



Analisis Efektivitas Model CNN dalam Mendiagnosis Maloklusi Gigi Berdasarkan Foto Senyum

Muhammad Cahya Rifqi^{1*}, Intan Kumalasari²

^{1,2} Fakultas Ilmu Komputer, Teknik Informatika, Universitas Pamulang, Tangerang Selatan Jl. Puspitek, Buaran, Kec. Pamulang, Kota Tangerang Selatan, Banten, Indonesia

muhammadcahyarifqi@gmail.com, dosen02368@unpam.ac.id

Abstrak

Maloklusi merupakan kondisi susunan gigi atau hubungan antara rahang atas dan rahang bawah yang tidak berada pada posisi sebagaimana mestinya, dan pemeriksaannya pada umumnya dilakukan secara langsung oleh dokter gigi atau ortodontis. Perkembangan teknologi kecerdasan buatan membuka peluang pemanfaatan citra digital untuk membantu proses pengenalan kondisi gigi secara otomatis. Penelitian ini menerapkan metode *Convolutional Neural Network (CNN)* dengan arsitektur *MobileNetV2* untuk mengklasifikasikan foto senyum menjadi dua kategori, yaitu normal dan maloklusi. Dataset terdiri atas 1.000 citra yang dibagi menjadi data *training*, *validation*, dan *testing*. Sebelum pelatihan, citra disesuaikan menjadi ukuran 224 x 224 piksel dan melalui tahap *preprocessing* serta augmentasi data. Model dikembangkan menggunakan pendekatan *transfer learning* dengan memanfaatkan bobot awal *ImageNet*, dan kinerjanya dievaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix*. Hasil pengujian menunjukkan model mencapai *accuracy* sebesar 95%, dengan kelas maloklusi memperoleh *precision* 0,96, *recall* 0,94, dan *F1-score* 0,95, sedangkan kelas normal memperoleh *precision* 0,94, *recall* 0,96, dan *F1-score* 0,95. Model yang telah dilatih selanjutnya diimplementasikan pada aplikasi web dengan fitur unggah foto, prediksi, penyimpanan riwayat menggunakan *SQLite*, dan pembuatan laporan PDF. Pengujian Black Box menunjukkan seluruh fungsi utama aplikasi berjalan sesuai rancangan. *MobileNetV2* terbukti dapat digunakan untuk klasifikasi awal kondisi normal dan maloklusi berdasarkan foto senyum, namun sistem yang dikembangkan hanya ditujukan sebagai alat bantu skrining awal dan bukan pengganti pemeriksaan klinis oleh dokter gigi atau ortodontis.

Kata Kunci: *Convolutional Neural Network; MobileNetV2; Maloklusi; Foto Senyum; Transfer Learning*

1. Pendahuluan

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence*) terus mengalami kemajuan pesat dan mulai diterapkan pada berbagai bidang, salah satunya bidang kesehatan gigi. Salah satu metode yang banyak dimanfaatkan untuk pengolahan dan pengenalan pola pada citra adalah *Convolutional Neural Network (CNN)*, yaitu bagian dari *deep learning* yang mampu mempelajari karakteristik visual pada citra secara otomatis melalui proses pelatihan. Penerapan *CNN* pada bidang ortodontik menunjukkan potensi yang menjanjikan, termasuk untuk mendukung proses diagnosis dan perencanaan perawatan pasien [1].

Salah satu kondisi yang cukup sering ditemukan dalam kedokteran gigi adalah maloklusi, yaitu ketidaksesuaian susunan gigi maupun hubungan rahang atas dan rahang bawah yang dapat memengaruhi fungsi pengunyahan, kemampuan berbicara, dan penampilan seseorang. Penelitian menunjukkan bahwa beberapa jenis maloklusi memengaruhi karakteristik dan dinamika senyum baik dari arah frontal maupun lateral [2], sehingga karakteristik visual pada foto senyum berpotensi digunakan sebagai salah satu informasi untuk mengenali kondisi maloklusi.

Identifikasi maloklusi pada umumnya dilakukan melalui pemeriksaan langsung oleh dokter gigi atau ortodontis, dan pemeriksaan oleh tenaga profesional tetap menjadi langkah utama untuk memperoleh diagnosis yang tepat. Namun proses tersebut memerlukan ketersediaan tenaga profesional dan fasilitas kesehatan yang belum tentu mudah dijangkau oleh seluruh masyarakat, sehingga terbuka peluang bagi pengembangan teknologi yang dapat membantu memberikan informasi awal mengenai kondisi susunan gigi secara lebih praktis sebagai alat bantu skrining, bukan pengganti pemeriksaan klinis.

Pemanfaatan *deep learning* pada bidang kedokteran gigi telah diterapkan pada beberapa penelitian sebelumnya. Shin dkk. menerapkan *CNN* untuk memprediksi kebutuhan operasi ortognatik pada pasien maloklusi skeletal berdasarkan citra sefalogram dan menunjukkan bahwa *CNN* mampu mempelajari karakteristik citra yang berkaitan dengan kondisi gigi dan struktur wajah [3]. Kartbak dkk. melakukan klasifikasi foto intraoral menggunakan algoritma *deep learning* yang dilatih berdasarkan parameter sefalometri terhadap 990 pasien dan memperoleh performa klasifikasi yang baik [4]. Zhang dkk. mengembangkan model *deep learning* untuk klasifikasi oklusi menggunakan foto intraoral dan menunjukkan tingkat performa yang tinggi [5]. Kocakaya dkk. mengevaluasi performa *deep learning* dalam mengklasifikasikan foto profil pasien berdasarkan pengukuran sefalometri dan memperoleh akurasi yang tinggi pada beberapa parameter [6]. Cejudo Grano de Oro dkk. meneliti pengaruh hyperparameter tuning dan augmentasi citra terhadap klasifikasi foto ortodonti menggunakan *deep learning* dan

menunjukkan bahwa augmentasi serta pengaturan hyperparameter berpengaruh terhadap peningkatan performa model [7].

Berdasarkan penelitian-penelitian tersebut, sebagian besar penelitian terdahulu memanfaatkan citra intraoral, foto profil, maupun radiografi sefalometri sebagai sumber data, yang umumnya memerlukan proses akuisisi data khusus di lingkungan klinis [8], [9]. Penggunaan foto senyum frontal sebagai sumber data klasifikasi maloklusi masih relatif terbatas, padahal foto senyum lebih mudah diperoleh, tidak memerlukan paparan radiasi, dan dapat diambil menggunakan kamera ponsel [10]. Kesenjangan (gap) inilah yang menjadi dasar penelitian ini, yaitu memanfaatkan foto senyum frontal yang lebih mudah diakses masyarakat umum sebagai sumber data klasifikasi normal dan maloklusi.

Penelitian ini menerapkan *CNN* dengan arsitektur *MobileNetV2* menggunakan pendekatan *transfer learning* berbasis bobot *ImageNet* untuk mengklasifikasikan foto senyum ke dalam dua kelas, yaitu normal dan maloklusi. Pemilihan *MobileNetV2* didasarkan pada karakteristik arsitekturnya yang ringan dan memiliki jumlah parameter lebih sedikit dibandingkan arsitektur *CNN* lain [11], sehingga sesuai untuk kebutuhan *dataset* yang relatif terbatas dan model yang akan diimplementasikan pada aplikasi berbasis web. *Dataset* penelitian diperoleh dari *Kaggle* dan *Mendeley Data*, kemudian diproses dan dilatih menggunakan *Google Colab*. Kinerja model dievaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*, kemudian diimplementasikan pada aplikasi web sebagai alat bantu skrining awal yang dilengkapi fitur unggah foto, prediksi, penyimpanan riwayat menggunakan *SQLite*, dan pembuatan laporan PDF.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk (1) menerapkan *CNN MobileNetV2* dalam mengklasifikasikan foto senyum ke dalam kelas normal dan maloklusi, (2) mengevaluasi performa model berdasarkan *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*, serta (3) mengimplementasikan model tersebut ke dalam aplikasi web sederhana sebagai alat bantu skrining awal maloklusi gigi berbasis foto senyum. Manfaat yang diharapkan antara lain memberikan informasi awal bagi masyarakat mengenai potensi pemanfaatan teknologi klasifikasi citra berbasis kecerdasan buatan sebagai alat bantu skrining kondisi maloklusi, menambah referensi penelitian penerapan *CNN* pada bidang kedokteran gigi, serta menjadi acuan bagi pengembang sistem dan peneliti selanjutnya dalam merancang sistem deteksi maloklusi berbasis *AI* yang lebih interaktif dan akurat.

2. Metode Penelitian

Metode penelitian menjelaskan tahapan yang dilakukan dalam proses pengembangan model klasifikasi maloklusi menggunakan pendekatan *Convolutional Neural Network (CNN)* dengan arsitektur *MobileNetV2*. Penelitian dimulai dari studi literatur, pengumpulan *dataset*, persiapan dan *preprocessing* data, perancangan model, proses pelatihan, evaluasi performa model, hingga implementasi model ke dalam aplikasi berbasis web. Setiap tahapan dirancang secara sistematis untuk menghasilkan model klasifikasi yang memiliki performa baik serta dapat diterapkan sebagai alat bantu skrining awal kondisi maloklusi berdasarkan foto senyum [11].

2.1. Tahapan Penelitian

Penelitian ini dilakukan melalui delapan tahapan utama, yaitu studi literatur, pengumpulan *dataset*, persiapan dan *preprocessing* data, perancangan model, pelatihan model, evaluasi model, implementasi aplikasi web, dan pengujian aplikasi. Studi literatur dilakukan untuk mempelajari referensi terkait maloklusi gigi, pengolahan citra digital, *deep learning*, *CNN*, *MobileNetV2*, *transfer learning*, serta metode evaluasi model. Tahapan tersebut dilakukan secara berurutan agar setiap proses dapat saling mendukung dan menghasilkan model klasifikasi yang optimal sebelum diterapkan pada aplikasi web.

2.2. Dataset Penelitian

Dataset penelitian diperoleh dari platform *Kaggle* dan *Mendeley Data* yang menyediakan kumpulan data untuk kebutuhan *machine learning* dan *deep learning* [12]. *Dataset* terdiri atas 1.000 citra foto senyum frontal yang dikelompokkan ke dalam dua kelas, yaitu normal dan maloklusi, masing-masing berjumlah 500 citra. Sumber *dataset* ditunjukkan pada Tabel 1.

Sumber Dataset	Keterangan
<i>Kaggle</i>	Dataset citra gigi
<i>Mendeley Data</i>	Dataset citra gigi

Tabel 1. Sumber Dataset

Dataset kemudian dibagi menjadi data *training*, *validation*, dan *testing* dengan perbandingan 400:50:50 pada masing-masing kelas, sebagaimana ditunjukkan pada Tabel 2. Pembagian ini dilakukan agar model dapat

DOI: <https://doi.org/10.69693/ijmst.v4i2.12881>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

mempelajari pola citra secara maksimal sekaligus memperoleh evaluasi performa yang objektif dan bebas dari *data leakage* [13].

<i>Dataset</i>	Normal	Maloklusi	Total
<i>Training</i>	400	400	800
<i>Validation</i>	50	50	100
<i>Testing</i>	50	50	100
Total	500	500	1000

Tabel 2. Pembagian Dataset

2.3. Preprocessing Data

Sebelum digunakan untuk pelatihan, seluruh citra melalui tahap *preprocessing* agar memiliki format yang seragam [14]. Tahapan *preprocessing* meliputi *resize* citra menjadi ukuran 224x224 piksel sesuai kebutuhan *input MobileNetV2*, normalisasi nilai piksel menggunakan fungsi *preprocess_input* bawaan *MobileNetV2* sehingga rentang nilai piksel disesuaikan ke antara -1 hingga 1 agar sesuai dengan bobot *ImageNet*, serta augmentasi data pada data *training* berupa *RandomFlip*, *RandomRotation*, *RandomZoom*, dan *RandomContrast*. Augmentasi data digunakan untuk menambah variasi data pelatihan sekaligus mengurangi risiko *overfitting* [7].

2.4. Perancangan Model CNN MobileNetV2

Model klasifikasi dibangun menggunakan arsitektur *MobileNetV2* dengan pendekatan *transfer learning* berbasis bobot awal *ImageNet* [11]. Bagian klasifikasi bawaan *MobileNetV2* tidak digunakan; pada bagian akhir model ditambahkan lapisan *Global Average Pooling* untuk merangkum fitur, dilanjutkan dengan *Dense layer* dan fungsi aktivasi *Sigmoid* pada lapisan keluaran untuk menghasilkan prediksi dua kelas. Pemilihan *MobileNetV2* didasarkan pada karakteristik arsitekturnya yang menggunakan *depthwise separable convolution* sehingga memiliki jumlah parameter yang relatif ringan dan efisien untuk diintegrasikan ke aplikasi berbasis web [15]. Proses pelatihan menggunakan optimizer Adam dengan fungsi loss *Binary Crossentropy* karena klasifikasi yang dilakukan hanya terdiri dari dua kelas. Parameter pelatihan yang digunakan ditunjukkan pada Tabel 3.

Parameter	Nilai
Arsitektur Model	<i>MobileNetV2</i>
Input Size	224 x 224
<i>Batch Size</i>	32
<i>Epoch</i>	20
Optimizer	Adam
<i>Learning Rate</i>	0.0001
Loss Function	<i>Binary Crossentropy</i>
Activation Output	<i>Sigmoid</i>
Jumlah Kelas	2 (Normal, Maloklusi)
<i>Framework</i>	<i>TensorFlow / Keras</i>

Tabel 3. Parameter Training

2.5. Evaluasi Model

Kinerja model dievaluasi menggunakan data *testing* berdasarkan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* [16], [17]. *Confusion matrix* digunakan untuk membandingkan kelas aktual dengan hasil prediksi

model pada kelas normal dan maloklusi, sedangkan *accuracy*, *precision*, *recall*, dan *F1-score* digunakan untuk memberikan gambaran performa model secara lebih menyeluruh.

2.6. Implementasi dan Pengujian Aplikasi

Model yang telah dilatih dan dievaluasi selanjutnya diimplementasikan ke dalam aplikasi web menggunakan *framework Flask* [18] sebagai *backend*, *OpenCV* untuk validasi kualitas citra sebelum diklasifikasi, database *SQLite* [19] untuk menyimpan riwayat hasil prediksi, serta *ReportLab* untuk menghasilkan laporan hasil klasifikasi dalam format PDF. Pengujian aplikasi dilakukan menggunakan metode *Black Box Testing* untuk memastikan fungsi utama aplikasi, meliputi unggah gambar, validasi masukan, proses prediksi, penyajian hasil, penyimpanan riwayat, dan pembuatan laporan PDF, berjalan sesuai dengan rancangan sistem.

3. Hasil dan Pembahasan

Hasil dan pembahasan pada penelitian ini disajikan berdasarkan tahapan yang telah dilakukan, mulai dari implementasi dataset dan *preprocessing*, proses pelatihan model, evaluasi performa menggunakan *confusion matrix* dan *classification report*, implementasi model ke dalam aplikasi web, hingga pengujian fungsional menggunakan metode *Black Box Testing*. Penyajian hasil dilakukan secara sistematis agar setiap tahapan dapat menunjukkan capaian penelitian sekaligus memberikan pembahasan mengenai performa model dan implementasi sistem yang dikembangkan.

3.1. Implementasi Dataset dan Preprocessing

Implementasi penelitian dilakukan menggunakan *dataset* yang terdiri dari 1.000 citra foto senyum yang telah dibagi ke dalam folder normal dan maloklusi pada Google Drive, sebagaimana direkomendasikan pada penelitian klasifikasi citra dengan jumlah data terbatas [12]. Struktur folder tersebut memudahkan proses pembacaan label secara otomatis oleh sistem selama pelatihan berlangsung. Seluruh citra kemudian di-*resize* menjadi ukuran 224x224 piksel dan dinormalisasi menggunakan fungsi *preprocess_input* bawaan *MobileNetV2*. Pada data *training* diterapkan augmentasi berupa *RandomFlip*, *RandomRotation*, *RandomZoom*, dan *RandomContrast* untuk memperkaya variasi data tanpa perlu menambah jumlah pengambilan gambar baru. Implementasi *preprocessing* dan augmentasi ini berjalan sesuai rancangan dan tidak ditemukan kendala pada tahap pembacaan maupun pemrosesan citra.

3.2. Implementasi Model dan Proses Pelatihan

Model dibangun menggunakan arsitektur *MobileNetV2* dengan bobot awal *ImageNet* menggunakan *framework TensorFlow/Keras* pada lingkungan *Google Colab* [20]. Bagian akhir model disesuaikan dengan menambahkan lapisan *Global Average Pooling* dan *Dense layer* dengan aktivasi *Sigmoid* untuk menghasilkan dua keluaran kelas. Ringkasan arsitektur (*model summary*) yang dihasilkan pada Gambar 1 menunjukkan bahwa sebagian besar parameter berasal dari bagian *MobileNetV2* sebagai *feature extractor*, sementara lapisan tambahan pada bagian akhir model relatif ringan sehingga tidak menambah beban komputasi secara signifikan.

Drive already mounted at /content/drive; to attempt to forcibly remount, call `drive.mount('/content/drive', force_remount=True)`.
Model: "functional_1"

Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 224, 224, 3)	0
sequential (Sequential)	(None, 224, 224, 3)	0
true_divide (TrueDivide)	(None, 224, 224, 3)	0
subtract (Subtract)	(None, 224, 224, 3)	0
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,984
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
dropout (Dropout)	(None, 1280)	0
dense (Dense)	(None, 128)	163,968
dropout_1 (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 1)	129

Total params: 2,750,281 (10.49 MB)
Trainable params: 164,097 (641.00 KB)
Non-trainable params: 2,257,984 (8.61 MB)
Optimizer params: 328,200 (1.25 MB)

Input Shape: (None, 224, 224, 3)
Output Shape: (None, 1)

Gambar 1. Output Model Summary

Proses pelatihan dilakukan menggunakan parameter yang telah ditentukan pada Tabel 3, yaitu *batch size* 32, jumlah *epoch* 20, optimizer Adam dengan *learning rate* 0,0001, serta fungsi loss *Binary Crossentropy*. Selama pelatihan berlangsung, sistem menampilkan perkembangan nilai *accuracy*, loss, *validation accuracy*, dan


DOI: <https://doi.org/10.69693/ijmst.v4i2.12881>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

validation loss pada setiap *epoch*, sehingga performa model dapat dipantau secara bertahap. Proses pelatihan pada *Google Colab* berhasil diselesaikan tanpa kendala teknis berarti, dan model akhir yang dihasilkan kemudian disimpan untuk digunakan pada tahap evaluasi serta implementasi aplikasi web.


3.3. Hasil Pelatihan Model

Perkembangan proses pelatihan dipantau melalui grafik *training accuracy* dan *validation accuracy* sebagaimana ditunjukkan pada Gambar 2. Pada *epoch-epoch* awal, nilai *accuracy* masih relatif rendah karena model masih mempelajari pola dasar dari data. Seiring bertambahnya *epoch*, nilai *accuracy* meningkat secara konsisten hingga mendekati 98% pada data *training*, dengan pola kurva *validation accuracy* yang mengikuti tren serupa dan selisih yang tidak terlalu jauh dari *training accuracy*. Kondisi ini mengindikasikan bahwa model mampu mempelajari data dengan baik tanpa mengalami *overfitting* yang signifikan.



Gambar 2. Grafik Training dan Validation Accuracy

Grafik loss pada Gambar 3 menunjukkan tren penurunan nilai kesalahan model selama proses pelatihan berlangsung. Nilai loss pada *epoch-epoch* awal masih relatif tinggi, kemudian menurun secara bertahap hingga mencapai kondisi yang stabil pada *epoch-epoch* akhir. Validation loss juga menunjukkan pola penurunan yang serupa dengan *training loss* tanpa kenaikan signifikan pada akhir pelatihan, yang menunjukkan proses pelatihan berjalan stabil dan model tidak mengalami *overfitting* berarti [21].




Gambar 3. Grafik Training dan Validation Loss

3.4. Confusion Matrix dan Classification Report

Evaluasi performa model pada data *testing* dilakukan menggunakan *confusion matrix* sebagaimana ditunjukkan pada Gambar 4. Hasil pengujian menunjukkan bahwa sebagian besar data *testing*, yang terdiri dari 50 citra normal

dan 50 citra maloklusi, berhasil diklasifikasikan dengan tepat oleh model, dengan sejumlah kecil kesalahan prediksi pada kedua kelas.



Gambar 4. Hasil Confusion Matrix

Hasil *classification report* ditunjukkan pada Tabel 4. Berdasarkan tabel tersebut, kelas maloklusi memperoleh nilai *precision* sebesar 0,96, *recall* sebesar 0,94, dan *F1-score* sebesar 0,95, sedangkan kelas normal memperoleh *precision* sebesar 0,94, *recall* sebesar 0,96, dan *F1-score* sebesar 0,95. Nilai *precision* yang tinggi menunjukkan bahwa sebagian besar prediksi yang dihasilkan model sudah sesuai dengan kelas sebenarnya, sementara nilai *recall* yang tinggi menunjukkan model mampu mengenali sebagian besar data pada masing-masing kelas. Nilai *F1-score* sebesar 0,95 pada kedua kelas menunjukkan adanya keseimbangan yang baik antara *precision* dan *recall* [16].

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Support
Maloklusi	0,96	0,94	0,95	50
Normal	0,94	0,96	0,95	50
<i>Accuracy</i>			0,95	100
Macro Average	0,95	0,95	0,95	100
Weighted Average	0,95	0,95	0,95	100

Tabel 4. Classification Report

3.5. Hasil Evaluasi Model

Secara keseluruhan, model *MobileNetV2* memperoleh nilai *accuracy* sebesar 95%, *precision* sebesar 94,12%, *recall* sebesar 96,00%, dan *F1-score* sebesar 95,05% sebagaimana ditunjukkan pada Tabel 5. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dan cukup seimbang dalam membedakan foto senyum normal dan maloklusi pada data yang belum pernah dipelajari sebelumnya. Beberapa kesalahan klasifikasi yang masih terjadi diduga disebabkan oleh perbedaan kondisi citra, seperti kualitas gambar, posisi pengambilan foto, pencahayaan, dan kemiripan visual antara susunan gigi normal dan maloklusi ringan.


Parameter Evaluasi	Nilai
<i>Accuracy</i>	95%
<i>Precision</i>	94,12%
<i>Recall</i>	96,00%

Parameter Evaluasi	Nilai
<i>F1-Score</i>	95,05%

Tabel 5. Hasil Evaluasi Model

3.6. Implementasi dan Pengujian Aplikasi Web

Model yang telah dilatih selanjutnya diimplementasikan ke dalam aplikasi web berbasis *Flask* yang dilengkapi dengan halaman *upload* gambar, halaman hasil prediksi, penyimpanan riwayat menggunakan database *SQLite*, dan fitur unduh laporan dalam format PDF [18], [19]. Pada halaman *upload*, pengguna dapat memilih foto senyum melalui tombol *Choose File*, *drag and drop*, atau kamera perangkat apabila didukung. Setelah gambar diunggah dan divalidasi menggunakan *OpenCV* [22], sistem melakukan *preprocessing* kemudian meneruskan citra ke model *MobileNetV2* untuk diklasifikasi.



Gambar 5. Halaman Hasil Prediksi

Hasil pengujian pada halaman prediksi menunjukkan bahwa aplikasi berhasil menampilkan hasil klasifikasi berupa kategori normal atau maloklusi disertai nilai confidence, sebagaimana ditunjukkan pada Gambar 5, serta diagnosis singkat dan rekomendasi agar informasi yang diterima pengguna lebih mudah dipahami. Fitur *download* laporan PDF juga berhasil menghasilkan dokumen yang memuat foto yang dianalisis, hasil klasifikasi, nilai confidence, diagnosis, rekomendasi, dan waktu pemeriksaan sehingga dapat digunakan sebagai dokumentasi hasil skrining.

3.7. Pengujian Black Box

Pengujian *Black Box Testing* dilakukan terhadap lima fungsi utama aplikasi, yaitu *upload* gambar dengan format valid, *upload* file dengan format tidak valid, proses prediksi, penyimpanan riwayat ke database, dan pengunduhan laporan PDF, sebagaimana ditunjukkan pada Tabel 6. Seluruh skenario pengujian menunjukkan hasil valid, yang berarti setiap fungsi aplikasi berjalan sesuai dengan hasil yang diharapkan pada rancangan sistem

No.	Fitur yang Diuji	Skenario Pengujian	Hasil yang Diharapkan	Kesimpulan
1	Upload gambar	Mengunggah file gambar valid	Gambar berhasil diterima sistem	Valid
2	Upload file tidak valid	Mengunggah file selain gambar	Sistem menolak file	Valid
3	Prediksi	Menjalankan prediksi gambar	Sistem menampilkan hasil klasifikasi	Valid
4	Penyimpanan riwayat	Melakukan proses klasifikasi	Data tersimpan pada database	Valid
5	Download PDF	Mengunduh laporan	Sistem menghasilkan file PDF	Valid

Tabel 6. Pengujian Black Box

3.8. Pembahasan

Berdasarkan hasil implementasi dan pengujian yang telah dilakukan, model *CNN* dengan arsitektur *MobileNetV2* terbukti dapat digunakan untuk mengklasifikasikan foto senyum menjadi kategori normal dan maloklusi dengan performa yang baik, yaitu *accuracy* sebesar 95% pada data *testing*. Hasil ini sejalan dengan penelitian-penelitian sebelumnya yang menunjukkan bahwa pendekatan *deep learning*, khususnya *CNN*, memiliki kemampuan yang baik dalam mengenali pola visual pada citra gigi dan wajah untuk mendukung proses diagnosis di bidang kedokteran gigi [3], [4], [5], [23].

Penggunaan pendekatan *transfer learning* dengan bobot awal *ImageNet* terbukti membantu proses pelatihan model meskipun jumlah *dataset* yang digunakan relatif terbatas, yaitu hanya 1.000 citra. Hal ini konsisten dengan penelitian sebelumnya yang menyatakan bahwa *transfer learning* dapat mempercepat proses pembelajaran dan meningkatkan performa klasifikasi pada kondisi ketersediaan data yang terbatas [24], [25]. Selain itu, penerapan augmentasi data turut membantu memperkaya variasi data pelatihan sehingga membantu mengurangi risiko *overfitting*, sebagaimana ditunjukkan oleh kesamaan pola antara kurva *training* dan *validation* baik pada grafik *accuracy* maupun *loss*.

Walaupun demikian, model masih melakukan sejumlah kecil kesalahan prediksi sebagaimana terlihat pada *confusion matrix*. Kesalahan tersebut kemungkinan besar dipengaruhi oleh variasi kondisi pengambilan foto, seperti sudut, pencahayaan, dan kualitas kamera yang digunakan, serta kemiripan visual antara kondisi gigi normal dan maloklusi ringan yang sulit dibedakan hanya dari foto senyum tanpa pemeriksaan langsung [26]. Oleh karena itu, hasil klasifikasi yang dihasilkan sistem tetap ditujukan sebagai alat bantu skrining awal, bukan sebagai pengganti pemeriksaan maupun diagnosis klinis yang dilakukan oleh dokter gigi atau ortodontis.

Dari sisi implementasi sistem, integrasi model ke dalam aplikasi berbasis web yang dilengkapi fitur penyimpanan riwayat dan pembuatan laporan PDF menunjukkan bahwa model *CNN MobileNetV2* tidak hanya mampu mencapai performa klasifikasi yang baik, tetapi juga dapat diterapkan pada sistem yang mudah digunakan oleh masyarakat umum tanpa memerlukan perangkat komputasi khusus, sehingga berpotensi meningkatkan aksesibilitas informasi awal terkait kondisi maloklusi gigi.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode *Convolutional Neural Network* dengan arsitektur *MobileNetV2* berhasil diterapkan untuk mengklasifikasikan foto senyum ke dalam dua kategori, yaitu normal dan maloklusi, menggunakan pendekatan *transfer learning* berbasis bobot awal *ImageNet*. Model yang dikembangkan memperoleh nilai *accuracy* sebesar 95% pada data *testing*, dengan nilai *precision*, *recall*, dan *F1-score* yang cukup seimbang pada kedua kelas, yaitu masing-masing berkisar antara 0,94 hingga 0,96. Hasil tersebut menunjukkan bahwa model mampu membedakan foto senyum normal dan maloklusi dengan baik meskipun jumlah *dataset* yang digunakan relatif terbatas.

Model yang telah dilatih dan dievaluasi berhasil diimplementasikan ke dalam aplikasi berbasis web yang dilengkapi fitur unggah foto senyum, prediksi otomatis, penyimpanan riwayat hasil klasifikasi menggunakan database *SQLite*, dan pembuatan laporan dalam format PDF. Hasil pengujian *Black Box Testing* menunjukkan bahwa seluruh fungsi utama aplikasi berjalan sesuai dengan rancangan sistem yang telah dibuat.

Secara keseluruhan, penelitian ini membuktikan bahwa arsitektur *MobileNetV2* dapat dimanfaatkan untuk melakukan klasifikasi awal kondisi normal dan maloklusi berdasarkan foto senyum frontal secara cepat dan konsisten. Meskipun demikian, performa dan keandalan model masih sangat bergantung pada karakteristik serta jumlah *dataset* yang digunakan selama pelatihan. Oleh karena itu, sistem yang dikembangkan pada penelitian ini lebih tepat digunakan sebagai alat bantu skrining awal dan bukan sebagai pengganti pemeriksaan maupun diagnosis klinis yang dilakukan oleh dokter gigi atau ortodontis. Penelitian selanjutnya disarankan untuk memperbanyak variasi *dataset*, melibatkan validasi label dari tenaga profesional, membandingkan performa dengan arsitektur *CNN* lain, serta menambahkan pendekatan *explainable artificial intelligence* agar dasar pengambilan keputusan model dapat lebih mudah dipahami oleh pengguna.

Ucapan Terimakasih

Penulis mengucapkan terima kasih kepada Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang, serta dosen pembimbing yang telah memberikan arahan dan bimbingan selama proses penelitian dan penyusunan artikel ini.

Reference

- [1] S. Azizi, S. Hatampoor, And S. Tahamtan, “Applications Of Artificial Intelligence In Diagnosis And Treatment Planning Of Orthodontics: A Narrative Review,” Oct. 01, 2025, *Springer International Publishing*. Doi: 10.1007/S44445-025-00077-0.
- [2] R. M. Kabalan, R. K. Tayyar, T. Z. Khattab, And M. Y. Hajeer, “Characteristics And Dynamics Of Smile In Patients With Skeletal Class Ii Malocclusion Versus Class I Malocclusion Using Still Digital Video Captures: A Three-Group, Cross-Sectional, Comparative Study,” *Cureus*, Oct. 2022, Doi: 10.7759/Cureus.30704.
- [3] W. S. Shin *Et AL.*, “Deep Learning Based Prediction Of Necessity For Orthognathic Surgery Of Skeletal Malocclusion Using Cephalogram In Korean Individuals,” *Bmc Oral Health*, Vol. 21, No. 1, Dec. 2021, Doi: 10.1186/S12903-021-01513-3.
- [4] S. B. A. Kartbak, M. B. Özel, D. N. C. Kocakaya, M. Çakmak, And E. A. Sinanoğlu, “Classification Of Intraoral Photographs With Deep Learning Algorithms Trained According To Cephalometric Measurements,” *Diagnostics*, Vol. 15, No. 9, May 2025, Doi: 10.3390/Diagnostics15091059.
- [5] R. Zhang *Et AL.*, “Development And Evaluation Of A Deep Learning Model For Occlusion Classification In Intraoral Photographs,” *Peerj*, Vol. 13, P. E20140, Sep. 2025, Doi: 10.7717/Peerj.20140.
- [6] D. N. C. Kocakaya, M. B. Özel, S. B. A. Kartbak, M. Çakmak, And E. A. Sinanoğlu, “Profile Photograph Classification Performance Of Deep Learning Algorithms Trained Using Cephalometric Measurements: A Preliminary Study,” *Diagnostics*, Vol. 14, No. 17, Sep. 2024, Doi: 10.3390/Diagnostics14171916.
- [7] J. E. C. G. De Oro *Et AL.*, “Hyperparameter Tuning And Automatic Image Augmentation For Deep Learning-Based Angle Classification On Intraoral Photographs—A Retrospective Study,” *Diagnostics*, Vol. 12, No. 7, Jul. 2022, Doi: 10.3390/Diagnostics12071526.
- [8] M. Hung *Et AL.*, “Applications Of Artificial Intelligence In Dental Malocclusion: A Scoping Review Of Recent Advances (2020–2025),” *Ai*, Vol. 7, No. 1, P. 10, Dec. 2025, Doi: 10.3390/Ai7010010.
- [9] R. S. Gracea *Et AL.*, “Artificial Intelligence For Orthodontic Diagnosis And Treatment Planning: A Scoping Review,” Jan. 01, 2025, *Elsevier Ltd*. Doi: 10.1016/J.Jdent.2024.105442.
- [10] H. Mohammed, B. K. Daniel, And M. Farella, “Smile Analysis In Dentistry And Orthodontics—A Review,” 2025, *Taylor And Francis Asia Pacific*. Doi: 10.1080/03036758.2024.2316226.
- [11] Y. M. Alsakar, N. Elazab, N. Nader, W. Mohamed, M. Ezzat, And M. Elmogy, “Multi-Label Dental Disorder Diagnosis Based On Mobilenetv2 And Swin Transformer Using Bagging Ensemble Classifier,” *Sci. Rep.*, Vol. 14, No. 1, Dec. 2024, Doi: 10.1038/S41598-024-73297-9.
- [12] L. Brigato, B. Barz, L. Iocchi, And J. Denzler, “Image Classification With Small Datasets: Overview And Benchmark,” 2022, *Institute Of Electrical And Electronics Engineers Inc.* Doi: 10.1109/Access.2022.3172939.
- [13] C. Patricio, J. C. Neves, And L. F. Teixeira, “Explainable Deep Learning Methods In Medical Image Classification: A Survey,” *Acm Comput. Surv.*, Vol. 56, No. 4, Apr. 2024, Doi: 10.1145/3625287.
- [14] N. T. Singh, C. Kaur, A. Chaudhary, And S. Goyal, “Preprocessing Of Medical Images Using Deep Learning: A Comprehensive Review,” In *Proceedings Of The 2023 2nd International Conference On Augmented Intelligence And Sustainable Systems, Icaiss 2023*, Institute Of Electrical And Electronics Engineers Inc., 2023, Pp. 521–527. Doi: 10.1109/Icaiss58487.2023.10250462.
- [15] D. B. Rathod And K. Saritha, “Enhanced Mobilenetv2 With An Attention Mechanism For Real-Time Mri-Based Brain Tumor Classification: A Deep Learning Approach,” *Architecture Image Studies*, Vol. 6, No. 3, Pp. 1309–1319, Sep. 2025, Doi: 10.62754/Ais.V6i3.447.
- [16] S. A. Hicks *Et AL.*, “On Evaluation Metrics For Medical Applications Of Artificial Intelligence,” *Sci. Rep.*, Vol. 12, No. 1, Dec. 2022, Doi: 10.1038/S41598-022-09954-8.
- [17] O. Rainio, J. Teuho, And R. Klén, “Evaluation Metrics And Statistical Tests For Machine Learning,” *Sci. Rep.*, Vol. 14, No. 1, Dec. 2024, Doi: 10.1038/S41598-024-56706-X.
- [18] D. J. Evan And P. O. N. Saian, “Implementasi Python Framework Flask Pada Modul Transfer Out Toko Di Pt Xyz,” *Jipi (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, Vol. 8, No. 4, Pp. 1121–1131, Nov. 2023, Doi: 10.29100/Jipi.V8i4.4020.
- [19] Y. Yuliani, “Rancangan Aplikasi Belajar Bahasa Inggris Berbasis Mobile Menggunakan Database Sqlite,” *Jorapi : Journal Of Research And Publication Innovation*, Vol. 2, No. 1, 2024, [Online]. Available: <https://Jurnal.Portalpublikasi.Id/Index.Php/Jorapi/Index>
- [20] I. S. Ahmad, J. Dai, Y. Xie, And X. Liang, “Deep Learning Models For Ct Image Classification: A Comprehensive Literature Review,” Jan. 02, 2025, *Ame Publishing Company*. Doi: 10.21037/Qims-24-1400.

- [21] R. Archana And P. S. E. Jeevaraj, "Deep Learning Models For Digital Image Processing: A Review," *Artif. Intell. Rev.*, Vol. 57, No. 1, Jan. 2024, Doi: 10.1007/S10462-023-10631-Z.
- [22] E. Bardideh, F. Lal Alizadeh, M. Amiri, And M. Ghorbani, "Designing An Artificial Intelligence System For Dental Occlusion Classification Using Intraoral Photographs: A Comparative Analysis Between Artificial Intelligence-Based And Clinical Diagnoses," *American Journal Of Orthodontics And Dentofacial Orthopedics*, Vol. 166, No. 2, Pp. 125–137, Aug. 2024, Doi: 10.1016/J.Ajodo.2024.03.012.
- [23] I. D. Mienye, T. G. Swart, G. Obaido, M. Jordan, And P. Ilono, "Deep Convolutional Neural Networks In Medical Image Analysis: A Review," Mar. 01, 2025, *Multidisciplinary Digital Publishing Institute (Mdpi)*. Doi: 10.3390/Info16030195.
- [24] E. Supriyadi *Et Al.*, "Pendampingan Guru Matematika Di Cianjur Dalam Penggunaan Bahasa Pemrograman Python Dengan Google Collaboratory," 2023.
- [25] W. Wahyuningsih, G. S. Nugraha, And R. Dwiyanaputra, "Classification Of Dental Caries Disease In Tooth Images Using A Comparison Of Efficientnet-B0, Mobilenetv2, Resnet-50, Inceptionv3 Architectures," *Jurnal Teknik Informatika (Jutif)*, Vol. 5, No. 4, Pp. 177–185, Jul. 2024, Doi: 10.52436/1.Jutif.2024.5.4.2187.
- [26] S. Talaat *Et Al.*, "The Validity Of An Artificial Intelligence Application For Assessment Of Orthodontic Treatment Need From Clinical Images," *Semin. Orthod.*, Vol. 27, No. 2, 2021, Doi: 10.1053/J.Sodo.2021.05.012.