



Klasifikasi Penyakit Daun Pada Tanaman Jagung Menggunakan Algoritma Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron

Jaka Kusuma¹, Rubianto², Rika Rosnelly³, Hartono⁴, B. Herawan Hayadi⁵

^{1,2,3,4,5}Magister Ilmu Komputer, Fakultas Teknik Dan Ilmu Komputer, Universitas Potensi Utama
¹jakakusuma41@gmail.com*, ²rubiantoditpi@gmail.com, ³rikarosnelly@gmail.com, ⁴hartonoibbi@gmail.com,
⁵b.herawan.hayadi@gmail.com

Abstract

Corn is one of the substitute staple foods in Indonesia after rice. Maize crops grown in Indonesia often experience considerable losses due to maize plant diseases. Generally, plant diseases are initially caused by morphological changes in the leaves. Accurate detection and classification of diseases that appear on the leaves will prevent the widespread spread of the disease. This study will compare classification algorithms, namely Support Vector Machine, K-Nearest Neighbors, and Multilayer Perceptron to find the best algorithm in the classification of leaf disease in corn plants, namely, *cercospora leaf spot gray*, common rust, and northern leaf blight using the VGG-16 deep learning model used as image feature extraction. The results showed that the Multilayer Perceptron algorithm produced the best values with accuracy, precision, and recall of 97.4% each.

Keywords: Corn Leaf Disease, Support Vector Machine, K-Nearest Neighbors, Multilayer Perceptron, VGG-16.

Abstrak

Jagung merupakan salah satu bahan pangan pokok pengganti di Indonesia setelah beras. Tanaman jagung yang ditanam di Indonesia sering mengalami kerugian yang cukup besar akibat penyakit tanaman jagung. Umumnya penyakit tanaman pada awalnya disebabkan oleh perubahan morfologi pada daun. Deteksi dan klasifikasi penyakit yang muncul pada daun secara akurat akan mencegah penyebaran penyakit yang meluas. Pada penelitian ini akan melakukan komparasi algoritma klasifikasi yaitu Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron untuk menemukan algoritma terbaik dalam klasifikasi penyakit daun pada tanaman jagung yaitu *cercospora leaf spot gray*, *common rust* dan *northern leaf blight* menggunakan model deep learning VGG-16 yang digunakan sebagai ekstraksi fitur citra. Hasil yang didapatkan menunjukkan bahwa algoritma Multilayer Perceptron menghasilkan nilai terbaik dengan *accuracy*, *precision* dan *recall* masing-masing sebesar 97.4%.

Kata kunci: Penyakit Daun Jagung, Support Vector Machine, K-Nearest Neighbors, Multilayer Perceptron, VGG-16.

1. Pendahuluan

Indonesia merupakan negara agraris dan mata pencaharian utama masyarakatnya adalah bertani. Letak geografis Indonesia yang berada di daerah tropis, sehingga kondisi iklim, tanah dan sumber daya lainnya di berbagai wilayah Indonesia memiliki potensi yang besar untuk pengembangan pertanian. Pemanfaatan sumber daya pertanian merupakan kunci untuk meningkatkan produktivitas pertanian sehingga sumber daya yang terbatas harus dialokasikan seefisien mungkin [1].

Indonesia memiliki potensi sumber daya alam yang sangat kaya. Salah satu potensi tersebut adalah sumber daya kehutanan yang merupakan komoditas utama dan banyak dimanfaatkan di sektor industri. Sumber daya kehutanan juga dapat dimanfaatkan untuk memenuhi kebutuhan masyarakat salah satunya yaitu jagung [2].

Jagung merupakan salah satu bahan pangan pokok pengganti di Indonesia setelah beras. Jagung juga ditanam dan diproses sebagai pakan ternak, minyak, tepung jagung dan bahan baku industri. Tanaman jagung yang ditanam di Indonesia sering mengalami kerugian yang cukup besar akibat penyakit tanaman jagung. Umumnya penyakit tanaman pada awalnya disebabkan oleh perubahan morfologi pada daun. Deteksi dan klasifikasi penyakit yang muncul pada daun secara akurat akan mencegah penyebaran penyakit yang meluas [3].

Deteksi, identifikasi serta penanggulangan penyakit tanaman jagung dapat dilakukan oleh seorang pakar atau ahli tanaman. Tetapi ini sangat memberatkan petani karena biaya konsultasi yang tidak murah dan memakan waktu apalagi jika petani lokasinya jauh dari kota. Hal ini dapat mengakibatkan produksi jagung menjadi menurun karena minimnya informasi terkait penyakit



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

daun pada tanaman jagung. Penggunaan sistem komputer dapat dimanfaatkan oleh para petani sebagai pengganti peran seorang pakar atau ahli tanaman dalam identifikasi penyakit tanaman.

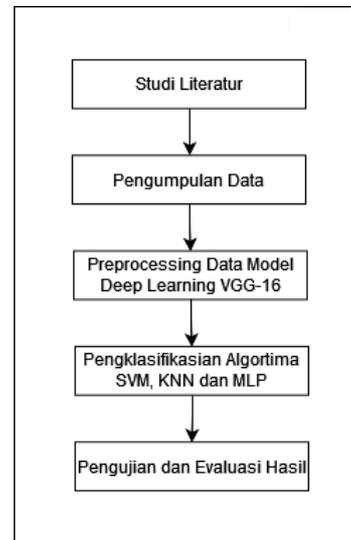
Perkembangan teknologi komputasi saat ini dan kapasitas proses komputer telah semakin meningkat sehingga komputer mampu melakukan pengenalan objek secara otomatis dengan cara mengambil dan mengolah informasi dari suatu citra [4]-[5]. Pengolahan citra ini dapat menjadi salah satu pilihan dalam pengenalan, identifikasi serta klasifikasi jenis penyakit daun pada tanaman jagung. Salah satu teknologi yang dapat digunakan adalah *data mining* yang merupakan teknologi untuk pencarian informasi dengan kapasitas data besar yang dapat mempermudah dan mempercepat pengenalan serta mengkategorikan jenis berdasarkan label dengan memanfaatkan metode-metode dalam *data mining* salah satunya yaitu klasifikasi [6].

Adapun beberapa kajian penelitian terdahulu terkait klasifikasi menggunakan teknik *data mining* dan pengolahan citra. Pada penelitian Putra, dkk [5] melakukan penelitian terkait klasifikasi menggunakan metode CNN terhadap penyakit daun jagung dengan hasil yang diberikan untuk arsitektur Resnet 50 dengan menggunakan optimizer Adam didapatkan tingkat akurasi sebesar 98,4%. Pada penelitian Hasan, dkk [6] telah melakukan penelitian terkait klasifikasi citra menggunakan model CNN VGG-16 untuk mendiagnosa penyakit daun pada anggur dengan hasil pengujian akurasi sebesar 97,25 %. Pada penelitian Kusuma, dkk [7] juga telah melakukan penelitian terkait komparasi algoritma SVM dan NB untuk klasifikasi citra ras kucing dengan hasil algoritma yang terbaik adalah SVM dengan akurasi sebesar 88,4%. Pada penelitian Gunawan dan Putra [8] melakukan penelitian terkait perbandingan metode *Multi-Class SVM*, *Backpropagation NN*, *K-NN* dan *NB* dalam identifikasi penggunaan *American Sign Language* dengan hasil *Multi-Class SVM* memiliki tingkat keberhasilan tertinggi mencapai 99,3% selanjutnya *Backpropagation NN* sebesar 98,28%, *K-NN* sebesar 97,7% dan *NB* sebesar 95,98%.

Penelitian ini akan melakukan komparasi algoritma Support Vector Machine (SVM), K-Nearest Neighbors (KNN) dan Multilayer Perceptron (MLP) dalam klasifikasi penyakit daun pada tanaman jagung menggunakan model *deep learning* VGG-16 sebagai ekstraksi fitur citra berdasarkan penelitian Veni dan Manjula [9] model *deep learning* VGG-16 membuktikan dapat meningkatkan performa akurasi. Dari beberapa arsitektur *deep learning* seperti Xception, MobileNet V1, Resnet50, dan VGG-16 berdasarkan pada penelitian Prasetyo, dkk [10] membuktikan bahwa model VGG-16 memiliki akurasi terbaik.

2. Metode Penelitian

Alur penelitian dari perbandingan algoritma SVM, KNN dan MLP dapat dilihat pada Gambar 1. Adapun tahapan yang dilakukan untuk klasifikasi penyakit daun pada tanaman jagung yaitu:

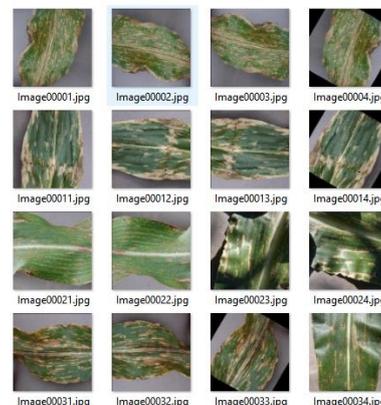


Gambar 1. Tahapan klasifikasi penyakit daun pada tanaman jagung.

2.1 Pengumpulan Data

Adapun data yang digunakan yaitu citra penyakit daun pada tanaman jagung dimana dalam pengumpulan citra tersebut didapatkan melalui data sekunder yang bersumber dari website kaggle. Adapun alasan mengapa memilih data tersebut karena memiliki kategori penyakit daun pada tanaman jagung yang sesuai dengan karakteristik serta fokus penelitian [11].

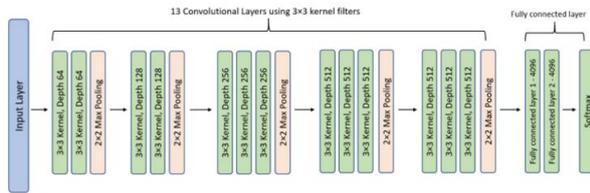
Dataset citra tersebut berisi 8200 data dengan 4 katagori yang mana terdiri dari 2050 *cercospora leaf spot gray*, 2050 *common rust*, 2050 *northern leaf blight* dan 2050 *healthy*. Setiap *dataset* dari masing-masing kelas citra daun yang digunakan dibagi menjadi data *training* dan data *testing* dengan pembagian data 80% (6560 data *training*) dan 20% (1640 data *testing*) yang mana disesuaikan dengan jumlah masing-masing 4 katagori.



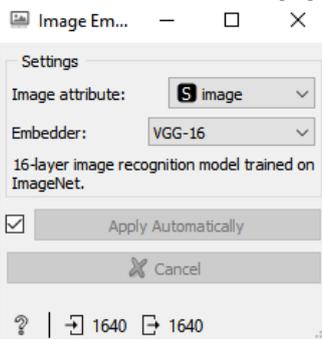
Gambar 2. *Dataset* citra penyakit daun pada tanaman jagung.

2.2 Preprocessing Data

Kemudian akan melakukan perbaikan *dataset* agar dapat diproses oleh algoritma. Langkah pada *preprocessing* sendiri meliputi penyeragaman ukuran citra yang akan diinput, disini menggunakan ukuran 150x150 piksel dan selanjutnya menggunakan model *deep learning* VGG-16 sebagai proses ekstraksi fitur pada citra dapat dilihat pada Gambar 3 dan Gambar 4.



Gambar 3. Arsitektur VGG-16 [12].



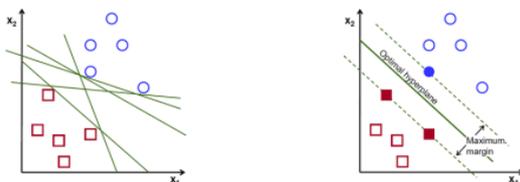
Gambar 4. Pengaplikasian model *deep learning* VGG-16.

2.3 Pengklasifikasian

Pada Tahap selanjutnya adalah melakukan klasifikasi citra penyakit daun pada tanaman jagung dengan menggunakan algoritma SVM, KNN dan MLP menggunakan model *deep learning* VGG-16 yang digunakan sebagai ekstraksi fitur citra.

2.3.1 Support Vector Machine

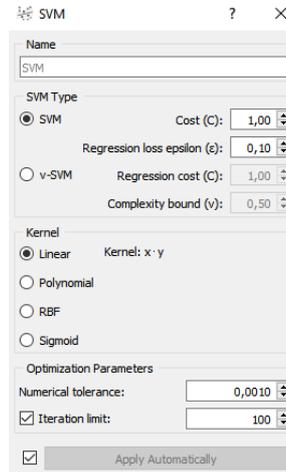
SVM adalah pengklasifikasi diskriminatif dengan *hyperplane* yang memisahkan. Algoritma ini akan menghasilkan *hyperplane* optimal yang mengkategorikan kasus baru berdasarkan data pelatihan berlabel. Dalam masalah ruang dua dimensi, *hyperplane* ini adalah garis yang membagi bidang menjadi dua bagian, dengan setiap kelas di kedua sisi [13].



Gambar 5. *Hyperplane* optimal memiliki jarak maksimum antara titik data (kanan) [13].

Dari Gambar 5, untuk memisahkan dua kelas titik data, ada banyak kemungkinan *hyperplane* yang bisa dipilih. Tujuannya adalah untuk menemukan pesawat yang memiliki margin maksimum antara titik data dari kedua

kelas. Memaksimalkan jarak margin memberikan beberapa penguatan sehingga poin data masa depan dapat diklasifikasikan dengan lebih percaya diri. *Hyperplane* adalah batas-batas keputusan yang membantu mengklasifikasikan titik data. Titik data jatuh di kedua sisi *hyperplane* dapat dikaitkan dengan kelas yang berbeda serta dimensi *hyperplane* tergantung pada jumlah fitur [13]. Adapun model SVM yang digunakan dapat dilihat pada Gambar 6.



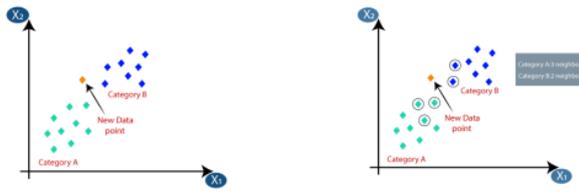
Gambar 6. Pengaplikasian model SVM pada klasifikasi citra penyakit daun pada tanaman jagung.

2.3.2 K-Nearest Neighbours

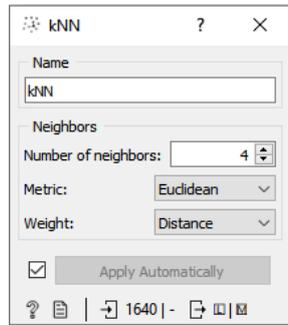
KNN bersifat *non-parametrik* dan sederhana. Struktur model KNN didasarkan pada himpunan data dan tidak adanya asumsi tentang distribusi data yang mendasarinya. Ini akan sangat berguna dalam praktiknya, karena sebagian besar kumpulan data dunia nyata tidak mematuhi matematika asumsi teoretis. Model ini tidak memerlukan poin data pelatihan apa pun. Pada tahap pengujian, semua data pelatihan digunakan. Pendekatan ini mempercepat latihan sambil memperlambat dan meningkatkan biaya pengujian. Dalam skenario terburuk, KNN akan membutuhkan lebih banyak waktu untuk memindai semua titik data, serta lebih banyak memori untuk menyimpan data pelatihan. Jarak dihitung menggunakan metode *Euclidean Distance* (ED), seperti yang ditunjukkan pada Persamaan 1 [13]:

$$D(x_1, x_2) = \sqrt{\sum(x_{1i} - x_{2i})^2} \quad (1)$$

Dimana $D(x_1, x_2)$ adalah jarak ED antara data x_1 dan x_2 , x_{1i} adalah nilai i dari data x_1 atribut, dan x_{2i} nilai atribut i dari data x_2 . Nilai k dalam KNN adalah angka tetangga terdekat yang digunakan untuk menyimpulkan label data pengujian. Pertimbangkan titik data baru, sebagai ditunjukkan pada Gambar 7, dengan menghitung ED antara titik data baru dan *neighbours*-nya, tiga tetangga terdekat berasal dari kategori A dibandingkan dengan hanya dua dari kategori B. Oleh karena itu, titik data baru dapat ditetapkan ke kategori A [13]. Adapun model KNN yang digunakan dapat dilihat pada Gambar 8.



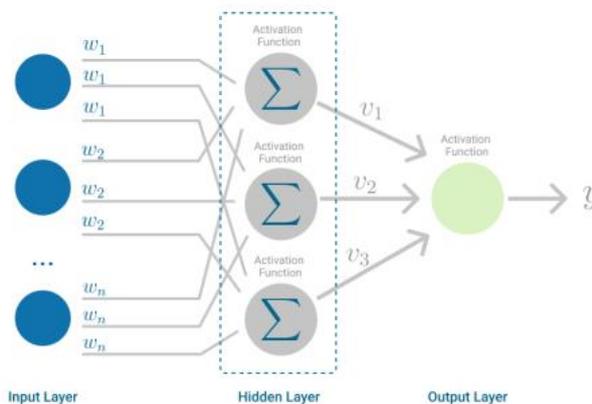
Gambar 7. Ilustrasi menghitung ED antara titik data baru dan *neighbours*-nya [13].



Gambar 8. Pengaplikasian model KNN pada klasifikasi citra penyakit daun pada tanaman jagung.

2.3.3 Multilayer Perceptron

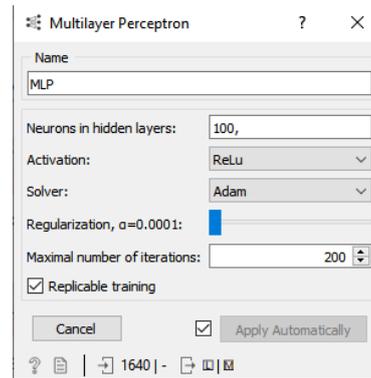
Jaringan saraf tiruan yang disebut MLP adalah jenis *feedforward* jaringan saraf tiruan. Lapisan input, lapisan tersembunyi, dan lapisan keluaran adalah tiga lapisan node yang membentuk MLP, seperti yang digambarkan pada Gambar 8. Setiap node, dengan pengecualian node input, adalah *neuron* dengan fungsi aktivasi *non-linier*. Backpropagation adalah teknik pembelajaran diawasi yang digunakan oleh MLP selama pelatihan. MLP dibedakan dari *perceptron linier* dengan banyak lapisan dan aktivasi *non-linier*. Ini dapat digunakan untuk membedakan data yang tidak dapat dipisahkan secara *linier*. Karena input digabungkan dengan bobot awal dalam jumlah tertimbang dan diterapkan pada fungsi aktivasi, MLP termasuk dalam kategori algoritma *feedforward*. Dalam MLP, setiap kombinasi *linier* diperbanyak ke lapisan berikutnya [13].



Gambar 9. MLP terdiri dari tiga layer: *input layer*, *hidden layer*, dan *output layer* [13].

Arsitektur MLP yang digunakan dalam penelitian ini yaitu menggunakan fungsi aktivasi ReLU dan optimisasi

Adam dengan *hidden layer* 100 adapun model terlampir pada Gambar 10.



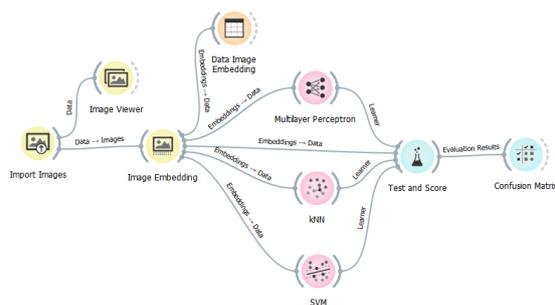
Gambar 10. Pengaplikasian model MLP pada klasifikasi citra penyakit daun pada tanaman jagung.

2.3.4 Pengujian dan Evaluasi Hasil

Selanjutnya akan dilakukan evaluasi untuk mengetahui hasil akurasi terbaik dari klasifikasi citra penyakit daun pada tanaman jagung. Dimana akan disajikan menggunakan *Confusion Matrix* dan akan menampilkan hasil prediksi dan nilai aktual untuk menentukan keakuratan dari setiap metode [14].

3. Hasil dan Pembahasan

Proses klasifikasi dilakukan menggunakan aplikasi Orange Data Mining dengan pembagian data *training* 80% dan data *testing* 20% yang mana jumlahnya disesuaikan dengan setiap kategori. Dalam penelitian ini menggunakan algoritma SVM, KNN dan MLP dimana sebelumnya data yang digunakan sudah dilakukan proses *preprocessing*. Adapun bentuk desain terlihat pada Gambar 11.



Gambar 11. Desain klasifikasi penyakit daun pada tanaman jagung.

Klasifikasi dengan algoritma SVM menggunakan data *training*, pada Gambar 12 terdapat total 6033 prediksi dengan nilai benar (1375 *cercospora leaf spot gray*, 1639 *common rust*, 1637 *healthy*, 1382 *northern leaf blight*) dan total 527 prediksi dengan nilai salah (253 *cercospora leaf spot gray*, 3 *common rust*, 10 *healthy*, 261 *northern leaf blight*) dari total 6560 data *training*.

		Predicted				
		Cercospora Leaf Spot Gray	Common Rust	Healthy	Northern Leaf Blight	Σ
Actual	Cercospora Leaf Spot Gray	1375	1	4	260	1640
	Common Rust	0	1639	0	1	1640
	Healthy	3	0	1637	0	1640
	Northern Leaf Blight	250	2	6	1382	1640
Σ		1628	1642	1647	1643	6560

Gambar 12. *Confusion Matrix* algoritma SVM menggunakan data *training*.

Klasifikasi dengan algoritma KNN menggunakan data *training*, pada Gambar 13 terdapat total 6273 prediksi dengan nilai benar (1430 *cercospora leaf spot gray*, 1621 *common rust*, 1637 *healthy*, 1585 *northern leaf blight*) dan total 287 prediksi dengan nilai salah (37 *cercospora leaf spot gray*, 11 *common rust*, 35 *healthy*, 204 *northern leaf blight*) dari total 6560 data *training*.

		Predicted				
		Cercospora Leaf Spot Gray	Common Rust	Healthy	Northern Leaf Blight	Σ
Actual	Cercospora Leaf Spot Gray	1430	3	16	191	1640
	Common Rust	5	1621	2	12	1640
	Healthy	2	0	1637	1	1640
	Northern Leaf Blight	30	8	17	1585	1640
Σ		1467	1632	1672	1789	6560

Gambar 13. *Confusion Matrix* algoritma KNN menggunakan data *training*.

Klasifikasi dengan algoritma MLP menggunakan data *training*, pada Gambar 14 terdapat total 6391 prediksi dengan nilai benar (1544 *cercospora leaf spot gray*, 1633 *common rust*, 1635 *healthy*, 1579 *northern leaf blight*) dan total 169 prediksi dengan nilai salah (60 *cercospora leaf spot gray*, 4 *common rust*, 11 *healthy*, 94 *northern leaf blight*) dari total 6560 data *training*.

		Predicted				
		Cercospora Leaf Spot Gray	Common Rust	Healthy	Northern Leaf Blight	Σ
Actual	Cercospora Leaf Spot Gray	1544	2	4	90	1640
	Common Rust	4	1633	0	3	1640
	Healthy	4	0	1635	1	1640
	Northern Leaf Blight	52	2	7	1579	1640
Σ		1604	1637	1646	1673	6560

Gambar 14. *Confusion Matrix* algoritma MLP menggunakan data *training*.

Berdasarkan pengujian yang dilakukan menggunakan data *training* maka didapatkan hasil seperti terlihat pada Tabel 1. Dapat disimpulkan bahwa algoritma MLP menghasilkan nilai terbaik dengan *accuracy*, *precision* dan *recall* masing-masing sebesar 97.4%.

Tabel 1. Hasil pengujian klasifikasi menggunakan data *training*.

Algoritma	Accuracy	Precision	Recall
SVM	92.0%	91.9%	92.0%
KKN	95.6%	95.8%	95.6%
MLP	97.4%	97.4%	97.4%

Klasifikasi dengan algoritma SVM menggunakan data *testing*, pada Gambar 15 terdapat total 1539 prediksi dengan nilai benar (363 *cercospora leaf spot gray*, 407 *common rust*, 406 *healthy*, 363 *northern leaf blight*) dan total 101 prediksi dengan nilai salah (45 *cercospora leaf spot gray*, 3 *common rust*, 2 *healthy*, 51 *northern leaf blight*) dari total 1640 data *testing*.

		Predicted				
		Cercospora Leaf Spot Gray	Common Rust	Healthy	Northern Leaf Blight	Σ
Actual	Cercospora Leaf Spot Gray	363	1	0	46	410
	Common Rust	1	407	0	2	410
	Healthy	1	0	406	3	410
	Northern Leaf Blight	43	2	2	363	410
Σ		408	410	408	414	1640

Gambar 15. *Confusion Matrix* algoritma SVM menggunakan data *testing*.

Klasifikasi dengan algoritma KNN menggunakan data *testing*, pada Gambar 16 terdapat total 1511 prediksi dengan nilai benar (328 *cercospora leaf spot gray*, 396 *common rust*, 408 *healthy*, 379 *northern leaf blight*) dan total 129 prediksi dengan nilai salah (17 *cercospora leaf spot gray*, 8 *common rust*, 14 *healthy*, 90 *northern leaf blight*) dari total 1640 data *testing*.

		Predicted				
		Cercospora Leaf Spot Gray	Common Rust	Healthy	Northern Leaf Blight	Σ
Actual	Cercospora Leaf Spot Gray	328	1	5	76	410
	Common Rust	1	396	0	13	410
	Healthy	1	0	408	1	410
	Northern Leaf Blight	15	7	9	379	410
Σ		345	404	422	469	1640

Gambar 16. *Confusion Matrix* algoritma KNN menggunakan data *testing*.

Klasifikasi dengan algoritma MLP menggunakan data *testing*, pada Gambar 17 terdapat total 1549 prediksi dengan nilai benar (365 *cercospora leaf spot gray*, 405 *common rust*, 408 *healthy*, 371 *northern leaf blight*) dan total 91 prediksi dengan nilai salah (31 *cercospora leaf spot gray*, 9 *common rust*, 11 *healthy*, 40 *northern leaf blight*) dari total 1640 data *testing*.

		Predicted				
		Cercospora Leaf Spot Gray	Common Rust	Healthy	Northern Leaf Blight	Σ
Actual	Cercospora Leaf Spot Gray	365	3	3	39	410
	Common Rust	4	405	0	1	410
	Healthy	2	0	408	0	410
	Northern Leaf Blight	25	6	8	371	410
Σ		396	414	419	411	1640

Gambar 17. *Confusion Matrix* algoritma MLP menggunakan data *testing*.

Berdasarkan pengujian yang dilakukan menggunakan data *testing* maka didapatkan hasil seperti terlihat pada Tabel 2. Dapat disimpulkan bahwa algoritma MLP menghasilkan nilai terbaik dengan *accuracy* 94.5%, *precision* 94.4%, dan *recall* 94.5%.

Tabel 2. Hasil pengujian klasifikasi menggunakan data *testing*.

Algoritma	Accuracy	Precision	Recall
SVM	93.8%	93.9%	93.8%
KKN	92.1%	92.6%	92.1%
MLP	94.5%	94.4%	94.5%

4. Kesimpulan

Dalam melakukan pengujian algoritma Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron menggunakan aplikasi Orange Data Mining. Adapun *dataset* yang digunakan yaitu citra penyakit daun pada tanaman jagung dimana dalam pengumpulan citra tersebut didapatkan melalui data sekunder yang

bersumber dari website kaggle. *Dataset* citra tersebut berisi 8200 data dengan 4 katagori yang mana terdiri dari 2050 *cercospora leaf spot gray*, 2050 *common rust*, 2050 *northern leaf blight* dan 2050 *healthy* yang mana sebelum dilakukan proses klasifikasi dilakukan tahapan *preprocessing* meliputi penyeragaman ukuran citra yang akan diinput dengan ukuran 150x150 pixel dan selanjutnya menggunakan model *deep learning* VGG-16 sebagai proses ekstraksi fitur pada citra. Hasil yang didapatkan menunjukkan bahwa algoritma Multilayer Perceptron menghasilkan nilai terbaik dengan *accuracy*, *precision* dan *recall* masing-masing sebesar 97.4%.

Daftar Rujukan

- [1] U. Mawaddah, A. L. Virganta, N. Adinda, D. Z. Br Ginting, C. F. Aulia, and I. Hasugian, "Eskalasi Nilai Ekonomi Jagung Melalui Kreasi Olahan Makanan di Desa Kolam Kecamatan Percut Sei Tuan Kabupaten Deli Serdang," *Bunga Rampai Usia Emas*, vol. 7, no. 2, pp. 56–62, Dec. 2021.
- [2] S. Rahmawati and Y. Widayanti, "Pengembangan Formulasi Biomassa Limbah Pohon Sengon Dan Bonggol Jagung Dalam Inovasi Senggol- Char (Biochar Limbah Pohon Sengon Dan Bonggol Jagung) Melalui Proses Pirolisis," p. 7, 2022.
- [3] E. H. Rachmawanto and H. P. Hadi, "Optimasi Ekstraksi Fitur Pada Knn Dalam Klasifikasi Penyakit Daun Jagung," vol. 22, no. 2, p. 10, 2021.
- [4] T. F. Kusumaningrum, "Implementasi convolution neural network (CNN) untuk klasifikasi jamur konsumsi di Indonesia menggunakan Keras," Universitas Islam Indonesia, Yogyakarta, 2018.
- [5] I. P. Putra, R. Rusbandi, and D. Alamsyah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network," *J. Algoritme*, vol. 2, no. 2, pp. 102–112, Apr. 2022, doi: 10.35957/algoritme.v2i2.2360.
- [6] Moh. A. Hasan, Y. Riyanto, and D. Riana, "Grape leaf image disease classification using CNN-VGG16 model," *J. Teknol. Dan Sist. Komput.*, vol. 9, no. 4, pp. 218–223, Oct. 2021, doi: 10.14710/jtsiskom.2021.14013.
- [7] J. Kusuma, J. Abwabul, M. Zulkarnain Lubis, Rubianto, and R. Rosnelly, "Komparasi Algoritma Support Vector Machine Dan Naive Bayes Pada Klasifikasi Ras Kucing," *J. Generic*, vol. 14, no. 2, pp. 8–12, Jan. 2022.
- [8] V. A. Gunawan and L. S. A. Putra, "Comparison of American Sign Language Use Identification using Multi-Class SVM Classification, Backpropagation Neural Network, K - Nearest Neighbor and Naive Bayes," *Teknik*, vol. 42, no. 2, pp. 137–148, Aug. 2021, doi: 10.14710/teknik.v42i2.36929.
- [9] N. Veni and J. Manjula, "High-performance visual geometric group deep learning architectures for MRI brain tumor classification," *J. Supercomput.*, Mar. 2022, doi: 10.1007/S11227-022-04384-9.
- [10] E. Prasetyo, R. Purbaningtyas, R. D. Adityo, E. T. Prabowo, and A. I. Ferdiansyah, "Perbandingan Convolution Neural Network Untuk Klasifikasi Kesegaran Ikan Bandeng Pada Citra Mata," *J. Teknol. Inf. Dan Ilmu Komput.*, vol. 8, no. 3, p. 601, Jun. 2021, doi: 10.25126/jtiik.2021834369.
- [11] S. BHATTARAI, "New Plant Diseases Dataset," Nov. 18, 2018. <https://www.kaggle.com/datasets/vipooool/new-plant-diseases-dataset>
- [12] R. Rismiyati and A. Luthfiarta, "VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification," *Telematika*, vol. 18, no. 1, p. 37, Mar. 2021, doi: 10.31315/telematika.v18i1.4025.
- [13] A. Saudi, S. H. Tanalol, and M. Musa, "Comparative Study of Ensemble Method vs Deep Learning on Human Activity Recognition for Elderly Care," vol. 10, no. 1, p. 12, 2022, doi: <https://doi.org/10.37134/jsml.vol10.1.4.202>.
- [14] J. Kusuma, A. Jinan, and Z. Situmorang, "Penerapan Decision Tree Algoritma C4.5 Dalam Penentuan Izin Pembongkaran Muatan Kapal," vol. 7, no. 1, p. 5, 2022.