

Klasifikasi Kesesuaian Hasil Assembly Wire Harness Menggunakan Mobilenet Teroptimasi di Edge TPU

Penulis 1, Shabrina Rachmawati Azzahra 2, Eko Rudiawan Jamzuri

Department of Electrical Engineering, Politeknik Negeri Batam, Batam, Kepulauan Riau, Indonesia

Article Info

Article history:

Received month dd, yyyy

Revised month dd, yyyy

Accepted month dd, yyyy

Keywords:

Edge TPU

Klasifikasi Gambar

MobilNet

Google Coral

Wire Harness

ABSTRACT

QC masih menjadi topik penting untuk diteliti, terutama pada bidang industri. Di industri yang memproduksi kabel harness, dibutuhkan pengecekan untuk memastikan *blue tape*, *pink tape* dan konektor terpasang sesuai dengan urutan dan standar kerja. Pengecekan tersebut saat ini masih dilakukan secara visual, oleh karena itu penelitian ini dilakukan dengan menggunakan *Convolutional Neural Network* (CNN) untuk klasifikasi gambar dan pengenalan pola dengan menggunakan *Tensor Processing Unit* (TPU). Klasifikasi gambar memerlukan dataset sebanyak 12.510 yang sudah diberi label yang sesuai lalu di *retrain* menggunakan dataset baru dengan Tensorflow. Pada pengujian pelatihan data dilakukan iterasi 50 kali pada data, mendapatkan nilai loss 0.01 dan akurasi sebesar 0,99. Sehingga model dapat berhasil mengklasifikasikan gambar dengan tepat ketika semua poin ada dan berada dalam urutan yang benar. Ketika ada poin yang hilang atau urutan poin berubah, maka sistem akan mengklasifikasi sebagai NG.

This is an open access article under the [CC BY-SA](#) license.



Corresponding Author:

Eko Rudiawan Jamzuri

Department of Electrical Engineering, Politeknik Negeri Batam

Jl. Ahmad Yani, Kel. Teluk Tering, Kec. Batam Kota, Kota Batam, Kepulauan Riau 29461, Indonesia

Email: ekorudiawan@polibatam.ac.id

1. INTRODUCTION

Dalam dunia pengolahan citra dan machine learning adalah klasifikasi gambar, di mana gambar diidentifikasi dan dikelompokkan berdasarkan karakteristik tertentu. Proses ini melibatkan langkah-langkah seperti ekstraksi fitur dari gambar, pelatihan model mesin, dan penggunaan model tersebut untuk mengklasifikasikan gambar yang tidak dikenali. Kemajuan teknologi seperti *Convolutional Neural Networks* (CNN), telah meningkatkan kemampuan dalam klasifikasi gambar, membuka peluang dalam berbagai industri [1].

Dalam era pertumbuhan teknologi yang pesat dan persaingan bisnis yang semakin sengit, industri harus berupaya keras untuk menciptakan produk yang unggul. Oleh karena itu, setiap perusahaan perlu menjamin kualitas produk mereka dengan efisien [2]. Kualitas (*quality control*) adalah aspek penting dalam dunia produksi industri. Proses yang dirancang untuk memastikan bahwa produk sesuai dengan standar spesifikasi yang ditetapkan.[3]. Seperti pada perusahaan industri yang memproduksi kabel *harness*, selama proses produksi perlu dipastikan bahwa konektor dan selotip penanda dipasang sesuai dengan standar kerja yang telah ditetapkan. Namun, proses ini dilakukan oleh karyawan/operator khusus dengan melakukan pengecekan secara visual, yang memakan waktu sekitar 1,5 menit untuk menginspeksi kabel harness sebanyak 30 poin.

Oleh karena itu, penelitian ini yang bertujuan untuk, mengklasifikasi konektor dan selotip penanda dipasang sesuai dengan standar kerja yang ditentukan. Proses kegiatan yang masih dilakukan secara manual melalui visual operator tersebut tidak efektif, terutama dalam efisiensi waktu untuk mendapatkan target produksi perusahaan [4]. Inspeksi yang dilakukan secara manual oleh operator visual terbukti kurang efektif dalam mencapai target produksi perusahaan, dan adanya risiko kesalahan manusia selama proses tersebut dapat menyebabkan produk cacat masuk ke

pasar. Jika situasi ini berlanjut, hal ini akan mengakibatkan penurunan kepercayaan konsumen terhadap mutu produk dari perusahaan tersebut.

Oleh karena itu, diperlukan pengembangan sistem kamera inspeksi yang lebih cepat dan akurat sebagai solusi terhadap inspeksi visual yang saat ini masih dilakukan secara manual oleh operator [5]. Sistem ini akan memiliki kemampuan untuk memastikan bahwa konektor dan selotip penanda dipasang sesuai dengan standar kerja yang ditentukan. Sistem ini akan menjalankan tugasnya secara otomatis, menghasilkan hasil yang lebih efisien, dan menghemat waktu pengerjaan. Solusi yang diimplementasikan untuk sistem inspeksi otomatis ini menggunakan sebuah sistem klasifikasi gambar. Penggunaan pendekatan ini merupakan hal yang cukup menarik karena memberikan solusi yang efektif. *Convolutional Neural Networks* (CNN) menunjukkan kinerja terbaik dalam hal klasifikasi gambar, *machine learning* dan pengenalan pola [6]. *Google* baru-baru ini merilis perangkat keras baru yang dapat melakukan komputasi AI tertentu dengan kecepatan yang sangat cepat. Penggunaan *Tensor Processing Unit* (TPU) untuk mempercepat pelatihan *machine learning*[7]. Pada tahun 2017 dikeluarkan sebuah Arsitektur jaringan saraf yang ringan yang dirancang untuk sebuah aplikasi tertanam seperti telepon/handphone dan perangkat *edge* yang diberi nama *MobileNet* [8]. Sejak saat itu banyak penelitian yang mengembangkan model jaringan saraf yang ringan seperti *MobileNet* [8], *MobileNet-V2* [9], *MobileNet-V3* [10], dan *MobileDet* [11].

Menurut penelitian sebelumnya yang membahas mengenai *MobileNetV2*[12]. Penelitian yang dilakukan oleh Tej Bahadur Shahi dkk [13], para peneliti membandingkan beberapa model, seperti *DenseNet121*, *NASNetMobile*, *VGG-16*, *MobileNetV1*, *InceptionV3*, dan *MobileNetV2*, untuk klasifikasi gambar buah. Dari keenam model tersebut, *MobileNetV2* menunjukkan kinerja terbaik dengan akurasi klasifikasi yang stabil sebesar 95,75% pada Dataset 1, 96,74% pada Dataset 2, dan 96,23% pada Dataset 3. Hasil ini menunjukkan bahwa *MobileNetV2* tidak hanya efisien dalam hal kecepatan dan penggunaan sumber daya, tetapi juga unggul dalam memberikan hasil yang konsisten dan akurat pada berbagai set data klasifikasi gambar. Kemudian pada penelitian Sheikh Rufsan Reza dkk [14], membandingkan performa klasifikasi dari beberapa jenis CNN yang populer pada perangkat *edge computing*. Khususnya, model *MobileNet V1 & V2* dan *Inception V3* diuji pada *NVIDIA Jetson TX2*, *Jetson Nano*, dan *Google Edge TPU* untuk klasifikasi gambar. Hasil eksperimen menunjukkan bahwa *Edge TPU*[15] mengungguli *Nvidia Jetson TX2* dan *Nano* dalam sebagian besar uji dengan kecepatan inferensi yang lebih cepat dan akurasi yang lebih tinggi. Selain itu, pada penelitiannya *MobileNetV2* terbukti menjadi model yang unggul dalam hal kecepatan. Hasil ini menunjukkan bahwa kombinasi *Edge TPU* dan *MobileNet V2* sangat cocok, memberikan kecepatan inferensi yang cepat dan akurasi tinggi untuk klasifikasi gambar.

Pembahasan lanjutan dalam penelitian ini akan menjelaskan metodologi yang digunakan, prosedur kerja sistem klasifikasi, penilaian hasil pengujian, serta analisis dan temuan yang dihasilkan. Serta kesimpulan akhir berdasarkan hasil dan diskusi dari keseluruhan penelitian yang dilakukan.


2. METHOD

Pada tahap ini, membahas mengenai metode yang dipakai pada sistem klasifikasi gambar. Proses untuk pengumpulan dataset ini, menggunakan satu kamera dan *Edge Tensor Processing Unit* (TPU) yang disediakan oleh *Google USB Accelerator* [7]. Proses berikutnya menerapkan pelatihan model menggunakan *TensorFlow* untuk membuat model klasifikasi gambar [16]. Melatihnya dengan kumpulan data, dan mengonversinya menjadi *TensorFlow Lite* menggunakan kuantisasi pasca-pelatihan. Model ini didasarkan pada versi *MobileNetV2* yang telah dilatih sebelumnya yang akan dijalankan pada sistem ini [6]. Terakhir dalam bagian ini adalah melakukan evaluasi metode dengan berbagai macam skenario yang telah disiapkan. Hal ini akan memungkinkan, sistem untuk mengklasifikasi dengan akurat komponen seperti: *Blue Tape*, *Pink Tape* dan *Connector* sesuai dengan urutannya.

2.1. Dataset Collection

Pada penelitian ini, proses dalam pengumpulan dataset dilakukan dengan cara mengambil sampel foto konektor dan selotip penanda dengan warna yang berbeda. Tujuannya adalah mengelompokkan dan mengidentifikasi objek yang telah ditentukan sebelumnya. Proses ini menggunakan algoritma *Machine Learning* (ML) untuk menganalisis fitur visual dalam gambar dan menentukan kategori kelas yang paling sesuai [17]. Klasifikasi gambar memiliki berbagai peranan yang penting pada penelitian ini, yaitu dalam pengenalan bentuk komponen seperti konektor dan 2 warna selotip penanda. Dataset yang berisi gambar-gambar yang telah dikelompokkan, seperti pada Gambar 1. Kecerdasan dan penambahan saturasi juga akan dilakukan supaya model dapat menyesuaikan diri dengan lebih baik dalam kondisi pencahayaan yang berbeda-beda. Dataset penelitian ini terdiri dari total 12.510 gambar, yang dikategorikan ke dalam empat kelas: *Blue Tape* 2.388 gambar, *Pink Tape* 2.220 gambar, *Connector* 2.334 gambar, dan *Empty* 5.568 gambar. Kelas “*Empty*” adalah kategori yang mencakup gambar-gambar yang tidak termasuk dalam tiga kelas lainnya, yaitu *Blue Tape*, *Pink Tape*, dan *Connector*. Jika sebuah gambar tidak dapat diklasifikasikan sebagai *Blue Tape*, *Pink Tape*, dan *Connector*, maka gambar tersebut akan dimasukkan ke dalam kelas “*Empty*”. Kategori ini juga bisa dianggap sebagai kelas “*Reject*” karena mencakup semua gambar yang tidak sesuai dengan tiga kategori utama. Setiap gambar dalam dataset telah diberi anotasi sesuai dengan kategori yang telah ditentukan. Setelah proses


anotasi selesai, data tersebut akan digunakan untuk melatih model menggunakan arsitektur *MobileNetV2*. Dengan demikian, model dapat belajar dan memahami data tersebut untuk melakukan tugas yang diminta.



Gambar 1. *Dataset Collection*

2.2. Training Model

Dalam penelitian ini, TensorFlow digunakan untuk memproses *MobileNetV2* [18]. Kemudian melatih ulang model dengan data baru, menghasilkan pengklasifikasi dengan komputasi yang cepat dan akurasi yang baik. TensorFlow adalah *opensource library* untuk *machine learning* yang di *release* oleh Google yang mendukung beberapa bahasa pemrograman [19]. TensorFlow menyediakan banyak model yang telah dilatih dengan dataset *Common Object in Context* (COCO). Model-model tersebut memiliki kecepatan dan tingkat akurasi masing-masing, sesuai dengan arsitektur modelnya [20]. Salah satunya adalah model *MobileNetV2* [21]. Model-model tersebut memiliki kecepatan dan tingkat akurasi masing-masing, sesuai dengan arsitektur modelnya [20]. Seperti yang digambarkan dalam Gambar 2, arsitektur *MobileNetV2* dimulai dengan konvolusi awal yang menerima input berukuran $224 \times 224 \times 3$, menggunakan *depthwise separable convolution*, *global average pooling*, dan *fully connected layers* untuk klasifikasi akhir.




Gambar 2. Arsitektur *MobileNet-V2*

Sumber: [Hastomo et al., 2021]

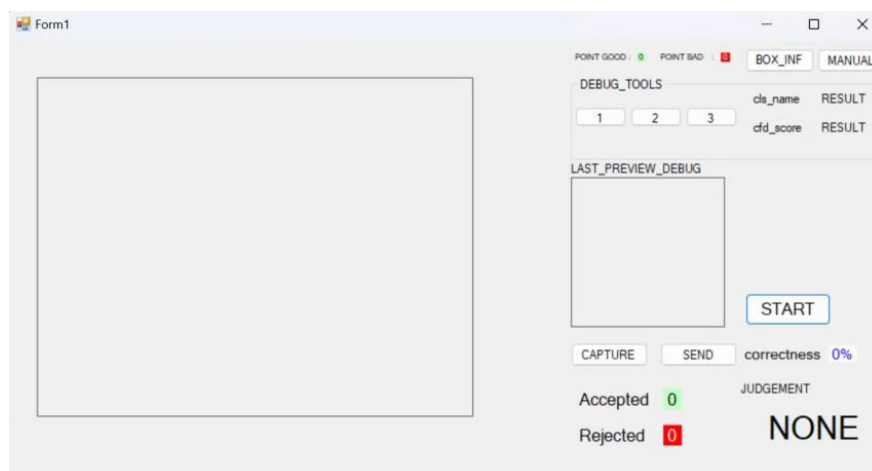
Penelitian ini dilanjutkan dengan mengadopsi arsitektur *MobileNetV2* untuk melatih model. Proses pelatihan dilakukan di platform *Google Colab*. Dalam konfigurasi pelatihan, menggunakan total 50 iterasi. Setiap iterasi melibatkan 128 gambar yang diproses dalam satu batch untuk memperbarui bobot model. Gambar yang digunakan dalam pelatihan memiliki ukuran 224×224 piksel. Selain itu, dalam proses pelatihan menggunakan beberapa strategi augmentasi data seperti gambar-gambar dapat mengalami rotasi maksimal hingga 15 derajat, serta zoom maksimal sebesar 30%. Langkah ini membantu meningkatkan variasi data yang digunakan dalam pelatihan. Untuk memastikan keakuratan model, data validasi dipisahkan sebesar 20% dari total data yang tersedia. Ini memungkinkan evaluasi model terhadap data yang belum pernah dilihat sebelumnya.

2.3. Image Classification

Dalam penelitian ini klasifikasi gambar bagian penting dalam pengolahan gambar. Oleh karena itu klasifikasi memiliki peran yang signifikan dalam berbagai industri. Seperti pengembangan aplikasi cerdas, otomasi, dan pemahaman data visual [23]. Pada Gambar 3 merupakan proses sistem klasifikasi gambar pada penelitian ini. Proses sistem klasifikasi gambar melibatkan beberapa langkah, dimulai dari pengambilan gambar hingga visualisasi hasilnya. Mencakup *capture* gambar, penentuan ROI, *crop* gambar, ekstraksi fitur, klasifikasi menggunakan model *MobileNetV2*, prediksi hasil, dan visualisasi hasil.

Gambar 3. *Image Classification*

Sistem ini juga memanfaatkan *Graphical User Interface* (GUI), guna memvisualisasikan hasil klasifikasi kepada pengguna. Seperti yang ditunjukkan pada Gambar 4. Pengguna akan mengambil gambar dengan menekan tombol *Start*, kemudian sistem akan menghasilkan prediksi dari gambar yang diklasifikasikan. Hasil prediksi digunakan untuk menentukan apakah gambar tersebut “*Accept*” atau “*Reject*”, dan hasilnya divisualisasikan untuk ditampilkan kepada pengguna.



Gambar 4. Tampilan Sistem Pada GUI

2.4. Evaluation Method


Pada tahap evaluasi penelitian ini, bertujuan untuk memvalidasi ketahanan model klasifikasi gambar. Analisis ketahanan model penting untuk memastikan bahwa model dapat tetap berkinerja baik dalam berbagai situasi nyata [24]. Ketahanan model menjadi krusial mengingat variasi yang mungkin terjadi pada kondisi pengambilan gambar di lapangan, seperti perubahan pencahayaan atau kehilangan sebagian poin [25]. Pada penelitian ini, metode evaluasi yang digunakan mencakup beberapa skenario seperti klasifikasi benar, satu poin hilang, dua poin hilang, tiga poin hilang, urutan poin yang ditukar, kondisi gelap, dan kondisi terang [26]. Metode-metode ini dirancang untuk menguji respons model terhadap berbagai tingkat ketidakpastian dan variabilitas dalam data input [27].

3. RESULTS AND DISCUSSION

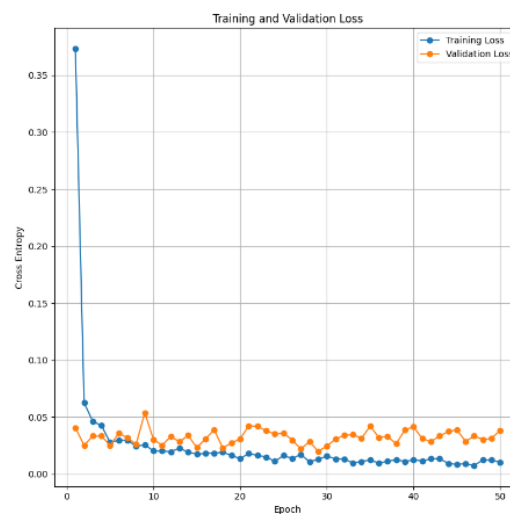
Pada bagian ini akan membahas hasil penelitian. Penelitian ini dimulai dengan membahas *learning curve* dari proses training model, kemudian dilanjutkan dengan analisis akurasi dan loss pada data pelatihan serta validasi. Yang terakhir akan membahas evaluasi performa keseluruhan model.

3.1. Training Data

Grafik pelatihan memvisualisasikan perjalanan pembelajaran model sepanjang proses pelatihan [28]. Tujuan utama dari melihat grafik pelatihan yaitu untuk mengidentifikasi apakah model mengalami *overfitting* atau *underfitting*. Model ini menggunakan MobileNetV2 yang dilatih ulang dengan dataset yang telah dikelompokkan. Model ini kemudian dikonversi ke *TensorFlow Lite* dengan kuantisasi pasca-pelatihan dan dikompilasi agar kompatibel dengan Edge TPU pada perangkat Coral. Hasil pengujian pelatihan data ditunjukkan pada yang merupakan grafik pada saat melakukan pelatihan data.



Gambar 5. Grafik Pelatihan Akurasi



Gambar 6. Grafik Pelatihan Loss

Jika berdasarkan grafik diatas didapatkan hasil nilai dengan iterasi yang dilakukan sebanyak 50 kali untuk data yang dilatih. Setiap iterasi memproses 128 gambar dalam satu batch untuk memperbarui bobot model. Gambar yang digunakan dalam pelatihan berukuran 224x224 piksel. Selain itu, beberapa strategi augmentasi data diterapkan, seperti rotasi gambar hingga 15 derajat dan zoom maksimal sebesar 30%, untuk meningkatkan variasi data pelatihan. Sebanyak 20% dari total data yang tersedia dipisahkan untuk validasi guna memastikan keakuratan model. Pada Gambar 5 menunjukkan hasil pelatihan data dengan nilai akurasi 0,99 sedangkan nilai validasinya sebesar 0,98. Sedangkan pada Gambar 6 menunjukkan hasil pelatihan data dengan nilai loss sebesar 0,01, sementara itu nilai validasi mencapai loss 0,03. Hasil grafik-grafik tersebut menunjukkan model berfungsi dengan baik pada data pelatihan dan validasi. Secara keseluruhan, hasil grafik ini menunjukkan bahwa strategi pelatihan yang digunakan, termasuk augmentasi data dan konfigurasi iterasi, berhasil menghasilkan model yang dapat mengklasifikasi dengan baik pada data baru.

3.2. Testing and Evaluation

Setelah proses pelatihan, langkah selanjutnya adalah melakukan pengujian untuk mengevaluasi kinerja model. Seperti yang sudah disampaikan sebelumnya pada bagian ini dilakukan pengujian pada kabel harness. Yang dimana klasifikasi gambar dilakukan untuk empat kelas yaitu; *Blue Tape*, *Pink Tape*, *Connector*, dan *Empty*. Selanjutnya akan dievaluasi dengan beberapa skenario seperti klasifikasi benar, satu poin hilang, dua poin hilang, tiga poin hilang, dan urutan poin yang ditukar.

3.2.1. Testing Data

Pengujian ini bertujuan untuk mengukur sejauh mana model mampu menggeneralisasi dan melakukan klasifikasi dengan akurat pada data yang belum pernah dilihat sebelumnya. Pada tahap ini sistem ini akan memeriksa hasil klasifikasi dengan mengevaluasi nilai rasio kebenarannya. Jika ketiga poin terklasifikasi dengan benar, GUI akan menampilkan rasio kebenaran sebesar 100%, dan hasil ini akan dinyatakan sebagai “*Accept*” atau “*G*”. Sebaliknya, jika kurang dari tiga poin terklasifikasi dengan benar, GUI akan menampilkan rasio kebenaran sebesar 33% untuk satu poin dan 66% untuk dua poin, dan sistem akan menetapkan status “*Reject*” atau “*NG*” pada UI. Terlihat pada Gambar 7 bahwa keseluruhan tiga kategori yang terdapat dalam gambar, berhasil diklasifikasikan dengan benar sehingga mendapatkan status “*Accept*” atau “*G*” pada tampilan *User Interface* mendapatkan nilai kebenaran sebesar 100%.



Gambar 7. Hasil Pengujian Tiga Class

Sementara untuk percobaan selanjutnya, dilakukan dengan berbagai macam skenario. Di mana satu poin hilang, dua poin hilang, tiga poin hilang, dan urutan poin yang ditukar. Meskipun terdapat perubahan pada jumlah kelas, model klasifikasi mampu mengatasi variasi ini. Pada Gambar 8 terlihat dimana dua poin hilang sistem berhasil mengidentifikasi dengan benar. Oleh karena itu, status yang diperoleh adalah “*Reject*” atau “*NG*” dan mendapatkan nilai correctness sebanyak 33,33%.



Gambar 8. Hasil Pengujian Satu Poin Hilang

Pada Gambar 9, terlihat bahwa percobaan yang dilakukan menunjukkan kemampuan sistem untuk mengklasifikasikan setiap poin hanya dalam waktu 5ms. Dengan demikian, untuk mengklasifikasikan keseluruhan 3

Paper's should be the fewest possible that accurately describe ... (First Author)

poin, sistem hanya memerlukan total waktu 15ms. Jika 1 poin memerlukan 5ms, maka untuk mengklasifikasikan 30 poin diperlukan sekitar 150ms atau setara dengan 0,0025 menit. Hasil ini menunjukkan efisiensi yang sangat tinggi dari sistem klasifikasi, membuktikan kecepatan dan akurasi yang unggul dalam pengolahan data.



Gambar 9. Hasil Pengujian Waktu


3.2.2. Results of Evaluation Method

Pada penelitian ini, dilakukan 170 kali percobaan untuk mengevaluasi kinerja model klasifikasi. Terdiri dari 50 *Correct* sampel lengkap yang mencakup tiga *class* yaitu: *Blue Tape*, *Pink Tape*, dan *Connector*. Dari 50 percobaan tersebut, selanjutnya dilakukan percobaan dengan sampel *defect*, 15 *One Missing*, 15 *Double Missing*, 15 *Triple Missing*, 15 *Swapping Points*, 15 *Correct Low Light*, 15 *Swapping Low Light*, 15 sampel *Correct High Light*, dan 15 *Swapping High Light*. Maka didapatkan hasil seperti yang terdapat pada Tabel 1.

Tabel 1. *Evaluation Method*

No	Experiment Categories	Condition	Accept	Reject	Expected Result
1	Correct	[Blue Tape, Pink Tape, Connector]	48	2	Accept
		[Blue Tape, Pink Tape, X]	0	15	Reject
2	One Missing	[Blue Tape, X, Connector]	0	15	Reject
		[X, Pink Tape, Connector]	0	15	Reject
		[Blue Tape, X, X]	0	15	Reject
3	Double Missing	[X, X, Connector]	0	15	Reject
		[X, Pink Tape, X]	0	15	Reject
4	Triple Missing	[X, X, X]	0	15	Reject
5	Swapping Points	[Pink Tape, Blue Tape, Connector]	1	14	Reject
6	Correct Low Light	[Blue Tape, Pink Tape, Connector]	14	1	Accept
7	Swapping Low Light	[Pink Tape, Blue Tape, Connector]	2	13	Reject
8	Correct High Light	[Blue Tape, Pink Tape, Connector]	0	15	Accept
9	Swapping High Light	[Pink Tape, Blue Tape, Connector]	0	15	Reject

Dari hasil percobaan yang terlihat hasil menunjukkan bahwa, model memiliki performa yang baik dalam mengklasifikasi kondisi yang benar terutama dalam kondisi pencahayaan yang normal dan rendah. Namun, model cenderung *Reject* dengan konsistensi tinggi pada kondisi dengan poin yang hilang, urutannya dirubah, pencahayaan normal, rendah, maupun tinggi, menunjukkan keandalan model dalam mengklasifikasi kesalahan. Model dapat berhasil mengklasifikasikan gambar dengan tepat ketika semua poin ada dan berada dalam urutan yang benar. Sedangkan, ketika ada poin yang hilang atau urutan poin ditukar, model akan mengklasifikasikannya sebagai *Reject*, sesuai dengan yang diharapkan.



Gambar 10. Kondisi *Correct High Light*

Pada percobaan dengan kondisi *Correct High Light*, model mengklasifikasikan gambar sebagai “*Reject*”. Hal ini disebabkan oleh pengaruh pencahayaan tinggi yang mengubah tampilan visual dari komponen-komponen yang harus dikenali oleh model. Pencahayaan yang terlalu terang dapat menyebabkan warna dan kontras setiap poin memudar, membuat model kesulitan mengenali komponen dengan benar. Karena sistem menggunakan evaluasi berdasarkan rasio kebenaran, jika ada satu poin yang tidak dikenali atau terlihat berbeda dari yang diharapkan, sistem akan mengklasifikasikannya sebagai “*Reject*”. Gambar 10 mengilustrasikan bagaimana pencahayaan tinggi menyebabkan warna setiap poin menjadi kurang jelas, yang kemudian membuat sistem salah mengenali poin tersebut sebagai kosong atau salah, sehingga mengarah pada hasil “*Reject*”.

4. CONCLUSION

Penelitian ini dilakukan dengan tujuan memastikan komponen seperti konektor dan selotip penanda dipasang sesuai dengan standar kerja yang ditetapkan dalam produksi. Penelitian ini berhasil menunjukkan bahwa penggunaan *Edge TPU* dalam sistem klasifikasi gambar secara signifikan meningkatkan kecepatan dan efisiensi proses dibandingkan dengan inspeksi manual oleh operator. Proses penelitian melibatkan langkah-langkah seperti pengumpulan dataset, pelatihan model, dan evaluasi kinerja model dalam beragam situasi yang mungkin terjadi selama tahap produksi. Hasil pengujian menunjukkan akurasi pelatihan 0,99 dan akurasi validasi 0,98, dengan performa konsisten dalam kondisi pencahayaan normal dan rendah. Sistem ini juga mampu mengatasi berbagai skenario, seperti poin yang hilang dan urutan poin yang ditukar. Hanya saja terdapat kesulitan dalam kondisi pencahayaan tinggi yang menyebabkan hasil “*Reject*”. Percobaan yang dilakukan berhasil mengklasifikasikan setiap poin dalam waktu 5ms. Apabila sistem mengklasifikasi 30 poin, diperlukan waktu 150ms atau 0,0025 menit. Ini terbukti lebih cepat dibandingkan inspeksi manual oleh operator yang memakan waktu sekitar 1,5 menit untuk 30 poin. Sistem ini secara keseluruhan menawarkan solusi lebih cepat untuk inspeksi otomatis di industri. Penggunaan kombinasi *MobileNetV2* dan *Edge TPU* terbukti sangat efektif, memberikan kecepatan inferensi yang cepat dan akurasi tinggi, menunjukkan potensi besar untuk meningkatkan efisiensi dan kualitas inspeksi produk di industri.

ACKNOWLEDGEMENTS

Penulis mengucapkan ucapan terima kasih disampaikan kepada pembimbing saya, Bapak Eko Rudiawan Jamzuri, S.ST.,M.Sc, atas bimbingan dan arahan selama penelitian berlangsung. Penulis juga ingin berterima kasih kepada teman dan penutur yang sudah bersedia meluangkan waktunya untuk membantu saya dalam penelitian ini. Serta Politeknik Negeri Batam terkhusus Robotic and Artificial Intelligence Lab (BRAIL) yang telah memfasilitasi dalam melakukan penelitian.

REFERENCES







- [1] T. Zimmermann *et al.*, “Visual-based defect detection and classification approaches for industrial applications—A SURVEY,” *Sensors (Switzerland)*, vol. 20, no. 5. MDPI AG, Mar. 01, 2020. doi: 10.3390/s20051459.
- [2] M. Kim, Y. Kwon, J. Kim, and Y. Kim, “Image Classification of Parcel Boxes under the Underground Logistics System Using CNN MobileNet,” *Applied Sciences (Switzerland)*, vol. 12, no. 7, Apr. 2022, doi: 10.3390/app12073337.
- [3] J. Villalba-Diez, D. Schmidt, R. Gevers, J. Ordieres-Meré, M. Buchwitz, and W. Wellbrock, “Deep learning for industrial computer vision quality control in the printing industry 4.0,” *Sensors (Switzerland)*, vol. 19, no. 18, Sep. 2019, doi: 10.3390/s19183987.

Paper’s should be the fewest possible that accurately describe ... (First Author)

- [4] D. P. Penumuru, S. Muthuswamy, and P. Karumbu, "Identification and classification of materials using machine vision and machine learning in the context of industry 4.0," *J Intell Manuf*, vol. 31, no. 5, pp. 1229–1241, Jun. 2020, doi: 10.1007/s10845-019-01508-6.
- [5] R. Iqbal, T. Maniak, F. Doctor, and C. Karyotis, "Fault Detection and Isolation in Industrial Processes Using Deep Learning Approaches," *IEEE Trans Industr Inform*, vol. PP, p. 1, Oct. 2019, doi: 10.1109/TII.2019.2902274.
- [6] A. S. Aguiar, F. N. Dos Santos, A. J. M. De Sousa, P. M. Oliveira, and L. C. Santos, "Visual trunk detection using transfer learning and a deep learning-based coprocessor," *IEEE Access*, vol. 8, pp. 77308–77320, 2020, doi: 10.1109/ACCESS.2020.2989052.
- [7] Y. Sun and A. M. Kist, "Deep Learning on Edge TPUs," Aug. 2021, [Online]. Available: <http://arxiv.org/abs/2108.13732>
- [8] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," Apr. 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>
- [9] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," Jan. 2018, [Online]. Available: <http://arxiv.org/abs/1801.04381>
- [10] A. Howard *et al.*, "Searching for MobileNetV3," May 2019, [Online]. Available: <http://arxiv.org/abs/1905.02244>
- [11] Y. Xiong *et al.*, "MobileDets: Searching for Object Detection Architectures for Mobile Accelerators," Apr. 2020, [Online]. Available: <http://arxiv.org/abs/2004.14525>
- [12] K. Dong, C. Zhou, Y. Ruan, and Y. Li, "MobileNetV2 Model for Image Classification," in *Proceedings - 2020 2nd International Conference on Information Technology and Computer Application, ITCA 2020*, Institute of Electrical and Electronics Engineers Inc., Dec. 2020, pp. 476–480. doi: 10.1109/ITCA52113.2020.00106.
- [13] T. B. Shahi, C. Sitaula, A. Neupane, and W. Guo, "Fruit classification using attention-based MobileNetV2 for industrial applications," *PLoS One*, vol. 17, no. 2 February, Feb. 2022, doi: 10.1371/journal.pone.0264586.
- [14] Y. and D. X. and Q. L. Reza Sheikh Rufsan and Yan, "Inference Performance Comparison of Convolutional Neural Networks on Edge Devices," in *Science and Technologies for Smart Cities*, S. I. and Z. R. and G. N. and L. S. F. and Y. T. Paiva Sara and Lopes, Ed., Cham: Springer International Publishing, 2021, pp. 323–335.
- [15] R. Tobiasz, G. Wilczyński, P. Graszka, N. Czechowski, and S. Łuczak, "Edge Devices Inference Performance Comparison," Jun. 2023, doi: 10.5626/JCSE.2023.17.2.51.
- [16] D. Kolosov, V. Kelefouras, P. Kourtessis, and I. Mporas, "Anatomy of Deep Learning Image Classification and Object Detection on Commercial Edge Devices: A Case Study on Face Mask Detection," *IEEE Access*, vol. 10, pp. 109167–109186, 2022, doi: 10.1109/ACCESS.2022.3214214.
- [17] J. Ren and X. Huang, "Defect Detection Using Combined Deep Autoencoder and Classifier for Small Sample Size," Feb. 2020, pp. 32–35. doi: 10.1109/ICCSSE50399.2020.9171953.
- [18] Y. Gulzar, "Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique," *Sustainability (Switzerland)*, vol. 15, no. 3, Feb. 2023, doi: 10.3390/su15031906.
- [19] O. Devi, S. Sunanto, and P. H. Utomo, "IMPLEMENTASI DEEP LEARNING DENGAN CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI GAMBAR SAMPAH ORGANIK DAN ANORGANIK (Implementation Of Deep Learning With Convolutional Neural Network To Classification Organic And Nonorganic Waste Picture)." [Online]. Available: <https://magestic.unej.ac.id/>
- [20] W. and R. Y. B. Seetala Kiran and Birdsong, "Image Classification Using TensorFlow," in *16th International Conference on Information Technology-New Generations (ITNG 2019)*, S. Latifi, Ed., Cham: Springer International Publishing, 2019, pp. 485–488.
- [21] K. Dong, C. Zhou, Y. Ruan, and Y. Li, "MobileNetV2 Model for Image Classification," in *Proceedings - 2020 2nd International Conference on Information Technology and Computer Application, ITCA 2020*, Institute of Electrical and Electronics Engineers Inc., Dec. 2020, pp. 476–480. doi: 10.1109/ITCA52113.2020.00106.
- [22] W. Hastomo and S. dan Sudjiran, "CONVOLUTION NEURAL NETWORK ARSITEKTUR MOBILENET-V2 UNTUK MENDETEKSI TUMOR OTAK," *Seminar Nasional Teknologi Informasi dan Komunikasi STI&K (SeNTIK)*, vol. 5, no. 1, 2021.
- [23] Q. Lv, S. Zhang, and Y. Wang, "Deep Learning Model of Image Classification Using Machine Learning," *Advances in Multimedia*, vol. 2022, 2022, doi: 10.1155/2022/3351256.
- [24] F.-D. Muntean Mihaela and Militaru, "Metrics for Evaluating Classification Algorithms," in *Education, Research and Business Technologies*, P. and F. F. G. Ciurea Cristian and Pocatilu, Ed., Singapore: Springer Nature Singapore, 2023, pp. 307–317.

- [25] P. García Laencina, J. Morales-Sánchez, R. Verdú-Monedero, J. Larrey-Ruiz, J. L. Sancho-Gómez, and A. Figueiras-Vidal, "Classification with missing data," 2010, pp. 147–175. doi: 10.4018/978-1-60566-766-9.ch007.
- [26] R. Al Sobhahi and J. Tekli, "Comparing deep learning models for low-light natural scene image enhancement and their impact on object detection and classification: Overview, empirical evaluation, and challenges," *Signal Process Image Commun*, vol. 109, p. 116848, 2022, doi: <https://doi.org/10.1016/j.image.2022.116848>.
- [27] D. Kumar and V. Kukreja, "Image segmentation, classification, and recognition methods for wheat diseases: Two Decades' systematic literature review," *Comput Electron Agric*, vol. 221, p. 109005, 2024, doi: <https://doi.org/10.1016/j.compag.2024.109005>.
- [28] A. S. Ali and M. Abdulmunem, "Image classification with Deep Convolutional Neural Network Using Tensorflow and Transfer of Learning," *Journal of the College of Education for Women*, vol. 31, no. 2, pp. 156–171, Jun. 2020, doi: 10.36231/coedw/vol31no2.9.

BIOGRAPHIES OF AUTHORS

	<p>Shabrina Rachmawati Azzahra Student at Batam State Polytechnic, Department of Robotics Engineering. Her research interests include mechanical and machine learning. Currently, she is focusing on technology development related to robotics and automation. can be contacted at email : shabrinara27@gmail.com.</p>
	<p>Eko Rudiawan Jamzuri     received a B.A.Sc. in Electrical Engineering from Bandung Institute of Technology in 2013 and earned an M.Sc. in Electrical Engineering from National Taiwan Normal University in 2020. Currently, he is a Lecturer at the Department of Electrical Engineering at Politeknik Negeri Batam. His research interests include humanoid robotics, computer vision, machine learning, and deep learning. He can be contacted at email: ekorudiawan@polibatam.ac.id.</p>