



Klasifikasi Tanaman Herbal Menggunakan Metode Naïve Bayes Classifier Dan K-Nearest Neighbor

Fingki Junaidi Manurung¹, Sutejo², Lisnawita³, Fajrizal⁴

^{1,2,3,4} Program Studi Teknik Informatika Fakultas Ilmu Komputer Universitas Lancang Kuning

^{1,2,3,4} Jl. Yos Sudarso KM. 8 Rumbai, Pekanbaru, Riau, telp. 0811 753 2015

e-mail:¹fingiki71@gmail.com,²sutejo@unilak.ac.id

Abstrak

Perkembangan ilmu tanaman telah mengalami kemajuan yang pesat, khususnya ilmu mengenai tanaman herbal. Tanaman herbal memiliki banyak manfaat bagi kehidupan manusia yaitu sebagai penyediaan oksigen, bahan makanan, obat-obatan, maupun bahan kosmetika. Untuk mengetahui jenis-jenis tanaman herbal dapat dilakukan dengan proses klasifikasi. Pada penelitian ini, fitur VGG16 digunakan untuk ekstraksi fitur daun herbal. Fitur yang digunakan berjumlah 6 fitur. Ada beberapa macam metode klasifikasi yang biasa digunakan. Pada penelitian ini metode klasifikasi yang digunakan adalah metode Naïve Bayes Classifier dan K-Nearest Neighbor (KNN). Metode Naïve Bayes Classifier merupakan metode Bayesian Learning yang paling cepat dan sederhana. Sedangkan metode KNN dapat melakukan klasifikasi dengan cepat berdasarkan jarak terdekat diantara objek data. Berdasarkan hasil uji coba yang dilakukan, penggunaan metode Naïve Bayes Classifier didapatkan nilai akurasi sebesar 92,86%, sedangkan dengan menggunakan metode K-Nearest Neighbor didapatkan nilai akurasi sebesar 82,14%. Hal ini menunjukkan bahwa kinerja metode Naïve Bayes Classifier lebih baik dibandingkan metode KNN.

Kata kunci: machine learning, klasifikasi, tanaman herbal, naïve bayes classifier, k-nearest neighbor

Abstract

The development of plant science has made rapid progress, especially the science of herbal plants. Herbal plants have many benefits for human life, namely as a provider of oxygen, food ingredients, medicines, and cosmetics. To find out the types of herbal plants, a classification process can be carried out. In this study, the VGG16 feature was used to extract herbal leaf features. The features used were 6 features. There are several types of classification methods that are commonly used. In this study, the classification methods used were the Naïve Bayes Classifier and K-Nearest Neighbor (KNN) methods. The Naïve Bayes Classifier method is the fastest and simplest Bayesian Learning method. While the KNN method can classify quickly based on the closest distance between data objects. Based on the results of the trials conducted, the use of the Naïve Bayes Classifier method obtained an accuracy value of 92.86%, while using the K-Nearest Neighbor method obtained an accuracy value of 82.14%. This shows that the performance of the Naïve Bayes Classifier method is better than the KNN method.

Keywords: machine learning, classification, herbal plants, naïve bayes classifier, k-nearest neighbor.

1. PENDAHULUAN

Tanaman herbal adalah tumbuh-tumbuhan yang berada di alam dan memiliki khasiat sebagai obat. Tumbuh-tumbuhan tertentu memiliki kegunaan khusus yang dapat mencegah dan menyembuhkan penyakit. Indonesia dikenal sebagai negara nomor dua dengan tanaman obat tradisional terbanyak setelah Brazil. Banyak faktor yang menjadi alasan masyarakat modern kembali menggunakan tanaman herbal karena harga obat-obat kimia semakin mahal yang tidak terjangkau oleh semua kalangan masyarakat. Tanaman herbal terbagi menjadi lima kelas, yaitu binahong, cincau hijau, keji beling, sambung nyawa dan sirih. Dengan tekstur dan daun yang sama masyarakat banyak tidak mengetahui pemanfaatan tanaman herbal sebagai obat tidak sesuai dengan kegunaannya [6].

Indonesia merupakan negara yang kaya akan keanekaragaman hayati, termasuk tanaman herbal. Berbagai jenis tanaman herbal tumbuh melimpah di berbagai wilayah Indonesia, baik di daratan maupun di kepulauan. Tanaman herbal ini telah menjadi bagian

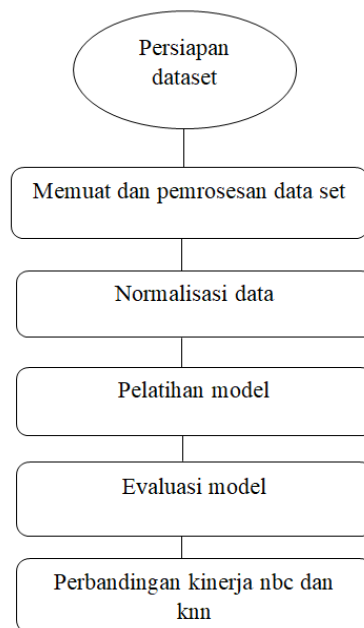
integral dari tradisi pengobatan masyarakat Indonesia selama berabad-abad. Permasalahan yang dihadapi masyarakat dengan keterbatasan biaya dan terbatasnya stok obat-obatan ditambah dengan krisis finansial dengan sendiri masyarakat harus bisa memanfaatkan tanaman-tanaman yang ada disekitar lingkungannya, walaupun sebenarnya tanaman obat herbal ini bukanlah sesuatu yang baru melainkan sudah ada sejak dulu dari jaman nenek moyang bangsa ini, mengingat masyarakat sudah maju maka mereka lebih menyukai hal-hal berbau instan dan mudah diadapat serta tidak perlu proses pembuatan [2]. Tanaman herbal memiliki potensi besar untuk memberikan kontribusi pada bidang kesehatan, pengembangan obat-obatan, dan keberlanjutan lingkungan.

Dalam mengelola dan memanfaatkan kekayaan tanaman herbal ini, penting untuk memiliki pemahaman yang baik tentang identifikasi dan klasifikasi jenis-jenis tanaman herbal yang berbeda. Pengelompokan tanaman herbal berdasarkan karakteristik morfologisnya adalah langkah awal yang krusial dalam memahami kegunaan dan manfaat potensialnya [1].

Penelitian sebelumnya telah menunjukkan bahwa teknik klasifikasi data, seperti Naïve Bayes Classifier dan K-Nearest Neighbor, dapat digunakan untuk mengklasifikasikan tanaman herbal berdasarkan ciri-ciri morfologisnya. Namun, perbandingan kinerja dan aplikasi praktis kedua metode ini dalam konteks klasifikasi tanaman herbal masih perlu diteliti lebih lanjut

2. METODE PENELITIAN

Adapun tahapan penelitian sebagai berikut



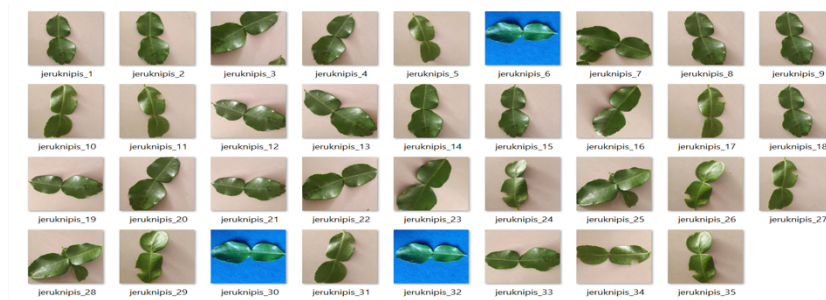
Gambar 1. Tahapan Penelitian

2.1. persiapan data set

Tahap ini mencakup mengatur lokasi dataset yang akan digunakan. Dataset ini berisi gambar-gambar tanaman herbal yang akan digunakan untuk melatih dan menguji model klasifikasi. Data yang digunakan berada di google drive dengan 4 jenis tanaman herbal: Jambu, jeruk nipis, sirih, mulbery dan memiliki jumlah 140 gambar daun herbal yang masing masing jenisnya memiliki 35 gambar tiap jenis.



Gambar 2. Daun Jambu Biji



Gambar 3. Daun Jeruk Nipis



Gambar 4. Daun sirih



Gambar 5. Daun Mulberry

2.2. memuat dan pemrosesan data set

Pada tahap ini, gambar-gambar dari dataset dimuat ke dalam memori komputer. Kemudian, gambar-gambar tersebut diubah ke ukuran yang sama (100x100 piksel) agar ukuran

gambar seragam dan tidak terlalu besar. Selain itu, jika gambar-gambar tersebut tidak dalam format citra grayscale, maka akan dikonversi menjadi citra grayscale. Tahap ini bertujuan untuk memastikan bahwa data siap digunakan untuk proses pelatihan model.

2.3. Normalisasi Data

Normalisasi adalah proses yang dilakukan untuk mengubah nilai-nilai piksel dalam gambar menjadi rentang yang lebih kecil, biasanya dari 0 hingga 1. Hal ini dilakukan untuk mempermudah proses pelatihan model dan meningkatkan kinerja model.

2.4. Pelatihan Model

Pada tahap ini, model klasifikasi, yaitu Naive Bayes Classifier dan K-Nearest Neighbors Classifier, dilatih menggunakan data latih yang telah diproses sebelumnya. Proses pelatihan ini dilakukan dengan memberikan masukan berupa gambar-gambar dan kelas-kelas yang sesuai.

2.5. Evaluasi Model

Setelah model dilatih, langkah selanjutnya adalah mengevaluasi kinerja model menggunakan data uji yang telah diproses sebelumnya. Model akan melakukan prediksi terhadap data uji, dan hasil prediksi tersebut akan dibandingkan dengan label yang sebenarnya. Akurasi model kemudian dihitung sebagai ukuran kinerja, yang menggambarkan seberapa baik model dapat mengklasifikasikan gambar-gambar tersebut dengan benar.

2.6. Perbandingan Kinerja NBC dan KNN

Perbandingan NBC dan KNN dengan Matriks keputusan dan laporan klasifikasi digunakan untuk membandingkan kinerja kedua model.

3. HASIL DAN PEMBAHASAN

1. Memuat dan pemrosesan data set

Tahapan memuat dan pemrosesan data set meliputi beberapa tahapan yaitu :

a. Merubah ukuran gambar

Pada tahap ini, gambar-gambar dari dataset dimuat ke dalam memori komputer. Kemudian, gambar-gambar tersebut diubah ke ukuran yang sama (100x100 piksel) agar ukuran gambar seragam dan tidak terlalu besar.



Gambar 6. Gambar Setelah Ukurannya di Ubah

Pengubahan ukuran gambar ini bertujuan untuk mengurangi variasi ukuran gambar dalam dataset serta mempermudah proses ekstraksi fitur dan pelatihan model. Selain itu, gambar asli juga disimpan untuk keperluan visualisasi dan verifikasi. Melalui visualisasi gambar-gambar asli dan yang telah diubah ukurannya, kita dapat melihat bahwa proses resize tidak mengubah informasi penting dalam gambar dan tetap mempertahankan karakteristik utama dari setiap gambar.

b. Konversi Gambar Menjadi Format Array Numpy

Jika gambar-gambar tersebut tidak dalam format array numpy, maka akan dikonversi menjadi array numpy. Berikut contoh hasil konversi gambar menjadi format array numpy

```
Contoh X_train:
Sample 1 - Bentuk: (100, 100, 3), Label: sirih
Contoh piksel (baris 0, kolom 0-4): [[ 34 150 121]
 [ 29 137 108]
 [ 26 148 115]
 [ 51 148 117]
 [136 176 151]]
Sample 2 - Bentuk: (100, 100, 3), Label: sirih
Contoh piksel (baris 0, kolom 0-4): [[17 79 43]
 [17 75 40]
 [ 8 63 28]
 [17 67 33]
 [18 68 34]]
```

Gambar 7. Hasil Array Numpy

Dari gambar diatas merupakan hasil gambar setelah di ekstraksi menjadi array numpy Tahap ini bertujuan untuk memastikan bahwa data siap digunakan untuk proses latih model.

c. Pembagian data training dan testing

Setelah melakukan konversi gambar menjadi format array numpy kemudian bagi Data Menjadi Set Pelatihan dan Pengujian. Penelitian ini menggunakan fungsi `train_test_split` dari `sklearn.model_selection` untuk membagi dataset menjadi set pelatihan dan pengujian. Dalam penelitian ini, 80% data digunakan untuk pelatihan dan 20% untuk pengujian. Hasil pembagian menunjukkan bahwa dataset memiliki distribusi label yang seimbang antara set pelatihan dan set pengujian. Hal ini penting untuk memastikan bahwa model yang dilatih tidak bias terhadap kelas tertentu dan dapat melakukan generalisasi dengan baik pada data baru. Statistik mengenai jumlah sampel untuk setiap label juga dihitung. Distribusi yang seimbang ini memberikan dasar yang baik untuk pelatihan model, karena tidak ada kelas yang terlalu mendominasi atau terlalu sedikit. Pada penelitian terdahulu yang diteliti oleh [10]. Peneliti menggunakan 120 data set di antaranya 80% data train atau 96 gambar dan 20% data test atau 24 gambar.

2. Normalisasi data

Setelah mendapatkan format array numpy kemudian akan dilakukan normalisasi guna untuk mengubah nilai-nilai piksel dalam gambar menjadi rentang yang lebih kecil, biasanya dari 0 hingga 1. Hal ini dilakukan untuk mempermudah proses pelatihan model dan meningkatkan kinerja model. Proses normalisasi dilakukan untuk memastikan bahwa data memiliki skala yang seragam. Hal ini penting karena berbagai algoritma pembelajaran mesin, termasuk Naive Bayes dan KNN, sensitif terhadap skala fitur.

a. Ekstraksi menggunakan VGG16

VGG16 adalah arsitektur jaringan saraf konvolusional (CNN) yang dikembangkan oleh Karen Simonyan dan Andrew Zisserman dari Universitas Oxford. Ini adalah salah satu arsitektur yang sangat terkenal dan berhasil dalam pengenalan gambar.

```
Beberapa contoh fitur-fitur dari data pelatihan:
Fitur ke- 1
[1993.1373 2600.0637 0. ... 1031.0306 0. 513.599 ]
Fitur ke- 2
[ 984.897 2233.984 1218.2173 ... 0. 0. 719.94336]
Fitur ke- 3
[ 537.44696 440.945 78.032295 ... 0. 0.
3600.7075 ]

Beberapa contoh fitur-fitur dari data pengujian:
Fitur ke- 1
[459.39423 678.76196 0. ... 0. 0. 0. ]
Fitur ke- 2
[176.78326 308.84744 0. ... 0. 450.6772 0. ]
Fitur ke- 3
[223.2658 289.08896 0. ... 0. 75.67027 0. ]
```

Gambar 8. Hasil Ekstraksi Fitur

Ekstraksi fitur dilakukan menggunakan model VGG16 yang telah dilatih sebelumnya. Model ini dipotong pada lapisan block3_pool untuk mendapatkan fitur yang lebih abstrak dan informatif dari gambar. Hasil ekstraksi fitur menunjukkan bahwa bentuk fitur yang dihasilkan memiliki dimensi yang lebih kecil dibandingkan dengan gambar asli, sehingga dapat memudahkan proses pelatihan model. Penelitian sebelumnya oleh [1] menggunakan ekstraksi fitur geometri dan invariant moment.

3. Model Naïve Bayes Classifier

Pada tahap ini, model klasifikasi, yaitu Naive Bayes Classifier dilatih menggunakan data latih yang telah diproses sebelumnya. Proses pelatihan ini dilakukan dengan memberikan masukan berupa gambar-gambar dan kelas-kelas yang sesuai. Berikut tahapan yang dilakukan model naïve bayes clasifier.

a. Probabilitas Prior

Probabilitas prior adalah konsep dalam statistik Bayesian yang menggambarkan keyakinan awal atau pengetahuan sebelumnya tentang suatu peristiwa sebelum ada data baru yang diperoleh.

b. Mean dan varian

Karena melakukan perhitungan manual untuk seluruh fitur dan data bisa sangat rumit, kita akan fokus pada satu fitur sebagai contoh dan menghitung mean dan varians untuk fitur pertama saja.

c. Probabilitas Likelihood

Probabilitas likelihood, atau lebih sering disebut sebagai likelihood, adalah konsep dalam statistik yang mengukur seberapa mungkin data yang diamati terjadi mengingat suatu model atau parameter tertentu. Dalam konteks Bayesian, likelihood digunakan untuk memperbarui probabilitas prior menjadi probabilitas posterior.

d. Menghitung Probabilitas Posterior

Menghitung probabilitas posterior adalah langkah penting dalam analisis Bayesian, di mana kita memperbarui keyakinan kita tentang parameter model berdasarkan data yang diamati.

4. Model K-Nearest Neighbor

Pada tahap ini, model klasifikasi, yaitu K-Nearest Neighbor dilatih menggunakan data latih yang telah diproses sebelumnya. Proses pelatihan ini dilakukan dengan memberikan masukan berupa gambar-gambar dan kelas-kelas yang sesuai. Berikut tahapan yang dilakukan model K-Nearest Neighbor

a. Hitung jarak ecludient

Menghitung jarak Euclidean adalah langkah dasar dalam banyak aplikasi matematika, statistik, dan ilmu data, terutama dalam konteks analisis klaster dan pembelajaran mesin

$$\text{jarak}(p, q) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (1)$$

b. Urutkan jarak

Setelah mendapatkan hasil menghitung jarak ecludien selanjutnya kita urutkan hasilnya.

c. Pilih tetangga

Dalam konteks ini, setelah menghitung dan mengurutkan jarak Euclidean dari titik referensi ke titik-titik lainnya, kita dapat memilih tetangga terdekat berdasarkan jarak yang terkecil.

d. Prediksi kelas

Prediksi kelas menggunakan algoritma K-Nearest Neighbors (K-NN) melibatkan beberapa langkah yang telah dibahas sebelumnya, seperti menghitung jarak Euclidean dan memilih tetangga terdekat.

5. Akurasi model naïve bayes clasifier dan k nearest neighbor

Setelah model dilatih, langkah selanjutnya adalah mengevaluasi kinerja model menggunakan data uji yang telah diproses sebelumnya. Model akan melakukan prediksi terhadap data uji, dan hasil prediksi tersebut akan dibandingkan dengan label yang sebenarnya. Akurasi model kemudian dihitung sebagai ukuran kinerja, yang menggambarkan seberapa baik model dapat mengklasifikasikan gambar-gambar tersebut dengan benar.

a. Akurasi naïve bayes

Tabel 1. Table Prediksi Naive Bayes

NO	LABEL SEBENARNYA	PREDIKSI
1	jeruknipis	jeruknipis
2	mulbery	mulbery
3	sirih	sirih
4	jeruknipis	jeruknipis
5	mulbery	sirih
6	sirih	sirih
7	jambu	jambu
8	mulbery	mulbery
9	jambu	jambu
10	jeruknipis	jeruknipis
11	jeruknipis	jeruknipis
12	mulbery	mulbery
13	mulbery	mulbery
14	sirih	sirih
15	jeruknipis	jeruknipis
16	jambu	jambu
17	sirih	sirih
18	sirih	sirih
19	jeruknipis	jeruknipis
20	jeruknipis	jeruknipis
21	mulbery	mulbery
22	jeruknipis	mulbery
23	mulbery	mulbery
24	sirih	sirih
25	jeruknipis	jeruknipis
26	sirih	sirih
27	jeruknipis	jeruknipis
28	jambu	jambu

Dari tabel 1 di atas terdapat hasil prediksi dan label sebenarnya yang mana akan di gunakan untuk menghitung akurasi naïve bayes clasifier. Dari tabel tersebut terdapat 28 data tanaman herbal yang mana terdapat 26 data yang prediksinya sesuai atau sama dengan label yang sebenarnya sedangkan terdapat 2 data kesalahan atau prediksinya tidak sesuai dengan label sebenarnya maka dapat di hitung sebagai berikut :Data uji = 28, Data benar = 26, Data salah = 2

$$akurasi\ nbc\ dan\ knn = \frac{data\ benar}{data\ uji} \times 100\% \quad (2)$$

$$akurasi\ nbc = \frac{26}{28} \times 100\% = 92,857142857142\%$$

Model Gaussian Naive Bayes dilatih dan diuji pada set pengujian. Dengan menggunakan 28 data uji hasil evaluasi menunjukkan akurasi sebesar 92.86%. Peneliti juga melakukan uji coba terhadap 42 data uji hasil evaluasi menunjukkan akurasi sebesar 95,24%. Model ini memiliki kelebihan dalam kecepatan pelatihan dan inferensi, serta kemampuan untuk menangani data dengan distribusi Gaussian. pada penelitian terdahulu dengan menggunakan 24 data uji di dapatkan 18 data terklasifikasi dan terdapat 6 data kesalahan maka di dapatkan akurasi sebesar 75%.

Tabel 2. Tabel Perbandingan NBC Dengan Penelitian Terdahulu

Penelitian	Data uji	Data Terklasifikasi	Akurasi
[10]	24	18	75%
Fingki	28	26	92,86%

b. Akurasi K-Nearest Neighbor

Tabel 1. Prediksi Dan Label Data Uji Dengan Model KNN

NO	LABEL SEBENARNYA	PREDIKSI
1	jeruknipis	jeruknipis
2	mullbery	mullbery
3	sirih	mullbery
4	jeruknipis	jeruknipis
5	mullbery	mullbery
6	sirih	sirih
7	jambu	mullbery
8	mullbery	mullbery
9	jambu	jambu
10	jeruknipis	jeruknipis
11	jeruknipis	jeruknipis
12	mullbery	mullbery
13	mullbery	mullbery
14	sirih	sirih
15	jeruknipis	mullbery
16	jambu	jambu
17	sirih	sirih
18	sirih	mullbery
19	jeruknipis	jeruknipis
20	jeruknipis	jeruknipis

NO	LABEL SEBENARNYA	PREDIKSI
21	mullbery	mullbery
22	jeruknipis	jeruknipis
23	mullbery	mullbery
24	sirih	sirih
25	jeruknipis	jeruknipis
26	sirih	sirih
27	jeruknipis	jeruknipis
28	jambu	mullbery

Dari tabel 3 terdapat hasil prediksi dan label sebenarnya yang mana akan di gunakan untuk menghitung akurasi k-nearest neighbor yang dimana hasil tersebut dengan menggunakan nilai k=3. Dari tabel tersebut terdapat 28 data tanaman herbal yang mana terdapat 23 data yang prediksinya sesuai atau sama dengan label yang sebenarnya sedangkan terdapat 5 data kesalahan atau prediksinya tidak sesuai dengan label sebenarnya maka dapat di hitung sebagai berikut: Data uji = 28, Data benar = 23, Data salah = 5

$$\text{akurasi } k - \text{nearest neighbor} = \frac{23}{28} \times 100\% = 82,142857$$

Maka hasil akurasi knn adalah 82,14%.

Model K-Nearest Neighbors dengan k=3 juga dilatih dan diuji pada set pengujian. Hasil evaluasi menunjukkan akurasi sebesar 82,14%. peneliti juga melakukan uji coba dengan mengubah nilai k=5 dan mendapatkan nilai 82,14% dan mencoba dengan k=8 hasil yang di dapatkan 78,57%. KNN memiliki kelebihan dalam menangkap kompleksitas data dengan mengandalkan kedekatan antar sampel, namun memerlukan komputasi yang lebih besar dibandingkan dengan Naive Bayes.

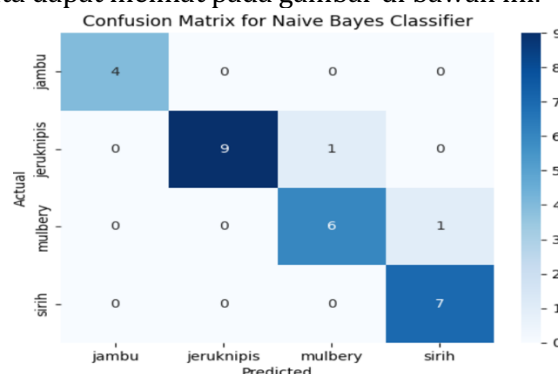
Penelitian yang di lakukan oleh [10] yang mana dengan menggunakan 24 data uji di dapatkan hasil akurasi k-nearest neighbor nya 70,83%.

Tabel 2. Tabel Perbandingan KNN Dengan Penelitian Terdahulu

Penelitian	Data uji	Data Terklasifikasi	Akurasi
Oleh [10]	24	17	70,83%
Fingki	28	23	84,12%

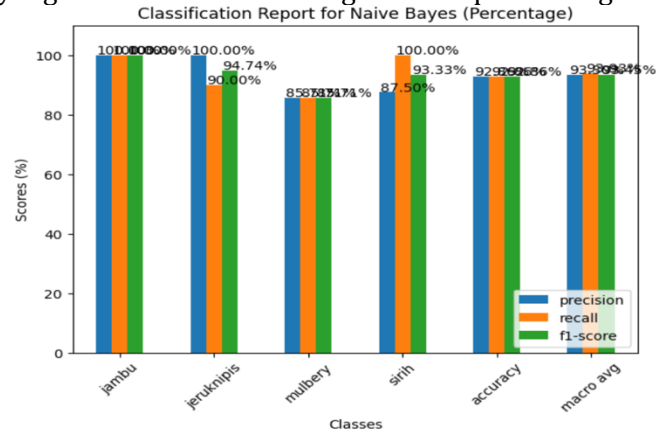
6. Perbandingan Kedua Model

Dari kedua metode berikut peneliti akan membandingkannya menggunakan confusion matrik yang mana kita dapat melihat pada gambar di bawah ini.



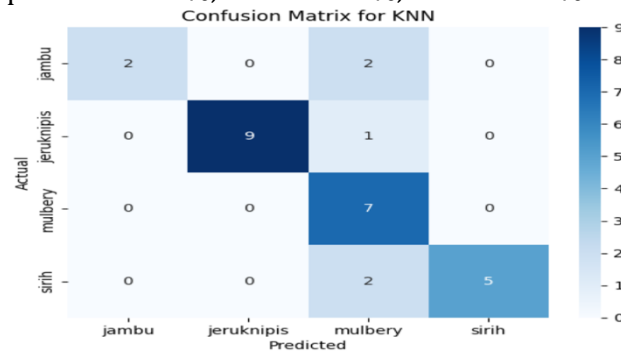
Gambar 9. Hasil Cmfusion Matrix NBC

Confusion matrix untuk NBC menunjukkan distribusi kesalahan yang lebih merata, dengan tingkat kesalahan yang lebih rendah dibandingkan KNN pada sebagian besar kelas.



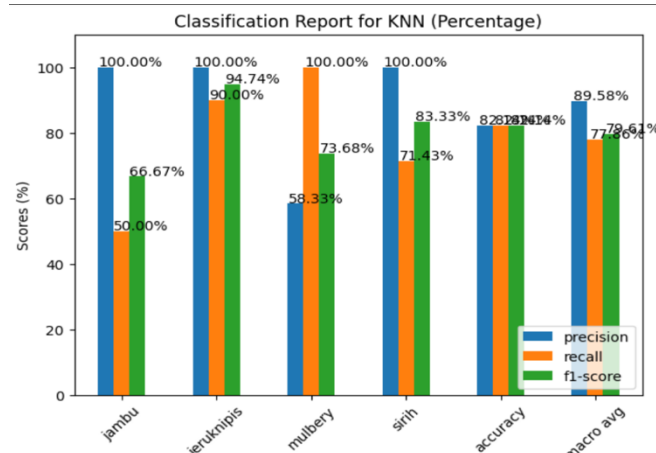
Gambar 10. Diagram Confusion Matrix NBC

Kelas jambu memiliki nilai precision = 100%, recall = 100%, F1-score =100%.
 Kelas jeruk nipis memiliki precision = 100%, recall = 90%, F1-score 94,74%.
 Kelas mulbery memiliki precision = 85%, recall = 85%, F1-score 85%.
 Kelas sirih memiliki precision = 87%, recall = 100%, F1-score 93%.



Gambar 11. Hasil Confusion Matrix KNN

Confusion matrix untuk KNN menunjukkan bahwa beberapa kelas memiliki tingkat kesalahan yang lebih tinggi, terutama kelas-kelas yang memiliki karakteristik visual yang mirip.



Gambar 12. Diagram Confusion Matrix KNN



Kelas jambu memiliki nilai precision = 100%, recall = 50%, F1-score = 66,67%.

Kelas jeruk nipis memiliki precision = 100%, recall = 90%, F1-score 94,74%.

Kelas mulberry memiliki precision = 58,33%, recall = 100%, F1-score 73,68%.

Kelas sirih memiliki precision = 100%, recall = 71,43%, F1-score 83,33%.

Dari laporan klasifikasi ini, kita bisa melihat bahwa Naïve bayes clasifier memiliki performa yang lebih baik dibandingkan dengan K-Nearest Neighbor dalam hal precision, recall, dan F1-Score untuk kedua kelas. Precision, recall, dan F1-Score yang lebih tinggi pada NBC menunjukkan bahwa model ini lebih akurat dan efektif dalam mengklasifikasikan gambar tanaman herbal dibandingkan dengan KNN. Selain itu, support menunjukkan bahwa kedua model telah dievaluasi dengan jumlah sampel yang sama untuk setiap kelas, sehingga perbandingan ini valid dan dapat diandalkan.

4. KESIMPULAN

Berdasarkan hasil eksperimen dan evaluasi, Naïve Bayes Classifier terbukti lebih efektif dan efisien dalam mengklasifikasikan gambar tanaman herbal dibandingkan dengan K-Nearest Neighbor. Naïve Bayes Classifier memberikan hasil yang lebih baik dalam hal akurasi dan konsistensi prediksi, menjadikannya metode yang lebih disarankan untuk tugas klasifikasi tanaman herbal dalam penelitian ini. Dengan demikian, metode Naïve Bayes Classifier direkomendasikan untuk digunakan dalam klasifikasi tanaman herbal berdasarkan dataset dan fitur yang digunakan dalam penelitian ini. Penelitian lebih lanjut dapat dilakukan untuk mengoptimalkan kedua metode dan mengeksplorasi teknik-teknik lain yang mungkin lebih efektif untuk tugas klasifikasi yang lebih kompleks.

DAFTAR PUSTAKA

- [1] Batubara, I., & Prastya, M. E. (2020). Potensi Tanaman Rempah Dan Obat Tradisional Indonesia Sebagai Sumber Bahan Pangan Fungsional. *Seminar Nasional Lahan Suboptimal Ke-8 Tahun 2020, October*, 24–38.
 - [2] Darnita, Y., & Toyib, R. (2021). *Klasifikasi Penentuan Manfaat Tanaman Obat Herbal Berbasis Rule Based Reasoning*. 10, 82–95.
 - [3] Fansyuri, M. (2020). Analisa Algoritma Klasifikasi K-Nearest Neighbor Dalam Menentukan Nilai Akurasi Terhadap Kepuasan Pelanggan (Study Kasus Pt. Trigatra Komunikatama). *Humanika: Jurnal Ilmu Sosial, Pendidikan, Dan Humaniora*, 3(1), 29–33.
 - [4] Kartarina, K., Sriwinarti, N. K., & Juniarti, N. Luh P. (2021). Analisis Metode K-Nearest Neighbors (K-NN) Dan Naive Bayes Dalam Memprediksi Kelulusan Mahasiswa. *JTIM : Jurnal Teknologi Informasi Dan Multimedia*, 3(2), 107–113. <https://doi.org/10.35746/jtim.V3i2.159>
 - [5] Marsuciati, R., Gumelar, G., & Prietno, R. (2021). Klasifikasi Metode Naïve Bayes Dan K-Nearest Neighbor Untuk Menentukan Keluarga Tidak Mampu. *Prosiding SISFOTEK*, 246–249. <http://Seminar.Iaii.Or.Id/Index.Php/SISFOTEK/Article/View/294%0Ahttp://Seminar.Iaii.Or.Id/Index.Php/SISFOTEK/Article/Download/294/261>
 - [6] Neighbor, P. K., Pengolahan, P., Digital, C., Local, M., Untuk, P., Tanaman, K., & Melati, P. (2020). *CITRA DIGITAL MENGGUNAKAN LOCAL BINARY PATTERN UNTUK KLASIFIKASI TANAMAN HERBAL*.
 - [7] Nurjulianty, A., & Darwis, H. (2023). *Perbandingan Metode Naïve Bayes Dan K-NN Dengan Ekstraksi Fitur GLCM Pada Klasifikasi Daun Herbal*. 7, 1740–1748. <https://doi.org/10.30865/Mib.V7i4.6262>
-

- [8] Rahman, S., Sembiring, A., Siregar, D., Khair, H., Gusti Prahmana, I., Puspadini, R., & Zen, M. (2023). Python : Dasar Dan Pemrograman Berorientasi Objek. In *Penerbit Tahta Media*.
- [9] Rinanda, P. D., Delvika, B., Nurhidayarnis, S., Abror, N., & Hidayat, A. (2022). Perbandingan Klasifikasi Antara Naive Bayes Dan K-Nearest Neighbor Terhadap Resiko Diabetes Pada Ibu Hamil. *MALCOM: Indonesian Journal Of Machine Learning And Computer Science*, 2(2), 68–75. <https://doi.org/10.57152/malcom.v2i2.432>
- [10] Liantoni, F., & Nugroho, H. (2015). Klasifikasi Daun Herbal Menggunakan Metode Naïve Bayes Classifier Dan Knearest Neighbor. *Jurnal Simantec*, 5(1), 9–16.



Prosiding- SEMASTER: Seminar Nasional Teknologi Informasi & Ilmu Komputer is licensed under a [Creative Commons Attribution International \(CC BY-SA 4.0\)](https://creativecommons.org/licenses/by-sa/4.0/)
