

BAB I

PENDAHULUAN

A. Latar Belakang

Pada era modern, teknologi informasi telah mengalami kemajuan yang signifikan. Salah satu manifestasi paling penting dari kemajuan ini adalah pengembangan kecerdasan buatan (*Artificial Intelligence/AI*). Menurut Copeland, kecerdasan buatan dapat didefinisikan sebagai kemampuan komputer digital atau robot yang dikendalikan komputer untuk melaksanakan tugas-tugas yang umumnya diasosiasikan dengan kecerdasan pada makhluk hidup [1]. Kemampuan belajar dari data merupakan inti dari sistem AI modern, khususnya pada sub-bidang *machine learning* dan *deep learning*, yang memungkinkan mesin untuk mengenali pola, membuat prediksi, dan melakukan klasifikasi secara otonom.

Secara konvensional, paradigma pelatihan model AI dilakukan secara terpusat (*centralized training*), di mana seluruh dataset dari berbagai sumber harus dikumpulkan ke dalam satu server pusat untuk diproses [2]. Meskipun metode ini telah menjadi standar industri, pengumpulan data mentah dalam jumlah masif di satu lokasi sentral sangat rawan terhadap risiko pelanggaran privasi dan potensi kebocoran data sensitif (*privacy leakage*) akibat kerentanan paparan data di lingkungan server atau komputasi awan (*cloud*) [2]. Selain risiko keamanan tersebut, pendekatan terpusat memiliki keterbatasan mendasar dalam menghasilkan model yang mampu beradaptasi dengan kondisi dunia nyata yang dinamis. Data yang dikumpulkan di server pusat seringkali bersifat homogen dan tidak sepenuhnya merepresentasikan variasi karakteristik data yang tersebar di perangkat pengguna (*edge devices*) [2]. Dalam konteks visi komputer, perbedaan kondisi lingkungan pengambilan gambar, pencahayaan, dan latar belakang pada setiap perangkat pengguna menciptakan distribusi data yang bersifat *non-Independent and Identically Distributed* (non-IID) dan dapat mempengaruhi performa model [3]. Ketidakmampuan server pusat untuk mengakses keberagaman data ini secara langsung membatasi kemampuan model global untuk melakukan generalisasi dengan baik. Akibatnya, model mungkin memiliki performa tinggi pada data

validasi terpusat, namun mengalami penurunan akurasi yang signifikan saat diuji pada perangkat pengguna dengan karakteristik data yang berbeda. Oleh karena itu, diperlukan pendekatan yang memungkinkan model untuk belajar dari distribusi data yang heterogen secara kolaboratif guna meningkatkan ketangguhan (*robustness*) dan akurasi model global tanpa harus memindahkan data mentah secara fisik.

Sebagai jawaban atas tantangan homogenitas data dan keterbatasan generalisasi tersebut, paradigma *Federated Learning* (FL) muncul sebagai pendekatan pembelajaran mesin terdistribusi yang inovatif. FL membalik arsitektur pelatihan konvensional dengan mengusung prinsip “model mendatangi data”. Dalam skema ini, proses pelatihan dilakukan secara lokal di masing-masing perangkat pengguna (*edge devices*) menggunakan distribusi data nyata yang mereka miliki [4]. Alih-alih memindahkan data mentah ke server pusat, perangkat hanya mengirimkan pembaruan bobot (parameter) model hasil pelatihan lokal untuk diagregasi. Pendekatan ini memungkinkan model global untuk mengakumulasi pengetahuan dari berbagai kondisi lingkungan secara kolaboratif, sehingga secara efektif meningkatkan kemampuan adaptasi model di dunia nyata ([4], [5]). Melalui teknik agregasi seperti *Federated Averaging* (FedAvg), FL mengkonsolidasikan pembaruan parameter lokal dari berbagai perangkat klien untuk memperbarui model global secara kolaboratif, di mana privasi pengguna tetap terjaga karena sistem hanya mengagregasi parameter model alih-alih memindahkan data mentah ([6], [7]).

Akan tetapi, penerapan *local training* pada perangkat *mobile* menghadirkan tantangan teknis baru. Perangkat seperti ponsel pintar memiliki keterbatasan sumber daya mencakup daya komputasi (CPU/GPU), memori (RAM), dan masa pakai baterai [8]. Tantangan ini diperumit oleh karakteristik perangkat keras *mobile* yang heterogen. Penelitian yang dilakukan oleh Singapuram *et al* pada tahun 2022 menunjukkan bahwa, mendistribusikan pelatihan ke banyak *core* CPU tidak selalu menghasilkan waktu pelatihan yang paling cepat akibat karakteristik arsitektur *chip smartphone* dan arsitektur model komputasinya. Pada model tertentu seperti Resnet34, penggunaan 4 *core* berkinerja tinggi (*low-latency*) secara bersamaan

memang menjadi konfigurasi tercepat [9]. Namun sebaliknya, pada model dengan operasi yang padat memori seperti ShuffleNet, penggunaan 1 *core* justru menjadi pilihan paling optimal untuk mencapai latensi terendah karena penggunaan banyak *thread* akan memicu rebutan *cache* (*cache-thrashing*) yang menurunkan performa [9]. Terlepas dari konfigurasi *core* yang digunakan, proses pelatihan model *deep learning* di perangkat seluler tetaplah sangat intensif komputasi, yang dapat memicu perebutan sumber daya (*resource contention*) dan secara signifikan menurunkan performa aplikasi lain yang sedang digunakan oleh pengguna [9]. Jika model terlalu besar atau kompleks, hal ini dapat menurunkan kinerja perangkat, menguras daya baterai secara berlebihan, dan merusak pengalaman pengguna.

Oleh karena itu, efisiensi komputasi menjadi faktor penentu keberhasilan implementasi *federated learning* di lingkungan mobile. Arsitektur EfficientNet, yang diperkenalkan oleh Tan dan Le, dirancang secara eksplisit untuk memaksimalkan akurasi model dengan meminimalkan biaya komputasi [10]. Varian dasarnya, EfficientNet-B0, menawarkan keseimbangan sangat baik antara performa klasifikasi tinggi dan jumlah parameter ringan, menjadikannya kandidat ideal untuk perangkat dengan sumber daya terbatas ([11], [12]). EfficientNet-B0 menggunakan metode *compound scaling* yang mengoptimalkan kedalaman, lebar, dan resolusi jaringan secara serempak sehingga mencapai efisiensi komputasi tinggi tanpa pengorbanan akurasi yang berarti ([10], [11]).

Untuk mengevaluasi efektivitas kerangka kerja ini dalam konteks dunia nyata, penelitian ini akan menggunakan studi kasus klasifikasi citra sampah. Pengelolaan sampah merupakan masalah lingkungan global yang sangat relevan dan mendesak. Menurut laporan *Global Waste Management Outlook 2024* dari Program Lingkungan PBB (UNEP), produksi sampah padat perkotaan global saat ini telah mencapai 2,1 miliar ton per tahun. Angka ini diproyeksikan akan melonjak drastis menjadi 3,8 miliar ton pada tahun 2050 jika skenario bisnis seperti biasa terus berlanjut [13]. Skala tantangan yang masif ini menuntut solusi inovatif, sehingga aplikasi AI diharapkan dapat memberikan kontribusi positif yang signifikan. Penggunaan dataset klasifikasi sampah untuk mengevaluasi kerangka kerja ini memungkinkan analisis kinerja model dalam tugas *computer vision* yang

praktis dan representatif. Penelitian yang dilakukan oleh Kurniawan *et al.* dan Malik *et al.* menunjukkan bahwa model *deep learning* berbasis CNN, seperti EfficientNet-B0, mampu mencapai metrik akurasi yang tinggi dalam klasifikasi berbagai dataset citra sampah seperti TrashNet. Penggunaan model yang efisien ini terbukti sangat potensial untuk mendukung implementasi aplikasi pengelolaan sampah pintar secara otomatis di masa depan. ([14]–[15]).

Meskipun *Federated Learning* (FL) menawarkan solusi privasi serta kemampuannya dalam menangani homogenitas data dan EfficientNet-B0 menjanjikan efisiensi, analisis kuantitatif mengenai kinerja dan karakteristik kombinasi keduanya dalam skenario *local training* di perangkat *mobile* masih perlu dieksplorasi lebih dalam. Berdasarkan hal tersebut, penelitian ini bertujuan untuk menganalisis kinerja proses *local training* dalam sistem *federated learning* pada perangkat *mobile* dengan mengimplementasikan arsitektur EfficientNet-B0. Analisis akan difokuskan pada metrik kinerja kunci yang merefleksikan kemampuan belajar model, yaitu tingkat akurasi (*accuracy*), tingkat kesalahan (*error rate*), presisi (*precision*), recall (*recall*), dan *F1-score* pada studi kasus klasifikasi sampah. Hasil dari penelitian ini diharapkan dapat memberikan wawasan empiris yang berharga mengenai efektivitas pembelajaran model dalam arsitektur AI terdistribusi, sekaligus menunjukkan kelayakan implementasi solusi yang efisien, aman, dan akurat.

B. Rumusan Masalah

Berdasarkan permasalahan yang telah disebutkan pada latar belakang yang telah dijelaskan sebelumnya, maka rumusan masalah pada penelitian ini adalah Bagaimana performa proses *local training* dengan pendekatan *federated learning* pada perangkat *mobile* dapat meningkatkan akurasi dan performa model global dalam konteks klasifikasi sampah menggunakan model EfficientNet-B0 ?

C. Batasan Masalah

Agar penelitian lebih terfokus sesuai dengan apa yang ingin dicapai, maka perlu ditetapkan batasan masalah pada penelitian ini yang mana batasan masalah bertujuan untuk membatasi bidang dan cakupan penelitian yang akan diteliti.

Berikut beberapa batasan masalah pada penelitian ini:

1. Jenis sampah yang diklasifikasi pada penelitian ini adalah jenis sampah anorganik dengan total 6 jenis label sampah yaitu plastik, kaca, logam, kertas, kardus, serta sampah (label untuk sampah umum selain 5 label yang telah dijabarkan) dengan skema distribusi antarklien yang diuji sebatas seimbang dan cukup bervariasi (tidak mencakup kondisi keacakan ekstrem/*Highly Non-IID*).
2. Penelitian akan dilakukan pada lingkungan simulasi *federated learning* menggunakan perangkat komputasi standar dengan spesifikasi minimum Android versi 10, dengan 4 jumlah *core* prosesor, dan RAM 6 GB serta tidak melibatkan pengujian langsung pada berbagai jenis sistem operasi lainnya.
3. Penelitian ini akan menggunakan strategi agregasi *Federated Averaging* (FedAvg) standar dan akan membatasi pada 5 jumlah ronde simulasi.
4. Penelitian ini mensimulasikan distribusi label pada skenario variasi untuk setiap klien dengan mendistribusikan dataset menggunakan distribusi Dirichlet, di mana tingkat ketimpangan kelas (*label skew*) diatur melalui parameter konsentrasi (α).
5. Penelitian ini tidak menerapkan metode *dynamic client sampling*, sehingga proses agregasi global mengharuskan seluruh klien untuk mengunggah pembaruan bobot model mereka.
6. Metrik kinerja yang akan dianalisis berfokus pada akurasi (*accuracy*), nilai kerugian (*loss*), presisi (*precision*), *recall* dan *F1-score* dan tidak mencakup metrik lain seperti latensi komunikasi atau konsumsi daya perangkat.

D. Tujuan Penelitian

Dilakukannya penelitian ini bertujuan untuk menganalisis kemampuan *local training* menggunakan model EfficientNet-B0 dengan pendekatan *federated learning* pada perangkat *mobile* dalam meningkatkan akurasi model global dalam studi kasus klasifikasi jenis sampah anorganik.

E. Manfaat Penelitian

Mengenai manfaat penelitian yang menjadi nilai dalam penelitian yang dilakukan ini baik untuk peneliti, dan pembaca baik itu dalam segi teoritis maupun praktis, berikut kajian manfaat penelitian yang dihasilkan dari penelitian ini:

1. Manfaat Teoritis

- a. Pengembangan Ilmu Pengetahuan: Memberikan kontribusi pada pengembangan ilmu pengetahuan di bidang Kecerdasan Buatan, khususnya *federated learning* dan *deep learning* (EfficientNet-B0), dalam konteks implementasi pada perangkat *mobile* dengan keterbatasan sumber daya.
- b. Wawasan Implementasi *federated learning*: Menambah wawasan literatur bagi peneliti dan pembaca mengenai efektivitas dan tantangan *local training* dalam sistem *federated learning* untuk tugas klasifikasi citra pada perangkat *mobile*.
- c. Kajian Efisiensi Model: Memperkaya kajian ilmu terkait optimalisasi arsitektur model ringan seperti EfficientNet-B0 dalam lingkungan komputasi terdistribusi untuk mencapai keseimbangan antara akurasi dan efisiensi sumber daya.

2. Manfaat Praktis

- a. Solusi Pengelolaan Sampah: Memberikan dasar empiris dan wawasan teknis bagi pengembangan aplikasi *mobile* cerdas untuk klasifikasi sampah yang efisien, akurat, dan menjaga privasi pengguna, sehingga mendukung upaya pengelolaan lingkungan yang lebih baik.
- b. Panduan Implementasi *federated learning* di *Mobile*: Menyediakan referensi praktis bagi pengembang atau peneliti yang ingin mengimplementasikan *federated learning* dengan model *deep learning* pada perangkat *mobile*, terutama dalam menghadapi tantangan sumber daya.
- c. Peningkatan Akurasi Model Global: Menunjukkan potensi pelatihan lokal dalam *federated learning* untuk secara signifikan meningkatkan akurasi model global tanpa mengkompromikan privasi data pengguna.

Tabel 1. Keaslian Penelitian

Indikator	Penelitian Sebelumnya			Penelitian yang Diusulkan		
Judul	<i>Deep Learning-Based Waste Classification with Transfer Learning Using EfficientNet-B0 Model</i>	<i>FedADC: Federated Average Knowledge Distilled Mutual Conditional Learning for Waste Classification</i>		Analisis Performa <i>Local Training</i> pada Sistem Klasifikasi Sampah Berbasis <i>Federated Learning</i> Menggunakan Model <i>Pre-Trained EfficientNet-B0</i>		
Tahun	2024	2024		2026		
Metode	<i>Centralized Learning (Transfer Learning)</i> , EfficientNet-B0.	<i>Federated Learning (FedADC)</i> , DenseNet201.		<i>Federated Learning</i> , EfficientNet-B0.		
Bagian yang Diidentifikasi	Efektivitas penggunaan model EfficientNet-B0 dengan teknik <i>Transfer Learning</i> .	Mengidentifikasi algoritma FedADC untuk mengatasi masalah heterogenitas data dan privasi.		Performa <i>Local Training</i> dalam lingkungan <i>federated learning</i> dengan algoritma agregasi FedAvg.		
Hasil	Mencapai akurasi 91.94% menggunakan EfficientNet-B0 dengan pendekatan <i>transfer learning</i> terpusat.	Mengusulkan algoritma (FedADC) yang menggabungkan <i>Knowledge Distillation</i> untuk menangani heterogenitas data pada klasifikasi sampah. Akurasi mencapai 85.56%.		Hasil penelitian ini direncanakan akan mengukur performa <i>local training</i> pada metode <i>federated learning</i> dalam meningkatkan akurasi model global.		