

BAB I

PENDAHULUAN

A. Latar Belakang

Peningkatan volume sampah padat perkotaan (*municipal solid waste/MSW*) kini menjadi salah satu isu lingkungan paling signifikan yang menuntut penanganan serius. Urbanisasi pesat di negara berkembang, khususnya Asia dan Afrika, telah memperburuk timbunan sampah, sementara keterbatasan lahan, finansial, dan perilaku masyarakat yang belum terorganisir membuat kebijakan pengelolaan sulit berjalan efektif [1]. Pada praktiknya, pemilahan sampah masih banyak dilakukan secara manual, suatu pendekatan yang tidak hanya memakan waktu dan rentan menimbulkan ketidakkonsistenan, tetapi juga meningkatkan risiko kesehatan bagi pekerja. Sejalan dengan itu, tren penelitian global menunjukkan peningkatan publikasi sekitar 10% per tahun sejak 1990, dengan fokus pada daur ulang, konversi termokimia, konversi biokimia, serta perspektif keberlanjutan dan ekonomi sirkular [2]. Dengan demikian, integrasi antara pemahaman lokal dan tren global menegaskan bahwa strategi pengelolaan sampah tidak cukup hanya berfokus pada daur ulang, melainkan harus mengedepankan pemilahan sejak sumber, optimalisasi praktik *landfill*, penerapan perlakuan termal, serta pemanfaatan nilai ekonomis sampah dalam kerangka ekonomi sirkular, yang pada akhirnya menuntut dukungan solusi berbasis teknologi untuk meningkatkan efektivitas dan keberlanjutan.

Kemajuan teknologi Kecerdasan Buatan (*Artificial Intelligence/AI*), khususnya dalam bidang *Computer Vision* (CV) yang ditopang oleh teknik *Deep Learning* (DL), telah membuka peluang besar untuk mengotomatisasi proses pemilahan sampah. *Convolutional Neural Networks* (CNN) terbukti efektif dalam tugas klasifikasi citra, dengan beberapa penelitian menunjukkan akurasi yang sangat tinggi, misalnya mencapai 98,92% pada dataset *Kaggle* [3] dan 93,28% pada dataset dua kelas dengan lebih dari 25 ribu citra [4]. Fakta ini menegaskan bahwa CNN mampu memberikan hasil yang konsisten dan efisien dalam konteks pengelolaan sampah. Di antara berbagai arsitektur CNN yang tersedia, ResNet-18 menonjol karena kemampuannya menjaga keseimbangan antara akurasi yang baik 88,66% dan kebutuhan komputasi yang relatif rendah, dibandingkan dengan

ResNet-50 yang mencapai akurasi sedikit lebih tinggi 89,70% namun dengan beban komputasi lebih besar [4]. Hal ini menjadikan ResNet-18 relevan untuk implementasi pada sistem berskala operasional yang menuntut efisiensi sekaligus keandalan.

Namun demikian, penerapan model *Deep Learning* (DL) secara konvensional umumnya mengandalkan pendekatan terpusat (*Centralized Learning*), di mana seluruh data pelatihan, misalnya citra sampah dari berbagai sumber seperti TPS maupun kendaraan pengangkut, harus dikumpulkan dan diproses pada satu server pusat. Pola ini menimbulkan dua isu utama. Pertama, potensi pelanggaran privasi dan eksposur data sensitif karena data dari berbagai lokasi harus dipindahkan ke pusat, suatu risiko yang telah banyak disoroti dalam literatur mengenai perlindungan data pada sistem *machine learning* modern [5]. Kedua, tingginya kebutuhan komunikasi dan *bandwidth* terutama ketika data yang dikirim berupa citra berukuran besar dalam jumlah signifikan, yang dapat menyebabkan *overhead* komunikasi, penurunan akurasi model, serta biaya komputasi tinggi. Lebih jauh lagi, pendekatan terpusat sering gagal merepresentasikan heterogenitas data yang muncul akibat perbedaan kondisi lingkungan, pencahayaan, maupun latar belakang pada setiap perangkat pengguna, sehingga distribusi data bersifat *non-Independent and Identically Distributed* (non-IID). Hal ini membatasi kemampuan model global untuk melakukan generalisasi secara optimal di dunia nyata.

Federated Learning (FL) dikembangkan sebagai paradigma alternatif untuk mengatasi permasalahan privasi, beban komunikasi, sekaligus keterbatasan generalisasi akibat heterogenitas data. FL memungkinkan proses pelatihan model berlangsung secara terdistribusi pada perangkat lokal, di mana setiap klien melatih model menggunakan data yang tersimpan di perangkatnya, lalu hanya mengirimkan pembaruan parameter ke server pusat untuk kemudian diagregasikan menjadi model global yang lebih representatif. Dengan cara ini, data mentah tidak perlu dipindahkan sehingga aspek kerahasiaan dan privasi dapat terjaga [6]. Selain itu, FL juga menawarkan efisiensi dan skalabilitas, meskipun implementasinya menghadapi tantangan berupa heterogenitas data dan perangkat, keterbatasan komunikasi, serta ancaman keamanan. Berbagai penelitian mutakhir menekankan

pentingnya arsitektur kolaboratif *cloud-edge-end* dan kerangka kerja ringan untuk perangkat dengan sumber daya terbatas, guna memastikan FL tetap dapat diterapkan secara praktis dan mendukung prinsip *trustworthy* AI seperti ketahanan, keadilan, dan keterjelasan [7].

Walaupun *Federated Learning* (FL) menawarkan keunggulan dari sisi privasi dan efisiensi data, keberhasilannya sangat bergantung pada mekanisme pelatihan di tiap klien atau *local training*. Faktor-faktor seperti jumlah *epoch* lokal yang dijalankan sebelum pengiriman pembaruan ke server serta ukuran *batch* yang digunakan berperan penting dalam menentukan kualitas parameter yang dihasilkan. Pengaturan yang kurang tepat dapat memperlambat konvergensi model global, menimbulkan inefisiensi pemanfaatan sumber daya komputasi di klien, dan bahkan menurunkan performa model [8]. Tantangan ini semakin kompleks karena adanya keterbatasan komunikasi, serta ancaman keamanan yang telah diidentifikasi dalam tinjauan sistematis mengenai serangan dan langkah penanggulangan di FL [9]. Selain itu, penelitian terbaru juga menekankan pentingnya penerapan teknologi peningkatan privasi seperti *differential privacy*, *homomorphic encryption*, dan *secure multiparty computation* untuk menjaga keseimbangan antara privasi, efisiensi komunikasi, dan biaya komputasi [10]. Oleh karena itu, strategi optimisasi *local training* yang adaptif dan terintegrasi dengan mekanisme perlindungan privasi menjadi krusial agar FL dapat mencapai akurasi tinggi sekaligus tetap aman dan efisien.

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. Tantangan ini diperumit oleh karakteristik perangkat keras *mobile* yang heterogen. Penelitian menunjukkan bahwa penggunaan lebih banyak core CPU tidak selalu memberikan peningkatan performa. faktanya, mendistribusikan pelatihan ke seluruh 8 core CPU sering kali menghasilkan waktu pelatihan tertinggi karena arsitektur CPU *mobile* yang asimetris dan strategi pembagian beban kerja yang belum sempurna pada pustaka pelatihan. Dalam banyak kasus, penggunaan 4 core CPU justru menjadi konfigurasi paling optimal untuk mencapai latensi terendah [11]. Namun proses

pelatihan model *Deep Learning* sangat intensif komputasi, dengan latensi yang bisa mencapai 17,8 kali lebih lama dibandingkan tahap inferensi [11]. Jika model terlalu besar atau kompleks, hal ini dapat menurunkan kinerja perangkat, menguras daya baterai secara berlebihan, dan merusak pengalaman pengguna.

Berdasarkan penelitian terdahulu dan uraian di atas, penelitian ini berfokus pada analisis kinerja proses *local training* dalam sistem *Federated Learning* dengan mengimplementasikan *pre-trained* model berarsitektur ResNet-18. Fokus utama penelitian bukan pada peningkatan akurasi klasifikasi jenis sampah, melainkan pada analisis *local training* untuk menemukan faktor-faktor yang memengaruhi performa model global hasil agregasi. Analisis dilakukan terhadap metrik kinerja utama yang merefleksikan kemampuan belajar dan efisiensi model, meliputi akurasi, *error rate*, presisi, *recall*, F1-Score, dan *loss*. Hasil penelitian diharapkan memberikan wawasan empiris mengenai efektivitas proses pembelajaran terdistribusi serta kelayakan penerapan *Federated Learning* untuk sistem klasifikasi sampah yang efisien, aman, dan akurat.

B. Perumusan Masalah

Berdasarkan permasalahan pada latar belakang yang telah dijelaskan sebelumnya, maka rumusan masalah pada penelitian ini adalah Bagaimana pengaruh *Local Training* pada sistem *Federated Learning* terhadap performa model global dalam klasifikasi jenis sampah menggunakan model ResNet-18?

C. Batasan Penelitian

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 diklasifikasikan pada penelitian ini adalah jenis sampah anorganik dengan total 6 jenis label yaitu plastik, kaca, logam, kertas, kardus dan sampah (label sampah umum selain 5 label yang telah dijabarkan).
2. Penelitian akan dilakukan pada lingkungan simulasi *Federated Learning* menggunakan perangkat komputasi standar dengan spesifikasi minimum

Android versi 12, dengan 8 jumlah *core* prosesor, dan RAM 8 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 heterogenitas data (*Non-IID*) pada setiap klien dengan mendistribusikan dataset menggunakan Distribusi Dirichlet.
5. Metrik kinerja yang akan dianalisis berfokus pada akurasi, *error rate*, presisi, *recall*, *F1-score* dan *loss*, tidak mencakup metrik lain seperti penggunaan CPU, RAM dan sebagainya.

D. Tujuan Penelitian

Penelitian ini bertujuan untuk menganalisis pengaruh *Local Training* pada sistem *Federated Learning* terhadap performa model global untuk klasifikasi jenis sampah menggunakan model ResNet-18.

E. Manfaat Penelitian

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

1. Manfaat untuk Peneliti
 - a. Memberikan pemahaman mengenai pengaruh *local training* terhadap kinerja, dan stabilitas konvergensi model global.
 - b. Menjadi referensi tambahan bagi penelitian di bidang *computer vision* dan *deep learning*.
2. Manfaat untuk Masyarakat
 - a. Menjamin keamanan privasi masyarakat, karena foto atau data pribadi pengguna tidak perlu diunggah ke internet, melainkan diproses langsung dengan aman di dalam ponsel masing-masing.
 - b. Menyediakan aplikasi ponsel yang praktis bagi warga untuk mengenali jenis sampah secara otomatis, sehingga mendorong masyarakat untuk lebih peduli dan berpartisipasi dalam menjaga kebersihan lingkungan.

Tabel 1. Keaslian Penelitian

Indikator	Penelitian Terdahulu	Penelitian Sebelumnya	Penelitian yang diusulkan
Judul	Perbandingan Klasifikasi Jenis Sampah Menggunakan <i>Convolutional Neural Network</i> Dengan Arsitektur ResNet18 dan ResNet50	<i>FedADC: Federated Average Knowledge Distilled Mutual Conditional Learning for Waste Classification</i>	Analisis Kinerja <i>Local Training</i> pada Sistem <i>Federated Learning</i> untuk Klasifikasi Jenis Sampah dengan Arsitektur ResNet-18
Tahun	2024 [12]	2024 [13]	2026
Metode	<i>Centralized Learning</i> , ResNet-18 dan ResNet-50	<i>Federated Learning</i> (FedADC), DenseNet201	<i>Federated Learning</i> , ResNet-18
Bagian yang diidentifikasi	Perbandingan performa arsitektur ResNet dalam klasifikasi sampah dengan pendekatan terpusat.	Mengidentifikasi algoritma untuk mengatasi masalah heterogenitas data dan privasi.	Performa <i>Local Training</i> dalam lingkungan <i>Federated Learning</i> dengan algoritma agregasi FedAvg.
Hasil	ResNet18 lebih cepat dan stabil (akurasi 98,69%), sedangkan ResNet50 lebih akurat (99,41%) namun membutuhkan waktu pelatihan lebih lama.	Mengusulkan algoritma 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 perangkat mobile dalam meningkatkan akurasi model global dengan <i>Federated Learning</i> .