

Deteksi Penyakit Cabai Berdasarkan Citra Daun Menggunakan Metode *Gray Level Co-Occurrence Matrix* Dan *Support Vector Machine*

Fahmi Zikra^{1*}, Koredianto Usman², Raditiana Patmasari³

^{1,2,3}Fakultas Teknik Elektro, Universitas Telkom, Bandung 40257, Indonesia
Email: ¹fahmiizikraa@student.telkomuniversity.ac.id, ²korediantousman@telkomuniversity.ac.id,
³raditiana@telkomuniversity.ac.id

Abstract

Chili is a type of vegetable that has the highest production level in Indonesia. However, pests or other diseases are the biggest risk in chili cultivation. The absence of a chili disease identification system based on digital images currently makes many farmers experience crop failure. Therefore, this study designed a system that is able to identify chili diseases based on leaf images using camera on smartphones for the image acquisition process. Furthermore, the leaf image data will be extracted using the Gray Level Co-occurrence Matrix method on the polynomial kernel and multiclass-based classification on the Support Vector Machine. Based on the test results with parameters of 3 characteristics including contrast, correlation, and energy and 4 characteristics including contrast, correlation, energy, and homogeneity, an accuracy rate of 95% was obtained to detect chili plant diseases through leaves in a computation time of 3 to 3.7 seconds.

Keywords : Chili Disease, Chili Leaf; Digital Image; GLCM; SVM

Abstrak

Cabai merupakan jenis sayuran yang memiliki tingkat produksi tertinggi di Indonesia. Namun demikian, hama ataupun penyakit lainnya menjadi resiko terbesar dalam budidaya tanaman cabai. Tidak adanya sistem identifikasi penyakit cabai berbasis citra digital saat ini membuat banyak petani yang mengalami gagal panen. Oleh karena itu, penelitian ini merancang sistem yang mampu mengidentifikasi penyakit cabai berdasarkan citra daun menggunakan kamera pada *smartphone* untuk proses akuisisi citra gambar. Selanjutnya, data citra daun tersebut akan diekstraksi menggunakan metode *Gray Level Co-occurrence Matrix* pada kernel *polynomial* dan klasifikasi berbasis *multiclass* pada *Support Vector Machine*. Berdasarkan hasil pengujian dengan parameter 3 ciri meliputi kontras, korelasi, dan energi dan 4 ciri meliputi kontras, korelasi, energi, dan homogeniti didapatkan tingkat akurasi sebesar 95% untuk mendeteksi penyakit tanaman cabai melalui daun dalam waktu komputasi sebesar 3 hingga 3,7 detik.

Keywords : Penyakit Cabai, Daun Cabai; Citra Digital; GLCM; SVM

1. PENDAHULUAN

Cabai merupakan tanaman dengan tingkat produksi tertinggi di Indonesia, yang menjadikan tanaman cabai sebagai peringkat tertinggi dari luas panennya dibandingkan dengan sayuran lainnya (Naully, 2016). Indonesia menempati posisi pada urutan keempat dunia sebagai penghasil cabai, yang menghasilkan 5% dari total produksi global (Mariyono & Sumarno, 2015). Dengan permintaan dan produksi yang tinggi terhadap tanaman cabai tersebut dapat dijadikan sebagai peluang untuk meningkatkan pendapatan petani dan membuka lapangan usaha untuk membudidayakan tanaman cabai.

Namun demikian, budidaya tanaman cabai merupakan kegiatan bertani yang berisiko sering terjadi gagal panen karena tanaman cabai sangat mudah terkena penyakit ataupun hama (Duriat et al., 2007). Hama ataupun penyakit yang menyerang pada tanaman cabai sangat merugikan petani jika tidak cepat ditanggulangi. Tanaman cabai yang terserang penyakit dapat diketahui dengan identifikasi secara fisik dari keadaan daunnya (Wibowo, 2017). Beberapa penyakit yang dapat diketahui melalui visualisasi dari daun adalah virus kuning, keriting, dan bercak daun. Pada daun bisa dilihat dari bentuk dan warnanya, tetapi bentuk dan warna daun pada tanaman cabai memiliki kemiripan dan kesamaan (Permadi & Harjoko, 2015). Sehingga, petani sulit untuk mengetahui penyakit yang menyerang tanamannya. Permasalahan identifikasi penyakit tanaman cabai ini bisa diatasi dengan mendeteksi penyakit berdasarkan daun pada tanaman cabai berbasis *computer vision* melalui citra digital menggunakan kamera *smartphone*. Metode yang digunakan pada penelitian ini adalah *Gray Level Co-occurrence Matrix* dan *Support Vector Machine* dengan klasifikasi sehat, virus kuning, keriting, dan bercak daun. Selain itu, sistem pada penelitian

ini dapat memberikan referensi kepada petani untuk tindakan penanggulangan dan pencegahan penyakit yang dideteksi oleh sistem.

Berdasarkan hasil pengujian yang didapatkan dari proses pembagian data didataset, sistem ini memiliki tingkat akurasi yang baik sebesar 95% untuk mendeteksi penyakit tanaman cabai melalui citra daun berbasis kamera *smartphone* menggunakan metode *gray level co-occurrence matrix* dan *support vector machine*. Pada pengujian pengaruh jenis kernel dan *multiclass* pada klasifikasi *support vector machine* mendapatkan akurasi sebesar 95% pada jenis kernel *polynomial* dengan *multiclass one-against-one*. Sistem ini menggunakan parameter 3 ciri meliputi kontras, korelasi, energi dan 4 ciri meliputi kontras, korelasi, energi, homogeniti dalam waktu komputasi 3 hingga 3,7 detik.

2. KERANGKA TEORI

2.1. Cabai

Cabai merupakan tanaman hortikultura yang berbentuk perdu tegak dengan batang berkayu. Tinggi tanaman cabe dewasa antara 65-120 cm. lebar mahkota tanaman cabe 50-90 cm (Arifin et al., 2017). Budidaya cabai sangat mudah terkena penyakit karena berbagai sebab, terutama pada saat musim hujan. Selain itu, penyakit tanaman cabai juga disebabkan oleh bakteri, jamur dan bahkan oleh hama pengganggu. Berikut ini adalah beberapa penyakit yang dapat menyerang cabai melalui pengamatan fisik pada daun

1. Penyakit Virus Kuning

Helai daun mengalami *vein clearing* yang dimulai dari pucuk daun berkembang menjadi warna kuning, tulang daun menebal dan daun menggulung ke atas. Infeksi selanjutnya dari virus kuning adalah daun akan mengecil dan berwarna kuning terang, tanaman kerdil dan produksi buah berkurang (Meilin, 2014) seperti pada Gambar 1.



Gambar 1. Penyakit Virus Kuning

2. Penyakit Bercak Daun

Penyakit ini menyebabkan kerusakan pada daun, batang dan akar. Gejala serangan penyakit ini adalah bercak bulat berwarna coklat pada daun dan kering, ukuran bercak mencapai sekitar 2.54 cm. Bercak yang tua dapat menyebabkan daun cabai berlubang (Meilin, 2014) seperti pada Gambar 2.



Gambar 2. Penyakit Bercak Daun

3. Penyakit Keriting

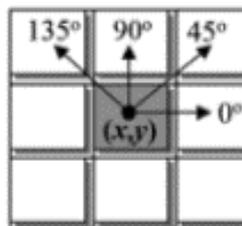
Penyakit daun keriting pada daun cabai disebabkan oleh organisme pengganggu tanaman (OPT) seperti kutu yang bersarang di daun. Daun keriting umumnya bagian tepi daun menggulung ke bagian dalam sehingga membentuk cekungan (Duriat et al., 2007) seperti pada Gambar 3.



Gambar 3. Penyakit Keriting

2.2. Gray Level Co-occurrence Matrix

Gray Level Co-Occurrence Matrix (GLCM) merupakan metode statistik untuk mengekstraksi informasi tekstur orde kedua dari citra yang merepresentasikan hubungan ketetanggaan antarpiksel dalam citra pada berbagai arah orientasi θ dan jarak spasial d (Andono et al., 2017). Metode GLCM memiliki beberapa arah derajat yang ditunjukkan pada Gambar 4.



Gambar 4. Sudut GLCM

Berikut adalah langkah-langkah kerja yang dilakukan dalam ekstraksi menggunakan metode *Gray Level Co-Occurrence Matrix (GLCM)*:

1. Quantization

Pada tahap ini, citra sudah melakukan Proses konversi citra RGB menjadi citra *grayscale* yang berfungsi untuk mengubah citra tiga dimensi menjadi satu dimensi dengan nilai intensitas yang sama, sehingga dalam proses komputasinya tidak memerlukan waktu yang lama. Setelah itu melakukan konversi pada nilai *grayscale* citra ke dalam rentang nilai-nilai tertentu. Nilai *grayscale* yang di maksud adalah 256 nilai keabuan. Tujuannya adalah untuk meringankan komputasi dan mengurangi angka pada perhitungan. Terdapat 8 rentang, dimana setiap rentang mewakili 32 nilai keabuan seperti pada Tabel 1.

Nilai Kuantisasi	Rentang Nilai
0	0 - 31
1	32 - 63
2	64 - 95
3	96 - 127
4	128 - 159
5	160 - 191
6	192 - 223
7	224 - 255

Berikut ini adalah contoh matriks $A = 5 \times 6$ yang terdapat pada persamaan matriks 1.

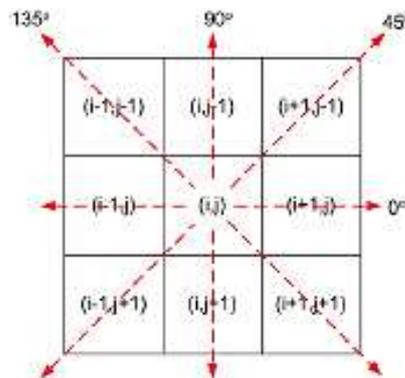
$$A = \begin{matrix} & \begin{matrix} 34 & 133 & 52 & 27 & 97 & 85 \end{matrix} \\ \begin{matrix} 100 & 80 & 112 & 71 & 47 & 129 \\ 34 & 44 & 141 & 160 & 245 & 3 \\ 54 & 137 & 99 & 78 & 162 & 253 \\ 144 & 190 & 143 & 182 & 136 & 169 \end{matrix} & \end{matrix} \quad (1)$$

Maka di dapat matriks B yang merupakan hasil kuantisasi dari matriks A , pada persamaan 2.

$$B = \begin{matrix} & \begin{matrix} 1 & 4 & 1 & 0 & 3 & 2 \end{matrix} \\ \begin{matrix} 3 & 2 & 3 & 2 & 1 & 4 \\ 1 & 1 & 4 & 5 & 7 & 0 \\ 1 & 4 & 3 & 2 & 5 & 7 \\ 4 & 5 & 4 & 5 & 4 & 5 \end{matrix} & \end{matrix} \quad (2)$$

2. Co-Occurrence

Co-Occurrence adalah jumlah kejadian satu level terhadap nilai intensitas piksel yang bertetangga dengan satu level intensitas piksel lain dalam jarak (d) dan orientasi sudut (θ) tertentu (Kasim & Harjoko, 2014). Jarak dinyatakan dengan piksel. Orientasi dibentuk dalam empat arah sudut dengan *interval* tiap sudutnya sebesar 45° sedangkan jarak antar piksel ditetapkan sebesar satu piksel seperti pada Gambar 5.



Gambar 5. Co-Occurrence

3. Feature Extraction

Dalam metode *Gray Level Co-Occurrence Matrix* (GLCM) terdapat beberapa fitur sebagai berikut:

1. Energi

Mengukur kesamaan tekstur, energi akan bernilai tinggi ketika nilai pixel satu sama dengan yang lainnya dan sebaliknya akan bernilai kecil menandakan nilai dari GLCM normalisasi adalah heterogen. Nilai tertinggi energi adalah 1 artinya distribusi pixel dalam kondisi konstan atau bentuknya yang berperiodik (Kusanti et al., 2018) dengan persamaan energi seperti pada Persamaan 3.

$$\text{Homogeniti} = \sum_i^m \sum_j^n P(i, j) \frac{P(i, j)}{1 + (i - j)^2} \quad 3$$

2. Korelasi

Mengukur linearitas (*the joint probability*) dari sejumlah pasangan pixel (Kusanti et al., 2018). Korelasi merepresentasikan keterkaitan linear dari derajat dengan citra keabuan seperti Persamaan 4.

$$\text{Korelasi} = \sum_{i=1}^K \sum_{j=1}^K \frac{(i - mr)(j - mc)p_{ij}}{\sigma_r \sigma_c} \quad 4$$

3. Kontras

Frekuensi spasial dari citra dan perbedaan moment GLCM yang dihasilkan terkait perbedaan tinggi dan rendahnya suatu pixel. Kontras bernilai 0 jika nilai ketetanggaan pixel bernilai sama (Kusanti et al., 2018) sesuai Persamaan 5.

$$\text{Kontras} = \sum_{i=0}^m \sum_{j=0}^n P(i, j) (i - j) \quad 5$$

4. Homogeniti

Homogeniti disebut juga dengan *Inverse Difference Moment* untuk mengukur tingkat homogenitas citra. Homogeniti memiliki sensitifitas terhadap nilai disekitar nilai diagonal utama. Jika nilai yang dihasilkan oleh piksel mirip atau seragam maka akan bernilai tinggi. Kebalikan dari kontras, bernilai tinggi jika pada saat energi bernilai tetap mempunyai nilai piksel yang sama (B et al., 2018). Persamaan homogeniti seperti Persamaan 6.

$$\text{Homogeniti} = \sum_i^m \sum_j^n P(i, j) \frac{P(i, j)}{1+(i-j)^2} \quad 6$$

2.3. Support Vector Machine

Support Vector Machine (SVM) adalah metode *machine learning* yang bekerja atas prinsip *Structural Risk Minimization* (SRM) dengan tujuan menemukan *hyperplane* terbaik yang memisahkan dua buah *class* pada *input space*. *Support Vector Machine* (SVM) bekerja dengan cara memetakan data ke *feature space* berdimensi tinggi sehingga titik data dapat dikelompokkan. Suatu *hyperplane* yang berada di antara kelas-kelas akan ditemukan. Kemudian data ditransformasikan sehingga *hyperplane* dapat digambarkan dengan jelas. Dengan menggunakan hasil tersebut, karakteristik dari data baru dapat digunakan untuk menentukan di kelas mana data tersebut seharusnya berada (Nugroho, Satriyo et al., 2003).

Berikut karakteristik *Support Vector Machine* (SVM):

1. Secara prinsip SVM adalah linear *classifier*
2. Pattern recognition dilakukan dengan mentransformasikan data pada *input space* ke ruang yang berdimensi lebih tinggi, dan optimisasi dilakukan pada ruang *vector* yang baru tersebut. Hal ini membedakan SVM dari solusi *pattern recognition* pada umumnya, yang melakukan optimisasi parameter pada ruang hasil transformasi yang berdimensi lebih rendah dari pada dimensi *input space*.
3. Menerapkan strategi *Structural Risk Minimization* (SRM)
4. Prinsip kerja SVM pada dasarnya hanya mampu menangani klasifikasi dua *class*.

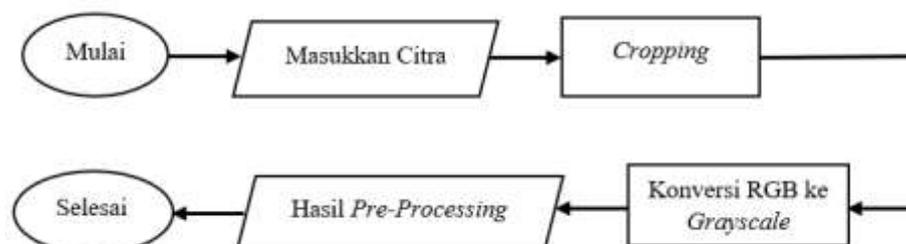
3. METODOLOGI

3.1 Akuisisi Citra

Akuisisi citra merupakan tahap awal dalam pemrosesan citra. Akuisisi citra meliputi pengumpulan data latih dan data uji untuk menghasilkan pengolahan citra yang berupa citra digital. Pada penelitian ini, proses pengambilan data dilakukan dengan pengambilan secara langsung pada tanaman cabai. Pengambilan sampel daun cabai dilakukan dengan cara memfoto daun cabai menggunakan kamera *handphone*. Data yang telah didapat memiliki ukuran yang sama yaitu 6936 x 9248 dengan format *joint photographic group* (jpg). Data daun cabai dari citra latih dan citra uji terdiri dari atas empat kelas yaitu cabai sehat, virus kuning, keriting, dan bercak daun. Data yang akan digunakan adalah sebanyak 400 citra dengan rincian 100 citra pada setiap kelas.

3.2 Pre-Processing

Preprocessing merupakan proses awal yang dilakukan setelah mendapatkan citra masukan dari akuisisi citra. Proses ini dilakukan untuk mempermudah sistem dalam mengenali objek. Untuk tahapan yang dilakukan dalam *pre-processing* seperti pada Gambar 6.



Gambar 6. Flowchart *Pre-Processing*

Berdasarkan Gambar 6, *Cropping* merupakan sebuah proses memberikan batasan yang lebih jelas dan terarah untuk mendapatkan citra dengan ukuran yang seragam. Citra awal yang masuk ke dalam sistem merupakan citra berukuran 6936 x 9248 dengan format JPG. Proses *cropping* dilakukan untuk mendapatkan citra dengan ukuran 3000 x 3000. Citra hasil ini berikutnya akan diubah ke citra *grayscale*. Proses ini berfungsi untuk mengubah citra

tiga dimensi menjadi satu dimensi dengan nilai intensitas yang sama, sehingga dalam proses komputasinya tidak memerlukan waktu yang lama. Untuk mengkonversi citra RGB menjadi citra *grayscale* seperti persamaan 7.

$$grayscale = 0.299R + 0.587G + 0.114B$$

7

3.3 Ekstraksi Ciri

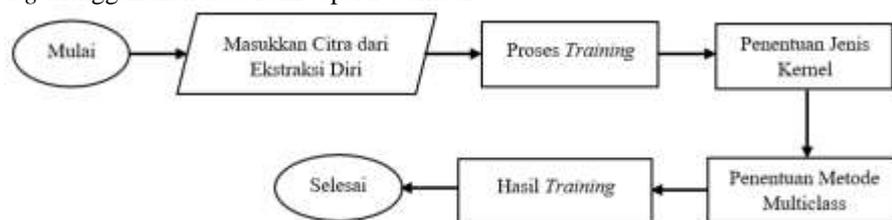
Ekstraksi ciri merupakan sebuah proses yang dilakukan terhadap citra masukan yang sudah diproses pada tahap *pre-processing* untuk memperoleh ciri tekstur citra yang merepresentasikan karakteristik dari sebuah objek sehingga dapat digunakan untuk tahap selanjutnya. Lalu ciri yang didapatkan akan digunakan sebagai pembeda antara karakter yang satu dengan yang lainnya. Ekstraksi ciri pada penelitian ini menggunakan metode *Gray Level Co-Occurrence Matrix* (GLCM) dengan tujuan untuk mengambil beberapa informasi penting dari citra daun cabai.

3.4 Klasifikasi

Klasifikasi adalah proses untuk menentukan model atau fungsi yang dapat membedakan konsep sebuah kelas data dengan tujuan untuk memprediksikan kelas yang tidak diketahui dari suatu objek. Pada umumnya, proses klasifikasi memiliki dua proses sebagai berikut:

1. Proses *Training*

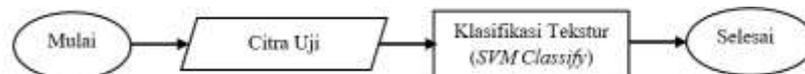
Proses *Training* merupakan tahap latih *machine learning* pada citra daun cabai menggunakan model SVM yang nantinya akan digunakan untuk mengklasifikasi penyakit cabai pada tahap pengujian atau *testing*. Tahap pelatihan yang berawal dari mendapatkan ekstraksi ciri dari citra latih. Kemudian ciri citra yang telah didapatkan dilatih dengan menggunakan SVM *training* dengan cara menentukan jenis kernel dan menentukan metode *multiclass* SVM. Untuk penentuan jenis kernel karena datanya berupa data *non-linear* maka digunakan jenis *Gaussian*, *Polynomial*, atau RBF, sehingga dibutuhkan fungsi kernel untuk mengubah data-data pada ruang dimensi awal ke ruang dimensi baru yang relatif lebih tinggi. Sedangkan penentuan metode *multiclass* SVM yang digunakan adalah *One Against One* (OAO) atau *One Against All* (OAA). Setelah itu pelatihan data dari hasil *training* SVM sudah didefinisikan tergolong sebagai data latih kelas. Flowchart dari klasifikasi pada proses *training* menggunakan data latih seperti Gambar 7.



Gambar 7. Proses *Training*

2. Proses *Testing*

Proses ini dilakukan untuk mengetahui keakuratan model yang dibangun pada proses *training*, maka digunakan data yang disebut dengan *testing set* untuk memprediksi kelas-kelasnya. Selanjutnya, fungsi SVM *classify* untuk menentukan kelas data uji dengan parameter hasil klasifikasi yang diperoleh pada tahap *training* SVM. Kemudian sistem akan menampilkan hasil klasifikasi dengan flowchart seperti pada Gambar 8.

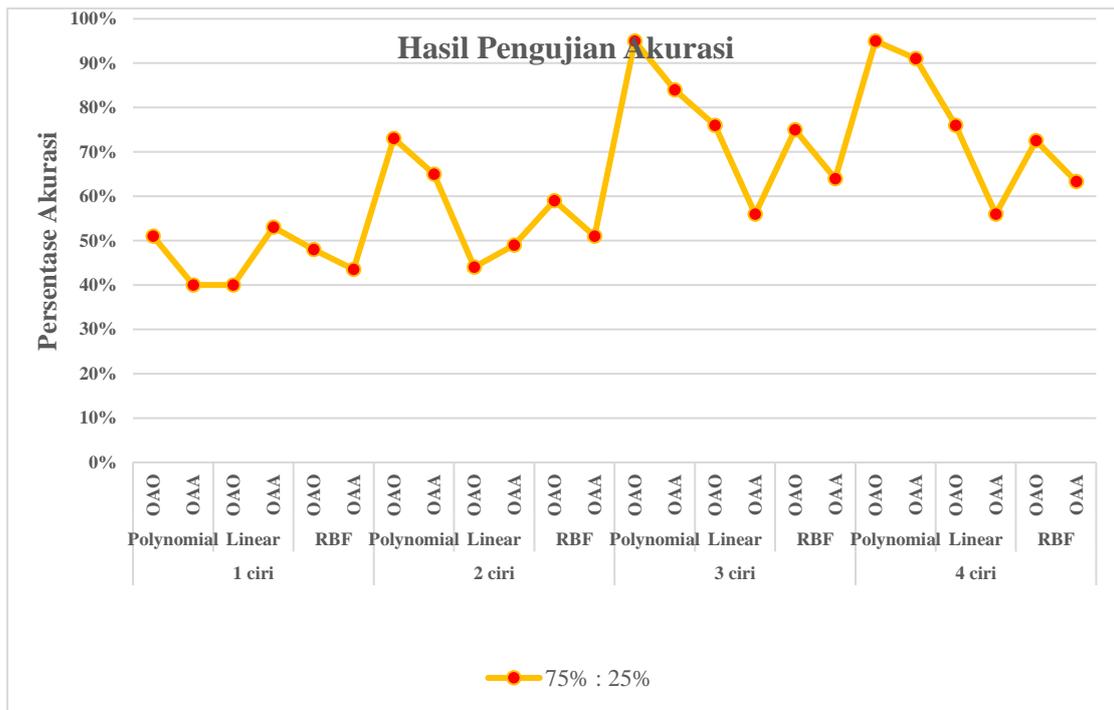


Gambar 8. Proses *Testing*

4. HASIL DAN PEMBAHASAN

4.1 Pengujian Akurasi Menggunakan Perbandingan Data di Dataset

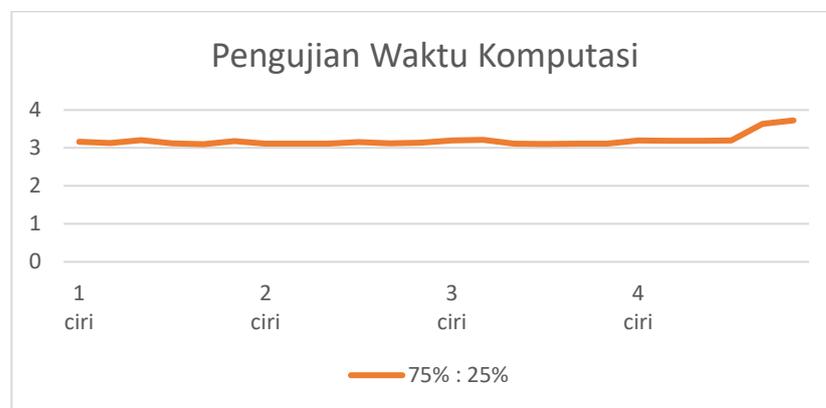
Pengujian dilakukan dengan menggunakan 400 citra yang terdiri dari 4 kelas dengan masing-masing kelas memiliki 100 citra. Berdasarkan Gambar 9, didapatkan tingkat akurasi sebesar 95% pada saat parameter 3 ciri (kontras, korelasi dan energi) dan 4 ciri (kontras, Korelasi, Energi, dan Homogeniti), jenis kernel *polynomial* dan *multiclass* OAO (*One Against One*). Sedangkan akurasi terkecil adalah 40 % dengan parameter 1 ciri (kontras), jenis kernel *polynomial* dan *multiclass* OAA (*One Against All*) dan jenis kernel linear dan *multiclass* OAO (*One Against One*). Sehingga dapat disimpulkan bahwa semakin banyak data latih maka akan semakin tinggi hasil akurasi yang didapatkan oleh sistem.



Gambar 9. Grafik Hasil Pengujian Akurasi dengan Perbandingan Data di Dataset

4.2 Pengujian Waktu Komputasi

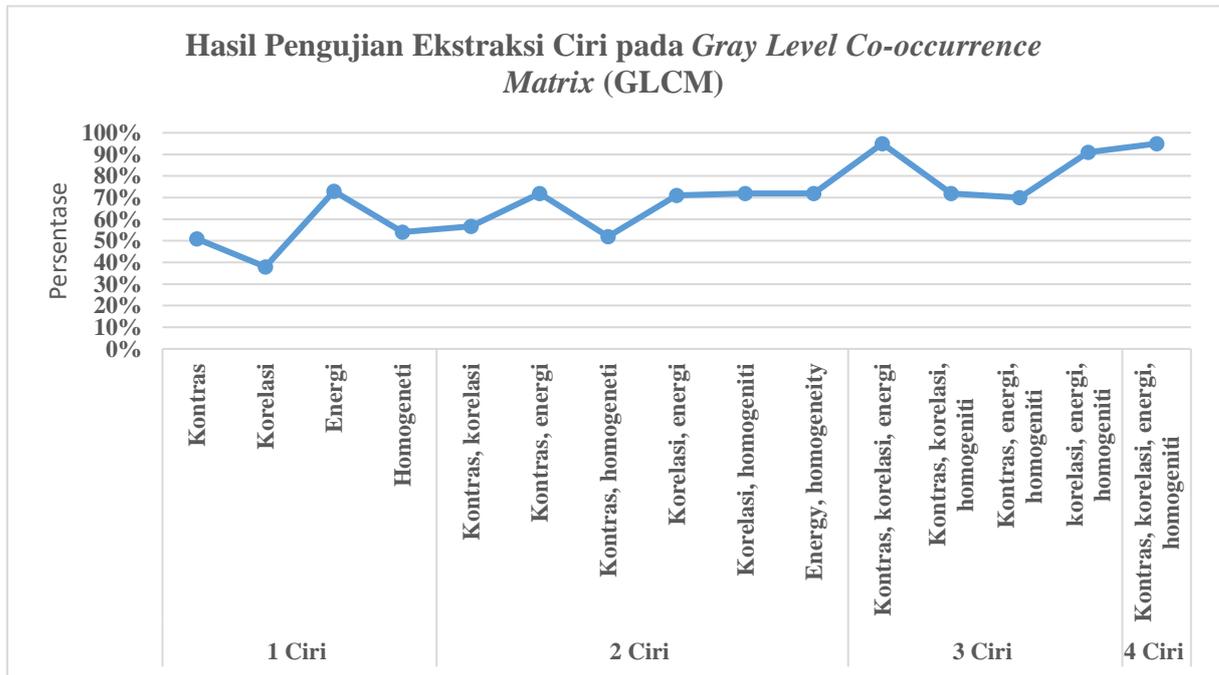
Waktu komputasi yang tertera pada sumbu Y di Gambar 10 merupakan rata-rata waktu yang dibutuhkan sistem untuk melakukan menjalankan 1 pemrosesan citra daun cabai. Pada Gambar 10, menjelaskan bahwa performansi sistem dan waktu komputasi terbesar adalah 3,7266 s dengan parameter 4 ciri (kontras, korelasi, energi, dan homogeniti), jenis kernel RBF dan *multiclass* OAA (*One Against All*). Secara umum performansi dan waktu komputasi yang digunakan relatif sama yaitu berkisar 3,0 s – 3,7 s, karena pada penelitian ini hanya menggunakan 4 ciri fitur pada ekstraksi ciri, sehingga tidak mempengaruhi waktu komputasi.



Gambar 10. Grafik Hasil Pengujian Waktu Komputasi

4.3 Pengujian Akurasi Ekstraksi Ciri pada GLCM

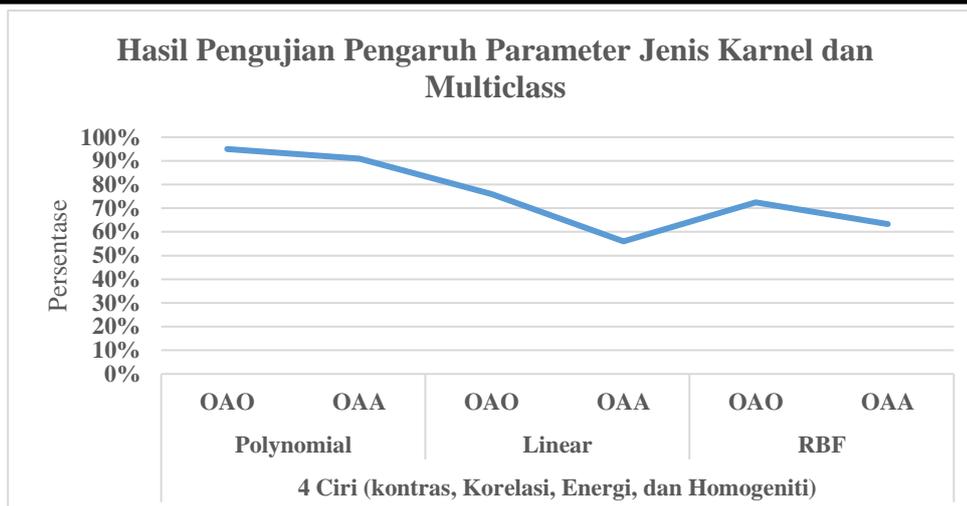
Pengujian dilakukan menggunakan perbandingan data latih sebesar 75% dan data uji sebesar 25% pada setiap kelas untuk mengetahui tingkat akurasi dan waktu komputasi terhadap pengaruh parameter ekstraksi ciri *Gray Level Co-occurrence Matrix* (GLCM). Untuk pengujian parameter ekstraksi ciri *Gray Level Co-occurrence Matrix* (GLCM) ini dilakukan kombinasi dari ciri fitur dengan menggunakan sudut 0° , 45° , 90° , dan 135° dan jarak 1 pada *Gray Level Co-occurrence Matrix* (GLCM) dan jenis kernel *polynomial* dan *multiclass* OAO (*One Against One*). Berdasarkan hasil pengujian akurasi ekstraksi ciri pada Gambar 11, semakin banyak parameter ciri yang digunakan, maka semakin banyak ciri yang didapatkan dan akurasi yang diperoleh semakin besar oleh sistem. Sehingga dapat mempermudah sistem dalam membedakan ciri pada setiap kelas.



Gambar 11. Hasil Pengujian Ekstraksi Ciri

4.4 Pengujian Pengaruh Jenis Kernel dan Multiclass

Pengujian ini untuk mengetahui hasil akurasi dari jenis kernel dan *multiclass* pada *Support Vector Machine* (SVM). Pada pengujian ini parameter ekstraksi ciri yang digunakan adalah hasil dari pengujian pada kombinasi 4 ciri dengan parameter kontras, korelasi, energi, homogeniti dengan menggunakan sudut 0° , 45° , 90° , dan 135° dan jarak 1. Berdasarkan Gambar 12, akurasi tertinggi pada jenis kernel *polynomial* dengan *multiclass* OAO (*One Against One*) sebesar 95% dan akurasi terkecil pada saat jenis kernel linear dengan *multiclass* OAA (*One Against All*) sebesar 56%. Dapat disimpulkan bahwa jenis kernel *polynomial* lebih cocok pada data jenis penelitian ini sebab jenis kernel *polynomial* mampu memprediksi kelas pada data itu sendiri, yang artinya mampu mengklasifikasikan tepat sesuai dengan kelas aslinya, dan lebih mempunyai performa lebih baik jika dibandingkan dengan jenis kernel linear dan rbf. Hal ini disebabkan karena data yang ada pada penelitian ini memiliki pola yang cenderung tidak tetap atau naik turun.



Gambar 12. Grafik Hasil Pengujian Parameter Jenis Kernel dan *Multiclass*

5. KESIMPULAN

Sistem pada penelitian ini dapat mendeteksi penyakit pada tumbuhan cabai dengan tingkat akurasi 95% pada kombinasi 3 ciri meliputi kontras, korelasi, dan energi dan 4 ciri meliputi kontras, korelasi, energi, dan homogeniti menggunakan metode *Gray Level Co-occurrence Matrix* dengan parameter *polynomial* dan *Support Vector Machine* dengan parameter *multiclass one-against-one* dalam waktu komputasi yang dibutuhkan adalah 3 – 3,7 detik. Pada pengujian pengaruh jenis kernel dan *multiclass* pada *support vector machine* (SVM) mendapat akurasi terbesar jenis kernel *polynomial* dengan *multiclass* OAO (*One Against One*) sebesar 95 %.

DAFTAR PUSTAKA

- Andono, Nurtantio, P., & Sutojo. (2017). *Pengolahan citra digital*. Andi.
- Arifin, Z., Muhimmah, I., & Fidianingsih, I. (2017). Identifikasi Kerusakan Jaringan Histologi Pada Ginjal Dengan Fitur Tekstur Menggunakan Model Fitur Gray Level Coocurrence Matrix (GLCM). *Informatics Journal*, 2(2), 101.
- B, M. M., Ana, A., & Hidayat, A. S. (2018). Implementasi Algoritma GLCM Dan MED pada Aplikasi Pendeteksi Kolesterol Melalui Iris Mata. *MIND Journal*, 2(2), 23–42. <https://doi.org/10.26760/mindjournal.v2i2.23-42>
- Duriat, A., Gunaeni, N., & Wulandari, A. (2007). *Penyakit Penting Tanaman Cabai dan Pengendaliannya*.
- Kasim, A. A., & Harjoko, A. (2014). Klasifikasi Citra Batik Menggunakan Jaringan Syaraf Tiruan Berdasarkan Gray Level Co- Occurrence Matrices (GLCM). *Seminar Nasional Aplikasi Teknologi Informasi (SNATI) Yogyakarta, 21 Juni 2014*, 7–13.
- Kusanti, J., Penyakit, K., Padi, D., & Haris, A. (2018). Klasifikasi Penyakit Daun Padi Berdasarkan Hasil Ekstraksi Fitur GLCM Interval 4 Sudut. *Jurnal Informatika: Jurnal Pengembangan IT (JPIT)*, 03(01), 1–6.
- Mariyono, J., & Sumarno. (2015). Chilli Production and Adoption of Chilli-based Agribusiness in Indonesia. *Journal of Agribusiness in Developing and Emerging Economy*, 5(1), 57–75. DOI 10.1108/JADEE-10-2012-0025
- Meilin, A. (2014). Hama dan Penyakit pada Tanaman Cabai Serta Pengendaliannya. *Science Innovation Network*, 1, 1–26.
- Naully, D. (2016). Fluktuasi dan Disparitas Harga Cabai di Indonesia. *Jurnal Agrosains Dan Teknologi*, 1(1), 57–69.
- Nugroho, Satriyo, A., Witarto, Budi, A., & Handoko, D. (2003). Support Vector Machine. *Proceedings of the 2011 Chinese Control and Decision Conference, CCDC 2011*. <https://doi.org/10.1109/CCDC.2011.5968300>
- Permadi, J., & Harjoko, A. (2015). Identifikasi Penyakit Cabai Berdasarkan Gejala Bercak Daun dan Penampakan Conidia Menggunakan Probabilistic Neural Network. *Semnaskit 20152*, 49–53.
- Wibowo, H., & Indriyani, F. (2018, October). K-Nearest Neighbor Method For Monitoring Of Production And Preservation Information (Treatment) Of Rubber Tree Plant. In *International Conference on Information Technology and Business (ICITB)* (pp. 29-44).
- Wibowo, A. P. W. (2017). Penerapan Teknik Computer Vision Pada Bidang Fitopatologi Untuk Diteksi Penyakit dan Hama Tanaman Cabai. *Jurnal Informatika: Jurnal Pengembangan IT Poltek Tegal*, 2(2), 102–108. <http://ejournal.poltektegal.ac.id/index.php/informatika/article/view/528>