

Komparasi Kernel SVM Pada Klasifikasi Citra Tumor Otak Menggunakan Ekstraksi Fitur GLCM

Hanif Nur Fadlilah^{*1}, I Gede Susrama², Yisti Vita Via³

^{1,2,3}Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur

E-mail: ^{*}hanifkadot@gmail.com, ²igsusrama.if@upnjatim.ac.id, ³yistivia.if@upnjatim.ac.id

Abstrak

Otak manusia memiliki lebih dari 100 miliar sel yang berfungsi mengirimkan informasi. Tumor otak terjadi akibat pertumbuhan sel yang tidak normal di dalam atau sekitar otak. Deteksi dini sangat penting untuk mencegah perkembangan tumor ke tahap yang lebih parah. Proses manual seperti biopsi membutuhkan waktu lama dan berisiko kesalahan. Oleh karena itu, teknologi komputer seperti machine learning menjadi solusi efektif untuk mendukung diagnosis tumor otak. Penelitian ini menerapkan klasifikasi citra tumor otak menggunakan metode ekstraksi fitur GLCM dan algoritma SVM sebagai klasifier dengan empat kernel berbeda: linier, polinomial, RBF, dan sigmoid dengan parameter default. Dataset yang digunakan terdiri dari 2800 citra dengan dua kelas: tumor dan no-tumor. Hasil pengujian menunjukkan bahwa kernel linier mendapatkan akurasi 97% dan polinomial memperoleh akurasi 97%, kernel RBF mencapai 75%, sementara kernel sigmoid menghasilkan akurasi terendah sebesar 48%. Hal ini menunjukkan bahwa kernel linier dan polinomial mampu menangkap pola dengan lebih baik dibandingkan kernel lainnya dalam klasifikasi citra tumor otak. Dengan confusion matrix yang tinggi, kernel linier direkomendasikan untuk digunakan dalam klasifikasi citra sejenis.

Kata Kunci—Tumor Otak, GLCM, SVM, Klasifikasi.

Abstract

The human brain contains more than 100 billion cells that function to transmit information. Brain tumors occur due to the abnormal growth of cells within or around the brain. Early detection is crucial to prevent tumors from progressing to more severe stages. Manual processes such as biopsies are time-consuming and prone to errors. Therefore, computer technology, such as machine learning, offers an effective solution to support brain tumor diagnosis. This study applies brain tumor image classification using the GLCM feature extraction method and the SVM algorithm as a classifier with four different kernels: linear, polynomial, RBF, and sigmoid with default parameter. The dataset used consists of 2,800 images divided into two classes: tumor and no-tumor. Testing results indicate that the linear kernel achieved an accuracy of 97%, while the polynomial kernel also reached 97%. The RBF kernel achieved 75% accuracy, while the sigmoid kernel produced the lowest accuracy at 48%. These results demonstrate that the linear and polynomial kernels are better at capturing patterns compared to other kernels for brain tumor image classification. With a high confusion matrix score, the linear kernel is recommended for similar image classification tasks.

Keywords—Brain Tumor, GLCM, SVM, Classifier.

1. PENDAHULUAN

Organ yang berfungsi sebagai pusat sistem saraf adalah otak. Otak merupakan organ vital manusia yang mampu mengendalikan segala aktivitas, baik yang dilakukan secara sadar maupun tidak sadar. Otak manusia memiliki lebih dari 100 miliar sel yang berperan dalam mengirimkan informasi, menjadikannya sistem biologis paling kompleks [1]. Kumpulan sel otak yang tumbuh secara tidak normal dan tanpa terkendali di dalam atau di sekitar otak, dikenal sebagai tumor otak [2].

Deteksi dini tumor otak akan sangat membantu pasien yang terkena tumor otak sebelum tumor berkembang ke tahap yang lebih parah. Anatomi citra kesehatan adalah salah satu dari banyak metode yang digunakan untuk deteksi dini tumor otak [2]. Ada beberapa jenis anatomi citra kesehatan, seperti *X-Ray*, *Computer Tomography (CT)*, dan *Magnetic Resonance Image (MRI)*. Citra yang dihasilkan oleh *X-Ray* memiliki kualitas yang rendah, sehingga memberikan informasi yang terbatas. *CT-Scan* lebih cocok untuk melihat struktur tulang, tetapi kurang efektif mendeteksi jaringan lunak di otak. Sebaliknya, *MRI-Scan* sangat sensitif dan mampu memberikan citra berkualitas tinggi yang jelas, menunjukkan perbedaan antara jaringan lunak dan keras di otak [3]. Dalam diagnosis manual, dokter menggunakan biopsi dan pengamatan langsung terhadap tumor otak. Namun, biopsi memerlukan waktu yang cukup lama untuk proses laboratorium, sementara diagnosis manual berisiko mengalami kesalahan [2]. Oleh karena itu, diagnosis otomatis menggunakan komputer sangat membantu dokter dalam pengambilan keputusan. Teknologi komputer seperti machine learning memberikan solusi efektif pada permasalahan ini.

Klasifikasi tumor otak telah dilakukan oleh beberapa penelitian sebelumnya, seperti Penelitian yang dilakukan oleh [4] pada tahun 2023 yang berjudul “*Klasifikasi Jenis Tumor Otak Berdasarkan Citra Glioma Menggunakan Metode Support Vector Machine*”. Penelitian ini, membahas penggunaan metode *Support Vector Machine (SVM)* untuk mengklasifikasikan jenis citra tumor otak. Tahapan dari penelitian ini meliputi pengumpulan data dari *benchmark Kaggle* sebanyak 100 data dengan dua kategori citra glioma dan citra meningioma, *preprocessing* citra terdiri dari *scaling* dan *grayscale*, lalu citra akan disegmentasi melalui tahapan *Binary Thresholding*, kemudian tahap ekstraksi fitur menggunakan *Gray Level Co-occurrence Matrix (GLCM)*, dan hasil dari citra yang selesai terekstraksi akan diklasifikasi menggunakan SVM dengan kernel *linear*. Proses pengujian dilakukan dengan 100 data training, dimana tiap kategori mempunyai 50 data training, dan 24 data testing yang digunakan, dengan 12 data testing untuk masing-masing kategori. Hasil dari penelitian ini menunjukkan hasil yang baik dalam mengidentifikasi jenis tumor otak dengan nilai akurasi 91%.

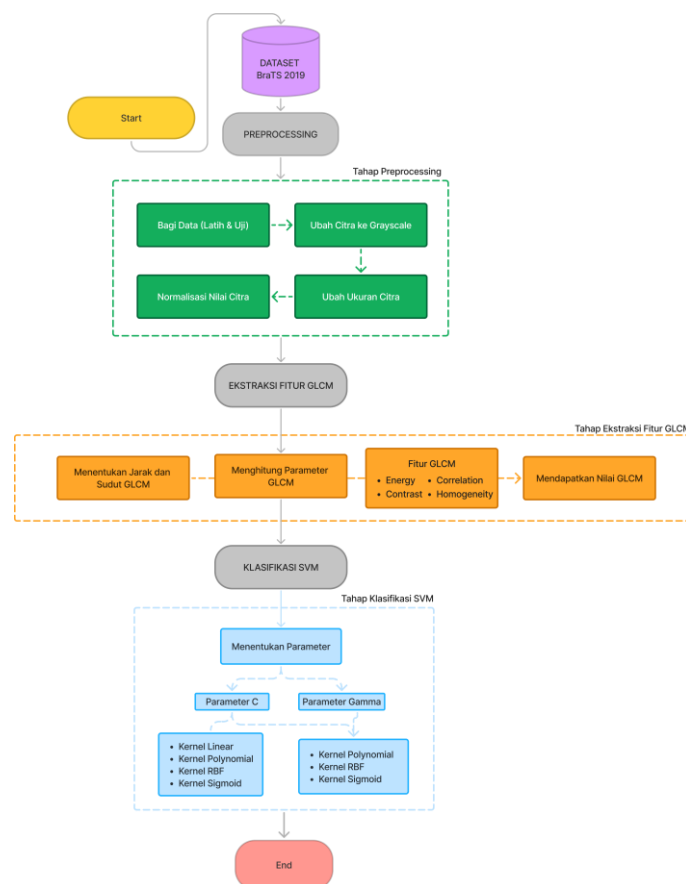
Selain itu penelitian terdapat penelitian lain yang dilakukan oleh Muhamad Saenudin [5] yang berjudul “*Classification of Covid-19 Using Feature Extraction GLCM and SVM Algorithm*”. Penelitian ini membahas klasifikasi penyakit Covid-19 menggunakan metode ekstraksi fitur *Gray Level Co-occurrence Matrix (GLCM)* dan algoritma *Support Vector Machine (SVM)* untuk analisis citra *X-ray* dada. Dataset yang digunakan terdiri dari 408 citra untuk pelatihan dan 128 citra untuk pengujian yang diambil dari *Kaggle*. Proses penelitian melibatkan pengumpulan data, ekstraksi fitur, klasifikasi, dan evaluasi model. Hasil akurasi yang diperoleh dari penelitian ini menunjukkan algoritma SVM dalam klasifikasi citra *X-ray* dada Covid-19 memberikan akurasi tertinggi sebesar 90.47% pada pengujian dengan jarak $d=1$ dan sudut $\phi=0^\circ$. Sebaliknya, akurasi terendah yang dicapai adalah 80.35% pada sudut $\phi=90^\circ$ dengan jarak $d=3$. Penelitian ini menyimpulkan bahwa sudut $\phi=0^\circ$ memberikan hasil akurasi yang lebih baik dibandingkan dengan sudut lainnya dalam semua pengujian yang dilakukan.

Berdasarkan penelitian-penelitian terdahulu, penelitian ini menggunakan tiga tahap untuk memproses klasifikasi tumor otak. Tahap pertama adalah *pre-processing*, yang kemudian dilanjutkan dengan ekstraksi fitur menggunakan *Gray Level Co-occurrence Matrix (GLCM)*, karena GLCM berfungsi untuk mengumpulkan informasi dari setiap citra MRI. Fitur GLCM yang digunakan meliputi energi, kontras, homogenitas, dan korelasi. Tahap terakhir adalah

proses klasifikasi dengan menggunakan *Support Vector Machine* (SVM). SVM dipilih karena kemampuannya yang unggul dalam menangani masalah klasifikasi dengan menemukan *hyperplane* terbaik antara kelas-kelas dan mengontrol keputusan berdasarkan kernel yang digunakan [6]. Pada penelitian ini, kernel SVM yang digunakan adalah kernel linier, RBF, polinomial, dan sigmoid. Dengan menggabungkan kedua metode ini, diharapkan dapat menghasilkan klasifikasi yang lebih akurat.

2. METODE PENELITIAN

Gambar 1 merupakan flowchart penelitian yang memberikan visualisasi diagram untuk membantu menggambarkan tahapan proses klasifikasi citra MRI tumor otak dengan menggunakan algoritma GLCM sebagai ekstraksi fitur dan SVM sebagai klasifikasi.




Gambar 1. Flowchart Penelitian

Penelitian ini dimulai dengan pengumpulan dataset citra MRI berjumlah 2800 yang terdiri dari 2 kelas yaitu kelas tumor dan no-tumor. Selanjutnya dilanjutkan tahap preproses, preproses merupakan langkah untuk meningkatkan kualitas gambar dan menyederhanakan langkah proses selanjutnya. Setelah tahap preproses dilanjutkan tahap ekstraksi fitur GLCM yang menggunakan empat fitur yakni, energi, korelasi, kontras, dan homogenitas. Setelah citra selesai dipreproses dan diekstraksi fitur, citra kemudian diklasifikasi dengan algoritma SVM yang menggunakan empat kernel yaitu, kernel linierr, polinomial, RBF, dan sigmoid. Tujuan digunakan berbagai macam kernel supaya mengetahui kernel mana yang menghasilkan akurasi paling baik pada kasus citra tumor otak. Tahap terakhir adalah evaluasi model dengan menghitung akurasi setiap kernel menggunakan *confusion matrix*.

2.1. Dataset Tumor Otak

Pada tahap pengumpulan data, dilakukan pencarian dataset yang relevan dengan penelitian ini. Dataset yang dikumpulkan terdiri dari citra MRI tumor otak dengan dua label, di mana setiap label merepresentasikan kategori citra, yaitu ada tumor dan tidak ada tumor. Dalam penelitian ini, penulis menggunakan dataset yang dibuat oleh Aryan Felix dengan nama BraTS 2019. Dataset ini tersedia secara publik di situs Kaggle dan berisi total 2800 citra MRI otak. Dataset ini memiliki dua sub kelas yakni kelas “yes” dan kelas “no”. jumlah data untuk kelas “yes” adalah 1400 gambar dan untuk kelas “no” adalah 1400 gambar. Berikut ini adalah beberapa contoh citra MRI dari dataset yang digunakan dalam penelitian.



Gambar 2. Contoh Dataset BraTS 2019

Gambar 2 merupakan contoh sampel dataset citra MRI tumor dan non-tumor. Citra yang menunjukkan adanya tumor memiliki area lesi yang menyerupai tumor, seperti pada bagian kanan, sedangkan kondisi normal tanpa tumor seperti di bagian kanan, sedangkan kondisi normal tanpa tumor seperti di bagian kiri.

2.2. Preprocessing

Sebelum melakukan klasifikasi pada data citra, seluruh citra harus melalui tahap praproses terlebih dahulu. praproses adalah langkah awal yang dilakukan untuk meningkatkan kualitas citra sebelum analisis atau ekstraksi informasi lebih lanjut. Tujuan utamanya adalah untuk menghilangkan *noise*, meningkatkan tampilan citra, memisahkan objek dari latar belakang, serta menyederhanakan proses selanjutnya [7].

Pada tahapan praproses yang dilakukan yaitu pertama, citra diubah dari format RGB ke *grayscale*. Setelah semua citra memiliki skala warna yang seragam, langkah berikutnya adalah mengubah ukuran citra menjadi 200x200 piksel untuk mengatasi variasi ukuran dan supaya semua citra memiliki ukuran yang sama. Ukuran 200x200 dipilih karena ukuran tersebut merupakan ukuran standar yang tidak terlalu besar maupun terlalu kecil. Dengan demikian ia dapat mempercepat waktu komputasi sekaligus tidak menghilangkan detail yang terdapat di dalam citra. Selanjutnya, citra dinormalisasi menggunakan teknik normalisasi *Min-Max*, di mana rentang awal 0-255 diubah menjadi 0-1 untuk mendistribusikan nilai secara lebih merata.

2.3 Gray Level Co-occurrence Matrix

Gray-Level Co-Occurrence Matrix (GLCM) adalah metode yang digunakan dalam pemrosesan citra untuk menganalisis tekstur gambar. GLCM merupakan representasi matematis yang menggambarkan hubungan spasial antara pasangan piksel dengan intensitas tertentu dalam sebuah citra. Matriks GLCM berbentuk dua dimensi dan menunjukkan frekuensi kemunculan pasangan piksel dengan intensitas pada jarak dan sudut tertentu. GLCM menyediakan informasi tentang interaksi antara intensitas piksel dalam citra, sehingga memungkinkan analisis tekstur yang lebih mendetail.

Pada penelitian ini proses ekstraksi fitur menggunakan GLCM dimulai dengan praproses citra kembali untuk mendapatkan keakuratan data, kemudian menentukan parameter GLCM, seperti jarak dan sudut, kemudian dihitung untuk setiap parameter tersebut. Penelitian ini menggunakan parameter matriks GLCM dengan sudut dan jarak default yakni sudut 0° , serta jarak 1 piksel. Untuk setiap piksel, frekuensi kemunculan pasangan piksel dengan intensitas yang sesuai akan dihitung dan dimasukkan ke dalam matriks GLCM. Selanjutnya menghitung berbagai fitur ekstraksi GLCM. Penelitian ini, terdapat empat fitur yang digunakan, yaitu energi, kontras, korelasi, homogenitas.

1) Energi

Energi (E) adalah fitur yang merepresentasikan tingkat intensitas piksel dalam sebuah gambar, di mana semakin tinggi nilai energi, semakin tinggi pula kemiripan antar piksel [8]. Energi dapat dihitung dengan persamaan 1:

$$E = \sum_x \sum_y P(x,y)^2 \quad (1)$$

2) Kontras

Kontras (I) adalah fitur untuk menunjukkan perbedaan antara dua atau lebih gambar, baik perbedaan yang disebabkan oleh faktor kecerahan maupun perbedaan warna pada setiap gambar [8]. Kontras dapat dihitung dengan persamaan 2:

$$I = \sum_x \sum_y (x - y)^2 P(x,y) \quad (2)$$

3) Korelasi

Korelasi (C) adalah fitur yang menghitung hubungan tingkat keabuan untuk beberapa pasangan piksel gambar, serta menggambarkan korelasi antara skala abu-abu linier dan derajat kemiripan [8]. Korelasi dapat dihitung dengan persamaan 3:

$$C = \frac{\sum_x \sum_y (x - \mu_s)(y - \mu_v) * P(x,y)}{\sigma_s \sigma_v} \quad (3)$$

4) Homogenitas

Homogenitas (H) adalah fitur yang menggambarkan tingkat kesamaan antara level abu-abu dalam gambar. Semakin mirip piksel dalam gambar, semakin tinggi nilai homogenitasnya [8]. Homogeniti dapat dihitung dengan persamaan 4:

$$H = \sum_x \sum_y \frac{1}{1 + |x - y|^2} P(x,y) \quad (4)$$

Setelah proses selesai, nilai atau pola dan kombinasi jarak sudut GLCM diperoleh dari setiap citra akan ditransformasi. Setiap citra yang telah memiliki pola baru akan memiliki nilai GLCM yang berbeda. Setiap fitur tersebut memberikan informasi spesifik tentang pola tekstur citra yang dapat digunakan dalam proses klasifikasi

2.4 Support Vector Machine

Support Vector Machine (SVM) merupakan algoritma pembelajaran mesin yang banyak diterapkan dalam pengolahan citra, terutama untuk masalah klasifikasi dan regresi [9]. Algoritma ini bekerja dengan menemukan garis atau batas keputusan terbaik yang dapat membagi ruang n-dimensi menjadi beberapa kelas, sehingga memungkinkan pengelompokan titik data baru dengan cepat. Batas keputusan yang optimal ini dikenal sebagai *hyperplane*.

Dalam pengolahan citra, SVM digunakan untuk mengklasifikasikan gambar berdasarkan fitur-fitur yang diekstraksi dari citra tersebut [10]. SVM tersedia memiliki dua jenis klasifikasi: SVM linier dan SVM non-linier. SVM linier digunakan untuk data yang dapat dipisahkan menjadi dua kelas dengan menggunakan garis lurus, dan pengklasifikasi ini disebut pengklasifikasi SVM linier. Sebaliknya, SVM non-linier diterapkan pada data yang tidak dapat dipisahkan secara linier, yaitu dataset yang tidak dapat diklasifikasikan dengan garis lurus [11].

Pada proses klasifikasi SVM dimulai dengan memasukkan data latih yang digunakan untuk melatih model klasifikasi. Pelatihan dilakukan dengan mencoba berbagai kernel dan parameter SVM. Kernel yang digunakan yaitu: linier, polinomial, RBF (*Radial Basis Function*), dan sigmoid. Kemudian untuk parameter yang digunakan yaitu: nilai C , γ , dan degree .

1) Kernel Linier

Kernel linier digunakan untuk menganalisis data yang dapat dipisahkan secara linier dan memiliki banyak fitur pada berbagai jenis data [8]. Kernel linier dapat dihitung dengan persamaan 5.

$$K(x, x^i) = x^T x^i \quad (5)$$

2) Kernel Polinomial

Kernel polinomial digunakan pada data non-linier untuk menyelesaikan masalah setelah semua data pelatihan dinormalisasi [12]. Kernel polinomial dihitung dengan persamaan 6.

$$K(x, x^i) = (\gamma(x^T x^i) + r)^d \quad (6)$$

3) Kernel *Radial Basis Function*

Kernel RBF digunakan untuk menangani berbagai jenis data dengan komputasi yang efisien, sehingga menghasilkan nilai yang akurat [12]. Kernel sigmoid dihitung dengan persamaan 7.

$$K(x, x^i) = \exp(-\gamma \|x - x^i\|^2) \quad (7)$$

4) Kernel Sigmoid

Kernel sigmoid merupakan kernel yang akan mengaktifkan neuron buatan dari turunan jaringan saraf [12]. Kernel sigmoid dihitung dengan persamaan 8.

$$K(x, x^i) = \tanh(\gamma(x^T x^i) + r) \quad (8)$$

Setiap kernel digunakan untuk melatih model, kemudian diuji dengan data uji. Tujuan dari pelatihan dengan berbagai kernel ini adalah untuk menemukan model SVM terbaik dalam mengklasifikasikan citra MRI tumor otak. Setelah model dilatih, pengujian dilakukan menggunakan data uji yang telah disiapkan sebelumnya, dan hasil dari masing-masing kernel SVM dievaluasi menggunakan *confusion matrix*.

2.5 Model Evaluasi

Tahap model evaluasi adalah tahap terakhir dalam penelitian ini, dimana model GLCM-SVM dengan kernel linier, polinomial, RBF, dan sigmoid yang telah dilatih akan dibandingkan untuk menilai kernel mana yang memiliki efektivitas dalam mengklasifikasikan data. Evaluasi dilakukan dengan menggunakan matrik utama menggunakan *confusion matrix*.

Confusion matrix berfungsi untuk mengukur kinerja metode prediksi dengan menghitung tingkat kebenaran proses klasifikasi [13]. Dengan membandingkan prediksi model dengan nilai data yang diuji, *confusion matrix* menunjukkan bagaimana model klasifikasi bekerja. Pada tahap evaluasi akan melibatkan beberapa percobaan yang menggunakan algoritma GLCM-SVM.

Penelitian ini akan menggunakan confusion matrix untuk menguji nilai *accuracy*, *precision*, *recall*, dan *F1-score* dari kernel yang berbeda-beda.

3 HASIL DAN PEMBAHASAN

Skenario pengujian pada penelitian ini dilakukan dengan membagi dataset menjadi dua bagian, yaitu data uji dan data latih dengan pembagian 80% untuk data latih dan 20% untuk data uji, dengan rincian 2240 gambar untuk data latih dan 560 gambar untuk data uji. Pembagian ini bertujuan untuk memastikan model yang dibuat mampu mempelajari data latih dan data uji dengan baik, sehingga dapat menghasilkan hasil yang optimal. Citra tersebut kemudian diproses melalui proses *preprocessing* dan ekstraksi fitur GLCM dengan menggunakan fitur energi, kontras, korelasi, dan homogenitas dengan sudut 0^0 dan jarak 1 piksel. Setiap skenario diuji pada kernel SVM berbeda untuk membandingkan kernel mana yang optimal untuk penelitian ini. Pengujian ini dilakukan dengan menggunakan empat kernel SVM yakni kernel linier, polinomial, *radial basic function* (RBF) dan sigmoid. Setiap kernel menggunakan berbagai macam parameter, digunakannya berbagai macam parameter untuk mengetahui parameter mana yang memiliki akurasi terbaik. Tabel 1 merupakan parameter default yang digunakan pada penelitian ini.

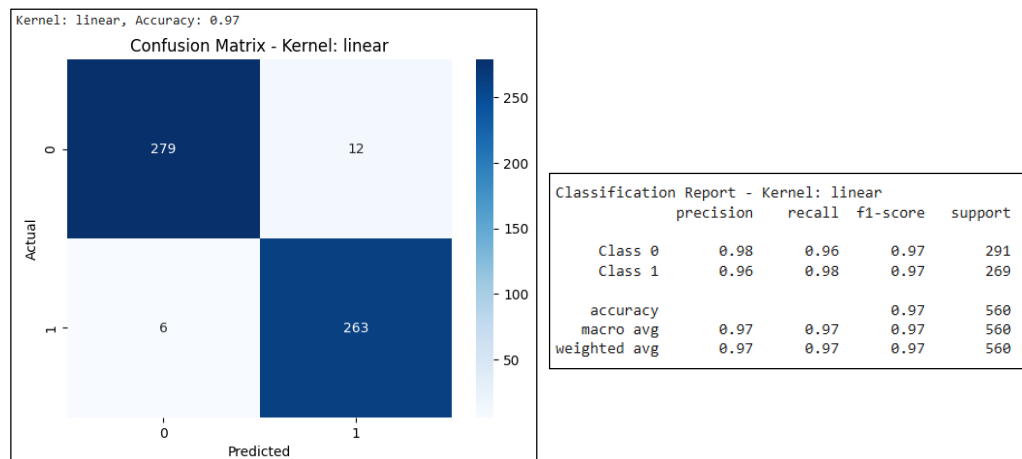
Tabel 1. Parameter Kernel SVM

Kernel	Parameter		
	C	Gamma	Degree
Linear	1	-	-
Polynomial	1	0.1	1
Radial Basis Fucntion (RBF)	1	0.1	-
Sigmoid	1	0.1	-

Parameter C mengontrol keseimbangan antara margin yang lebar dan kesalahan klasifikasi pada data *training*. Semakin kecil nilai C maka margin semakin lebar sehingga mengizinkan beberapa titik data berada di sisi yang salah dari margin, sedangkan C yang besar mencoba mengklasifikasikan semua data dengan benar, tetapi hal ini berisiko *overfitting*. Parameter Gamma menentukan seberapa jauh pengaruh satu titik data dalam kernel *non-linear*. Nilai Gamma yang tinggi menghasilkan batas keputusan yang sangat ketat, yang dapat menyebabkan *overfitting*, sementara gamma rendah menghasilkan batas yang lebih halus dan sederhana, tetapi dapat menyebabkan *underfitting*. Parameter Degree digunakan pada kernel polinomial untuk menentukan tingkat kompleksitas batas keputusan. Degree rendah menghasilkan model yang sederhana, sedangkan degree tinggi menghasilkan model yang lebih kompleks tetapi berisiko *overfitting*.

3.1.1 Pengujian Kernel Linier

Pada pengujian kernel linier, pengujian menggunakan parameter C dengan nilai yakni 1. Digunakan nilai parameter C untuk mengetahui parameter tersebut apakah memiliki kinerja optimal dan menghasilkan akurasi yang tinggi pada proses klasifikasi.

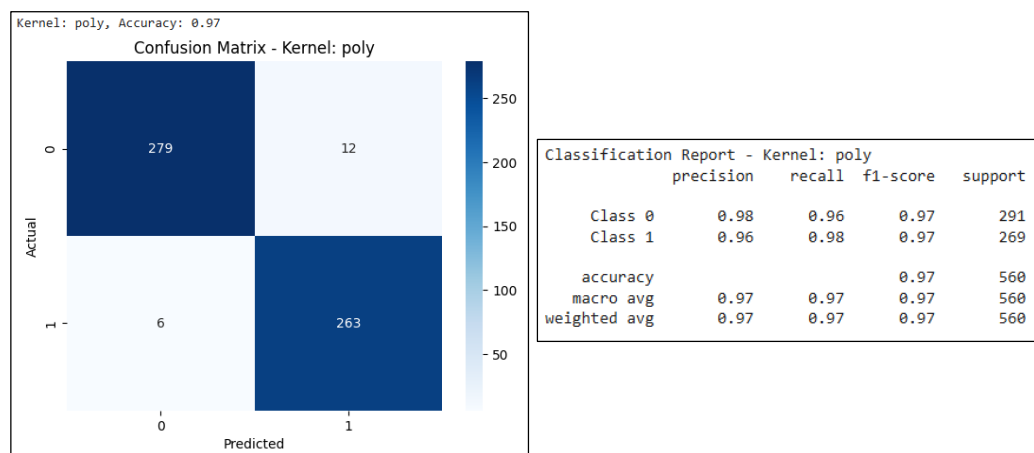


Gambar 3. Hasil Akurasi Kernel Linier

Gambar 3 merupakan hasil pengujian akurasi kernel linier yang menunjukkan performa yang sangat baik dalam mendeteksi tumor (label 1) dengan akurasi keseluruhan sebesar 97%. Dari hasil *Confusion Matrix*, sebanyak 263 kasus tumor berhasil terdeteksi dengan benar (*True Positive*), sementara 6 kasus tumor salah diklasifikasikan sebagai no-tumor (*False Negative*). Selain itu, terdapat 12 kasus no-tumor yang salah diprediksi sebagai tumor (*False Positive*). Dengan nilai Recall sebesar 98%, model mampu mengidentifikasi sebagian besar kasus tumor secara akurat, sedangkan nilai Precision sebesar 96% menunjukkan bahwa sebagian besar prediksi tumor benar adanya. Kombinasi antara Precision dan Recall menghasilkan nilai F1-Score sebesar 97%, yang mencerminkan keseimbangan performa model.

3.1.2 Pengujian Kernel Polinomial

Pengujian kernel polinomial menggunakan parameter C, degree dan gamma. Parameter C yang digunakan pada kernel polinomial adalah (1), parameter degree adalah (2). Dan parameter gamma (0.1). Penggunaan kombinasi dari parameter C, degree, dan gamma memungkinkan eksplorasi yang lebih luas untuk mencari konfigurasi parameter yang optimal.




Gambar 4. Hasil Akurasi Kernel Polinomial

Gambar 4 menunjukkan hasil klasifikasi menggunakan kernel polynomial dengan akurasi tinggi sebesar 97%. Dari confusion matrix, model berhasil mengidentifikasi 279 dari 291 sampel kelas non-tumor dengan benar, dan 263 dari 269 sampel kelas tumor dengan tepat. *Precision* untuk kelas non-tumor mencapai 98%, sementara kelas tumor mencapai 96%. *Recall* masing-masing adalah 96% dan 98%, menunjukkan model jarang melewati citra tumor.

Dengan performa ini, model sangat andal untuk klasifikasi tumor dan non-tumor, dengan tingkat kesalahan minimal dan sensitivitas yang baik terhadap klasifikasi tumor.

3.1.3 Pengujian Kernel RBF

Dalam penelitian ini, pengujian menggunakan kernel RBF pada SVM dengan berbagai parameter C dan gamma. Parameter C yang digunakan pada kernel RBF adalah (1) kemudian parameter Gamma (0.1).

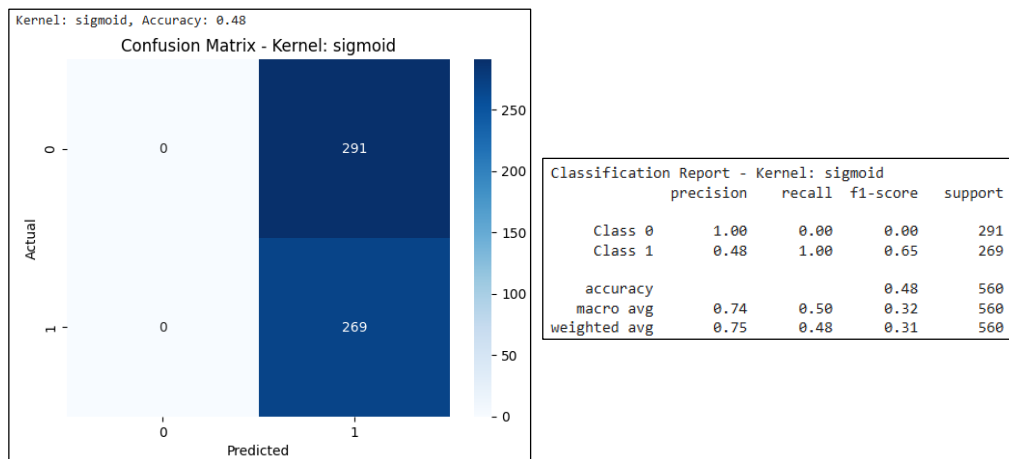


Gambar 5. Hasil Akurasi Kernel RBF

Gambar 5 menunjukkan bahwa akurasi kernel RBF memiliki akurasi sebesar 75%, yang menunjukkan performa yang kurang optimal. Dalam mendeteksi tumor (label 1), model berhasil mengidentifikasi semua citra tumor dengan benar, menghasilkan *Recall* sebesar 100%. Namun, nilai *Precision* untuk tumor hanya mencapai 66%, menunjukkan bahwa banyak prediksi tumor yang salah (*False Positive*). Kombinasi kedua metrik ini menghasilkan *F1-Score* sebesar 79%. Sebaliknya, untuk no-tumor (label 0), model memiliki *Precision* sempurna (100%), namun nilai *Recall* hanya 52%. Hal ini disebabkan oleh tingginya jumlah kasus no-tumor yang salah diklasifikasikan sebagai tumor (141 kasus). *F1-Score* untuk no-tumor adalah 68%.

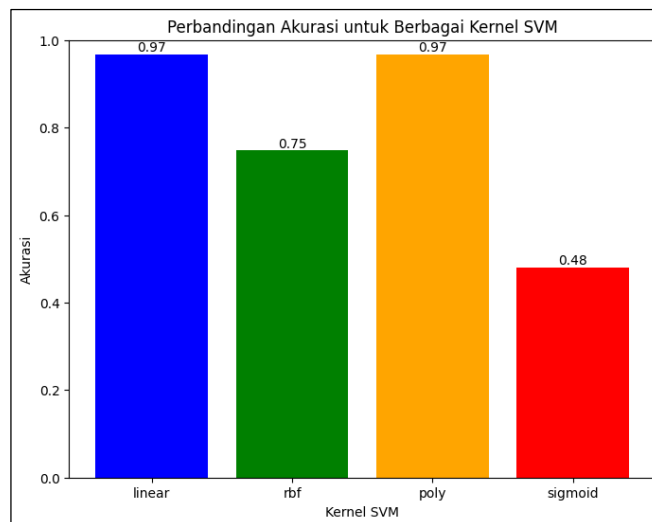
3.1.4 Pengujian Kernel Sigmoid

Pengujian menggunakan kernel sigmoid untuk mengevaluasi kinerja klasifikasi parameter, yaitu C dan gamma. Nilai parameter C berupa (1) dan (0.1) untuk parameter gamma. Dengan menggunakan keduanya, kita dapat menyesuaikan bagaimana model bekerja dalam kasus klasifikasi yang melibatkan pola *non-linear*.



Gambar 6. Hasil Akurasi Kernel Sigmoid

Gambar 6 menunjukkan hasil evaluasi model klasifikasi menggunakan kernel Sigmoid dengan akurasi sebesar 48%. *Confusion Matrix* memperlihatkan bahwa model gagal memprediksi dengan benar untuk kelas 0 (no tumor), karena semua data kelas 0 (sebanyak 291) salah diklasifikasikan sebagai kelas 1 (tumor). Sebaliknya, seluruh data kelas 1 (sebanyak 269) diprediksi dengan benar sebagai tumor, tanpa kesalahan prediksi. Dari laporan klasifikasi, *precision* untuk kelas 0 adalah 1.00, namun *recall* dan *F1-score* bernilai 0 karena tidak ada prediksi benar untuk kelas tersebut. Untuk kelas 1, *precision* mencapai 0.48, *recall* 1.00, dan *F1-score* sebesar 0.65, yang menunjukkan performa lebih baik pada deteksi tumor, tetapi dengan banyak prediksi yang salah untuk no tumor.



Gambar 7. Hasil Akurasi Kernel SVM

4 KESIMPULAN

Berdasarkan hasil perbandingan setiap kernel SVM, kernel Linear dan Polynomial memberikan performa terbaik dengan akurasi masing-masing sebesar 97%. Hal ini menunjukkan bahwa data memiliki pola yang dapat dipisahkan secara linear atau melalui hubungan non-linear sederhana, sehingga kedua kernel ini mampu menangkap pola dengan baik. Kernel RBF, dengan akurasi 75%, menunjukkan performa yang lebih rendah, kemungkinan karena model terlalu kompleks untuk data ini dan kurang efisien dalam

menangkap pola. Sementara itu, kernel Sigmoid memiliki akurasi terendah sebesar 48%, yang menunjukkan bahwa kernel ini tidak cocok untuk dataset ini, kemungkinan karena sifatnya yang kurang mampu memisahkan kelas dengan baik dalam ruang fitur.

Kesimpulannya, kernel Linear adalah pilihan terbaik karena memberikan hasil akurasi yang tinggi sekaligus efisiensi komputasi, sementara kernel Polynomial juga menjadi alternatif yang baik untuk menangkap pola non-linear sederhana.

5 SARAN

Terdapat beberapa saran yang dapat digunakan untuk pengembangan lebih lanjut terkait penelitian ini, seperti penggunaan parameter jarak dan sudut lain pada GLCM, algoritma ekstraksi fitur lain seperti CNN, dan sebagainya. Kemudian bisa juga untuk melakukan *hyperparameter tuning* untuk setiap kernel SVM untuk mengetahui kombinasi parameter yang lebih luas dan juga menggunakan algoritma klasifikasi lain CNN, KNN, RandomForest dan lainnya. Dengan begitu bisa diharapkan bisa memberikan akurasi lebih baik lagi dan bisa dimanfaatkan.

DAFTAR PUSTAKA

- [1] V. Essianda, A. D. Indrasari, P. Widyastuti, T. Syahla, and R. Rohadi, "Brain Tumor : Molecular Biology, Pathophysiology, and Clinical Symptoms," *Jurnal Biologi Tropis*, vol. 23, no. 4, pp. 260–269, 2023, doi: 10.29303/jbt.v23i4.5585.
- [2] R. Andre, B. Wahyu, and R. Purbaningtyas, "Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur Efficientnet-B3," *Jurnal IT*, vol. 11, no. 3, pp. 55–59, 2021, [Online].
- [3] I. B. L. M. Suta, R. S. Hartati, and Y. Divayana, "Diagnosa Tumor Otak Berdasarkan Citra MRI (Magnetic Resonance Imaging)," *Majalah Ilmiah Teknologi Elektro*, vol. 18, no. 2, 2019, doi: 10.24843/mite.2019.v18i02.p01.
- [4] A. J. Sinulingga, D. R. Manalu, and S. Manurung, "Klasifikasi Jenis Tumor Otak Berdasarkan Citra Glioma Menggunakan Metode Support Vector Machine," *METHODIKA: Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 2, pp. 23–25, 2023, doi: 10.46880/mtk.v9i2.1887.
- [5] M. H. Saenudin Fauzan; Riza Ibnu Adam, "Classification of Covid-19 Using Feature Extraction GLCM and SVM Algorithm," *Jurnal Mantik*, vol. 5, no. Vol. 5 No. 1 (2021): May: Manajemen, Teknologi Informatika dan Komunikasi (Mantik), pp. 179–183, 2021, [Online].
- [6] J. Sisfotenika, "Implementasi Support Vector Machine (SVM) pada Klasifikasi Jenis Tanah Memanfaatkan Fitur RGB Implementation of SVM in Soil Type Classification Using RGB Features," vol. 14, no. 2, pp. 175–184, 2024.
- [7] D. Rohpandi, A. Sugiharto, and G. A. Winara, "Aplikasi Pengolahan Citra Dalam Pengenalan Pola Huruf Ngalagena Menggunakan MATLAB," *Konferensi Nasional Sistem & Informatika*, pp. 772–777, 2015.

- [8] P. Purnawansyah *et al.*, “Comparative Study of Herbal Leaves Classification using Hybrid of GLCM-SVM and GLCM-CNN,” *ILKOM Jurnal Ilmiah*, vol. 15, no. 2, pp. 382–389, 2023, [Online].
- [9] Lisa Amelia Putri, Andriani Sitorus, Nurul Fitriah, Havni Virul, Syawaliah Putri Rangkuti, and Supiyandi Supiyandi, “Pengolahan Citra Huruf Hijaiyah Menggunakan Algoritma Support Vector Machine,” *Neptunus: Jurnal Ilmu Komputer Dan Teknologi Informasi*, vol. 2, no. 3, pp. 01–15, 2024, doi: 10.61132/neptunus.v2i3.168.
- [10] R. Pujiyanto, M. Lestari, and N. W. P. Septiani, “Pengolahan Citra Dan Metode Support Vector Machine (SVM) Dalam Pengenalan Pola Tanda Tangan,” *JRKT (Jurnal Rekayasa Komputasi Terapan)*, vol. 1, no. 01, pp. 45–51, 2021, doi: 10.30998/jrkt.v1i01.4048.
- [11] A. Srinivasa Reddy, R. Raja, N. Satheesh, and R. Muruganatham, “Brain Tumor Prediction using Adaptive Connected Component based GLCM and SVM Method,” *International Journal on Recent and Innovation Trends in Computing and Communication*, vol. 11, no. May, pp. 485–491, 2023, doi: 10.17762/ijritcc.v11i9s.7459.
- [12] A. Z. Praghakusma and N. Charibaldi, “Komparasi Fungsi Kernel Metode Support Vector Machine untuk Analisis Sentimen Instagram dan Twitter (Studi Kasus : Komisi Pemberantasan Korupsi),” *JSTIE (Jurnal Sarjana Teknik Informatika) (E-Journal)*, vol. 9, no. 2, p. 88, 2021, doi: 10.12928/jstie.v9i2.20181.
- [13] E. W. Hary Candana, I. Gede, A. Gunadi, and D. G. H. Divayana, “Perbandingan Fuzzy Tsukamoto, Mamdini Dan Sugeno Dalam Penentuan Hari Baik Pernikahan Berdasarkan Wariga Menggunakan Confusion Matrix,” *Jurnal Ilmu Komputer Indonesia (JIK)*, vol. 6, no. 2, pp. 14–22, 2021.
- [14] Kowalczyk, A. (2017). Support Vector Machines Succinctly, Syncfusion. *Succinctly E-Book Series*, 114. www.syncfusion.com.
- [15] Kim, E. (2014). *Everything You Wanted to Know about the Kernel Trick So , What is a Kernel Anyway ? Linear SVM , Binary Classification. 1*, 1–11.