

Hybrid Fourier Descriptor Naïve Bayes dan CNN pada Klasifikasi Daun Herbal

Sunarti Passura Backar^{1*)}, Purnawansyah², Herdianti Darwis³, Wistiani Astuti⁴

^{1,2,3,4}Jurusan Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muslim Indonesia, Makassar

^{1,2,3,4}Jl. Urip Sumoharjo Km.5, Kota Makassar, 90231, Indonesia

email: ¹sunartisudirman.passurabackar@gmail.com, ²purnawansyah@umi.ac.id, ³herdianti.darwis@umi.ac.id, ⁴wistiani.astuti@umi.ac.id

Abstract – Plants are vital to human life on earth, and the leaves and their whole parts have many benefits. These parts of the plant can help distinguish between different species. The leaf identification can be performed at any time, while the other parts of the plants can only be identified at a certain time. The study aims to classify two types of herbs i.e. saur-opus androgynous and moringa oleifera, implementing the Fourier Descriptor method to extract the shape and texture features. In the process of classification using the Naïve Bayes method with three types of nuclei (Gaussian, Bernoulli, and Multinomial) and a Convolutional Neural Network. The testing process was carried out using two scenarios, dark and light, where each scenario consisted of 240 images for a total of 480 images divided into 20% of the data testing and 80% of the training data. The Fourier Descriptor-Bernoulli Naive Bayes method gives the lowest accuracy in both light and dark scenarios, at 46% and 52%, respectively. As for the classification of herbal leaves using a combination of the Fourier Descriptor-Convolutional Neural Network method, it is recommended to be used in light image scenarios and Fourier Descriptor-Gaussian Naive Bayes in the dark scenarios because it is able to detect herbal leaf types with 100% accuracy.

Abstrak – Tumbuhan sangat penting bagi kehidupan manusia di bumi dimana daun, kelopak, dan seluruh bagiannya mempunyai banyak manfaat. Bagian tumbuhan tersebut dapat membantu membedakan antara spesies-spesies yang berbeda. Identifikasi daun dapat dilakukan kapan saja sedangkan identifikasi bagian tumbuhan lainnya hanya dapat dilakukan di waktu tertentu. Penelitian ini bertujuan untuk melakukan klasifikasi terhadap dua jenis daun herbal yaitu daun katuk (*sauropus androgynus*) dan daun kelor (*moringa oleifera*) yang mengimplementasikan metode ekstraksi *Fourier Descriptor* untuk mengekstraksi fitur bentuk dan tekstur. Pada proses klasifikasi menggunakan metode *Naïve Bayes* dengan tiga jenis kernel (*Gaussian*, *Bernoulli*, *Multinomial*) dan *Convolutional Neural Network*. Proses pengujian dilakukan dengan menggunakan dua skenario yaitu gelap dan terang, dimana setiap skenario berjumlah 240 citra dengan total 480 citra yang dibagi menjadi 20% data *testing* dan 80% data *training*. Berdasarkan hasil penelitian diperoleh bahwa metode *Fourier Descriptor - Bernoulli Naïve Bayes* memberikan akurasi paling rendah baik pada skenario terang maupun gelap yaitu masing-masing sebesar 46% dan 52%. Adapun klasifikasi daun herbal dengan kombinasi metode *Fourier Descriptor - Convolutional Neural Network* direkomendasikan untuk digunakan pada skenario citra terang dan *Fourier Descriptor - Gaussian Naïve Bayes* pada skenario gelap karena mampu mendeteksi jenis daun herbal dengan akurasi sebesar 100%.

***) penulis korespondensi:** Sunarti Passura Backar
Email: sunartisudirman.passurabackar@gmail.com

Kata Kunci – Klasifikasi Daun Herbal, Fourier Descriptor, Naïve Bayes, Convolutional Neural Network.

I. PENDAHULUAN

Kemampuan untuk mengidentifikasi dan mengklasifikasikan daun sangat dibutuhkan oleh ahli taksonomi untuk memahami keanekaragaman tumbuhan [1]. Tumbuhan dimanfaatkan sebagai salah satu penghasil oksigen, sumber makanan, penyedia bahan bakar, obat-obatan herbal, kosmetik dan lainnya. Salah satu bagian tumbuhan yang sering dijadikan objek penelitian adalah daun karena mempunyai bentuk yang sederhana, tersedia kapan saja dan dapat diambil terus-menerus tanpa merusak tanaman. Hal tersebut menjadikan daun sangat bagus untuk dilakukan identifikasi otomatis karena mudah dalam pengambilan gambarnya dan mudah dianalisis [2]. Karakteristik yang dimiliki daun seperti bentuk dan tekstur merupakan bagian yang sering dimanfaatkan dalam proses klasifikasi, lain halnya dengan ciri warna digunakan dalam mengklasifikasi bunga [3]. Dengan demikian, dapat dilakukan identifikasi pola dengan ciri-ciri struktural yang dimiliki daun seperti bentuk dan tekstur [4]. Untuk mendapatkan bentuk dan karakteristik struktural dari setiap daun maka dapat dilakukan dengan metode ekstraksi fitur yaitu pengenalan fitur morfologi digital [5].

Saat ini teknologi untuk pengolahan citra mengalami perkembangan yang sangat pesat. Banyak metode yang dikembangkan untuk memberikan kemudahan bagi masyarakat untuk mengelolah citra maupun menganalisis citra. Pada proses pengolahan menggunakan citra yang memiliki gangguan seperti gambar yang kurang fokus, memiliki *noise*, dan objek tidak jelas sehingga mempengaruhi hasil analisa, maka dibutuhkan teknik pengolahan untuk mendapatkan citra yang optimal [6].

Daun kelor (*moringa oleifera*) dan daun katuk (*sauropus androgynus*) merupakan jenis tanaman herbal yang banyak dibudidayakan dan dimanfaatkan oleh masyarakat desa Sapaya, Kab. Gowa. Meskipun tidak memiliki nilai ekonomi tinggi tetapi sangat disukai dan dibutuhkan oleh masyarakat karena memiliki banyak manfaat bagi kesehatan salah satu dapat dijadikan sebagai obat herbal. Namun masih terdapat masyarakat yang kesulitan dalam membedakan jenisnya sehingga mereka salah dalam memanfaatkannya. Secara kasat mata kedua jenis daun herbal tersebut memiliki perbedaan dan kesamaan fisik dan nonfisik yang dapat diklasifikasikan. Oleh sebab itu, dilakukan proses identifikasi dengan memanfaatkan teknologi pengolahan citra untuk memberikan kemudahan kepada masyarakat dalam melakukan proses klasifikasi objek

sesuai dengan karakter berupa bentuk, tekstur, dan warna yang dimiliki oleh daun herbal tersebut [7]. Metode ekstraksi yang digunakan pada penelitian ini yaitu *Fourier Descriptor* (FD), setelah melakukan proses ekstraksi maka diperoleh data fisik daun yang nantinya dijadikan sebagai data pengelompokkan.

Penelitian ini bertujuan untuk mengimplementasikan ekstraksi FD dan metode *Naïve Bayes* dengan 3 kernel (*Gaussian*, *Bernoulli*, *Multinomial*) dan CNN sebagai pembanding dalam mengukur tingkat keakuratan akurasi dalam klasifikasi citra data daun. Penelitian ini akan melakukan klasifikasi citra daun menggunakan dua jenis daun yaitu katuk dan kelok. Masing-masing terdiri dari dua skenario dan setiap skenario terdiri dari 240 citra daun, sehingga jumlah keseluruhan citra yang digunakan pada penelitian ini berjumlah 480 citra. Penelitian ini dilakukan tahap *preprocessing* citra dan ekstraksi fitur citra daun untuk mendapatkan data masukan sebelum melakukan klasifikasi jenis daun herbal.

II. PENELITIAN YANG TERKAIT

Penelitian mengenai identifikasi daun telah dilakukan oleh Abdul Kadir dengan judul “*Leaf Identification Using Fourier Descriptor and Other Shape Features*” [8]. Pada penelitian ini, menggabungkan metode FD dengan beberapa fitur bentuk dalam mengidentifikasi 100 jenis daun dengan 16 sampel pada setiap jenis daun. Data uji menggunakan 20% sampel dan 80% untuk daun. Dataset yang digunakan terdiri dari daun dengan warna putih dan hitam yang diuji coba pada fitur bentuk atau *morfologi*, kemudian dilakukan proses klasifikasi menggunakan *bayes classifier*. Sehingga penelitian ini menghasilkan tingkat akurasi identifikasi senilai 88,03%.

Klasifikasi *Naïve Bayes* juga telah dilakukan oleh Hedva Kenang Candra Alivian Pratama, dkk pada data penyakit kanker payudara dan paru-paru [9]. Klasifikasi dilakukan dengan tahap awal *preprocessing*, tahap kedua melakukan proses pengklasifikasian dengan memisahkan data menjadi 2 yaitu *training* dan data uji yang mengaplikasikan teknik *k-fold cross validation*. Tahap ketiga klasifikasi *Gaussian Naïve Bayes* (GNB), *Multinomial Naïve Bayes* (MNB), dan *Bernoulli Naïve Bayes* (BNB) dengan data *testing*. tahap keempat melakukan evaluasi dengan *confusion matrix*. Jumlah dataset yang digunakan sebanyak 699 data pada *Breast Cancer* dan 309 pada *Lung Cancer*. Performa yang unggul di peroleh pada metode BNB dengan rata-rata *accuracy*, *precision* dan *recall* senilai 93,25%, 94,23%, dan 94,69%.

Penelitian [11] melakukan implementasi CNN Alexnet menggunakan tools MATLAB untuk mengetahui penyakit yang terdapat pada kopi. Penelitian ini menggunakan 300 data citra yang diklasifikasikan menjadi tiga yaitu *health*, *rust*, dan *red spider mite*. Proses uji coba dilakukan dengan 260 data dengan akurasi 69.44% - 80.56%. Pengujian menggunakan 40 data memperoleh akurasi 81.6%.


Penelitian [12] menggunakan metode ekstraksi HOG + SVM dalam mengidentifikasi jenis daun berdasarkan polanya dan menerapkan metode CNN untuk tujuan pengenalan. Penelitian ini menggunakan dua jenis daun yaitu Swedia yang

terdiri dari 15 spesies pohon Swedia dengan 75 daun per spesies (total 1125) dan Flavia yang terdiri dari 1907 gambar daun dari 32 spesies. Dataset dibagi menjadi 3 yaitu pelatihan 80%, validasi 20%, dan pengujian 20%, kemudian dilakukan proses *augmentasi*. Hasil pengujian terbaik pada daun Swedia (15 lapis) dengan metode HOG-SVM sebesar 98% dan CNN sebesar 98%, sedangkan pada daun Flavia (32 lapis) dengan metode HOG-SVM sebesar 92% dan CNN sebesar 95,2%.

Penelitian sebelumnya telah membuktikan bahwa beberapa metode klasifikasi dan ekstraksi berhasil diterapkan untuk mengetahui seberapa akurat dalam melakukan klasifikasi terhadap suatu objek. Oleh karena itu, dilakukan pengembangan menggunakan sistem pengolahan citra dengan metode *Naïve Bayes* dengan 3 kernel (GNB, BNB, GNB) dan CNN untuk klasifikasi dan pembanding. Sedangkan metode FD digunakan untuk ekstraksi ciri seperti bentuk dan tekstur. Perbedaan pada penelitian sebelumnya terletak pada objek yang digunakan terdiri dari 2 jenis daun herbal yaitu daun kelor (*moringa oleifera*) dan daun katuk (*sauropus androgyne*). *Output* yang diperoleh oleh sistem berupa performa hasil klasifikasi jenis daun herbal.

III. METODE PENELITIAN

Metode *Naïve Bayes* dan CNN akan digunakan dalam proses pengklasifikasian citra daun kelor dan katuk. Penelitian ini menggunakan FD sebagai ekstraksi fitur tekstur dan bentuk. Dalam pengembangan sistemnya dilakukan dengan beberapa tahap seperti pada Gbr 1.



Gbr. 1 Flowchart Sistem

A. Pengumpulan Data

Pengumpulan data dilakukan dengan observasi secara langsung di hutan yang bertempat di desa Sapaya, Kabupaten Gowa. Jenis daun yang digunakan adalah daun kelor dan katuk. Data citra daun yang digunakan berjumlah 480 citra dari 2 skenario diantaranya gelap dan terang yang setiap skenario terdiri dari 240 citra. Pengambilan citra gambar daun menggunakan kamera yang beresolusi 64 MP dengan format .JPG, ukuran yang digunakan 1:1 dengan *background* putih. Kemudian data disimpan di dalam satu folder dan diberikan label untuk diteruskan ke proses ekstraksi.

B. Preprocessing

Preprocessing merupakan proses yang dilakukan sebelum melakukan ekstraksi ciri yang bertujuan dalam memudahkan komputer mengenali pemrosesan algoritma dan mengganti sebuah citra yang acak sehingga menjadi sebuah citra yang sistematis [13]. Tahapan yang dimaksud antara lain *labelling, cropping, dan resizing*.

1) Labeling

Proses *labeling* merupakan suatu proses pemberian label atau nama terhadap objek berdasarkan jenis daun dan skenario yang berbeda-beda.

2) Cropping

Suatu proses pemisahan objek citra daun dengan *background* atau sesuai dengan yang dibutuhkan pada *preprocessing* sehingga mengurangi *noise* pada citra gambar.

3) Resizing

Melakukan perubahan terhadap ukuran *pixel*, hal ini dilakukan untuk mengurangi beban pada proses komputasi dan memastikan bahwa citra gambar yang akan dijalankan pada proses pelatihan dan pengujian berukuran sama sehingga memperlancar proses yang dilakukan.

C. Ekstraksi ciri

Untuk menemukan citra daun memerlukan ekstraksi ciri yang dianalisis dengan menggunakan bagian dari citra daun yang memungkinkan untuk menunjukkan karakteristik dari citra daun seperti pola gambar, diameter, bentuk, tekstur, dan sebagainya. Pada tahapan ini menggunakan ekstraksi ciri FD yang dianggap telah berhasil dalam mengisyaratkan bentuk citra yang bersumber dari *Fourier Transform* (FT) dan *shape signature*. Prinsip utama untuk memperoleh FD objek citra harus melalui proses pengolahan yang menjadi langkah pertama [14] dengan komputasi FD $F(x, y)$ sebagai citra biner. Dalam perhitungan *pixel* tepi pada suatu objek menggunakan *boundary tracing algorithm* yang didalamnya terdapat sebuah data geometri pada kontur objek. Secara umum FD $r-1$ dimensi didapatkan dari FT untuk fungsi *shape signature* bersumber dari suatu koordinat tepi ke- t sampai berjumlah N $\{(x(t), y(t), t = 0, 1, \dots, N-1)\}$. Perhitungan jarak *shape signature* pada FT dilakukan dengan persamaan (1). Penormalisasian pertama oleh *magnitude* koefisien dimana a_n ($n = 0, 1, \dots, N-1$) digunakan sebagai *shape signature* yang dirumuskan pada persamaan (2) dan vector s_n disebut sebagai *descriptor* bentuk [15], [16].

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

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

D. Klasifikasi

Klasifikasi pada penelitian ini menggunakan metode *Naïve Bayes* dan CNN, kedua metode klasifikasi tersebut digunakan untuk melakukan perbandingan terhadap data citra dalam menentukan keakuratan nilai akurasi.

1) Naïve Bayes

Naïve Bayes adalah suatu pengklasifikasi probabilistik dengan menambahkan kombinasi nilai frekuensi dari kumpulan data. Proses klasifikasi menghitung nilai probabilitas untuk setiap label kelas yang diberi input [17]. Algoritma ini didasarkan pada *teorema bayes* berasumsi bahwa setiap atribut yang berdiri sendiri atau tidak ditugaskan ke variabel kelas bernilai dan tidak terpengaruh oleh fitur lain. Nilai atributnya bisa berupa data statis atau berupa kategori [18]. *Teorema bayes* beroperasi dengan menemukan nilai probabilitas posterior ($P(X|Y)$) didasarkan pada probabilitas sebelumnya ($P(Y|X)$), ($P(X)$) merupakan probabilitas dari nilai X , dan pembuktian ($P(Y)$). X dan Y adalah suatu peristiwa [19]. Dari nilai yang telah dinyatakan maka diperoleh persamaan (3).

$$P(X|Y) = \frac{P(Y|X) \cdot P(X)}{P(Y)} \quad (3)$$

Pada algoritma *Naïve Bayes* memiliki banyak panduan dalam menganalisis suatu sampel maka nilai probabilitas *posterior* perhitungannya dapat disesuaikan seperti pada persamaan (4).

$$P(A|B_1 \dots B_N) = P(A) \cdot \frac{P(B_1 \dots B_N|A)}{P(B_1 \dots B_N)} \quad (4)$$

Pada klasifikasi data numerik, *Naïve Bayes* membutuhkan kernel dalam proses analisis antara lain;

a) Gaussian Naïve Bayes

Gaussian Naïve Bayes adalah suatu algoritma pengkajian yang menerapkan *teorema bayes* dengan struktur klasifikasi pada suatu kategori kelas yang sudah ditetapkan terlebih dahulu sesuai dengan keterangan dari variabel prediktor yang *independent* [20]. Klasifikasi GNB pada proses *training* data yang sifatnya *continuous* dilakukan segmentasi sesuai dengan kelas (y), jenis, dan rata-rata (μ) pada setiap kategorinya [21]. Nilai probabilitas dihitung seperti pada persamaan (5).

$$P(X = x | Y = y) = \frac{1}{\sqrt{2\pi\sigma^2_{ij}}} e^{-\frac{(x - \mu)^2}{2\sigma^2}} \quad (5)$$

Dimana x merupakan fitur citra *variable* dan σ adalah *standard deviation* fitur.

b) Bernoulli Naïve Bayes

Bernoulli Naïve Bayes merupakan suatu algoritma yang

bekerja dengan variabel biner *independent* yang disebut sebagai fitur, dimana hal tersebut membuktikan pada pengambilan keputusan suatu data yang sedang di proses apakah ya atau tidak [22]. Algoritma BNB bekerja lebih maksimal pada jumlah data yang lebih sedikit dengan pengambilan keputusan seperti pada persamaan (6).

$$P(x_i|y) = P(i|y)x_i + (1 - P(i|y))(1 - x_i) \quad (6)$$

c) Multinomial Naïve Bayes


Multinomial Naïve Bayes merupakan suatu algoritma yang menerapkan algoritma *Naïve Bayes* pada data yang terdistribusi *multinomial* dalam memperhitungkan nilai variabel *class* yang ditetapkan sehingga tidak terikat dengan variabel lain [23].

$$P(x|y) = P(x)P(y_1|x)P(y_2|x)\dots P(y_n|x) \quad (7)$$

Dimana $P(x|y)$ probabilitas *posterior* fitur pada kelas y .

2) Convolution Neural Network

Convolution Neural Network merupakan suatu konsep yang berperan sebagai pendeteksi fitur hierarki dimana prosesnya terinspirasi secara biologis yang bisa mempelajari dan mendeteksi objek, meskipun objeknya sangat abstrak [24]. CNN dimanfaatkan dalam mengklasifikasi data yang sudah diberi label dan terdapat metode pembelajaran *supervised* didalamnya [25]. Langkah penyelesaian dibagi menjadi ekstraksi fitur dan ekstraksi citra. Model pengembangan CNN pada umumnya terdapat empat komponen, yaitu *convolution layer*, *pooling layer*, fungsi aktivasi, dan *fully connected layer* [26]. Gbr 2 menunjukkan ilustrasi arsitektur CNN.



Gbr. 2 Ilustrasi Struktur *Convolutional Neural Network*

a) Convolution Layer

Convolution layer termasuk unsur terpenting dari CNN yang bertujuan melakukan ekstraksi terhadap fitur citra gambar dengan bobot konvolusi yang berbeda. Setelah melakukan konvolusi secara berulang maka dapat mengekstrak set fitur map dari citra gambar masukan [27]. *Feature map* pada *convolutional layer* [28].

$$FM_{(i,j)}^{(m)} = \text{ReLU} \left(b^{(m)} \sum_{r=1}^n \sum_{c=1}^n C_{(r1,c1)}^{(m)} I_{((r1+i),(c1+j))} \right) \quad (8)$$

b) Pooling Layers

Penggunaan *pooling layers* dilakukan sebagai upaya mengurangi jumlah parameter yang dapat dilatih agar

meminimalisir waktu pada proses komputasi [29]. Terdapat dua teknik pooling, yaitu *max pooling* dan *average pooling*. *Max pooling* bertujuan dalam menemukan nilai maksimum dalam suatu area, sedangkan *average pooling* untuk menemukan rata-rata dari fitur dari suatu area [25]. Persamaan *pooling layer* [30] yaitu :

$$FM_{i,j}^{m1} = \text{ReLU} \left(b^{(m1)} + \sum_{i=3j}^{3nj+2} \sum_{j=3j}^{3nj+2} p^{(m1)} FM_{(i,j)}^{(m1)} \right) \quad (9)$$

c) Fungsi aktivasi

Fungsi aktivasi merupakan suatu fungsi yang memungkinkan jaringan mengubah data input menjadi dimensi yang lebih tinggi untuk pengklasifikasian. Fungsi *sigmoid* merupakan fungsi aktivasi dari CNN yang diaplikasikan untuk mengganti nilai input x menjadi 0 dan 1 menggunakan bentuk distribusi fungsi, pada persamaan (10) [29]. Adapun fungsi ReLU secara umum dimanfaatkan sebagai fungsi pengganti yang menjaga karakteristik model *linear* seperti pada persamaan (11) [31].

$$\sigma(x) = \frac{1}{(1 + e^{-x})} \quad (10)$$

$$\sigma(x) = \max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (11)$$

d) Fully Connected Layer

Fully Connected Layer merupakan sebuah lapisan yang menghubungkan setiap neuron yang mempunyai lintasan yang sama dan mengklasifikasikan citra gambar sesuai dengan citra fitur yang telah terekstraksi, seperti pada persamaan (12) [25][30].

$$o^{(i)} = \text{ReLU} \left(b^{(i)} + \sum_{k=0}^{n_k-1} W_{(k)}^{(i)} N_{(k)} \right) \quad (12)$$

E. Evaluasi

Dalam melakukan proses klasifikasi model label kelas menggunakan beberapa matriks diantaranya, *accuracy*, *precision*, *recall*, dan *f1-score*. Setiap baris matriks mewakili kelas dari data aktual, kolom mewakili kelas data prediksi begitu juga dengan sebaliknya. Sebelum menggunakan matriks terlebih dahulu mendefinisikan *True Negative* (TN) sebagai data aktual negatif yang diprediksi menjadi negatif, *False Negatif* (FN) sebagai data aktual positif yang diprediksi menjadi negatif, *False Positive* (FP) sebagai data aktual negatif yang diprediksi menjadi positif, *True Positive* (TP) sebagai data aktual positif yang diprediksi menjadi positif [32]. Seperti yang ditunjukkan pada Tabel I.

TABEL I
CONFUSION MATRIX

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

1) Accuracy

Accuracy merupakan nilai proporsi secara keseluruhan

dalam mendefinisikan tingkat ketepatan pada proses klasifikasi data dengan bentuk persentase [33].

$$\frac{TP + TN}{Total} \quad (13)$$

2) Precision

Precision merupakan proporsi pada perkiraan nilai benar positif terhadap proses klasifikasi data yang diperkirakan positif dalam bentuk persentase [33].

$$\frac{TP}{FP + TP} \quad (14)$$

3) Recall

Recall merupakan proporsi pada perkiraan nilai benar positif terhadap proses klasifikasi data yang diperkirakan benar positif dalam bentuk persentase.

$$\frac{TP}{FN + TP} \quad (15)$$

4) F1-Score

F1-Score adalah nilai dari perhitungan *precision* dan *recall*.


$$2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (16)$$

F. Performa Klasifikasi

Setelah melewati proses pengumpulan data, *preprocessing*, ekstraksi, klasifikasi, dan evaluasi, maka memperoleh hasil pengujian klasifikasi daun herbal yang direpresentasikan dan dibahas pada bab selanjutnya.


IV. HASIL DAN PEMBAHASAN

Untuk mengetahui tingkat akurasi sistem yang dibentuk dilakukan pengujian dengan proses klasifikasi pada citra daun katuk dan kelor. Citra daun yang di proses telah melalui *preprocessing* yang ditunjukkan pada Gbr. 4



Gbr. 4 Daun Kelor (a) Dan Daun Katuk (b)

Proses pengujian dilakukan dengan menggunakan 2 skenario yaitu gelap dan terang, setiap skenario berjumlah 240 citra dengan total *dataset* yang digunakan adalah 480 citra yang dibagi dengan fungsi *split* 20% data *testing* dan 80% data *training*. Setelah itu, dilakukan perbandingan menggunakan metode klasifikasi *Naive Bayes* dengan CNN untuk mengukur kinerja sistem dan ketepatan dalam proses klasifikasi citra daun. Fungsi aktivasi ReLU dan *sigmoid* diimplementasikan dalam arsitektur CNN sebagaimana pada Gbr. 5



Gbr. 5 Arsitektur *Convolutional Neural Network*


Hasil pengujian citra data pada setiap metode ditunjukkan pada Tabel II, yang menampilkan performa terdiri dari *accuracy*, *precision*, *recall*, dan *f1-Score*. Dimana keakuratan hasil klasifikasi disesuaikan pada jenis citra data dan metode yang digunakan. Kondisi ini membuktikan dengan menerapkan metode dan skenario yang berbeda dapat memperoleh hasil yang berbeda atau tidak konsisten pada setiap kasusnya. Hasil perbandingan pada klasifikasi citra daun herbal ini menunjukkan metode CNN dan GNB dengan menggunakan ekstraksi FD menghasilkan hasil yang bagus untuk pengujian citra daun herbal dan lebih baik dibandingkan dengan metode lainnya. Sedangkan metode klasifikasi BNB memperoleh nilai yang jauh lebih rendah dibandingkan dengan metode klasifikasi lainnya, karena metode BNB bekerja lebih maksimal pada data yang berbentuk dokumen daripada citra gambar dengan jumlah data sedikit. Sehingga tidak dapat diusulkan sebagai metode klasifikasi untuk citra daun herbal.

TABEL II
PERFORMA FD – *NAÏVE BAYES* (GNB, MBN, BNB), FD - CNN, DAN CNN

Skenario	Precision	Recall	F1-Score	Accuracy
FD - GNB				
Gelap	1.00	1.00	1.00	1.00
Terang	0.94	0.94	0.94	0.94
FD - MNB				
Gelap	0.98	0.98	0.98	0.98
Terang	0.98	0.98	0.98	0.98
FD - BNB				
Gelap	0.26	0.50	0.34	0.52
Terang	0.23	0.50	0.31	0.46
FD - CNN				
Gelap	0.98	0.98	0.98	0.98
Terang	1.00	1.00	1.00	1.00
CNN				
Gelap	0.98	0.98	0.98	0.98
Terang	0.99	0.99	0.99	0.99


Tingkat akurasi di setiap metode dipengaruhi oleh *background* dan pencahayaan dari input *dataset*. Percobaan dengan menggunakan ekstraksi FD dengan tambahan kernel mendapatkan akurasi, *precision*, *recall*, dan *f1-score* tertinggi

pada metode GNB dalam skenario gelap sebesar 100%. Metode MNB memperoleh akurasi yang tinggi di kedua skenario dengan akurasi, *precision*, *recall*, dan *f1-score* masing-masing 98%. Metode BNB pada skenario terang mendapatkan akurasi senilai 46% dengan *precision*, *recall*, *f1-score* sebesar 23%, 50%, dan 31%, sedangkan pada skenario gelap memperoleh akurasi lebih tinggi dari skenario terang sebesar 52% dengan *precision*, *recall*, dan *f1-score* senilai 26%, 50%, dan 34%. Gbr. 6 menunjukkan hasil performa metode FD - *Naive Bayes* untuk setiap kernel dan skenario data.




Gbr. 6 Performa FD - *Naive Bayes* (GNB, MNB, BNB) pada Skenario Gelap dan Terang

Percobaan dengan menggunakan metode FD - CNN pada skenario terang memperoleh akurasi, *precision*, *recall*, dan *f1-score* sebesar 100%, dalam skenario gelap memperoleh akurasi sedikit lebih rendah dengan nilai *precision*, *recall*, dan *f1-score* sebesar 98% seperti yang ditunjukkan pada Gbr. 7



Gbr. 7 Pembelajaran Algoritma FD-CNN (20 Epoch)

Metode CNN dilakukan tanpa metode ekstraksi karena telah mempunyai ekstraksi bawaan yang dapat melakukan pembelajaran mandiri untuk pengenalan objek, sehingga menghasilkan nilai akurasi lebih tinggi pada skenario terang sebesar 99% dan skenario gelap sebesar 98%. Hasil pembelajaran algoritma CNN ditunjukkan pada Gbr. 8



Gbr. 8 Pembelajaran Algoritma CNN (20 Epoch)

V. KESIMPULAN

Berdasarkan hasil pengujian yang telah dilakukan pada proses klasifikasi daun herbal diperoleh kesimpulan bahwa metode FD - CNN pada skenario citra terang dan metode FD - GNB pada skenario gelap, dapat digunakan untuk meningkatkan performa klasifikasi daun herbal yang didasarkan pada bentuk dan tekstur dengan akurasi sebesar 100% dimana nilai *precision*, *recall*, *f1-score* masing-masing 100%.

Pada pengembangan penelitian selanjutnya direkomendasikan menggunakan beberapa jenis daun dan menambah fokus ke fitur warna, karena penelitian ini hanya menggunakan fitur tekstur dan bentuk, serta menambahkan skenario pengujian untuk memperoleh beberapa nilai perbandingan lainnya. Selain itu dapat menambahkan ekstraksi fitur yang mempunyai fungsi sama untuk memperoleh nilai akurasi lebih maksimal pada proses klasifikasi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada lab Riset FIKOM UMI yang telah memberikan izin dalam penggunaan sarana dan prasarana untuk penelitian ini.

DAFTAR PUSTAKA

- [1] A. Ash, B. Ellis, L. J. Hickey, K. Johnson, P. Wilf, and S. Wing, *Manual of Leaf Architecture, Morphological description and categorization of dicotyledonous and net-veined monocotyledonous angiosperms*, vol. 34, no. 4. 1999. doi: 10.13140/2.1.3674.5282.
- [2] G. Cerutti *et al.*, "Guiding Active Contours for Tree Leaf Segmentation and Identification To cite this version : Segmentation

- and Identification,” 2013.
- [3] J. Wäldchen and P. Mäder, *Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review*, vol. 25, no. 2. Springer Netherlands, 2018. doi: 10.1007/s11831-016-9206-z.
- [4] F. Liantoni, “Klasifikasi Daun Dengan Perbaikan Fitur Citra Menggunakan Metode K-Nearest Neighbor,” *J. Ultim.*, vol. 7, no. 2, pp. 98–104, 2016, doi: 10.31937/ti.v7i2.356.
- [5] Z. Husin *et al.*, “Embedded portable device for herb leaves recognition using image processing techniques and neural network algorithm,” *Comput. Electron. Agric.*, vol. 89, pp. 18–29, Nov. 2012, doi: 10.1016/J.COMPAG.2012.07.009.
- [6] R. Rahmadewi, V. Efelina, and E. Purwanti, “IDENTIFIKASI JENIS TUMBUHAN MENGGUNAKAN CITRA DAUN BERBASIS JARINGAN SARAF TIRUAN (ARTIFICIAL NEURAL NETWORKS),” vol. VII, no. 2, pp. 38–43.
- [7] W. O. W. Sofyani, “Sistem Klasifikasi Kelor dalam Etnobotani Masyarakat Wolio,” *JSW (Jurnal Sosiol. Walisongo)*, vol. 3, no. 1, pp. 49–64, 2019, doi: 10.21580/jsw.2019.3.1.3488.
- [8] A. Kadir, “Leaf Identification Using Fourier Descriptors and Other Shape Features,” *Gate to Comput. Vis. Pattern Recognit.*, vol. 1, no. 1, pp. 3–7, 2015, doi: 10.15579/gtcvpr.0101.003007.
- [9] H. Kenang Candra Alivian Pratama, W. Suharto, K. Kunci, B. Naïve Bayes, G. Naïve Bayes, and M. Naïve Bayes, “Pengklasifikasian Kanker Payudara Dan Kanker Paru-Paru Dengan Metode Gaussian Naïve Bayes, Multinomial Naïve Bayes, Dan Bernoulli Naïve Bayes Classification Of Breast Cancer And Lung Cancer Using The Gaussian Naïve Bayes Multinomial Nave Bayes And Bernoul,” *J. Smart Teknol.*, vol. 3, no. 4, pp. 2774–1702, 2022, [Online]. Available: <http://jurnal.unmuhjember.ac.id/index.php/JST>
- [10] K. Ayuningsih, Y. A. Sari, and P. P. Adikara, “Klasifikasi Citra Makanan Menggunakan HSV Color Moment dan Local Binary Pattern dengan Naïve Bayes Classifier,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Univ. Brawijaya*, vol. 3, no. 4, pp. 3166–3173, 2019.
- [11] D. Irfansyah *et al.*, “Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi,” vol. 6, no. 2, pp. 87–92, 2021.
- [12] T. Q. Bao, N. T. T. Kiet, T. Q. Dinh, and H. X. Hiep, “Plant species identification from leaf patterns using histogram of oriented gradients feature space and convolution neural networks,” *J. Inf. Telecommun.*, vol. 4, no. 2, pp. 140–150, 2020, doi: 10.1080/24751839.2019.1666625.
- [13] H. Tuhuteru and A. Iriani, “Analisis Sentimen Perusahaan Listrik Negara Cabang Ambon Menggunakan Metode Support Vector Machine dan Naive Bayes Classifier,” *J. Inform. J. Pengemb. IT*, vol. 3, no. 3, pp. 394–401, 2018, doi: 10.30591/jpit.v3i3.977.
- [14] S. E. Basri, D. Indra, H. Darwis, A. W. Mufila, L. B. Ilmawan, and B. Purwanto, “Recognition of Indonesian Sign Language Alphabets Using Fourier Descriptor Method,” *3rd 2021 East Indones. Conf. Comput. Inf. Technol. EIconCIT 2021*, pp. 405–409, 2021, doi: 10.1109/EIconCIT50028.2021.9431883.
- [15] P. A. R. Devi, N. Suciati, and W. N. Khotimah, “Apakah kombinasi power lbp dan fourier descriptor dapat digunakan untuk klasifikasi citra kerang?,” *Teknologi*, vol. 6, no. 2, p. 68, 2016, doi: 10.26594/teknologi.v6i2.768.
- [16] R. E. Pawening, A. Z. Arifin, and A. Yuniarti, “Ekstraksi Fitur Berdasarkan Deskriptor Bentuk dan Titik Salien Untuk Klasifikasi Citra Ikan Tuna,” *J. Buana Inform.*, vol. 7, no. 3, pp. 215–224, 2016, doi: 10.24002/jbi.v7i3.660.
- [17] D. Sartika and D. I. Sensuse, “Perbandingan Algoritma Klasifikasi Naive Bayes, Nearest Neighbour, dan Decision Tree pada Studi Kasus Pengambilan Keputusan Pemilihan Pola Pakaian,” *Jatissi*, vol. 1, no. 2, pp. 151–161, 2017.
- [18] A. Aninditya, M. A. Hasibuan, and E. Sutoyo, “Text mining approach using TF-IDF and naive bayes for classification of exam questions based on cognitive level of bloom’s taxonomy,” *Proc. - 2019 IEEE Int. Conf. Internet Things Intell. Syst. IoTaIS 2019*, no. November 2019, pp. 112–117, 2019, doi: 10.1109/IoTaIS47347.2019.8980428.
- [19] A. Budiman, J. C. Young, and A. Suryadibrata, “Implementasi Algoritma Naïve Bayes untuk Klasifikasi Konten Twitter dengan Indikasi Depresi,” *J. Inform. J. Pengemb. IT*, vol. 6, no. 2, pp. 133–138, 2021, [Online]. Available: <http://ejournal.poltektegal.ac.id/index.php/informatika/article/view/2419>
- [20] J. C. Griffis, J. B. Allendorfer, and J. P. Szaflarski, “Voxel-based Gaussian naïve Bayes classification of ischemic stroke lesions in individual T1-weighted MRI scans,” *J. Neurosci. Methods*, vol. 257, pp. 97–108, 2016, doi: 10.1016/j.jneumeth.2015.09.019.
- [21] B. M. and C. P., “An Automated Technique using Gaussian Naïve Bayes Classifier to Classify Breast Cancer,” *Int. J. Comput. Appl.*, vol. 148, no. 6, pp. 16–21, 2016, doi: 10.5120/ijca2016911146.
- [22] G. Singh, “Comparison between Multinomial and Bernoulli Naïve Bayes for Text Classification,” *2019 Int. Conf. Autom. Comput. Technol. Manag.*, pp. 593–596, 2019.
- [23] M. Sadikin, R. Rosnelly, and T. Surya Gunawan, “Perbandingan Tingkat Akurasi Klasifikasi Penerimaan Dosen Tetap Menggunakan Metode Naive Bayes Classifier dan C4.5,” *J. Media Inform. Budidarma*, vol. 4, pp. 1100–1109, 2020, doi: 10.30865/mib.v4i4.2434.
- [24] Z. Zhang, “Derivation of Backpropagation in Convolutional Neural Network (CNN),” *Univ. Tennessee, Knoxville, TN*, pp. 1–7, 2016.
- [25] M. Sholihin, “Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network,” *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 3, pp. 1352–1360, 2021, doi: 10.35957/jatissi.v8i3.939.
- [26] S. Indolia, A. K. Goswami, S. P. Mishra, and P. Asopa, “Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach,” *Procedia Comput. Sci.*, vol. 132, pp. 679–688, 2018, doi: 10.1016/j.procs.2018.05.069.
- [27] 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, p. 105393, Jun. 2020, doi: 10.1016/J.COMPAG.2020.105393.
- [28] L. Mookdarsanit, P. M.-S. S. S. and, and undefined 2019, “Thai Herb Identification with Medicinal Properties Using Convolutional Neural Network,” *ssstj.sci.ssru.ac.th*, Accessed: Jan. 17, 2023. [Online]. Available: http://www.ssstj.sci.ssru.ac.th/Content/journals/Volume6_No2/Vol

6_No2_005.pdf

- [29] M. P. Véstias, "Convolutional Neural Network," *Encycl. Inf. Sci. Technol. Fifth Ed.*, vol. 8, no. 4, pp. 12–26, 2020, doi: 10.4018/978-1-7998-3479-3.ch002.
- [30] Haryono, Khairul Anam, and Azmi Saleh, "Autentikasi Daun Herbal Menggunakan Convolutional Neural Network dan Raspberry Pi," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 9, no. 3, pp. 278–286, 2020, doi: 10.22146/v9i3.302.
- [31] P. Purnawansyah, H. Haviluddin, H. Darwis, H. Azis, and Y. Salim, "Backpropagation Neural Network with Combination of Activation Functions for Inbound Traffic Prediction," *Knowl. Eng. Data Sci.*, vol. 4, no. 1, p. 14, 2021, doi: 10.17977/um018v4i12021p14-28.
- [32] C. Journal, I. W. Saputro, B. W. Sari, P. Studi, I. Komputer, and J. Informatika, "Uji Performa Algoritma Naïve Bayes untuk Prediksi Masa Studi Mahasiswa," vol. 6, no. 1, pp. 1–11, 2019.
- [33] A. Prabhat and V. Khullar, "Sentiment classification on big data using Naïve bayes and logistic regression," *2017 Int. Conf. Comput. Commun. Informatics, ICCCI 2017*, no. January 2017, 2017, doi: 10.1109/ICCCI.2017.8117734.