

Detection Of CT Kidney Disease Using GLCM Feature Extraction and Kernel Extreme Learning Machine (KELM) Classification Method

Deteksi CT Penyakit Ginjal dengan Ekstraksi Fitur GLCM dan Menggunakan Metode Klasifikasi Kernel Extreme Learning Machine (KELM)

Arifah Khairina Maulidiyah¹, Nurissaidah Ulinnuha², Lutfi Hakim³

^{1,2,3} Matematika, Universitas Islam Negeri Sunan Ampel Surabaya, Indonesia

^{1*} arifahkhair24@gmail.com, ² nuris.ulinnuha@uinsby.ac.id, ³ lutfihakimbungah@gmail.com

*: Penulis korespondensi (corresponding author)

Informasi Artikel

Received: January 2025

Revised: February 2025

Accepted: May 2025

Published: June 2025

Abstract

Kidney disease includes a variety of disorders affecting renal function, such as kidney cysts, tumors, and stones. If left untreated, these conditions can progress to chronic kidney disease, posing significant health risks and potentially leading to mortality. This study aims to classify kidney diseases by using the Gray Level Co-occurrence Matrix (GLCM) for feature extraction and the Kernel Extreme Learning Machine (KELM) as a classification method, with renal CT images as the dataset. The classification process categorizes kidney conditions into four classes: Cyst, Normal, Stone, and Tumor. The dataset consists of 4,232 CT images, with 1,058 images per class, evenly divided into axial and coronal orientations. The study utilizes k -fold cross-validation with $k = 5$ and $k = 10$ and implements the Radial Basis Function (RBF) as the kernel function in the KELM model. An iterative tuning of parameters, including the kernel parameter (σ) and the regularization constant (C), was conducted to identify the optimal model configuration. The best classification performance was achieved at 0° angle using $k = 5$, with an accuracy of 97.26%, sensitivity of 97.16%, and specificity of 99.05%. Furthermore, the model demonstrated high computational efficiency, requiring only 6.07 seconds.

Abstrak

Penyakit ginjal mencakup berbagai gangguan yang memengaruhi fungsi ginjal, seperti kista ginjal, tumor, dan batu ginjal. Apabila tidak ditangani segera, kondisi ini dapat berkembang menjadi penyakit ginjal kronis, yang berisiko serius bagi kesehatan dan berpotensi menyebabkan

Keywords: Classification; GLCM; Kidney Disease; KELM; RBF
Kata kunci: Klasifikasi; GLCM; Penyakit Ginjal; KELM; RBF

kematian. Penelitian ini bertujuan untuk mengklasifikasikan penyakit ginjal dengan menggunakan *Gray Level Co-occurrence Matrix* (GLCM) sebagai teknik ekstraksi fitur dan *Kernel Extreme Learning Machine* (KELM) sebagai metode klasifikasi, dengan memanfaatkan citra CT ginjal sebagai dataset. Proses klasifikasi ini mengelompokkan kondisi ginjal ke dalam empat kelas, yaitu kista, normal, batu, dan tumor. Dataset yang digunakan terdiri dari 4.232 citra CT, dengan masing-masing kelas memiliki 1.058 citra yang dibagi secara merata ke dalam orientasi aksial dan koronal. Penelitian ini menggunakan teknik validasi silang k-fold dengan nilai $k = 5$ dan $k = 10$, serta menerapkan fungsi kernel *Radial Basis Function* (RBF) dalam model KELM. Proses tuning parameter, termasuk parameter kernel (σ) dan konstanta regulasi (C), dilakukan secara iteratif untuk mendapatkan konfigurasi model yang optimal. Kinerja klasifikasi terbaik dicapai pada sudut 0° dengan $k = 5$, menghasilkan akurasi sebesar 97,26%, sensitivitas 97,16%, dan spesifisitas 99,05%. Selain itu, model ini menunjukkan efisiensi komputasi yang tinggi, dengan waktu pelatihan hanya 6,07 detik.

1. Pendahuluan

Ginjal adalah organ vital pada manusia yang berfungsi untuk menyaring limbah metabolik dan kelebihan cairan dari darah, serta menjaga keseimbangan elektrolit tubuh [1]. Gangguan pada ginjal seperti kista, tumor, dan batu ginjal, dapat mengakibatkan disfungsi organ dan memiliki dampak serius terhadap Kesehatan tubuh. Kista ginjal merupakan pembentukan kantung berisi cairan pada struktur ginjal, sementara tumor ginjal melibatkan pertumbuhan sel abnormal, dan batu ginjal terbentuk dari endapan mineral yang mengeras [2]. Jika tidak dijaga secara baik, kondisi ini dapat semakin parah dan dapat mengakibatkan penyakit ginjal kronis yang signifikan, secara global penyakit ini memiliki prevalensi yang memengaruhi lebih dari 10% populasi dunia. Diprediksikan bahwa penyakit ginjal kronis akan menjadi penyebab kematian keenam pada tahun 2040 [3]. Deteksi dini melalui metode radiografi seperti Ultrasonografi (USG), X-ray, Magnetic Resonance Imaging (MRI), dan Computed Tomography (CT) sangat penting untuk mendukung intervensi medis yang cepat dan tepat sasaran [4].

Kemajuan teknologi terutama pada pembelajaran mesin (*machine learning*) dalam analisis citra medis memberikan potensi besar untuk meningkatkan presisi diagnosis penyakit ginjal. Beberapa model, seperti Vision Transformers, VGG16, dan ResNet50, telah diterapkan untuk klasifikasi penyakit ginjal berbasis citra CT, dengan tingkat akurasi masing-masing sebesar 96,54%, 98,20%, dan 73,80% [5]. Selain itu, metode ekstraksi fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) telah terbukti memberikan representasi tekstur citra yang efektif dan meningkatkan kinerja model analisis citra medis. Sebagai contoh, penelitian sebelumnya menunjukkan bahwa penggunaan GLCM dalam klasifikasi batu ginjal dengan metode Support


Vector Machine (SVM) mencapai akurasi 95% [6]. Di sisi lain, deteksi kanker paru-paru menggunakan kombinasi GLCM dan Fuzzy C-means Clustering menghasilkan akurasi hingga 98,78% [7].

Kernel Extreme Learning Machine (KELM) merupakan algoritma pembelajaran mesin yang telah menunjukkan keunggulan dalam klasifikasi citra medis dibandingkan dengan algoritma lain seperti SVM, KNN, dan Multi-Layer Perceptron menghasilkan akurasi sebesar 91,1%, 89,1%, 76,4%, 85,1% secara berurutan [8]. Penelitian sebelumnya menunjukkan bahwa penggunaan kernel Radial Basis Function (RBF) pada KELM dapat meningkatkan kemampuan generalisasi dan kinerja model. Pada penelitian klasifikasi kanker serviks berbasis GLCM-KELM dengan kernel RBF menghasilkan akurasi sebesar 92,5% [9], sementara klasifikasi cedera panggul berbasis KELM dengan kernel RBF mencapai akurasi 90,32% [10]. Penemuan ini menegaskan bahwa pemilihan kernel yang sesuai, khususnya kernel RBF, sangat penting dalam mengoptimalkan kinerja model pada data citra medis yang kompleks.

Berdasarkan paparan tersebut, penelitian ini bertujuan untuk mengembangkan metode klasifikasi penyakit ginjal pada citra CT dengan mengintegrasikan teknik ekstraksi fitur GLCM dan algoritma KELM menggunakan kernel RBF. Kombinasi metode ini diharapkan dapat meningkatkan akurasi dan efisiensi diagnosis penyakit ginjal dibandingkan pendekatan yang telah dilaporkan dalam penelitian terdahulu.

2. Metode/Perancangan

Penelitian ini dirancang secara sistematis untuk melaksanakan proses dalam pengolahan data citra, ekstraksi fitur, dan implementasi metode klasifikasi *Kernel Extreme Learning Machine* (KELM). Tahapan-tahapan pada penelitian meliputi pengumpulan dan preprocessing data, ekstraksi fitur, klasifikasi, dan evaluasi kinerja model yang dapat dilihat pada *flowchart* dibawah.



Gambar 1. Tahapan Proses Penelitian

2.1. Pengumpulan Data

Data yang digunakan adalah citra CT ginjal yang diunduh dari situs Kaggle (<https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>). Dataset ini terdiri dari empat kelas: kista, normal, batu ginjal, dan tumor ginjal. Awalnya, dataset mencakup 12.446 citra yang tidak seimbang antar kelas. Untuk memastikan keseimbangan data, dilakukan proses undersampling sehingga setiap kelas memiliki 1.058 citra, dengan distribusi yang sama antara orientasi aksial dan koronal masing-masing 529 citra. Jumlah total data yang digunakan dalam penelitian ini adalah 4.232 citra.

Tabel 1. Sampel Citra Penyakit Ginjal secara Axial dan Coronal

Kelas	Axial	Coronal
Kista		
Normal		
Stone		
Tumor		

2.2. Preprocessing Data

Proses preprocessing bertujuan meningkatkan kualitas data dan mempersiapkannya untuk analisis lebih lanjut. Ukuran citra yang digunakan pada penelitian ini sangat beragam dengan ukuran 512x512, 705x569, 947x765, dan 588x476, maka langkah pertama yaitu melakukan resize citra yang bertujuan agar dimensi citra diseragamkan untuk memastikan konsistensi

semua ukuran citra pada data [11]. Selanjutnya melakukan konversi ke grayscale, citra RGB diubah menjadi grayscale menggunakan rumus berikut [12]:

$$I_{Gray}(x, y) = 0.299 \times R(x, y) + 0.587 \times G(x, y) + 0.114 \times B(x, y) \quad (1)$$

Dimana:

$I_{Gray}(x, y)$ = Intensitas piksel abu-abu

R, G , dan B = Intensitas warna merah, hijau, dan biru

Langkah terakhir akan dilakukan penyesuaian kontras dan penghilangan noise menggunakan filter harmonic mean yang bertujuan untuk mengurangi atau menghilangkan noise yang dapat mengaburkan atau merusak kualitas pada citra, yang bekerja dengan menghitung nilai rata-rata harmonik dari intensitas piksel dalam jendela filter [13].

2.3. Ekstraksi Fitur

Ekstraksi fitur dilakukan menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM) untuk menganalisis tekstur citra. Matriks GLCM dihitung berdasarkan jarak (d) dan arah (θ), dengan orientasi 0° , 45° , 90° , dan 135° [14]. Setelah konstruksi matriks, fitur tekstur seperti kontras, korelasi, energi, dan homogenitas akan digunakan dan dapat dihitung menggunakan rumus [15]:

1. Kontras

$$Kontras = \sum_i \sum_j (i - j)^2 G(i, j) \quad (2)$$

2. Korelasi

$$Korelasi = \sum_i \sum_j \frac{(i - \mu_x)(j - \mu_y)G(i, j)}{\sigma_x \sigma_y} \quad (3)$$

3. Energi

$$Energi = \sum_i \sum_j G(i, j)^2 \quad (4)$$

4. Homogenitas

$$Homogenitas = \sum_i \sum_j \frac{G(i, j)}{1 + |i - j|} \quad (5)$$

Di mana:

$G(i, j)$ = Nilai matriks GLCM pada posisi (i, j)


μ_x, μ_y = Rata-rata dari baris dan kolom

σ_x, σ_y = Standar deviasi dari baris dan kolom

2.4. K-fold Cross Validation

K-fold cross-validation adalah salah satu metode evaluasi yang digunakan dalam pembelajaran mesin untuk mengukur performa model secara lebih akurat dan mengurangi risiko bias [16]. Teknik ini bekerja dengan membagi dataset menjadi k subset atau lipatan (*fold*), di mana setiap subset secara bergantian digunakan sebagai data uji, sementara lipatan lainnya digabungkan untuk membentuk data latih. Proses ini diulang sebanyak k kali sehingga setiap subset digunakan sebagai data uji satu kali. Pendekatan ini memastikan bahwa seluruh dataset berkontribusi baik pada pelatihan maupun pengujian model [17].

Metode ini sangat berguna untuk mengatasi masalah *overfitting* atau *underfitting*, karena semua data digunakan secara bergantian dalam pelatihan dan pengujian. Dengan demikian, *k-fold cross-validation* memberikan estimasi performa model yang lebih stabil dan generalisasi yang lebih baik pada data baru [18].



Gambar 2. K-fold Cross Validation

2.5. Kernel Extreme Learning Machine (KELM)

Kernel Extreme Learning Machine (KELM) adalah pengembangan dari *Extreme Learning Machine* (ELM), sebuah algoritma pembelajaran mesin yang awalnya dirancang untuk melatih jaringan saraf tiruan *feedforward* dengan satu lapisan tersembunyi (SLFN). ELM dikenal karena kemampuannya melatih model dengan sangat cepat tanpa perlu menggunakan metode pengulangan konvensional untuk mengoptimalkan bobot jaringan [19]. Model dasar ELM memetakan input x ke output $f(x)$ menggunakan bobot jaringan sebagai berikut:

$$f(x) = \sum_{i=1}^L \beta_i h_i(x) = h(x)\beta \quad (6)$$

Namun, metode ini memiliki keterbatasan dalam menangani data non-linear yang kompleks, terutama ketika matriks tersebut bersifat singular atau mendekati singularitas. Hal ini dapat mengakibatkan penurunan kinerja model secara signifikan. Untuk mengatasi masalah tersebut, diperkenalkan parameter kernel I/C ke dalam model ELM. Parameter ini bertujuan untuk meningkatkan kemampuan generalisasi model sekaligus memberikan stabilitas dalam menangani matriks yang bermasalah, seperti singularitas, serta dataset yang lebih kompleks yang biasanya digunakan dalam *Support Vector Machines* (SVM) diperkenalkan ke dalam ELM [20].

Dengan memasukkan parameter kernel I/C , persamaan ELM yang dinyatakan sebelumnya dapat dijabarkan. Substitusi antara persamaan $f(x) = h(x)\beta$ dan solusi bobot keluaran $\beta = H^T(I/C + HH^T)^{-1}T$ menghasilkan rumus berikut:

$$f(x) = h(x)H^T \left(\frac{I}{C} + HH^T \right)^{-1} T \quad (7)$$

Dimana:

$h(x)$ = Vektor fitur pada lapisan tersembunyi

H^T = Transpos dari matriks fitur

T = Matriks label

I/C = Parameter regulasi

Berdasarkan teori kernel, fungsi aktivasi dalam ELM digantikan dengan fungsi kernel, sehingga hubungan antara pasangan data dapat didefinisikan dalam ruang fitur berdimensi tinggi tanpa eksplisit menghitungnya. Fungsi kernel ini dinyatakan sebagai:

$$\Omega_{KELM} = HH^T, \Omega_{KELM,i,j} = h(x_i)h(x_j) = K(x_i, x_j) \quad (8)$$


Dimana:

Ω_{KELM} = Matriks kernel

$K(x_i, x_j)$ = Fungsi kernel hubungan antara data x_i dan x_j

Dengan mensubstitusi persamaan kernel Ω_{KELM} kedalam persamaan awal KELM, persamaan akhir untuk fungsi keluaran model dapat dituliskan sebagai:

$$f(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T \left(\frac{I}{C} + \Omega_{KELM} \right)^{-1} T \quad (9)$$



Gambar 3. Arsitekur Kernel Extreme Learning Machine

Setelah itu langkah berikutnya adalah menerapkan metode ini untuk proses klasifikasi. Tahapan implementasi KELM dijelaskan secara sistematis melalui langkah-langkah berikut:

Langkah 1: Inisialisasi Parameter

Inisialisasi parameter seperti jenis kernel, nilai regularisasi C dan parameter kernel σ untuk *Radial Basis Function* (RBF).

Langkah 2: Pemodelan Hidden Layer

Hidden layer dibangun dengan pemetaan input ke ruang fitur menggunakan fungsi kernel. Matriks kernel Ω_{KELM} dihitung menggunakan persamaan RBF berikut [21]:

$$K(x_i, x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{2\sigma^2} \right) \quad (10)$$

dimana x_i dan x_j adalah data input, dan σ adalah parameter kernel.

Langkah 3: Pelatihan Model

Persamaan linear dalam KELM diselesaikan untuk mencari bobot keluaran (β) sebagai berikut:

$$\beta = \left(\frac{I}{C} + \Omega_{KELM} \right)^{-1} T \quad (11)$$

dimana I/C merupakan regularisasi matriks dan T adalah matriks target untuk label kelas.

Langkah 4: Proses Pengujian

Model KELM yang telah dilatih digunakan untuk memprediksi label pada data uji (x) menggunakan persamaan:

$$f(x) = K(x, X) \left(\frac{I}{C} + \Omega_{KELM} \right)^{-1} T \quad (12)$$

dimana $K(x, X)$ adalah kernel antara data uji dan data pelatihan.

Langkah 5: Evaluasi Model

Kinerja model dievaluasi menggunakan confusion matrix untuk menghitung akurasi, sensitivitas, dan spesifisitas berdasarkan jumlah *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), dengan rumus evaluasi sebagai berikut [22]:

		Kelas Prediksi			
		K_1	K_2		K_m
Kelas Aktual	K_1	TP	FN	FN	FN
	K_2	FP	TN	TN	TN
		FP	TN	TN	TN
	K_m	FP	TN	TN	TN

Gambar 4. Multi-class Confusion Matrix

$$\begin{aligned} \text{Akurasi} &= \frac{\sum TP_{all}}{N} \times 100\% \\ \text{Spesifisitas} &= \frac{\sum \frac{TP}{TP + FN}}{n} \times 100\% \\ \text{Sensitivitas} &= \frac{\sum \frac{TN}{TN + FP}}{n} \times 100\% \end{aligned} \quad (13)$$

3. Hasil dan Pembahasan

Pada penelitian ini metode *Kernel Extreme Learning Machine* (KELM) digunakan untuk mengklasifikasikan penyakit ginjal ke dalam empat kelas utama, yaitu kista, normal, batu ginjal, dan tumor ginjal. Sebelum tahap klasifikasi, dataset yang berjumlah total 4.232 citra terlebih dahulu dibagi menjadi data training dan data testing. Teknik pembagian data dilakukan dengan *k-fold cross-validation*, menggunakan nilai $k = 5$ dan $k = 10$. Pada $k = 5$, data training berjumlah 3.386 citra dan data testing 846 citra, sementara untuk $k = 10$, data training berjumlah 3.809 citra dan data testing 423 citra.

Metode klasifikasi ini menggunakan fungsi kernel *Radial Basis Function* (RBF), dengan parameter yang diatur melalui uji coba untuk memperoleh konfigurasi optimal. Parameter σ yang digunakan memiliki nilai pada interval $[10^{-4}, 10^{-1}]$, sedangkan parameter C berada dalam rentang $[10^2, 10^4]$. Setiap kombinasi parameter diuji, dan model yang terbentuk dievaluasi berdasarkan nilai akurasi, sensitivitas, dan spesifisitas. Evaluasi dilakukan dengan menggunakan *confusion matrix* yang menggambarkan distribusi prediksi model terhadap data uji.

Hasil pengklasifikasian menghasilkan nilai akurasi paling optimal pada $k = 5$ dengan orientasi sudut 0° , berikut merupakan tabel hasil klasifikasi pada sudut 0° dikarenakan memuat nilai paling optimal dari beberapa percobaan yang telah dilakukan.

Tabel 2. Hasil Klasifikasi pada Sudut 0°

Sigma	C	Akurasi	Sensitivitas	Spesifitas	Waktu
10^{-4}	10^2	84.16%	84.51%	92.71%	6.36s
	10^3	85.11%	85.13%	93.73%	6.80s
	10^4	83.92%	84.11%	91.36%	6.24s
10^{-3}	10^2	93.26%	93.51%	97.95%	7.25s
	10^3	93.85%	93.99%	97.96%	6.83s
	10^4	94.44%	94.96%	98.04%	6.29s
10^{-2}	10^2	96.45%	96.50%	98.53%	7.39s
	10^3	97.26%	97.16%	99.05%	6.07s
	10^4	97.04%	97.03%	98.04%	7.12s
10^{-1}	10^2	71.98%	97.67%	95.33%	6.97s
	10^3	75.29%	98.84%	95.57%	7.79s
	10^4	79.55%	98.27%	96.73%	7.19s

Dari hasil diatas ditunjukkan nilai akurasi paling besar terdapat pada parameter $\sigma = 10^{-2}$ dan $C = 10^3$ dengan nilai evaluasi pada *confusion matrix* yang didapatkan menunjukkan nilai akurasi, sensitivitas, dan spesifisitas berdasarkan persamaan (13) menghasilkan nilai sebagai berikut:

Confusion Matrix				
True Class	Cyst	Normal	Stone	Tumor
Cyst	202	2	3	4
Normal	4	203	2	3
Stone		1	211	
Tumor	1	3	1	206
Predicted Class				

Gambar 5. Hasil Evaluasi dari Klasifikasi KELM

$$Akurasi = \frac{202 + 203 + 211 + 206}{846} \times 100\% = 97,26\%$$

$$Sensitivitas = \frac{\frac{202}{202+9} + \frac{203}{203+9} + \frac{211}{211+1} + \frac{206}{206+5}}{4} \times 100\% = 97,16\%$$

$$Spesifisitas = \frac{\frac{630}{630+5} + \frac{628}{628+6} + \frac{628}{628+6} + \frac{624}{624+7}}{4} \times 100\% = 99,05\%$$

Hasil evaluasi dari berbagai konfigurasi parameter menunjukkan bahwa nilai parameter σ dalam interval $[10^{-4}, 10^{-1}]$ dan C dalam rentang $[10^2, 10^4]$ menghasilkan performa model paling optimal. Model ini berhasil mencapai akurasi, sensitivitas, dan spesifisitas yang sangat tinggi yaitu 97,26%, 97,16% dan 99,05% dengan waktu training selama 6,07s. Berdasarkan nilai yang tercantum pada tabel hasil evaluasi, maka hal ini menunjukkan efektivitas antara kombinasi parameter dan metode KELM dalam tugas pengklasifikasi penyakit ginjal.

4. Kesimpulan dan Saran

Berdasarkan hasil evaluasi penelitian ini berhasil mengklasifikasikan penyakit ginjal berdasarkan citra CT scan menggunakan metode *Kernel Extreme Learning Machine* (KELM). Berdasarkan beberapa uji coba, pembagian data dengan $k = 5$ menunjukkan kinerja model yang paling optimal, khususnya pada konfigurasi parameter $\sigma = 10^{-2}$ dan $C = 10^3$, menghasilkan akurasi 97,26%, sensitivitas 97,16%, dan spesifisitas 99,05%, dengan waktu pelatihan 6,07 detik pada sudut 0° menunjukkan hasil terbalik. Secara keseluruhan, KELM mampu memberikan kinerja yang efektif dengan akurasi tinggi, sensitivitas, dan spesifisitas optimal pada data citra penyakit ginjal.

5. Daftar Pustaka

- [1] M. H. Murjanah, S. Sulastri, R. D. Martha, A. Muadifah, M. D. Siswidiani, and R. A. Wijaya, "Penyuluhan dan Pemeriksaan Urinalisa sebagai Awal Skrining Kesehatan Ginjal di Desa Jabalsari," *J. Kreat. Pengabd. Kpd. Masy.*, vol. 6, no. 7, pp. 2963–2971, 2023, doi: 10.33024/jkpm.v6i7.10148.
- [2] M. S. Hossain, S. M. Nazmul Hassan, M. Al-Amin, M. N. Rahaman, R. Hossain, and M. I. Hossain, "Kidney Disease Detection from CT Images using a customized CNN model and Deep Learning," *2023 Int. Conf. Adv. Intell. Comput. Appl.*, pp. 1–6, 2023, doi: 10.1109/AICAPS57044.2023.10074314.
- [3] S. D. Pande and R. Agarwal, "Multi-Class Kidney Abnormalities Detecting Novel System Through Computed Tomography," *IEEE Access*, vol. 12, no. October 2023, pp. 21147–21155, 2024, doi: 10.1109/ACCESS.2024.3351181.
- [4] H. Bingol, M. Yildirim, K. Yildirim, and B. Alatas, "Automatic classification of kidney CT images with relief based novel hybrid deep model," *PeerJ Comput. Sci.*, vol. 9, pp.

- 1–16, 2023, doi: 10.7717/peerj-cs.1717.
- [5] M. N. Islam, M. Hasan, M. K. Hossain, M. G. R. Alam, M. Z. Uddin, and A. Soyulu, “Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography,” *Sci. Rep.*, vol. 12, no. 1, pp. 1–14, 2022, doi: 10.1038/s41598-022-15634-4.
- [6] P. Chak, P. Navadiya, B. Parikh, and K. C. Pathak, “Neural Network and SVM Based Kidney Stone Based Medical Image Classification,” *Comput. Vis. Image Process.*, pp. 158–173, 2020.
- [7] S. A. Althubiti, S. Paul, R. Mohanty, S. N. Mohanty, F. Alenezi, and K. Polat, “Ensemble Learning Framework with GLCM Texture Extraction for Early Detection of Lung Cancer on CT Images,” *Comput. Math. Methods Med.*, vol. 2022, 2022, doi: 10.1155/2022/2733965.
- [8] R. S. P. Priya and P. S. Vadivu, “Research Article A Novel Adaptive Mutation Enhanced Elephant Herding Optimization (Ameho) Based Feature Selection And Kernel Extreme Learning Machine (Kelm) Classifier For Breast Cancer Diagnosis Turkish Journal of Computer and Mathematics Education R,” vol. 12, no. 13, pp. 1198–1216, 2021.
- [9] D. C. R. Novitasari, A. H. Asyhar, M. Thohir, A. Z. Arifin, H. Mu’jizah, and A. Z. Foeady, “Cervical Cancer Identification Based Texture Analysis Using GLCM-KELM on Colposcopy Data,” *2020 Int. Conf. Artif. Intell. Inf. Commun. ICAIIC 2020*, pp. 409–414, 2020, doi: 10.1109/ICAIIIC48513.2020.9065252.
- [10] S. Nur Aisah, D. Candra Rini Novitasari, Y. Farida, A. H. Surabaya Jalan Ir Soekarno, K. Gunung Anyar, and S. Korespondensi, “Perbandingan Metode Extreme Learning Machine (ELM) dan Kernel Extreme Learning Machine (KELM) Pada Klasifikasi Penyakit Cedera Panggul,” vol. 12, no. 2, pp. 69–78, 2023, doi: 10.14421/fourier.2023.122.69-78.
- [11] G. Parmar, R. Zhang, and J. Y. Zhu, “On Aliased Resizing and Surprising Subtleties in GAN Evaluation,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2022-June, pp. 11400–11410, 2022, doi: 10.1109/CVPR52688.2022.01112.
- [12] A. Fadjeri, B. A. Saputra, D. K. Adri Ariyanto, and L. Kurniatin, “Karakteristik Morfologi Tanaman Selada Menggunakan Pengolahan Citra Digital,” *J. Ilm. SINUS*, vol. 20, no. 2, p. 1, 2022, doi: 10.30646/sinus.v20i2.601.
- [13] D. Agusti and A. A. Nababan, “Penerapan Metode Harmonic Mean Filter Dalam Mereduksi Gaussian Noise Pada Citra Digital,” *J. Nas. Komputasi dan Teknol. Inf.*, vol. 5, no. 3, pp. 565–571, 2022, doi: 10.32672/jnkkti.v5i3.4468.
- [14] R. Sandha and N. Kirubanandasarathy, “QR image feature extraction effectiveness based on metrics using spectral clustering and grey level Co-Occurrence matrix algorithm,” *Mater. Today Proc.*, vol. 33, no. xxxx, pp. 4112–4116, 2020, doi: 10.1016/j.matpr.2020.06.551.
- [15] S. Bakheet and A. Al-Hamadi, “Automatic detection of COVID-19 using pruned GLCM-Based texture features and LDCRF classification,” *Comput. Biol. Med.*, vol. 137, no. August, p. 104781, 2021, doi: 10.1016/j.compbiomed.2021.104781.

- [16] I. Castiglioni *et al.*, “AI applications to medical images: From machine learning to deep learning,” *Phys. Medica*, vol. 83, no. February, pp. 9–24, 2021, doi: 10.1016/j.ejmp.2021.02.006.
- [17] Q. Ren, M. Li, and S. Han, “Tectonic discrimination of olivine in basalt using data mining techniques based on major elements: a comparative study from multiple perspectives,” *Big Earth Data*, vol. 3, no. 1, pp. 8–25, 2019, doi: 10.1080/20964471.2019.1572452.
- [18] B. Ghogh and M. Crowley, “The Theory Behind Overfitting, Cross Validation, Regularization, Bagging, and Boosting: Tutorial,” no. 3, 2019, [Online]. Available: <http://arxiv.org/abs/1905.12787>
- [19] Y. Tian, J. Zhang, L. Chen, Y. Geng, and X. Wang, “Single Wearable Accelerometer-Based Human Activity Recognition via Kernel Discriminant Analysis and QPSO-KELM Classifier,” *IEEE Access*, vol. 7, pp. 109216–109227, 2019, doi: 10.1109/ACCESS.2019.2933852.
- [20] L. Lv, W. Wang, Z. Zhang, and X. Liu, “A novel intrusion detection system based on an optimal hybrid kernel extreme learning machine,” *Knowledge-Based Syst.*, vol. 195, no. xxxx, 2020, doi: 10.1016/j.knosys.2020.105648.
- [21] Y. Shi, P. Li, H. Yuan, J. Miao, and L. Niu, “Fast kernel extreme learning machine for ordinal regression,” *Knowledge-Based Syst.*, vol. 177, pp. 44–54, 2019, doi: 10.1016/j.knosys.2019.04.003.
- [22] M. Heydarian, T. E. Doyle, and R. Samavi, “MLCM: Multi-Label Confusion Matrix,” *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: 10.1109/ACCESS.2022.3151048.