

Klasifikasi Penyakit Tumor Ginjal Menggunakan SVM dengan Ekstraksi Ciri HOG dan GLCM**Muhammad Eric Affandy¹, Mohamad Sofie², Muhammad Rofi'i³**ericmuhammad904@gmail.com¹, msocie.ms@gmail.com², mohmdrofii@gmail.com³^{1,2,3}D-III Teknik Elektromedik, Sekolah Tinggi Ilmu Kesehatan Semarang**Informasi Artikel**

Diterima : 13 Mei 2025

Direvisi : 23 Mei 2025

Disetujui : 16 Jun 2025

Kata Kunci

Tumor ginjal, GLCM, HOG, SVM

Abstrak

Deteksi dini terhadap tumor ginjal sangat penting untuk meningkatkan peluang kesembuhan pasien. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi citra CT scan ginjal guna membedakan antara ginjal normal dan ginjal yang mengandung tumor. Metode klasifikasi yang digunakan adalah *Support Vector Machine* (SVM) dengan tiga jenis kernel, yaitu *linear*, *polynomial*, dan *radial basis function* (RBF). Sebelumnya, dilakukan ekstraksi fitur menggunakan dua pendekatan, yaitu *Histogram of Oriented Gradients* (HOG) untuk mendapatkan nilai bentuk, serta *Gray Level Co-occurrence Matrix* (GLCM) untuk mendapatkan ciri tekstur dari citra. Hasil pengujian menunjukkan SVM dengan kernel *linear* memberikan akurasi tertinggi sebesar 92,5%, diikuti oleh *polynomial* sebesar 85%, sedangkan kernel RBF hanya mencapai 50%. Berdasarkan hasil tersebut, dapat disimpulkan bahwa kombinasi ekstraksi fitur HOG dan GLCM yang diikuti dengan klasifikasi menggunakan SVM kernel *linear* efektif untuk membedakan citra ginjal normal dan tumor ginjal. Penelitian ini memberikan kontribusi positif dalam pengembangan sistem pendukung diagnosis penyakit ginjal berbasis citra medis.

Keywords

Kidney tumors, GLCM, HOG, SVM

Abstract

Early detection of kidney tumors is essential to increase the chances of a patient's recovery. This study aims to develop a classification system for kidney CT scan images to distinguish between normal kidneys and kidneys containing tumors. The classification method used is Support Vector Machine (SVM) with three types of kernels, namely linear, polynomial, and radial basis function (RBF). Previously, feature extraction was performed using two approaches, namely Histogram of Oriented Gradients (HOG) to obtain shape values, and Gray Level Co-occurrence Matrix (GLCM) to obtain texture characteristics of the image. The test results show that SVM with a linear kernel gives the highest accuracy of 92.5%, followed by polynomial at 85%, while the RBF kernel only reaches 50%. Based on these results, it can be concluded that the combination of HOG and GLCM feature extraction followed by classification using linear kernel SVM is effective for distinguishing normal kidney images and kidney tumors. This research makes a positive contribution to the development of a medical image-based kidney disease diagnosis support system.

A. Pendahuluan

Ginjal adalah kelenjar penting dalam saluran kemih karena berfungsi untuk menghilangkan racun dari sistem peredaran darah, menjaga keseimbangan cairan dan elektrolit tubuh. Ginjal juga berfungsi mengontrol kadar gula darah, dan berpartisipasi dalam pembuatan hormon. Ginjal membantu menjaga keseimbangan elektrolit dan air dalam tubuh manusia dengan membuang dan memurnikan limbah. Ginjal juga mengeluarkan berbagai jenis protein dan mengontrol tekanan darah tinggi. Salah satu dari sepuluh penyakit yang paling umum terjadi pada pria dan wanita adalah kanker ginjal. Ada kemungkinan 1 banding 75 (1,34%) kanker ginjal berkembang. Diperkirakan 400.000 orang terkena karsinoma ginjal (RC), kondisi urologi yang berpotensi fatal, setiap tahun. Penyakit ginjal adalah masalah kesehatan masyarakat yang serius di seluruh dunia. Pada tahun 2018, 175.000 orang meninggal karena tumor ginjal, yang merupakan sekitar 1,8% dari semua kematian akibat tumor di seluruh dunia [1], [2].

Computer Tomography (CT) dianggap sebagai salah satu modalitas pencitraan terbaik dan telah menjadi modalitas standar untuk menganalisis dan menilai tumor di ginjal. Segmentasi nodul tumor yang akurat dari citra CT scan sangat penting, karena memberikan informasi yang diperlukan sangat terkait dengan diagnosis dini tumor ginjal. Segmentasi nodul tumor juga digunakan untuk menghitung ukuran total ginjal untuk memprediksi fungsi ginjal, dan meningkatkan kemungkinan kelangsungan hidup pasien [2], [3].

Melalui penelitian, sektor teknologi yang terus berkembang bertujuan untuk membantu dalam aktivitas sehari-hari. Salah satu penelitian terus-menerus yang bertujuan untuk identifikasi tumor ginjal. Karena bidang pengolahan citra mencakup banyak hal, seperti fotografi, seni, matematika, fisika, elektronika, dan teknologi komputer, penelitian ini sangat penting. Visi komputer dan pemrosesan citra saling terkait. Fokus utama visi komputer adalah menemukan objek, menyebarkannya, dan mengklasifikasinya [4], [5].


Dokter mengidentifikasi dan mengklasifikasikan tumor ginjal secara manual yang kurang efektif, karena mereka tidak dapat membedakan ciri morfologi seperti bentuk, tekstur, dan warna. Pengolahan citra digunakan untuk melakukan penelitian untuk menyelesaikan masalah tersebut. Pada penelitian sebelumnya menggunakan dataset ginjal sehat dan tumor ginjal. Penelitian sebelumnya menggunakan metode *machine learning* dengan data CT scan yaitu Maha Gharaibeh, dkk menerapkan beberapa metode HOG, MMD, LBP, SURF, ANN, SVM, CNN, dan InceptionV3 akurasi tertinggi sebesar 95% [6]. Sakib Mahmud, dkk menggunakan metode ROI menggunakan YOLO, dan Logistic Regression didapat akurasi sebesar 90,63% [7]. Oleh Jie Xu, dkk dengan metode XGBoost, *random forest* (RF) didapat akurasi sebesar 95% [8]. Oleh Bansari Shah, dkk menggunakan metode CNN-4 2D didapat akurasi sebesar 92% [9]. Oleh Khadim, dkk penelitian pada karsinoma sel ginjal menggunakan metode GLCM dan filter gabor dengan klasifikasi SVM mendapatkan akurasi sebesar 93% [10].

Mengacu pada penelitian sebelumnya menggunakan data CT scan dengan *machine learning* diperoleh hasil tingkat akurasi tertinggi dari penelitian sebelumnya yaitu 93% tetapi pada karsinoma sel, dari hasil tersebut peneliti mencoba untuk menerapkan untuk deteksi penyakit ginjal normal dan tumor ginjal. Cara yang dilakukan yaitu dengan mengambil data CT scan dengan proses

menggabungkan metode ekstraksi ciri *Histogram of Oriented Gradient* (HOG) dan *Gray Level Co-occurrence Matrix* (GLCM) dengan klasifikasi *Support Vector Machine* (SVM). Penggunaan metode ekstraksi ciri GLCM dan HOG secara kombinasi dapat memberikan representasi fitur yang lebih kaya, yang pada akhirnya dapat meningkatkan akurasi klasifikasi menggunakan SVM. Penelitian-penelitian terbaru mendukung pendekatan ini, menunjukkan bahwa integrasi fitur bentuk dan tekstur merupakan strategi yang menjanjikan dalam analisis citra medis.

B. Metode Penelitian

Perancangan dan pembuatan diagram alir sistem klasifikasi tumor ginjal menggunakan metode *Support Vector Machine* (SVM) dengan ekstraksi ciri *Histogram of Oriented Gradient* (HOG) dan *Gray Level Co-occurrence Matrix* (GLCM). Alur atau langkah-langkah pengerjaan dalam penelitian dapat dilihat pada diagram alir Gambar 1.



Gambar 1. Diagram alir perancangan penelitian

Algoritma dari Gambar 1 menjelaskan tentang perancangan penelitian yang dilakukan. Langkah awal untuk memulai pelatihan. Pengambilan citra latih ginjal sebagai citra yang akan diolah. Prapengolahan untuk membuat citra mudah dianalisis dengan cara mengubah dari RGB ke *grayscale*. Segmentasi untuk


memudahkan menganalisis dengan metode *bounding box* dengan cara memotong area objek ginjal. Ekstraksi ciri untuk mendapatkan nilai ciri dari ginjal dengan metode *Histogram of Oriented Gradient* (HOG) dan *Gray Level Co-occurrence Matrix* (GLCM). Klasifikasi untuk menentukan ginjal normal atau tumor ginjal menggunakan metode *Support Vector Machine* (SVM). Penyimpanan Basis Data Model Pelatihan, hasil pelatihan ginjal normal dan tumor ginjal disimpan sebagai model pelatihan yang nantinya digunakan sebagai *load* pengujian.

Mulai untuk pengujian, pengambilan citra uji ginjal sebagai citra yang akan diolah. Prapengolahan untuk membuat citra mudah dianalisis dengan cara mengubah dari RGB ke *grayscale*. Segmentasi untuk memudahkan menganalisis dengan metode *bounding box* dengan cara memotong area objek ginjal. Ekstraksi ciri untuk mendapatkan nilai ciri dari ginjal dengan metode *Histogram of Oriented Gradient* (HOG) dan *Gray Level Co-occurrence Matrix* (GLCM). Klasifikasi untuk menentukan ginjal normal atau tumor ginjal menggunakan metode *Support Vector Machine* (SVM). Data latih yang sudah disimpan sebagai model tersebut, kemudian dimuat (*load*) pada program untuk proses klasifikasi data uji. Hasil pengujian berupa tingkat akurasi dari klasifikasi ginjal normal atau tumor ginjal. Pengujian selesai.

Prinsip kerja keseluruhan dari perancangan penelitian dijelaskan pada tahapan berikut ini.

Akuisisi Citra

Proses akuisisi citra merupakan tahap awal untuk mengambil atau memperoleh citra digital menggunakan perangkat atau alat tambahan tertentu, dalam penelitian mengambil data sekunder dari Kaggle dataset citra ginjal dengan lisensi *open database* dari <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone> [11]. Citra yang digunakan dalam penelitian adalah citra ginjal dalam format JPEG. Citra asli yang diambil berupa citra ginjal normal dan penyakit tumor ginjal. Dua ratus data sampel masing-masing 100 untuk ginjal normal dan 100 yang terindikasi penyakit tumor ginjal. Sebagai contoh 2 sampel ginjal normal dan tumor ginjal pada Gambar 2.



Gambar 2. Citra ginjal (a) normal, (b) penyakit tumor

Prapengolahan

Prapengolahan digunakan untuk meningkatkan citra dengan menghapus latar belakang. Fitur ini digunakan untuk meningkatkan citra supaya mudah diproses dan dianalisis [12]. Langkah awal mengubah citra dari RGB ke *grayscale*.

Dengan mengubah citra menjadi *grayscale* memudahkan untuk proses selanjutnya yaitu segmentasi dan ekstraksi ciri [13], [14].

Segmentasi

Setelah dilakukan proses perbaikan citra, selanjutnya dilakukan segmentasi citra. Proses segmentasi memudahkan untuk menganalisis lebih lanjut dan mengenali informasi yang terdapat dalam citra. Metode *Bounding box* adalah sebuah kotak persegi panjang yang mengelilingi objek target dalam citra. Kotak ini didefinisikan oleh dua koordinat (x, y) dari pojok kiri atas dan pojok kanan bawah (atau oleh titik pusat, lebar, dan tinggi). *Bounding box* digunakan untuk menunjukkan keberadaan dan lokasi objek, bukan detail piksel objek tersebut. *Bounding box* digunakan dengan cara memotong area objek ginjal. Citra *grayscale* diubah ke dalam bentuk citra *blackwhite* untuk memudahkan mendeteksi area objek. Kemudian deteksi area objek dengan *bounding box* dan dilakukan *cropping* sehingga hanya area yang ada objeknya yang di tampilkan. Hasil *cropping* dikembalikan lagi dalam bentuk *grayscale* untuk memudahkan dalam proses selanjutnya yaitu ekstraksi ciri [15], [16]. Gambar 3 menunjukkan segmentasi menggunakan bounding box dan cropping.



Gambar 3. Segmentasi menggunakan bounding box dan cropping

Ekstraksi Ciri

Proses selanjutnya bagian hasil segmentasi diekstraksi untuk mendapatkan informasi tentang bagian yang terdampak penyakit. Ekstraksi tekstur dilakukan menggunakan metode GLCM. *Gray Level Co-occurrence Matrix* (GLCM) merupakan metode ekstraksi fitur yang digunakan untuk tekstur yang menghasilkan kalkulasi statistik. Fitur tekstur dapat dihitung dari GLCM yang dihasilkan, seperti Angular Second Moment (ASM)/energi, kontras, korelasi, dan Inverse Different Moment (IDM)/homogenitas. Nilai tersebut didapatkan dari sudut 0° sebagai sudut default serta jarak antar piksel dari citra hasil segmentasi. Fitur ekstraksi ciri tekstur [17]–[20]:

1. Momen Angular Kedua (Angular Second Moment/Energy/Uniformity)

ASM atau energi memiliki kemampuan untuk mengukur intensitas keabuan atau keseragaman tekstur dan kepadatan citra dalam matriks GLCM. Jika perubahan intensitas pada citra kecil maka nilai ASM akan besar. Berikut Persamaan 1 untuk menghitung nilai ASM:

$$f_1 = \sum_i \sum_j \{p(i, j)\}^2 \quad (1)$$

2. Kontras (Contrast/Inertia)

Kontras menunjukkan ukuran penyebaran (momen inersia) elemen-elemen matriks citra. Jika letaknya jauh dari diagonal utama, nilai kontras semakin besar. Secara visual, nilai kekontrasan adalah ukuran variasi antar derajat keabuan suatu daerah citra. Berikut Persamaan 2 untuk menghitung nilai kontras:

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \right\}_{|i-j|=n} \quad (2)$$

3. Korelasi (Correlation)

Korelasi menunjukkan ukuran ketergantungan linier antara nilai skala keabuan pada suatu citra. Berikut Persamaan 3 untuk menghitung nilai korelasi:

$$f_3 = \frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3)$$

4. Momen Selisih Terbalik (Inverse Difference Moment/Homogeneity)

Momen selisih terbalik atau biasa disebut keseragaman, merupakan ciri yang menunjukkan keseragaman citra dengan derajat keabuan yang sama dalam matriks kookurensi. Nilai energi meningkat ketika pasangan piksel yang memenuhi persyaratan matriks intensitas kejadian bersama terkonsentrasi pada sejumlah kecil koordinat, dan menurun ketika mereka tersebar. Oleh karena itu, dapat kita simpulkan bahwa citra yang homogen mempunyai nilai IDM yang besar. Berikut Persamaan 4 untuk menghitung nilai IDM:

$$f_5 = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j) \quad (4)$$

Keterangan:

$p(i, j)$ = (i, j) masukan dalam matriks ketergantungan spasial aras keabuan yang dinormalisasi, $P(i, j) / R$.

$p_x(i)$ = i masukan ke matrik probabilitas marjinal yang diperoleh dengan menjumlahkan baris-baris dari $p(i, j), = \sum_{j=1}^{N_g} P(i, j)$.

N_g = Jumlah tingkat keabuan yang berbeda dalam gambar terkuantisasi

$\sum_i$ dan $\sum_j \sum_{i=1}^{N_g} \sum_{j=1}^{N_g}$ masing-masing.

Penelitian Haralick mengusulkan 14 fitur ekstraksi, pada jurnal lainnya [21] didapatkan 4 fitur yang paling baik untuk digunakan yaitu Angular Second Moment (ASM)/energi, kontras, korelasi, dan Inverse Different Moment (IDM)/homogenitas. Penggunaan keempat sifat ini didasarkan pada fungsi program MATLAB yaitu greycoprops yang memiliki jumlah sifat yang relatif sedikit sehingga mengurangi waktu yang diperlukan untuk pelatihan dan pengujian.

Ekstraksi ciri *Histogram of Oriented Gradient* (HOG) adalah metode ekstraksi fitur yang menangkap informasi tepi dan bentuk objek dalam citra dengan menghitung distribusi orientasi gradien. Dalam penelitian oleh Bhattarai, dkk HOG digunakan untuk menghasilkan pseudo-label dalam pembelajaran multi-tugas pada segmentasi citra medis. Pendekatan ini meningkatkan kinerja model segmentasi dengan memanfaatkan informasi struktural dari HOG tanpa memerlukan anotasi tambahan [22].

Selain itu, Alhakeem dan Jang mengembangkan deskriptor M-HOG berbasis proyeksi matriks untuk klasifikasi mammogram. Metode ini mengurangi biaya komputasi dengan menghindari operasi pemindaian iteratif dan menunjukkan kinerja yang menjanjikan dalam hal akurasi dan efisiensi komputasi [23]. Metode ekstraksi fitur HOG dan GLCM telah terbukti efektif dalam menangkap informasi bentuk dan tekstur dari citra medis.

Klasifikasi

Support Vector Machine untuk prediksi dalam kasus klasifikasi dan regresi adalah suatu teknik baru yang telah menjadi sangat populer dalam beberapa tahun terakhir. Teknik ini berusaha untuk menemukan fungsi pemisah (klasifier) terbaik di antara banyak fungsi untuk memisahkan dua jenis objek atau lebih. Pemisah ini disebut sebagai *hyperplane*. *Hyperplane* terbaik terletak di tengah-tengah antara dua obyek yang termasuk dalam kategori yang berbeda. Memaksimalkan margin adalah jarak tegak lurus antara *hyperplane* dan *support vector machine*. Untuk data yang tidak dapat dipisahkan secara linier, SVM menggunakan teknik kernel *trick* untuk memetakan data ke dalam ruang berdimensi lebih tinggi agar dapat dipisahkan secara linier. Beberapa fungsi kernel yang umum digunakan antara lain:

- *Linear Kernel*: digunakan ketika data dapat dipisahkan secara linier.
- *Polynomial Kernel*: memetakan data ke ruang polinomial berdimensi lebih tinggi.
- *Radial Basis Function (RBF) Kernel*: efektif untuk data *non-linear* dan sangat populer digunakan dalam pengolahan citra dan klasifikasi.

SVM dikenal dengan kemampuannya dalam menangani data berdimensi tinggi, serta *robust* terhadap *overfitting*, terutama pada kasus di mana jumlah fitur lebih besar daripada jumlah sampel, seperti pada pengolahan citra medis [17],[24].


Dalam penelitian ini, SVM digunakan sebagai metode klasifikasi utama untuk membedakan citra CT scan ginjal normal dan tumor ginjal. Ekstraksi fitur dilakukan terlebih dahulu menggunakan HOG dan GLCM, kemudian hasil ekstraksi tersebut digunakan sebagai *input* ke dalam model SVM. Tiga jenis kernel diuji dalam penelitian ini, yaitu *linear*, *polynomial*, dan RBF, untuk mengetahui kernel mana yang memberikan performa terbaik.

C. Hasil dan Pembahasan


Penelitian yang dilakukan menggunakan CT scan ginjal normal dan tumor ginjal. Citra diperoleh dari data sekunder kaggle. Data penelitian berjumlah 200 citra, dimana dibagi menjadi dua jenis yaitu data ginjal normal dan tumor ginjal.

Dua jenis citra tersebut kemudian dibagi menjadi data latih dan data uji. Data latih sebanyak 180 citra, sedangkan data uji sebanyak 40 citra. Proses klasifikasi didahului dengan ekstraksi fitur menggunakan dua teknik yaitu *Histogram of Oriented Gradients* (HOG) untuk menangkap informasi tepi dan bentuk, serta *Gray Level Co-occurrence Matrix* (GLCM) untuk mengambil fitur tekstur dari citra. Parameter GLCM terdiri dari *Angular Second Moment* (ASM)/energi, kontras, korelasi, dan *Inverse Different Moment* (IDM)/homogenitas menggunakan sudut 0° dengan 1 piksel jaraknya.


Pengujian dilakukan dengan menggunakan tiga jenis kernel pada SVM, yaitu *linear*, *polynomial*, dan *radial basis function* (RBF). Untuk mengevaluasi performa model klasifikasi, confusion matrix digunakan untuk membandingkan label sebenarnya dan diprediksi [25].



Gambar 4. Confusion matrix SVM kernel Linear



Gambar 5. Confusion matrix SVM kernel Polynomial



Gambar 6. Confusion matrix SVM kernel RBF

Berdasarkan hasil pada Gambar 4, dapat dilihat bahwa SVM dengan kernel *linear* mendapatkan nilai prediksi 0 (data ginjal normal) sebesar 95% dan prediksi 1 (data tumor ginjal) sebesar 90% dengan 37 data yang benar sesuai prediksi. Pada Gambar 5, dapat dilihat bahwa SVM kernel *polynomial* mendapatkan nilai prediksi 0 (data ginjal normal) sebesar 70% dan prediksi 1 (data tumor ginjal) sebesar 100% dengan 34 data yang benar sesuai prediksi. Pada Gambar 6, dapat dilihat bahwa SVM kernel RBF mendapatkan nilai prediksi 0 (data ginjal normal) sebesar 100% dan prediksi 1 (data tumor ginjal) sebesar 0% dengan 20 data yang benar sesuai prediksi.

Hasil akurasi klasifikasi berdasarkan tiga jenis kernel SVM ditunjukkan pada Tabel 1 berikut.

Tabel 1. Akurasi Klasifikasi Berdasarkan Jenis Kernel SVM

No.	Ekstraksi Ciri	Klasifikasi	Akurasi
1	GLCM dan HOG	SVM kernel <i>Linear</i>	92,5%
2	GLCM dan HOG	SVM kernel <i>Polynomial</i>	85%
3	GLCM dan HOG	SVM kernel <i>Radian Basis Funcion</i>	50%

Berdasarkan hasil pada Tabel 1, dapat dilihat bahwa SVM dengan kernel *linear* memberikan akurasi tertinggi sebesar 92,5%, diikuti oleh kernel *polynomial* sebesar 85%, sedangkan kernel RBF menghasilkan akurasi terendah yaitu hanya 50%. Hal ini menunjukkan bahwa data fitur hasil ekstraksi HOG dan GLCM kemungkinan memiliki distribusi yang cukup linier, sehingga pemisahan antar kelas dapat dilakukan secara efektif menggunakan *hyperplane linear*.

Kernel *polynomial* meskipun mampu menghasilkan akurasi yang cukup tinggi, menunjukkan bahwa pemetaan ke ruang berdimensi lebih tinggi tidak memberikan peningkatan performa yang signifikan, dan justru berpotensi menyebabkan *overfitting* pada data terbatas. Sementara itu, kernel RBF yang biasanya unggul dalam menangani data *non-linear*, justru tidak mampu menangkap pola pada data fitur yang digunakan dalam penelitian ini, yang kemungkinan disebabkan oleh parameter kernel yang kurang optimal atau tidak sesuai dengan karakteristik data.

Gabungan fitur HOG dan GLCM terbukti efektif dalam merepresentasikan karakteristik visual dari citra CT scan ginjal, baik dari sisi struktur bentuk maupun tekstur jaringan. Hasil ini mengindikasikan bahwa pendekatan penggabungan fitur dapat meningkatkan kemampuan diskriminatif model klasifikasi.

Akurasi tinggi pada kernel *linear* juga menunjukkan bahwa metode ini berpotensi digunakan dalam implementasi praktis karena secara komputasi lebih efisien dibandingkan kernel yang lebih kompleks. Namun, untuk meningkatkan keandalan sistem, penelitian lanjutan dapat dilakukan dengan menambahkan teknik seleksi fitur atau menggunakan metode klasifikasi *ensemble*.

D. Simpulan

Penelitian ini telah berhasil menerapkan metode klasifikasi *Support Vector Machine* (SVM) dengan pendekatan ekstraksi ciri menggunakan *Histogram of Oriented Gradients* (HOG) dan *Gray Level Co-occurrence Matrix* (GLCM) pada citra CT scan ginjal untuk membedakan antara ginjal normal dan tumor ginjal.

Berdasarkan hasil penelitian, didapatkan bahwa pemilihan kernel pada SVM memiliki pengaruh signifikan terhadap performa klasifikasi. Kernel *linear* menghasilkan akurasi tertinggi sebesar 92,5%, diikuti oleh kernel *polynomial* sebesar 85%, dan kernel RBF dengan akurasi terendah yaitu 50%. Hal ini menunjukkan bahwa karakteristik data fitur HOG dan GLCM lebih sesuai dengan pemisahan linier dalam ruang fitur. Penggunaan kombinasi fitur bentuk HOG dan tekstur GLCM terbukti mampu menangkap karakteristik penting dari tumor ginjal pada citra CT scan, sehingga dapat meningkatkan kemampuan diskriminatif model SVM. Penelitian ini juga menunjukkan bahwa metode klasifikasi berbasis SVM dengan ekstraksi fitur yang tepat dapat digunakan sebagai pendekatan awal yang efektif dalam sistem pendukung diagnosis penyakit tumor ginjal berbasis citra medis.

E. Referensi

- [1] H. Hadi dan E. Ratnawati, "(NWKNN)Identifikasi Penyakit Gagal Ginjal Menggunakan Metode Neighbor Identifikasi Penyakit Gagal Ginjal Menggunakan Metode Neighbor Weighted K-Nearest Neighbor," *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, vol. 8, no. 2, hal. 39–44, 2018.
- [2] V. V. Patel, A. R. Yadav, P. Jain, dan L. R. Cenkeramaddi, "A Systematic Kidney Tumour Segmentation and Classification Framework Using Adaptive and Attentive-Based Deep Learning Networks With Improved Crayfish Optimization Algorithm," *IEEE Access*, vol. 12, no. June, hal. 85635–85660, 2024, doi: 10.1109/ACCESS.2024.3410833.
- [3] Z. Riaz, B. Khan, S. Abdullah, S. Khan, dan M. S. Islam, "Lung Tumor Image Segmentation from Computer Tomography Images Using MobileNetV2 and Transfer Learning," *Bioengineering*, vol. 10, no. 8, hal. 1–13, 2023, doi: 10.3390/bioengineering10080981.
- [4] T. S. Prihartini dan P. N. Andono, "Deteksi Tepi dengan Metode Laplacian of Gaussian pada Citra Daun Tanaman Kopi," *Mathematics*, hal. 1–5, 2015.
- [5] D. E. Saputra dan A. F. Ibadillah, "Pengolahan Citra Digital Dalam Penentuan Panen Jamur Tiram," *Jurnal Teknik Elektro dan Komputer TRIAC*, vol. 6, no. 1, hal. 2–6, 2019, doi: 10.21107/triac.v6i1.4356.
- [6] M. Gharaibeh *dkk.*, "Radiology Imaging Scans for Early Diagnosis of Kidney Tumors: A Review of Data Analytics-Based Machine Learning and Deep Learning Approaches," *Big Data and Cognitive Computing*, vol. 6, no. 1, hal. 1–29, 2022, doi: 10.3390/bdcc6010029.
- [7] S. Mahmud, T. O. Abbas, A. Mushtak, J. Prithula, dan M. E. H. Chowdhury, "Kidney Cancer Diagnosis and Surgery Selection by Machine Learning from CT Scans Combined with Clinical Metadata," *Cancers*, vol. 15, no. 12, hal. 1–25, 2023, doi: 10.3390/cancers15123189.
- [8] J. Xu, X. He, W. Shao, J. Bian, dan R. Terry, "Classification of Benign and Malignant Renal Tumors Based on CT Scans and Clinical Data Using Machine Learning Methods," *Informatics*, vol. 10, no. 3, hal. 1–10, 2023, doi: 10.3390/informatics10030055.
- [9] B. Shah, C. Sawla, S. Bhanushali, dan P. Bhogale, "Kidney Tumor Segmentation and Classification on Abdominal CT Scans," *International*

- Journal of Computer Applications*, vol. 164, no. 9, hal. 1–5, 2017, doi: 10.5120/ijca2017913691.
- [10] D. A. Kadhim dan M. A. Mohammed, “Advanced Machine Learning Models for Accurate Kidney Cancer Classification Using CT Images,” hal. 1–25, 2025.
 - [11] M. N. ISLAM dan H. K. Mehedi, “CT KIDNEY DATASET: Normal-Cyst-Tumor and Stone.” 2021.
 - [12] T. W. A. Putra, *Pengenalan Wajah Dengan Matriks Kookurensi Aras Keabuan Dan Jaringan Syaraf Tiruan Probabilistik*. Semarang: Universitas Diponegoro, 2013.
 - [13] P. K. Garg, P. Verma, dan A. Bhardwaz, “A Survey Paper on Various Median Filtering Techniques for Noise Removal from Digital Images,” no. 1, hal. 43–47, 2014.
 - [14] K. S. Rani dan D. N. Rao, “A Comparative Study of Various Noise Removal Techniques Using Filters,” vol. 7, no. 2, hal. 47–52, 2018.
 - [15] H.-C. Shin dkk., “Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning,” *IEEE Transactions on Medical Imaging*, vol. 35, no. 5, hal. 1285–1298, 2016, doi: 10.1109/TMI.2016.2528162.
 - [16] M. Everingham, L. Van Gool, C. K. I. Williams, J. Winn, dan A. Zisserman, “The Pascal Visual Object Classes (VOC) Challenge,” *International Journal of Computer Vision*, vol. 88, no. 2, hal. 303–338, 2010, doi: 10.1007/s11263-009-0275-4.
 - [17] A. Supriyanto, R. Rizal Isnanto, dan O. D. Nurhayati, “Robusta Coffee Leaf Disease Classifications Using SVM Method and GLCM Feature Extraction,” *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, vol. 4, no. 4, hal. 241–248, 2023.
 - [18] X. Zhang, J. Cui, W. Wang, dan C. Lin, “A study for texture feature extraction of high-resolution satellite images based on a direction measure and gray level co-occurrence matrix fusion algorithm,” *Sensors (Switzerland)*, vol. 17, no. 7, 2017, doi: 10.3390/s17071474.
 - [19] F. Utaminingrum dkk., “Results in Engineering Feature selection of gray-level Cooccurrence matrix using genetic algorithm with Extreme learning machine classification for early detection of Pole roads,” *Results in Engineering*, vol. 20, no. September, hal. 101437, 2023, doi: 10.1016/j.rineng.2023.101437.
 - [20] E. Winarno, “Edge Detection and Grey Level Co-Occurrence Matrix (GLCM) Algorithms for Fingerprint Identification,” 2021.
 - [21] Seganya, Rajaram, dan Abdullah, “Efficient analysis of satellite image denoising and resolution enhancement for improving classification accuracy,” *Big Data in Medical Image Processing*, hal. 129–144, 2018, doi: 10.1201/b22456.
 - [22] B. Bhattarai, R. Subedi, R. R. Gaire, E. Vazquez, dan D. Stoyanov, “Histogram of Oriented Gradients meet deep learning: A novel multi-task deep network for 2D surgical image semantic segmentation,” *Medical Image Analysis*, vol. 85, 2023, doi: 10.1016/j.media.2023.102747.
 - [23] Z. Alhakeem dan S.-I. Jang, “An LBP-HOG Descriptor Based on Matrix Projection For Mammogram Classification,” 2019, [Daring]. Tersedia pada:

- <http://arxiv.org/abs/1904.00187>.
- [24] C. Cortes dan V. Vapnik, "Support-Vector Networks," in *Machine Learning*, vol. 20, no. 1, L. Saitta, Ed. Boston: Kluwer Academic Publishers, 1995, hal. 273–297.
- [25] Y. D. Al Iman, R. R. Isnanto, dan O. D. Nurhayati, "Klasifikasi Jenis Ikan Laut K-Nearest Neighbor Berdasarkan Ekstraksi Ciri 2-Dimensional Linear Discriminant Analysis," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 4, hal. 919–926, 2023, doi: 10.25126/jtiik.20241046787.