TEMU KEMBALI INFORMASI NUTRISI BERBASIS KLASIFIKASI CITRA BUAH MENGGUNAKAN *GAUSSIAN NAÏVE BAYES*

SKRIPSI

Oleh:
ZULFA HINDI AULIA
NIM. 200605110128

PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024

TEMU KEMBALI INFORMASI NUTRISI BERBASIS KLASIFIKASI CITRA BUAH MENGGUNAKAN *GAUSSIAN NAÏVE BAYES*

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh:
ZULFA HINDI AULIA
NIM. 200605110128

PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024

HALAMAN PERSETUJUAN

TEMU KEMBALI INFORMASI NUTRISI BERBASIS KLASIFIKASI CITRA BUAH MENGGUNAKAN *GAUSSIAN NAÏVE BAYES*

SKRIPSI

Oleh :
ZULFA HINDI AULIA
NIM. 200605110128

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 14 Juni 2024

Pembimbing I,	Pembimbing II,
Dr. Cahyo Crysdian, MCS	Roro Inda Melani, M.T, M.Sc
NIP. 19740424 200901 1 008	NIP. 19780925 200501 2 008

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang

Dr. Fachrul Kurniawan, M.MT, IPM
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

TEMU KEMBALI INFORMASI NUTRISI BERBASIS KLASIFIKASI CITRA BUAH MENGGUNAKAN *GAUSSIAN NAÏVE BAYES*

SKRIPSI

Oleh :
ZULFA HINDI AULIA
NIM. 200605110128

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 14 Juni 2024

Susunan Dewan Penguji

Ketua Penguji	: Dr. Ririen Kusumawati, S.Si, M.Kom NIP. 19720309 200501 2 002	( )
Anggota Penguji I	: Nur Fitriyah Ayu Tunjung Sari, M.CS NIP. 19911226 202012 2 001	( )
Anggota Penguji II	: Dr. Cahyo Crysdian, M.CS NIP. 19740424 200901 1 008	( )
Anggota Penguji III	: Roro Inda Melani, M.T, M.Sc NIP. 19780925 200501 2 008	( )

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang

Dr. Fachrul Kurniawan, M.MT, IPM
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama	: Zulfa Hindi Aulia
NIM	: 200605110128
Fakultas / Program Studi	: Sains dan Teknologi / Teknik Informatika
Judul Skripsi	: Temu Kembali Informasi Nutrisi Berbasis Klesifikasi Citra Buah Menggunakan *Gaussian Naive Bayes*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 20 Juni 2024
Yang membuat pernyataan,

METERAI TEMPEL
B682BAKX307659930

Zulfa Hindi Aulia
NIM.200605110128

MOTTO

Pada akhirnya, apa yang selama ini dianggap beban justru jadi yang paling menguatkan selama proses ke depan.

HALAMAN PERSEMBAHAN

Segala puji bagi Allah SWT, Tuhan semesta alam yang dengan rahmat dan hidayah-Nya, penulis dapat menyelesaikan tugas akhir skripsi dengan baik. Sholawat serta salam senantiasa tercurahkan kepada junjungn kita Nabi Muhammad SAW yang telah membawa umat manusia dari zaman jahiliyah menuju zaman yang terang benerang dengan cahaya islam. Skripsi ini penulis persembahkan kepada seluruh pihak yang telah berperan dan berjasa dalam perjalanan penelitian ini.

Pertama-tama, penulis persembahkan skripsi ini untuk diri sendiri yang telah berusaha keras dan berjuang tanpa kenal lelah hingga skripsi ini selesai. Semoga ini menjadi langkah awal untuk mencapai mimpi dan cita-cita yang lebih tinggi. Selanjutnya, kepada kedua orang tua tercinta, Bapak Pardi dan Ibu Hindoen Djaenab yang tak henti-hentinya mendoakan, memberikan dukungan, serta cinta kasih yang tiada tara. Kalian adalah inspirasi terbesar dalam hidup penulis. Penulis juga menyampaikan terima kasih yang tulus kepada adik tersayang, Muhammad Ibnu Fauzi yang senantiasa memberikan semangat dan motivasi untuk terus berusaha dan tidak mudah menyerah dalam mengejar cita-cita.

Ucapan terima kasih yang sebesar-besarnya penulis sampaikan kepada Bapak Dr. Cahyo Crysdian, M.CS, selaku dosen pembimbing I yang telah memberikan bimbingan, ilmu, dan arahan yang berharga dalam menyelesaikan setiap permasalahan selama proses penelitian dan penulisan skripsi ini. Kepada Ibu Roro Inda Melani, M.T, M.Sc, selaku dosen pembimbing II, yang dengan penuh kesabaran memberikan petunjuk, motivasi, dan koreksi yang begitu bermanfaat

dalam penulisan skripsi ini. Tak lupa, kepada seluruh dosen dan staf program studi Teknik Informatika yang selalu siap membantu dan memberikan dukungan baik secara langsung maupun tidak langsung.

Penulis juga berterima kasih kepada teman-teman seperjuangan INTEGER 2020 serta sahabat-sahabat saya Disca dan Baiq yang selalu menemani, mendukung, dan memberikan semangat dalam setiap langkah penyelesaian skripsi ini. Juga kepada teman-teman satu bimbingan yang telah memberikan saran, motivasi, dan semangat untuk segera menyelesaikan skripsi ini. Akhir kata, kepada seluruh keluarga, sahabat, dan rekan-rekan yang tidak dapat disebutkan satu per satu, penulis sampaikan terima kasih atas segala bantuan, dukungan, dan doa yang diberikan. Semoga Allah SWT membalas segala kebaikan kalian dengan pahala yang berlipat ganda dan keberkahan yang tiada henti. Aamiin.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dengan menyebut nama Allah SWT yang Maha Pengasih lagi Maha Penyayang, penulis panjatkan syukur atas segala rahmat dan hidayah-Nya. Berkat pertolongan-Nya, penulis dapat menyelesaikan skripsi yang berjudul "Temu Kembali Informasi Nutrisi Berbasis Klasifikasi Citra Buah Menggunakan *Gaussian Naive Bayes*" dengan baik dan lancar. Sholawat serta salam semoga selalu tercurah kepada junjungan kita, Nabi Muhammad SAW yang telah membawa umat manusia dari zaman jahiliyah menuju zaman yang terang benerang dengan cahaya islam.

Skripsi ini merupakan hasil penelitian yang digunakan untuk memenuhi tugas akhir perkuliahan serta syarat kelulusan Program Studi Teknik Informatika UIN Maulana Malik Ibrahim Malang. Dalam proses penyusunan dan penyelesaian skripsi ini, penulis banyak menerima bantuan dan dukungan dari berbagai pihak. Oleh karena itu, dengan penuh rasa syukur dan hormat, penulis ingin mengucapkan terima kasih kepada :

1. Prof. Dr. M. Zainuddin, M.A. selaku Rektor Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang.
2. Prof. Dr. Hj. Sri Harini, M.Si. selaku Dekan Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang.
3. Dr. Fahrul Kurniawan ST., M.MT., IPM selaku Ketua Program Studi UIN Maulana Malik Ibrahim Malang.

4. Dr. Cahyo Crysdian, M.CS. selaku dosen pembimbing I yang telah banyak membantu dan memberikan arahan dalam menyelesaikan setiap permasalah-masalahan yang ditemukan selama perjalanan penelitian dan penulisan skripsi.
5. Roro Inda Melani, M.T, M.Sc. selaku dosen pembimbing II yang dengan sabar membimbing dan memberikan arahan dalam proses penulisan integrasi islam dan penulisan skripsi.
6. Dr. Ririen Kusumawati, S.Si, M.Kom. selaku dosen penguji I dan Nur Fitriyah Ayu Tunjung Sari, M.CS. selaku dosen penguji II yang telah memberikan ilmu, kritikan dan saran untuk penulis agar penulis dapat menyelesaikan skripsi dengan baik.
7. Seluruh Dosen dan jajaran staff program studi Teknik Informatika yang senantiasa membantu baik secara langsung maupun tidak langsung dalam proses penyelesaian skripsi penulis.
8. Bapak Pardi dan Ibu Hindoen Djaenab selaku kedua orang tua penulis, tempat pulang ternyaman dari segala lelah. Dua manusia terbaik yang Tuhan berikan untuk merawat, menemani, melindungi, mendukung, dan memberikan doa-doa terbaik di hidup penulis.
9. Muhammad Ibnu Fauzi selaku adik penulis. Manusia menyebalkan sekaligus menyenangkan yang tidak pernah lelah menghibur dan memberikan motivasi penulis. Saudara serta sahabat terbaik yang penulis miliki
10. Seluruh teman seperjuangan INTEGER 2020, terutama Anisa, Vio, Qorina, Zahro, Najma, Muchiss, dan Ijul yang selalu setia menemani setiap langkah penulis dari awal hingga perkuliahan hingga saat ini. Terima kasih orang-orang

yang tidak pernah mengenalkan penulis tentang arti kata kesepian selama tinggal di tanah perantauan yang konon katanya begitu keras.

11. Sahabat senasib dan sepenanggungan, Disca dan Baiq, yang selalu memberi dukungan dan motivasi serta menjadi tempat mengeluh selama penulis menempuh pendidikan.
12. Seluruh keluarga, teman, dan sahabat yang tidak dapat disebutkan satu per satu, yang turut dalam memberikan bantuan, dukungan serta doa terbaik untuk penulis.
13. Diri sendiri, yang telah berjuang tanpa kenal lelah, berusaha tetap konsisten, dan bertekad kuat menyelesaikan skripsi ini hingga akhir. Terima kasih karena selalu berusaha menjadi manusia terbaik bagi diri sendiri. Menjadi manusia yang percaya bahwa bukan hidup yang berat tapi diri sendiri yang ditakdirkan untuk jadi wanita hebat.

DAFTAR ISI

HALAMAN PERSETUJUAN ..... **iii**
HALAMAN PENGESAHAN ..... **iv**
PERNYATAAN KEASLIAN TULISAN ..... **v**
MOTTO ..... **vi**
HALAMAN PERSEMBAHAN ..... **vii**
KATA PENGANTAR ..... **ix**
DAFTAR GAMBAR ..... **xiii**
DAFTAR TABEL ..... **xiv**
ABSTRAK ..... **xv**
ABSTRACT ..... **xvi**
مستخلص البحث ..... **xvii**
BAB I **1**
1.1 Latar Belakang Penelitian 1
1.2 Pernyataan Masalah 4
1.3 Tujuan Penelitian 4
1.4 Batasan Penelitian 5
1.5 Manfaat Penelitian 5
BAB II TINJAUAN PUSTAKA **6**
2.1 Klasifikasi Buah 6
2.2 *Gaussian Naive Bayes* 8
BAB III METODOLOGI PENELITIAN **11**
3.1 Pengumpulan Data 11
3.2 Desain Sistem 15
3.2.1 *Grayscale* 16
3.2.2 *Thresholding* 17
3.2.3 *Contours* 18
3.2.4 *Histogram* Warna 20
3.2.5 *Local Binary Patterns* 21
3.2.6 Fitur Bentuk 22
3.2.7 *Gaussian Naive* Bayes 25
BAB IV UJI COBA DAN PEMBAHASAN **30**
4.1 Skenario Pengujian 30
4.2 Hasil Uji Coba Menggunakan Split Data 33
4.3 Hasil Uji Coba Menggunakan K-fold 40
4.4 Hasil Uji Coba Data Baru 41
4.5 Hasil Uji Coba Fitur 44
4.6 Pembahasan 48
BAB V KESIMPULAN DAN SARAN **57**
5.1 Kesimpulan 57
5.2 Saran 58
DAFTAR PUSTAKA
LAMPIRAN

DAFTAR GAMBAR

Gambar 3.1 Data Citra Baru 14
Gambar 3.2 Sampel Informasi Nutrisi 15
Gambar 3.3 Desain Sistem 15
Gambar 3.4 Citra Setelah dan Sebelum *Grayscale* 16
Gambar 3.5 Citra Setelah dan Sebelum *Thresholded* 18
Gambar 3.6 Citra setelah dan sebelum *contours* 19
Gambar 3.7 Alur Ekstraksi Fitur Bentuk 22
Gambar 3.8 *Flowchart* Alur *Gaussian Naive Bayes* 28
Gambar 4.1 *Confusion Matrix Split* Data Rasio 70:30 34
Gambar 4.2 *Confusion Matrix Split* Data Rasio 80:20 36
Gambar 4.3 *Confusion Matrix Split* Data Rasio 90:10 38
Gambar 4.4 Confusion Matrix Uji Coba Menggunakan Data Baru 42
Gambar 4.5 *Confusion Matrix* Uji Coba Hanya dengan Fitur Histogram Warna. 44
Gambar 4.6 *Confusion Matrix* Uji Coba Hanya dengan Fitur LBP 45
Gambar 4.7 *Confusion Matrix* Uji Coba Hanya dengan Fitur Bentuk 45
Gambar 4.8 *Confusion Matrix* Uji Coba Hanya dengan Fitur Histogram Warna dan LBP 46
Gambar 4.9 *Confusion Matrix* Uji Coba Menggunakan Seluruh Fitur 46

DAFTAR TABEL

Tabel 3.1 Citra yang Digunakan dalam Setiap Kelas 11
Tabel 4.1 Hasil Evaluasi Menggunakan *Split* Data 70:30..... 34
Tabel 4.2 Hasil Evaluasi Menggunakan *Split* Data 80:20..... 36
Tabel 4.3 Hasil Evaluasi Menggunakan *Split* Data 90:10..... 38
Tabel 4.4 Ringkasan Hasil Evaluasi 3 Skenario Pengujian 39
Tabel 4.5 Hasil Uji Coba K-Fold 41
Tabel 4.6 Hasil Evaluasi Menggunakan Data Baru 42
Tabel 4.7 Hasil Evaluasi Uji Coba Fitur 47
Tabel 4.8 Ringkasan Hasil Uji Coba..... 48

ABSTRAK

Aulia, Zulfa Hindi. 2024. **Temu Kembali Informasi Nutrisi Berbasis Klasifikasi Citra Buah Menggunakan *Gaussian Naive Bayes***. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Cahyo Crysdian, M.T. (II) Roro Inda Melani, M.T, M.Sc

Kata kunci: *Computer Vision, Gaussian Naive Bayes, Fruit Classification*

Buah-buahan merupakan kelompok pangan yang digolongkan sebagai pola pangan harapan, yaitu konsep pola makan yang diharapkan dapat memenuhi kebutuhan gizi seimbang dan kesehatan manusia secara berkelanjutan. Setiap individu seharusnya melakukan monitoring asupan gizi mereka. Namun sayangnya masih banyak individu yang kesulitan dalam memantau dan mengontrol asupan gizi harian. Oleh karena itu, dikembangkan sebuah sistem menggunakan kecerdasan buatan untuk analisis citra buah dalam pemantauan asupan nutrisi dengan memanfaatkan metode klasifikasi *Gaussian Naive Bayes* (GNB). Penelitian ini memanfaatkan dataset yang tersedia di Kaggle yaitu dataset "Fruit Classification". *Pre-processing* yang dilakukan pada penelitian ini berupa *grayscale*, *thresholding*, dan *contours*. Sedangkan ekstraksi fitur yang diambil berupa histogram warna, *Local Binary Patterns* (LBP), dan bentuk. Pengujian dilakukan dengan beberapa skenario yaitu *split data*, *k-fold*, data baru, dan variasi fitur. Berdasarkan hasil pengujian yang dilakukan, dapat disimpulkan bahwa sistem yang dirancang menunjukkan hasil evaluasi dengan nilai akurasi rata-rata di atas 80% pada pengujian menggunakan metode *split data* dan *k-fold cross-validation*. Namun, terdapat penurunan hingga 54% pada hasil uji coba menggunakan data baru. sedangkan uji coba menggunakan variasi fitur menunjukkan bahwa fitur histogram warna memberikan kontribusi yang paling signifikan dalam meningkatkan akurasi sistem, dengan akurasi mencapai 90%. Hal ini menunjukkan bahwa model mungkin mengalami masalah *overfitting* atau kurang generalisasi pada data yang belum pernah dilihat sebelumnya.

ABSTRACT

Aulia, Zulfa Hindi. 2024. **Nutritional Information Retrieval Based on Fruit Image Classification Using *Gaussian Naive Bayes***. Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University Malang. Advisor: (I) Dr. Cahyo Crysdian, M.T. (II) Roro Inda Melani, M.T, M.Sc.

Fruits are a food group classified as a food pattern of hope, a dietary concept expected to meet the needs of balanced nutrition and human health sustainably. Every individual should monitor their nutritional intake. Unfortunately, there are still many individuals who need help in monitoring and controlling daily dietary intake. Therefore, a system was developed using artificial intelligence for fruit image analysis to monitor nutritional intake using the Gaussian Naive Bayes (GNB) classification method. This research utilises the Kaggle dataset, the "Fruit Classification" dataset. They are pre-processing carried out in this study in the form of grayscale, thresholding, and contours. Meanwhile, feature extraction is taken in the form of colour histograms, local binary patterns (LBP), and shapes. Testing involves several scenarios: split data, k-fold, new data, and feature variations. Based on the test results, the designed system shows evaluation results with an average accuracy above 80% in tests using split data and k-fold cross-validation methods. However, there is a decrease of up to 54% in the test results using new data. In contrast, the test using feature variations shows that the colour histogram feature makes the most significant contribution in improving the system's accuracy, with accuracy reaching 90%. This suggests that the model may experience overfitting or undergeneralisation issues on data that has never been seen before.

Keywords: *Computer Vision, Gaussian Naive Bayes, Fruit Classification*

مستخلص البحث

أوليا، زلفى هندي. 2024. استرجاع المعلومات الغذائية استنادًا إلى تصنيف صور الفاكهة باستخدام نظام غوسي ساذج باي. الأطروحة. برنامج دراسة هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المستشار: (الأول) د. كاهيو كريسديان، ماجستير في العلوم والتكنولوجيا (الثاني) رورو إندا ميلاني، ماجستير في العلوم والتكنولوجيا.

الكلمات المفتاحية : رؤية الكمبيوتر، غاوسي بايز الساذج، تصنيف الفاكهة

الفاكهة هي مجموعة غذائية تصنف على أنها نمط غذائي للأمل، وهو مفهوم غذائي من المتوقع أن يلبي احتياجات التغذية المتوازنة وصحة الإنسان بطريقة مستدامة. يجب على كل فرد مراقبة مدخوله الغذائي. ولسوء الحظ، لا يزال هناك العديد من الأفراد الذين يحتاجون إلى المساعدة في مراقبة المدخول الغذائي اليومي والتحكم فيه. ولذلك، تم تطوير نظام باستخدام الذكاء الاصطناعي لتحليل صور الفاكهة لمراقبة المدخول الغذائي باستخدام طريقة تصنيف غاوسي ساذج (GNB). يستخدم هذا البحث مجموعة بيانات Kaggle، وهي مجموعة بيانات "تصنيف الفاكهة". يتم إجراء المعالجة المسبقة في هذه الدراسة على شكل تدرج الرمادي، والعتبة، والخطوط. وفي الوقت نفسه، يتم استخراج السمات في شكل رسوم بيانية ملونة، وأنماط ثنائية محلية (LBP)، وأشكال. يتضمن الاختبار عدة سيناريوهات: البيانات المقسّمة، والبيانات المضاعفة k، والبيانات الجديدة، وتنويعات السمات. استنادًا إلى نتائج الاختبار، يُظهر النظام المصمم نتائج تقييم بمتوسط دقة أعلى من 80% في الاختبارات باستخدام طرق التحقق المتقاطع للبيانات المقسمة و k-fold. ومع ذلك، هناك انخفاض يصل إلى 54% في نتائج الاختبار باستخدام البيانات الجديدة. في المقابل، يُظهر الاختبار باستخدام تنويعات الميزات أن ميزة المدرج التكراري اللوني تُسهم بشكل كبير في تحسين دقة النظام، حيث تصل الدقة إلى 90%. يشير هذا إلى أن النموذج قد يواجه مشكلات في التعميم المفرط أو التعميم الناقص على البيانات التي لم يسبق رؤيتها من قبل.

BAB I

PENDAHULUAN

1.1 Latar Belakang Penelitian

Allah *Subhanahu wa ta'ala* (SWT) adalah dzat yang maha pengasih lagi maha penyayang. Sebagai bukti kasih sayang-Nya yang tiada tara, Allah SWT telah melimpahkan berbagai macam nikmat kepada makhluk. Nikmat yang telah Allah SWT berikan tidak dapat dihitung jumlahnya. Bahkan hidup, bernafas, dan dapat beraktifitas juga merupakan nikmat yang Allah SWT berikan. Karena begitu banyaknya nikmat tersebut, tak ada seorangpun yang mampu menghitung berapa jumlah nikmat yang diterimanya (Khulaimah, 2018). Istilah "nikmat" sendiri dalam kitab suci Al-Qur'an dapat diartikan sebagai anugerah, rahmat, atau karunia yang telah Allah SWT berikan. Nikmat-nikmat ini dapat bersifat materil maupun spiritual, baik yang diterima di dunia maupun yang akan diterima di akhirat (Mifaro & Syahputra, 2023). Salah satu surah yang membahas tentang kebesaran Allah SWT yaitu Q.S. An-Nahl. Dalam Q.S. An-Nahl [16]: 11 dikatakan salah satu bukti kebesaran dan kasih sayang Allah SWT. Ayat tersebut berbunyi :

يُنْۢبِتُ لَكُمْ بِهِ الزَّرْعَ وَالزَّيْتُوْنَ وَالنَّخِيْلَ وَالْاَعْنَابَ وَمِنْ كُلِّ الثَّمَرٰتِۗ اِنَّ فِيْ ذٰلِكَ لَاٰيَةً لِّقَوْمٍ يَّتَفَكَّرُوْنَ

“Dengan (air hujan) itu Dia menumbuhkan untukmu tumbuh-tumbuhan, zaitun, kurma, anggur, dan segala macam buah-buahan. Sesungguhnya pada yang demikian itu benar-benar terdapat tanda (kebesaran Allah SWT) bagi orang yang berpikir." *(Q.S. An-Nahl:11)*

Ayat tersebut Allah SWT diturunkan untuk menunjukkan kepada umatnya bahwa dengan air hujan, Allah SWT telah menumbuhkan berbagai macam tanaman. Mulai dari paling cepat layu, paling panjang usianya, sampai paling

banyak manfaatnya. Sepertihalnya zaitun, kurma, dan juga anggur. Zaitun merupakan salah satu pohon dengan usia yang cukup panjang. Sedangkan pohon kurma mmeiliki buah yang dapat dimakan mentah atau matang, mudah dipetik, dan sangat bergizi lagi berkalori tinggi. Buah anggur dapat diolah menjadi makanan yang halal atau minuman yang haram dari sekian macam buah-buahan. Selain yang telah disebutkan, seharusnya sudah dapat kita pahami tentang kebesaran Allah SWT. Sesungguhnya Allah SWT adalah Maha Esa lagi Maha Kuasa (Shihab, 2002).

Berdasarkan tafsir tersebut, dapat dikatakan bahwa salah satu nikmat yang Allah SWT berikan adalah diciptakannya buah-buahan. Menurut Kamus Besar Bahasa Indonesia (KBBI) 2016, buah sendiri merupakan bagian tumbuhan yang pada dasarnya memiliki biji dan berasal dari bunga atau putik. Namun secara botani, buah merupakan bagian dari tanaman yang memiliki kulit dengan struktur lebar dan rapat sehingga dapat membungkus biji dimana struktur tersebut merupakan bagian dari bunga atau putik tumbuhan itu sendiri (Dewi, 2014). Menurut P2PTM kemenkes RI, buah-buahan merupakan sumber nutrisi berbagai vitamin, mineral, dan serat pangan yang tentunya sangat bermanfaat bagi tubuh. Buah-buahan juga merupakan kelompok pangan yang digolongkan sebagai pola pangan harapan, yaitu konsep pola makan yang diharapkan dapat memenuhi kebutuhan gizi seimbang dan kesehatan manusia secara berkelanjutan (Aswatini, 2008).

Salah satu cara agar tercipta pemenuhan gizi seimbang dan kesehatan berkelanjutan, yaitu dengan memperhatikan nilai-nilai nutrisi dari makanan yang dikonsumsi sehari-hari. Nutrisi merupakan proses pengolahan dan penerimaan

makanan atau bahan-bahan penting dari luar tubuh yang dapat dimanfaatkan oleh tubuh. Kata nutrisi sendiri berasal dari kata "*nutrition*" atau dalam bahasa indonesia biasa disebut dengan "gizi". Gizi memiliki makna sebagai makanan yang menyehatkan. Nutrisi memiliki banyak sekali manfaat bagi tubuh, antara lain yaitu mengatur kondisi fisik, meningkatkan imunitas tubuh, membantu memulihkan kondisi fisik, mencegah penuaan dini, serta mencegah penyakit yang timbul akibat salah memilih makanan. Pada dasarnya konsep nutrisi dalam pangan telah berubah. Awalnya nutrisi adalah solusi untuk mengatasi rasa lapar atau pencegahan dari pengaruh buruk yang dapat merugikan tubuh menjadi dasar untuk pola hidup sehat atau sebagai pencegahan timbulnya suatu penyakit (Saidi *et al*., 2022).

Konsep dasar gizi seimbang menekankan bahwa untuk hidup dan meningkatkan kualitas hidup, setiap orang membutuhkan lima kelompok zat gizi yaitu: karbohidrat, protein, lemak, vitamin dan mineral, dalam jumlah yang cukup, tidak berlebihan dan juga tidak kekurangan. Salah satu masalah umum dari perilaku konsumsi remaja adalah kurangnya konsumsi buah. Menurut rekomendasi Pedoman Gizi Seimbang, masyarakat Indonesia dianjurkan untuk mengkonsumsi buah 2-3 porsi buah atau setara dengan 150 gram per hari. Kurangnya konsumsi buah dapat menimbulkan resiko terjadinya gangguan kesehatan dimasa yang akan datang. Berbagai penelitian mengenai konsumsi buah dan sayur dapat berisiko dalam pekembangan penyakit degeneratif seperti obesitas, diabetes hipertensi dan kanker (Aswatini, 2008).

Setiap individu seharusnya melakukan monitoring asupan gizi mereka. Namun sayangnya masih banyak individu yang kesulitan dalam memantau dan

mengontrol asupan gizi harian. Salah satu kendala tersebut adalah terbatasnya akses terhadap informasi nutrisi yang dibutuhkan. Oleh karena itu, dikembangkan sebuah sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah. Metode klasifikasi yang digunakan harus memungkinkan klasifikasi dengan akurasi yang tinggi. Algoritma *Gaussian Naive Bayes* (GNB) dipilih karena dapat dapat menggunakan tipe data kontinu. Sistem ini diharapkan dapat menjadi solusi yang efektif dan efisien dengan melakukan analisis nutrisi buah berdasarkan citra.

1.2 Pernyataan Masalah

Masalah utama yang akan diteliti pada penelitian ini telah dinyatakan secara jelas di pernyataan masalah, yang meliputi :

a. Sebarapa akurat kinerja Algoritma *Gaussian Naive Bayes* pada sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah?

b. Seberapa signifikan pengaruh ekstraksi fitur histogram warna, *Local Binary Patterns*, dan bentuk dalam meningkatkan akurasi sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah menggunakan *Gaussian Naive Bayes*?

1.3 Tujuan Penelitian

Tujuan penelitian dirancang untuk memberikan arah dan fokus yang jelas dari tujuan yang ingin dicapai. Tujuan tersebut di antaranya :

a. Mengevaluasi kinerja Algoritma *Gaussian Naive Bayes* pada sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah.

b. Menganalisis pengaruh ekstraksi fitur histogram warna, *Local Binary Patterns*, dan bentuk pada sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah menggunakan *Gaussian Naive Bayes*.

1.4 Batasan Penelitian

Untuk menghindari pembahasan yang keluar dari konteks, maka dirumuskanlah batasan penelitian sebagai berikut :

a. Dataset yang digunakan untuk penelitian ini terbatas pada citra buah segar dengan 33 kelas yang didapatkan di *Kaggle* dengan nama "*Fruit Classification*" dan citra buah segar yang dikumpulkan penulis dengan cara *web scraping Google Images*.

b. Menggunakan dasar informasi nutrisi dari website resmi departemen pertanian Amerika Serikat yaitu *National Agricultural Library*.

c. Ekstraksi fitur yang digunakan terbatas pada fitur histogram warna, *Local Binary Patterns*, dan bentuk.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan beberapa manfaat kepada :

a. Untuk pelaku diet, membantu dalam memantau dan mengelola asupan gizi harian dengan lebih akurat. Sehingga dapat dipastikan bahwa kebutuhan nutrisi terpenuhi tanpa kelebihan atau kekurangan.

b. Untuk ahli gizi, membantu dalam memahami kandungan nutrisi buah-buahan dengan lebih baik. Sehingga ahli gizi dapat memberikan rekomendasi yang lebih tepat sasaran kepada klien mereka.

BAB II

TINJAUAN PUSTAKA

2.1 Klasifikasi Buah

Klasifikasi berasal dari kata latin "*classis*" yang kerarti tingkat. Sedangkan secara bahasa, klasifikasi dapat diartikan sebagai proses pengelompokan, yang artinya mengumpulkan benda/entitas yang sama serta memisahkan benda/entitas yang tidak sama. Secara umum dapat dikatakan bahwa batasan klasifikasi adalah usaha menata alam pengetahuan ke dalam tata urutan sistematis (Subrata, 2009). Menurut Kamus Besar Bahasa Indonesia (KBBI) 2016, buah sendiri merupakan bagian tumbuhan yang pada dasarnya memiliki biji dan berasal dari bunga atau putik. Namun secara botani, buah merupakan bagian dari tanaman yang memiliki kulit dengan struktur lebar dan rapat sehingga dapat membungkus biji dimana struktur tersebut merupakan bagian dari bunga atau putik tumbuhan itu sendiri (Dewi, 2014). Jadi klasifikasi buah dapat dikatakan sebagai pengelompokan buah ke dalam suatu kelas yang memiliki kesamaan dalam fitur-fitur tertentu. Fitur-fitur tersebut dapat mencakup kesamaan warna, bentuk, rasa, ukuran, tekstur, atau fitur lainnya.

Wijaya & Ridwan (2019) pernah melakukan penelitian tentang klasifikasi jenis buah apel dengan kenggunakan metode *K-Nearest Neighbors* (KNN). Penelitian ini menggunakan data 160 citra buah apel, dengan citra uji sebanyak 40 citra dan citra latih sebanyak 120 citra. Beberapa jenis apel yang digunakan yaitu Apel Fuji *Sun Sheet*, Apel *Green Smith*, Apel *Pasific Rose*, Apel *Red Del USA*, dan Apel *RG France*. Pada ekstraksi fitur, dilakukan ekstraksi fitur warna dan bentuk

menggunakan *Hue Saturation Value* (HSV) dan *Local Binary Patern* (LBP). Berdasarkan fitur-fitur yang didapat maka dilakukanlah proses klasifikasi menggunakan KNN. *Pre-processing* yang dilakukan pada penelitian ini berupa perubahan ulang ukuran pada citra dan memisahkan *background* dengan objek apel menggunakan aplikasi *photoshop*. Selain itu dilakukan konversi citra RGB ke citra HSV, citra RGB ke citra *Grayscale* baru ke citra LBP.Hasil penelitian menunjukkan bahwa sistem yang dikembangkan memiliki *precision* sebesar 94%, *recall* sebesar 100% dan *accuracy* sebesar 94%.

Penelitian lain juga pernah dilakukan oleh Yohannes *et al*., (2020). Penelitian tersebut tentang klasifikasi jenis buah dan sayuran menggunakan metode klasifikasi *Support Vector Machine* (SVM) menggunakan fitur bentuk berbasis *saliency* (*Saliency-HOG*) dan fitur warna (*Color Moments*). Data yang digunakan pada penelitian ini terdiri dari 11.400 citra dengan 114 kelas yang berasal dari dataset *Fruit 360*. Ekstraksi fitur yang dilakukan adalah ekstraksi fitur bentuk menggunakan metode *saliency-HOG* dan ekstraksi fitur warna menggunakan metode *color moments*. Kemudian dari kedua ekstraksi fitur tersebut digabungkan sehingga menciptakan satu fitur gabungan. Metode klasifikasi yang digunakan adalah SVM dengan menggunakan 70% data trainning dan 30% data testing. Performa klasifikasi yang dihasilkan pada penelitian ini adalah *precision, recall*, dan *accuracy* terbaik masing-masing sebesar 98,57%, 98,55%, dan 99,120%.

Pada tahun 2022 Paraijun *et al.*, juga pernah melakukan penelitian tentang klasifikasi kesegaran buah berdasarkan gambar menggunakan algoritma *Convolutional Neural Network* (CNN) dengan harapan dapat membantu distributor

buah untuk memeriksa kesegaran buah dalam jumlah besar. Data yang digunakan dalam penelitian ini berupa citra buah sebanyak 13.599. Lalu data tersebut dibagi menjadi 3 bagian, yaitu data latih 80%, data validasi 10%, dan data uji 10%. Proses CNN dilakukan melalui beberapa tahapan, diawali dengan akusisi citra, lalu mengambil nilai RGB pada citra, sehingga dapat dilakukan *feature learning* menggunakan *layer convolutional, Rectified Linear Unit (ReLU),* dan *pooling*. Dari nilai fitur-fitur tersebut, dilakukan klasifikasi menggunakan CNN dengan beberapa layer, yaitu *flatten, fully connected layer, backpropagation neural network,* dan *softmax*. Hasil pengujian menunjukkan bahwa akurasi, *precision*, dan *recall* sistem yang dibangun berturut-turut sebesar 93,3%, 93,5%, dan 93,31%. Sedangkan untuk *f1-score* mendapatkan nilai sebesar 93,34%.

2.2 *Gaussian Naive Bayes*

Gaussian Naïve Bayes (GNB) merupakan algoritma klasifikasi yang menggunakan teori *Bayes* dengan cara kerja klasifikasi pada label kelas yang sebelumnya telah ditentukan berdasarkan aturan yang telah ditetapkan dari variabel prediktor yang bersifat independen (Griffis *et al*., 2016). Pada GNB, klasifikasi data yang bersifat continuous terdapat proses training dengan melakukan segmentasi berdasarkan kelas, jenis, dan rata-rata pada masing-masing label. GNB cocok untuk menganalisis data numerik dan mendefinisikan bahwa fitur-fiturnya terbagi dengan baik. Pada umumnya GNB digunakan pada sistem klasifikasi gambar, analisis sentimen, dan serta prediksi. (Gayathri & Sumathi, 2016).

Saputra (2019) pernah melakukan penelitian tentang klasifikasi pengenalan buah menggunakan algoritma *naive baiyes*. Penelitian ini menggunakan data

berupa 150 gambar varietas apel dengan saluran warna warna RGB yang diambil menggunakan kamera ponsel. Gambar tersebut memiliki resolusi sebesar 2048x1024 piksel dengan latar belakang putih. Varietas apel yang digunakan yaitu *pink lady*, *honey crisp*, dan *golden delicious*. Lalu dari data tersebut dilakukan segmentasi dan prapemrosesan yang bertujuan untuk mendapatkan citra biner dengan metode *Otsu*. Metode *Otsu* didasarkan pada pemilihan titik terendah antara dua kelas histogram mempertimbangkan varian antar kelas. Pra-pemrosesan yang dilakukan yaitu menghilangkan *noise* latar belakang frekuensi rendah, menormalkan intensitas gambar partikel individu, menghapus refleksi, dan menutupi bagian gambar. Evaluasi kinerja dilakukan dengan matriks keputusan dengan mengambil nilai untuk sensitivitas, spesifisitas, akurasi dan presisi. Hasil yang terkait dengan tiga varietas apel menunjukkan bahwa nilai rata-rata estimasi akurasi, sensitivitas, presisi dan spesifisitas masing-masing adalah 81%, 73%, 100% dan 70%.

Kamel *et al*., (2019) pernah melakukan penelitian tentang deteksi dini kanker. Deteksi tersebut dinilai sangat penting kerena diagnosis yang dilakukan secara manual kurang akurat dan tepat waktu. Oleh karena itu, penelitian tentang klasifikasi kanker menggunakan algoritma GNB diperlukan, guna membantu dokter dalam mendiagnosis kanker dengan lebih akurat dan efisien. *Preprocessing* data pada sistem yang diteliti ini menggunakan normalisasi *z-score* untuk mengidentifikasi nilai nol yaitu nilai yang tidak mempengaruhi proses klasifikasi. Pelatihan pada pembangunan sistem ini dilakukan dengan pembagian data berdasarkan kelas serta perhitungan rata-rata dan standar deviasi dari setiap atribut

kelas yang ada sehingga probabilitas atribut yang diberikan kelas tertentu dapat diestimasi. Estimasi tersebut dilakukan agar algoritma GNB dapat mengklasifikasikan input baru dengan memilih kelas berdasarkan probabilitas tertinggi. Algoritma GNB pada penelitian ini diuji dengan menggunakan dua dataset, yaitu *Wisconsin Breast Cancer Dataset* (WBCD) dan *lung cancer dataset*. Berdasarkan evaluasi yang bangun, sistem ini memiliki akurasi sebesar 98% untuk dataset WBCD dan 90% untuk *lung cancer dataset*.

Backar *et al*., (2023) pernah melakukan penelitian tentang klasifikasi dua jenis daun herbal, yaitu daun kelor dan daun katuk. Penelitian tersebut, menggunakan *Fourier Descriptor* (FD) untuk mengekstraksi fitur bentuk dan tekstur. Klasifikasi dilakukan dengan menggunakan 3 jenis *Naïve Bayes* (*Gaussian, Bernoulli, dan Multinomial)* dan *Convolutional Neural Network* (CNN). Pengujian sistem yang diteliti ini menggunakan dua skenario, yaitu skenario gelap dan terang dengan hasil bahwa skenario gelap disarankan untuk menggunakan metode GNB sedangkan untuk skenario terang disarankan menggunakan metode CNN. Data citra daun yang digunakan pada penelitian ini didapatkan dengan pengumpulan citra melalui observasi langsung di hutan. Tahap *preprocessing* yang dilakukan yaitu *labeling, cropping,* dan *resizing*. Sedangkan ekstraksi fitur dilakukan dengan menggunakan metode FD. Hasil akhir dari penelitian ini menunjukkan bahwa metode CNN dengan ekstraksi FD mencapai akurasi, presisi, *recall,* dan *f1-score* tertinggi sebesar 100% pada GNB dengan skenario gelap.

BAB III

METODOLOGI PENELITIAN

3.1 Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan dengan memanfaatkan dataset yang tersedia di *Kaggle* yaitu dataset dengan nama "*Fruit Classification*". Dataset ini berisi 16,854 citra. *Fruit Classification* memiliki 33 kelas yang masih-masing kelas berisi satu jenis buah atau sayuran. Setiap citra memiliki ukuran 100x100 piksel dan sebagian besar citra telah dirotasi untuk membantu memudahkan proses pelatihan. Dengan memanfaatkan dataset yang telah terstruktur ini, tahap analisis lebih lanjut dapat dilakukan dengan mudah karena data ini dapat menjadi kunci utama untuk membangun dan melatih model yang akurat. Pada Tabel 3.1 telah ditampilkan beberapa jenis buah yang digunakan pada penelitian ini.

Tabel 3.1 Citra yang Digunakan dalam Setiap Kelas

No	**Kelas**	**Citra**	**Nama Latin**	**Jumlah Citra**
1	Apple Braeburn	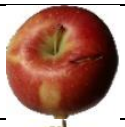	*Malus domestica*	492
2	Apple Granny Smith		*Malus domestica*	492
3	Apricot		*Prunus armeniaca*	492
4	Avocado		*Persea americana*	427
5	Banana		*Musa acuminata*	490

No	Kelas	Citra	Nama Latin	Jumlah Citra
6	Blueberry		*Vaccinium corymbosum*	462
7	Cactus fruit		*Opuntia ficus-indica*	490
8	Cantaloupe		*Cucumis melo*	492
9	Cherry		*Prunus avium*	492
10	Clementine		*Citrus × clementina*	490
11	Corn		*Zea mays*	450
12	Cucumber Ripe		*Cucumis sativus*	392
13	Grape Blue		*Vitis vinifera*	984
14	Kiwi		*Actinidia deliciosa*	466
15	Lemon		*Citrus limon*	492
16	Limes		*Citrus aurantiifolia*	490
17	Mango		*Mangifera indica*	490
18	Onion White		*Allium cepa*	438
19	Orange		*Citrus × sinensis*	479

No	Kelas	Citra	Nama Latin	Jumlah Citra
20	Papaya		*Carica papaya*	492
21	Passion Fruit		*Passiflora edulis*	490
22	Peach		*Prunus persica*	492
23	Pear		*Pyrus communis*	696
24	Pepper Green		*Capsicum annuum*	444
25	Pepper Red		*Capsicum annuum*	666
26	Pineapple		*Ananas comosus*	490
27	Plum		*Prunus domestica*	447
28	Pomegranate		*Punica granatum*	492
29	Potato Red		*Solanum tuberosum*	450
30	Raspberry	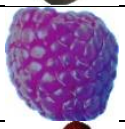	*Rubus idaeus*	490
31	Strawberry		*Fragaria × ananassa*	492
32	Tomato		*Solanum lycopersicum*	738
33	Watermelon		*Citrullus lanatus*	475
	Total Citra			**16.854**

Dataset citra buah selanjutnya dikumpulkan dengan cara *web scraping* pada *Google Images*. Data tersebut juga memiliki 33 kelas yang sama dengan dataset yang didapatkan di *kaggle*. Namun masing-masing kelas pada data ini berisi 50 citra buah dengan kondisi yang bervariasi. Sehingga untuk total citra buah pada dataset ini sejumlah 1650 citra. Gambar 3.1 merupakan beberapa kelas pada dataset cita buah yang kedua.

Gambar 3.1 Data Citra Baru

Selain data citra buah, penelitian ini juga menggunakan dataset berupa informasi nutrisi. Pengumpulan data nutrisi makanan dilakukan dengan memanfaatkan sumber data yang dikelola oleh *Agricultural Research Service's Beltsville Human Nutrition Research Center* dan dihosting oleh *National Agricultural Library*. Terdapat 5 jenis data yang dikelola oleh mereka, namun penelitian ini memanfaatkan jenis data *National Nutrient Database for Standard Reference Legacy Release (SR Legacy).* Jenis data tersebut merupakan jenis data yang menyajikan informasi terkait komponen makanan termasuk nutrisi yang

berasal dari analisis, serta data mentah untuk berbagai jenis makanan dan bahan makanan tunggal. Dengan menggunakan data ini, maka penelitian dapat menghasilkan informasi akurat tentang komposisi nutrisi dari berbagai jenis makanan. Pada Gambar 3.2 ditampilkan salah satu informasi nutrisi yang digunakan dalam penelitian ini.

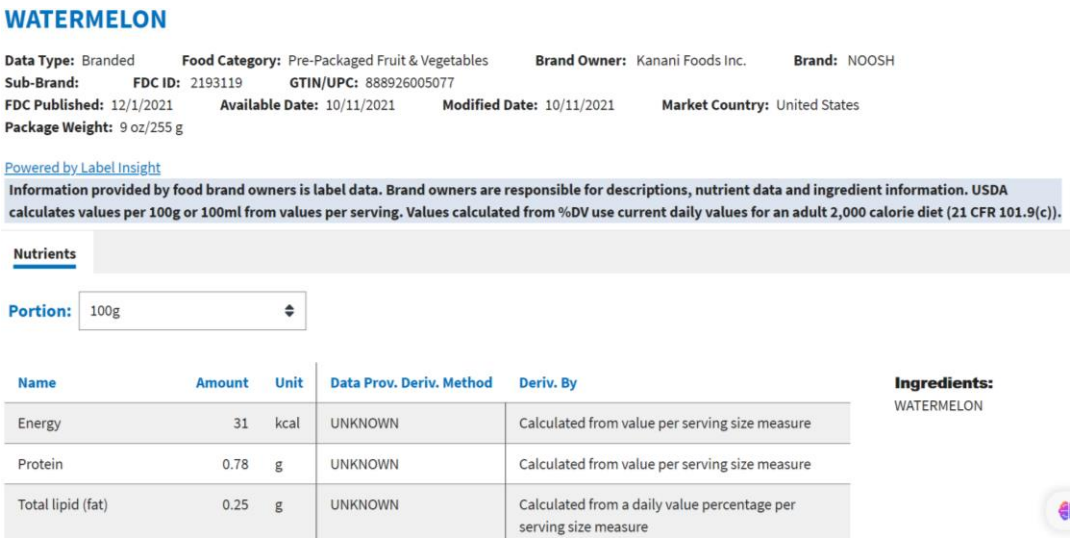

WATERMELON

Data Type: Branded **Food Category:** Pre-Packaged Fruit & Vegetables **Brand Owner:** Kanani Foods Inc. **Brand:** NOOSH
Sub-Brand: **FDC ID:** 2193119 **GTIN/UPC:** 888926005077
FDC Published: 12/1/2021 **Available Date:** 10/11/2021 **Modified Date:** 10/11/2021 **Market Country:** United States
Package Weight: 9 oz/255 g

Powered by Label Insight

Information provided by food brand owners is label data. Brand owners are responsible for descriptions, nutrient data and ingredient information. USDA calculates values per 100g or 100ml from values per serving. Values calculated from %DV use current daily values for an adult 2,000 calorie diet (21 CFR 101.9(c)).

Nutrients

Portion: 100g

Name	Amount	Unit	Data Prov. Deriv. Method	Deriv. By
Energy	31	kcal	UNKNOWN	Calculated from value per serving size measure
Protein	0.78	g	UNKNOWN	Calculated from value per serving size measure
Total lipid (fat)	0.25	g	UNKNOWN	Calculated from a daily value percentage per serving size measure

Ingredients:
WATERMELON

Gambar 3.2 Sampel Informasi Nutrisi

3.2 Desain Sistem

Desain sistem yang digunakan pada penelitian ini adalah seperti yang ditunjukkan Gambar 3.3.

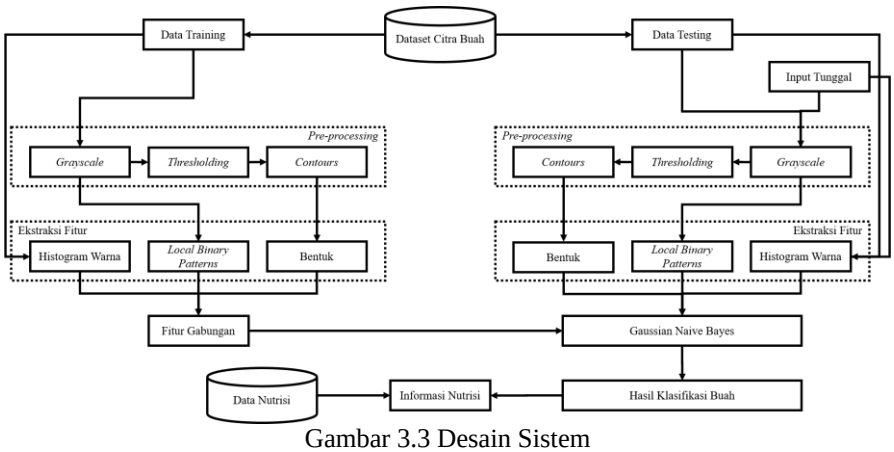

Gambar 3.3 Desain Sistem

Alur desain sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah dimulai dengan melakukan input dataset citra buah. Data tersebut kemudian dibagi menjadi 2 kelompok, yaitu data *training* (pelatihan) dan data *testing* (pengujian). Tahap selanjutnya yaitu *pre-processing* berupa *grayscale*, *thresholding*, dan *contours* pada masing-masing kelompok data. Setelah melalui *pre-processing*, dilakukan beberapa ekstraksi fitur berupa histogram warna, *Local Binary Patterns*, dan bentuk. Lalu nilai-nilai yang didapatkan dari hasil ekstraksi, dilatih menggunakan algoritma GNB agar mendapat pola dan fitur yang relevan untuk klasifikasi. Proses dilanjutkan dengan input tunggal citra yang melalui proses serupa dengan data testing hingga mendapatkan hasil klasifikasi. Sehingga informasi nutrisi buah yang diprediksi tersebut dapat ditampilkan dengan mengambil data nutrisi yang tersedia.

3.2.1 *Grayscale*

Grayscale adalah suatu bentuk visualisasi suatu citra di mana setiap piksel pada citra memiliki tingkat keabuan tunggal (*grayscale*) yang menggambarkan tingkat kecerahan pada piksel tersebut. Citra *grayscale* hanya memiliki tingkat keabuan yaitu dari warna hitam dengan diwakili 0 hingga warna putih dengan diwakili 255 pada skala 8-bit.

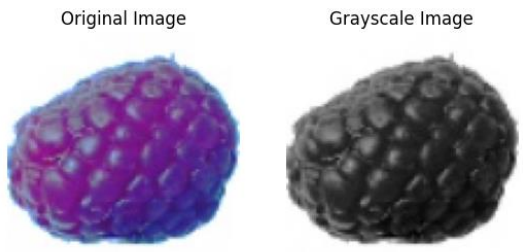

Gambar 3.4 Citra Setelah dan Sebelum *Grayscale*

Gambar 3.4 menampilkan hasil pengolahan citra dari RGB menjadi *grayscale*. Persamaan untuk mengubah citra berwarna (RGB) menjadi citra *grayscale* dapat dijelaskan dengan Persamaan (3.1).

$$Grayscale = 0{,}299 \times \mathrm{R} + 0{,}587 \times \mathrm{G} + 0{,}114 \times \mathrm{B} \qquad (3.1)$$

Pada Persamaan (3.1), R, G, dan B merupakan intensitas masing-masing komponen warna *red*, *green*, dan *blue* dalam citra RGB, dimana intensitas tersebut memiliki rentang 0 sampai 255. Sedangkan 0.299, 0.587, dan 0.114 adalah faktor bobot yang mewakili kontribusi relatif dari tiap-tiap warna RGB. Angka-angka tersebut merupakan faktor yang diturunkan dari penelitian psikovisual, yaitu penelitian yang menunjukkan bahwa urutan untuk kepekaan mata manusia terhadap masing-masing komponen warna dalam persepsi kecerahan atau luminositas. Urutan tersebut adalah hijau, diikuti oleh merah, dan yang terakhir warna biru.

3.2.2 *Thresholding*

Thresholding adalah suatu proses pemisahan atau pengelompokan piksel dalam citra menjadi dua kelas berbeda berdasarkan suatu nilai ambang (*threshold*). Piksel dengan intensitas di atas nilai ambang akan dilabeli ke kelas putih, sedangkan piksel dengan intensitas di bawah atau sama dengan nilai ambang akan dilabeli dengan kelas hitam. *Thresholding* merupakan proses yang cukup penting pada pengolahan citra, karena proses ini bermanfaat untuk memisahkan objek dari latar belakang atau mengidentifikasi area tertentu dalam citra.

Gambar 3.5 Citra Setelah dan Sebelum *Thresholded*

Gambar 3.5 menampilkan hasil pengolahan citra dari RGB ke *grayscale* lalu menjadi *threshold*. Persamaan sederhana yang digunakan pada *thresholding* dapat dijelaskan pada Persamaan (3.2).

$$\mathrm{T(x,y)} = \begin{cases} 1 \text{ jika } \mathrm{I(x,y)} > threshold \\ 0 \text{ jika } \mathrm{I(x,y)} \leq threshold \end{cases} \tag{3.2}$$

T(x,y) pada Persamaan (3.2) menjelaskan tentang nilai *thresholding* untuk piksel pada koordinat *x* dan *y*. Sedangkan *I(x,y)* menjelaskan tentang intensitas piksel pada koordinat *x* dan *y*. Dan *threshold* merupakan nilai ambang yang digunakan untuk mengelompokkan piksel menjadi 2 kelas. Proses ini memiliki hasil akhir berupa citra biner, dengan menganggap piksel yang memenuhi kondisi *threshold* merupakan bagian dari objek sedangkan piksel yang tidak memenuhi kondisi menjadi latar belakang dari objek tersebut.

3.2.3 *Contours*

Kontur (*contours*) dalam konteks pengolahan citra adalah garis yang mengelilingi area yang memiliki intensitas piksel yang sama atau memiliki karakteristik yang serupa. Kontur adalah gambaran dari tepian wilayah objek dalam

suatu citra. Pada Gambar 3.5 disertakan proses pengolahan citra dari RGB ke *contours*.

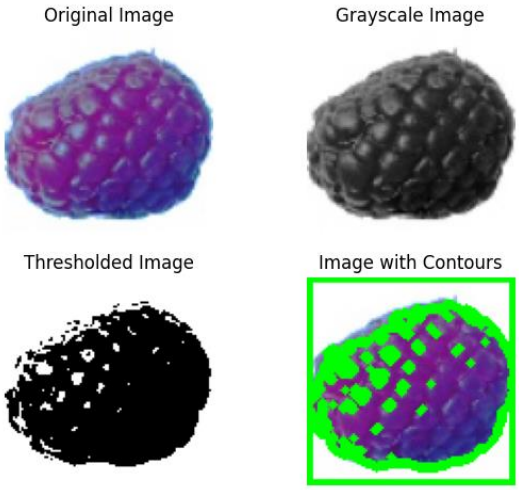

Gambar 3.6 Citra setelah dan sebelum *contours*

Kontur dapat dicari menggunakan transformasi *hough*. Transformasi *hough* menspesifikasikan kurva dalam bentuk parametrik. Kurva dinyatakan sebagai bentuk parametrik ($x(u)$, $y(u)$) dengan panjang kurva dicari dengan Persamaan (3.3).

$$P = \int_{u_1}^{u_2} \sqrt{\left(\frac{dx}{du}\right)^2 + \left(\frac{dy}{du}\right)^2}\, du \tag{3.3}$$

Transformasi *hough* menggunakan mekanisme *voting* untuk mengestimasi nilai parameter. Setiap titik di kurva menyumbang suara untuk beberapa kombinasi parameter. Parameter yang memperoleh suara terbanyak terpilih sebagai pemenang. Pada awalnya, Transformasi *hough* digunakan untuk mendeteksi garis lurus. Namun, ia juga dapat digunakan untuk mendeteksi kurva sederhana lainnya seperti lingkaran dan elips.

3.2.4 *Histogram* Warna

Histogram warna atau *color histogram* adalah bentuk sebaran warna pada sebuah gambar dua dimensi atau tiga dimensi. Sebaran tersebut didapatkan dengan cara menghitung jumlah piksel dari setiap warna yang dapat dijangkau. Dalam pembangunan histogram, nilai RGB mempunyai range dari 0 sampai 255 akan punya kombinasi warna sebesar 16.777.216 yang didapatkan dari : 255 x 255 x 255. Misalkan terdapat sebuah citra dengan derajat keabuan L. n_i adalah jumlah piksel dengan intensitas warna i (0 sampai 255), maka histogram untuk intensitas i adalah histogram[i] = n_i untuk jumlah piksel pada suatu citra adalah n, maka untuk persamaanya ada pada Persamaan (3.4).

$$N = \frac{n_i}{n}, i = 0,1, \ldots, L - 1 \tag{3.4}$$

Histogram dibuat pada setiap kanal warna, jadi apabila terdapat citra berwarna dengan suluran RGB. Histogram yang dibuat seharusnya juga ada 3, yaitu kanal merah, hijau, dan biru. Nilai h_i merupakan probabilitas piksel dengan derajat keabuan i. Jumlah seluruh probabilitas sama dengan 1 atau dapat dilihat pada Persamaan (3.5).

$$\sum_{I=0}^{L-1} h_i = 1 \tag{3.5}$$

Peluang suatu piksel memiliki derajat keabuan lebih kecil atau sama dengan derajat keabuan tertentu adalah jumlah h_i untuk $0 \leq i \leq j$ atau dapat dituliskan dengan Persamaan (3.6).

$$P(i \leq j) = \sum_{i=0}^{j} h_i \, , \; 0 \; \leq j \leq L - 1 \tag{3.6}$$

3.2.5 *Local Binary Patterns*

Local Binary Patterns atau bisa dikenal dengan LBP adalah metode untuk menggambarkan tekstur dengan menghitung pola biner lokal pada setiap piksel dalam citra *grayscale*. Parameter yang digunakan pada metode ini adalah citra *grayscale*, jumlah piksel, serta jarak radial dari piksel inti ke piksel tetangga. Hasil akhir dari LBP sendiri pada umumnya berupa citra dengan pola biner di setiap piksel. Metode ini bekerja dengan membandingkan intensitas piksel inti dengan intensitas piksel tetangga. Sirkular blok piksel diperlukan guna mengambangkan satu piksel dengan piksel-piksel disekelilingnya. Ukuran dari sirkular blok piksel dapat diubah dengan menentukan jarak dan jumlah piksel tetangga dengan menggunakan Persamaan (3.7) dan (3.8).

$$x_i = x_c + R_{\cos}\left(\frac{2\pi i}{P}\right) \tag{3.7}$$

$$y_i = y_c + R_{\sin}\left(\frac{2\pi i}{P}\right) \tag{3.8}$$

Kedua persamaan di atas menjelaskan perhitungan jarak, dimana x_c, y_c mewakili koordinat piksel tengah, sedangkan x_i, y_i piksel tetangga. Adapun *R*, *P*, dan *i* berturut-turut mewakili jarak, jumlah piksel tetangga, dan nilai piksel. Rumus yang digunakan untuk menghitung ciri dari metode LBP terdapat pada Persamaan (3.9).

$$\mathrm{LBP_{PR}}(\mathrm{x_c}, \mathrm{y_c}) = \sum_{\mathrm{i}=0}^{\mathrm{P}-1} \mathrm{s}(\mathrm{g_i} - \mathrm{g_c})2^{\mathrm{i}} \tag{3.9}$$

Pada persamaan di atas g_i mewakili piksel blok ketetanggan pada posisi ke i sedangkan g_c mewakili piksel tengah blok dan $s(x)$ memiliki nilai $\begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$

3.2.6 Fitur Bentuk

Ekstraksi fitur bentuk adalah proses menganalisis dan menghitung karakteristik atau properti kuantitatif dari objek atau region tertentu dalam citra untuk mengenal bentuknya. Ekstraksi fitur ini bertujuan untuk menciptakan persamaan objek secara numerik berdasarkan atribut-atribut geometris atau struktural yang dapat digunakan dalam berbagai aplikasi, khususnya pengolahan citra. Berikut merupakan alur ekstraksi fitur pada penelitian ini.

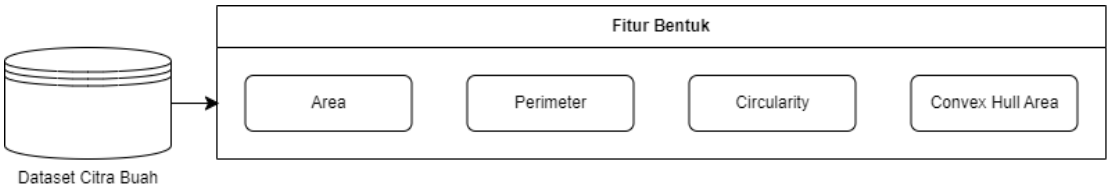

Gambar 3.7 Alur Ekstraksi Fitur Bentuk

Berdasarkan Gambar 3.7, terdapat beberapa fitur bentuk yang diekstrak dari citra setelah proses pencarian kontur. Berikut adalah fitur-fitur bentuk yang diekstrak:

3.2.6.1 Area

Luas objek atau dalam pengolahan citra biasa dikenal dengan "*area*" merupakan ukuran pada suatu daerah dalam citra. Area diukur dalam satuan piksel

persegi yang mewakili jumlah piksel untuk membentuk objek tersebut. Untuk lebih jelasnya, terdapat persamaan matematis yang mewakili perhitungan area pada Persamaan (3.10).

$$A = \sum_{i=1}^{n} . \sum_{j=1}^{m} f(i,j) \tag{3.10}$$

Di mana *A* pada Persamaan (3.10) mewakili *area* objek, *n* adalah jumlah kolom piksel yang ada pada objek, *m* adalah jumlah baris piksel yang ada pada objek, dan $f(i,j)$ bernilai 1 jika (i,j) adalah piksel objek dalam citra biner.

3.2.6.2 Perimeter

Perimeter atau keliling adalah panjang garis yang mengelilingi tepi luar objek dalam suatu citra. Dalam konteks pengolahan citra, *perimeter* mengacu pada panjang dari piksel-piksel yang berada pada tepi objek, atau garis yang mengelilinginya. Persamaan yang umum digunakan untuk menghitung *perimeter* yaitu dengan menjumlahkan seluruh panjang dari piksel-piksel yang mengelilingi objek. Berikut rumus matematis (3.11) dari perimeter.

$$P = \sum_{i=1}^{N-1} d_i = \sum_{i=1}^{N-1} |x_i - x_{i+1}| \tag{3.11}$$

Pada rumus (3.11), huruf *P* mewakili *perimeter* objek, dimana d_i menunjukkan panjang segmen garis antara titik ke-*i* dan titik ke-*i* + 1 sedangkan $|x_i - x_{i+1}|$ menunjukkan jarak horizontal (dalam sumbu *x*) antara titik ke-*i* dan titik ke-*i* + 1. Jadi, berdasarkan rumus tersebut *perimeter* total objek dapat dihitung

dengan menjumlahkan panjang semua segmen garis yang menghubungkan titik-titik dalam kontur objek.

3.2.6.3 *Circularity*

Circularity adalah analisis pada pengolahan citra yang bekerja dengan mengukur sejauh mana objek menyerupai bentuk lingkaran sempurna. Dalam istilah matematis, *circularity* dihitung dengan membandingkan antara luas dengan keliling objek tersebut. Di mana apabila objek tersebut memiliki bentuk mendekati lingkaran sempurna maka nilai *circularity*-nya akan mendekati 1, sedangkan apabila bentuk objek tersebut jauh dari bentuk lingkaran maka nilai *circularity*-nya juga akan semakin jauh dari angka 1. Berikut adalah Persamaan (3.12) yang digunakan untuk menghitung *circularity*.

$$C = \frac{4\pi A}{P^2} \tag{3.12}$$

Pada Persamaan (3.12) terdapat *C* yang mewakili nilai *circularity*, konstanta *Pi*, serta luas objek dan keliling objek. *Circularity* memiliki nilai $0 \leq C \leq 1$ yang mengartikan bahwa *circularity* bernilai lebih besar atau sama dengan 0 hingga kurang dari atau sama dengan 1 tergantung dengan kemiripan objek dengan bentuk lingkaran sempurna. Oleh karena itu, *circularity* ini dapat membantu pengklasifikasian objek berdasarkan bentuknya.

3.2.6.4 *Convex Hull*

Convex hull adalah bentuk konveks terkecil yang mengelilingi objek sehingga dapat menutupi seluruh objek atau titik-titik dalam objek tersebut. Untuk

menghitung *convex hull area*, dilakukan perhitungan untuk mencari *convex hull* terlebih dahulu. Yaitu dengan menggunakan algoritma *convex hull* seperti algoritma *graham scan* yang menghasilkan nilai poligon konveks dari objek. Algoritma tersebut memiliki 3 tahapan dalam pengoperasinnya. Yang pertama yaitu memilih titik extermal yang akan menjadi pivot. Titik extermal adalah titik unik yang memiliki kriteria tertentu misalnya, titik yang memiliki nilai absis paling besar atau memiliki nilai ordinat paling kecil. Lalu lakukan sorting terhadap titik sisa secara mengecil berdasarkan besar sudut relatif terhadap titik extermal. Dilanjutkan dengan melakukan traversal terhadap titik yang telah disorting. Membuat sisi baru jika sudut lebih kecil dari 180º dan apabila lebih besar dari 180º maka dilakukan runut balik. Untuk (x_1, y_1), (x_2, y_2), (x_3, y_3), determinannya dihitung dengan Persamaan (3.13).

$$\begin{vmatrix} x_1 & y_1 & 1 \\ x_2 & y_2 & 1 \\ x_3 & y_3 & 1 \end{vmatrix} = x_1y_2 + x_3y_1 + x_2y_3 - x_3y_2 - x_2y_1 - x_1y_3 \qquad (3.13)$$

3.2.7 *Gaussian Naive* Bayes

Gaussian Naive Bayes (GNB) adalah salah satu metode klasifikasi berdasarkan teorema *bayes* yang mengartikan bahwa fitur-fitur (atribut) pembentuk suatu kelas adalah independen secara statistik. Secara khusus, GNB mengartikan bahwa distribusi nilai-nilai fitur untuk setiap kelas mengikuti distribusi *gaussian* (normal). Dalam menghitung probabilitas, GNB menggunakan teorema *bayes* dengan Persamaan (3.14).

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \tag{3.14}$$

Pada Persamaan (3.14), P(C_i|X) mewakili probabilitas kelas C yang diberikan fitur X, $P(x_j|C_i)$ adalah probabilitas fitur x_j yang diberikan kelas C dengan menghitungnya berdasarkan asumsi GNB, $P(C_i)$ adalah probabilitas prior dari kelas C, dan $P(x_j)$ adalah probabilitas keseluruhan fitur x_j. $P(C_i|X)$ memiliki nilai yang sama dengan $\log(P(C_i|X))$ sehingga dapat dipahami bahwa Persamaan (3.15) dapat dituliskan dengan Persamaan (3.15).

$$\log(P(C_i|X)) = \log(P(X|C_i)) + \log\big(P(C_i)\big) - \log(P(X)) \tag{3.15}$$

Untuk GNB sendiri, rumus $P(X|C)$ dimodifikasi dengan memasukkan distribusi *gaussian* yaitu dengan menggunakan *mean* (μ) dan *varians* (σ^2).

$$P(X|C_i) = \prod_{j=1}^{d} \frac{1}{\sqrt{2\pi\sigma_{ij}^2}} e^{-\frac{(x_j-\mu_{ij})^2}{2\sigma_{ij}^2}} \tag{3.16}$$

Berdasarkan Persamaan (3.16) dapat dipahami bahwa pada GNB, perhitungan probabilitas distribusi fitur X yang diberikan kelas C_i dilakukan dengan mengalikan distribusi gauss untuk setiap fitur x_j. Persamaan tersebut mewakili probabilitas bahwa fitur x_j berasal dari kelas C_i dengan rata-rata μ_{ij} dan *varians* $\sigma^2{}_{ij}$. Selanjutnya, kaidah peluang bersyarat digunakan untuk mendapatkan Persamaan (3.17).

$$P(C_i|X) = P(C_i)P(X|C_i) = P(C_i)\prod_{j=1}^{d} \frac{1}{\sqrt{2\pi\sigma_{ij}^2}} e^{-\frac{(x_j-\mu_{ij})^2}{2\sigma_{ij}^2}} \quad (3.17)$$

$P(C_i, X)$ adalah probabilitas bersama bahwa objek memiliki fitur X dan termasuk dalam kelas C_i. Persamaan (3.17) menggambarkan tentang cara menghitung probabilitas bersama antara kelas C_i dan fitur X dengan mengalikan probabilitas sebelumnya dari kelas C_i dengan hasil perkalian dari probabilitas distribusi setiap fitur x_j jika objek berasal dari kelas C_i.

Maka untuk menentukan hasil klasifikasi berdasarkan atribut atau inputan dari fitur objek berdasarkan nilai probabilitas terbesar dari $P(C_i|X)$ dapat dituliskan dengan Persamaan (3.18).

$$c = \arg\max P(C_i)\prod_{j=1}^{d} \frac{1}{\sqrt{2\pi\sigma_{ij}^2}} e^{-\frac{(x_j-\mu_{ij})^2}{2\sigma_{ij}^2}} \quad (3.18)$$

Persamaan (3.18) adalah persamaan untuk menentukan kelas c yang paling mungkin atau memiliki probabilitas tertinggi untuk objek dengan fitur X. Jadi, secara keseluruhan, persamaan tersebut menggambarkan cara memilih kelas yang paling mungkin untuk data dengan fitur x dengan memilih kelas yang memiliki probabilitas sebelumnya tertinggi $P(C_i)$ dan hasil perkalian dari probabilitas distribusi setiap fitur x_j yang tinggi jika objek berasal dari kelas C_i.

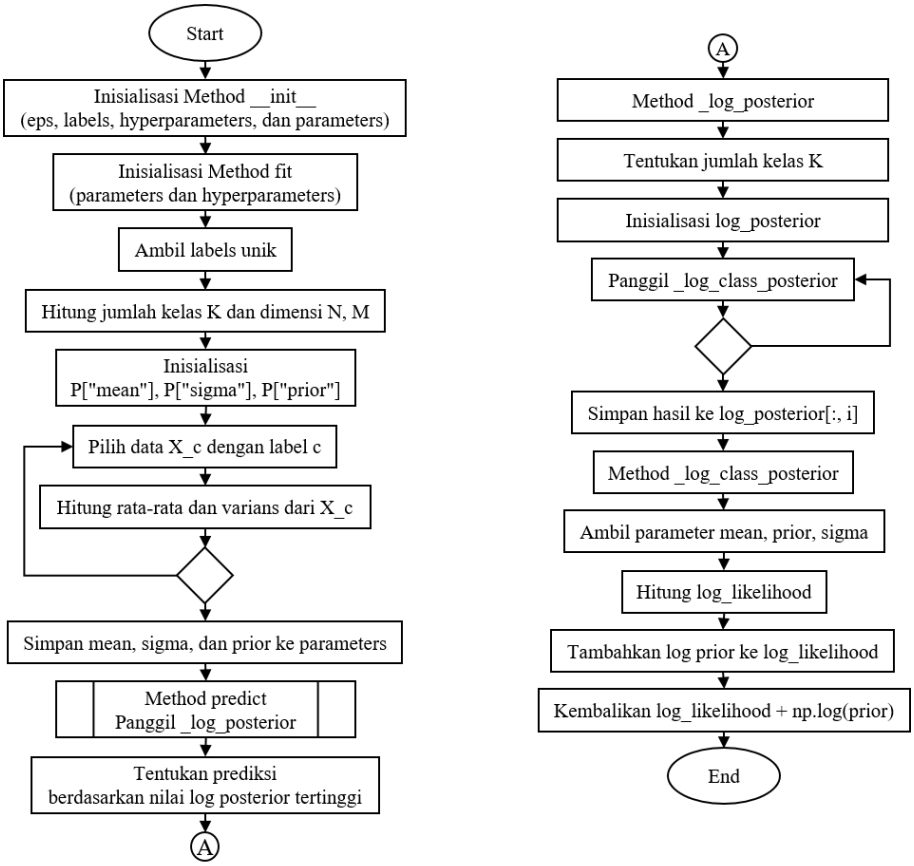

Gambar 3.8 *Flowchart* Alur *Gaussian Naive Bayes*

Flowchart diawali dengan menginisialisasi *method* __init__ berupa *labels*, *hyperparameters*, dan *parameters* yang berisi mean, sigma, dan prior. Selanjutnya membuat *method* fit yang digunakan untuk melatih model menggunakan data fitur X dan label y. Pertama, *labels* diatur menjadi label unik yang dapat ditemukan dalam y. Selanjutnya, menghitung jumlah kelas (K) dan dimensi data dimana, N mewakili jumlah sampel sedangkan M mewakili jumlah fitur. Parameter mean, sigma, dan prior diinisialisasi sebagai array nol dengan ukuran yang sesuai. Kemudian rata-rata (mean), *varians* (sigma), dan probabilitas prior (prior) dihitung untuk setiap kelas yang ditemukan dalam label. Rata-rata dan *varians* dihitung

berdasarkan data fitur X yang sesuai dengan label kelas, sedangkan prior ditentukan berdasarkan proporsi sampel yang termasuk dalam kelas tersebut.

Method predict digunakan untuk membuat prediksi pada data baru X (data uji). Proses prediksi melibatkan pemanggilan *method* _log_posterior yang menghitung log posterior *probabilities* untuk setiap sampel dari setiap kelas. Di dalam _log_posterior, jumlah kelas K ditentukan dan *matriks* log_posterior diinisialisasi. Kemudian setiap kelas diiterasi dengan memanggil *method* _log_*class*_posterior untuk menghitung log posterior *probability* pada kelas tersebut. *Method* _log_class_posterior menghitung log posterior *probability* dengan menggunakan parameter mean, prior, dan sigma yang telah dilatih sebelumnya. Log *likelihood* dihitung berdasarkan distribusi *gaussian* untuk setiap fitur, di mana komponen normalisasi dan eksponensial dijumlahkan. Log *likelihood* ini kemudian ditambahkan dengan log prior untuk mendapatkan log posterior *probability*. Terakhir, hasil dari _log_posterior digunakan dalam *method predict* untuk menentukan prediksi kelas akhir. Prediksi dilakukan dengan memilih label kelas dengan nilai log posterior tertinggi untuk setiap sampel dalam data X. Prediksi kelas ini kemudian dikembalikan sebagai *output* dari *method predict*.

BAB IV

UJI COBA DAN PEMBAHASAN

4.1 Skenario Pengujian

Skenario pengujian dilakukan dengan 4 skenario, yaitu menggunakan *split* data, *k-fold*, variasi fitur, dan juga data baru. Dataset yang digunakan untuk uji coba tersebut mencakup 16.854 citra buah dan terbagi ke dalam 33 kelas. Dataset tersebut akan dibagi menjadi dua bagian, yaitu data pelatihan (data *training*) dan data pengujian (data *test*). Pembagian untuk uji coba menggunakan *split* data sendiri dilakukan dalam tiga skenario, yaitu 70:30, 80:20, dan 90:10. Selanjutnya, model akan melalui tahap *pre-processing* dan *process* untuk diambil nilai dari beberapa fitur, yaitu histogram warna, LBP, dan bentuk. Lalu fitur-fitur tersebut akan digabung agar dapat dilatih dan diuji menggunakan algoritma GNB. Percobaan ini dilakukan tiga kali dengan variasi rasio pembagian data agar mendapatkan hasil klasifikasi yang diinginkan.

Setelah mendapatkan hasil klasifikasi dari model GNB, langkah berikutnya adalah melakukan evaluasi sejauh mana model mampu mengklasifikasikan citra buah dengan benar. Salah satu metode yang dapat digunakan untuk mengevaluasi kinerja sistem adalah *confusion matrix*. Pada dasarnya *confusion matrix* digunakan untuk membandingkan antara hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya. Terdapat empat istilah dalam penentuan nilainya yaitu, *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN). *True Positive* (TP) merupakan hasil nilai positif yang diklasifikasikan dengan benar oleh model sebagai nilai positif sedangkan nilai *True*

Negative (TN) merupakan jumlah data negatif yang terdeteksi dengan benar. *False Positive* (FP) merupakan data negatif namun terdeteksi sebagai data positif sedangkan *False Negative* (FN) merupakan hasil nilai positif yang diklasifikasikan salah oleh model sebagai nilai negatif. Dari *confusion matrix* tersebut dapat diketahui nilai akurasi, presisi, *recall*, dan *f-1 score*.

Akurasi sendiri dapat didefinisikan sebagai tingkat kesamaan hasil antara nilai prediksi dengan nilai aktual. Untuk lebih jelasnya, akurasi memiliki persamaan (4.1) :

$$\text{Akurasi} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FN} + \text{FP} + \text{TN}} \tag{4.1}$$

Sedangkan presisi adalah tingkat ketepatan antara pertanyaan yang diajukan oleh pengguna dengan jawaban yang diberikan oleh sistem. Secara matematis, presisi dapat dilihat pada Persamaan (4.2) :

$$\text{Presisi} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{4.2}$$

Recall adalah tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi. Secara matematis, *recall* dapat dilihat pada Persamaan (4.3) :

$$Recall = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{4.3}$$

Terakhir adalah *f-1 score* yang merupakan perhitungan yang digunakan untuk mengukur timbal balik antara *recall* dan presisi ketikan nilai *recall* dan presisi

memiliki bobot yang berbeda. Secara matematis, *f-1 score* dapat didefinisikan dengan Persamaan (4.4)

$$F - 1\ Score = \frac{2\ \times \text{Recall}\ \times \text{Presisi}}{\text{Recall} + \text{Presisi}} \tag{4.4}$$

Pengujian akan dihitung untuk setiap variasi *split* data. Setelah mendapatkan rasio terbaik berdasarkan hasil dari *confusion matrix*, uji dilanjutkan dengan menggunakan *cross validation* atau *k-fold* dengan rasio pembagian data terbaik. *K-fold* sendiri merupakan metode *cross validation* yang digunakan untuk menguji kemampuan sistem pada bagian data acak. *K-fold* pada penelitian ini perlu dilakukan untuk memastikan bahwa performa model tetap stabil pada data yang berbeda. *K-fold* akan menggunakan seluruh data sebagai data latih dan data uji secara bergantian, sehingga persebaran datanya lebih representatif dan memastikan bahwa model yang dibuat tidak hanya mengenali pola data tertentu saja. *K-fold* digunakan dengan membagi data menjadi beberapa iterasi. Pada setiap iterasi, dibagi lagi menjadi beberapa lipatan. Dari lipatan-lipatan tersebut, 1 lipatan diantaranya merupakan data uji sedangkan lipatan lainnya merupakan data latih. Kemudian, setiap iterasi dilatih dan diuji kembali menggunakan algoritma GNB. Setelah melakukan pengujian, maka *confusion matrix* setiap iterasi dapat diketahui. Dengan menggunakan *k-fold*, maka dapat dipastikan bahwa setiap sampel data digunakan untuk pengujian tepat satu kali, dan akhirnya mendapatkan estimasi yang lebih baik tentang kinerja model secara keseluruhan.

Langkah berikutnya yaitu melakukan pengujian menggunakan dataset baru berupa data citra buah dengan berbagai kondisi dan tangkapan langsung oleh

peneliti. Skenario pengujian yang dilakukan pada dataset tersebut menggunakan iterasi terbaik pada pengujian *k-fold* yang telah dilakukan sebelumnya. Pengujian ini dilakukan untuk mengetahui sejauh mana sistem bekerja pada kasus sebenarnya. Sehingga, sistem ini dapat memberikan informasi akurat ketika dilakukan input tunggal untuk mendapatkan informasi jenis buah dan nutrisinya.

Uji coba yang terakhir yaitu menggunakan variasi fitur. Uji coba ini dilakukan untuk mengidentifikasi kontribusi relatif dari berbagai jenis ekstraksi fitur dalam meningkatkan kinerja sistem. Melalui penggunaan variasi fitur seperti histogram warna, Local Binary Patterns (LBP), dan bentuk, uji coba ini bertujuan untuk mengevaluasi sejauh mana setiap fitur mempengaruhi akurasi, presisi, recall, dan F1-score sistem. Dengan membandingkan hasil kinerja dari setiap fitur maka informasi yang didapatkan dapat memberikan wawasan yang mendalam tentang pentingnya masing-masing fitur dalam representasi citra buah. Uji coba dilakukan pada data awal dengan menggunakan split data yang memiliki rasio 70:30.

4.2 Hasil Uji Coba Menggunakan *Split* Data

Pengujian menggunakan *split* data dilakukan dengan membagi dataset menjadi dua bagian, yaitu data pelatihan dan data pengujian. Pembagian dilakukan dalam tiga skenario, yaitu 70:30, 80:20, dan 90:10. Skenario pertama yaitu menggunakan data pelatihan dengan rasio 70:30 atau data pelatihan sebesar 11.797 dan data pengujian sebesar 5.057. Untuk lebih jelasnya, hasil evaluasi sistem dapat dilihat pada Gambar 4.1 berupa tabel *confusion matrix.*

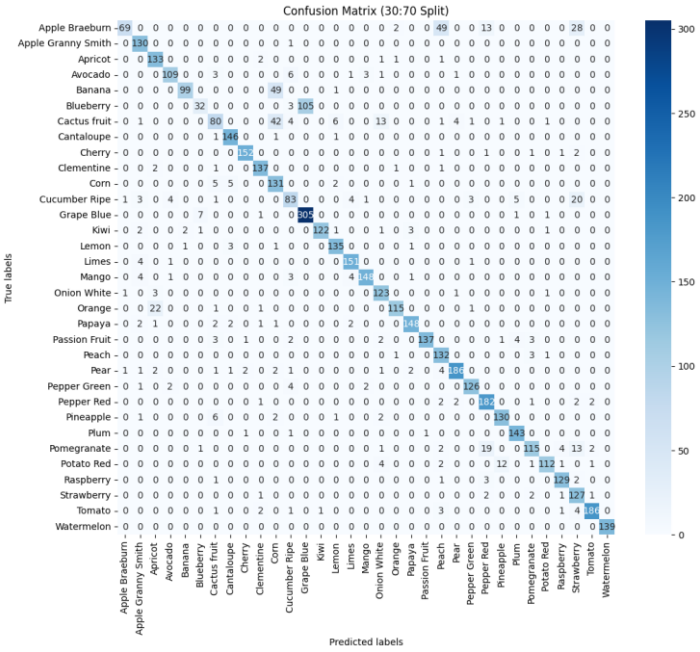

Gambar 4.1 *Confusion Matrix Split* Data Rasio 70:30

Berdasarkan Gambar 4.1, hasil perhitungan *confusion matrix* untuk akurasi, presisi, *recall*, dan *f1-score* dari *split* data menggunakan rasio 70:30 dapat ditunjukkan pada Tabel 4.1.

Tabel 4.1 Hasil Evaluasi Menggunakan *Split* Data 70:30

Hasil Evaluasi Menggunakan *Split* Data 70:30				
Kelas	**Presisi**	***Recall***	***F1-score***	***Support***
Apple_Braeburn	0,96	0,43	0,59	161
Apple_Granny_Smith	0,87	0,99	0,93	131
Apricot	0,82	0,96	0,88	138
Avocado	0,93	0,88	0,90	124
Banana	0,97	0,66	0,79	149
Blueberry	0,78	0,23	0,35	140
Cactus_fruit	0,75	0,52	0,62	154
Cantaloupe	0,93	0,98	0,95	149
Cherry	0,97	0,96	0,97	158
Clementine	0,94	0,96	0,95	142
Corn	0,57	0,91	0,70	144
Cucumber_Ripe	0,76	0,66	0,71	125
Grape_Blue	0,74	0,97	0,84	315
Kiwi	0,99	0,92	0,95	133
Lemon	0,92	0,96	0,94	141
Limes	0,93	0,96	0,95	157
Mango	0,96	0,92	0,94	161
Onion_White	0,83	0,95	0,88	129
Orange	0,96	0,82	0,88	140
Papaya	0,95	0,93	0,94	159

Hasil Evaluasi Menggunakan *Split* Data 70:30					
Kelas		**Presisi**	***Recall***	***F1-score***	***Support***
Passion_Fruit		0,99	0,90	0,94	153
Peach		0,66	0,96	0,79	137
Pear		0,96	0,91	0,93	204
Pepper_Green		0,95	0,93	0,94	135
Pepper_Red		0,83	0,95	0,88	192
Pineapple		0,90	0,92	0,91	142
Plum		0,93	0,98	0,96	146
Pomegranate		0,91	0,73	0,81	157
Potato_Red		0,96	0,84	0,90	133
Raspberry		0,94	0,95	0,95	136
Strawberry		0,64	0,95	0,77	134
Tomato		0,97	0,93	0,95	199
Watermelon		1,00	1,00	1,00	139
Akurasi				**0,87**	**5057**
				87%	
Rata - Rata	**Presisi**	**0,89**			
		89%			
	Recall		**0,86**		
			86%		
	F1-Score			**0,86**	
				86%	

Berdasarkan nilai-nilai pada Tabel 4.1, dapat diketahui bahwa evaluasi kinerja sistem menggunakan *split* data 70:30 memiliki nilai akurasi sebesar 87%, presisi sebesar 89%, *recall* sebesar 86%, dan *f1-score* sebesar 86%. Selanjutnya, pada skenario pengujian kedua dilakukan dengan menggunakan data yang memiliki rasio 80:20 atau dataset dengan total data pelatihan sebesar 13.483 dan total data pengujian sebesar 3.371. Untuk lebih jelasnya, ditampilkan hasil evaluasi sistem berupa gambar tabel *confusion matrix* yang dapat dilihat pada Gambar 4.2.

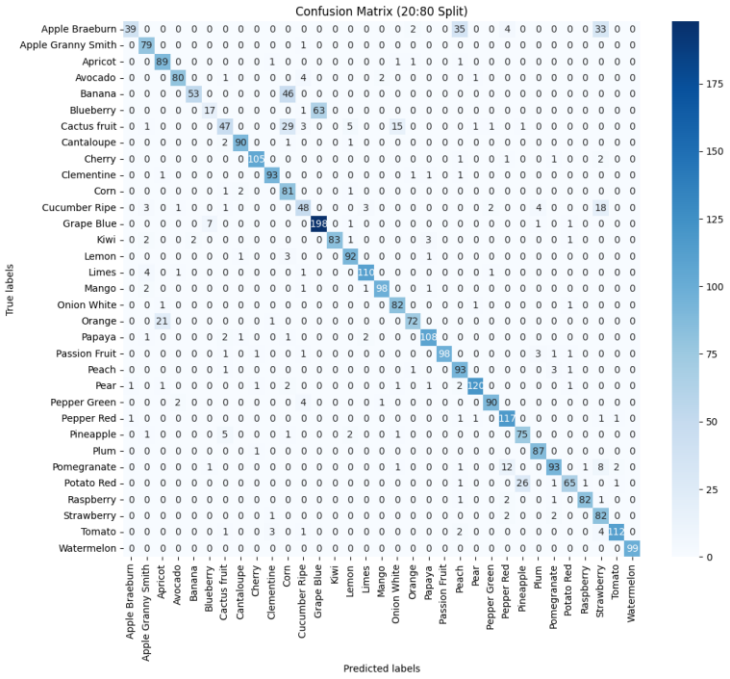

Gambar 4.2 *Confusion Matrix Split* Data Rasio 80:20

Gambar 4.2 merupakan *confusion matrix* dari pengujian sistem menggunakan *split* data dengan rasio 80:20. Berdasarkan *confusion matrix* tersebut, dapat diambil evaluasi dengan penjabaran yang ditunjukkan pada Tabel 4.2.

Tabel 4.2 Hasil Evaluasi Menggunakan *Split* Data 80:20

Hasil Evaluasi Menggunakan *Split* Data 80:20				
Kelas	**Presisi**	***Recall***	***F1-score***	***Support***
Apple_Braeburn	0,95	0,35	0,51	113
Apple_Granny_Smith	0,85	0,99	0,91	80
Apricot	0,79	0,96	0,86	93
Avocado	0,95	0,91	0,93	88
Banana	0,96	0,54	0,69	99
Blueberry	0,68	0,21	0,32	81
Cactus_fruit	0,76	0,46	0,57	103
Cantaloupe	0,96	0,96	0,96	94
Cherry	0,97	0,95	0,96	110
Clementine	0,94	0,96	0,95	97
Corn	0,49	0,95	0,65	85
Cucumber_Ripe	0,74	0,60	0,66	80
Grape_Blue	0,76	0,95	0,84	208
Kiwi	1,00	0,9	0,95	92
Lemon	0,89	0,95	0,92	97
Limes	0,95	0,94	0,94	117
Mango	0,97	0,95	0,96	103
Onion_White	0,81	0,96	0,88	85

Hasil Evaluasi Menggunakan *Split* Data 80:20					
Kelas		**Presisi**	***Recall***	***F1-score***	***Support***
Orange		0,94	0,77	0,84	94
Papaya		0,94	0,94	0,94	115
Passion_Fruit		1,00	0,92	0,96	106
Peach		0,67	0,94	0,78	99
Pear		0,97	0,92	0,94	130
Pepper_Green		0,96	0,93	0,94	97
Pepper_Red		0,85	0,96	0,90	122
Pineapple		0,74	0,88	0,80	85
Plum		0,92	0,99	0,95	88
Pomegranate		0,91	0,78	0,84	119
Potato_Red		0,92	0,68	0,78	95
Raspberry		0,98	0,94	0,96	87
Strawberry		0,55	0,94	0,69	87
Tomato		0,97	0,91	0,94	123
Watermelon		1,00	1,00	1,00	99
Akurasi				**0,85**	**3371**
				85%	
Rata - Rata	**Presisi**	**0,87**			
		87%			
	Recall		**0,85**		
			85%		
	F1-Score			**0,84**	
				84%	

Berdasarkan nilai-nilai pada Tabel 4.2, dapat diketahui bahwa evaluasi kinerja sistem menggunakan skenario pengujian kedua berupa *split* data 80:20, tidak memiliki perbedaan yang begitu signifikan dengan skenario sebelumnya. Evaluasi kinerja sistem menggunakan skenario kedua memiliki nilai akurasi sebesar 85%, presisi sebesar 87%, *recall* sebesar 85%, dan *f1-score* sebesar 84%. Selanjutnya, pada skenario ketiga pengujian dilakukan dengan menggunakan data yang memiliki rasio 90:10 atau dataset dengan total data pelatihan sebesar 15.168 dan total data pengujian sebesar 1.686. Untuk lebih jelasnya, ditampilkan hasil evaluasi sistem berupa gambar tabel *confusion matrix* yang dapat dilihat pada Gambar 4.3.

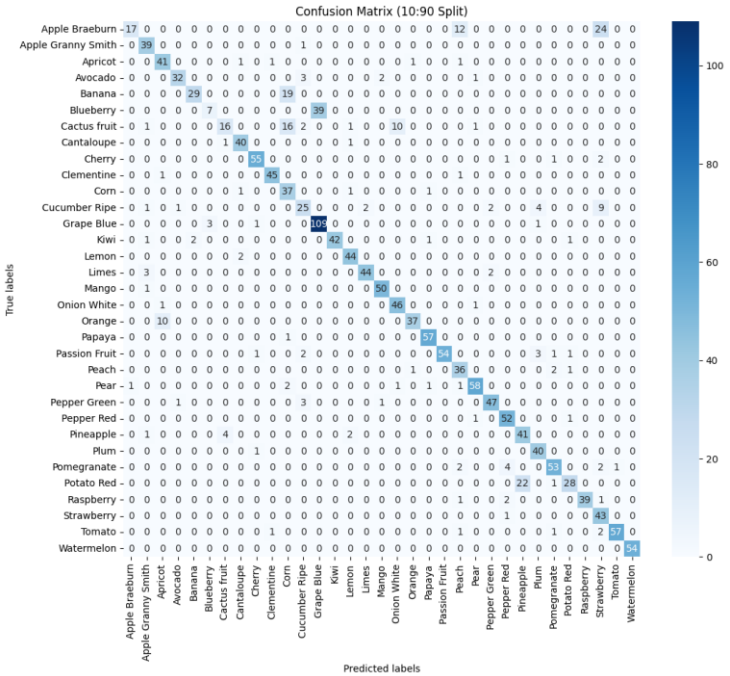

Gambar 4.3 *Confusion Matrix Split* Data Rasio 90:10

Gambar 4.3 merupakan *confusion matrix* dari pengujian sistem menggunakan *split* data dengan rasio 90:10. Berdasarkan *confusion matrix* tersebut, dapat diambil evaluasi dengan penjabaran yang ditunjukkan pada Tabel 4.3.

Tabel 4.3 Hasil Evaluasi Menggunakan *Split* Data 90:10

Hasil Evaluasi Menggunakan *Split* Data 90:10				
Kelas	**Presisi**	***Recall***	***F1-score***	***Support***
Apple_Braeburn	0,94	0,32	0,48	53
Apple_Granny_Smith	0,83	0,97	0,90	40
Apricot	0,77	0,91	0,84	45
Avocado	0,94	0,84	0,89	38
Banana	0,94	0,60	0,73	48
Blueberry	0,7	0,15	0,25	46
Cactus_fruit	0,76	0,34	0,47	47
Cantaloupe	0,91	0,95	0,93	42
Cherry	0,95	0,93	0,94	59
Clementine	0,96	0,96	0,96	47
Corn	0,49	0,93	0,64	40
Cucumber_Ripe	0,69	0,57	0,62	44
Grape_Blue	0,74	0,96	0,83	114
Kiwi	1,00	0,89	0,94	47
Lemon	0,9	0,96	0,93	46
Limes	0,96	0,90	0,93	49
Mango	0,94	0,98	0,96	51
Onion_White	0,81	0,96	0,88	48
Orange	0,95	0,79	0,86	47

Hasil Evaluasi Menggunakan *Split* Data 90:10					
Kelas		**Presisi**	***Recall***	***F1-score***	***Support***
Papaya		0,95	0,98	0,97	58
Passion_Fruit		1,00	0,87	0,93	62
Peach		0,65	0,90	0,76	40
Pear		0,94	0,91	0,92	64
Pepper_Green		0,92	0,90	0,91	52
Pepper_Red		0,87	0,96	0,91	54
Pineapple		0,65	0,85	0,74	48
Plum		0,83	0,98	0,90	41
Pomegranate		0,90	0,85	0,88	62
Potato_Red		0,88	0,55	0,67	51
Raspberry		1,00	0,91	0,95	43
Strawberry		0,52	0,98	0,68	44
Tomato		0,98	0,92	0,95	62
Watermelon		1,00	1,00	1,00	54
Akurasi				**0,84**	**1686**
				84%	
Rata - Rata	**Presisi**	**0,86**			
		86%			
	Recall		**0,83**		
			83%		
	F1-Score			**0,83**	
				83%	

Berdasarkan nilai-nilai pada Tabel 4.3, dapat diketahui bahwa evaluasi kinerja sistem menggunakan skenario pengujian ketiga berupa split data 90:10, tidak memiliki perbedaan yang begitu signifikan dengan 2 skenario sebelumnya. Evaluasi kinerja sistem menggunakan *split* data dengan rasio 90:10 memiliki nilai akurasi sebesar 84%, presisi sebesar 86%, *recall* sebesar 83%, dan *f1-score* sebesar 83%. Untuk lebih jelasnya, dapat dilihat pada Tabel 4.4 yang memuat tentang hasil ringkasan dari 3 skenario pengujian menggunakan split data.

Tabel 4.4 Ringkasan Hasil Evaluasi 3 Skenario Pengujian

Ringkasan Hasil Evaluasi 3 Skenario Pengujian				
Rasio	Akurasi	Presisi	*Recall*	*F1-Score*
70:30	0,85	0,87	0,85	0,84
	85%	87%	85%	84%
80:20	0,85	0,86	0,84	0,83
	85%	86%	84%	83%
90:10	0,84	0,86	0,83	0,83
	84%	86%	83%	83%

4.3 Hasil Uji Coba Menggunakan *K-fold*

Pengujian menggunakan *split* data yang telah dilakukan sebelumnya memberikan hasil bahwa ketiga skenario pengujian memiliki hasil evaluasi yang cukup baik dengan rentang nilai sebesar 83% sampai 87%. Untuk menggali lagi hasil evaluasi yang lebih akurat, dilakukan kembali pengujian menggunakan *k-fold* dengan *10-fold cross validation* yang memiliki rasio data sebesar 70:30 yang artinya pengujian menggunakan 30% dari total data sebagai data pengujian sedangkan 70% lainnya sebagai data pelatihan. Rasio 70:30 dipilih karena rasio tersebut memiliki hasil evaluasi yang paling baik dari pengujian sebelumnya, yaitu pengujian menggunakan *split* data. Pengujian *k-fold* menggunakan nilai *k* sebesar 10 dan iterasi akan berjalan sebanyak 10 kali dengan rasio pembagian data sebesar 70:30. Pengujian menggunakan data uji sebesar 30% dari total keseluruhan data, yang artinya pengujian ini menggunakan data uji sejumlah 5.057 citra buah dari 16.854 total keseluruhan citra, sedangkan 11.797 citra lainnya menjadi data latih. Proses pengujian ini melibatkan pembagian data latih sebesar 11.797 citra menjadi 10 lipatan atau "*folds*" sama besar. 9 lipatan dari data tersebut akan menjadi data latih, sedangkan 1 lipatan lainnya menjadi data uji. Model GNB dilatih untuk 10 iterasi sehingga nilai matriks akurasi, *presisi*, *recall*, dan *F1-Score* didapatkan untuk tiap-tiap iterasi. Evaluasi akhir dilakukan dengan menggunakan 30% data uji yang tidak pernah digunakan selama proses pelatihan atau cross-validation. Evaluasi ini memberikan gambaran tentang bagaimana model bekerja pada data yang benar-benar baru. Pengujian menggunakan *10-fold cross validation* memiliki hasil yang dituliskan pada Tabel 4.6.

Tabel 4.5 Hasil Uji Coba K-Fold

Iterasi ke-	*10-fold cross validation*			
	Akurasi	**Presisi**	***Recall***	***F1-Score***
1	0.863559	0.868528	0.856180	0.849526
	86%	87%	86%	85%
2	0.871186	0.887011	0.865095	0.864241
	87%	89%	87%	86%
3	0.867797	0.879350	0.851730	0.851988
	87%	88%	85%	85%
4	0.878814	0.887350	0.868360	0.864897
	88%	89%	87%	86%
5	0.881356	0.891211	0.872267	0.871305
	88%	89%	87%	87%
6	0.861864	0.890382	0.857493	0.855363
	86%	89%	86%	86%
7	0.874576	0.899847	0.876656	0.875270
	87%	90%	88%	88%
8	0.871077	0.885195	0.864179	0.862663
	87%	89%	86%	86%
9	0.883800	0.897805	0.879598	0.878085
	88%	90%	88%	88%
10	0.892282	0.904680	0.881848	0.883576
	89%	90%	88%	88%
Evaluasi Akhir	**0.868499**	**0.884727**	**0.864813**	**0.860766**
	87%	**88%**	**86%**	**86%**

Hasil evaluasi kinerja model menggunakan metode *10-fold cross validation* telah disajikan dalam Tabel 4.7. Dari 10 iterasi, didapatkan persentase hasil evaluasi akhir untuk akurasi sebesar 87%, pesisi sebesar 88%, *recall* sebesar 86%, dan *F1-Score* sebesar 86%. Nilai evaluasi terbaik didapatkan pada beberapa iterasi kesepuluh. Iterasi tersebut memiliki hasil evaluasi untuk akurasi sebesar 89%, pesisi sebesar 90%, *recall* sebesar 86%, dan *F1-Score* sebesar 86%.

4.4 Hasil Uji Coba Data Baru

Dua uji coba yang telah dilakukan sebelumnya menunjukkan hasil evaluasi yang cukup baik pada kinerja sistem. Untuk mengetahui lebih dalam apakah sistem ini juga bekerja dengan baik pada kasus nyata, dilakukan kembali uji coba menggunakan data baru berupa citra buah dengan berbagai kondisi dan juga hasil

tangkapan langsung oleh peneliti. Data tersebut akan diuji menggunakan iterasi terbaik dari pengujian *k-fold* sebelumnya. Hasil pengujian sistem menggunakan data baru ditampilkan menggunakan Gambar 4.4.

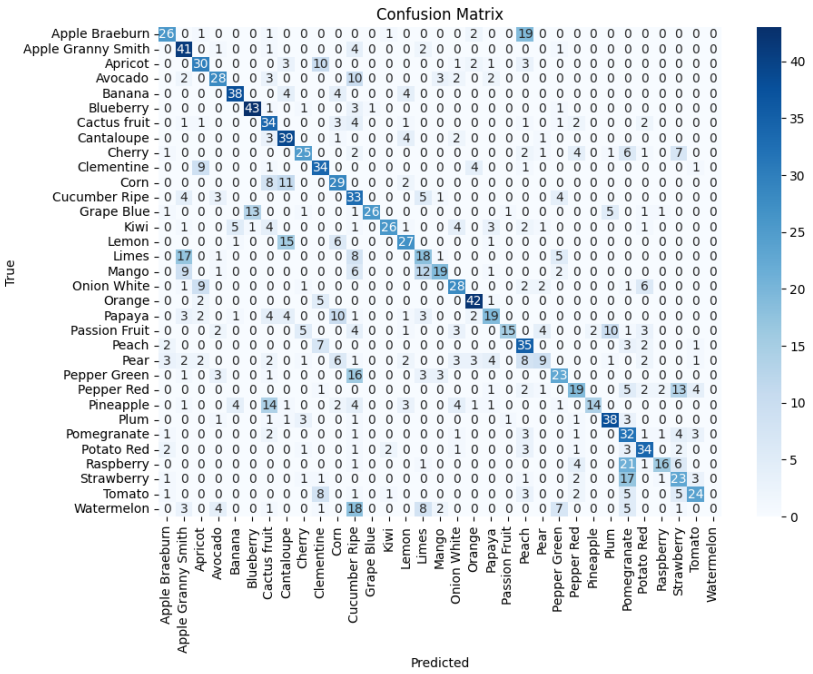

Gambar 4.4 Confusion Matrix Uji Coba Menggunakan Data Baru

Gambar 4.4 merupakan *confusion matrix* dari pengujian menggunakan data baru. Berdasarkan *confusion matrix* tersebut, dapat diambil evaluasi dengan penjabaran yang ditunjukkan pada Tabel 4.6.

Tabel 4.6 Hasil Evaluasi Menggunakan Data Baru

Hasil Evaluasi Menggunakan Data Baru				
Kelas	**Presisi**	***Recall***	***F1-score***	***Support***
Apple_Braeburn	0,68	0,52	0,59	50
Apple_Granny_Smith	0,48	0,82	0,6	50
Apricot	0,54	0,60	0,57	50
Avocado	0,64	0,56	0,60	50
Banana	0,78	0,76	0,77	50
Blueberry	0,75	0,86	0,80	50
Cactus_fruit	0,42	0,68	0,52	50
Cantaloupe	0,50	0,78	0,61	50
Cherry	0,64	0,50	0,56	50
Clementine	0,51	0,68	0,58	50
Corn	0,48	0,58	0,52	50

Hasil Evaluasi Menggunakan Data Baru					
Kelas		**Presisi**	***Recall***	***F1-score***	***Support***
Cucumber_Ripe		0,27	0,66	0,39	50
Grape_Blue		0,96	0,52	0,68	50
Kiwi		0,87	0,52	0,65	50
Lemon		0,59	0,54	0,56	50
Limes		0,35	0,36	0,35	50
Mango		0,66	0,38	0,48	50
Onion_White		0,57	0,56	0,57	50
Orange		0,75	0,84	0,79	50
Papaya		0,56	0,38	0,45	50
Passion_Fruit		0,88	0,30	0,45	50
Peach		0,41	0,70	0,52	50
Pear		0,47	0,18	0,26	50
Pepper_Green		0,51	0,46	0,48	50
Pepper_Red		0,53	0,38	0,44	50
Pineapple		0,88	0,28	0,42	50
Plum		0,69	0,76	0,72	50
Pomegranate		0,31	0,64	0,42	50
Potato_Red		0,61	0,68	0,64	50
Raspberry		0,76	0,32	0,45	50
Strawberry		0,38	0,46	0,41	50
Tomato		0,65	0,48	0,55	50
Watermelon		0,00	0,00	0,00	50
Akurasi				**0,54**	**1.650**
				54%	
Rata - Rata	**Presisi**	**0,61**			
		61%			
	Recall		**0,54**		
			54%		
	F1-Score			**0,53**	
				53%	

Berdasarkan hasil evaluasi pada Tabel 4.6, dapat diketahui bahwa evaluasi kinerja sistem menggunakan data pengujian baru dengan jumlah 50 citra pada tiap kelasnya. Sehingga dapat diketahui bahwa total data yang digunakan pada pengujian ini sejumlah 1.650 citra. Sedangkan total data pelatihan yang digunakan yaitu total keseluruhan data utama, yaitu 16.854 citra. Pengujian ini menghasilkan evaluasi nilai akurasi sebesar 54%, presisi sebesar 61%, *recall* sebesar 54%, dan *f1-score* sebesar 53%.

4.5 Hasil Uji Coba Fitur

Uji coba fitur dilakukan untuk mengidentifikasi kontribusi relatif dari berbagai jenis ekstraksi fitur dalam meningkatkan kinerja sistem. Melalui penggunaan variasi fitur seperti histogram warna, *Local Binary Patterns* (LBP), dan bentuk, uji coba ini bertujuan untuk mengevaluasi sejauh mana setiap fitur mempengaruhi akurasi, presisi, *recall*, dan *F1-score* sistem. Dengan membandingkan hasil kinerja dari setiap fitur maka informasi yang didapatkan dapat memberikan wawasan yang mendalam tentang pentingnya masing-masing fitur dalam representasi citra buah. Uji coba dilakukan pada data awal dengan menggunakan *split* data yang memiliki rasio 70:30. Untuk lebih jelasnya, disajikan *confusion matrix* dari beberapa hasil uji coba fitur.

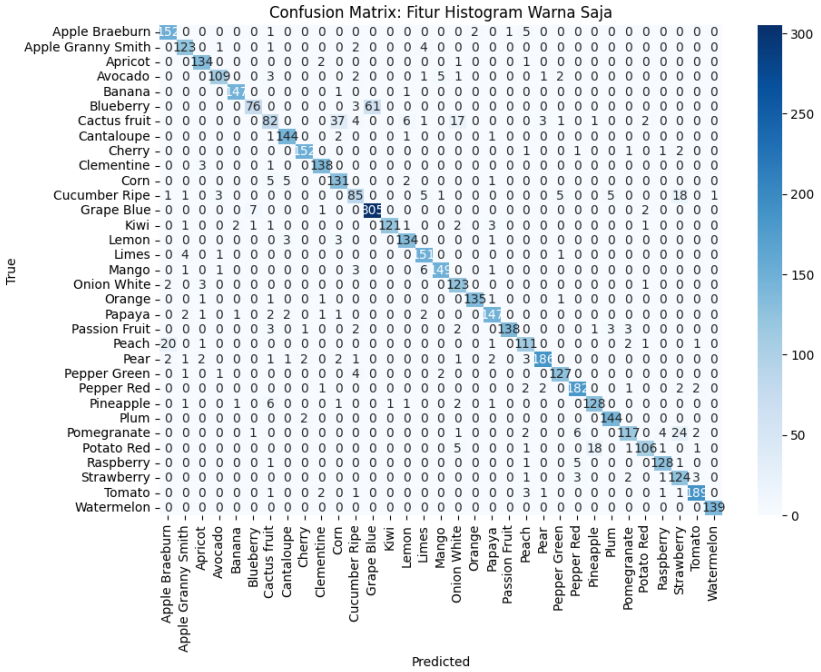

Gambar 4.5 *Confusion Matrix* Uji Coba Hanya dengan Fitur Histogram Warna

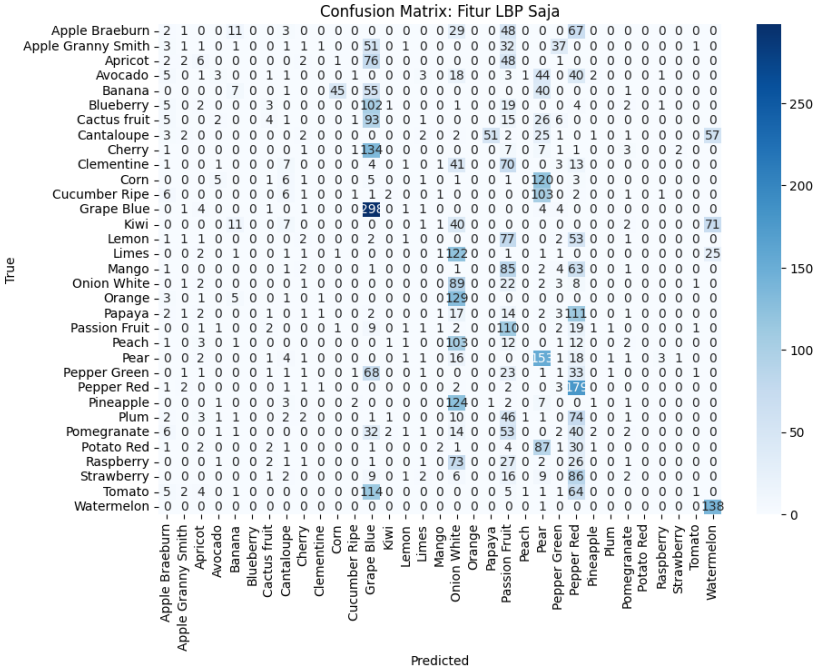

Gambar 4.6 *Confusion Matrix* Uji Coba Hanya dengan Fitur LBP

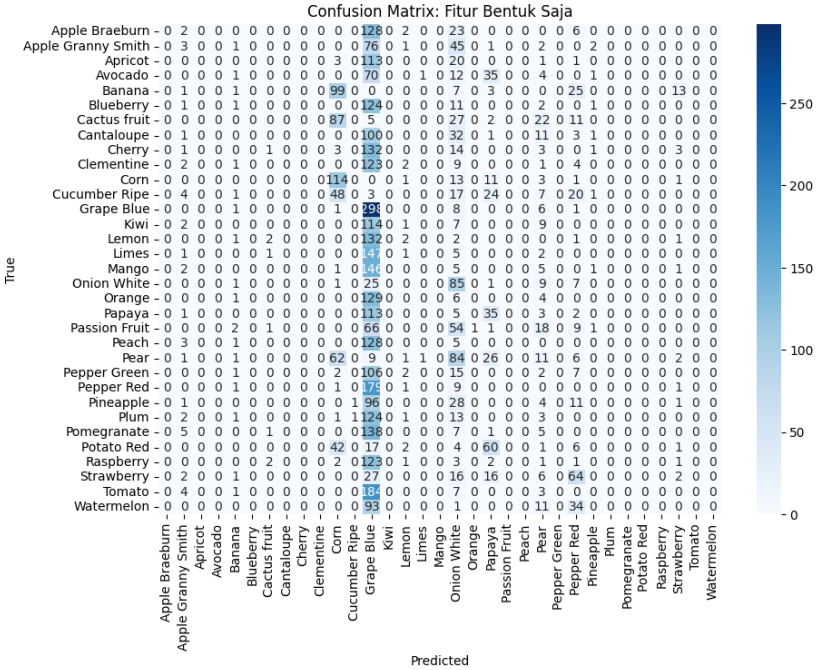

Gambar 4.7 *Confusion Matrix* Uji Coba Hanya dengan Fitur Bentuk

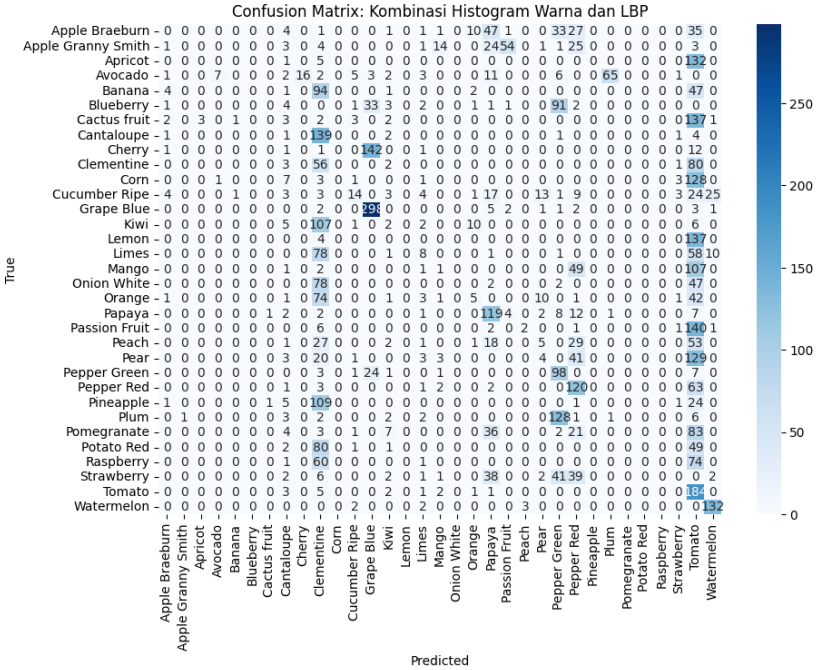

Gambar 4.8 *Confusion Matrix* Uji Coba Hanya dengan Fitur Histogram Warna dan LBP

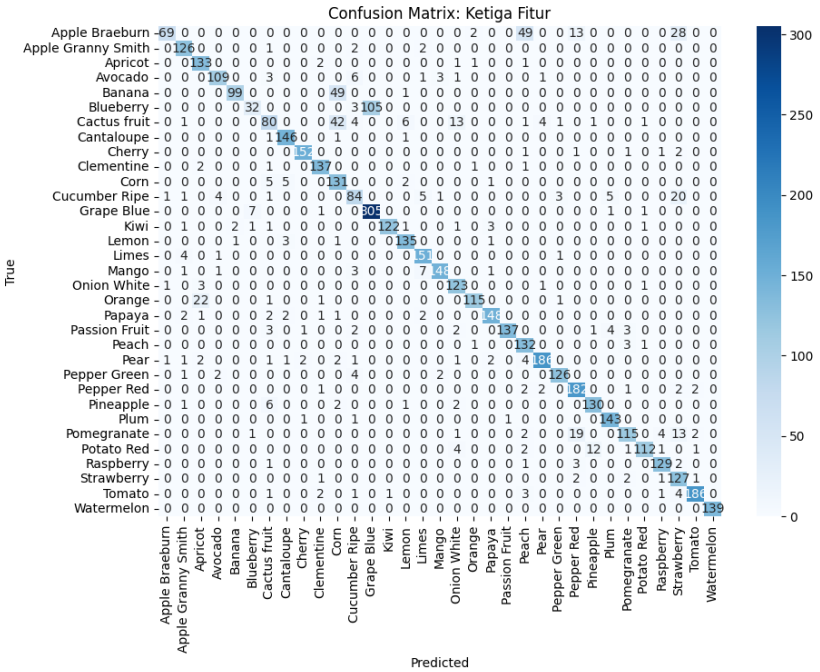

Gambar 4.9 *Confusion Matrix* Uji Coba Menggunakan Seluruh Fitur

Gambar 4.5 sampai 4.9 merupakan *confusion matrix* dari pengujian menggunakan fitur. Berdasarkan kelima *confusion matrix* tersebut, dapat diambil evaluasi dengan penjabaran yang ditunjukkan pada Tabel 4.7.

Tabel 4.7 Hasil Evaluasi Uji Coba Fitur

Uji Coba Fitur				
Uji coba	**Akurasi**	**Presisi**	**Recall**	**F1-score**
Histogram Warna	0.901127	0.904211	0.897023	0.896771
	90%	90%	90%	90%
LBP	0.19735	0.090463	0.158918	0.076968
	20%	9%	16%	8%
Bentuk	0.108957	0.030937	0.082708	0.033818
	11%	3%	8%	3%
Histogram warna dan LBP	0.207632	0.132026	0.170410	0.110381
	21%	13%	17%	11%
Histogram Warna, LBP, dan Bentuk	0.867905	0.88418	0.864130	0.860313
	87%	89%	86%	86%

Berdasarkan hasil evaluasi pada Tabel 4.7, dapat diketahui bahwa uji coba dengan fitur histogram warna saja memiliki kinerja yang signifikan, dengan akurasi sebesar 90%. Presisi dan recall juga relatif tinggi, masing-masing mencapai 90%. Namun, pengujian dengan hanya menggunakan fitur LBP, fitur bentuk, serta fitur histogram warna dan LBP menunjukkan kinerja yang jauh lebih rendah dari uji coba dengan hanya menggunakan ekstraksi fitur berupa histogram warna. Sedangkan pengujian yang mengkombinasikan seluruh fitur menunjukkan peningkatan kinerja, meskipun masih di bawah hasil evaluasi menggunakan fitur histogram warna. Pengujian yang menggunakan semua fitur, yaitu histogram warna, LBP, dan bentuk, memiliki akurasi sebesar 87%, presisi sebesar 89%, *recall* sebesar 86%, dan *f1-score* sebesar 86%.

4.6 Pembahasan

Data yang digunakan telah diuji menggunakan beberapa skenario pengujian. Evaluasi yang digunakan adalah *confusion matrix* dengan mengambil nilai akurasi, presisi, *recall*, dan *f1-score*. Ringkasan hasil dari beberapa pengujian yang telah dilakukan dapat dilihat pada Tabel 4.8.

Tabel 4.8 Ringkasan Hasil Uji Coba

Ringkasan Hasil Uji Coba					
Uji coba		**Hasil**			
		Akurasi	**Presisi**	***Recall***	***F1-score***
***Split* data**	70:30	87%	89%	86%	86%
	80:20	85%	87%	85%	84%
	90:10	84%	86%	83%	82%
K-fold	1	86%	80%	80%	80%
	2	87%	80%	80%	80%
	3	87%	80%	80%	80%
	4	88%	80%	80%	80%
	5	88%	80%	80%	80%
	6	86%	80%	80%	80%
	7	87%	80%	80%	80%
	8	87%	80%	80%	80%
	9	88%	80%	80%	80%
	10	89%	80%	80%	80%
Data Baru		54%	61%	54%	53%
Fitur	Histogram Warna	90%	90%	90%	90%
	LBP	20%	9%	16%	8%
	Bentuk	11%	3%	8%	3%
	Histogram warna dan LBP	21%	13%	17%	11%
	Histogram Warna, LBP, dan Bentuk	87%	89%	86%	86%

Uji coba yang pertama yaitu pengujian menggunakan *split* data yang dilakukan dalam tiga skenario, yaitu 70:30, 80:20, dan 90:10. Skenario pertama yaitu menggunakan data pelatihan dengan rasio 70:30 atau data pelatihan sebesar 11.797 dan data pengujian sebesar 5.057. Pengujian tersebut menghasilkan evaluasi akurasi sebesar 87%, presisi sebesar 89%, *recall* sebesar 86%, dan *f1-score* sebesar

86%. Skenario pengujian yang kedua dilakukan dengan menggunakan data yang memiliki rasio 80:20 atau dataset dengan total data pelatihan sebesar 13.483 dan total data pengujian sebesar 3.371. Pengujian tersebut menghasilkan evaluasi yang tidak memiliki perbedaan yang terlalu signifikan dengan pengujian yang pertama, yaitu nilai akurasi sebesar 85%, presisi sebesar 87%, *recall* sebesar 85%, dan *f1-score* sebesar 84%. Selanjutnya, pada skenario ketiga pengujian dilakukan dengan menggunakan data yang memiliki rasio 90:10 atau dataset dengan total data pelatihan sebesar 15.168 dan total data pengujian sebesar 1.686. Pengujian tersebut menghasilkan nilai yang hampir sama dengan 2 pengujian sebelumnya, yaitu mendapatkan evaluasi dengan nilai akurasi sebesar 84%, presisi sebesar 86%, *recall* sebesar 83%, dan *f1-score* sebesar 83%. Jadi dapat diambil kesimpulan bahwa pengujian menggunakan *split* data memiliki perbedaan hasil evaluasi yang tidak tidak terlalu signifikan. Evaluasi tertinggi dari pengujian menggunakan *split* data didapatkan pada pengujian menggunakan rasio 70:30 dan evaluasi terendah didapatkan pengujian dengan rasio 90:10.

Rasio 70:30 dipilih untuk digunakan dalam uji coba berikutnya, yaitu uji coba menggunakan *k-fold*. Rasio tersebut dipilih karena memiliki hasil evaluasi yang paling baik dari 2 rasio lannya. Uji coba *k-fold* dilakukan menggunakan 10 *fold* untuk evaluasi yang lebih rinci. Pengujian menggunakan data uji sebesar 30% dari total keseluruhan data, yang artinya pengujian ini menggunakan data uji sejumlah 5.057 citra buah dari 16.854 total keseluruhan citra, sedangkan 11.797 citra lainnya menjadi data latih. Hasil evaluasi dari 10 iterasi, didapatkan persentase hasil evaluasi akhir untuk akurasi sebesar 87%, pesisi sebesar 88%, *recall* sebesar

86%, dan *F1-Score* sebesar 86%. Nilai evaluasi terbaik didapatkan pada beberapa iterasi kesepuluh. Iterasi tersebut memiliki hasil evaluasi untuk akurasi sebesar 89%, pesisi sebesar 90%, *recall* sebesar 86%, dan *F1-Score* sebesar 86%. Perbedaan hasil evaluasi pada uji coba menggunakan *k-fold* disebabkan karena adanya unsur keberuntungan acak yang terlibat ketika pembagian data menjadi *fold-folds*. *Fold-folds* tertentu mungkin berisi pola atau karakteristik data yang membuatnya lebih mudah atau lebih sulit untuk diprediksi oleh model.

Uji coba yang terakhir yaitu menggunakan data baru. Pengujian ini bertujuan untuk mengetahui lebih dalam apakah sistem ini juga bekerja dengan baik pada kasus nyata. Oleh karena itu, dilakukanlah uji coba menggunakan data baru berupa citra buah dengan berbagai kondisi dan juga hasil tangkapan langsung oleh peneliti. Data tersebut akan diuji kembali menggunakan iterasi terbaik pada hasil *k-fold* pengujian sebelumnya. Jumlah citra yang digunakan pada uji coba ini adalah 50 citra buah pada tiap kelasnya dengan total keseluruhan 1.650 citra untuk data pengujian. Sedangkan total data pelatihan yang digunakan yaitu total keseluruhan data utama, yaitu 16.854 citra. Berdasarkan *confusion matrix*, didapatkan hasil evaluasi dengan nilai akurasi sebesar 54%, presisi sebesar 61%, *recall* sebesar 54%, dan *f1-score* sebesar 53%.

Uji coba sistem menggunakan data baru memiliki hasil evaluasi yang jauh lebih rendah dengan 2 skenario uji coba sebelumnya. Hal tersebut kemungkinan dapat disebabkan karena bias dalam data pelatihan. Bias dalam data pelatihan terjadi ketika data pelatihan tidak representatif dari situasi yang akan dihadapi model dalam penggunaan nyata. Sehingga, apabila data pengujian mencakup

variasi yang tidak ada dalam data pelatihan, model akan kesulitan mengenali pola yang tidak pernah dilihat sebelumnya. Untuk mengatasi masalah tersebut, dapat dilakukan dengan pengumpulan data yang lebih representatif sehingga dapat dipastikan bahwa data pelatihan mencakup berbagai kondisi, variasi, dan kasus yang mungkin dihadapi dalam dunia nyata. Selain itu, *pre-processing* dan ekstraksi fitur yang lebih kompleks juga dibutuhkan untuk mengatasi data yang lebih variatif. Hal tersebut dibutuhkan untuk meningkatkan kualitas data sebelum digunakan dalam pelatihan. Sehingga model dapat menangani data yang heterogen dengan lebih efektif. Pengujian menggunakan data baru membuktikan bahwa pada kasus nyata, sistem yang dirancang menghasilkan akurasi 54% apabila diberikan data dengan berbagai kondisi. Meskipun demikian, sistem ini dapat memberikan hasil yang lebih baik dengan hasil akurasi di atas 80% apabila input tunggal yang dilakukan menggunakan citra yang berisi buah tunggal dengan latar belakang yang bersih dan varietas yang sama dengan data pengujian.

Uji coba fitur dilakukan untuk mengidentifikasi kontribusi relatif dari berbagai jenis ekstraksi fitur dalam meningkatkan kinerja sistem. Dengan membandingkan hasil kinerja dari setiap fitur maka informasi yang didapatkan dapat memberikan wawasan yang mendalam tentang pentingnya masing-masing fitur dalam representasi citra buah. Uji coba ini menghasilkan evaluasi untuk fitur histogram warna saja sebesar 90% untuk akurasinya. Presisi dan *recall* juga relatif tinggi, masing-masing mencapai 90%. Namun, pengujian yang menggunakan ekstraksi fitur hanya berupa LBP, bentuk, serta histogram warna dan LBP menunjukkan kinerja yang jauh lebih rendah dari uji coba menggunakan ekstraksi

fitur histogram warna. Sedangkan pengujian yang mengkombinasikan seluruh fitur menunjukkan peningkatan kinerja, meskipun masih di bawah hasil evaluasi menggunakan fitur histogram warna. Pengujian yang menggunakan semua fitur, yaitu histogram warna, LBP, dan bentuk, memiliki akurasi sebesar 87%, presisi sebesar 89%, *recall* sebesar 86%, dan *f1-score* sebesar 86%. Dengan demikian, dapat disimpulkan bahwa fitur histogram warna memiliki kontribusi yang signifikan terhadap kinerja model klasifikasi ini, sementara fitur LBP dan bentuk kurang memberikan kontribusi yang signifikan.

Berdasarkan pemaparan-pemaparan sebelumnya, dapat dikatakan bahwa kinerja GNB pada sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah menunjukkan kinerja dengan akurasi rata-rata di atas 80%. Namun, pada data baru, akurasi menurun drastis hingga 54%. Hal ini menunjukkan bahwa model mungkin mengalami masalah *overfitting* atau kurang generalisasi pada data yang belum pernah dilihat sebelumnya. Sedangkan ekstraksi fitur berupa histogram warna, LBP, dan bentuk yang digunakan, dapat dilihat bahwa ekstraksi fitur histogram warna memberikan kontribusi yang signifikan dalam meningkatkan akurasi sistem, dengan akurasi mencapai 90% ketika hanya menggunakan fitur tersebut. Ekstraksi fitur LBP dan bentuk memiliki kontribusi yang lebih rendah dalam meningkatkan akurasi, dengan akurasi mencapai hanya 20% dan 11% masing-masing. Namun, kombinasi dari semua fitur (histogram warna, LBP, dan bentuk) memberikan akurasi sebesar 87%, yang menunjukkan bahwa gabungan fitur tersebut dapat meningkatkan performa sistem secara signifikan dibandingkan dengan menggunakan fitur tunggal.

Dalam konsep integrasi Islam, terdapat ketertarikan yang mendalam terhadap segala aspek kehidupan, termasuk pemahaman terhadap klasifikasi. Salah satu contoh yang menunjukkan hubungan ini terdapat dalam Surah Al-Baqarah ayat 173 :

اِنَّمَا حَرَّمَ عَلَيْكُمُ الْمَيْتَةَ وَالدَّمَ وَلَحْمَ الْخِنْزِيْرِ وَمَآ اُهِلَّ بِهٖ لِغَيْرِ اللّٰهِ ۚ فَمَنِ اضْطُرَّ غَيْرَ بَاغٍ وَّلَا عَادٍ فَلَآ اِثْمَ عَلَيْهِ ۗ اِنَّ اللّٰهَ غَفُوْرٌ رَّحِيْمٌ

“Sesungguhnya Allah SWT hanya mengharamkan bagimu bangkai, darah, daging babi, dan binatang yang (ketika disembelih) disebut (nama) selain Allah SWT tetapi Barang siapa dalam Keadaan terpaksa (memakannya) sedang Dia tidak menginginkannya dan tidak (pula) melampaui batas, Maka tidak ada dosa baginya. Sesungguhnya Allah SWT Maha Pengampun lagi Maha Penyayang” (Q.S. Al-Baqarah : 173)

Ayat tersebut mengandung pesan bahwa Allah SWT telah membagi makanan menjadi 2 jenis, yaitu makanan yang halal dan haram dengan memberikan klasifikasi yang jelas tentang apa yang diharamkan dalam makanan bagi umat Muslim. Diharamkan bagi umat Muslim untuk memakan makanan yang membahayakan, seperti bangkai binatang, darah yang mengalir, daging babi, dan hewan-hewan sembelihan untuk selain Allah SWT. Selain itu, Rasulullah juga bersabda bahwa Allah SWT menghalalkan 2 jenis bangkai dan darah sebagaimana yang dijelaskan pada hadits sahih berikut:

عن عبد الله بن عمر رضي الله عنهما قال: قال رسول الله صلى الله عليه وسلم : أُحِلَّتْ لكم مَيْتَتَانِ وَدَمَانِ، فأما الميتتان: فَالْجَرَادُ والْحُوتُ، وأما الدَّمَانِ: فالكبد والطحال

"Dari Ibnu Umar RA dia berkata, Rasulullah SAW bersabda, "Dihalalkan bagi kami dua bangkai dan dua darah. Dua bangkai yaitu belalang dan ikan. Adapun dua darah yaitu hati dan limpa." (H.R. Ahmad dan Ibnu Majah)

Hadits di atas merupakan hadits riwayat Ahmad dan Ibnu Majah yang memberikan penjelasan lebih dalam untuk surah Al-Baqarah ayat 173. Dapat diketahui bahwa bangkai adalah sesuatu kotor sehingga sudah jelas apabila daging bangkai tidak boleh dikonsumsi oleh umat Islam, kecuali bangkai ikan dan belalang sebagaimana yang dijelaskan dalam hadits tersebut. Fatwa Majelis Ulama Indonesia Nomor Kep-13/MUI/ IV/Tahun 2000 tentang Makan dan Budidaya Cacing dan Jangkrik, menempatkan belalang seperti halnya jangkrik, yaitu sejenis serangga yang boleh (mubah/ halal) dikonsumsi sepanjang tidak menimbulkan kerugian (mudharat).

Integrasi islam dalam kehidupan sehari-hari mencakup tentang pemilihan sumber makanan yang halal, memeriksa kandungan makanan untuk memastikan kehalalannya, serta memahami bahwa dalam keadaan darurat, ada kelonggaran yang diberikan. Salah satu makanan halal yang kaya akan nutrisi adalah buah-buahan. Namun Allah SWT juga menekankan aturan tentang urusan makan dan minum. Karena pada masa Jahiliyah, manusia hanya mengetahui bahwa makan adalah kegiatan agar perut merasa kenyang. Sehingga orang-orang pada jaman itu hanya makan makanan yang mengenyangkan saja, bukan makan makanan baik yang memiliki nilai gizi dan vitamin. Oleh karena itu, Allah SWT menurunkan Q.S. Al-A’raf Ayat 31 yang berisi tentang aturan makan dan minum. Ayat tersebut adalah sebagai berikut:

يٰبَنِيْٓ اٰدَمَ خُذُوْا زِيْنَتَكُمْ عِنْدَ كُلِّ مَسْجِدٍ وَّكُلُوْا وَاشْرَبُوْا ۚ وَلَا تُسْرِفُوْٓا ۚ اِنَّهٗ لَا يُحِبُّ الْمُسْرِفِيْنَ

“Wahai anak cucu Adam, pakailah pakaianmu yang indah pada setiap (memasuki) masjid dan makan serta minumlah, tetapi janganlah berlebihan. Sesungguhnya Dia tidak menyukai orang-orang yang berlebihan.” (Q.S. Al-A’raf:31)

Dalam ayat tersebut, Allah SWT menerangkan bahwa dengan tidak berlebihan dalam mengkonsumsi makanan dan minuman merupakan salah satu cara untuk menjaga kesehatan agar manusia senantiasa beribadah kepada Allah SWT dengan baik. Allah SWT memerintahkan untuk tidak berlebihan dalam makan dan minum karena mengkonsumsi makanan atau minuman dengan porsi yang berlebihan hanya akan menimbulkan penyakit. Dengan demikian, sudah selayaknya masyarakat mengetahui bahwa monitoring asupan memiliki peran penting dalam kehidupan. Jangan sampai, makanan yang seharusnya menjadi sumber energi malah berbalik menjadi sumber penyakit bagi tubuh. Konsep dasar gizi seimbang menekankan bahwa untuk hidup dan meningkatkan kualitas hidup, setiap orang membutuhkan lima kelompok zat gizi yaitu: karbohidrat, protein, lemak, vitamin dan mineral, dalam jumlah yang cukup, tidak berlebihan dan juga tidak kekurangan. Oleh karena itu, sistem ini dirancang untuk memudahkan penggunanya dalam melakukan monitoring asupan gizi mereka. Sehingga tercipta asupan gizi seimbang demi kualitas hidup yang lebih baik.

Allah SWT akan senantiasa memberikan kemudahan pada kesulitan yang dihadapi oleh orang-orang yang dengan ikhlas memberi jalan kemudahan bagi orang lain. Seperti ditegaskan oleh Rasulullah SAW dalam sebuah hadits yang diriwayatkan oleh Imam Muslim dari Abu Hurairah:

مَنْ نَفَّسَ عَنْ مُؤْمِنٍ كُرْبَةً مِنْ كُرَبِ الدُّنْيَا نَفَّسَ اللَّهُ عَنْهُ كُرْبَةً مِنْ كُرَبِ يَوْمِ الْقِيَامَةِ وَمَنْ يَسَّرَ عَلَى مُعْسِرٍ يَسَّرَ اللَّهُ عَلَيْهِ فِى الدُّنْيَا وَالآخِرَةِ

"Siapa yang menyelesaikan kesulitan seorang mukmin dari berbagai kesulitan-kesulitan dunia, niscaya Allah SWT akan memudahkan kesulitan-kesulitannya pada

hari kiamat. Siapa yang memudahkan orang yang sedang kesulitan niscaya Allah SWT mudahkan baginya di dunia dan akhirat." (HR Imam Muslim)

Setiap individu, sudah seharusnya dapat menjadi orang yang mampu memberi manfaat pada orang lain, karena seperti yang diketahui bahwa sebaik-baik manusia adalah manusia yang dapat memberi manfaat kepada sesamanya. Terkait dengan tolong-menolong, Allah SWT telah mengingatkan untuk saling membantu hanya dalam hal kebaikan dan bisa meningkatkan ketakwaan kepada Allah SWT.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah dimulai dengan input dataset "*Fruit Classification*" yang kemudian dibagi menjadi data *training* dan *testing*. Selanjutnya, dilakukan *pre-processing* berupa *grayscale*, *thresholding*, dan *contouring*, diikuti dengan ekstraksi fitur histogram warna, LBP, dan bentuk. Nilai-nilai fitur tersebut dilatih menggunakan algoritma GNB untuk mendapatkan pola klasifikasi. Proses ini diulang pada pengujian menggunakan *split* data, *k-fold*, variasi fitur, dan data baru.

Berdasarkan hasil pengujian yang dilakukan, dapat disimpulkan bahwa kinerja sistem temu kembali informasi nutrisi berbasis klasifikasi citra buah menggunakan metode GNB menunjukkan hasil evaluasi dengan nilai akurasi rata-rata di atas 80% pada pengujian menggunakan metode *split* data dan *k-fold cross-validation*. Namun, terdapat penurunan yang signifikan dalam akurasi saat menghadapi data baru yang tidak pernah dilihat sebelumnya, menurun hingga hanya mencapai 54%. Hal ini mengindikasikan adanya masalah *overfitting* atau kurangnya generalisasi pada data baru, yang perlu diperhatikan untuk meningkatkan kinerja sistem. Pengujian menggunakan data baru membuktikan bahwa pada kasus nyata, sistem yang dirancang menghasilkan evaluasi berupa akurasi di bawah 60% apabila diberikan data dengan berbagai kondisi. Meskipun demikian, sistem ini dapat memberikan hasil akurasi yang lebih tinggi dengan besar 80% ke atas, apabila input tunggal yang dilakukan menggunakan citra yang berisi

buah tunggal dengan latar belakang yang bersih dan varietas yang sama dengan data pengujian. Pengujian fitur juga menunjukkan bahwa fitur histogram warna memberikan kontribusi yang paling signifikan dalam meningkatkan akurasi sistem, dengan akurasi mencapai 90% ketika hanya menggunakan fitur tersebut. Sementara itu, LBP dan bentuk memiliki kontribusi yang lebih rendah dalam meningkatkan akurasi. Namun, kombinasi dari semua fitur (histogram warna, LBP, dan bentuk) dapat memberikan peningkatan performa yang signifikan.

5.2 Saran

Berdasarkan hasil hasil yang telah didapatkan, terdapat beberapa saran dari penulis untuk meningkatkan kinerja sistem. Pertama yaitu penambahan data yang lebih representatif dengan mencakup berbagai kondisi, variasi, dan kasus yang mungkin dihadapi dalam dunia nyata untuk memastikan bahwa data pelatihan mencerminkan distribusi data yang sebenarnya. Kedua yaitu meningkatkan *pre-processing* dan ekstraksi fitur untuk mengeksplorasi teknik ekstraksi fitur yang lebih kompleks atau fitur-fitur tambahan yang dapat meningkatkan representasi citra buah dan membantu meningkatkan kinerja sistem. Terakhir yaitu pengembangan sistem ke dalam bentuk mobile agar sistem dapat digunakan dengan lebih fleksibel. Dengan mengimplementasikan saran-saran tersebut, diharapkan sistem dapat memberikan hasil yang lebih konsisten dan akurat dalam mengklasifikasikan citra buah serta memberikan informasi nutrisi yang lebih handal dan berguna bagi pengguna.

DAFTAR PUSTAKA

Abdi, M. F., . K., & Kurniawan, M. P. (2022). Local Binary Pattern Untuk Ektraksi Tekstur Gambar Wajah Menggunakan Masker Dan Tanpa Masker. *Technologia : Jurnal Ilmiah*, *13*(2), 108. https://doi.org/10.31602/tji.v13i2.6275

Aswatini, M. N. dan F. (2008). *Konsumsi Sayur dan Buah di Masyarakat Dalam Konteks Pemenuhan Gizi Seimbang*. *Ill*(2), 97–119.

Backar, S. P., Purnawansyah, P., Darwis, H., & Astuti, W. (2023). Hybrid Fourier Descriptor Naïve Bayes dan CNN pada Klasifikasi Daun Herbal. *Jurnal Informatika: Jurnal Pengembangan IT*, *8*(2), 126–133. https://doi.org/10.30591/jpit.v8i2.5186

Bernadetha, S. (2022). *Perhitungan Objek Pada Citra Menggunakan TeknikThresholding*. https://informatika.stei.itb.ac.id/~rinaldi.munir/Citra/2022-2023/Makalah/Makalah/Makalah-IF4073-Citra-Sem1-2022 (16).pdf

Dewi, T. (2014). *Kualitas Es Krim dengan Kombinasi Wortel (Daucus carota L.) dan Tomat (Lycopersicum esculentum Mill.)*. skripsi. uaty. http://e-journal.uajy.ac.id/6537/

Favoria Gusa, R. (2013). Pengolahan Citra Digital Untuk Menghitung Luas Daerah Bekas Penambangan Timah. *Jurnal Nasional Teknik Elektro*, *2*(2), 27–34. https://doi.org/10.20449/jnte.v2i2.71

Gayathri, B. M., & Sumathi, C. P. (2016). An Automated Technique using Gaussian Naïve Bayes Classifier to Classify Breast Cancer. *International Journal of Computer Applications*, *148*(6), 16–21. https://doi.org/10.5120/ijca2016911146

Gharajeh, M. S. (2017). To Measure the Perimeter of an Ellipse Using Image Processing and Mathematical Reasoning. *International Journal of Research Studies in Computer Science and Engineering*, *4*(4), 15–21. https://doi.org/10.20431/2349-4859.0404002

Griffis, J. C., Allendorfer, J. B., & Szaflarski, J. P. (2016). Voxel-based Gaussian naïve Bayes classification of ischemic stroke lesions in individual T1-weighted MRI scans. *Journal of Neuroscience Methods*, *257*, 97–108. https://doi.org/10.1016/j.jneumeth.2015.09.019

Irwan Budi Santoso, S. S., & Supriyono, S.Kom., M. K. (2017). Optimalisasi Dimensi Image Untuk Meningkatkan Akurasi Naïve Bayes Classifier Dengan Menggunakan Interpolasi. *Kementerian Agama Lembaga Penelitian Dan Pengabdian Kepada Masyarakat Universitas Islam Negeri Maulana Malik Ibrahim Malang*, *197701032011011000*.

Kamel, H., Abdulah, D., & Al-Tuwaijari, J. M. (2019). Cancer Classification Using Gaussian Naive Bayes Algorithm. *Proceedings of the 5th International Engineering Conference, IEC 2019*, 165–170. https://doi.org/10.1109/IEC47844.2019.8950650

Khulaimah, M. (2018). *Perilaku Manusia Atas Nikmat Allah SWT Dan Ketiadaannya Dalam Al-Qur'an*. http://repository.uinjkt.ac.id/dspace/handle/123456789/43211

Mifaro, P. P., & Syahputra, M. R. (2023). *Konsep " Nikmat " dalam Al-Qur ' an*. *3*(3), 439–446.

Paraijun, F., Aziza, R. N., & Kuswardani, D. (2022). Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah. *Kilat*, *11*(1), 1–9. https://doi.org/10.33322/kilat.v10i2.1458

Purwanto, S. D., & Santoso, I. B. (2017). Sistem Identifikasi Kandungan Boraks pada Bakso Daging Sapi Berbasis Android Menggunakan Algoritma Naive Bayes Classifier. *Matics*, *9*(1), 33. https://doi.org/10.18860/mat.v9i1.3954

Saidi, I. A., Azara, R., & N, S. R. (2022). Nutrisi dan Komponen Bioaktif pada Sayuran Daun. In *Nutrisi dan Komponen Bioaktif pada Sayuran Daun*. https://doi.org/10.21070/2022/978-623-464-017-5

Saputra, A. (2019). Klasifikasi Pengenalan Buah Menggunakan Algoritma Naive Baiyes. *Jurnal Resistor (Rekayasa Sistem Komputer)*, *2*(2), 83–88.

Shihab, M. Q. (2002). *Tafsir Al-Mishbah : Pesan, Kesan dan Keserasian Al-Qur'an*. *7*.

Subrata, G. (2009). Klasifikasi Bahan Pustaka. *Universitas Negeri Malang*, *Ddc*, 1–13.

Takashimizu, Y., & Iiyoshi, M. (2016). New parameter of roundness R: circularity corrected by aspect ratio. *Progress in Earth and Planetary Science*, *3*(1). https://doi.org/10.1186/s40645-015-0078-x

Wijaya, N., & Ridwan, A. (2019). *Klasifikasi Jenis Buah Apel Dengan Metode K-Nearest Neighbors*. *08*, 74–78.

Yohannes, Y., Pribadi, M. R., & Chandra, L. (2020). Klasifikasi Jenis Buah dan Sayuran Menggunakan SVM Dengan Fitur Saliency-HOG dan Color Moments. *Elkha*, *12*(2), 125. https://doi.org/10.26418/elkha.v12i2.42160

LAMPIRAN

Penjabaran Hasil Uji Coba Menggunakan *K-fold*

No.	Lipatan Ke-	Image Path	Actual	Predicted	TP	TN	FP	FN
1	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_103.jpg	Apple Braeburn	Apple Braeburn	1	0	0	0
2	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_119.jpg	Apple Braeburn	Strawberry	0	0	1	1
3	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_130.jpg	Apple Braeburn	Strawberry	0	0	1	1
4	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_146.jpg	Apple Braeburn	Apple Braeburn	1	0	0	0
5	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_147.jpg	Apple Braeburn	Strawberry	0	0	1	1
6	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_157.jpg	Apple Braeburn	Apple Braeburn	1	0	0	0
7	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_159.jpg	Apple Braeburn	Strawberry	0	0	1	1
8	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_185.jpg	Apple Braeburn	Apple Braeburn	1	0	0	0
9	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_188.jpg	Apple Braeburn	Apple Braeburn	1	0	0	0
10	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_199.jpg	Apple Braeburn	Peach	0	0	1	1
11	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_201.jpg	Apple Braeburn	Apple Braeburn	1	0	0	0
12	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_202.jpg	Apple Braeburn	Strawberry	0	0	1	1
13	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_203.jpg	Apple Braeburn	Strawberry	0	0	1	1
14	1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Apple Braeburn\Apple Braeburn_223.jpg	Apple Braeburn	Apple Braeburn	1	0	0	0
...	...	...	...	...	...	...	...	...
16854	10	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Watermelon\Watermelon_81.jpg	Watermelon	Watermelon	1	0	0	0

Penjabaran Hasil Uji Coba Menggunakan *split* data 70:30

No.	Image Path	Actual	Predicted	TP	TN	FP	FN
1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Pear\Pear_53.jpg	Pear	Pear	1	0	0	0
2	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Limes\Limes_295.jpg	Limes	Limes	1	0	0	0
3	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Grape Blue\Grape Blue_5_52.jpg	Grape Blue	Grape Blue	1	0	0	0
4	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cucumber Ripe\Cucumber Ripe_223.jpg	Cucumber Ripe	Strawberry	0	0	1	1
5	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Papaya\Papaya_338.jpg	Papaya	Papaya	1	0	0	0
6	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Banana\Banana_354.jpg	Banana	Banana	1	0	0	0
7	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Orange\Orange_152.jpg	Orange	Orange	1	0	0	0
8	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cherry\Cherry_326.jpg	Cherry	Cherry	1	0	0	0
9	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Mango\Mango_103.jpg	Mango	Mango	1	0	0	0
10	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Mango\Mango_203.jpg	Mango	Mango	1	0	0	0
11	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Peach\Peach_442.jpg	Peach	Peach	1	0	0	0
12	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Tomato\Tomato_58.jpg	Tomato	Tomato	1	0	0	0
13	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Potato Red\Potato Red_96.jpg	Potato Red	Potato Red	1	0	0	0
12	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cherry\Cherry_379.jpg	Cherry	Cherry	1	0	0	0
...	...	...	...	...	...	...	...
5057	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Mango\Mango_321.jpg	Mango	Mango	1	0	0	0

Penjabaran Hasil Uji Coba Menggunakan *split* data 80:20

No.	Image Path	Actual	Predicted	TP	TN	FP	FN
1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Pear\Pear_53.jpg	Pear	Pear	1	0	0	0
2	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Limes\Limes_295.jpg	Limes	Limes	1	0	0	0
3	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Grape Blue\Grape Blue_5_52.jpg	Grape Blue	Grape Blue	1	0	0	0
4	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cucumber Ripe\Cucumber Ripe_223.jpg	Cucumber Ripe	Strawberry	0	0	1	1
5	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Papaya\Papaya_338.jpg	Papaya	Papaya	1	0	0	0
6	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Banana\Banana_354.jpg	Banana	Banana	1	0	0	0
7	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Orange\Orange_152.jpg	Orange	Orange	1	0	0	0
8	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cherry\Cherry_326.jpg	Cherry	Cherry	1	0	0	0
9	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Mango\Mango_103.jpg	Mango	Mango	1	0	0	0
10	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Mango\Mango_203.jpg	Mango	Mango	1	0	0	0
11	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Peach\Peach_442.jpg	Peach	Peach	1	0	0	0
12	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Tomato\Tomato_58.jpg	Tomato	Tomato	1	0	0	0
13	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Potato Red\Potato Red_96.jpg	Potato Red	Potato Red	1	0	0	0
14	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cherry\Cherry_379.jpg	Cherry	Cherry	1	0	0	0
...		...	...	...	...	...	...
3371	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Plum\Plum_120.jpg	Plum	Plum	1	0	0	0

Penjabaran Hasil Uji Coba Menggunakan *split* data 90:10

No.	Images Path	Actual	Predicted	TP	TN	FP	FN
1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Pear\Pear_53.jpg	Pear	Pear	1	0	0	0
2	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Limes\Limes_295.jpg	Limes	Limes	1	0	0	0
3	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Grape Blue\Grape Blue_5_52.jpg	Grape Blue	Grape Blue	1	0	0	0
4	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cucumber Ripe\Cucumber Ripe_223.jpg	Cucumber Ripe	Strawberry	0	0	1	1
5	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Papaya\Papaya_338.jpg	Papaya	Papaya	1	0	0	0
6	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Banana\Banana_354.jpg	Banana	Banana	1	0	0	0
7	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Orange\Orange_152.jpg	Orange	Orange	1	0	0	0
8	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cherry\Cherry_326.jpg	Cherry	Cherry	1	0	0	0
9	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Mango\Mango_103.jpg	Mango	Mango	1	0	0	0
10	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Mango\Mango_203.jpg	Mango	Mango	1	0	0	0
11	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Peach\Peach_442.jpg	Peach	Peach	1	0	0	0
12	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Tomato\Tomato_58.jpg	Tomato	Tomato	1	0	0	0
13	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Potato Red\Potato Red_96.jpg	Potato Red	Potato Red	1	0	0	0
14	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Cherry\Cherry_379.jpg	Cherry	Cherry	1	0	0	0
...		...	...	...	...	...	...
1686	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Pepper Green\Pepper Green_277.jpg	Pepper Green	Pepper Green	1	0	0	0

Penjabaran Hasil Uji Coba Menggunakan Data Baru

No.	Images Path	Actual	Predicted	TP	TN	FP	FN
1	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_0.jpg	Apple Braeburn	Peach	0	0	1	1
2	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_11.jpg	Apple Braeburn	Peach	0	0	1	1
3	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_13.jpg	Apple Braeburn	Peach	0	0	1	1
4	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_15.jpg	Apple Braeburn	Peach	0	0	1	1
5	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_17.jpg	Apple Braeburn	Peach	0	0	1	1
6	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_19.jpg	Apple Braeburn	Peach	0	0	1	1
7	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_2.jpg	Apple Braeburn	Peach	0	0	1	1
8	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_21.jpg	Apple Braeburn	Peach	0	0	1	1
9	d:/Documents/A SKRIPSI ZULFA/PROGRAM/baru/Data Baru - Salin\Apple Braeburn\AppleBraeburn2_23.jpg	Apple Braeburn	Peach	0	0	1	1
...		...	...	...	...	...	...
1686	d:/Documents/A SKRIPSI ZULFA/PROGRAM/train/train new\Pepper Green\Pepper Green_277.jpg	Pepper Green	Pepper Green	1	0	0	0