

PENERAPAN *COMPUTER VISION* UNTUK MENDETEKSI KELENGKAPAN ATRIBUT SISWA MENGGUNAKAN METODE CNN

Aang Alim Murtopo¹, Maulana Aditdy², Pingky Septiana Ananda³, Gunawan Gunawan⁴

Teknik Informatika, STMIK YMI Tegal

Jalan Pendidikan 1, Kota Tegal 52142, Indonesia

E-mail: aang.alim@stmik-tegal.ac.id¹, *aditdyamaulana@gmail.com², pingky@stmik-tegal.ac.id³, gunawan@stmik-tegal.ac.id⁴

Abstrak - Kepatuhan dalam mengenakan atribut sekolah secara lengkap merupakan salah satu aspek penting yang mencerminkan disiplin dan karakter siswa di lingkungan pendidikan. Namun, seringkali ditemukan pelanggaran terkait kelengkapan atribut siswa yang dapat berdampak negatif pada pembentukan budaya disiplin. Tujuan dari penelitian ini yaitu menerapkan metode *Convolutional Neural Network* (CNN) dalam mendeteksi kelengkapan atribut siswa seperti logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu dari gambar menggunakan *computer vision*. Penerapan teknologi *computer vision* dengan CNN dapat membantu pihak sekolah dalam menegakkan disiplin penggunaan atribut siswa secara lebih efektif, efisien, dan objektif. Pada penelitian ini, *dataset* gambar siswa yang mengenakan atribut lengkap dan tidak lengkap dikumpulkan untuk proses pelatihan model CNN. Teknik augmentasi data dan pelabelan gambar dilakukan untuk mempersiapkan *dataset* yang digunakan. Model CNN dibangun dengan beberapa lapisan konvolusi, *pooling*, *dense*, dan fungsi aktivasi seperti ReLU dan Sigmoid. Selanjutnya, empat kali pengujian dilakukan dengan menggunakan data uji yang berbeda untuk mengevaluasi performa model. Hasil pengujian menunjukkan bahwa model CNN yang dibangun dapat mencapai rata-rata akurasi 93,34%, presisi 95%, recall 94,12%, dan F1-score 94,35% dalam mendeteksi kelengkapan atribut siswa. Temuan ini mengindikasikan bahwa metode CNN berpotensi besar untuk dimanfaatkan dalam mendeteksi kelengkapan atribut siswa secara otomatis, objektif, dan efisien, serta dapat berkontribusi pada upaya peningkatan disiplin dan pembentukan karakter di lingkungan sekolah.

Kata Kunci: Atribut siswa, CNN, *computer vision*, deteksi objek, pembelajaran mesin

I. PENDAHULUAN

Pendidikan merupakan pilar utama dalam pembangunan suatu bangsa. Di dalam proses pendidikan, pengawasan terhadap kelengkapan atribut siswa menjadi aspek yang tidak kalah pentingnya, salah satu aspek penting yang menjadi perhatian adalah kepatuhan siswa dalam mengenakan atribut sekolah secara lengkap (Herdiansyah & Kurniati, 2020). Atribut sekolah, seperti logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu, merupakan elemen penting yang mencerminkan identitas, disiplin, dan citra institusi pendidikan (Ibnu Sholeh, 2020). Namun, seringkali ditemukan pelanggaran terkait kelengkapan atribut siswa, di mana sebagian siswa tidak mematuhi peraturan dengan tidak mengenakan salah satu atau beberapa atribut yang diwajibkan.

Pelanggaran terhadap peraturan atribut ini dapat menimbulkan dampak negatif pada pembentukan karakter dan budaya disiplin di kalangan siswa. Terlebih lagi, kondisi tersebut berpotensi memberikan dampak terhadap sekolah dan menghambat upaya dalam menciptakan lingkungan belajar yang teratur dan kondusif. Terdapat beberapa isu yang terkait dengan permasalahan dalam menegakkan kelengkapan atribut siswa di lingkungan sekolah (Duta et al., 2024). Pertama, kurangnya kesadaran dan komitmen siswa dalam mematuhi peraturan sekolah mengenai

atribut. Sebagian siswa cenderung abai atau kurang memahami pentingnya mengenakan atribut sekolah secara lengkap, yang dapat disebabkan oleh faktor-faktor seperti kurangnya pendidikan karakter, keteladanan, atau kurangnya penguatan peraturan secara konsisten (Esmiati et al., 2020). Kedua, adanya keterbatasan sumber daya manusia dalam mengawasi dan menegakkan peraturan secara manual. Pengawasan secara manual terhadap kelengkapan atribut siswa membutuhkan upaya yang signifikan dari sumber daya manusia, terutama di sekolah dengan jumlah siswa yang besar. Hal ini dapat menyebabkan keterbatasan dalam pengawasan dan penegakan peraturan secara efektif (Alfanda Annur et al., 2023). Isu ketiga adalah potensi subjektivitas dan inkonsistensi dalam penilaian kelengkapan atribut oleh pengawas manusia. Penilaian kelengkapan atribut siswa secara manual oleh manusia dapat rentan terhadap subjektivitas dan inkonsistensi. Faktor-faktor seperti perbedaan persepsi, kelelahan, atau bias pribadi dapat menyebabkan penilaian yang tidak seragam (Satyo Prihatin & Dina Atika, 2021).

Penerapan teknologi *computer vision* dengan metode CNN dapat membantu dalam mendeteksi kelengkapan atribut siswa secara otomatis, objektif, dan efisien. Dengan memanfaatkan kecerdasan buatan dan pembelajaran mesin, sistem berbasis CNN dapat dilatih untuk mendeteksi gambar siswa berdasarkan kelengkapan atribut yang dikenakan,

seperti logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu (Rizqi Efrian et al., n.d.). Studi terdahulu menunjukkan bahwa metode CNN memiliki akurasi hingga diatas 90% dalam mendeteksi objek yaitu citra gambar beras, memungkinkan sistem untuk melakukan klasifikasi pada objek beras (Zainal Altim et al., 2022). Penelitian lainnya membahas tentang klasifikasi wajah berdasarkan objek masker yang digunakan dengan memakai metode CNN. Hasil evaluasi menunjukkan keberhasilan model dengan mencapai akurasi sebesar 82%. Akurasi yang tinggi ini menunjukkan model sangat baik untuk mendeteksi objek menggunakan data gambar dalam penerapan metode CNN untuk mendeteksi kelengkapan atribut siswa secara akurat (Qotrunnada & Utomo, 2022).

Penelitian ini bertujuan untuk menerapkan sistem pendeteksi kelengkapan atribut siswa menggunakan metode CNN pada gambar. Sistem ini ditujukan agar memberikan solusi objektif, efisien, dan akurat dalam mengidentifikasi siswa yang mematuhi atau melanggar peraturan atribut sekolah secara lengkap, meliputi logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu. Sistem ini akan dilatih menggunakan *dataset* gambar siswa yang memakai atribut lengkap dan tidak lengkap, sehingga dapat mengklasifikasikan gambar siswa ke dalam kategori yang sesuai.

Dengan adanya sistem pendeteksi kelengkapan atribut siswa berbasis CNN, diharapkan dapat membantu pihak sekolah dalam menegakkan disiplin penggunaan atribut siswa secara lebih efektif dan efisien. Sistem ini dapat digunakan untuk melakukan pengawasan secara otomatis dan objektif, mengurangi beban sumber daya manusia, serta mendukung pembentukan karakter dan budaya disiplin di lingkungan sekolah (Computer et al., 2022). Selain itu, penelitian ini juga bertujuan untuk mengeksplorasi potensi penerapan teknologi *computer vision* dan kecerdasan buatan dalam bidang pendidikan, khususnya dalam upaya meningkatkan disiplin dan tata tertib sekolah. Dengan adanya solusi inovatif ini, diharapkan dapat memberikan kontribusi positif terhadap peningkatan kualitas pendidikan dan pembentukan karakter siswa yang lebih baik.

II. TINJAUAN PUSTAKA

Penelitian terdahulu dengan judul Implementasi Metode CNN untuk klasifikasi objek. Penelitian tersebut menyediakan kemampuan untuk mengetahui tingkat akurasi dari metode CNN dalam mengklasifikasikan objek, seperti manusia, hewan, kendaraan, dan lain-lain. Hasil pengujian mengindikasikan bahwa pendekatan jaringan syaraf tiruan konvolusi seperti CNN mampu mencapai tingkat akurasi hingga 98% dalam mengklasifikasikan objek-objek tersebut. Meskipun demikian, penelitian ini tidak secara spesifik

membahas tentang penerapan CNN untuk mendeteksi objek secara mendalam seperti atribut siswa, sehingga masih diperlukan penelitian lebih lanjut untuk mengimplementasikan metode CNN pada kasus yang lain. Selain itu, kekurangan dari penelitian ini seperti tidak adanya penjelasan mengenai teknik pra-pemrosesan data pada metode CNN yang terapkan, sehingga sulit dalam mengimplementasikan metode yang sama secara efektif pada kasus yang berbeda (Nasution, 2023).

Penelitian selanjutnya dengan judul Penerapan *Computer Vision* Untuk Absensi Wajah Berbasis Algoritma CNN Pada Guru SMK Excellent 1 Tangerang. Penelitian ini bertujuan untuk mengimplementasikan teknologi *face recognition* dengan pendekatan CNN terhadap sistem absensi dengan gambar wajah guru sebagai objek utama, sehingga dapat mengatasi permasalahan seperti ketidakakuratan, pemalsuan tanda tangan, serta kehilangan lembar absensi yang sering terjadi pada sistem absensi konvensional. Meski begitu, penelitian ini tidak secara khusus mengkaji penerapan CNN untuk mendeteksi objek yang lebih dalam seperti kelengkapan atribut siswa, sehingga perlu riset lebih lanjut untuk mengaplikasikan metode CNN pada kasus yang berbeda dan terdapat banyak objek. Selain itu terdapat kekurangan seperti minimnya penjelasan terkait tahapan pra-pemrosesan citra wajah, sehingga sulit untuk mereplikasikan pendekatan seperti CNN secara efektif dalam situasi yang berbeda. Penelitian ini berhasil membangun sebuah sistem absensi wajah menggunakan *Raspberry Pi* dan kamera *Logitech C270* dengan menerapkan algoritma CNN untuk pengenalan wajah guru, meskipun berhasil dalam penerapan sistem, akan tetapi tidak ada informasi kuantitatif tentang keberhasilan implementasi dan tidak menyebutkan secara rinci hasil pengujiannya, seperti tingkat akurasi atau evaluasi kinerja sistem absensi wajah (Dwi Hartomo, 2021).

Penelitian lainnya dengan judul Implementasi Machine Learning dengan Menggunakan CNN untuk Klasifikasi Citra Candi. Penelitian ini mengeksplorasi penggunaan CNN sebagai pilihan di antara beragam teknik pembelajaran mesin yang kini sedang berkembang pesat dalam mengklasifikasikan gambar candi dengan tujuan membantu masyarakat mempelajari peninggalan budaya bangsa. Penelitian ini merancang struktur CNN yang digunakan, terdiri dari dua lapis konvolusi, dua lapis penyatuan, dan satu lapis yang terhubung sepenuhnya, serta memanfaatkan fungsi pengaktifan ReLU dan Softmax sebagai fungsi aktivasi. Hasil penelitian menyajikan bukti model yang dibangun berhasil memperoleh tingkat akurasi hingga 92% dalam melakukan klasifikasi citra candi dengan menggunakan dataset gambar yang dikumpulkan dari *GitHub*. Namun, penelitian ini tidak menyebutkan secara spesifik jumlah data yang digunakan atau menjelaskan secara rinci bagaimana

proses pengumpulan dan pelabelan dataset citra candi dari *GitHub* sehingga sulit untuk mengevaluasi kecukupan, representasi, integritas serta kualitas data yang digunakan (Fajri & Atika, n.d.).

Penelitian selanjutnya dengan judul Implementasi Deep Learning Menggunakan CNN pada Ekspresi Manusia. penyelidikan ini memanfaatkan dataset gambar raut muka dengan total 28.821 citra untuk data validasi dan 7.066 citra untuk data pelatihan. arsitektur CNN yang dirancang terdiri dari beberapa lapisan konvolusi, *pooling*, *fully connected layer*, serta fungsi aktivasi ReLU dan Softmax. Hasil terbaik diperoleh dengan konfigurasi epoch 100 dan batch size 128, mencapai angka 90% untuk akurasi pelatihan dan 65% pengujian. Namun, penelitian ini tidak ada pembahasan tentang teknik apa yang digunakan dalam mempersiapkan atau mengolah data citra (*pre-processing*) seperti augmentasi dan pelabelan data, serta kurang menyediakan rekomendasi untuk pengembangan lebih lanjut (Adi Nugroho et al., 2020).

Penelitian selanjutnya dengan judul *The Implementation of Convolution Neural Network (CNN) Metode On Automatic Lip Reading Application*. Penelitian ini mengimplementasikan teknologi pengolahan citra (*Computer Vision*) untuk mendeteksi posisi mulut pembicara, kemudian menggunakan metode CNN untuk memprediksi huruf atau angka yang diucapkan. Temuan dari studi ini mengindikasikan bahwa aplikasi yang diterapkan mampu melakukan pembacaan dengan tingkat akurasi 19,2% untuk huruf alfabet dan 43,2% untuk angka. Meskipun tingkat akurasi masih rendah dan kurangnya analisis mendalam terkait faktor-faktor yang memengaruhi tingkat akurasi, seperti kualitas video, pencahayaan, atau posisi pembicara, penelitian ini menyimpulkan bahwa penambahan jumlah dataset pada proses pelatihan dapat meningkatkan akurasi sistem (Mamuriyah & Sumantri, 2022).

III. METODE PENELITIAN

Analisis Metode

Dalam penelitian ini, metode utama yang diterapkan ialah CNN dalam mendeteksi kelengkapan atribut siswa dari gambar, metode ini merupakan jenis arsitektur jaringan saraf tiruan yang telah terbukti cukup efektif dalam memproses data visual seperti gambar dan video. CNN mengambil inspirasi dari proses visual biologis di mana pola-pola neuron yang disebut medan reseptif (*receptive fields*) digunakan untuk mengekstraksi fitur-fitur visual secara hierarkis. Salah satu kelebihan utama CNN yaitu mampu untuk mempelajari fitur-fitur yang invariant terhadap translasi (pergeseran), skalasi (perubahan skala), dan rotasi. Ini dicapai melalui penggunaan operasi konvolusi dan lapisan *pooling* yang membuat model CNN lebih robust terhadap perubahan-perubahan kecil pada data input.

Selain itu, CNN juga mampu menangkap hubungan spasial antara piksel-piksel dalam gambar, yang sangat penting dalam tugas-tugas seperti deteksi objek dan segmentasi gambar. Dalam proses pelatihan CNN, parameter-parameter seperti bobot dan bias dari lapisan-lapisan konvolusi dan *fully-connected* disesuaikan secara iteratif untuk meminimalkan fungsi *loss* dan meningkatkan akurasi prediksi. Proses ini dilakukan dengan menggunakan teknik optimasi seperti Adam optimizer. Selain itu, teknik regularisasi seperti *dropout* sering digunakan untuk mencegah overfitting dan meningkatkan generalisasi model. Meskipun CNN cukup efektif untuk diterapkan di *Computer Vision*, arsitektur tersebut juga memiliki sejumlah keterbatasan. Satu di antaranya ialah kebutuhan akan kuantitas *dataset* yang besar diperlukan guna memperoleh kinerja yang optimal. Selain itu, CNN juga dapat rentan terhadap serangan adversarial, di mana perubahan kecil pada input gambar dapat menyebabkan prediksi yang salah secara signifikan.

Tahapan Penelitian

Penelitian ini dilakukan dengan mengikuti serangkaian tahapan yang sistematis dan terstruktur untuk memastikan proses yang efisien dan hasil yang akurat. Tahapan-tahapan ini dirancang dengan cermat untuk mengatasi tantangan yang dihadapi dalam mendeteksi kelengkapan atribut siswa dari gambar menggunakan pendekatan *Computer Vision* dan metode CNN. Terdapat beberapa tahapan yaitu pengumpulan data, pra-pemrosesan data, pembagian data, membangun model CNN, dan evaluasi model.

1. Pengumpulan data

Pada penelitian ini, pengumpulan data adalah langkah yang sangat penting, tahap ini bertujuan untuk memperoleh dataset yang representatif untuk pelatihan model CNN dalam mendeteksi kelengkapan atribut siswa melalui penerapan *computer vision*. Sumber utama data untuk penelitian ini di dapat dari internet berupa gambar siswa yang memakai atribut seperti logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu. Jumlah *dataset* yang berhasil dikumpulkan sebanyak 100 gambar.



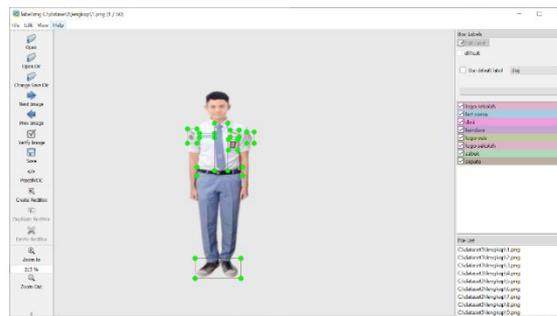
Gambar 1. *Dataset* siswa atau siswi yang lengkap dan tidak lengkap

2. Pra-pemrosesan data

Sebelum data dimasukan ke model dilakukan pra-pemrosesan terlebih dahulu seperti augmentasi data. Augmentasi data yaitu teknik yang diterapkan untuk memproses data, khususnya dalam konteks *computer vision* dan *machine learning* untuk meningkatkan variasi data serta memegang peranan penting dalam meningkatkan performa model terutama dalam tugas-tugas yang melibatkan data visual seperti gambar. Dengan melakukan teknik augmentasi data, jumlah data dapat ditingkatkan secara signifikan tanpa perlu mengumpulkan data baru yang memakan waktu dan biaya. Teknik ini sangat bermanfaat dalam situasi di mana jumlah data yang tersedia terbatas. Dengan menggunakan teknik augmentasi, model CNN dapat dilatih dengan dataset yang lebih besar dan beragam, sehingga dapat mempelajari fitur-fitur yang lebih umum dan menghasilkan performa yang lebih baik. Di samping itu, augmentasi data juga berfungsi untuk dapat membantu mengatasi masalah *overfitting*, di mana model biasanya hanya belajar fitur-fitur spesifik dari data latih dan gagal untuk mengeneralisasi dengan baik pada data baru. Dengan memperkenalkan variasi pada data melalui augmentasi, model dipaksa untuk mempelajari fitur-fitur yang lebih umum dan robust terhadap perubahan-perubahan kecil pada data. Dalam penelitian ini, Teknik augmentasi data menggunakan *library augmentor* untuk melakukan operasi perubahan ukuran gambar menjadi 400x400 piksel, peningkatan kecerahan dan kontras secara acak, pergeseran gambar, serta pembalikan horizontal dan vertikal dengan probabilitas yang telah ditentukan.

Setelah selesai melakukan augmentasi data selanjutnya melabeli data menggunakan labeling. Labelimg yaitu alat atau aplikasi *open source* yang digunakan dalam membuat anotasi dan pelabelan pada gambar secara manual. Aplikasi ini dikembangkan dengan menggunakan bahasa pemrograman Python dan library PyQt. Labelimg menyediakan antarmuka pengguna grafis yang intuitif dan mudah digunakan untuk menggambar kotak pembatas (*bounding box*) di sekitar objek-objek yang ingin dilabeli dalam gambar. Dengan menggunakan *labeling* dapat mempermudah pemberian label pada objek-objek dalam gambar siswa, seperti logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu. Hasil dari pelabelan ini kemudian disimpan dalam format XML yang dapat dibaca oleh model yang digunakan. Salah satu kelebihan utama dari LabelImg adalah kemampuannya untuk melakukan pelabelan secara massal pada banyak gambar dalam satu *dataset* serta dapat memuat seluruh folder berisi gambar dan melakukan pelabelan secara efisien. Ini sangat membantu dalam mempersiapkan dataset yang besar untuk digunakan dalam pelatihan model CNN. LabelImg memegang peranan penting dalam proses persiapan data. Dengan adanya pelabelan yang

akurat pada *dataset* gambar, model CNN dapat dilatih dengan lebih baik dan menghasilkan performa yang lebih akurat dalam tugas-tugas seperti deteksi kelengkapan atribut siswa.



Gambar 2. Proses pelabelan gambar menggunakan labeling

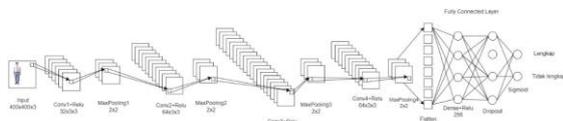
3. Pembagian data

Sebelum melakukan pelatihan model, *dataset* yang telah dikumpulkan dan diproses perlu dibagi menjadi dua bagian yaitu data pelatihan dan data pengujian dengan memakai teknik *train test split* dari pustaka *scikit-learn* dengan rasio 70:30. Teknik ini digunakan untuk membagi *dataset* secara acak, dimana 70% akan dialokasikan sebagai data pelatihan yang akan berperan dalam melatih model, sedangkan 30% sisanya akan menjadi data uji untuk mengevaluasi performa model setelah proses pelatihan selesai. Pembagian *dataset* ke dalam data pelatihan serta data pengujian sangat penting guna menghindari masalah *overfitting*, di mana model hanya belajar fitur-fitur spesifik dari data latih dan gagal untuk mengeneralisasi dengan baik pada data baru. Dengan menggunakan data uji yang terpisah, peneliti mampu menilai sejauh mana model dalam memprediksi atau mengklasifikasikan data yang baru. Pada penelitian ini, data pelatihan yang terbentuk akan dipakai guna melatih model CNN dalam mendeteksi kelengkapan atribut siswa dari gambar, sementara data pengujian akan dipakai dalam mengevaluasi kinerja model.

4. Model CNN

Model ini dibangun dengan menggunakan arsitektur API Sequential dari library Keras di TensorFlow. CNN tersusun dalam berbagai lapisan yang terhubung secara berurutan. Lapisan-lapisan tersebut meliputi lapisan konvolusi, lapisan *pooling*, lapisan *flatten*, lapisan *dropout* dan lapisan *dense (full-connected)*. Lapisan konvolusi terdapat empat blok lapisan yang masing-masing terdiri dari lapisan konvolusi 2D dengan jumlah filter berturut-turut 32, 64, 128, dan 64, dengan ukuran filter 3x3 serta aktivasi ReLu bertanggung jawab untuk mengekstraksi fitur-fitur visual dari gambar melalui operasi konvolusi untuk melakukan operasi pada input gambar. Lapisan *pooling* juga terdapat 4 lapisan maksimum 2D (MaxPooling2D) dengan ukuran 2x2 yang dipakai dalam mereduksi dimensi ruang dari fitur-fitur yang diekstrak oleh lapisan

konvolusi, sehingga membantu mengontrol *overfitting* dan mengurangi kompleksitas komputasi. Setelah blok konvolusi-*pooling*, lapisan *flatten* digunakan untuk meratakan output menjadi vektor 1D. Selanjutnya, terdapat lapisan *dropout* dengan tingkat 0.5 untuk mencegah *overfitting*. Dilanjutkan dengan lapisan *dense* yang terhubung penuh dengan 256 unit, aktivasi ReLU, dan regularisasi L2. Lapisan *dropout* lain dengan tingkat 0.3 dimasukkan sebelum lapisan output. Lapisan output merupakan lapisan *dense* dengan satu unit dan fungsi aktivasi sigmoid untuk melakukan klasifikasi biner apakah atribut siswa lengkap atau tidak lengkap. Model dikompilasi dengan optimizer Adam, fungsi loss *binary_crossentropy*, dan metrik-metrik seperti akurasi, presisi, recall, dan F1-score guna memastikan pelatihan model yang efisien serta memberikan gambaran seberapa baik model dapat mendeteksi kelengkapan atribut siswa dari gambar. Pelatihan dilakukan selama 10 epoch menggunakan data pelatihan dan validasi.



Gambar 3. Arsitektur CNN

5. Evaluasi model

Evaluasi model adalah tahap penting dalam membangun dan mengembangkan model CNN, evaluasi ini dilakukan untuk menilai kinerja model dalam mendeteksi kelengkapan atribut siswa. Model ini telah dilatih dengan menggunakan dataset gambar atribut siswa yang beragam seperti logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu. Setelah proses pelatihan selesai, model diuji dengan data uji yang tidak pernah dilihat sebelumnya untuk mengevaluasi kemampuan generalisasi model. Dalam evaluasi ini, metrik utama yang digunakan meliputi akurasi, presisi, recall, dan F1-score. Akurasi mengukur persentase prediksi yang tepat dari keseluruhan prediksi, sedangkan presisi mengukur proporsi prediksi positif yang benar-benar positif. Recall mengukur proporsi sampel positif yang benar-benar teridentifikasi oleh model, dan F1-score memberikan keseimbangan antara presisi dan recall. Dalam evaluasi model CNN, menghitung rumus metrik seperti akurasi, presisi, recall dan F1-score terdapat empat nilai penting yang digunakan untuk mengukur performa model, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). TP merupakan jumlah sampel positif yang diprediksi dengan benar oleh model sebagai positif. TN merupakan jumlah sampel negatif yang diprediksi dengan benar oleh model sebagai negatif. FP merupakan jumlah sampel negatif yang salah diprediksi oleh model sebagai positif. Sedangkan FN merupakan jumlah sampel positif yang salah

diprediksi oleh model sebagai negatif. Nilai-nilai ini digunakan untuk menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score, yang memberikan gambaran menyeluruh tentang kinerja model dalam melakukan prediksi dengan tepat.

$$akurasi = \frac{TP + TN}{TP + TN + FP + FN} \tag{1}$$

TP menunjukkan *True Positive*, TN menunjukkan *True Negative*, FP menunjukkan *False Positive*, dan FN menunjukkan *False Negative*.

$$Presisi = \frac{TP}{TP + FP} \tag{2}$$

TP menunjukkan *True Positive*, TN menunjukkan *True Negative*, FP menunjukkan *False Positive*, dan FN menunjukkan *False Negative*.

$$Recall = \frac{TP}{TP + FN} \tag{2}$$

TP menunjukkan *True Positive*, TN menunjukkan *True Negative*, FP menunjukkan *False Positive*, dan FN menunjukkan *False Negative*.

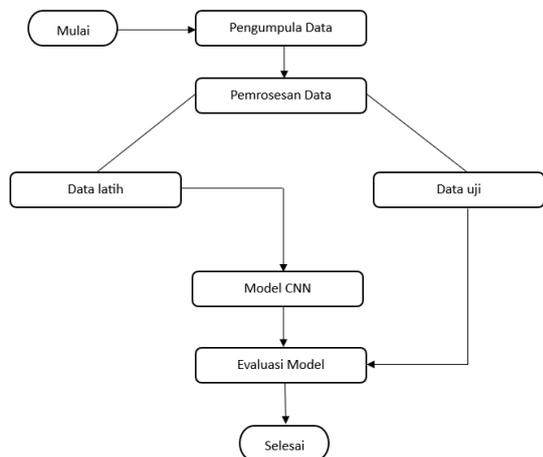
$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \tag{4}$$

Hasil evaluasi menunjukkan bahwa model CNN yang dibangun memberikan pemahaman tentang kinerja model dalam memprediksi kelengkapan atribut siswa.

Alur metode

Alur metode menjelaskan tentang jalannya metode yang dimulai dari pengumpulan data, data yang dipakai berisi foto gambar siswa yang menggunakan atribut lengkap serta tidak lengkap untuk dideteksi. Selanjutnya adalah pemrosesan data dengan cara augmentasi data untuk menyamakan ukuran gambar, peningkatan kecerahan dan kontras secara acak serta pergeseran gambar untuk membuat data lebih bervariasi menggunakan library augmentor, setelah itu dilakukan pelabelan pada gambar menggunakan labelimg. Langkah berikutnya data terbagi ke dalam 2 bagian yaitu data pelatihan dan data pengujian dengan memakai fungsi *train test split* dari pustaka *sklearn.model_selection*. Sebanyak 70% dari data digunakan sebagai data pelatihan untuk melatih model, sementara 30% sisanya dialokasikan sebagai data pengujian guna menilai performa model. Tahap berikutnya menyusun model CNN yang terbuat dari beberapa lapisan konvolusi, *max pooling*, *flatten* dan *dense*. Untuk pelatihan model memakai data pelatihan yang sudah dibagi sebelumnya. Selama proses pelatihan,

model terus disesuaikan dengan data pelatihan untuk meningkatkan kemampuannya dalam memprediksi kelengkapan atribut siswa. Kinerja model dievaluasi menggunakan data uji yang telah dipisahkan sebelumnya dari dataset. Metrik evaluasi yang digunakan untuk mengevaluasi model termasuk akurasi, presisi, recall, dan F1-score. Hasil evaluasi ini memberikan pemahaman yang jelas tentang kemampuan model dalam memprediksi kelengkapan atribut siswa berdasarkan data yang belum pernah dilihat selama proses pelatihan.



Gambar 4. Alur metode

Alat dan bahan penelitian

Pada penelitian ini, alat atau instrumen yang dipakai yaitu sebuah laptop Infinix Inboox X1 yang memiliki prosesor Intel Core i5-1035G1 generasi ke-10 dengan kecepatan hingga 3,6 GHz, yang cukup memadai untuk melakukan pemrosesan gambar dan pelatihan model CNN. Laptop ini dilengkapi dengan memori RAM berkapasitas 8GB DDR4, yang memungkinkan kinerja multitasking yang baik saat melakukan operasi yang memakan memori. Untuk menangani operasi komputasi paralel seperti pelatihan model CNN, laptop Infinix Inboox X1 ini dilengkapi dengan kartu grafis terintegrasi Intel UHD Graphics. Meskipun bukan kartu grafis dedicated, kartu grafis ini masih dapat digunakan untuk mempercepat proses pelatihan model CNN, meskipun tidak seefisien kartu grafis NVIDIA atau AMD. Laptop ini menggunakan solid-state drive (SSD) berkapasitas 256GB sebagai media penyimpanan utama, yang memastikan kecepatan akses data yang tinggi dan waktu booting yang cepat.



Gambar 5. Alat penelitian berupa laptop infinix inboox X1

Penelitian ini menggunakan beberapa library python untuk membantu proses pengembangan dan implementasi model CNN untuk deteksi kelengkapan atribut siswa. Library-library tersebut antara lain:

1. os merupakan library bawaan python yang digunakan untuk berinteraksi dengan sistem operasi, seperti membaca direktori dan *file dataset*.
2. xml.etree merupakan library bawaan python yang digunakan untuk memproses file XML untuk memproses informasi dari *dataset*.
3. numpy merupakan *library* yang digunakan untuk komputasi numerik dan manipulasi array. Dalam penelitian ini, numpy digunakan untuk memanipulasi data gambar sebagai array numpy yang dapat diproses oleh model CNN.
4. sklearn.model_selection dari library scikit-learn dipakai untuk memisahkan dataset menjadi data pelatihan dan data pengujian.
5. tensorflow merupakan *library open-source* yang dikembangkan oleh google untuk pengembangan dan pelatihan model CNN. Pada penelitian ini, tensorflow dipakai guna membangun arsitektur model CNN, melakukan kompilasi model, dan melatih model dengan data gambar yang sudah di proses.
6. keras adalah library yang berjalan di atas tensorflow dan menyediakan antarmuka yang lebih sederhana untuk membangun dan melatih serta mendefinisikan arsitektur model.
7. sklearn.metrics juga dari library scikit-learn yang dipakai untuk perhitungan metrik evaluasi seperti akurasi, presisi, recall, dan F1-score.
8. matplotlib.pyplot merupakan library yang dipakai untuk memvisualisasikan data dalam bentuk plot, grafik, atau gambar. Dalam penelitian ini, Matplotlib digunakan untuk menampilkan gambar dan hasil prediksi model CNN secara visual.

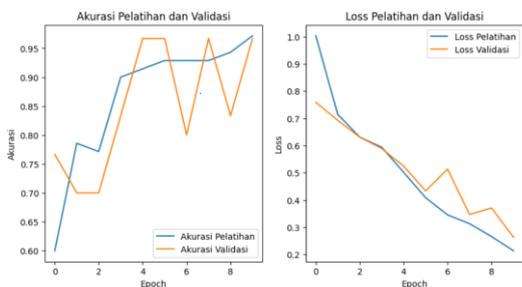
Dengan kombinasi library-library tersebut, peneliti dapat melakukan tugas-tugas seperti memuat data gambar dari *dataset*, membangun dan melatih model CNN, mengevaluasi performa model, serta memvisualisasikan hasil prediksi model dengan lebih efisien.

Bahan utama yang digunakan dalam penelitian ini berupa *dataset* gambar siswa yang mengenakan atribut sekolah lengkap dan tidak lengkap. *Dataset* ini terdiri dari 100 gambar dengan variasi yang cukup untuk melatih model CNN agar dapat mengenali dan mendeteksi kelengkapan atribut siswa dengan akurat. *Dataset* ini dibagi menjadi dua bagian, yaitu data latih dan data uji. Meskipun data gambar dalam penelitian ini diambil dari internet seperti *website* sekolah, peneliti menyarankan untuk menggunakan kamera digital dengan resolusi yang cukup tinggi untuk mengambil gambar siswa yang akan diproses.

IV. HASIL DAN PEMBAHASAN

Penelitian ini mengimplementasikan model CNN dalam mendeteksi kelengkapan atribut siswa dari gambar. Data yang dipakai terdiri dari gambar siswa yang mengenakan atribut lengkap serta tidak lengkap, seperti logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu. *Dataset* ini dibagi menjadi data pelatihan dan data pengujian secara acak dengan rasio 70:30 dengan memakai fungsi *train test split* dari pustaka *scikit-learn*. Model dilatih selama 10 *epoch* dengan *batch size* 16. Proses pelatihan ini bertujuan untuk mengoptimalkan bobot dan bias dalam model sehingga dapat mempelajari pola-pola dari data latih dan mampu melakukan deteksi dengan akurat. Untuk mengevaluasi performa model CNN dalam mendeteksi kelengkapan atribut siswa, dilakukan empat kali pengujian dengan menggunakan data uji yang berbeda di setiap pengujianya. Selama proses pengujian, grafik *epoch*, diagram batang hasil prediksi dan hasil metrik seperti akurasi, presisi, recall, dan F1-score dicatat dalam setiap pengujian. Hasil dari empat kali pengujian ini akan dibahas secara terperinci di mana setiap pengujian akan disajikan dengan grafik *epoch*, diagram batang untuk hasil prediksi setiap kelas dan nilai metrik yang diperoleh.

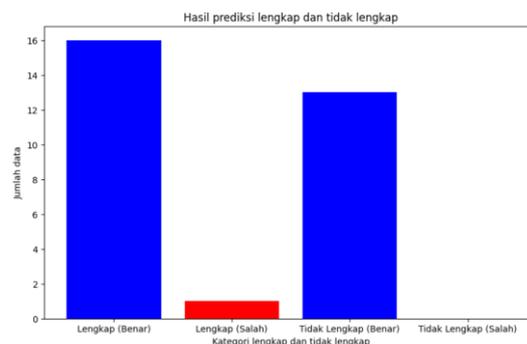
Berdasarkan hasil pengujian pertama jumlah data pengujian yang dipakai adalah 30 data dengan dataset yang sudah diacak yaitu 17 data dari kelas lengkap dan 13 data untuk kategori tidak lengkap.



Gambar 6. Grafik *epoch* pengujian 1

Gambar 6 menampilkan hasil akurasi dan *loss* selama pelatihan 10 *epoch* dengan *batch size* 16. Grafik *epoch* menunjukkan performa model selama proses pelatihan berlangsung, pada *epoch* satu, akurasi pelatihan berada di angka 0.5672 sedangkan akurasi validasi yaitu 0.7667, yang menunjukkan bahwa model masih belum dapat mendeteksi data dengan baik pada awal pelatihan. Namun, seiring bertambahnya *epoch*, akurasi pelatihan terus meningkat secara teratur hingga mencapai angka 0.9627 pada *epoch* terakhir, sedangkan akurasi validasi cenderung fluktuasi seperti tidak stabilnya model dalam mendeteksi data uji, akan tetapi untuk akurasi validasi mencapai angka yang tinggi yaitu 0.9667 dan merupakan akurasi yang cukup baik. Sebaliknya, nilai *loss* (*binary cross-entropy*) terus

menurun dari angka 1.1134 pada *epoch* satu hingga mencapai 0.2282 pada *epoch* terakhir untuk *loss* pelatihan sedangkan *loss* validasi dimulai dari 0.7587 dan terus menurun hingga 0.2632. Penurunan nilai *loss* ini mengindikasikan bahwa model semakin baik dalam mempelajari pola-pola dari data pelatihan serta data uji dan meminimalkan kesalahan prediksi. Selain itu, grafik juga menunjukkan bahwa akurasi validasi dan *loss* validasi cenderung lebih berfluktuasi dibandingkan dengan akurasi dan *loss* pada data pelatihan. Hal ini dapat disebabkan oleh *overfitting*, di mana model terlalu menyesuaikan dengan data pelatihan dan gagal untuk menggeneralisasi dengan baik pada data validasi yang belum pernah dilihat sebelumnya.



Gambar 7. Diagram hasil prediksi pengujian 1

Untuk mengevaluasi kinerja model secara lebih rinci, gambar 7 menunjukkan hasil prediksi pengujian pertama untuk kategori siswa yang memakai atribut lengkap dan tidak lengkap, diagram batang digunakan untuk memvisualisasikan hasil prediksi model berdasarkan matriks konfusi. Dari diagram batang tersebut, dapat dilihat bahwa nilai *true positive* (TP) adalah 16, yang berarti model berhasil memprediksi dengan benar 16 data gambar dari kategori lengkap. Nilai *false negative* (FN) adalah 1, yang menunjukkan bahwa terdapat 1 data yang seharusnya siswa tersebut lengkap tetapi salah diprediksi sebagai tidak lengkap. Sementara itu, nilai *true negative* (TN) adalah 13, yang berarti terdapat 13 data yang diprediksi dengan benar sebagai kategori tidak lengkap oleh model. Terakhir, nilai *false positive* (FP) adalah 0, yang menunjukkan bahwa model tidak salah memprediksi dari data tidak lengkap sebagai lengkap.

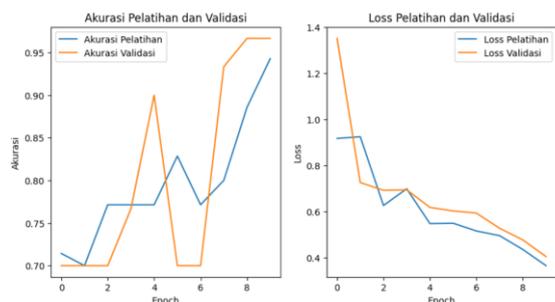
Tabel 1. Hasil evaluasi pengujian 1

Metrik	Hasil
Akurasi	96.67%
Presisi	100.00%
Recall	94.12%
F1-score	96.97%

Berdasarkan pada tabel hasil evaluasi pengujian 1, model mencapai hasil yang sangat baik dengan akurasi sebesar 96,67%, presisi 100,00%, recall

94,12%, dan F1-score 96,97%. Hasil metrik ini menunjukkan kinerja yang sangat baik dari model CNN dalam mendeteksi kelengkapan atribut siswa pada *dataset* gambar yang diberikan. Akurasi yang tinggi mengindikasikan bahwa model dapat memprediksi dengan benar sebagian besar data pengujian. Presisi sempurna menunjukkan bahwa semua data yang diprediksi lengkap oleh model adalah benar. Meskipun recall sedikit lebih rendah, namun F1-score yang tinggi mencerminkan keseimbangan yang baik antara presisi dan recall. Secara keseluruhan, hasil metrik pada pengujian 1 ini memvalidasi kinerja model CNN dalam mendeteksi kelengkapan atribut siswa pada *dataset* gambar dengan akurasi dan keandalan yang sangat baik.

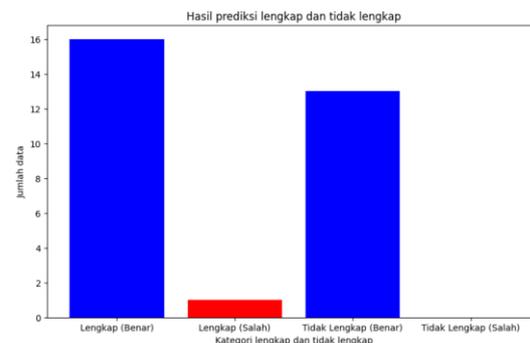
Setelah melakukan pengujian pertama dengan hasil yang sangat baik, langkah selanjutnya adalah melakukan pengujian kedua untuk memvalidasi kinerja model dan mengevaluasi konsistensinya. Pengujian kedua ini dilakukan dengan menggunakan *dataset* yang sudah diacak menggunakan *train test split* yaitu 17 data untuk lengkap dan 13 data untuk tidak lengkap sama seperti pengujian sebelumnya. Tujuannya adalah untuk melihat apakah model dapat mempertahankan kinerjanya yang baik dalam mendeteksi kelengkapan atribut siswa pada data yang berbeda. Selain itu, pengujian kedua juga bertujuan untuk mengidentifikasi adanya peningkatan atau penurunan kinerja model dibandingkan dengan pengujian pertama.



Gambar 8. Grafik *epoch* pengujian 2

Dari grafik pengujian 2, terlihat bahwa akurasi pelatihan meningkat dengan cukup konsisten seiring bertambahnya *epoch* meskipun ada yang menurun, dimana pada *epoch* pertama akurasi pelatihannya yaitu 0.6739 hingga ke *epoch* sepuluh mencapai 0.9667. Sementara itu, akurasi validasi menunjukkan peningkatan yang lebih fluktuatif, dimana pada *epoch* pertama akurasi validasi yaitu 0.7000 meningkat sampai 0.9667 di *epoch* terakhir. Sedangkan *loss* pelatihan dan validasi menurun, dimana nilai awal *loss* pelatihan yaitu 1.0377 sampai 0.4296 dan *loss* validasi yaitu 1.3521 turun sampai 0.4060. Berdasarkan gambar 8 dapat disimpulkan bahwa tidak terdapat indikasi *overfitting* yang signifikan pada model dikarenakan selisih antara

metrik pada data pelatihan dan validasi cukup kecil, dan performa model cukup baik.



Gambar 9. Diagram hasil prediksi pengujian 2

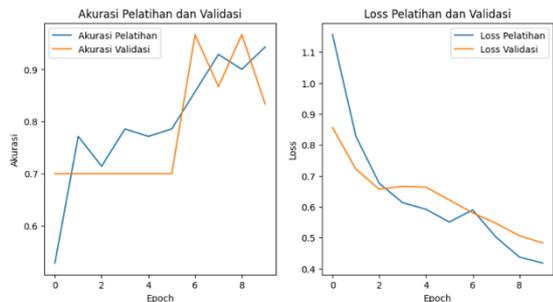
Gambar 9 yang menunjukkan hasil prediksi model pada pengujian kedua ini ternyata identik dengan diagram hasil prediksi yang diperoleh pada pengujian pertama sebelumnya. Diagram tersebut memvisualisasikan jumlah *true positive* (TP), *false negative* (FN), *true negative* (TN), dan *false positive* (FP) yang diperoleh dari matriks konfusi model. Seperti halnya pengujian pertama, diagram hasil prediksi yang kedua menunjukkan bahwa model berhasil memprediksi dengan benar 16 data dari kelas lengkap sebagai lengkap (TP). Namun, masih terdapat 1 data dari kelas lengkap yang salah diprediksi sebagai tidak lengkap (FN). Sementara itu, untuk kelas tidak lengkap model berhasil memprediksi dengan benar 13 data sebagai tidak lengkap (TN) dan tidak ada data yang salah diprediksi sebagai lengkap (FP).

Tabel 2. Hasil evaluasi pengujian 2

Metrik	Hasil
Akurasi	96.67%
Presisi	100.00%
Recall	94.12%
F1-score	96.97%

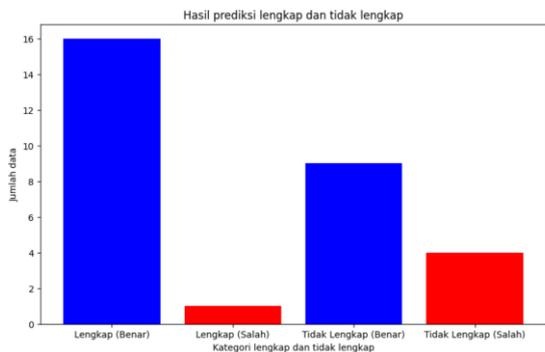
Pada pengujian yang kedua untuk hasilnya dapat dilihat dari tabel 2. Secara keseluruhan, hasil metrik pada pengujian kedua ini sangat mirip dengan pengujian pertama yang dilakukan sebelumnya, dimana untuk hasil akurasi mendapatkan 96.67%, presisi 100.00%, recall 94.12%, dan f1-score 96.97%.

Selanjutnya untuk pengujian yang ke 3 terdapat penurunan pada kinerja model.



Gambar 10. Grafik epoch pengujian 3

Pada grafik *epoch* pengujian ke 3, terlihat bahwa akurasi pelatihan meningkat secara konsisten dari *epoch* pertama hingga kesepuluh. Pada awalnya, akurasi pelatihan dimulai dari 0.4479 dan secara bertahap meningkat hingga mencapai 0.9627 pada *epoch* ke sepuluh. Di sisi lain, akurasi validasi menunjukkan pola yang lebih fluktuatif, tetap stabil di angka sekitar 0.7000 hingga *epoch* keenam sebelum akhirnya meningkat tajam hingga 0.9667 pada *epoch* ketujuh. Namun, pada *epoch* ke delapan, terjadi sedikit penurunan akurasi validasi sebelum akhirnya kembali meningkat pada *epoch* ke sembilan dan turun lagi pada *epoch* ke sepuluh yaitu 0.8333. *Loss* pelatihan dan *loss* validasi menunjukkan tren yang diinginkan, di mana baik *loss* pelatihan maupun validasi menurun seiring dengan bertambahnya *epoch*. *Loss* pelatihan mengalami penurunan signifikan dari 1.2593 di *epoch* pertama hingga mencapai sekitar 0.4143 pada *epoch* ke sepuluh. Sementara itu, *loss* validasi juga menurun dari 0.8563 di *epoch* pertama menjadi sekitar 0.4830 pada *epoch* ke sepuluh, menunjukkan bahwa model semakin mampu meminimalkan kesalahan dalam memprediksi kelengkapan atribut siswa. Fluktuasi yang terlihat dalam akurasi validasi adalah hal yang umum terjadi selama proses pelatihan model dan tidak secara langsung mengindikasikan *overfitting*. Meskipun terdapat beberapa fluktuasi, secara keseluruhan, akurasi validasi meningkat dan *loss* validasi menurun. Ini menunjukkan bahwa model masih belajar dari data secara efektif tanpa menunjukkan pola *overfitting* yang jelas, di mana akurasi validasi akan menurun dan *loss* validasi akan meningkat setelah beberapa *epoch*.



Gambar 11. Diagram hasil pengujian 3

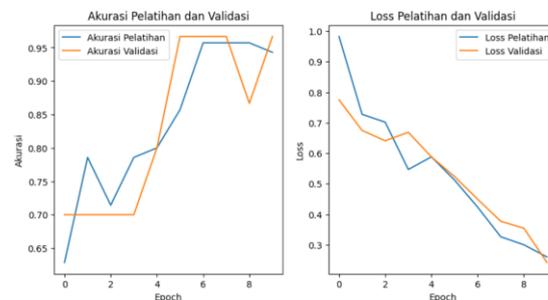
Hasil prediksi pengujian ketiga ditunjukkan pada gambar 11. Dari hasil pengujian ketiga terdapat penurunan pada kinerja model. Tidak seperti pengujian pertama dan kedua, diagram hasil prediksi yang ketiga menunjukkan bahwa model berhasil memprediksi dengan benar 16 data dari kelas lengkap sebagai lengkap (TP). Namun, masih terdapat 1 data dari kelas lengkap yang salah diprediksi sebagai tidak lengkap (FN). Sementara itu, untuk kelas tidak lengkap model berhasil memprediksi dengan benar sebanyak 9 data sebagai tidak lengkap (TN) dan 4 data tidak lengkap yang salah diprediksi sebagai lengkap (FP).

Tabel 3. Hasil evaluasi pengujian 3

Metrik	Hasil
Akurasi	83.33%
Presisi	80.00%
Recall	94.12%
F1-score	86.49%

Pada pengujian ketiga, terjadi penurunan kinerja model dibandingkan sebelumnya, tabel 3 hasil evaluasi pengujian menunjukkan perbedaan kinerja model dari pengujian sebelumnya, untuk hasil metrik akurasi hanya mencapai 83.33%, presisi 80.00%, recall 94.12%, dan F1-score 86.49%. Meskipun hasil pengujian metriknya masih terbilang cukup tinggi, akan tetapi akurasi keseluruhan mengalami penurunan dari angka 94.67% menjadi 83.33%. hal ini mencerminkan bahwa 16.67% prediksi model tidak akurat. Selain itu, presisi hanya mencapai angka 80.00% dari yang sebelumnya mencapai angka sempurna, hal tersebut menunjukkan adanya peningkatan kesalahan positif dibandingkan pengujian sebelumnya.

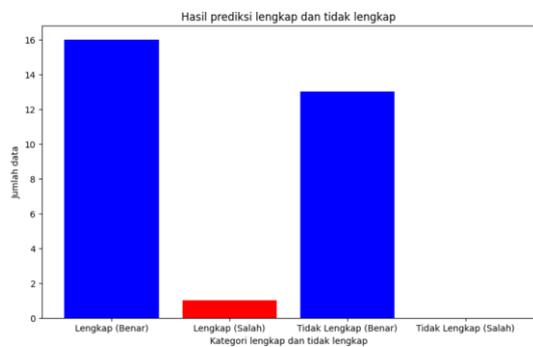
Selanjutnya untuk pengujian keempat, dimana hasil dari pengujian keempat ini menghasilkan metrik yang sama dengan pengujian satu dan dua.



Gambar 12. Grafik epoch pengujian ke 4

Pada awal proses pelatihan, akurasi pelatihan cukup rendah yaitu 0,6106 yang menunjukkan model belum dapat menangkap pola data dengan baik. Namun, akurasi pelatihan terus meningkat seiring bertambahnya *epoch* dan mencapai nilai tertinggi di angka 0,9549 pada *epoch* terakhir. Peningkatan ini mengindikasikan bahwa model berhasil mempelajari pola dari data pelatihan dengan sangat baik. Di sisi

lain, akurasi validasi memiliki pola yang sedikit berbeda. Pada awal pelatihan, akurasi validasi berada di angka 0,7000 yang menunjukkan model belum dapat menggeneralisasi pola dengan baik pada data validasi dan terdapat fluktuasi pada akurasi validasi. Setelah melewati beberapa *epoch*, akurasi validasi meningkat tajam di *epoch* kelima dan enam, serta mengalami penurunan di *epoch* ke sembilan dan nilai terakhir mencapai angka 0,9667 pada *epoch* akhir.



Gambar 13. Diagram hasil pengujian 4

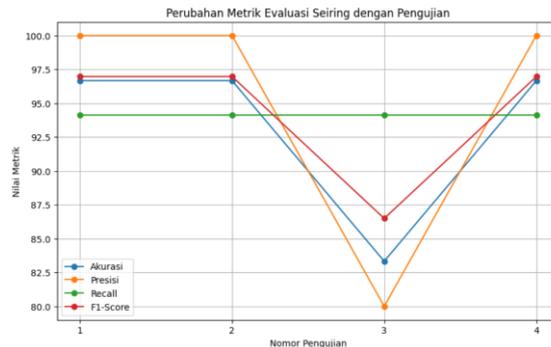
Hasil prediksi pengujian keempat dapat dilihat dari gambar 13, hasilnya sama seperti pada pengujian pertama dan kedua yaitu menunjukkan bahwa model berhasil memprediksi dengan benar 16 data dari kelas lengkap sebagai lengkap (TP). Namun, masih terdapat 1 data dari kelas lengkap yang salah diprediksi sebagai tidak lengkap (FN). Sementara itu, untuk kelas tidak lengkap model berhasil memprediksi dengan benar 13 data sebagai tidak lengkap (TN) dan tidak ada data yang salah diprediksi sebagai lengkap (FP).

Tabel 4. Hasil evaluasi pengujian 4

Metrik	Hasil
Akurasi	96.67%
Presisi	100.00%
Recall	94.12%
F1-score	96.97%

Pada pengujian ke empat juga menghasilkan metrik yang sama seperti pengujian pertama dan kedua, dimana untuk hasil akurasi mendapatkan 96.67%, presisi 100.00%, recall 94.12%, dan f1-score 96.97%.

Setelah melakukan empat kali pengujian, peneliti mendapatkan gambaran yang lebih komprehensif tentang performa model CNN dalam mendeteksi kelengkapan atribut siswa. Masing-masing pengujian menghasilkan nilai metrik evaluasi seperti akurasi, presisi, recall, dan F1-score. Dengan merata-ratakan hasil dari ke empat pengujian tersebut, peneliti dapat memperoleh estimasi performa model yang lebih stabil dan representatif.



Gambar 14. Grafik rata-rata pengujian

Setelah melakukan perhitungan rata-rata dari keempat pengujian, diperoleh nilai akurasi sebesar 93.34%, presisi sebesar 95.00%, recall sebesar 94.12%, dan skor F1 sebesar 94.35%. Nilai-nilai ini menunjukkan bahwa secara keseluruhan, model CNN mampu mendeteksi data gambar siswa dengan akurasi yang cukup tinggi. Presisi yang tinggi mengindikasikan bahwa model jarang salah dalam memprediksi data sebagai lengkap, sementara recall yang tinggi menunjukkan bahwa model dapat mendeteksi dengan baik data-data yang sebenarnya lengkap serta F1-score menunjukkan keharmonisan antara presisi dan recall.

Tabel 5. Hasil rata-rata

Metrik	Rata-Rata
Akurasi	93.34%
Presisi	95.00%
Recall	94.12%
F1-score	94.35%

Pada tabel 5 menunjukkan secara keseluruhan hasil rata-rata dari keempat pengujian yang memberikan bukti cukup kuat bahwa model CNN yang diterapkan memiliki potensi yang besar dalam membantu mendeteksi kelengkapan atribut siswa secara otomatis. Namun, masih terdapat ruang untuk perbaikan dan optimasi lebih lanjut agar performa model dapat ditingkatkan dan menjadi lebih andal dalam berbagai kondisi dan skenario penggunaan.

V. KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini bertujuan untuk menerapkan metode CNN dalam mendeteksi kelengkapan atribut siswa seperti logo sekolah, logo osis, *nametag*, logo bendera, sabuk, dan sepatu dari gambar menggunakan *computer vision*. Melalui serangkaian pengujian dengan *dataset* gambar siswa yang bervariasi, diperoleh temuan-temuan penting sebagai berikut:

1. Metode CNN terbukti efektif untuk melakukan deteksi kelengkapan atribut siswa dengan empat kali pengujian dan menghasilkan akurasi yang cukup tinggi dengan rata-rata 93,34%, presisi 95%, recall 94,12%, dan F1-score

94,35%. Hasil ini menunjukkan bahwa CNN dapat dimanfaatkan untuk proses pengawasan dan evaluasi kelengkapan atribut siswa secara objektif dan efisien.

2. Penerapan CNN dalam penelitian ini membuktikan potensi penggunaan teknik pembelajaran mesin (*machine learning*) dan kecerdasan buatan (*artificial intelligence*) di bidang pendidikan, terutama dalam membantu proses administrasi, evaluasi, dan penegakan disiplin di lingkungan sekolah.
3. Solusi berbasis CNN memberikan alternatif yang lebih objektif, efisien, dan mengurangi beban kerja manual dalam mengevaluasi kelengkapan atribut siswa dibandingkan dengan metode konvensional yang rentan terhadap subjektivitas dan ketidakkonsistenan.
4. Penelitian ini dapat berkontribusi pada pengembangan model deteksi dan klasifikasi menggunakan CNN dengan akurasi yang tinggi serta menunjukkan potensi penerapannya dalam bidang pendidikan dan evaluasi akademik.
5. Masih terdapat ruang untuk peningkatan akurasi dan generalisasi model dengan memperoleh dataset yang lebih besar dan beragam, serta mengeksplorasi teknik dan metrik evaluasi yang berbeda untuk mendapatkan hasil yang lebih optimal.

Saran

Meskipun penelitian ini telah menunjukkan hasil yang cukup menjanjikan dalam menerapkan metode CNN untuk mendeteksi kelengkapan atribut siswa dari gambar, masih terdapat beberapa area yang dapat ditingkatkan dan dikembangkan lebih lanjut. Dengan mempertimbangkan temuan serta kekurangan dalam penelitian ini, saran-saran yang dapat dipertimbangkan untuk penelitian di masa mendatang yaitu:

1. Mengumpulkan *dataset* gambar siswa yang lebih besar dan beragam, mencakup berbagai variasi seperti latar belakang, pencahayaan, posisi, dan resolusi gambar. Hal ini dapat meningkatkan generalisasi model dan akurasi dalam mendeteksi kelengkapan atribut siswa pada kondisi yang lebih realistis.
2. Mengeksplorasi teknik pra-pemrosesan gambar (*image preprocessing*) yang lebih canggih, seperti augmentasi data, normalisasi, dan teknik lainnya untuk meningkatkan kualitas dan variasi *dataset* serta memperbaiki performa model CNN.
3. Menerapkan metode *transfer learning* dengan menggunakan model CNN yang telah dilatih sebelumnya pada *dataset* gambar yang besar, seperti ImageNet, untuk mempercepat proses pelatihan dan meningkatkan akurasi model.
4. Mengembangkan model CNN yang mampu mendeteksi kelengkapan atribut siswa secara

lebih rinci, tidak hanya mengklasifikasikan lengkap atau tidak lengkap, tetapi juga dapat mengidentifikasi atribut mana yang tidak dikenakan oleh siswa.

DAFTAR PUSTAKA

- Adi Nugroho, P., Fenriana, I., & Arijanto, R. (2020). Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) pada Ekspresi Manusia. *Jurnal ALGOR*, 2(1). <https://jurnal.buddhidharma.ac.id/index.php/algor/index>
- Alfanda Annur, P., Eri Susanti, S., Irega Gelly Gera, S., S., & Author, C. (2023). Urgensi Pendidikan Moral Sekolah Dasar Dalam Membentuk Karakter Religius di Era Digital Menurut Henry Alexis Rudolf Tilaar. *J*, 271–287.
- Computer, P., Pendeteksi, V., Apel, B., Jeruk, D., Bahasa, M., Normalisa, P., Rachmaniar, A., Diana, D., Saefudin, M., & Parulian, R. (2022). Application Of Computer Vision Detection Of Apples And Oranges Using Python Language. *Journal of Information System, Informatics and Computing Issue Period*, 6(2), 455–466. <https://doi.org/10.52362/jisicom.v6i2.946>
- Duta, C., Dinata, W., & Ali, M. (2024). Strategi Inovatif Guru Pendidikan Agama Islam dalam Membentuk Karakter Disiplin Peserta Didik: Sebuah Kajian dengan Pendekatan Fenomenologi. In *Jurnal Kependidikan* (Vol. 13, Issue 1). <https://jurnaldidaktika.org>
- Dwi Hartomo, B. (2021). Penerapan Computer Vision untuk Absensi Wajah Berbasis Algoritma CNN pada Guru SMK Excellent 1 Tangerang. In *Jurnal Teknik Informatika Mahakarya (JTIM) JTIM* (Vol. 4, Issue 2).
- Esmiati, A. N., Prihartanti, N., & Partini, P. (2020). Efektivitas pelatihan kesadaran diri untuk meningkatkan kedisiplinan siswa. *Jurnal Ilmiah Psikologi Terapan*, 8(1), 113. <https://doi.org/10.22219/jipt.v8i1.11052>
- Fajri, R., & Atika, L. (n.d.). Implementasi Machine Learning dengan Menggunakan CNN (Convolutional Neural Network) untuk Klasifikasi Citra Candi. *Bina Darma Conference on Computer Science*.
- Herdiansyah, D., & Kurniati, P. S. (2020). Pembangunan Sektor Pendidikan sebagai Penunjang Indeks Pembangunan Manusia di Kota Bandung. *Jurnal Agregasi: Aksi Reformasi Government Dalam Demokrasi*, 8(1). <https://doi.org/10.34010/agregasi.v8i1.2765>
- Ibnu Sholeh, M. (2020). Menghadapi Persaingan Sengit Lembaga Pendidikan: Strategi Diferensiasi dalam Pemasaran Lembaga Pendidikan Islam di Indonesia. *Jurnal*

- Manajemen Pendidikan Islam*, 1(3), 192–222.
<https://doi.org/10.37348/aksi.v1i3.259>
- Mamuriyah, N., & Sumantri, J. (2022). Penerapan Metode Convolution Neural Network (CNN) Pada Aplikasi Automatic Lip Reading. *Journal Of Informatics And Telecommunication Engineering*, 6(1), 276–287. <https://doi.org/10.31289/jite.v6i1.7523>
- Nasution, D. (2023). *METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi*. 7(1). <https://doi.org/10.46880/jmika.Vol7No1.pp54-60>
- Qotrunnada, F. M., & Utomo, P. H. (2022). Metode Convolutional Neural Network untuk Klasifikasi Wajah Bermasker. *Prosiding Seminar Nasional Matematika*, 5, 799–807. <https://journal.unnes.ac.id/sju/index.php/prisma/>
- Rizqi Efrian, M., Latifa, U., Teknik Elektro, J., Teknik, F., Singaperbangsa Karawang, U., Ronggo Waluyo, J. H., Telukjambe Timur, K., Karawang, K., & Barat, J. (n.d.). Image Recognition Berbasis Convolutional Neural Network (CNN) untuk Mendeteksi Penyakit Kulit Pada Manusia. *Jurnal POLEKTRO: Jurnal Power Elektronik*, 11(1), 2022.
- Satyo Prihatin, S., & Dina Atika, P. (2021). Sistem Informasi Pemilihan Peserta Program Indonesia Pintar (PIP) Dengan Metode K-Nearest Neighbor pada SD Negeri Pejuang V Kota Bekasi (Vol. 2, Issue 2). <http://ejournal.ubharajaya.ac.id/index.php/JSR-CS>
- Zainal Altim, M., Yudhistira, A., Amalia Syamsul, R., & Teknik, J. (2022). Pengklasifikasi Beras Menggunakan Metode CNN (Convolutional Neural Network). 7(1).