



Perbandingan Performa Support Vector Machine (SVM) dan k-Nearest Neighbors (kNN) dalam Memverifikasi Orientasi Material

Tugas Akhir

**Oleh:
Eldio Utama (4212111063)**

**Program Studi Teknik Mekatronika
Jurusan Teknik Elektro
Politeknik Negeri Batam
2022**

Pernyataan Keaslian Tugas Akhir

Saya yang bertandatangan dibawah ini menyatakan bahwa isi sebagian maupun keseluruhan Tugas Akhir saya yang berjudul : “Perbandingan Performa Support Vector Machine (SVM) dan k-Nearest Neighbors (kNN) dalam Memverifikasi Orientasi Material” adalah **hasil karya sendiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diizinkan**, dan **bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri**. Semua referensi yang dikutip atau dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan saya ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Batam,02 Jan. 25



Eldio Utama

NIM: 4212111063

Lembar Pengesahan

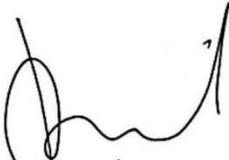
Tugas Akhir disusun untuk memenuhi salah satu syarat memperoleh gelar
Sarjana Terapan Teknik (S.Tr.T)
di
Politeknik Negeri Batam

Oleh:
Eldio Utama (4212111063)



Tanggal Sidang: 23 January, 2025

Disetujui oleh :



1. Daniel Sutopo Pamungkas, S.T.,M.T., Ph.D
NIK: 100006



1. Eko Rudiawan Jamzuri, S.ST.,M.Sc
NIK: 113117



2. Fadli Firdaus, S.Pd.,M.Pd
NIK: 122271

Perbandingan Performa Support Vector Machine (SVM) dan k-Nearest Neighbors (kNN) dalam Memverifikasi Orientasi Material

Abstrak

Dalam manufaktur otomatis, memverifikasi orientasi bahan sangat penting untuk memastikan perakitan produk berjalan tanpa kesalahan. Misalnya, dalam industri minuman, orientasi material yang salah, seperti tutup botol, dapat menyebabkan kegagalan dalam proses pengemasan, yang mengakibatkan botol tidak tersegel dengan benar yang dapat membahayakan kualitas dan keamanan produk. Penelitian ini membandingkan kinerja algoritma Support Vector Machine (SVM) dan k-Nearest Neighbors untuk memverifikasi orientasi material melalui inspeksi optik otomatis. Gambar diproses menggunakan Inception V3 Convolutional Neural Network (CNN) untuk mengekstrak fitur gambar yang relevan, yang kemudian diklasifikasikan menggunakan algoritme SVM dan kNN. Hasilnya, kedua metode tersebut mencapai kinerja klasifikasi yang sempurna, dengan akurasi klasifikasi, presisi, recall, dan F1-score sebesar 1,0. Namun, kNN menunjukkan efisiensi komputasi yang lebih unggul, dengan waktu pelatihan 1,126 detik dan waktu pengujian 0,713 detik, dibandingkan dengan waktu pelatihan SVM yang mencapai 3,101 detik dan waktu pengujian 1,479 detik. Hasil ini menunjukkan bahwa meskipun kedua metode tersebut sangat efektif untuk verifikasi orientasi material, kNN menawarkan keuntungan yang signifikan dalam hal kecepatan komputasi, sehingga lebih cocok untuk aplikasi real-time. Implikasi dari penelitian ini menyoroti potensi untuk mengintegrasikan metode yang diusulkan dalam aplikasi industri, mempromosikan peningkatan efisiensi dan mengurangi tingkat kesalahan dalam jalur perakitan otomatis

Kata kunci: Inspeksi Optik Otomatis, Permulaan V3, Jaringan Syaraf Tiruan Konvolusional, Machine Vector Machine, k-Nearest Neighbor.

Performance Comparison of Support Vector Machine (SVM) and k-Nearest Neighbors (kNN) in Verifying Material Orientation

Abstract

In automated manufacturing, verifying material orientation is essential to ensure the product assembly proceeds without errors. For instance, in the beverage industry, incorrect orientation of materials, such as bottle caps, can lead to failures in the packaging process, resulting in improperly sealed bottles that may compromise product quality and safety. This study compares the performance of Support Vector Machine (SVM) and k-Nearest Neighbors algorithms for verifying material orientation verification through automated optical inspection. The images were processed using the Inception V3 Convolutional Neural Network (CNN) to extract relevant image features, which were then classified using SVM and kNN algorithms. As a result, both methods achieved perfect classification performance, with classification accuracy, precision, recall, and F1-score of 1.0. However, kNN demonstrated superior computational efficiency, with a training time of 1.126 seconds and a testing time of 0.713 seconds, compared to SVM's training time of 3.101 seconds and testing time of 1.479 seconds. These results indicate that while both methods are highly effective for material orientation verification, kNN offers significant advantages in terms of computational speed, making it more suitable for real-time applications. The implications of this study highlight the potential for integrating the proposed method in industrial applications, promoting enhanced efficiency and reducing error rates in automated assembly lines

Keywords: Automated Optical Inspection, Inception V3, Convolutional Neural Network, Support Vector Machine, k-Nearest Neighbors

Kata Pengantar

Puji dan syukur saya panjatkan kepada Tuhan Yang Maha Esa atas segala rahmat dan karunia-Nya sehingga saya dapat menyelesaikan Tugas Akhir yang berjudul "Perbandingan Performa Support Vector Machine (SVM) dan k-Nearest Neighbors (kNN) dalam Memverifikasi Orientasi Material" dengan baik.

Penulisan Tugas Akhir ini dilakukan dalam rangka memenuhi salah satu syarat untuk memperoleh gelar Sarjana Terapan Teknik (S.Tr.T) di Program Studi Teknik Mekatronika, Jurusan Teknik Elektro, Politeknik Negeri Batam.

Saya menyadari bahwa tanpa bantuan dan bimbingan dari berbagai pihak, Tugas Akhir ini tidak akan dapat diselesaikan dengan baik. Oleh karena itu, saya mengucapkan terima kasih kepada:

1. Allah Subhanahu wata'ala karena dengan izinnya lah penulis dapat menyelesaikan tugas akhir ini
2. Orang tua dan keluarga saya yang telah memberikan bantuan dukungan material dan moral.
3. Bapak Eko Rudiawan Jamzuri, S.ST. M.Sc. selaku dosen pembimbing yang telah menyediakan waktu, tenaga, dan pikiran untuk mengarahkan saya dalam penyusunan Tugas Akhir ini.
4. Para dosen dan staff Program Studi Teknik Mekatronika yang telah membantu saya dalam perkuliahan dan penyelesaian Tugas Akhir ini.
5. Rekan-rekan mahasiswa Program Studi Teknik Mekatronika yang telah banyak membantu saya dalam menyelesaikan Tugas Akhir ini.

Akhir kata, saya berharap Tuhan Yang Maha Esa berkenan membalas segala kebaikan semua pihak yang telah membantu. Semoga Tugas Akhir ini dapat bermanfaat bagi pengembangan ilmu pengetahuan.

Batam, 02 Jan 2025

Eldio Utama

Daftar Isi

Pernyataan Keaslian Tugas Akhir	i
Lembar Pengesahan	ii
Abstrak	iii
<i>Abstract</i>	iv
Kata Pengantar	v
Daftar Isi	vi
Daftar Gambar	viii
Daftar Tabel	ix
Bab 1. Pendahuluan	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	3
1.3. Tujuan	3
1.4. Manfaat	3
1.5. Batasan	3
Bab 2. Tinjauan Pustaka	4
2.1. Pengumpulan data	4
2.2. Image Embedding	5
2.3. Support Vector Machine	7
2.4. K-Nearest Neighbors	9
2.5. Evaluasi Performa	10
Bab 3. Metodologi Penelitian	13
3.1. Perancangan	13
3.2. Flowchart Pengujian	14
Bab 4. Hasil dan Pembahasan	15
4.1. Data Hasil Penelitian	15
4.2. Pembahasan	16
Bab 5. Kesimpulan dan Saran	18
5.1. Kesimpulan	18

5.2. Saran	18
Daftar Pustaka.....	19
Biodata	20
Lampiran	21

Daftar Gambar

Gambar 1. Bottle caps feeding system	1
Gambar 2. Sample dataset	5
Gambar 3. Klasifikasi workflow orange data mining software	6
Gambar 4. Inception V3	7
Gambar 5. Klasifikasi Cross Validation.....	10
Gambar 6. Confusion Matrix	11
Gambar 7. Blok Diagram	Error! Bookmark not defined.
Gambar 8. Flow chart Pengujian	14
Gambar 9. Confusion Matrix	15

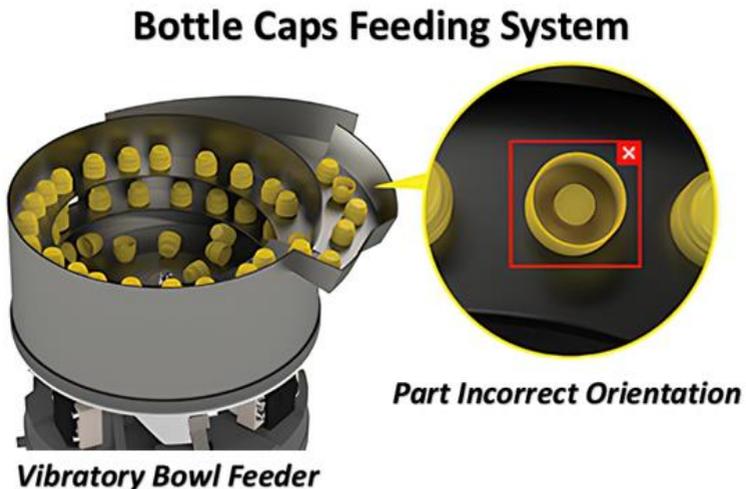
Daftar Tabel

Tabel 1. Comparison results of SVM and kNN on verifying material orientation. 16

Bab 1. Pendahuluan

1.1. Latar Belakang

Orientasi material memainkan peran penting dalam memastikan keberhasilan proses pemasangan dan pengemasan produk. Orientasi material yang salah dapat mengganggu proses ini, yang menyebabkan kegagalan. Misalnya, dalam pengemasan otomatis produk minuman, tutup botol harus dipoisiskan dan diorientasikan dengan benar untuk memastikan pengoperasian yang mulus. Biasanya, proses orientasi ini difasilitasi oleh pengumpan mangkuk, sistem getar yang dirancang untuk mengarahkan dan memberi makan bagian-bagian kecil secara otomatis di dalam jalur produksi [1]. Meskipun efektif, sistem pengumpan mangkuk tidak sempurna; kadang-kadang, tutup botol tetap salah orientasi pada konveyor, yang mengakibatkan kegagalan selama tahap pengemasan. Kesalahan orientasi seperti itu tidak hanya mengganggu proses pengemasan tetapi juga dapat membahayakan kualitas produk dan meningkatkan biaya operasional. Untuk mengilustrasikan masalah ini, gambaran visual dari tutup botol yang salah orientasi setelah proses pengumpan mangkuk disediakan pada Gambar 1, menyoroti potensi kesalahan orientasi yang dapat menyebabkan ketidaksejajaran dan kegagalan pada tahap selanjutnya.



Gambar 1. Bottle caps feeding system

Untuk mendeteksi kesalahan orientasi material, biasanya dilakukan proses penyortiran menggunakan sensor. Tujuan penyortiran ini adalah untuk mengeluarkan material yang orientasinya tidak sesuai dari jalur produksi agar tidak diteruskan ke tahapan berikutnya. Dalam beberapa kasus, sensor proximity dapat digunakan untuk melakukan penyortiran. Sebagai contoh, penelitian [2] menggunakan sensor proximity photoelectric dan sensor warna untuk menyortir apel merah dan hijau. Penelitian [3] menerapkan sensor proximity induktif untuk menyortir pecahan logam, sementara penelitian [4] juga menggunakan sensor proximity induktif untuk menyortir botol minuman berbahan plastik dan logam.

Meskipun sensor proximity dapat digunakan untuk menyortir material yang cacat, sensor ini tidak dapat diterapkan pada material tertentu, seperti tutup botol. Tutup botol memiliki bentuk yang unik, sehingga kesalahan orientasinya sulit dideteksi dengan sensor proximity biasa. Pengecekan orientasi hanya dapat dilakukan secara visual dengan memperhatikan permukaan botol yang terlihat dari sisi atas. Hal ini memotivasi penelitian ini untuk memverifikasi orientasi tutup botol menggunakan teknik visual. Proses verifikasi dilakukan dengan menangkap gambar tutup botol dari atas menggunakan sensor kamera. Selanjutnya, dilakukan proses pengenalan pola menggunakan algoritma machine learning untuk memprediksi apakah orientasi tutup botol tersebut sesuai. Pengenalan pola adalah pendekatan untuk mengelompokkan informasi input ke dalam item dan kelas-kelas sesuai dengan fokus utama [5].

Metode machine learning yang digunakan untuk pengenalan pola adalah SVM dan KNN. Kinerja kedua metode ini pernah dibandingkan untuk menentukan mana yang terbaik dalam kasus tertentu. Sebagai contoh, penelitian yang dilakukan oleh [3] membandingkan kinerja SVM dan KNN dalam menentukan kematangan buah kelapa sawit, dan menyimpulkan bahwa jumlah data yang sedikit dapat mempengaruhi validitas hasil prediksi dari kedua metode tersebut. Selain itu, studi komparatif [7] melakukan analisis model klasifikasi untuk deteksi pemalsuan gambar, namun menggunakan ekstraksi fitur yang kompleks. Beberapa penelitian juga menemukan kelemahan dalam penilaian performa yang hanya mengandalkan confusion matrix, tanpa mempertimbangkan aspek lain seperti precision dan recall.

Selain memiliki tujuan utama untuk memverifikasi orientasi material, penelitian ini juga bertujuan untuk membandingkan performa antara metode SVM dan KNN jika diimplementasikan pada kasus tersebut. Harapannya hasil penelitian ini dapat digunakan untuk mengembangkan sistem verifikasi orientasi material yang terintegrasi dengan line produksi secara realtime. Pada penelitian ini, perbandingan performa dilakukan pada hasil evaluasi yang mana itu adalah confusion matrix, presisi, akurasi, f1 score dan recall.

1.2. Rumusan Masalah

Perumusan masalah pada **Perbandingan Performa Metode Support Vector Machine dan K-Nearest Neighbors dalam Pengenalan Pola pada Gambar untuk Memverifikasi Orientasi Material** adalah :

- a) Bagaimana mengimplementasikan Metode SVM dan KNN dalam aplikasi *Orange Data Mining* untuk melakukan pengenalan pola pada gambar?
- b) Bagaimana perbandingan hasil akurasi antara Metode SVM dan KNN dalam pengenalan pola pada gambar untuk memverifikasi orientasi material?

1.3. Tujuan

Tujuan dari penelitian ini adalah:

- a) Mengimplementasikan metode SVM dan KNN pada pengenalan pola gambar kedalam aplikasi
- b) Membandingkan akurasi antara metode SVM dan KNN dalam pengenalan pola pada gambar untuk memverifikasi orientasi material.

1.4. Manfaat

Manfaat dari Penelitian adalah :

- a) Dapat dimanfaatkan dan digunakan oleh peneliti dan akademisi dalam mengembangkan metode dan teknik yang lebih baik dalam pengenalan pola pada gambar.
- b) Dapat memberikan wawasan bagi industri dalam menentukan metode yang efektif dan efisien dalam pengenalan pola *orientasi material*.

1.5. Batasan

Agar tujuan utama pembuatan alat ini tidak mengalami penyimpangan maka dibuatlah batasan masalah sebagai berikut:

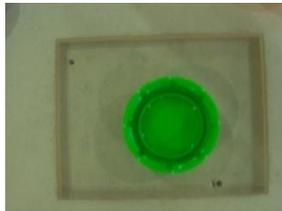
- a) Pengujian dilakukan tidak secara real-time, melainkan menggunakan test dataset yang telah disiapkan
- b) Dirancang untuk memverifikasi gambar tutup botol yang diambil dari jarak 20-25 cm
- c) Menggunakan metode SVM dan KNN

Bab 2. Tinjauan Pustaka

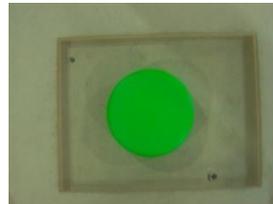
Penelitian ini dilakukan melalui tiga tahap utama. Tahap pertama adalah pengumpulan data tutup botol. Tahap kedua adalah ekstraksi fitur, di mana fitur-fitur diekstraksi dari setiap gambar menggunakan penyematan gambar Inception V3. Tahap ketiga difokuskan pada klasifikasi dan evaluasi, membandingkan kinerja SVM dan kNN.

2.1. Pengumpulan data

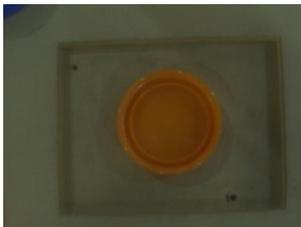
Dataset yang digunakan dalam penelitian ini terdiri dari 1500 dataset train gambar tutup botol dan 450 dataset test gambar, dengan 750 gambar correct orientation dan 750 gambar Incorrect, begitu pula dengan dataset test 225 correct orientation dan 225 incorrect orientation. Data yang dikumpulkan adalah tutup botol yang memiliki lima variasi warna, yaitu putih, biru, merah, oranye, dan hijau. Proses ini bertujuan untuk menguji apakah metode yang diusulkan dapat digunakan pada tutup botol yang memiliki warna yang berbeda. Gambar diambil menggunakan kamera industri Basler dan diambil dalam tiga kondisi pencahayaan: terang, redup, dan cahaya redup untuk meningkatkan variasi data.



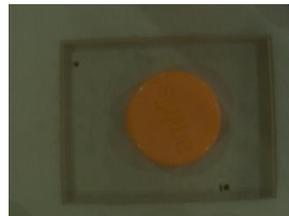
(a) Correct Orientation Terang



(a) Incorrect Orientation Terang



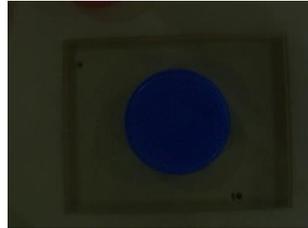
(b) Correct Orientation Sedang



(b) Incorrect Orientation Sedang



(c) Correct Orientation Redup



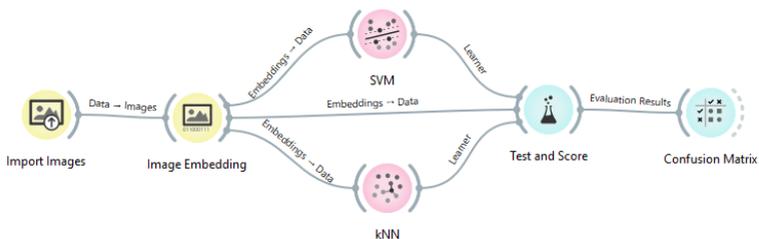
(c) Incorrect Orientation Redup

Gambar 2. Sample dataset

Contoh gambar yang mengilustrasikan orientasi yang benar dan salah dalam kondisi ini ditunjukkan pada Gambar 2. Secara khusus, Gambar 2 (a), (b), dan (c) menampilkan tutup botol di bawah pencahayaan yang terang, pencahayaan redup, dan pengaturan dalam ruangan yang redup, di mana cahaya minimal dari ruangan yang berdekatan menciptakan kondisi yang redup. Untuk menentukan pencahayaan dilakukan dengan mengatur konfigurasi lensa untuk menentukan pencahayaan yang digunakan pada kondisi pencahayaan terang konfigurasi lensa yang dilakukan atau parameter lensa adalah 2, sedang adalah 6, dan redup adalah 10.

2.2. Image Embedding

Image Embedding adalah metode ekstraksi fitur yang digunakan dalam penelitian ini untuk membuat representasi vektor gambar berdimensi tinggi. Tujuan dari penyematan gambar adalah untuk mengatur informasi visual secara efisien, yang memungkinkan model untuk menangkap fitur-fitur penting dari gambar [8]. Kami menggunakan arsitektur Inception V3 Convolutional Neural Network (CNN) sebagai dasar penyematan gambar untuk mengekstrak fitur gambar yang kompleks. Dengan menggunakan Inception V3, kami bertujuan untuk menangkap pola visual yang rinci yang penting untuk verifikasi orientasi material.



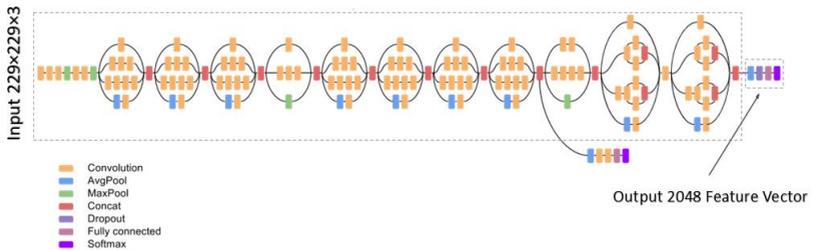
Gambar 3. Klasifikasi workflow orange data mining software

Kami merancang sebuah pipeline menggunakan Orange Data Mining untuk merampingkan alur kerja. Orange Data Mining adalah alat visualisasi dan analisis data sumber terbuka yang menyediakan lingkungan pemrograman visual. Alat ini memungkinkan pengguna untuk menghubungkan widget modular untuk tahap pemrosesan yang berbeda, sehingga lebih mudah untuk mengelola setiap langkah dalam proses klasifikasi. Gambar 3 mengilustrasikan alur kerja untuk memverifikasi orientasi tutup botol.

Proses pertama yang dilakukan adalah Import Image. Setelah pengumpulan data, dibuat folder utama bernama Orientation. Di dalam folder ini, dibuat dua subfolder: Correct dan Incorrect Orientation. Masing-masing subfolder kemudian diisi dengan gambar-gambar yang telah dikumpulkan sesuai kategorinya. Setelah struktur folder tersusun, proses import image dapat dilakukan. Selanjutnya, alur kerja dilanjutkan dengan proses Image Embedding.

Proses kedua adalah melakukan Image Embedding. Metode ini digunakan untuk menghasilkan representasi vektor berdimensi tinggi dari sebuah gambar dan dapat diaplikasikan dalam berbagai tugas computer vision [9]. Dalam penelitian ini, Image Embedding digunakan sebagai ekstraksi fitur untuk mengategorikan jenis, dengan memanfaatkan fitur Inception V3. Inception V3 adalah arsitektur CNN yang menggabungkan beberapa filter konvolusi untuk meningkatkan ekstraksi fitur di berbagai skala. Inception V3 menggunakan teknik regularisasi dan dropout untuk menghindari overfitting. Dibandingkan dengan Inception V2, arsitektur ini menawarkan ukuran grid yang lebih kecil dan

peningkatan efisiensi konvolusi. Peningkatan pada Inception V3 dapat mengurangi sumber daya komputasi dengan tetap mempertahankan akurasi yang tinggi [9].



Gambar 4. Inception V3

Dalam proses ekstraksi fitur, setiap gambar input diubah ukurannya menjadi 299x299 piksel agar sesuai dengan dimensi input Inception V3. Setelah diubah ukurannya, gambar diproses melalui seluruh arsitektur Inception V3, seperti yang ditunjukkan pada Gambar 4. Arsitektur ini terdiri atas beberapa tahap, termasuk lapisan input di mana konvolusi awal dan max-pooling menangani prapemrosesan dasar seperti tepi dan sudut, sementara lapisan lebih dalam menangkap fitur yang lebih kompleks dan spesifik seperti tekstur, bentuk, dan pola yang sulit ditangkap oleh analisis RGB sederhana. Selanjutnya, gambar melewati modul Inception A, B, dan C, di mana gambar akan dibagi menjadi kategori A dan B sebagai correct orientation dan incorrect orientation, inilah yang pembeda karena saat import image sudah dibedakan menjadi 2 kategori file dan belum melewati fitur ekstraksi, Namun setelah melewati fitur ekstraksi gambar diubah menjadi nilai vector yang sudah dikategorikan oleh inception v3. Lalu pada tahap akhir, vektor output yang telah dikategorikan akan diteruskan ke model klasifikasi.

2.3. Support Vector Machine

Support Vector Machine (SVM) adalah sistem pembelajaran yang melakukan prediksi dalam bentuk fungsi linear dengan fitur-fitur berdimensi tinggi [11]. mengklasifikasikan data menggunakan fungsi linier dalam ruang fitur berdimensi tinggi [10]. SVM dilatih pada data berlabel untuk menemukan hyperplane pemisah yang optimal, sebuah batas dalam ruang fitur yang membagi kelas secara maksimal. Tujuan dari pelatihan SVM adalah untuk memaksimalkan margin atau jarak antara kelas-kelas di kedua sisi hyperplane. Dalam kasus di mana data tidak dapat dipisahkan secara linear, SVM dapat memanfaatkan berbagai fungsi kernel, seperti kernel linear, polinomial, dan Radial Basis Function (RBF). Fungsi-fungsi kernel ini digunakan untuk memetakan data ke dalam ruang dimensi yang lebih tinggi dan menerapkan klasifikasi non-linear.

Kernel yang digunakan dalam penelitian ini adalah kernel linear, yang berfungsi sebagai pemisah data setelah diperoleh output dari Inception V3 berupa vektor berukuran 2048 dimensi. Model ini memanfaatkan vektor fitur tersebut untuk menemukan hyperplane optimal yang memisahkan kelas-kelas dalam ruang fitur berdimensi tinggi. Vektor-vektor yang membentuk hyperplane ini disebut Support Vector. Parameter yang digunakan pada SVM adalah sebagai berikut:

Cost (C) adalah parameter regularisasi dalam SVM yang mengontrol trade-off antara margin maksimum dan kesalahan klasifikasi. Dalam penelitian ini peneliti menggunakan nilai 1.00 pada Cost (C). Namun, nilai optimal bisa bervariasi tergantung pada kompleksitas dan karakteristik dataset Regression loss epsilon (ϵ) adalah parameter yang mengontrol seberapa dekat data harus cocok dengan hyperplane yang diprediksi. Pada regression loss epsilon nilai epsilon diatur 0.10 dalam kasus ini peneliti mengabaikan parameter ini atau menjaganya tetap rendah.

Kernel linear yang digunakan pada penelitian sebelumnya oleh karena itu kami menggunakan kernel linear, yang mana pada penelitian ini kami menggunakan dataset yang banyak dan bervariasi. Fungsi kernel pada SVM berfungsi untuk mengukur kesamaan antara dua vektor data. Kernel ini cukup simpel karena hanya melakukan perkalian titik antara dua vektor fitur. Semakin tinggi nilai produk dot, semakin mirip atau serupa kedua vektor tersebut. Persamaan (1) adalah rumus untuk mencari nilai kernel linear. Dimana K adalah Fungsi kernel yang digunakan dalam SVM dan $K(x,y)$ merupakan nilai kernel linear antara vektor x dan y. Sementara x_i dan y_i adalah kelas dan data pada indeks ke-i.

$$K(x, y) = \sum_{i=1}^n x_i \cdot y_i \quad (1)$$

Setelah memperoleh output dari Inception V3 berupa vektor berukuran 2048, proses selanjutnya melibatkan penjumlahan perkalian vektor sebanyak 2048 kali. Dalam hal ini, i dihitung dengan rentang $i = 1, 2, 3, \dots, n$, di mana $n = 2048$.

Nilai kernel linear $K(x,y)$ inilah yang kemudian digunakan dalam algoritma SVM untuk menemukan hyperplane pemisah terbaik antara kelas-kelas yang berbeda. Dalam SVM dengan kernel linear, semakin besar nilai dot product antara dua vektor fitur, semakin dekat atau mirip vektor-vektor tersebut dalam ruang fitur. Sebaliknya, semakin kecil nilai dot product, semakin jauh atau tidak mirip vektor-vektor tersebut. Jadi, perhitungan kernel linear pada SVM dengan data image embedding dari Inception V3 melibatkan operasi dot product antara vektor fitur berukuran 2048 untuk setiap pasangan gambar yang diproses.

2.4. K-Nearest Neighbors

K-Nearest Neighbor (KNN) merupakan salah satu metode yang digunakan untuk pengelompokan dan analisis data. Metode ini mengklasifikasikan data berdasarkan kelas yang paling umum di antara sejumlah k tetangga terdekatnya. Dalam konteks ini, k adalah parameter yang ditentukan oleh pengguna, yang mewakili jumlah tetangga terdekat yang akan dipertimbangkan dalam proses klasifikasi. Prinsip kerja KNN adalah menemukan data terdekat dari data yang sedang dianalisis, kemudian menentukan kelasnya berdasarkan mayoritas kelas dari tetangga tersebut.[12].

Parameter k yang digunakan dalam penelitian sebelumnya adalah 5. Oleh karena itu kami menggunakan parameter yang sama adalah 5 untuk membandingkan apakah dengan dataset yang banyak. Setelah diperoleh keluaran dari Inception V3 berupa vektor berdimensi tinggi berukuran 2048. Model ini akan mengelompokkan data baru ke dalam kategori-kategori tertentu, yang kemudian akan menentukan kelasnya berdasarkan mayoritas dari tetangga tersebut. Pengelompokan ini dilakukan berdasarkan kesamaannya dengan data latih yang telah ada[13]. Penelitian ini kami menggunakan parameter Metric Euclidean, adalah persamaan yang digunakan untuk mengukur jarak antara dua titik dalam ruang cartesian. Persamaan (2) adalah rumus menghitung jarak antara dua titik dalam ruang berdimensi n . Dimana $d(p, q)$ adalah mempresentasikan jarak antara dua titik p dan q dalam ruang multidimensi. Sementara p dan q adalah nilai dari koordinat titik dan n adalah jumlah dimensi.

$$d(p, q) = \sqrt{(p_1 - q_1)^2 + \dots + (p_n - q_n)^2} \quad (2)$$

Matrix jarak Euclidean merupakan metode yang paling umum digunakan dalam KNN. Jarak ini dihitung antara data baru dan data pelatihan untuk menentukan tetangga terdekat. Setelah memperoleh output dari Inception V3 berupa vektor berukuran 2048 dari image embedding, di mana $i = 1, 2, 3, \dots, n$ dan $n = 2048$, langkah selanjutnya adalah menghitung jarak Euclidean antara data baru dengan seluruh data pelatihan. Setelah itu, nilai K akan melanjutkan proses klasifikasi. Dalam penelitian ini, parameter yang digunakan pada KNN adalah weight uniform. Metode ini memberikan bobot yang sama kepada semua tetangga terdekat, tanpa mempertimbangkan jarak mereka dari titik data yang dianalisis. Artinya, jika terdapat k tetangga terdekat, setiap tetangga akan memiliki kontribusi yang setara dalam menentukan kelas atau prediksi nilai. Hal ini berbeda dengan skema pembobotan jarak terbalik yang memberikan bobot lebih besar kepada tetangga yang lebih dekat.

2.5. Evaluasi Performa

Evaluasi algoritma dimulai dengan proses K-Fold Cross Validation untuk data latih dan data uji. Metode ini digunakan untuk memperkirakan kesalahan prediksi saat menilai seberapa baik model bekerja. Dalam K-Fold Cross Validation, data dipisahkan menjadi k kelompok dengan ukuran yang hampir sama. Model klasifikasi dilatih dan diuji sebanyak k kali. Pada setiap iterasi, satu himpunan bagian dijadikan sebagai data uji, sedangkan himpunan lainnya digunakan sebagai data latih [14].

Cross validation, juga dikenal sebagai estimasi rotasi, adalah cara untuk menilai sampai sejauh mana data statistik telah dianalisis bisa digunakan pada data yang berbeda[15]. Dalam pendekatan ini, data dibagi menjadi k subset yang ukurannya sama. Setelah itu, satu subset digunakan sebagai data uji, sementara subset lainnya digunakan untuk melatih model. Proses ini diiterasi sebanyak k kali, dengan subset pengujian yang berbeda setiap kali. Secara khusus, penerapan validasi silang 5 lipatan (*5-fold cross validation*) memiliki kemampuan untuk mengurangi ketidaktepatan yang mungkin terjadi pada data. Kali dilakukan k proses pelatihan dan pengujian. Cara kerja *cross validation* dapat diperlihatkan pada Gambar 5 [16].

Iteration 1	Test	Train	Train	Train	Train
Iteration 2	Train	Test	Train	Train	Train
Iteration 3	Train	Train	Test	Train	Train
Iteration 4	Train	Train	Train	Test	Train
Iteration 5	Train	Train	Train	Train	Test

Gambar 5. Klasifikasi Cross Validation

Penelitian ini menggunakan metode K-fold Cross Validation dengan nilai $k = 5$ pada dataset yang terdiri dari 1500 data train dan 450 data test. Yang mana dari masing-masing data diklasifikasi secara terpisah.

Selanjutnya, dilakukan perbandingan hasil performa dari evaluasi metode SVM dan KNN untuk menentukan metode yang memberikan performa lebih baik.

Evaluasi ini mencakup beberapa matrix, antara lain Confusion Matrix, Akurasi, Presisi, Recall, dan F1 Score. Matrix-Matrix ini digunakan untuk mengevaluasi kinerja metode SVM dan KNN dalam pengenalan pola pada gambar guna memverifikasi orientasi material. Analisis ini akan membantu mengkaji kinerja performa dari kedua metode secara komprehensif. Berikut penjelasan dari metode evaluasi yang digunakan dalam penelitian ini adalah:

Confusion Matrix merupakan matrix yang sangat intuitif dan sederhana untuk menentukan tingkat akurasi dan keakuratan model yang dihasilkan. Jumlah prediksi yang benar ditunjukkan oleh variabel. Ada empat istilah yang mewakili hasil proses klasifikasi : dari hingga variabel FP dan FN. TP adalah jumlah data kelas sebenarnya dan kelas prediksi adalah kelas positif. TN adalah jumlah data kelas sebenarnya dan kelas prediksi merupakan kelas negatif. FN merupakan data kelas yang mewakili kelas yang benar, sedangkan kelas prediksi adalah kelas yang salah. FP merupakan penjumlahan data kelas sebenarnya kelas negatif dan kelas prediksi merupakan kelas positif.

Confusion Matrix		Actual	
		Positive	Negative
Predicted	Positive	TP	FP
	Negative	FN	TN

Gambar 6. Confusion Matrix

Gambar 8 Menunjukkan confusion matrix dimana TP adalah ketika sampel positif benar diprediksi. TN adalah ketika sampel negatif benar diprediksi. FP adalah ketika sampel negatif diprediksi sebagai positif, itu disebut sebagai *False Positives*, dan jika sampel positif diprediksi sebagai negatif, itu disebut sebagai FN. Semakin tinggi nilai akurasinya, semakin baik performa model.

CA (Akurasi) Akurasi adalah ukuran proporsi prediksi yang benar dari jumlah total sampel. Hal ini dinyatakan dalam Persamaan (3) berikut.

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (3)$$

Prec (Presisi) Presisi adalah matrix yang mengukur jumlah kasus positif yang benar-benar positif dari total jumlah kasus positif. Akurasi dihitung dengan membagi jumlah positif benar dengan jumlah *True Positives* dan *False Positives*. Hal ini dinyatakan dalam Persamaan (4) berikut.

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

Recall adalah rasio prediksi positif yang sebenarnya terhadap semua contoh positif yang sebenarnya. Matrix ini mengukur jumlah contoh positif yang dapat dipulihkan oleh model. Hal ini dinyatakan dalam Persamaan (5) berikut.

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

Skor F1 adalah ukuran keseimbangan antara presisi dan perolehan. Presisi adalah perbandingan positif sejati dengan jumlah total prediksi positif, dan recall (sensitivitas) adalah perbandingan positif sejati dengan jumlah total sampel positif sejati adalah Skor F1. Hal ini dinyatakan dalam Persamaan (6) berikut.

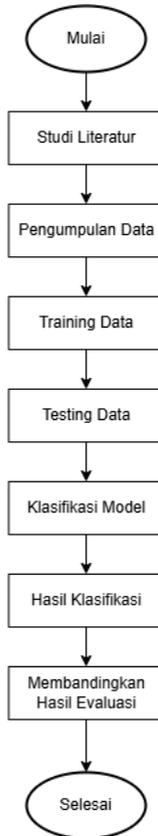
$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (6)$$

Dengan menganalisis matrix ini, kami memperoleh pemahaman yang komprehensif tentang kinerja masing-masing model dalam menangani verifikasi orientasi bagian. Akurasi, presisi, recall, dan F1-score yang lebih tinggi menunjukkan kinerja klasifikasi yang lebih baik, yang berkontribusi pada penilaian yang dapat diandalkan terhadap metode yang digunakan dalam penelitian ini.

Bab 3. Metodologi Penelitian

3.1. Perancangan

Dalam merencanakan studi penelitian pembuatan tugas akhir berjudul “Perbandingan Performa Support Vector Machine (SVM) dan k-Nearest Neighbors (kNN) dalam Memverifikasi Orientasi Material”,



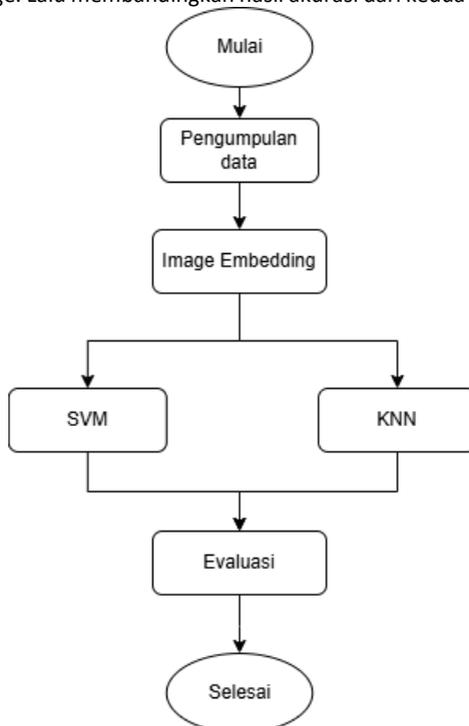
Gambar 3. 1 Diagram alur penelitian

Dalam studi ini, peneliti memanfaatkan SVM dan KNN dalam melakukan klasifikasi gambar belum pernah dilakukan melakukan studi literatur yang berkaitan dengan orientasi material, lalu pengumpulan sampel data yang diambil untuk memverifikasi orientasi material *Correct Orientation* dan *Wrong Orientation*

ialah tutup botol. Proses pengambilan gambar dilakukan penulis sebanyak 200 gambar dengan perbedaan sudut yaitu atas dengan 100 gambar, dan bawah dengan 100 gambar dengan menggunakan fitur ekstraksi Inception V3, Lalu mentraining data sekaligus testing data tersebut menggunakan K-Fold Cross Validation. Lalu klasifikasi model yaitu SVM dan KNN lalu Membandingkan hasil Evaluasi pada kedua model

3.2. Flowchart Pengujian

Pada flowchart pengujian menggunakan metode SVM dan KNN yang mana adalah capture atau proses pengambilan gambar lalu dilanjutkan dengan menggolongkan Correct Orientation dan Wrong Orientation pada pengujian yang akan dilakukan lalu Mengimplementasikan kedua Metode yaitu SVM dan KNN diAplikasi Orange. Lalu membandingkan hasil akurasi dari kedua metode tersebut.



Gambar 7. Flow chart Pengujian

Bab 4. Hasil dan Pembahasan

4.1. Data Hasil Penelitian

Bagian ini menguraikan evaluasi kinerja model klasifikasi yang diterapkan pada dataset tutup botol. Analisis mencakup kemampuan model untuk memvalidasi orientasi tutup botol, dengan memanfaatkan matriks kebingungan yang berasal dari metodologi SVM dan kNN. Selanjutnya, evaluasi dirinci untuk mendapatkan akurasi klasifikasi, presisi, recall, dan F1-score.

		Predicted		Σ
		Correct Orientation	Incorrect Orientation	
Actual	Correct Orientation	750	0	750
	Incorrect Orientation	0	750	750
Σ		750	750	1500

Gambar 8. Confusion Matrix Train

		Predicted		Σ
		Correct Orientation	Incorrect Orientation	
Actual	Correct Orientation	225	0	225
	Incorrect Orientation	0	225	225
Σ		225	225	450

Gambar 9. Confusion Matrix Test

Tabel 1. Comparison results of SVM and kNN on verifying material orientation

Model	CA	Precision	Recall	Training Time	Testing Time
SVM	1.0	1.0	1.0	3.101	1.479
KNN	1.0	1.0	1.0	1.126	0.713

4.2. Pembahasan

Gambar 5 menampilkan hasil matriks kebingungan untuk SVM dan kNN. Kedua algoritma tersebut menghasilkan matriks kebingungan yang sama. Matriks kebingungan menggambarkan bahwa 750 sampel orientasi yang benar diprediksi secara akurat sebagai tutup botol dengan orientasi yang benar. Untuk sampel orientasi yang salah, kedua algoritma juga memprediksi 750 sampel orientasi yang salah sebagai tutup botol dengan orientasi yang salah. Hasil ini berarti tidak ada prediksi yang salah. Hasil ini menghasilkan nilai TP = 750, TN = 750, FP = 0, dan FN = 0. Secara ringkas, SVM dan kNN menunjukkan kinerja yang sama dalam hasil confusion matrix.

Tabel 1 menunjukkan hasil dari proses pengujian ulang yang membandingkan kinerja metode SVM dan kNN. Evaluasi didasarkan pada metrik klasifikasi, termasuk akurasi klasifikasi (CA), presisi, recall, skor F1, dan waktu pelatihan dan pengujian. Baik SVM dan kNN mencapai skor sempurna 1.0 di semua metrik klasifikasi: CA, Precision, Recall, dan F1 Score. Hasil ini menunjukkan bahwa kedua metode tersebut sangat efektif dalam mengklasifikasikan dataset, menunjukkan kemampuan mereka untuk mencapai prediksi yang sempurna tanpa kesalahan klasifikasi.

Namun, perbedaan terlihat pada efisiensi komputasi, khususnya pada waktu pelatihan dan pengujian. Untuk SVM, proses pelatihan membutuhkan waktu 3.101 detik, sedangkan fase pengujian membutuhkan 1.479 detik. Sebaliknya, kNN menunjukkan kinerja yang jauh lebih cepat, dengan waktu pelatihan 1,126 detik dan waktu pengujian 0,713 detik. Hasil ini menyoroti efisiensi komputasi kNN, terutama dalam skenario di mana pengujian dan pelatihan yang cepat sangat penting. Singkatnya, meskipun SVM dan kNN memberikan akurasi klasifikasi yang sama luar biasanya, kNN menawarkan kinerja yang lebih unggul dalam hal kecepatan komputasi. Hasil ini menunjukkan bahwa kNN mungkin lebih cocok

untuk aplikasi real-time atau skenario yang melibatkan data berskala besar di mana kecepatan pemrosesan menjadi pertimbangan utama.

Bab 5. Kesimpulan dan Saran

5.1. Kesimpulan

Kesimpulannya, kedua metode SVM dan kNN menunjukkan kinerja klasifikasi yang sempurna, mencapai akurasi klasifikasi (CA), presisi, recall, dan F1-score sebesar 1.0. Hasil ini menyoroti keefektifan kedua algoritma dalam mengklasifikasikan data orientasi material secara akurat tanpa kesalahan klasifikasi. Namun, perbedaan penting diamati dalam efisiensi komputasi. kNN mengungguli SVM dalam hal kecepatan komputasi, dengan waktu pelatihan dan pengujian yang jauh lebih cepat. Waktu pelatihan untuk kNN adalah 1.126 detik dibandingkan dengan 3.101 detik untuk SVM, sedangkan waktu pengujian untuk kNN adalah 0.713 detik dibandingkan dengan 1.479 detik untuk SVM. Hasil ini membuat kNN lebih efisien dan lebih cocok untuk aplikasi real-time atau skenario yang melibatkan dataset yang lebih besar, di mana kecepatan pemrosesan sangat penting.

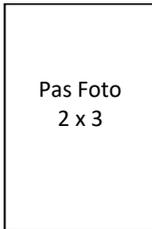
5.2. Saran

Dalam penelitian di masa depan, disarankan agar pendekatan alternatif untuk mengevaluasi orientasi material dieksplorasi, seperti convolutional neural networks (CNN), gradient boosting, dan teknik pembelajaran mesin lainnya. Memperluas evaluasi dengan menyertakan metode-metode ini dapat memungkinkan perbandingan yang lebih komprehensif, terutama dengan set data yang lebih luas dan lebih bervariasi. Pendekatan ini dapat menawarkan wawasan baru dan memungkinkan analisis yang lebih dalam tentang kinerja algoritme dalam evaluasi orientasi material

Daftar Pustaka

- [1] S. Azhar and S. I. A. Shah, "Modeling and Analysis of a Vibratory Bowl Feeder," in *2021 Seventh International Conference on Aerospace Science and Engineering (ICASE)*, Dec. 2021, pp. 1–13. doi: 10.1109/ICASE54940.2021.9904038.
- [2] S. Haque *et al.*, "Automatic Product Sorting and Packaging System," in *2023 15th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, Aug. 2023, pp. 163–167. doi: 10.1109/IHMSC58761.2023.00046.
- [3] R. Wulandari, M. R. Ariwibowo, T. Taryo, and G. Ananda, "Design Smart Trash Based on the Inductive Proximity Sensor," *International Journal of Multidisciplinary Approach Research and Science*, vol. 2, no. 01, Art. no. 01, 2024, doi: 10.59653/ijmars.v2i01.394.
- [4] A. D. Sevtian, F. A. Kurniawan, Yulfitra, and M. Arifin, "Pemograman Sistem pada Mesin Filling Bottle PLC dengan Menggunakan Penggerak Pneumatik dan Intelegensi Sensor," *Jurnal MESIL (Mesin Elektro Sipil)*, vol. 3, no. 2, Art. no. 2, Dec. 2022, doi: 10.53695/jm.v3i2.807.
- [5] C. Singh, "Machine Learning in Pattern Recognition," *European Journal of Engineering and Technology Research*, vol. 8, no. 2, Art. no. 2, Apr. 2023, doi: 10.24018/ejeng.2023.8.2.3025.
- [6] L. Almawas, A. Alotaibi, and H. Kurdi, "Comparative Performance Study of Classification Models for Image-splicing Detection," *Procedia Computer Science*, vol. 175, pp. 278–285, Jan. 2020, doi: 10.1016/j.procs.2020.07.041.
- [7] A. Rajput and A. K. Singh, "Handwritten Digit Recognition Accuracy Comparison Using KNN,CNN and SVM," *Educational Administration: Theory and Practice*, vol. 30, no. 2, Art. no. 2, Apr. 2024, doi: 10.53555/kuey.v30i2.1676.
- [8] K. B. Narayanan, D. K. Sai, K. A. Chowdary, and S. R. K, "Applied Deep Learning Approaches on Canker Effected Leaves to Enhance the Detection of the Disease Using Image Embedding and Machine Learning Techniques," *EAI Endorsed Transactions on Internet of Things*, vol. 10, Mar. 2024, doi: 10.4108/eetiot.5346.
- [9] U. Ungkawa and G. A. Hakim, "Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 11, no. 3, Art. no. 3, Jul. 2023, doi: 10.26760/elkomika.v11i3.731.
- [10] S. Ulum, R. F. Alifa, P. Rizkika, and C. Rozikin, "Perbandingan Performa Algoritma KNN dan SVM dalam Klasifikasi Kelayakan Air Minum," *Generation Journal*, vol. 7, no. 2, Art. no. 2, Jul. 2023, doi: 10.29407/gj.v7i2.20270.
- [11] R. H. Dananjaya, S. Sutrisno, and F. A. Wellianto, "Akurasi Penggunaan Metode Support Vector Machine dalam Prediksi Penurunan Pondasi Tiang," *Matriks Teknik Sipil*, vol. 10, no. 3, Art. no. 3, Dec. 2022, doi: 10.20961/mateksi.v10i3.64519.
- [12] A. Singh, M. Singh, and K. Kumar, "A Hybrid Method for Intrusion Detection Using SVM and k-NN," in *Conference Proceedings of ICDLAIIR2019*, M. Tripathi and S. Upadhyaya, Eds., Cham: Springer International Publishing, 2021, pp. 119–126. doi: 10.1007/978-3-030-67187-7_13.
- [13] D. Alita, Y. Fernando, and H. Sulistiani, "Implementasi Algoritma Multiclass SVM Pada Opini Publik Berbahasa Indonesia di Twitter," *Jurnal Tekno Kompak*, vol. 14, no. 2, Art. no. 2, Aug. 2020, doi: 10.33365/jtk.v14i2.792.

Biodata



Nama : Eldio Utama
TTL : Batam, 01 Mei 2001
Agama : Islam
Alamat : Bida ayu blok N no.129
Email : eldio1710@gmail.com
Riwayat Pendidikan SMA/SMK : SMKN 1 Batam
SMP : SMPN 16 batam

Lampiran

Silakan masukkan lampiran yang diperlukan. Jika diperlukan, lampiran dapat dipisah menjadi Lampiran A, Lampiran B, dan seterusnya.