
Klasifikasi Penyakit Bawang Merah Menggunakan Naïve Bayes dan Convolutional Neural Network

Dian Azurah¹, Purnawansyah², Herdianti Darwis³, Lilis Nur Hayati⁴

Dian.azurah.saharuddin@gmail.com, purnawansyah@umi.ac.id, herdianti.darwis@umi.ac.id,

lilis.nurhayati@umi.ac.id

Universitas Muslim Indonesia

Informasi Artikel

Diterima : 7 Jul 2023
Direview : 28 Jul 2023
Disetujui : 17 Ags 2023

Kata Kunci

Convolutional Neural Network (CNN), Fourier Descriptor, Naive Bayes, Penyakit Bawang Merah

Abstrak

Bawang merah rentan terhadap serangan penyakit yang dapat mengganggu pertumbuhan dan mengakibatkan hasil panen yang tidak maksimal bahkan gagal panen, seperti bercak ungu dan moler. Penelitian ini bertujuan untuk mengklasifikasikan penyakit bawang merah dengan mengimplementasikan metode *Naïve Bayes* (*gaussian*, *bernoulli*, dan *multinomial*) dan CNN pada citra bawang merah yang diekstraksi menggunakan *Fourier descriptor*. Metode FD – CNN memperoleh tingkat *accuracy* 98% dalam mengklasifikasikan penyakit bawang merah, moler dan bercak ungu, sedangkan metode CNN tanpa menggunakan ekstraksi menghasilkan nilai *accuracy* sebesar 97%. Adapun pada metode *Naïve Bayes*, pengklasifikasian yang memiliki *accuracy* paling tinggi adalah metode *gaussian Naïve Bayes* sebesar 95% sedangkan yang paling rendah yaitu metode *bernoulli Naïve Bayes* dengan tingkat *accuracy* sebesar 42%. Dengan demikian, dapat disimpulkan bahwa CNN, FD-CNN, dan FD-GNB efektif untuk meningkatkan performa klasifikasi pada citra daun bawang merah.

Keywords

Convolutional Neural Network (CNN), Fourier descriptor, Naive Bayes, onion diseases

Abstrak

Shallots are susceptible to disease attacks that can interfere with growth and result in sub-optimal yields and even crop failure, such as molaris and priole blotch. This study aims to classify shallot diseases by implementing the Naïve Bayes method (gaussian, bernoulli, and multinomial) and CNN on shallot images extracted using a Fourier descriptor. The FD – CNN method obtains an accuracy rate of 98% in classifying shallot, molaris and priole blotch diseases. The CNN method without using extraction produces an accuracy value of 97%. As for the Naïve Bayes method, the classification that has the highest accuracy is the Gaussian Naïve Bayes method of 95% while the lowest is the Bernoulli Naïve Bayes method with an accuracy rate of 42%. Thus, it can be concluded that CNN, FD-CNN, and FD-GNB are effective for improving classification performance on shallot image

A. Pendahuluan

Bawang merah adalah komoditas rempah-rempah yang memiliki peran penting dalam kehidupan manusia. Selain digunakan sebagai bahan masakan untuk memberikan rasa dan aroma pada makanan, bawang merah juga memiliki sejumlah manfaat kesehatan dan digunakan dalam pengobatan tradisional [1]. Nama latin dari bawang merah adalah *Allium Ascalonicum L*, memiliki umbi yang terdiri dari lapisan-lapisan yang melindungi dan menutupinya. Akar tanaman bawang merah berbentuk serabut dan daunnya memiliki bentuk silindris yang khas, dengan pangkal daun yang dapat berubah sesuai dengan pertumbuhan tanaman. Indonesia menanam berbagai macam varietas bawang merah seperti super *Philip*, lembah palu, bawang bauji, bima brebes, tuk-tuk dan masih banyak lagi [2]. Lahan pertanian yang ada di Indonesia sangat luas sehingga akan mempengaruhi tingkat produksi bawang merah, tetapi resiko terserang hama dan penyakit akan semakin tinggi juga yang dapat mempengaruhi kualitas tanaman tersebut [3].

Bawang merah juga rentan terhadap serangan penyakit yang dapat mengganggu pertumbuhan dan mengakibatkan hasil panen yang tidak maksimal atau gagal panen. Serangan penyakit pada tanaman ini umumnya disebabkan oleh bakteri, cendawan dan virus yang mengakibatkan infeksi pada daun. Contoh penyakit yang seringkali menyerang tanaman ini adalah bercak ungu dan moler [4]. Layu *fusarium* atau biasa disebut dengan moler dikarenakan jamur *Fusarium Oxysporum f.sp.cepae* menyerang tanaman bawang merah dan dapat menyebabkan tanaman menjadi layu secara patologis yang pada akhirnya berujung pada kematian tanaman [5]. Sementara itu penyakit bercak ungu atau dikenal juga dengan penyakit troto, disebabkan oleh jamur *Alternaria Porri* yang menyerang daun bawang merah dan menyebabkan munculnya bercak-bercak berwarna ungu atau cokelat pada daun yang tidak berurutan [6].


Pada penelitian sebelumnya melakukan klasifikasi pada penyakit bawang merah diklasifikasikan dengan metode *Naïve Bayes* dengan dua kelas yaitu ringan dan berat. Akurasi yang dihasilkan pada penelitian ini adalah 84% dan menggunakan pendekatan *Gray Level Co-Occurrence Matrix* (GLCM) dan disimpulkan bahwa metode *Naïve Bayes* dan ekstraksi ciri GLCM menghasilkan performa yang baik dalam mengklasifikasikan penyakit daun bawang merah [7]. Pada penelitian lainnya, yang menggunakan metode CNN untuk klasifikasi penyakit *Tuberculosis* melalui foto *rontgen* dan mendapatkan hasil akurasi sebesar 98%. Dari hasil akurasi tersebut dapat menjadi pertimbangan dalam mengklasifikasikan penyakit *Tuberculosis* [8]. Penelitian lain melakukan identifikasi daun menggunakan *Fourier descriptor* mendapatkan hasil akurasi sebesar 88% [9]. Penelitian lain yang melakukan klasifikasi penyakit bawang merah menggunakan metode *Naïve Bayes* dan GLCM menghasilkan *accuracy* 100% pada dua kernel yaitu *Gaussian Naïve Bayes* dan *Multinomial Naïve Bayes*, dan 100% untuk metode GLCM-CNN dan CNN [10]. Penelitian tersebut menggunakan ekstraksi fitur GLCM, maka penelitian ini mengusulkan penggunaan ekstraksi fitur yang lain yaitu ekstraksi *Fourier descriptor*.

Berdasarkan penelitian terdahulu yang hanya menggunakan salah satu dari metode, maka pada penelitian ini dilakukan dengan tujuan mengimplementasikan *Fourier descriptor* dengan metode *Naïve Bayes* dan CNN serta untuk mengetahui perbandingan kinerja kedua metode tersebut dalam mengklasifikasikan penyakit

bawang merah. Evaluasi pengujian dilakukan dengan menggunakan *confusion matrix* yang merupakan metode untuk mengukur seberapa sukses sistem dalam mendiagnosis penyakit bawang merah. Penelitian ini bertujuan untuk mengukur hasil akurasi pada klasifikasi citra daun bawang merah.

B. Metode Penelitian

Pada tahap ini dilakukan pendekatan sistematis dan terstruktur yang diilustrasikan pada Gambar 1.



Gambar 1. Metode penelitian

Langkah-langkah pengembangan sistem dilakukan secara berurutan mulai dari proses penginputan data dengan kamera *smartphone*, dan kemudian dilanjutkan dengan tahap *preprocessing* [11] kemudian tahap ekstraksi fitur menggunakan *Fourier descriptor*. Selanjutnya tahap klasifikasi dengan *Naïve Bayes* dan *CNN*. Setelah itu dilakukan evaluasi hasil klasifikasi dan performa klasifikasi. Setiap proses akan dijelaskan secara detail pada sub bab masing masing.

1. Input Dataset

Data citra daun pada penelitian ini adalah sebanyak 320 data dari dua kelas yaitu moler dan bercak ungu yang setiap kelas terdiri dari 160 citra dengan format JPG. Ukuran yang digunakan adalah 1:1 dengan *background* putih.

2. Preprocessing

Sebelum masuk ke tahap ekstraksi data citra terlebih dahulu akan melalui proses *preprocessing* agar menghasilkan output yang baik dan sesuai yang diinginkan. Metode *preprocessing* pada penelitian ini ada 2 yaitu *cropping* dan *resizing* dimana pada tahap *cropping* dilakukan pemisahan objek citra dengan *background* sehingga akan mengurangi *noise* pada citra sedangkan pada tahap *resizing* adalah perubahan *pixel* citra menjadi ukuran yang sama untuk mengurangi beban pada saat proses komputasi

3. Fourier descriptor

Ekstraksi *Fourier descriptor* merupakan pengolahan data yang dilakukan setelah tahap *preprocessing* dengan tujuan untuk memperoleh karakteristik objek dan mengubah citra yang acak menjadi citra yang terstruktur [12]. *Fourier descriptor* telah terbukti berhasil menggambarkan bentuk citra dari *Fourier Transform* (FT) dan *shape signature*. Dalam perhitungan *pixel* tepi menggunakan algoritma *boundary tracing*, diperoleh data geometri yang menggambarkan kontur objek tersebut. Untuk menganalisis kontur, digunakan *Fourier descriptor* satu dimensi yang didapatkan melalui transformasi *Fourier* pada fungsi *shape signature*. Jarak *shape signature* terhadap *Fourier descriptor* dirumuskan pada persamaan (1). *Fourier descriptor* dinyatakan sebagai a_n dengan $n = 0, 1, 2, \dots, N - 1$ merupakan penormalisasian dari magnitude koefisien dan berfungsi sebagai *shape signature* yang dirumuskan pada persamaan (2) [12].

$$a_n = \frac{1}{N} \sum_{t=1}^{N-1} r(t) \exp\left(-\frac{j2\pi nt}{N}\right), n = 0, 1, \dots, N - 1 \quad (1)$$

$$S_n = \left| \frac{a_n}{a_0} \right|, n = 0, 1, \dots, N - 1 \quad (2)$$

4. Klasifikasi

a. Naïve Bayes

Selain disebut sebagai metode statistik berdasarkan nilai peluang, *Naïve Bayes* juga dikenal sebagai metode klasifikasi probabilistik. Pendekatan ini mempertimbangkan perhitungan probabilitas berdasarkan variabel-variabel yang terlibat dalam kelas yang diberikan [13]. *Naïve Bayes* adalah model klasifikasi yang melakukan perhitungan dari dataset dan bertujuan untuk memprediksi dalam suatu kelas dengan asumsi independen yang kuat [14], [10]. Persamaan umum algoritma *Naïve Bayes* dirumuskan pada persamaan (3).

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3)$$

Dimana $P(A|B)$ merupakan *posterior probability*, $P(B)$ adalah *evidence probability*, $P(A)$ adalah *prior probability* dan $P(B|A)$ adalah *likelihood probability* yaitu probabilitas peristiwa B terjadi jika peristiwa A terjadi

Probabilitas menggambarkan peluang tingkat pengaruh informasi yang terjadi pada peristiwa lain. *Posterior probability* menunjukkan nilai probabilitas berdasarkan peristiwa informasi peristiwa yang berdasar dari peristiwa lain. Peluang suatu peristiwa yang telah diyakini sebelumnya mengandung probabilitas kemungkinan dipengaruhi oleh peristiwa lain [15].

1) Gaussian Naïve Bayes

Pengklasifikasian *Gaussian Naïve Bayes* (GNB) menggunakan teorema *Naïve Bayes* untuk mengklasifikasikan pengamatan ke dalam kelas berdasarkan informasi yang diberikan oleh variabel *predictor* [12], [16]. Untuk menghitung probabilitas dirumuskan pada persamaan (4).

$$P(X = x|Y = y) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x - \mu)^2}{2\sigma^2}} \quad (4)$$

X dapat dianggap sebagai variabel fitur dalam konteks citra, sedangkan σ merupakan ukuran standar deviasi fitur tersebut.

2) Bernoulli Naïve Bayes

Pengklasifikasian *Bernoulli Naïve Bayes* (BNB) menghitung perhitungan biner yang akan mendapatkan nilai *Boolean* sebagai output [17]. *Bernoulli Naïve Bayes* akan dirumuskan pada persamaan (5).

$$P(X_i|y) = P(i|y)x_i + (P(i|y))(1 - x_i) \quad (5)$$

3) Multinomial Naïve Bayes

Pengklasifikasian *Multinomial Naïve Bayes* (MNB) melakukan klasifikasi untuk menghitung frekuensi kemunculan setiap kata atau *term* dalam dokumen yang digunakan sebagai fitur untuk klasifikasi [18]. *Multinomial Naïve Bayes* dirumuskan pada persamaan (6).

$$P(x|y) = P(x)P(y_1|x)P(y_2|x)... P(y_n|x) \quad (6)$$

b. Convolutional Neural Network

Convolutional neural network (CNN) adalah algoritma yang sering digunakan dalam pemrosesan dan analisis citra visual. Algoritma ini memiliki kemampuan untuk menemukan fitur penting pada gambar dan mengumpulkan informasi dari *pixel* yang lebih kecil, sederhana, dan kompleks. Sehingga CNN memiliki performa yang sangat baik dalam menentukan *pixel* pada gambar [19].

1) Convolutional Layer

Layer ini adalah komponen inti dari algoritma CNN. Sebagian besar komputasi dijalankan pada lapisan ini. Pada tahap ini dilakukan proses konvolusi dalam pemrosesan citra yang memakai matriks kernel atau filter dalam pemrosesan citra. Kernel tersebut berfungsi sebagai bobot atau faktor yang didasarkan pada nilai-nilai *pixel* untuk

menghasilkan nilai *pixel* yang baru [20]. Konvolusi akan dilakukan secara berulang, setelah itu akan dilakukan ekstraksi set fitur map dari citra gambar inputan [21].

2) Pooling Layer

Pooling layer berfungsi untuk mereduksi dimensi *special*, mengontrol secara efektif risiko *overfitting* dan mengurangi kompleksitas komputasi [21]. *Pooling layer* digunakan untuk mengurangi ukuran setiap tumpukan *feature map* yang dihasilkan oleh *convolutional layer*. *max pooling* dengan ukuran 2×2 adalah salah satu bentuk *pooling layer* yang paling sering digunakan dalam CNN. Dengan menerapkan *max pooling* dua kali pada setiap lapisan, ukuran *feature map* dapat dikurangi sebanyak 75% dari ukuran aslinya [20]. *Pooling layer* dirumuskan pada persamaan (7).

$$FM_{i,j}^{m1} = ReLU(b^{(m1)} + \sum_{j=3j}^{3nj+2} \sum_{j=3j}^{3nj+2} p^{(m1)} FM_{i,j}^{m1}) \quad (7)$$

3) Activation Function

Activation function disebut juga *transfer function* menentukan output dari algoritma *neural network*. *Activation function* akan ditambahkan pada akhir output pada setiap jaringan [22]. *Activation function* dirumuskan pada persamaan (8).

$$f(x)_{ReLU} = \max(0, x) \quad (8)$$

4) Fully Connected Layer

Di lapisan ini, setiap neuron di lapisan berikutnya dihubungkan dengan setiap neuron aktivasi dari lapisan sebelumnya. Sebelum dihubungkan dengan *fully connected layer*, nilai aktivasi ada lapisan sebelumnya harus dikonversi menjadi satu dimensi [20].

5. Evaluasi

Evaluasi bertujuan mengukur dan mengevaluasi kinerja dari algoritma yang digunakan. Pendekatan evaluasi yang diterapkan pada penelitian ini adalah *confusion matrix* yang memiliki empat entri, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

Table 1. *Confusion Matrix*

	Predicted Negative	Predicted Positive
Actual Negative	TN	FP
Actual Positif	FN	TP

TP adalah akumulasi data yang benar teridentifikasi positif oleh model. TN adalah banyaknya data benar diprediksi negatif oleh model. FP adalah akumulasi data yang salah teridentifikasi positif oleh model. FN adalah akumulasi data yang teridentifikasi negatif oleh model. Dalam Proses klasifikasi,

ada beberapa matriks uji coba untuk mengukur kinerja model diantaranya *accuracy*, *precision*, *recall*, dan *f1-score*.

a. *Accuracy*

Accuracy merupakan nilai proporsi yang mendefinisikan tingkat ketepatan proses klasifikasi data [23]. *Accuracy* dirumuskan pada persamaan (9).

$$Accuracy = \frac{TP + TN}{Total} \quad (9)$$

b. *Precision*

Precision adalah perkiraan yang menggambarkan prediksi nilai benar positif dengan yang positif [23]. *Precision* dirumuskan pada persamaan (10)

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

c. *Recall*

Recall adalah prediksi data kelas positif dengan nilai *actual positive* [17]. Formula *recall* dirumuskan pada persamaan (11).

$$Recall = \frac{TP}{FN + TP} \quad (11)$$

d. *F1-score*

F1-score dihitung menggunakan *harmonic mean* dari *precision* dan *recall* dan dirumuskan pada persamaan (12).


$$F1 - Score = 2 \times \frac{precision \times recall}{precision + recall} \quad (12)$$

6. Performa klasifikasi

Performa klasifikasi daun bawang merah ditentukan setelah proses input data, *preprocessing*, ekstraksi, klasifikasi dan evaluasi dan akan dijelaskan secara rinci pada bab selanjutnya


C. Hasil dan Pembahasan

Keakuratan metode yang digunakan akan diketahui setelah dilakukan proses klasifikasi pada citra daun bawang merah dan telah melalui proses *preprocessing* disajikan pada Gambar 2.



Gambar 2. Bercak ungu dan moler

Perbandingan antara algoritma *Naïve Bayes* dan CNN menggunakan 2 kelas, yaitu bercak ungu dan moler, dengan masing-masing kelas memiliki 160 citra sehingga total dataset mencakup 320 citra. Struktur CNN diilustrasikan pada Gambar 3.



Gambar 3. Arsitektur CNN


Hasil pengujian pada citra daun bawang merah ditunjukkan pada Tabel 2. Performa metode tersebut dievaluasi berdasarkan *accuracy*, *precision*, *recall*, dan *f1-Score*. Jenis citra dan metode yang digunakan pada penelitian ini akan berpengaruh pada keakuratan hasil klasifikasi. Hal ini membuktikan bahwa nilai hasil klasifikasi akan berbeda atau tidak konsisten pada setiap kasus yang menerapkan metode berbeda. Untuk metode *Naïve Bayes*, hasil perbandingan CNN dan GNB dengan menggunakan ekstraksi *Fourier descriptor* pada klasifikasi citra daun bawang merah ini mendapatkan nilai akurasi yang paling tinggi untuk pengujian citra daun bawang merah dibandingkan dengan metode BNB dan MNB. Metode yang memiliki nilai paling rendah yaitu metode klasifikasi BNB, hal ini dikarenakan metode BNB umumnya memiliki kinerja yang lebih baik pada data berbentuk dokumen atau data dengan representasi biner, daripada pada data berupa citra dengan jumlah data yang sedikit. Oleh karena itu, metode BNB tidak dapat diajukan sebagai metode yang optimal untuk citra daun bawang merah. Untuk metode CNN yang menggunakan ekstraksi *Fourier descriptor* maupun tidak, sama-sama mendapatkan nilai yang tinggi. Nilai performa akan ditunjukkan pada Tabel 2.

Table 2. Performa FD – *Naïve Bayes* (GNB, MBN, BNB), FD - CNN, DAN CNN

Algoritma	Kelas	Precision	Recall	F1-Score	Accuracy
FD – GNB	0	1.00	0.92	0.96	0.95
	1	0.90	1.00	0.95	
FD – MNB	0	0.97	0.84	0.90	0.89
	1	0.81	0.96	0.88	
FD – BNB	0	0.00	0.00	0.00	0.42
	1	0.42	1.00	0.59	
FD – CNN	0	0.97	1.00	0.99	0.98
	1	1.00	0.96	0.98	
CNN	0	0.94	1.00	0.97	0.97
	1	1.00	0.94	0.97	


Tingkat akurasi dalam metode klasifikasi dipengaruhi oleh *background* dari dataset. pada metode GNB mencapai *accuracy* sebesar 95% dengan, *precision*, *recall*, dan *f1-score* sebesar 100%, 92%, dan 96% untuk kelas bercak ungu dan 90%, 100%,

dan 95% untuk kelas moler. *Accuracy* pada metode MNB adalah 89% dengan tingkat *precision* sebesar 97%, *recall* 84% , dan *f1-score* sebesar 90%, pada kelas bercak ungu dan 81%, 96%, dan 88% pada kelas moler. Pada metode BNB mendapatkan tingkat keakuratan sebesar 42% dengan *precision*, *recall*, dan *f1-score* 0% untuk kelas bercak ungu dan 42%, 100%, dan 59% untuk kelas moler ditunjukkan pada Gambar 4.



Gambar 4. Performa FD - Naïve Bayes


Metode FD – CNN mendapatkan nilai *accuracy* yang tinggi sebesar 98% dengan *precision*, *recall*, dan *f1-score* sebesar 97%, 100%, dan 99% untuk kelas bercak ungu dan 100%, 96%, dan 98% untuk kelas moler ditunjukkan pada Gambar 5.



Gambar 5. Pembelajaran algoritma FD-CNN

Metode CNN memiliki kemampuan untuk melakukan ekstraksi fitur secara mandiri dari data citra tanpa memerlukan metode ekstraksi tambahan. CNN dapat belajar dan mengekstraksi fitur-fitur penting secara otomatis melalui lapisan-

lapisan konvolusi dan *pooling*. Dengan demikian, CNN dapat mengenali pola dan objek dalam citra secara efektif tanpa memerlukan langkah ekstraksi fitur yang terpisah. Pada algoritma CNN tanpa menggunakan ekstraksi menghasilkan nilai *accuracy* sebesar 97% dengan *precision*, *recall*, dan *f1-score* sebesar 94%, 100%, dan 97% untuk kelas bercak ungu dan 100%, 94%, dan 97% untuk kelas moler seperti pada Gambar 6.



Gambar 6. Pembelajaran CNN

D. Simpulan

Dengan mengacu pada hasil yang diperoleh, disimpulkan bahwa CNN dan FD-CNN efektif dalam meningkatkan performa klasifikasi pada citra daun bawang merah karena memiliki nilai *accuracy*, *precision*, *recall*, dan *f1-score* mendapatkan nilai yang tinggi dari pendekatan lain yang telah diuji. Sedangkan untuk metode *Naïve Bayes*, pengklasifikasian yang memiliki nilai paling tinggi adalah metode GNB sedangkan yang paling rendah yaitu metode BNB. Akurasi yang dihasilkan tentunya belum sempurna, sehingga diperlukan usaha lain yang dapat digunakan untuk meningkatkan akurasi.

Untuk meningkatkan akurasi, dapat dilakukan dengan penggunaan dataset yang lebih besar, peningkatan kualitas *preprocessing* yang tepat seperti normalisasi, peningkatan kontras, atau penghapusan *noise* dapat membantu menghasilkan fitur-fitur yang lebih baik dan meningkatkan akurasi klasifikasi.

E. Referensi

- [1] A. D. T. Gau, E. Syam'Un, and F. Ulfa, "Application of *Bacillus subtilis* on red onion (*Allium ascalonicum*)," *GIESED*, vol. 921, no. 1, Dec. 2021, doi: 10.1088/1755-1315/921/1/012078.
- [2] M. V. Rosyidah, B. D. Setiawan, and M. T. Furqon, "Diagnosis Hama Penyakit Tanaman Bawang Merah Menggunakan Metode Neighbors Weighted K-Nearest Neighbors (NWKNN)," *J. PTIIK*, vol. 3, no. 3, pp. 3033–3038, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [3] R. Ristandi, N. Hidayat, and M. A. Fauzi, "Pemodelan Sistem Pakar Diagnosa Hama-Penyakit pada Tanaman Bawang Merah Menggunakan Metode *Naïve Bayes*," 2016. [Online]. Available: <https://www.researchgate.net/publication/324561891>
- [4] W. Sari and S. A. Inayah, "Inventarisasi Penyakit Pada Dua Varietas Lokal

- Bawang Merah (*Allium* Inventarisasi Penyakit Pada Dua Varietas Lokal Bawang Merah (*Allium Ascalonicum* L.) Bima Brebes Dan Trisula," *J. Pro-Stek*, vol. 2, no. 2, pp. 64–71, 2020, doi: 10.35194/prs.v2i2.1166.
- [5] Mariana, "Aplikasi Trichoderma sp. dalam Menekan Penyakit Moler (*Allium ascalonicum* L.)," *Agrosamud*, vol. 9, no. 1, pp. 10–18, 2022.
 - [6] T. Toni, P. Hadi, S. J. Rachmawatie, and S. M. P, "Uji Efikasi Biofungisida Bahan Aktif *Streptomyces* sp dan *Geobacillus* sp. Terhadap Intensitas Penyakit Bercak Ungu Pada Bawang Merah (*Allium ascalonicum* L.)," *J. Ilm. Ilmu-Ilmu Pertan.*, vol. 16, no. 2, 2022, doi: 10.35457/viabel.v16i2.2138.
 - [7] F. K. Fikriah, M. B. Sulthan, N. Mujahidah, and M. K. Roziqin, "Naïve Bayes untuk Klasifikasi Penyakit Daun Bawang Merah Berdasarkan Ekstraksi Fitur Gray Level Cooccurrence Matrix (GLCM)," *J. Komputasi dan Inform.*, vol. 6, no. 2, pp. 133–141, Nov. 2022, doi: 10.31603/komtika.v6i2.7925.
 - [8] M. Harahap, A. P. S. Pasaribu, D. R. Sinaga, R. Sipangkar, and S. Samuel, "Classification of Tuberculosis Based on Lung X-Ray Image With Data Science Approach Using Convolutional Neural Network," *Sinkron*, vol. 7, no. 4, pp. 2193–2197, Oct. 2022, doi: 10.33395/sinkron.v7i4.11711.
 - [9] A. Kadir, "Leaf Identification Using Fourier Descriptors and Other Shape Features," *Gate to Comput. Vis. Pattern Recognit.*, vol. 1, no. 1, pp. 3–7, Apr. 2015, doi: 10.15579/gtcvpr.0101.003007.
 - [10] J. Jumrayanti, P. Purnawansyah, H. Darwis, and R. Satra, "Klasifikasi Penyakit Bawang Merah Menggunakan Naive Bayes dan CNN dengan Fitur GLCM," *STMIK Indones. Padang*, vol. 12, no. 3, pp. 1231–1240, 2023.
 - [11] P. R. Prayoga, P. Purnawansyah, T. Hasanuddin, and H. Darwis, "Klasifikasi Daun Herbal Menggunakan K-Nearest Neighbor dan Support Vector Machine dengan Fitur Fourier Descriptor," *Edumatic J. Pendidik. Inform.*, vol. 7, no. 1, pp. 160–168, 2023, doi: 10.29408/edumatic.v7i1.17521.
 - [12] S. Passura Backar, P. Purnawansyah, H. Darwis, and W. Astuti, "Hybrid Fourier Descriptor Naïve Bayes dan CNN pada Klasifikasi Daun Herbal," *JPIT*, vol. 8, no. 2, pp. 126–133, 2023, doi: 10.30591/jpit.v8i2.5186.
 - [13] U. P. Sanjaya, T. Pribadi, and I. W. D. Prasatya, "Klasifikasi Dana Hibah Usaha Mikro Kecil Dan Menengah dengan Metode Naïve Bayes," *Indones. J. Comput. Sci.*, vol. 11, no. 3, pp. 975–984, 2022, doi: 10.33022/ijcs.v11i3.3099.
 - [14] A. Afdhaluzzikri, H. Mawengkang, and O. S. Sitompul, "Performance analysis of Naive Bayes method with data weighting," *Sinkron*, vol. 7, no. 3, pp. 817–821, Jul. 2022, doi: 10.33395/sinkron.v7i3.11516.
 - [15] I. Y. R. Pratiwi and A. F. Nugraha, "Hoax news identification using machine learning model from online media in Bahasa Indonesia," *MATRIX J. Manaj. Teknol. dan Inform.*, vol. 12, no. 2, pp. 58–67, Jul. 2022, doi: 10.31940/matrix.v12i2.58-67.
 - [16] J. V. Wie and M. Siddik, "Penerapan Metode Naïve Bayes dalam Mengklasifikasi Tingkat Obesitas Pada Pria," *J. JOISIE*, vol. 6, no. 2, pp. 69–77, 2022, doi: 10.35145/joisie.v6i2.2467.
 - [17] M. Raffi, A. Suharso, and I. Maulana, "Analisis Sentimen Ulasan Aplikasi Binar Pada Google Play Store Menggunakan Algoritma Naïve Bayes," *J. INTECOMS*, vol. 6, no. 1, pp. 238–462, 2023, doi: 10.31539/intecom.v6i1.6117.
 - [18] S. Fanissa, M. A. Fauzi, and S. Adinugroho, "Analisis Sentimen Pariwisata di

- Kota Malang Menggunakan Metode Naive Bayes dan Seleksi Fitur Query Expansion Ranking,” *J. JPTIHK*, vol. 2, no. 8, pp. 2766–2770, 2018, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [19] E. Rasywir, R. Sinaga, and Y. Pratama, “Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode Convolutional Neural Network (CNN),” *Paradig. – J. Inform. dan Komput.*, vol. 22, no. 2, pp. 117–123, 2020, doi: 10.31294/p.v21i2.
- [20] A. A. Santosa, R. Y. N. Fu’adah, and S. Rizal, “Deteksi Penyakit pada Tanaman Padi Menggunakan Pengolahan Citra Digital dengan Metode Convolutional Neural Network,” *J. Electr. Syst. Control Eng.*, vol. 6, no. 2, pp. 98–108, Feb. 2023, doi: 10.31289/jesce.v6i2.7930.
- [21] J. Chen, J. Chen, D. Zhang, Y. Sun, and Y. A. Nanekharan, “Using deep transfer learning for image-based plant disease identification,” *Comput. Electron. Agric.*, vol. 173, Jun. 2020, doi: 10.1016/j.compag.2020.105393.
- [22] M. R. Efrian and U. Latifa, “Image Recognition Berbasis Convolutional Neural Network (CNN) Untuk Mendeteksi Penyakit Kulit Pada Manusia,” *J. POLEKTRO*, vol. 11, no. 1, pp. 276–282, 2022, doi: 10.30591/polektro.v12i1.3874.
- [23] A. Prabhat and V. Khullar, “Sentiment classification on Big Data using Naïve Bayes and Logistic Regression,” in *International Conference on Computer Communication and Informatics*, 2017. doi: 10.1109/ICCCI.2017.8117734.