fitur penting dari data visual menggunakan lapisan-lapisan konvolusi, *pooling*, dan *fully connected*. CNN telah banyak diterapkan dalam berbagai bidang, termasuk klasifikasi gambar, segmentasi objek, serta deteksi pola dalam citra medis. Keunggulan CNN dalam menangani data visual menjadikannya alat yang sangat efektif dalam analisis citra dan video, memungkinkan model untuk mengenali pola kompleks secara otomatis tanpa rekayasa fitur manual (Purwono et al., 2022).



Gambar 1. Arsitektur CNN (Phung & Rhee, 2019).

Gambar 1 merupakan arsitektur umum CNN terdiri dari beberapa lapisan utama yang bekerja secara hierarkis. Lapisan konvolusi (*convolutional layer*) menggunakan *filter* atau kernel untuk mengekstrak fitur dari gambar, seperti tepi dan tekstur. Kemudian, lapisan *pooling* (*pooling layer*) berfungsi mengurangi dimensi fitur dengan memilih nilai maksimum (*max pooling*) atau rata-rata (*average pooling*), sehingga dapat mengurangi kompleksitas komputasi dan risiko *overfitting*. Setelah itu, lapisan *fully connected* (*fully connected layer*) bertindak sebagai klasifikator yang

menghubungkan fitur yang telah diekstraksi ke dalam kategori tertentu (Mo, 2022; Phung & Rhee, 2019).

Salah satu keunggulan utama CNN adalah kemampuannya dalam mengekstrak fitur secara otomatis, sehingga tidak memerlukan rekayasa fitur secara manual seperti metode tradisional. CNN juga memiliki sifat invarian terhadap translasi, yang memungkinkan model tetap dapat mengenali objek meskipun mengalami pergeseran posisi dalam citra. Dari segi efisiensi, CNN menggunakan *Convolutional Layer* untuk berbagi bobot, sehingga mengurangi jumlah parameter dan mempercepat proses pelatihan tanpa menurunkan akurasi. Dengan kemampuan generalisasi yang tinggi, CNN dapat diterapkan dalam berbagai tugas pemrosesan gambar tanpa perlu banyak penyesuaian. Berkat keunggulan ini, CNN menjadi salah satu model *deep learning* paling efektif dan banyak digunakan dalam *computer vision* (Purwono et al., 2022).

2.5.1 *Convolutional Layer*

Convolutional layer adalah lapisan ini dalam arsitektur CNN yang bertugas mengekstraksi fitur dari citra input. Proses ini dilakukan dengan menggunakan kernel atau fitur, yaitu matriks kecil berukuran $m \times m$ yang bergerak melintasi citra input dengan cara *sliding* (pergeseran) berdasarkan nilai *stride* tertentu. Secara teknis, kernel melakukan operasi *dot product* terhadap area lokal dari citra untuk menghasilkan *output* fitur baru yang menyoroti pola-pola penting, seperti tepi, tekstur, atau bentuk objek (Lee, 2023).

Kernel ini tidak hanya membaca satu titik, melainkan secara bertahap menyapu seluruh bagian citra melalui *receptive fields*, dan melalui proses *weight sharing*, kernel yang sama digunakan untuk mendeteksi pola berulang di berbagai area. Hal ini

membuat CNN efisien dan mampu mengenali pola yang sama meskipun dari posisi yang berbeda (Hashemi, 2019; Lee, 2023).

Untuk menjaga dimensi *output* tetap stabil, digunakan teknik *padding* di pinggiran citra. *Padding* berfungsi seperti "pinggiran roti" yang bisa diatur ketebalannya, memungkinkan kernel tetap bekerja meskipun berada di tepi gambar. Dengan demikian, *convolutional layer* menjadi lapisan utama yang mengubah citra menjadi representasi fitur yang lebih bermakna bagi proses klasifikasi selanjutnya (Hashemi, 2019) .

2.5.2 ReLU


Setelah melewati *convolutional layer*, *output* biasanya diproses oleh fungsi aktivasi. Salah satu fungsi aktivasi yang paling umum digunakan dalam CNN adalah ReLU (*Rectified Linear Unit*). Fungsi ini bekerja dengan menetapkan semua nilai negatif menjadi nol, sementara nilai positif tetap dipertahankan (Lee, 2023).

ReLU memiliki beberapa keunggulan dibandingkan fungsi aktivasi lain seperti *sigmoid* atau *tanh*, karena lebih sederhana secara komputasi dan mampu mengatasi masalah *vanishing gradient*. Namun, ReLU juga memiliki kelemahan yaitu fenomena *dead neurons*, di mana beberapa *neuron* tidak pernah aktif selama pelatihan karena nilai *output*-nya selalu nol. Untuk mengatasi ini, dikembangkan varian seperti *Parametric ReLU* dan GELU (*Gaussian Error Linear Unit*) (Lee, 2023).

2.5.3 Pooling Layer

Pooling layer adalah lapisan yang berfungsi untuk mengurangi dimensi spasial dari fitur yang dihasilkan oleh *convolutional layer*, tanpa kehilangan informasi penting. Proses ini disebut juga

subsampling atau *downsampling*. Dengan mengurangi dimensi data, *pooling* membantu mengurangi beban komputasi dan mencegah *overfitting* (Lee, 2023).



Gambar 2. Contoh *Max Pooling* (Zafaret al, 2022)

Terdapat tiga teknik *pooling* yang umum digunakan yaitu *MaxPooling* yang berfungsi untuk mengambil nilai maksimum dari area fitur, berguna untuk menonjolkan fitur domain seperti objek. Kemudian *average Pooling* yang berfungsi untuk mengambil nilai rata-rata dari area fitur berguna untuk menjaga informasi keseluruhan dan digunakan dalam deteksi objek. Dan yang terakhir yaitu *global pooling* yang berfungsi menghasilkan satu nilai tunggal dari seluruh peta fitur tetapi berisiko menyebabkan informasi hilang atau *over-smoothing*.


2.5.4 *Fully Connected Layer*

Fully Connected Layer atau *dense layer* adalah lapisan terakhir dari arsitektur CNN. Setiap *neuron* dalam lapisan ini terhubung dengan semua *neuron* dari lapisan sebelumnya (baik dari *convolution* maupun *pooling layer*). Karena setiap *neuron* dihubungkan secara penuh, maka lapisan ini bertanggung jawab untuk menggabungkan seluruh fitur yang telah dipelajari dan menghasilkan prediksi akhir. *Output* dari *fully connected layer* biasanya masuk ke dalam fungsi aktivasi akhir seperti *sigmoid* (untuk klasifikasi biner) atau *softmax* (untuk klasifikasi

multikelas). Dengan kata lain, *fully connected layer* berfungsi sebagai "pengambil keputusan" dalam jaringan CNN berdasarkan fitur-fitur yang telah diekstraksi dari citra input (Lee, 2023).

2.6 Support Vector Machine (SVM)

Support vector machine (SVM) adalah metode pembelajaran mesin berbasis klasifikasi dan regresi yang bekerja dengan mencari *hyperplane* optimal untuk memisahkan data ke dalam kelas yang berbeda. Gambar 3 menunjukkan model ini didasarkan pada prinsip margin maksimal, di mana SVM mencoba mencari garis atau bidang pemisah yang memiliki jarak maksimum dari titik-titik data terdekat (Barui et al., 2018b).



Gambar 3. Ilustrasi *Linear SVM* Sumber (Barui et al., 2018b).

SVM bekerja dengan mencari *hyperplane* optimal yang memisahkan kelas data dengan margin maksimum. Algoritma ini sangat efektif dalam menangani data berdimensi tinggi karena menggunakan fungsi kernel untuk memetakan data ke dalam ruang dimensi yang lebih tinggi, memungkinkan pemisahan yang lebih baik bahkan dalam kasus data yang tidak terpisahkan secara *linear* (Dabas, 2024). Selain itu, SVM dapat diubah menjadi masalah optimasi kuadratik, yang dapat ditingkatkan dengan menggunakan komputasi kuantum, memungkinkan pengolahan data dalam skala besar lebih efisien (Wang, 2024).

Support Vector Machine (SVM) dipilih dalam jurnal yang berjudul “*Classification and Segmentation of MRI Brain Images using Support Vector Machine and Fuzzy C-means Clustering*” sebagai metode klasifikasi gambar MRI otak karena kemampuannya dalam menangani data berdimensi tinggi, mengingat MRI menghasilkan banyak fitur yang diekstrak dari gambar. Dengan fitur ini, SVM dapat bekerja secara optimal terutama setelah dilakukan reduksi dimensi menggunakan *Principal Component Analysis* (PCA). Selain itu, SVM mampu menangani data *non-linear* melalui penggunaan fungsi kernel seperti *Radial Basis Function* (RBF) dan *polynomial*, yang memungkinkan pemetaan data ke dimensi lebih tinggi untuk meningkatkan akurasi klasifikasi. Ketahanan terhadap *overfitting* juga menjadi keunggulan utama SVM, karena metode ini menggunakan konsep margin maksimum yang memastikan generalisasi yang baik, terutama dalam skenario dengan jumlah data pelatihan yang terbatas (Dwivedi & Singhal, 2022).

Dalam penelitian ini, SVM diterapkan untuk klasifikasi tumor otak menjadi jinak atau ganas, yang merupakan kasus klasifikasi biner, di mana SVM dikenal sangat efektif. Evaluasi menunjukkan bahwa penggunaan SVM dengan kernel linear dan RBF mencapai akurasi hingga 90%, lebih unggul dibandingkan metode lain yang digunakan dalam studi serupa. SVM bekerja dengan mencari *hyperplane* optimal yang memisahkan dua kelas dengan margin maksimum, di mana *support vectors* berperan dalam menentukan posisi *hyperplane* tersebut. Fungsi kernel dalam SVM memungkinkan fleksibilitas dalam menangani berbagai jenis data, baik yang terpisah secara linear maupun *non-linear*. Selain itu, parameter regulasi (C) dalam SVM berfungsi untuk menyeimbangkan *margin* maksimum dan kesalahan klasifikasi, sehingga mencegah *overfitting* atau *underfitting*. Dengan karakteristik ini, SVM menjadi metode yang sangat efektif dalam mendukung klasifikasi tumor otak berbasis MRI, memberikan akurasi tinggi dan kinerja yang lebih baik dibandingkan metode lain yang ada (Dwivedi & Singhal, 2022).

Dalam *Support Vector Machine* (SVM), pemilihan kernel memiliki peran penting dalam menentukan cara data diproyeksikan ke ruang fitur yang lebih tinggi untuk dapat dipisahkan secara optimal. Dalam penelitian ini, beberapa fungsi kernel utama SVM seperti *linear*, *polynomial*, *Radial Basis Function* (RBF) dan *sigmoid* digunakan untuk memperluas kemampuan model dalam memisahkan data yang tidak terpisahkan secara *linear*. Kernel *linear* merupakan kernel paling sederhana dengan perhitungan berbasis *dot product*, sehingga tidak melakukan transformasi ke dimensi lebih tinggi. Kernel ini berfungsi efektif untuk data yang dapat dipisahkan secara *linear* dan sering digunakan karena perhitungannya cepat serta akurat pada data berdimensi tinggi (Safitri et al., 2020). Kernel *polynomial* berfungsi untuk menangkap hubungan *non-linear* dan interaksi kompleks antar fitur meskipun semakin tinggi derajat *polynomial* dapat meningkatkan beban komputasi (Du et al., 2024).

Kernel RBF (*Radial Basis Function*) adalah merupakan kernel yang paling populer karena mampu memetakan data ke ruang berdimensi tak terhingga dan sangat efektif dalam menangani data *non-linear* yang sulit dipisahkan secara garis lurus (Khan et al., 2024). Kernel *sigmoid* dapat digunakan untuk *non-linear* tertentu, tetapi kestabilannya relatif lebih rendah dibandingkan kernel lainnya (Chaeikar et al., 2020).

2.6.1 *Histogram Of Oriented Gradients* (HOG)

Histogram Of Oriented Gradients (HOG) adalah metode fitur yang digunakan untuk mendeskripsikan bentuk atau struktur objek dalam citra melalui pola arah gradien lokal. Metode ini pertama kali diperkenalkan oleh Dalal dan Triggs (2005) dan telah menjadi teknik populer dalam tugas-tugas klasifikasi dan deteksi objek, terutama karena kemampuannya dalam merepresentasikan informasi tepi (*edge*) yang kaya dan mendetail (Indrabulan & Aminuddin, 2018).

Proses utama dalam metode HOG dimulai dengan mengubah gambar menjadi *grayscale*, kemudian menghitung arah dan *magnitude gradien* pada setiap piksel. Gambar kemudian dibagi menjadi beberapa *cell* kecil, dan dalam setiap *cell* dibuat histogram dari arah gradien dominan. Histogram-histogram ini digabungkan ke dalam blok, dan dilakukan normalisasi untuk mengurangi pengaruh variasi pencahayaan. Seluruh blok yang telah dinormalisasi kemudian dirangkai menjadi satu vektor fitur yang menjadi representasi dari gambar tersebut (Anggraeny et al., 2020).

Keunggulan HOG terletak pada kemampuannya untuk menangkap bentuk lokal dengan presisi tinggi, serta *robust* terhadap rotasi kecil dan perubahan intensitas cahaya. Fitur-fitur HOG ini sering dikombinasikan dengan algoritma klasifikasi seperti *Support Vector Machine* (SVM) untuk menghasilkan performa klasifikasi yang lebih baik. Dalam konteks klasifikasi citra medis, HOG terbukti efektif ketika digunakan sebagai metode ekstraksi fitur awal (Hidayat et al., 2021).

2.7 CT Scan dan MRI

CT Scan (*Computed Tomography*) dan *MRI* (*Magnetic Resonance Imaging*) adalah dua teknik pencitraan medis yang digunakan untuk mendiagnosis berbagai kondisi dalam tubuh. Keduanya memiliki prinsip kerja yang berbeda, yang mempengaruhi keunggulan serta keterbatasan masing-masing metode. *CT Scan* menggunakan sinar-X yang diproses oleh komputer untuk menghasilkan gambar penampang tubuh dengan cepat dan akurat. Metode ini sangat berguna dalam keadaan darurat, seperti mendeteksi perdarahan otak, patah tulang, atau cedera organ dalam. Namun, karena menggunakan radiasi ionisasi, *CT Scan* memiliki risiko paparan radiasi yang lebih tinggi dibandingkan *MRI* (Dayarathna et al., 2024; Yang et al., 2024). Disisi lain, *MRI* menggunakan medan magnet

dan gelombang radio untuk menghasilkan gambar dengan resolusi lebih tinggi tanpa radiasi ionisasi, menjadikannya metode unggulan untuk pencitraan jaringan lunak, seperti otak dan organ dalam lainnya.

Dalam beberapa tahun terakhir, *Machine Learning* (ML) telah banyak digunakan dalam analisis data medis dari *CT scan* dan MRI untuk meningkatkan akurasi diagnosis dan mengurangi beban kerja radiolog. Teknik ML seperti *Support Vector Machine* (SVM), *Convolutional Neural Networks* (CNN), dan *Deep Learning* digunakan untuk mendeteksi anomali, mengklasifikasikan jenis tumor, dan meningkatkan segmentasi citra medis (Eli & Ali, 2024). Algoritma ini bekerja dengan cara belajar dari *dataset* besar untuk mengenali pola yang sulit diidentifikasi oleh manusia, sehingga mampu meningkatkan kecepatan dan keakuratan diagnosis.

Dengan perkembangan teknologi, penerapan *machine learning* dalam pencitraan medis diharapkan dapat semakin meningkatkan deteksi dini penyakit, mempercepat diagnosis, serta memberikan hasil yang lebih akurat. Hal ini dapat membantu tenaga medis dalam mengambil keputusan yang lebih tepat dan efisien dalam perawatan pasien (Rong & Liu, 2024).



Gambar 4. Citra *CT Scan* dari Kaggle

Teknologi pencitraan medis terus berkembang, termasuk penggunaan kecerdasan buatan untuk meningkatkan akurasi diagnosis. Studi terbaru menunjukkan bahwa pembelajaran mesin dapat digunakan untuk

mengonversi gambar CT menjadi MRI guna meningkatkan kualitas pencitraan tanpa memerlukan dua pemeriksaan terpisah (Dayarathna et al., 2024). Dengan kemajuan ini, kombinasi antara *CT Scan* dan MRI semakin memberikan manfaat dalam praktik medis. Pemilihan metode pencitraan terbaik bergantung pada kondisi medis spesifik, urgensi diagnosis, serta pertimbangan risiko dan manfaat bagi pasien.

2.8 Confusion Matrix

Confusion Matrix adalah metode yang digunakan untuk mengevaluasi kinerja sebuah model dalam mengklasifikasikan data. *Confusion matrix* membantu dalam perhitungan berbagai metrik evaluasi, seperti akurasi, presisi, dan *recall*. *Confusion matrix* disajikan dalam bentuk tabel yang menunjukkan jumlah prediksi yang tepat maupun keliru untuk setiap kelas dalam model klasifikasi (Heydarian et al., 2022). Struktur tabel *confusion matrix* dapat dilihat pada Tabel 2 berikut.

Tabel 2. *Confusion Matrix*

Prediksi/ Aktual	Positif	Negatif
Positif	TP (<i>True Positive</i>)	FP (<i>False Positive</i>)
Negatif	FN (<i>False Negative</i>)	TN (<i>True Negative</i>)

Keterangan :

- TP (*True Positive*) : Kondisi dimana model memprediksi kelas positif, dan hasil sebenarnya juga termasuk dalam kelas positif.
- FP (*False Positive*) : Kondisi dimana model memprediksi kelas positif, namun hasil sebenarnya adalah kelas negatif.
- FN (*False Negative*) : Kondisi dimana model memprediksi kelas negatif, tetapi hasil sebenarnya adalah kelas positif.
- TN (*True Negative*) : Kondisi dimana model memprediksi kelas negatif, dan hasil sebenarnya juga termasuk dalam kelas negatif.

Kinerja model yang ditampilkan melalui *confusion matrix* dapat dianalisis menggunakan berbagai metrik evaluasi, seperti *accuracy*, *precision*, *recall*, *F1-score*, *macro average* dan *weighted average*.

2.8.1 *Accuracy (Akurasi)*

Akurasi menunjukkan persentase prediksi model yang benar terhadap seluruh data yang diuji. Nilai akurasi dihitung menggunakan Persamaan 1 berikut:

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

2.8.2 *Precision (Presisi)*

Presisi mengukur seberapa banyak prediksi positif yang benar dibandingkan dengan seluruh prediksi positif yang dibuat oleh model. Nilai presisi dihitung menggunakan Persamaan 2 berikut:

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

2.8.3 *Recall*

Recall menggambarkan proporsi data yang benar-benar positif yang berhasil diidentifikasi oleh model sebagai positif. Perhitungan recall dilakukan menggunakan Persamaan 3 berikut:

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

2.8.4 *F1-Score*

F1-score merupakan rata-rata harmonik antara *precision* dan *recall*, yang digunakan untuk menyeimbangkan keduanya. Nilai *F1-score* berkisar antara 0 hingga 1, dengan 1 sebagai nilai terbaik. Untuk menghitung *F1-score* menggunakan Persamaan 4 berikut:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

2.8.5 *Macro Average*

Macro average adalah metode perhitungan rata-rata metrik evaluasi pada kasus klasifikasi multi-kelas dengan memberikan bobot yang sama pada setiap kelas. Nilai *macro average* diperoleh dengan menghitung rata-rata aritmatika dari nilai metrik

pada masing-masing kelas, tanpa memperhatikan jumlah data pada tiap kelas. Dengan demikian, metode ini menekankan kesetaraan antar kelas sehingga lebih sesuai untuk mengevaluasi performa model secara adil pada seluruh kelas. Untuk menghitung *macro average* menggunakan Persamaan 5 berikut:

$$Macro\ Average = \frac{1}{N} \sum_{i=1}^N M_i \quad (5)$$

Keterangan:

- N = Jumlah kelas dalam masalah klasifikasi.
- M_i = Nilai metrik evaluasi pada kelas ke- i .
- $\frac{1}{N}$ = Faktor pembagi agar hasilnya jadi rata-rata aritmatika.
- $\sum_{i=1}^N M_i$ = Penjumlahan semua nilai metrik dari setiap kelas.

2.8.6 *Weighted Average*

Weighted average adalah metode perhitungan rata-rata metrik evaluasi pada kasus klasifikasi multi-kelas dengan mempertimbangkan proporsi jumlah data (*support*) pada masing-masing kelas. Nilai *weighted average* diperoleh dengan memberikan bobot berdasarkan jumlah data tiap kelas, sehingga kelas dengan jumlah sampel yang lebih besar akan memiliki pengaruh lebih besar terhadap nilai akhir. Untuk menghitung *weighted average* menggunakan Persamaan 6 berikut:

$$Weighted\ Average = \frac{\sum_{i=1}^N (n_i \times M_i)}{\sum_{i=1}^N n_i} \quad (6)$$

Keterangan :

- N = Jumlah kelas dalam masalah klasifikasi
- M_i = Nilai metrik untuk kelas ke- i .
- n_i = Jumlah data aktual (*support*) pada kelas ke- i .
- $\sum_{i=1}^N (n_i \times M_i)$ = Total nilai metrik yang sudah dikalikan dengan banyak data pada kelas.
- $\sum_{i=1}^N n_i$ = Total jumlah data semua kelas.

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian


Tempat penelitian dilakukan di Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung bertempat di Jalan Prof. Dr. Soemantri Brojonegoro No. 1, Gedong Meneng, Bandar Lampung. Penelitian ini dilakukan pada bulan Desember 2024 pada semester tujuh ganjil sampai penyelesaian pada bulan Agustus tahun 2025. Tabel penelitian terdapat pada Lampiran 1.

3.2 Data Penelitian

Jenis data yang digunakan dalam penelitian ini adalah data sekunder. Data diperoleh dari *dataset Kidney Stones MRI and CT scans*, yang merupakan kumpulan citra *CT scan* dan MRI ginjal pasien dengan berbagai kondisi kesehatan. *Dataset* ini dikembangkan di Telangana India oleh Mohammed Rizwan Malik pada tahun 2022. *Dataset* ini dapat diakses secara umum melalui platform Kaggle dengan link sebagai berikut (<https://www.kaggle.com/datasets/mohammedrizwanmalik/kidney-stones-mri-and-ct-scans>).

Masing-masing citra memiliki resolusi yang beragam dengan format png. *Dataset* ini terdiri dari 1.783 citra yang sudah dibagi menjadi 2 folder yaitu *train* dan *test* yang diklasifikasikan menjadi 2 kategori utama yaitu normal dan *kidney stone* (batu ginjal). Tabel 3 berikut merupakan pembagian citra berdasarkan kategori.

Tabel 3. Kategori *Dataset*

Folder	Kategori	Jumlah citra	Contoh citra
<i>Train</i>	Normal	822	
	<i>Kidney Stone</i>	615	
<i>Test</i>	Normal	181	
	<i>Kidney stone</i>	165	
TOTAL		1.783	

3.3 Alat Pendukung

3.3.1 Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan dalam penelitian ini adalah sebuah laptop dengan spesifikasi sebagai berikut :

- Nama *device* : Asus
- Processor* : Intel(R) Core(TM) i3-1005G1
- Installed RAM* : 4.00 GB
- System type* : 64-bit *operating system*

3.3.2 Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan dalam penelitian ini antara lain :

- Sistem Operasi : Windows 11 *Home* 64-bit.
- Bahasa Pemrograman *Python*

Python merupakan bahasa pemrograman serbaguna yang bersifat interpretatif dan dirancang dengan prinsip kode yang

mudah dibaca. Bahasa ini mendukung berbagai gaya pemrograman, termasuk prosedural, berbasis objek, dan fungsional. *Python* juga memiliki sifat dinamis, dilengkapi dengan manajemen memori otomatis, serta dapat dijalankan di berbagai sistem operasi, seperti Java Virtual Machine, Palm, Amiga, Windows, Mac OS, dan Linux/Unix (Ihsan, 2021).

c. Google Colab

Google Colab adalah sebuah alat untuk pengajaran komputasi yang digunakan dalam pendidikan jarak jauh maupun kelas tatap muka. Google Colab sering dimanfaatkan dalam pengajaran kecerdasan buatan dan pembelajaran mesin, tetapi juga bisa digunakan untuk berbagai disiplin ilmu lainnya. *Platform* ini berbasis Jupyter Notebook, memungkinkan pengguna untuk menjalankan kode langsung di *browser* tanpa perlu instalasi tambahan. Google Colab juga menyediakan akses gratis ke GPU, mendukung berbagai bahasa pemrograman selain Python (Ferreira et al., 2023).

d. Google Drive

Google drive adalah *platform* layanan penyimpanan data berbasis *cloud* yang memungkinkan pengguna untuk menyimpan, mengatur dan membagikan *file* secara digital. Layanan menyediakan kapasitas gratis sebesar 15 GB, dengan opsi peningkatan melalui layanan Google One. Dengan fitur pengarsipan digital, Google Drive mempermudah akses informasi, meningkatkan efisiensi dalam pengelolaan dokumen serta mengurangi ketergantungan pada arsip fisik yang rentan terhadap kerusakan dan kehilangan (Irawati et al., 2024).

e. Tensorflow

TensorFlow adalah *framework* pembelajaran mesin *open-source* yang dikembangkan oleh Google untuk membangun dan melatih model *machine learning* maupun *deep learning*. TensorFlow menyediakan antarmuka pemrograman untuk merancang algoritma pembelajaran mesin dan mampu dijalankan di berbagai *platform* seperti CPU, GPU, dan TPU. *Library* ini banyak digunakan dalam pengembangan model kecerdasan buatan karena fleksibilitas dan skalabilitasnya (Ihsan, 2021a).

f. *Library* Keras

Keras merupakan *library neural network* tingkat tinggi yang ditulis menggunakan Python dan dapat berjalan di atas *framework* seperti *TensorFlow*. Keras menyediakan antarmuka yang sederhana dan efisien untuk membuat model *deep learning*. *Library* ini sangat cocok digunakan oleh pemula hingga peneliti karena memudahkan proses pembangunan model dengan hanya sedikit baris kode (Alzubaidi et al., 2021).

g. *Library* NumPy

NumPy (*Numerical Python*) adalah *library* fundamental dalam ekosistem Python yang digunakan untuk komputasi ilmiah dengan menyediakan struktur *array* multidimensi (*ndarray*) dan berbagai fungsi matematis yang efisien. NumPy memungkinkan operasi numerik dilakukan secara vektorisasi tanpa perulangan eksplisit, sehingga meningkatkan kecepatan pemrosesan data (Harris et al., 2020).

h. *Library Matplotlib*

Matplotlib adalah *library* visualisasi data dalam Python yang digunakan untuk membuat grafik dan plot. *Library* ini sering digunakan untuk memvisualisasikan hasil eksperimen model, seperti grafik akurasi, *loss*, *confusion matrix*, dan distribusi data *Open CV* (Hunter, 2007).

i. *Library skimage (Scikit-image)*

Scikit-image adalah *library open-source* berbasis Python yang dirancang untuk melakukan pemrosesan citra digital. *Library* ini menyediakan berbagai algoritma dan fungsi yang dapat digunakan untuk analisis gambar seperti *filtering*, segmentasi, transformasi morfologi, deteksi tepi, dan ekstraksi fitur (Walt et al., 2014).

j. *Open CV*

OpenCV (Open Source Computer Vision Library) adalah *library open-source* yang dirancang untuk mendukung pengembangan aplikasi *computer vision* secara *real-time*. *OpenCV* menjadi alat yang sangat berguna dalam penelitian dan pengembangan sistem pengolahan citra dan pengenalan pola (Zelinsky, 2009).

k. *Roboflow*

Roboflow merupakan alat berbasis *web* yang digunakan untuk membangun dan mengelola proyek *computer vision* secara *end-to-end*. *Platform* ini memungkinkan pengguna untuk mengunggah *dataset*, melakukan anotasi gambar, melakukan *preprocessing* serta augmentasi data, melatih model deteksi objek atau klasifikasi, hingga *men-deploy* model secara langsung ke berbagai *platform* seperti *web*, *mobile*, atau perangkat *edge* (Roboflow, 2020).

1. *Draw.io*

Draw.io (sekarang dikenal sebagai *diagrams.net*) merupakan aplikasi berbasis web yang digunakan untuk membuat berbagai jenis diagram seperti diagram alur (*flowchart*), diagram sistem, arsitektur perangkat lunak, jaringan, UML, ERD, hingga rancangan antarmuka. Aplikasi ini bersifat *open-source* dan dapat dijalankan secara *offline* maupun *online* melalui *browser* tanpa perlu instalasi tambahan (*Draw.io*, 2012).

3.4 Alur Kerja Penelitian


Alur penelitian mencakup serangkaian langkah sistematis yang ditempuh untuk mencapai tujuan penelitian. Alur ini berperan dalam membantu penelitian. Gambar 5 merupakan alur penelitian.

3.4.1 Input Data

Sebelum input data, langkah pertama yang dilakukan yaitu pengumpulan data. *Dataset* yang diambil berasal dari Kaggle. *Dataset* berjumlah 1.783 citra dari 2 folder yaitu *train* dan *test* dan 2 kelas yaitu normal dan *kidney stone*. *Dataset* yang digunakan dalam penelitian ini jumlahnya terhitung sangat terbatas, sehingga nantinya akan dilakukan augmentasi dengan metode *image augmentation*.

3.4.2 Preprocessing Data

Preprocessing adalah tahap awal dalam pemrosesan data yang bertujuan untuk mempersiapkan data agar sesuai dengan kebutuhan model yang akan digunakan. Pada tahap ini, citra yang telah dikumpulkan diproses agar sesuai dengan kebutuhan model. Langkah-langkah *preprocessing* meliputi:



Gambar 5. Alur Penelitian

- a. Segmentasi : Hanya mengambil area ginjal saja menggunakan roboflow secara manual.
- b. *Cropping* : Area yang tidak relevan dalam citra dipotong agar hanya fokus pada bagian ginjal.
- c. *Resizing image* : Citra diubah menjadi ukuran 224x224 piksel agar kompatibel dengan arsitektur CNN.

- d. *Augmentasi data* : Teknik augmentasi dilakukan secara *realtime* seperti rotasi, *flipping*, kontras dan pergeseran diterapkan untuk meningkatkan variasi *dataset* dan mengatasi ketidakseimbangan data.
- e. *Splitting data* : *Dataset* dibagi menjadi *subset* utama yaitu :
 1. *Training Set* (80%) : Digunakan untuk melatih model agar memahami pola dalam data.
 2. *Validation Set* (20%) : Digunakan untuk mengevaluasi performa model selama pelatihan guna menghindari *overfitting*.
 3. *Test Set* : Data uji telah disediakan secara terpisah sejak awal, sehingga tidak dihitung berdasarkan persentase dari keseluruhan *dataset*. Data tersebut digunakan secara khusus hanya untuk evaluasi akhir model setelah proses pelatihan dan validasi selesai dilakukan.

3.4.3 Training Model

Pada tahap ini, dilakukan pembuatan arsitektur model *Convolutional Neural Network* CNN dan *Support Vector Machine* SVM yang digunakan untuk klasifikasi batu ginjal. CNN bertugas mengekstrak fitur dari citra, sedangkan SVM dapat digunakan sebagai *classifier* tambahan. Setelah model dirancang, dilakukan proses pelatihan menggunakan *dataset* yang telah dibagi sebelumnya. Proses ini melibatkan:

- a. Optimasi bobot CNN
 1. *Optimizer*: Algoritma seperti Adam atau SGD (*Stochastic Gradient Descent*) digunakan untuk memperbarui bobot model secara bertahap.
 2. *Loss Function*: *Categorical Crossentropy* digunakan untuk mengukur perbedaan antara prediksi model dan label asli.
 3. *Batch Size*: Data dilatih dalam kelompok kecil untuk meningkatkan efisiensi komputasi.

4. *Epochs*: Model dilatih selama beberapa iterasi agar bobot dapat menyesuaikan dengan pola data.
5. *Early Stopping*: Digunakan untuk menghentikan pelatihan jika model mulai mengalami *overfitting*.

b. *Training SVM*

1. Mencari kernel terbaik dari 4 kernel yaitu RBF, *linear*, *polymoid* dan *sigmoid*.
2. Setelah mendapatkan kernel terbaik, diekstraksi dan digunakan untuk melatih model.

3.4.4 *Testing Model*

Setelah model selesai dilatih, dilakukan pengujian menggunakan data uji (*test set*) untuk mengevaluasi performa model dalam mengklasifikasikan batu ginjal secara akurat.

3.4.5 *Evaluasi Model*

Tahap terakhir adalah mengevaluasi model menggunakan metrik seperti akurasi, sensitivitas, spesifisitas, dan *confusion matrix*. Evaluasi ini bertujuan untuk mengetahui seberapa baik model dalam mengklasifikasikan batu ginjal dengan benar.

V. SIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa:

1. Model CNN menunjukkan performa yang sangat baik dalam mendeteksi kondisi ginjal normal maupun batu ginjal. Dengan preprocessing berupa segmentasi, *cropping*, *resize*, dan augmentasi data yang tepat, model CNN berhasil mencapai akurasi 97% pada data validasi dan 94% pada data uji. Selain itu, nilai *precision*, *recall*, dan *f1-score* juga sangat tinggi dan seimbang untuk kedua kelas, menunjukkan bahwa model mampu melakukan klasifikasi dengan baik dan tidak bias terhadap salah satu kelas.
2. Model SVM dengan fitur HOG dan kernel *sigmoid* menunjukkan performa yang cukup baik dengan akurasi 73% pada hasil *5-Fold Cross Validation* dan 67% pada data uji. Namun, model ini cenderung memiliki *recall* yang rendah pada kelas *Kidney_stone*, yang menunjukkan kesulitan dalam mendeteksi kasus batu ginjal secara konsisten.
3. Berdasarkan evaluasi keseluruhan, model CNN lebih unggul dibandingkan SVM, baik dari sisi akurasi maupun keseimbangan klasifikasi antar kelas. Hal ini menunjukkan bahwa pendekatan deep learning lebih efektif dalam menangani variasi dan kompleksitas citra medis ginjal, terutama karena CNN mampu mengekstraksi fitur spasial secara otomatis dan lebih mendalam.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa:

1. Penggunaan teknik gabungan model CNN dan metode lain seperti Random Forest dan VGG16 (*Visual Geometry Group* 16) atau SVM berbasis *deep feature* dapat dieksplorasi untuk meningkatkan akurasi klasifikasi, khususnya untuk kasus yang sulit dikenali.
2. Optimalisasi arsitektur CNN dan parameter pelatihan seperti penggunaan *transfer learning* dengan model *pretrained* (misalnya ResNet, EfficientNet) dapat menjadi alternatif untuk meningkatkan efisiensi dan akurasi model.

DAFTAR PUSTAKA

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00444-8>
- Anggraeny, F. T., Rahmat, B., & Pratama, S. P. (2020). Deteksi Ikan Dengan Menggunakan Algoritma Histogram of Oriented Gradients. *Informatika Mulawarman : Jurnal Ilmiah Ilmu Komputer*, 15(2), 114. <https://doi.org/10.30872/jim.v15i2.4648>
- Barui, S., Latha, S., Samiappan, D., & Muthu, P. (2018a). SVM Pixel Classification on Colour Image Segmentation. *Journal of Physics: Conference Series*, 1000(1). <https://doi.org/10.1088/1742-6596/1000/1/012110>
- Barui, S., Latha, S., Samiappan, D., & Muthu, P. (2018b). SVM Pixel Classification on Colour Image Segmentation. *Journal of Physics: Conference Series*, 1000(1). <https://doi.org/10.1088/1742-6596/1000/1/012110>
- Chaeikar, S. S., Manaf, A. A., Alarood, A. A., & Zamani, M. (2020). PFW: Polygonal fuzzy weighted—an SVM kernel for the classification of overlapping data groups. *Electronics (Switzerland)*, 9(4). <https://doi.org/10.3390/electronics9040615>

- Chen, Z., Xiao, C., Liu, Y., Hassan, H., Li, D., Liu, J., Li, H., Xie, W., Zhong, W., & Huang, B. (2024). Comprehensive 3D Analysis of the Renal System and Stones: Segmenting and Registering Non-Contrast and Contrast Computed Tomography Images. *Information Systems Frontiers*, 27(1), 97–111. <https://doi.org/10.1007/s10796-024-10485-y>
- Dabas, A. (2024). Application of Support Vector Machines in Machine Learning. In *e-Prints posted on TechRxiv are preliminary reports that are not peer reviewed*. C-BY 4.0. <https://doi.org/10.36227/techrxiv.172263291.17505159/v1>
- Dayarathna, S., Islam, K. T., Uribe, S., Yang, G., Hayat, M., & Chen, Z. (2024). Deep learning based synthesis of MRI, CT and PET: Review and analysis. In *Medical Image Analysis* (Vol. 92). Elsevier B.V. <https://doi.org/10.1016/j.media.2023.103046>
- Deshmukh, S. C. (2023). Study of Image Recognition Using Machine Learning. *International Journal for Research in Applied Science and Engineering Technology*, 11(6), 3229–3231. <https://doi.org/10.22214/ijraset.2023.54063>
- Draw.io. (2012). *About Draw.io*. <https://www.drawio.com/about>
- Du, K. L., Jiang, B., Lu, J., Hua, J., & Swamy, M. N. S. (2024). Exploring Kernel Machines and Support Vector Machines: Principles, Techniques, and Future Directions. In *Mathematics* (Vol. 12, Issue 24). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/math12243935>
- Dwivedi, S., & Singhal, V. (2022). Classification and Segmentation of MRI Brain Images using Support Vector Machine and Fuzzy C-means Clustering. *International Journal on Recent and Innovation Trends in Computing and Communication*, 10(1), 115–120. <https://doi.org/10.17762/ijritcc.v10i1s.5806>
- Eli, A. A., & Ali, A. (2024). Deep Learning Applications in Medical Image Analysis: Advancements, Challenges, and Future Directions. *Frontiers in Health Informatics*, 13(2). www.healthinformaticsjournal.com

- Ferreira, R., Canesche, M., & Penha, J. (2023). Google Colab para Ensino de Computação. *Sociedade Brasileira de Computação (SBC)*. <https://gradio.app/>
- George, M., & HB, A. (2022). Kidney Abnormalities Detection and Classification Using CNN-based Feature Extraction. *International Conference on Circuits, Control, Communication and Computing*.
- Gill, K. S., Anand, V., & Gupta, R. (2023). Kidney Disease Classification Using Machine Learning Approach on DenseNet201 Model using Xray Images. *First International Conference on Advances in Electrical, Electronics and Computational Intelligence (ICAEECI)*.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., del Río, J. F., Wiebe, M., Peterson, P., ... Oliphant, T. E. (2020). Array programming with NumPy. In *Nature* (Vol. 585, Issue 7825, pp. 357–362). Nature Research. <https://doi.org/10.1038/s41586-020-2649-2>
- Hashemi, M. (2019). Enlarging smaller images before inputting into convolutional neural network: zero-padding vs. interpolation. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0263-7>
- Heru,], Putra, S., Tri, A., Nurcahyo, P., Haryanto,], Chang, C.-J., Hwang, S.-L., & Chi, M. (2022). Computer Vision: Classification of Images Based On Deep Learning with the CNN Architecture Model. In *International Journal of Engineering Research in Computer Science and Engineering (IJERCSE)* (Vol. 9, Issue 11).
- Heydarian, M., Doyle, T. E., & Samavi, R. (2022). MLCM: Multi-Label Confusion Matrix. *IEEE Access*, 10, 19083–19095. <https://doi.org/10.1109/ACCESS.2022.3151048>
- Hidayat, R., Agustiani, S., Wildah, S. K., Mustopa, A., Safitri, R. A., Bina, U., & Informatika, S. (2021). Penerapan Metode Pembelajaran Menggunakan Ekstraksi Fitur dan Algoritma Klasifikasi untuk Identifikasi Pengenalan Iris. *Jurnal Teknik Komputer AMIK BSI*, 7(2). <https://doi.org/10.31294/jtk.v4i2>

- Hunter, John. D. (2007). Matplotlib: 2A Graphics Environment. *Journal & Magazines*, 9(3), 90–95. <https://ieeexplore.ieee.org/document/4160265>
- Ihsan, C. N. (2021a). Klasifikasi Data Radar Menggunakan Algoritma Convolutional Neural Network (CNN). *Journal of Computer and Information Technology*, 4(2), 115–121.
- Ihsan, C. N. (2021b). Klasifikasi Data Radar Menggunakan Algoritma Convolutional Neural Network (CNN). *Journal of Computer and Information Technology*, 4, 115–121.
- Indrabulan, T., & Aminuddin, R. (2018). Optimasi Window Pada Deskriptor HOG Dan SVM Untuk Klasifikasi Kendaraan Dalam Suvei Arus Lalu Lintas. *Jurnal Instek*, 3(1).
- Irawati, A., Fadli, S., Sunardi, Efendi, M. M., & Haryanto, E. (2024). Pelatihan Transformasi Digital Arsip di Desa Darmaji Menggunakan Google Drive. *Bumi: Jurnal Hasil Kegiatan Sosialisasi Pengabdian Kepada Masyarakat*, 2(3), 01–09. <https://doi.org/10.61132/bumi.v2i3.134>
- Khan, M., Hooda, B. K., Gaur, A., Singh, V., Jindal, Y., Tanwar, H., Sharma, S., Sheoran, S., Vishwakarma, D. K., Khalid, M., Albakri, G. S., Alreshidi, M. A., Choi, J. R., & Yadav, K. K. (2024). Ensemble and optimization algorithm in support vector machines for classification of wheat genotypes. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-72056-0>
- Konjengbam, H., Pebam, E., Singh, A. R., Yumnam, M., Devi, Y. L., & Meitei, S. Y. (2024). Body adiposity and body types susceptibility to kidney stone disease among the Meiteis of Manipur: A cross-sectional study. *Papers on Anthropology*, 33(1), 85–97. <https://doi.org/10.12697/poa.2024.33.1.05>
- Lee, Y. (2023). The CNN: The Architecture Behind Artificial Intelligence Development. *Journal of Student Research*, 12(4). <https://www.jsr.org/hs/index.php/path/article/view/5579/2731>

- Li, H., Rajbahadur, G. K., Lin, D., Bezemer, C.-P., Ming, Z., & Jiang. (2024). *Keeping Deep Learning Models in Check: A History-Based Approach to Mitigate Overfitting*. <https://doi.org/10.1109/ACCESS.2024.3402543>
- Ma, Q., Chen, G., Li, G., & Cui, D. (2024). Comparison of two negative pressure ureteral access sheaths combined with day-case flexible ureteroscopy for renal stones randomized trial. *Scientific Reports*, 14(1), 29092. <https://doi.org/10.1038/s41598-024-80934-w>
- Mo, R. (2022). A Survey of Image Classification Algorithms based on Convolution Neural Network. In *Highlights in Science, Engineering and Technology MECAE* (Vol. 2022).
- Modi, R. Y., & Lin, E. C. (2024). *Urinary Calculi (Urolithiasis) Imaging Practice Essentials*. https://emedicine.medscape.com/article/381993-overview?utm_source=chatgpt.com
- Navaneeth, B., & Suchetha, M. (2020). A dynamic pooling based convolutional neural network approach to detect chronic kidney disease. *Biomedical Signal Processing and Control*, 62. <https://doi.org/10.1016/j.bspc.2020.102068>
- Ning, N., Liu, Z., Li, X., Liu, Y., & Song, W. (2024). Progress of Induced Pluripotent Stem Cell-Derived Renal Organoids in Clinical Application. In *Kidney Diseases*. S. Karger AG. <https://doi.org/10.1159/000541919>
- Phung, V. H., & Rhee, E. J. (2019). A High-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets. *Applied Sciences (Switzerland)*, 9(21). <https://doi.org/10.3390/app9214500>
- Purwono, Ma'arif, A., Rahmانيar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & Haq, Q. M. U. (2022). Understanding of Convolutional Neural Network (CNN): A Review. *International Journal of Robotics and Control Systems*, 2(4), 739–748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Raj, P., Gayathri, N., & Kathrine, G. J. W. (2024). Artificial Intelligence for Precision Agriculture. In *KnowledgeWorks Global Ltd* (p. 321).

- Reddy, M. P., Pavan Kumar, K., Suresh, Y., & Vara Lakshmi, T. (2023). Prediction of Chronic Kidney Disease using SVM and CNN. *International Journal on Recent and Innovation Trends in Computing and Communication*, 11, 80–89. <https://doi.org/10.17762/ijritcc.v11i5s.6632>
- Roboflow. (2020). *About Roboflow*. <https://roboflow.com/about>
- Rong, J., & Liu, Y. (2024). Advances in medical imaging techniques. *BMC Methods*, 1(1). <https://doi.org/10.1186/s44330-024-00010-7>
- Safitri, L. R., Chamidah, N., Saifudin, T., & Alpandi, G. T. (2020). *Comparison of Kernel Support Vector Machine In Stroke Risk Classification (Case Study: IFLS data)*. <https://www.rand.org/well-being/social-and-behavioral->
- Tzou, D. T., Isaacson, D., Usawachintachit, M., Wang, Z. J., Taguchi, K., Hills, N. K., Hsi, R. S., Sherer, B. A., Reliford-Titus, S., Duty, B., Harper, J. D., Sorensen, M., Sur, R. L., Stoller, M. L., & Chi, T. (2018). Variation in Radiologic and Urologic Computed Tomography Interpretation of Urinary Tract Stone Burden: Results From the Registry for Stones of the Kidney and Ureter. *Urology*, 111, 59–64. <https://doi.org/10.1016/j.urology.2017.10.002>
- Vadim V, R. (2017). Appropriateness of Dropout Layers and Allocation of Their 0.5 Rates across Convolutional Neural Networks for CIFAR-10, EEACL26, and NORB Datasets. *Applied Computer Systems*, 22(1), 54–63. <https://doi.org/10.1515/acss-2017-0018>
- Walt, S. van der, Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., & Yu, T. (2014). Scikit-image: Image processing in python. *PeerJ*, 2014(1). <https://doi.org/10.7717/peerj.453>
- Wang, Q. (2024). Support vector machine based on the quadratic unconstrained binary optimization model. *Journal of Physics: Conference Series*, 2858(1). <https://doi.org/10.1088/1742-6596/2858/1/012002>
- Yang, Z., Chen, X., Qi, G., Gu, J., Liu, Z., & Zhang, X. (2024). Neutrophil Extracellular Traps Drive Kidney Stone Formation. *Kidney Diseases*. <https://doi.org/10.1159/000542471>

Zelinsky, A. (2009). Learning OpenCV—Computer Vision with the OpenCV Library. In *IEEE Robotics and Automation Magazine* (Vol. 16, Issue 3, p. 100). <https://doi.org/10.1109/MRA.2009.933612>