

BAB I

PENDAHULUAN

Bab pendahuluan ini membahas mengenai latar belakang masalah, rumusan masalah, tujuan dan manfaat, ruang lingkup, serta sistematika penulisan yang akan digunakan dalam dokumen skripsi ini.

1.1 Latar Belakang

Dalam beberapa tahun terakhir, kemampuan *deep learning* mampu menyamai performa manusia di berbagai bidang (Silver dkk., 2016). Dalam mencapai performa tersebut, model *deep learning* umumnya dilatih dengan pada lingkungan *Closed World Classification* dengan *fixed dataset* dalam pengulangan tertentu yang disebut *epoch*. *Closed World Classification* merujuk pada proses pelatihan model yang membatasi pemahaman model hanya pada kelas-kelas yang tersedia dalam dataset pelatihan. Konsekuensi dari pendekatan ini adalah model tidak memiliki kemampuan untuk mengenali kelas di luar data pelatihan, sehingga apabila dihadapkan pada input dari kelas yang tidak diketahui, model akan mengasosiasikannya dengan kelas yang telah dipelajari walaupun hal tersebut merupakan misklasifikasi. Walaupun begitu, kelemahan pelatihan diatas tidak sesuai dengan skenario pembelajaran pada dunia nyata yang mana pengetahuan akan terus bertumbuh secara inkremental.

Pembelajaran inkremental merupakan pendekatan pembelajaran dengan tujuan menambah pengetahuan baru secara bertahap sembari mempertahankan pengetahuan yang telah dipelajari oleh model baik dalam konteks penambahan kelas baru untuk klasifikasi, adaptasi terhadap domain pengetahuan, maupun penyesuaian terhadap beberapa tugas (Delange dkk., 2021; Grossberg, 2012; van de Ven dkk., 2022). Metode ini memanfaatkan pelatihan yang kontinu, dimana setiap tahap pembelajaran didasarkan pada data baru tanpa harus mengulang pelatihan dengan keseluruhan data yang pernah diproses sebelumnya. Karakteristik data yang umumnya hadir dalam bentuk *stream*, mendukung kebutuhan akan pendekatan ini dikarenakan penyimpanan data terdahulu secara menyeluruh untuk keperluan pembelajaran ulang menggunakan *Closed World Classification* tidak selalu dapat diimplementasikan karena adanya keterbatasan kapasitas penyimpanan serta berbagai pertimbangan terkait privasi data (Gomes dkk., 2017; Kreml dkk., 2014). Berdasarkan

faktor-faktor tersebut, diperlukan suatu paradigma pembelajaran yang dapat mengatasi tantangan tersebut, yang kemudian menjadi dasar pengembangan *Class Incremental Learning* (CIL).

Class Incremental Learning (CIL) merupakan skema pelatihan inkremental yang memungkinkan model untuk mengintegrasikan pengetahuan tentang kelas-kelas baru tanpa mengorbankan kemampuan identifikasi terhadap kelas-kelas yang telah dipelajari sebelumnya. Pendekatan ini menawarkan solusi terhadap keterbatasan metode pembelajaran konvensional yang mengharuskan pembelajaran ulang menggunakan seluruh dataset ketika terdapat penambahan kelas baru, suatu proses yang menimbulkan inefisiensi komputasional yang signifikan dan beban sumber daya komputasi yang besar. CIL memfasilitasi adaptasi model terhadap informasi baru dengan mempertahankan representasi pengetahuan yang telah diperoleh sehingga memungkinkan pengembangan sistem pembelajaran yang lebih berkelanjutan dan skalabel dalam lingkungan data yang dinamis dan terus berkembang.

Penambahan kelas dengan skema CIL tidak sebatas menambah jumlah pelatihan dengan data baru. Pada contoh kasus sistem pengenalan wajah, model harus mampu menambahkan wajah baru tanpa melupakan wajah lama dengan waktu pelatihan yang terbatas. Namun, seiring bertambahnya wajah yang dikenali oleh sistem, maka kemiripan suatu wajah baru dengan wajah yang telah dipelajari menjadi tak terhindarkan. Ada kemungkinan bahwa pengetahuan akan wajah lama menjadi hilang sehingga apabila wajah lama tersebut dimasukkan, model malah mengenalinya sebagai wajah baru milik orang lain. Fenomena tersebut menunjukkan bahwa seiring bertambahnya kelas baru, pengetahuan yang telah diperoleh tentang kelas lama perlahan tergerus, yang umumnya disebut *catastrophic forgetting* (Wu dkk., 2019).

Untuk menangani *catastrophic forgetting*, beberapa strategi telah diperkenalkan seperti *Knowledge Distillation* dan penggunaan *sejumlah data dari kelas lama* yang disebut *exemplar*. *Knowledge Distillation* adalah metode untuk mempertahankan informasi dan menyalin pengetahuan model lama ke model baru dengan menyamakan pengetahuan dalam bentuk *logits* antara hasil model lama dengan model baru pada kelas-kelas yang telah dipelajari oleh model lama (Z. Li & Hoiem, 2018). Namun, pendekatan tersebut masih memiliki keterbatasan dalam menangani ketidakseimbangan prediksi antara kelas lama dengan kelas baru. Oleh sebab itu, metode diatas dapat disempurnakan melalui

penggabungan *exemplar* dengan data kelas baru dalam proses pelatihan. Penggabungan kedua metode diatas menghasilkan prediksi yang lebih seimbang terhadap kedua kelompok kelas tersebut (Rebuffi dkk., 2017).

Walaupun kedua solusi diatas telah diimplementasikan, Wu dkk. (2019) mengidentifikasi ada kecenderungan klasifikasi terhadap kelas baru di dalam *Convolutional Neural Network* yang merupakan basis dari model yang digunakan. Untuk mengatasi hal ini, sebuah *linear layer* akan ditambahkan pada akhir model untuk mengoreksi *bias* terhadap kelas baru, yang kemudian diberi nama *Bias Correction Method* (BiC). Pendekatan ini menunjukkan keefektifan untuk menangani CIL dalam jumlah besar terlebih pada dataset besar seperti ImageNet (1000 kelas) serta MS-Celeb-1M (10.000 kelas). Implementasi *linear layer* yang kemudian disebut *Bias Correction Layer* (BiC Layer) berhasil meningkatkan performa model sebesar 11,1% dan 13,2% dibandingkan algoritma iCaRL dan EEIL secara berturut-turut pada skenario inkremen 20 kelas.

Wu dkk. (2019) melaporkan peningkatan nilai akurasi yang signifikan pada dataset besar melalui implementasi BiC, tetapi tidak menjelaskan seberapa efektifkah implementasi BiC pada inkremen kelas yang terbatas. Temuan ini mengindikasikan adanya celah penelitian terkait efektifitas penggunaan CIL dengan dan tanpa BiC pada inkremen kelas dibawah angka 5. Namun, dikarenakan keterbatasan daya komputasi yang dimiliki, cakupan penelitian hanya akan menggunakan 20 kelas. Penelitian ini diarahkan untuk menjawab pertanyaan tersebut melalui evaluasi komprehensif pada skenario inkremen kelas terbatas.

Dalam konteks penerapan CIL dengan metode BiC, pemilihan arsitektur model memiliki peranan krusial untuk mencapai performa yang optimal dengan tetap memperhatikan beban komputasi. ResNet-50 diambil sebagai basis model dikarenakan memiliki hasil akurasi yang mendekati InceptionNet dan lebih unggul dibandingkan VGG, dengan jumlah parameter yang lebih kecil dibandingkan VGG maupun InceptionNet serta arsitektur yang lebih sederhana sehingga menghasilkan beban komputasi yang lebih rendah dibandingkan kedua arsitektur tersebut. Di samping itu, tingginya kebutuhan *tuning hyperparameter* serta *inference time* pada arsitektur Inception serta VGG menjadikannya kurang ideal untuk skenario pembelajaran *incremental* (Bianco dkk., 2018). Sementara itu, penelitian terdahulu mengungkapkan penggunaan ResNet-18 dalam CIL menunjukkan keterbatasan kedalaman jaringan yang berdampak negatif terhadap penanganan masalah

catastrophic forgetting, sedangkan penggunaan ResNet-101 tidak memungkinkan karena keterbatasan daya komputasi yang dimiliki (Mirzadeh dkk., 2022). Oleh karena itu, ResNet-50 dianggap sebagai pilihan yang lebih *robust* dan efisien untuk menangani tantangan dalam CIL, khususnya dengan penerapan BiC pada daya komputasi standar.

Di sisi lain, berbeda dengan penelitian Wu dkk.(2019), Z. Li & Hoiem (2018), dan Rebuffi dkk.(2017) yang mengimplementasikan dataset ImageNet-1000 dengan format citra RGB yang memiliki beragam ukuran piksel, penelitian ini menggunakan subset ImageNet-100 yang diakusisi dari *platform Kaggle*. Karakteristik dataset penelitian ini mengandung heterogenitas format warna, dimana terdapat kombinasi citra RGB dan *grayscale*. Untuk mengatasi heterogenitas tersebut, penelitian ini menerapkan protokol seleksi kelas untuk menghasilkan dataset dengan *noise rendah* dengan harapan dataset ini memiliki karakteristik yang menyerupai penelitian-penelitian sebelumnya. Protokol seleksi kelas didasarkan dua parameter yakni nilai *F1-Score* yang melebihi 0,88 pada pengujian awal dengan 5 kelas dan jumlah citra format *grayscale* maksimal 10 gambar per kelas.

Sejalan dengan permasalahan yang telah diidentifikasi, penelitian ini diarahkan untuk mengimplementasikan BiC dengan arsitektur ResNet-50 untuk memperbaiki performa klasifikasi pada dataset terbatas, khususnya dengan mengurangi dampak *catastrophic forgetting* serta mengevaluasi efektifitas penerapan BiC dengan inkremen kelas yang kecil.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, maka dapat dirumuskan masalah yang diangkat pada penelitian ini adalah bagaimana menerapkan BiC sebagai salah satu metode CIL dengan arsitektur ResNet-50 dalam klasifikasi citra banyak kelas menggunakan 20 kelas dari dataset ImageNet100 serta menguji peningkatan performa klasifikasi dari penerapan BiC dengan skenario inkremen kelas kecil.

1.3 Tujuan dan Manfaat Penelitian

Tujuan yang ingin dicapai dalam penulisan penelitian ini adalah menghasilkan model dengan arsitektur ResNet-50 dari penerapan BiC dengan *hyperparameter* yang tepat dan memberikan data efektifitas penerapan metode BiC pada skenario inkremen kelas kecil.

Manfaat yang diharapkan dari tugas akhir ini adalah adanya peningkatan performa klasifikasi dari hasil penerapan BiC pada arsitektur ResNet-50 dibandingkan tanpa penerapan BiC pada skenario inkremen kelas kecil.

1.4 Ruang Lingkup

Ruang lingkup dirumuskan dengan tujuan agar dapat memberikan target pada tugas akhir ini agar memiliki batasan dan tidak menyimpan sehingga sesuai dengan target yang diinginkan. Berikut merupakan ruang lingkup pada tugas akhir ini:

A. Pengumpulan Data:

- 1) *Base* dataset berjudul ImageNet-100 yang merupakan subset dari ImageNet-1000 yang dihasilkan oleh Russakovsky dkk. (2015)
- 2) Dataset kemudian dipilah untuk menentukan kelas-kelas dengan klasifikasi yang baik sehingga didapatkan 42 kelas dengan *noise* rendah.
- 3) 42 kelas dengan *noise* rendah tersebut dilakukan *preprocessing* sehingga menghasilkan dataset citra unik, yang akan digunakan pada penelitian ini.

B. Pengembangan dan Evaluasi Model:

- 1) Pencarian *hyperparameter* berupa *pixel size* serta *learning rate* pada ResNet-50 yang digunakan sebagai acuan parameter pengembangan *Class Incremental Model* serta pelatihan model pertama menggunakan 5 kelas pertama dari dataset ImageNet100.
- 2) Evaluasi model untuk pencarian *hyperparameter* dilakukan dengan mengukur metrik *accuracy*, *precision*, *recall*, dan *F1-score* dengan memperhatikan waktu pelatihan dan hasil terbaik.
- 3) Penerapan BiC Method pada arsitektur ResNet-50 dengan total klasifikasi 20 kelas menggunakan perbedaan inkremental kelas serta perbedaan penerapan BiC Layer pada proses pelatihan yakni, tanpa BiC Layer, BiC Layer hanya pada fase kedua pelatihan, serta penerapan BiC Layer pada fase pertama dan fase kedua pelatihan.
- 4) Perbandingan performa model pada berbagai skenario hasil kombinasi inkremental kelas serta penerapan BiC Layer dalam pelatihan yang diukur menggunakan metrik

average accuracy, precision, recall, F1-score, dan forgetting ratio.

- 5) Perbandingan performa model terhadap beberapa kelas pertama serta melihat bias terhadap kelas terakhir pada berbagai skenario hasil kombinasi inkremental kelas serta penerapan BiC Layer dalam pelatihan yang diukur menggunakan metrik *average accuracy, precision, recall, F1-score, dan forgetting ratio* terhadap kelas-kelas tersebut.

1.5 Sistematika Penulisan

Sistematika penulisan yang digunakan dalam penelitian tugas akhir ini terbagi dalam beberapa bab, yaitu:

BAB I PENDAHULUAN

Bab ini memaparkan latar belakang masalah, perumusan masalah, tujuan dan manfaat penelitian, ruang lingkup penelitian, serta sistematika penulisan. Penekanan dalam bab ini diberikan pada pentingnya penerapan BiC sebagai salah satu metode CIL menggunakan arsitektur ResNet-50 dengan pertimbangan keterbatasan daya komputasi.

BAB II TINJAUAN PUSTAKA

Bab ini berisi ulasan teoritis dan studi pustaka yang relevan dengan topik penelitian. Tinjauan ini meliputi konsep arsitektur ResNet-50, *class incremental learning*, BiC, dan penerapan BiC untuk mengoreksi bias dengan arsitektur ResNet-50.

BAB III METODOLOGI PENELITIAN

Bab ini mendeskripsikan metodologi yang digunakan dalam penelitian, termasuk desain penelitian, pengumpulan data, pengembangan model dengan penerapan BiC pada arsitektur ResNet-50, serta parameter dan konfigurasi yang diterapkan. Juga akan dibahas metode evaluasi dan kriteria yang digunakan untuk membandingkan performa model.

BAB IV HASIL DAN ANALISIS

Bab ini menyajikan hasil dari pengujian model, termasuk analisis performa berbagai parameter dan konfigurasi yang diuji. Pembahasan akan mencakup perbandingan akurasi dan keandalan model dalam mendeteksi 20 kelas pada skenario yang telah ditetapkan serta analisis pengaruh penerapan metode BiC terhadap kelas awal dan kelas akhir.

BAB V KESIMPULAN DAN SARAN

Bab ini mengemukakan kesimpulan yang dapat diambil dari penelitian, mencerminkan sejauh mana tujuan penelitian telah tercapai. Selanjutnya, akan diuraikan saran-saran untuk pengembangan lebih lanjut berdasarkan hasil penelitian dan keterbatasan- keterbatasan yang ditemui