

IMPLEMENTASI MODEL TRANSFER LEARNING EFFICIENTNET UNTUK PENDETEKSIAN BAHASA ISYARAT INDONESIA (BISINDO) PADA PERANGKAT ANDROID

Irnanda Rizka Fadhilah, Muhammad Muharrom Al Haromainy, Hendra Maulana

Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

Jalan Raya Rungkut Madya No. 1, Gunung Anyar, Surabaya, Indonesia

irnanrf@gmail.com

ABSTRAK

Bahasa Isyarat Indonesia (BISINDO) adalah bahasa komunikasi yang digunakan oleh individu dengan gangguan pendengaran untuk berinteraksi satu sama lain dan dengan masyarakat umum. Namun, aksesibilitas informasi bagi komunitas BISINDO masih terbatas, terutama dalam hal pemahaman dan penerjemahan bahasa isyarat secara otomatis. Kurangnya alat bantu yang efektif menghambat interaksi mereka dengan masyarakat yang lebih luas, sehingga memperdalam kesenjangan komunikasi. Dalam upaya meningkatkan aksesibilitas informasi bagi komunitas BISINDO, penelitian ini mengimplementasikan model transfer learning EfficientNet untuk pendeteksian Bahasa Isyarat Indonesia pada perangkat Android. Data pelatihan yang digunakan adalah dataset gambar Bahasa Isyarat Indonesia (BISINDO) yang berisi gestur-gestur alfabet dari A sampai Z. Kumpulan data yang digunakan untuk model ini memiliki total sekitar 10400 gambar dengan 26 kelas yang berbeda. Penelitian ini menggunakan rasio data latih dan data uji 80-20, yaitu 80% kumpulan data citra digunakan untuk proses pelatihan dan 20% digunakan untuk proses pengujian. Model menggunakan pre-trained ImageNet, lalu dilakukan proses transfer learning menggunakan dataset BISINDO yang sudah disiapkan. Proses pelatihan model dilakukan dengan variasi jumlah epoch, yaitu 20, 30, dan 40, dengan evaluasi performa menggunakan metrik akurasi, precision, recall, dan F1 score. Hasil analisis menunjukkan bahwa model pada Epoch 20 mencapai akurasi tertinggi, yaitu 99.24%, dengan keseimbangan yang optimal antara kinerja dan efisiensi waktu pelatihan. Model berhasil diimplementasikan pada aplikasi android dengan kinerja yang sangat baik, membuktikan potensinya sebagai alat bantu yang efisien dan dapat diakses untuk komunitas tunarungu.

Kata kunci : *bisindo, machine learning, efficientnet, android, transfer learning*

1. PENDAHULUAN

Dalam era perkembangan teknologi yang pesat, terutama di bidang kecerdasan buatan dan komputasi bergerak, terdapat potensi besar untuk mengembangkan solusi inovatif dalam berbagai bidang, termasuk dalam pengembangan sistem pengenalan bahasa isyarat. Saat ini, banyak penyandang tunarungu yang masih menghadapi kendala dalam berkomunikasi dengan masyarakat umum karena keterbatasan alat bantu yang dapat menerjemahkan bahasa isyarat secara real-time. Hal ini mengakibatkan rendahnya partisipasi sosial dan ekonomi dari komunitas tunarungu, serta memperdalam kesenjangan sosial. Kecepatan dan kemudahan akses teknologi modern dapat memberikan kontribusi signifikan dalam meningkatkan kualitas hidup penyandang tunarungu dan memperluas partisipasi mereka dalam masyarakat.

Bahasa isyarat merupakan Bahasa yang digunakan oleh penyandang tunarungu dalam berkomunikasi [2]. Komunikasi melalui bahasa isyarat menjadi sarana utama bagi komunitas tuna rungu dan tuna wicara dalam berinteraksi, baik sesama maupun dengan masyarakat umum. Bahasa isyarat memungkinkan lawan bicara untuk memahami pesan yang disampaikan dengan mengenali pola alfabet yang dibentuk melalui gestur tangan atau tubuh.

Kesulitan dalam berkomunikasi menjadi kendala bagi teman Tuli yang tidak dapat mempelajari bahasa dalam bentuk verbal atau memperoleh kemampuan berbicara secara normal. Salah satu cara mereka untuk berkomunikasi adalah menggunakan bahasa isyarat. [3].

Jenis Bahasa isyarat yang terdapat di Indonesia sendiri, yakni Sistem Bahasa Isyarat Indonesia (SIBI) dan Bahasa Isyarat Indonesia (BISINDO) [4]. Berbeda dengan Sistem Isyarat Bahasa Indonesia (SIBI), BISINDO dianggap lebih mewakili keberagaman dan nilai-nilai budaya yang ada di berbagai daerah di Indonesia.

Sayangnya, dukungan teknologi untuk bahasa isyarat, khususnya BISINDO, masih sangat terbatas. Kebanyakan aplikasi yang ada tidak mendukung BISINDO atau tidak memiliki tingkat akurasi yang memadai untuk digunakan dalam kehidupan sehari-hari. Oleh karena itu, inovasi teknologi sangat diperlukan untuk menjembatani kesenjangan ini dan memberikan solusi yang dapat diandalkan. Pentingnya memahami keberagaman isyarat dalam BISINDO menciptakan kesempatan untuk menggali inovasi teknologi guna mendukung komunikasi efektif antara penyandang tunarungu dan masyarakat umum.

Oleh karena itu, penelitian ini akan mengusung implementasi transfer learning model EfficientNet dalam mendeteksi isyarat-isyarat BISINDO. Model

EfficientNet, yang dikenal dengan efisiensi dan akurasi tinggi, akan diintegrasikan pada aplikasi Android. Pendekatan ini bertujuan untuk menciptakan solusi yang efisien dan dapat diakses secara mudah untuk mendukung interaksi komunikatif antara penyandang tunarungu dan masyarakat umum melalui perangkat mobile. Dengan aplikasi ini, diharapkan penyandang tunarungu dapat lebih mudah berkomunikasi dan berinteraksi dengan masyarakat umum, sehingga meningkatkan partisipasi mereka dalam berbagai aspek kehidupan sosial dan ekonomi.

2. TINJAUAN PUSTAKA

Snehal Patil et al. dalam penelitiannya yang berjudul “Gesture Detection using Tensorflow Lite EfficientNet Model for Communication and E-learning Module for Mute and Deaf” mengembangkan aplikasi untuk membantu individu dengan cacat pendengaran atau bicara. Penelitian ini menggunakan model Tensorflow Lite EfficientNet untuk deteksi gerakan tangan guna membentuk teks, serta pengembangan modul e-learning dan mekanisme peringatan darurat. Hasil menunjukkan akurasi 98,91% untuk CNN tradisional dan 98,82% untuk Tensorflow Lite EfficientNet, dengan efisiensi komputasi yang tinggi [5].

Penelitian oleh Ayu Widya Agata dengan judul “Pengenalan Bahasa Isyarat Indonesia (BISINDO) Menggunakan Algoritma Scale Invariant Feature Transform (SIFT) dan Convolutional Neural Network (CNN)” membahas pengenalan huruf BISINDO dari A hingga Z. Penelitian ini menggabungkan algoritma SIFT untuk ekstraksi fitur dan CNN untuk klasifikasi gambar. Hasil pengujian menunjukkan akurasi tertinggi sebesar 99,78% pada epoch 55 [6].


Penelitian ini menggabungkan fokus dari penelitian-penelitian terdahulu dengan menciptakan sistem pengenalan Bahasa Isyarat dengan tingkat akurasi yang tinggi serta mengembangkan aplikasi khusus untuk pengenalan BISINDO. Diharapkan penelitian ini dapat menyediakan aplikasi efektif bagi kelompok tunarungu dan tunawicara serta memperluas pemahaman masyarakat tentang pentingnya Bahasa Isyarat Indonesia.

2.1. BISINDO

Menurut Dewan Pengurus Daerah Gerakan untuk Kesejahteraan Tunarungu Indonesia (DPD Gerkatin DKI Jakarta), Bahasa Isyarat Indonesia (BISINDO) adalah sistem komunikasi yang efektif untuk penyandang tunarungu di Indonesia, dikembangkan oleh komunitas tunarungu sendiri dan digunakan untuk berkomunikasi dengan orang yang mendengar. BISINDO mulai berkembang seiring dengan meningkatnya kesadaran akan kebutuhan bahasa isyarat yang bersifat nasional, menggantikan bahasa isyarat yang sebelumnya hanya digunakan di tingkat keluarga atau komunitas kecil. Pada tahun 2006, Pemerintah Indonesia mengakui BISINDO sebagai bahasa isyarat nasional melalui Keputusan Presiden

Nomor 50 Tahun 2006. Pengakuan ini memberikan dasar yang kuat untuk penggunaan BISINDO dalam berbagai konteks, termasuk pendidikan, media, dan layanan kesehatan.

Undang-undang Nomor 8 Tahun 2016 tentang Penyandang Disabilitas menyatakan bahwa bahasa isyarat adalah bentuk layanan aksesibilitas non-fisik yang resmi digunakan di Indonesia, dengan bahasa isyarat alamiah dari komunitas tunarungu yang diakui sebagai bahasa resmi [7]. Pengakuan resmi ini tidak hanya memberikan legitimasi pada BISINDO, tetapi juga mendorong perkembangan lebih lanjut dalam kosakata dan tata bahasa. Komunitas tunarungu terus memperkaya BISINDO, menyesuaikannya dengan perkembangan zaman dan kebutuhan komunikasi mereka, sehingga BISINDO menjadi sarana komunikasi yang efektif dan kaya bagi komunitas tunarungu di Indonesia. Pentingnya BISINDO juga tercermin dalam penggunaan kombinasi kedua tangan untuk mengekspresikan isyarat, seperti ditunjukkan pada contoh alfabet BISINDO pada Gambar selanjutnya.



Gambar 1. Abjad dalam BISINDO


2.2. EfficientNet

EfficientNet adalah keluarga arsitektur neural network yang dirancang untuk mencapai keseimbangan optimal antara kinerja dan efisiensi. EfficientNet merupakan kumpulan model yang terdiri dari EfficientNet-B0 hingga EfficientNet-B7 yang awalnya merupakan turunan dari EfficientNet-B0 kemudian dilakukan evaluasi hingga muncul model-modelnya yang lain [1].

Arsitektur ini diperkenalkan oleh tim peneliti di Google pada tahun 2019 dan telah menarik perhatian dalam bidang visi komputer karena kemampuannya untuk memberikan kinerja tinggi dengan jumlah parameter yang relatif lebih kecil dibandingkan dengan arsitektur sebelumnya.

Pendekatan utama yang digunakan dalam pengembangan EfficientNet adalah meningkatkan

kinerja dengan meningkatkan kedalaman, lebar, dan resolusi model secara proporsional. Dengan demikian, serangkaian model EfficientNet dapat dihasilkan dengan menggunakan faktor skala (scale factor) untuk mengatur tingkat kompleksitas arsitektur. Skala faktor ini mencakup parameter kedalaman (depth), lebar (width), dan resolusi gambar (resolution). Keunggulan utama dari EfficientNet adalah kemampuannya untuk mencapai tingkat akurasi yang tinggi dalam tugas-tugas visi komputer, seperti klasifikasi gambar, sambil tetap meminimalkan jumlah parameter yang diperlukan. Dalam hal kinerja, Gambar 3 menunjukkan kinerja EfficientNet dibandingkan dengan arsitektur jaringan lainnya. Model EfficientNet terbesar, yaitu EfficientNet B7, mencapai kinerja tingkat lanjut pada dataset ImageNet dan CIFAR-100. Model ini mencapai akurasi top-1 sekitar 84,4% dan akurasi top-5 sekitar 97,3% pada dataset ImageNet. Selain itu, ukuran model ini 8,4 kali lebih kecil dan 6,1 kali lebih cepat dibandingkan dengan model CNN terbaik sebelumnya. Pada dataset CIFAR-100, model ini mencapai akurasi 91,7%, dan pada dataset Flowers, mencapai akurasi 98,8%. Hal ini membuat EfficientNet menjadi pilihan yang menarik untuk aplikasi di mana sumber daya komputasi dan penyimpanan terbatas.



Gambar 2. Ukuran dan kinerja EfficientNet pada dataset ImageNet [11]

Dengan adanya EfficientNet, pengembang dan peneliti dapat memanfaatkan arsitektur yang efisien secara komputasional tanpa mengorbankan kinerja, sehingga cocok untuk diterapkan dalam berbagai konteks, termasuk di lingkungan dengan sumber daya terbatas seperti perangkat mobile atau sistem terdistribusi.


2.3. Transfer Learning

Transfer learning merupakan pendekatan dalam pembelajaran mesin di mana pengetahuan yang diperoleh dari menyelesaikan suatu tugas digunakan untuk meningkatkan kinerja dalam menyelesaikan tugas lain yang terkait [8]. Prinsip dasar transfer learning adalah memanfaatkan pengetahuan yang telah diperoleh dari satu tugas untuk meningkatkan kinerja pada tugas yang berbeda. Terdapat tiga jenis utama

transfer learning: berbasis instance, berbasis fitur, dan berbasis model [9].

Transfer learning berbasis instance melibatkan penyesuaian parameter model untuk tugas baru, sementara berbasis fitur menggunakan representasi fitur yang sudah ada untuk tugas baru [8]. Sementara itu, transfer learning berbasis model menggabungkan model yang sudah ada dengan model baru untuk meningkatkan kinerja secara keseluruhan [9]. Transfer learning telah berhasil diterapkan dalam berbagai bidang, seperti pengenalan gambar, pemrosesan bahasa alami, dan deteksi objek [10].

Sebagai contoh dalam pengembangan sistem pendeteksian bahasa isyarat BISINDO menggunakan EfficientNet, pendekatan transfer learning yang tepat adalah *fine-tuning* berbasis *instance*. *Fine-tuning* adalah bentuk umum dari transfer learning di mana model yang sudah dilatih pada tugas tertentu disesuaikan ulang atau dilatih kembali pada tugas yang berbeda. Fine-tuning ini dimulai dengan menggunakan EfficientNet yang telah dilatih pada dataset ImageNet sebagai model awal. Model ini memiliki kemampuan untuk menangkap fitur umum dari berbagai objek visual. Lapisan-lapisan awal EfficientNet, yang memiliki kemampuan ekstraksi fitur yang umum, dianggap sebagai "model dasar" atau "model awal." Dalam konteks ini, model yang sudah memiliki pemahaman terkait suatu domain dapat mentransfer wawasannya ke tugas baru, sehingga mempercepat proses pembelajaran dan meningkatkan akurasi prediksi.



Gambar 3. Konsep Transfer Learning

Dalam langkah selanjutnya, lapisan-lapisan akhir dari EfficientNet disesuaikan dengan menambahkan lapisan-lapisan tambahan yang khusus untuk tugas pendeteksian bahasa isyarat BISINDO. Selanjutnya, model yang telah disesuaikan tersebut dilatih ulang menggunakan dataset BISINDO. Pendekatan ini berguna ketika kumpulan data terbatas atau sulit diperoleh, karena model dapat menggunakan pengetahuannya dari tugas sebelumnya untuk memberikan solusi yang lebih baik pada tugas yang sedang dihadapi. Transfer learning diharapkan dapat menjadi strategi yang efektif untuk mengoptimalkan kinerja model dalam berbagai konteks aplikasi machine learning.

2.4. Android

Android adalah sistem operasi mobile open-source yang dikembangkan oleh Google dan telah dioperasikan pada lebih dari 400 juta perangkat di seluruh dunia. Android telah meraih dominasi luar biasa di pasar smartphone global.

Dengan pangsa pasar lebih dari 70% pada tahun 2021 menurut StatCounter, Android menjadi pilihan utama bagi pengguna di seluruh dunia. Keunggulan utama Android melibatkan fleksibilitas tinggi, kemampuan personalisasi yang luas, dan akses yang tak terbatas ke berbagai aplikasi melalui Google Play Store. Dengan sifat open-source-nya, Android membuka pintu lebar bagi para pengembang untuk menciptakan beragam aplikasi inovatif, mulai dari permainan hingga solusi bisnis yang kompleks.

3. METODE PENELITIAN

Tujuan dari penelitian ini adalah untuk membangun sebuah aplikasi android yang dapat mendeteksi huruf Bahasa Isyarat Indonesia (BISINDO) dengan cara mengimplementasikan teknik transfer learning menggunakan EfficientNet. Untuk mencapai tujuan tersebut, kami mengembangkan modul klasifikasi yang menggunakan arsitektur EfficientNet. Kami melatih model ini menggunakan kumpulan data gambar gerakan BISINDO dari huruf A sampai Z. Untuk tujuan evaluasi, kami juga menggunakan pelatihan model dengan jumlah epoch yang berbeda guna mencari model yang terbaik. Hasil model yang sudah di latih akan dibandingkan dalam akurasi klasifikasi.

3.1. Pengumpulan Data

Untuk mengimplementasikan transfer learning menggunakan EfficientNet, diperlukan kumpulan data gambar yang terdiri dari gestur BISINDO dari huruf A sampai Z. Dataset terdiri dari 10400 data milik 26 kelas huruf. Setiap kelas huruf BISINDO memiliki kurang lebih 400 data pada setiap kelasnya. Setiap data dalam dataset adalah gambar yang memiliki dimensi 224 x 224 piksel.



Gambar 4. Contoh dataset BISINDO


3.2. Preprocessing Data

Pada tahap praproses data dengan normalisasi dan augmentasi, akan dilakukan beberapa langkah penting untuk memastikan kualitas dan keberagaman dataset gerakan tangan BISINDO. Normalisasi dilakukan untuk menyamakan skala intensitas dan ukuran gambar dalam dataset, memastikan konsistensi dalam karakteristik visual. Hal ini membantu model dalam memahami pola-pola gerakan tanpa terpengaruh oleh perbedaan skala atau intensitas yang mungkin ada dalam dataset. Selanjutnya, augmentasi data dilakukan dengan tujuan menambah variasi dalam dataset. Proses ini mencakup teknik seperti rotasi, pergeseran, dan pembalikan gambar, yang bertujuan memperkaya dataset dengan contoh-contoh yang berbeda secara geometric.

Augmentasi data memberikan model kemampuan untuk mengenali dan menginterpretasi variasi gerakan tangan yang lebih luas, meningkatkan kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya. Tahapan praproses ini merupakan langkah kritis dalam mempersiapkan dataset untuk pelatihan model, memastikan keberhasilan model dalam mengenali dan mengklasifikasikan isyarat dalam Bahasa Isyarat Indonesia.

3.2. Model Transfer Learning EfficientNet

Pada tahap implementasi model transfer learning menggunakan EfficientNet, proses dimulai dengan pemilihan arsitektur yang tepat. EfficientNet adalah keluarga arsitektur neural network yang dirancang untuk mencapai keseimbangan optimal antara kinerja dan efisiensi. EfficientNet terdiri dari beberapa model, mulai dari EfficientNet-B0 hingga EfficientNet-B7, yang dikembangkan melalui evaluasi berkelanjutan dari model EfficientNet-B0. Arsitektur ini diperkenalkan oleh tim peneliti di Google pada tahun 2019 dan menarik perhatian di bidang visi komputer karena kemampuannya memberikan kinerja tinggi dengan jumlah parameter yang relatif kecil dibandingkan arsitektur sebelumnya.



Gambar 5. Arsitektur EfficientNet

Pendekatan utama dalam pengembangan EfficientNet adalah meningkatkan kinerja dengan meningkatkan kedalaman, lebar, dan resolusi model secara proporsional. Dengan menggunakan faktor skala (*scale factor*) untuk mengatur kedalaman (*depth*), lebar (*width*), dan resolusi gambar (*resolution*), serangkaian model EfficientNet dapat dihasilkan.

Hal yang setelah itu dilakukan adalah konfigurasi model transfer learning dengan mengintegrasikan pre-trained weights dari ImageNet. Pre-trained weights ini memberikan model representasi awal yang kuat terhadap fitur-fitur umum dalam gambar, yang kemudian disesuaikan dengan dataset khusus gerakan tangan BISINDO. Penggunaan pre-trained weights memungkinkan model memanfaatkan pengetahuan yang telah terakumulasi dari dataset besar seperti ImageNet, sehingga model dapat lebih cepat menyesuaikan diri dengan karakteristik dataset BISINDO. Konfigurasi model mencakup dimensi input gambar 224x224 piksel dengan tiga saluran warna (RGB), pengaturan 'include_top' menjadi false, penggunaan bobot pra-latih dari dataset ImageNet, pengolahan melalui lapisan Global Average Pooling 2D, dan penambahan lapisan Dense dengan aktivasi ReLU serta lapisan Dense terakhir dengan aktivasi softmax untuk klasifikasi.

3.3. Pelatihan Model

Setelah konfigurasi model selesai, langkah berikutnya adalah kompilasi model. Pada tahap ini, model dikompilasi dengan konfigurasi tertentu yang telah ditentukan. Peneliti memilih menggunakan optimizer Adam sebagai metode optimasi untuk meningkatkan pelatihan model. Fungsi loss yang digunakan adalah categorical_crossentropy, yang berfungsi untuk mengukur sejauh mana model mengikuti distribusi kelas pada dataset. Selain itu, metrik akurasi juga digunakan sebagai alat evaluasi kinerja model, memberikan pemahaman sejauh mana model mampu mengenali dan mengklasifikasikan isyarat BISINDO dengan tepat. Konfigurasi ini merupakan langkah penting dalam mempersiapkan model untuk tahap pelatihan selanjutnya.

Model dilatih menggunakan dataset BISINDO dengan rasio 80-20 untuk data latih dan data uji. Proses pelatihan dilakukan melalui beberapa epoch seperti epoch 20, epoch 30, dan epoch 40 untuk meningkatkan kinerja model dalam mengenali isyarat BISINDO. Pemilihan rasio 80-20 sudah menjadi praktik umum yang terbukti efektif dalam membagi dataset untuk melatih dan menguji model pembelajaran mesin. Selama pelatihan, model akan dihadapkan pada dataset yang telah dimodifikasi dan disiapkan sebelumnya, dan akan diperbarui berdasarkan dataset tersebut. Proses pelatihan ini bertujuan untuk memastikan bahwa model mencapai tingkat akurasi yang diharapkan dan dapat melakukan generalisasi dengan baik pada data baru.

3.4. Pengujian Model

Setelah tahap pelatihan selesai, langkah berikutnya adalah pengujian model untuk mengevaluasi kinerjanya dalam mengenali isyarat BISINDO. Pengujian dilakukan menggunakan data uji yang telah dipisahkan sebelumnya. Evaluasi model mencakup metrik akurasi, presisi, recall, dan F1 score untuk mengukur kinerja model dalam berbagai aspek

klasifikasi. Pengujian dilakukan untuk memastikan bahwa model tidak hanya mencapai akurasi yang tinggi tetapi juga memiliki kemampuan yang baik dalam mengenali variasi gerakan isyarat BISINDO.

Visualisasi hasil pelatihan melibatkan grafik akurasi dan loss selama proses pelatihan, memberikan pemahaman yang mendalam tentang performa model. Grafik akurasi menunjukkan sejauh mana model mampu mengenali isyarat BISINDO, sementara grafik loss menggambarkan perubahan nilai fungsi loss selama iterasi pelatihan. Visualisasi ini membantu peneliti dan pengembang dalam mengevaluasi kinerja model, mengidentifikasi tren, dan membuat penyesuaian jika diperlukan.

Pengujian model juga mencakup implementasi model pada perangkat Android. Model EfficientNet dikonversi ke format yang dapat dijalankan secara efisien pada platform Android. Pengembangan antarmuka pengguna aplikasi Android dilakukan untuk memungkinkan interaksi yang intuitif dengan model melalui kamera perangkat. Aplikasi diuji coba pada perangkat fisik atau emulator Android untuk memastikan integrasi model berjalan dengan lancar dan respons aplikasi memadai. Hasil pengujian memberikan wawasan tentang keakuratan deteksi gerakan tangan BISINDO dan respons aplikasi dalam situasi nyata, memastikan bahwa aplikasi dapat digunakan secara efektif oleh penyandang tunarungu dalam berkomunikasi.

4. HASIL DAN PEMBAHASAN

Pada bagian ini, penulis menyajikan analisis mendalam terhadap kinerja model yang diimplementasikan dan aplikasi yang dikembangkan, serta hasil pengujian yang diperoleh.

4.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah dataset BISINDO yang terdiri dari 10.400 gambar gestur tangan dari huruf A sampai Z, dengan 400 gambar per kelas. Selama pengumpulan data, kami memastikan kualitas dan kejelasan gambar untuk setiap gestur, dengan ukuran gambar 224x224 piksel. Dataset ini kemudian dibagi dengan rasio 80-20 untuk data latih dan data uji.

4.2. Preprocessing Data

Proses normalisasi dan augmentasi dilakukan untuk memastikan konsistensi dan keberagaman dataset. Gambar distandarisasi untuk menyamakan skala intensitas, dan augmentasi seperti rotasi dan pergeseran digunakan untuk memperkaya variasi data. Hasil augmentasi membantu model dalam mengenali berbagai variasi gerakan tangan.

4.3. Model Transfer Learning EfficientNet

Pemilihan arsitektur EfficientNet-B3 dilakukan karena efisiensinya dalam kinerja dan jumlah parameter. Model dikonfigurasi dengan bobot pra-latih dari ImageNet, menggunakan ukuran input

gambar 224x224 piksel. Arsitektur EfficientNet yang dipilih menunjukkan keseimbangan optimal antara kedalaman, lebar, dan resolusi.


4.4. Pelatihan model

Model dilatih dengan menggunakan optimizer Adam dan fungsi loss categorical_crossentropy. Pelatihan dilakukan dengan berbagai jumlah epoch (20, 30, dan 40) untuk menemukan konfigurasi terbaik. Selama pelatihan, data dibagi dengan rasio 80-20, dan evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan F1 score.


4.5. Hasil Pelatihan

Hasil pelatihan menunjukkan bahwa model dengan 20 epoch mencapai akurasi tertinggi, yaitu 99.24%, dengan keseimbangan optimal antara kinerja dan efisiensi waktu pelatihan.

4.5.1. Visualisasi Hasil & Analisis Perbandingan




Gambar 6. Akurasi Model dengan Epoch 20



Gambar 7. Akurasi Model dengan Epoch 30

Jika dibandingkan dengan model pada epoch 30 dan 40, dapat disimpulkan bahwa model pada epoch 20 adalah yang terbaik. Hal ini dikarenakan model pada epoch 20 menunjukkan kinerja yang sangat tinggi dan konsisten dalam metrik akurasi, precision, recall, dan F1 score, baik pada data pelatihan maupun validasi.



Gambar 8. Akurasi Model dengan Epoch 40

Tabel 1. Hasil Akurasi Model

Skenario Uji	Epoch	Batch Size	Akurasi
1	20	16	99.24%
2	30	16	99.05%
3	40	16	98.58%

Dengan akurasi pelatihan mencapai 99.24% dan akurasi validasi 98.00%, model ini mampu belajar secara efektif dari data pelatihan dan menggeneralisasi dengan baik pada data yang tidak terlihat. Data history juga memperlihatkan tren peningkatan yang stabil tanpa tanda-tanda overfitting, yang menunjukkan keseimbangan optimal antara kinerja dan efisiensi waktu pelatihan. Oleh karena itu, epoch 20 menjadi kombinasi terbaik dari performa tinggi, stabilitas, dan efisiensi, sehingga menjadi pilihan paling optimal.

Dalam penelitian oleh Snehal Patil yang berjudul “Gesture Detection using Tensor flow lite Efficient Net Model for Communication and E-learning Module for Mute and Deaf”, model Tensorflow Lite EfficientNet digunakan untuk deteksi gerakan tangan pada dataset Bahasa Isyarat Amerika (ASL). Penelitian ini menunjukkan bahwa model EfficientNet mampu mencapai akurasi 98.82%, sedangkan pada penelitian ini berhasil mendapat akurasi yang lebih tinggi yaitu 99.24 pada Epoch 20. Hal ini membuktikan bahwa perbedaan konfigurasi atau fine-tuning pada model sangat berpengaruh pada hasil akurasi, dengan konfigurasi yang baik, model akan juga bisa mencapai akurasi yang lebih optimal.

4.6. Uji Coba Model & Implementasi

Dalam implementasinya, penelitian ini memanfaatkan transfer learning dengan menggunakan model EfficientNet yang telah dilatih sebelumnya dengan dataset besar yaitu ImageNet. Model ini kemudian dilatih ulang menggunakan dataset BISINDO yang telah dikumpulkan. Model yang sudah dilatih ini dikonversi ke format yang lebih kompatibel untuk aplikasi Android, yaitu format ‘.tflite’. Setelah itu, model diimplementasikan ke dalam aplikasi Android yang dikembangkan menggunakan bahasa Kotlin.

Model terbaik diimplementasikan pada aplikasi android yang dapat mendeteksi gestur Bahasa Isyarat Indonesia (BISINDO) secara real-time menggunakan kamera. Hasil prediksi akan ditampilkan pada halaman pengguna, serta presentase kepercayaan diri dari model mendeteksi gestur BISINDO juga akan ditampilkan pada halaman pengguna guna kemudahan pengguna untuk mengetahui informasi mengenai gestur yang dideteksi.



Gambar 9. Contoh Hasil Prediksi

Hasil akhir dari pengujian ini adalah sistem yang dapat digunakan pada smartphone Android untuk menerjemahkan gerakan tangan dalam bahasa isyarat BISINDO menjadi huruf-huruf alfabet.

5. KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan bahwa model transfer learning EfficientNet sukses diintegrasikan ke dalam aplikasi Android untuk mendeteksi Bahasa Isyarat Indonesia, mencapai akurasi tertinggi 99,24% pada epoch 20 dengan konsistensi yang baik pada data pelatihan dan validasi. Implementasi pada aplikasi Android juga berhasil, memberikan pengalaman pengguna yang responsif dan efisien, serta menegaskan potensi teknologi AI untuk meningkatkan aksesibilitas bagi penyandang tunarungu. Untuk pengembangan lebih lanjut, disarankan melakukan fine-tuning lebih lanjut pada konfigurasi model untuk meminimalkan potensi overfitting, menerapkan teknik pengenalan gestur yang lebih canggih seperti penggunaan multiple view angle, menggali potensi integrasi dengan sistem komunikasi lainnya, mengembangkan aplikasi menjadi multi-platform, dan memperbanyak dataset untuk menghasilkan model yang lebih baik. Dengan mengikuti saran-saran ini, diharapkan penelitian selanjutnya dapat meningkatkan efektivitas dan efisiensi dalam pengenalan bahasa isyarat BISINDO.

DAFTAR PUSTAKA

- [1] A. R. Riantono, B. Wahyu, and R. Purbaningtyas, "KLASIFIKASI TUMOR OTAK MENGGUNAKAN CONVOLUTIONAL

NEURAL NETWORK DENGAN ARSITEKTUR EFFICIENTNET-B3," Just IT, vol. 11, no. 3, 2021. [Online]. Available: <https://jurnal.umj.ac.id/index.php/just-it/index>.

- [2] K. Dan et al., "PENGEMBANGAN MEDIA TUTORIAL BAHASA ISYARAT UNTUK SISWA TUNARUNGU SLB BC KEPANJEN," JINOTEP, vol. 6, no. 1, 2019. [Online]. Available: <http://journal2.um.ac.id/index.php/jinotep/index>.
- [3] H. M. Putri, F. Fadlisya, and W. Fuadi, "Pendeteksian bahasa isyarat Indonesia secara real-time menggunakan long short-term memory (LSTM)," *Jurnal Teknologi Terapan dan Sains* 4.0, vol. 3, no. 1, 2023, doi: 10.29103/tts.v3i1.6853.
- [4] N. A. Muhammad Amin and F. Pribadi, "Urgensi Bahasa Isyarat dalam Pendidikan Formal sebagai Media Komunikasi dan Transmisi Informasi Penyandang Disabilitas Rungu dan Wicara," *Jurnal Sosialisasi: Jurnal Hasil Pemikiran, Penelitian, dan Pengembangan Keilmuan Sosiologi Pendidikan*, vol. 9, no. 1, pp. xx-xx, Mar. 2022.
- [5] S. Patil, Y. Shah, P. Narkhede, A. Thakare, and R. Pitale, "Gesture Detection using Tensorflow lite EfficientNet Model for Communication and E-learning Module for Mute and Deaf," 2021.
- [6] A. W. Agata, W. S. J. Saputra, and C. A. Putra, "Pengenalan Bahasa Isyarat Indonesia (BISINDO) Menggunakan Algoritma Scale Invariant Feature Transform (SIFT) dan Convolutional Neural Network (CNN)," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, Feb. 2024.
- [7] R. A. Mursita, "Respon Tunarungu Terhadap Penggunaan Sistem Bahasa Isyarat Indonesia (SIBI) dan Bahasa Isyarat Indonesia (BISINDO) dalam Komunikasi," Pascasarjana, M., Tunarungu, R., UPI Bandung, P., 2015.
- [8] Raghu, M., Zhang, T., Kleinberg, J., & Bengio, S. (2019). "Transfusion: Understanding Transfer Learning for Medical Imaging." In *Advances in Neural Information Processing Systems* 32 (NeurIPS 2019), Vancouver, Canada, 3347-3357.
- [9] K. Weiss, T. M. Khoshgoftaar, and D. Wang, "A Survey of Transfer Learning," *Journal of Big Data*, vol. 3, no. 1, 2016.
- [10] Kornblith, S., Shlens, J., & Le, Q. V. (2019). "Do Better ImageNet Models Transfer Better?" In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2019)*, Long Beach, CA, USA, 2661-2671.
- [11] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," in *Proc. of the 36th Int. Conf. on Machine Learning (ICML)*, 2019.