

Pengaruh Data Preprocessing terhadap Imbalanced Dataset pada Klasifikasi Citra Sampah menggunakan Algoritma Convolutional Neural Network

Muhammad Resa Arif Yudianto, Pristi Sukmasetya, Rofi Abul Hasani, Dimas Sasongko*

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Muhammadiyah Magelang, Magelang, Indonesia

Email: ¹resamuhammad96@unimma.ac.id, ²pristi.sukmasetya@ummgl.ac.id, ³rofiabul@unimma.ac.id,

^{4,*}dimassasongko@ummgl.ac.id

Email Penulis Korespondensi: dimassasongko@ummgl.ac.id

Submitted: 23/11/2022; Accepted: 12/12/2022; Published: 30/12/2022

Abstrak—Sampah menjadi salah satu masalah terbesar negara Indonesia dengan peningkatan sampah setiap tahunnya mencapai 187,2 juta ton/tahun. Berbagai upaya untuk menekan jumlah sampah seperti Bank Sampah sudah digalakkan. Akan tetapi program ini belum berjalan dengan baik, dikarenakan sebagian masyarakat kesulitan dalam membedakan jenis sampah. Salah satu solusi untuk mengatasi hal tersebut yaitu diperlukan sistem yang dapat mengklasifikasikan jenis sampah. Pendekatan deep learning dengan algoritma CNN saat ini banyak digunakan untuk menyelesaikan permasalahan klasifikasi. Metode ini memerlukan jumlah dataset yang besar untuk meningkatkan tingkat akurasi. Sulitnya mendapatkan dataset sampah menjadi permasalahan tersendiri dalam proses training karena dataset yang tidak seimbang. Dataset yang digunakan berjumlah 2527 data yang terdiri dari 6 kelas. Beberapa perlakuan seperti *undersampling* dan augmentasi citra diterapkan untuk mengatasi *imbalanced dataset*. Perlakuan lain seperti jenis channel citra inputan serta penggunaan filter dikombinasikan menjadi 24 skenario percobaan untuk mencapai akurasi tertinggi. Hasil percobaan mendapatkan skenario terbaik yaitu dataset dilakukan proses *undersampling* kemudian diaugmentasi dengan 5 parameter transformasi geometris dengan citra inputan adalah RGB dan menerapkan sharpening filter mendapatkan nilai akurasi sebesar 0.9919 dengan 20 epoch.

Kata Kunci: Klasifikasi Sampah; Dataset tidak Seimbang; Convolutional Neural Network; Arsitektur MobileNet; Deep Learning

Abstract—Garbage is one of Indonesia's most significant problems with an increase in waste each year reaching 187.2 million tonnes/year. Various efforts to reduce the amount of waste such as Garbage Banks have been encouraged. However, this program has not run well, because some people have difficulty distinguishing the type of waste. One solution to overcome this problem is that need a system that can classify the type of waste. The deep learning approach with the CNN algorithm is currently widely used to solve classification problems. This method requires a large number of datasets to increase the level of accuracy. Getting a garbage dataset is a particular problem in the training process because the dataset is unbalanced. The dataset used amounted to 2527 data consisting of 6 classes. Several treatments such as undersampling and image augmentation are applied to overcome imbalanced datasets. Other treatments such as the type of input image channel and the use of filters are combined into 24 experimental scenarios to achieve the highest accuracy. The results of the experiment get the best scenario, namely, the dataset is undersampling and then augmented with 5 geometric transformation parameters with the input image being RGB and applying a sharpening filter to get an accuracy value of 0.9919 with 20 epochs.

Keywords: Trash Classification; Imbalanced Dataset; Convolutional Neural Network; MobileNet Architecture; Deep Learning

1. PENDAHULUAN

Sampah merupakan salah satu permasalahan terbesar yang dialami kebanyakan negara [1], tidak terkecuali Indonesia. Jumlah sampah akan selalu meningkat setiap tahunnya seiring dengan perkembangan populasi manusia. Seperti yang dilaporkan [2] saat ini peningkatan jumlah sampah di Indonesia mencapai 187,2 juta ton/tahun. Beberapa upaya penanganan sudah dilakukan melalui program Bank Sampah yang menerapkan konsep 3R (*Reduce, Reuse* dan *Recycle*) [3]. Berbagai upaya yang telah dilakukan belum berjalan dengan baik, dikarenakan beberapa masyarakat kesulitan dalam melakukan pemilahan sampah. Pemilahan jenis sampah yang tidak tepat dapat menyulitkan dalam proses penanganan lebih lanjut [4].

Pengenalan objek secara otomatis melalui kecerdasan buatan sudah semakin banyak diterapkan di berbagai sektor kehidupan. Pada bidang medis [5][6] sudah berhasil mengenali hasil CT scan dan X-Ray paru-paru yang terkena Covid-19 atau Pneumonia, serta dapat membedakan orang terkena tumor otak atau tidak. Pada sektor lain yaitu kebudayaan dan seni, pengenalan objek sudah diterapkan dalam membedakan jenis wayang punakawan melalui gambar/citra wayang [7]. Pada sektor lingkungan, pengenalan objek melalui citra digital sudah pernah dilakukan [8], akan tetapi hasilnya masih belum optimal. Hal tersebut dikarenakan jumlah data pada setiap kelas tidak seimbang.

Pengenalan citra digital dapat didekati dengan metode *machine learning* maupun *deep learning*. Hasil penelitian sebelumnya [9], menyebutkan bahwa algoritma *Convolutional Neural Network* (CNN) lebih unggul dibandingkan 2 algoritma *machine learning* lainnya dalam klasifikasi dataset sinyal emosional dengan tingkat akurasi 83,45%. CNN memiliki berbagai macam arsitektur yang membedakan kinerja dan kemampuan dalam mengenali objek. Setiap arsitektur CNN terdiri dari *convolutional layer*, *pooling layer* dan *fully connected layer*. Seluruh arsitektur CNN yang ada saat ini dibedakan dari kombinasi susunan dari setiap layer serta jumlah parameter tambahan yang mengisi di setiap layernya [10].

Setiap arsitektur CNN memiliki kinerja yang berbeda-beda sesuai dengan susunan kedalaman layer serta jumlah parameter yang akan dilatih. Penelitian sebelumnya telah melakukan perbandingan terhadap 21 arsitektur CNN

dalam mengklasifikasikan citra X-Ray untuk mendeteksi covid-19 atau bukan. Hasil yang diperoleh melalui berbagai macam scenario didapatkan 5 arsitektur terbaik yaitu DenseNet169, EfficientNetB2, InceptionResNetV2, InceptionV3 dan MobileNet [11]. Salah satu dari kelima arsitektur terbaik tersebut peneliti gunakan di dalam penelitian ini yaitu arsitektur MobileNet. Keunggulan dari arsitektur ini yaitu kebutuhan *resource* paling kecil dibandingkan arsitektur CNN lainnya. Selain itu arsitektur ini mampu memproses data gambar secara cepat dan ringan [12].

Sulitnya mendapatkan dataset sampah secara publik, menjadi sebuah tantangan baru dalam proses pengenalan citra digital. Beberapa penelitian yang terdahulu tentang klasifikasi citra sampah [8][13] menggunakan dataset yang jumlahnya tidak seimbang atau sering disebut sebagai *unbalanced dataset*. Hal tersebut karena minimnya dataset tentang jenis sampah yang dibagikan secara publik. Hasil akurasi yang diperoleh kurang maksimal, karena adanya perbedaan jumlah data antar kelas sebesar 3 kali lipat. Dampak dari jumlah dataset yang tidak seimbang mengakibatkan penurunan pada kinerja model CNN [14]. Selain penurunan tingkat keakuratan sebuah model dalam mengenali objek, dampak lain dari *imbalanced dataset* yaitu menurunnya nilai metrik evaluasi model yang lain seperti recall, presisi dan F1-score [15].

Beberapa perlakuan dapat diterapkan untuk mengatasi permasalahan pada *imbalanced dataset*. *Undersampling* yaitu teknik mengambil data kelas dengan jumlah paling minimal sebagai acuan untuk kelas yang lain. Teknik ini efektif jika perbedaan antara kelas yang dominan dengan kelas yang minoritas tidak terlalu jauh [16]. Akan tetapi jika perbedaan terlalu jauh, hal tersebut justru kurang efektif dalam mengatasi dataset yang tidak seimbang. Selain teknik *undersampling*, perlakuan lain yang dapat dilakukan yaitu dengan melakukan penggantian data atau yang dikenal dengan augmentasi data. Teknik augmentasi memiliki banyak variasi dalam proses duplikasi gambar. Teknik transformasi geometris (*rotation*, *cropping*, dan *scaling*) lebih berpengaruh signifikan dalam meningkatkan kinerja model dibandingkan transformasi fotometrik (*light*, *color*, dan *texture*) [17].

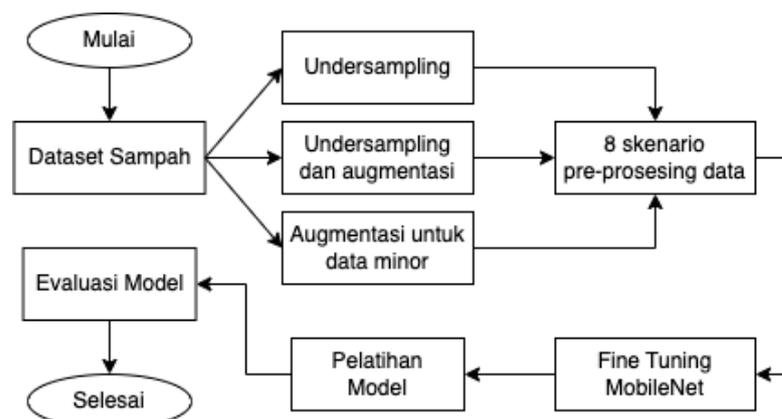
Peningkatan kinerja model dalam mengenali objek tidak hanya ditentukan dari arsitektur CNN yang digunakan. Terdapat beberapa faktor yang mempengaruhi kinerja model. Beberapa tahapan perlakuan terhadap dataset sebelum dilakukan proses pelatihan (*preprocessing*) memiliki pengaruh terhadap nilai akurasi yang dihasilkan. Salah satunya yaitu penggunaan filter (*structuring element*) yang dapat mengurangi jumlah gangguan (*noise*) pada citra, sehingga data yang akan dianalisis dapat diekstrak dengan baik [7]. Penggunaan filter dan pemilihan filter *sharpening* atau *smoothing* filter harus disesuaikan dengan kondisi dataset. Karena dampak negatif yang ditimbulkan citra menjadi tampak blur.

Selain filtering, penggunaan jenis sinyal warna sebuah citra digital juga berpengaruh terhadap nilai akurasi sebuah model [18]. Tidak semua channel warna selalu memberikan hasil yang baik atau sebaliknya akan tetapi channel warna berkaitan erat dengan jenis dataset yang digunakan. Beberapa jenis channel warna yang sering digunakan yaitu, RGB, *Red Channel*, *Green Channel*, *Blue Channel*, *Grayscale* dan *Biner*. Persebaran derajat keabuan sebuah citra digital yang tidak merata mengakibatkan proses ekstraksi fitur kurang optimal. Salah satu cara untuk melakukan proses perataan intensitas derajat keabuan yaitu menggunakan teknik histogram. Beberapa metode ekualisasi histogram dibandingkan untuk mencari metode yang optimal dalam meningkatkan kualitas citra [19]. CLAHE menjadi metode terbaik dalam meningkatkan kualitas citra digital, sehingga proses ekstraksi fitur lebih optimal.

Berdasarkan dari beberapa penelitian sebelumnya, tujuan penelitian ini yaitu untuk memperbaiki tingkat akurasi pengenalan sampah pada penelitian sebelumnya [8] yang memiliki jumlah dataset sampah yang tidak seimbang menggunakan algoritma CNN MobileNet dengan beberapa percobaan skenario kombinasi pra pengolahan dataset (*preprocessing*). Hasil dari penelitian ini diharapkan model classification yang tercipta dapat membedakan jenis sampah dengan lebih akurat.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian



Gambar 1. Tahapan Penelitian

Tahapan penelitian seperti yang ditunjukkan pada Gambar 1 dimulai dari proses pengumpulan dataset sampah yang didapatkan dari penelitian sebelumnya [8] dengan jumlah 6 kelas. Tahap berikutnya yaitu dilakukan pembagian 3 skenario utama yaitu teknik untuk mengatasi dataset yang tidak seimbang (*imbalanced dataset*).

Masing-masing hasil dari proses sebelumnya dilakukan kombinasi percobaan terhadap 8 skenario pada proses pre-prosesing data. Proses *fine tuning* diperlukan pada tahapan selanjutnya yaitu untuk mencari setelan yang sesuai dengan kondisi dataset. Setiap rangkaian kombinasi skenario dilakukan proses pelatihan (*training*) menggunakan arsitektur MobileNet yang telah dilakukan *fine tuning*. Semua hasil model yang terbentuk dilakukan proses pengujian model dan semua skenario dibandingkan untuk menentukan skenario terbaik dengan nilai akurasi tertinggi.

2.2 Dataset

Dataset yang digunakan pada penelitian ini didapatkan dari internet yang telah digunakan pada penelitian terdahulu [8]. Total dataset yang diperoleh yaitu berjumlah 2527 data citra yang terdiri dari 6 jenis sampah yaitu trash (137 data), plastic (482 data), paper (594 data), metal (410 data), glass (501 data) dan cardboard (403 data). Contoh untuk masing-masing kelas dari dataset sampah dapat dilihat pada Gambar 2. Seperti ditunjukkan pada Gambar 2, jumlah data dari setiap kelas tidak seimbang (*imbalanced dataset*). Perbedaan jumlah data terlalu besar antara kelas ‘trash’ yang hanya terdiri dari 137 citra dibandingkan dengan kelas ‘paper’ yang terdiri dari 594 citra.



Gambar 2. Contoh Dataset

2.3 Skenario Utama (*Imbalanced Dataset*)

Jumlah data yang tidak seimbang mengakibatkan penurunan kinerja klasifikasi yang signifikan dari sebuah model [20]. Dalam penelitian ini dibagi menjadi 3 skenario utama untuk mengatasi dataset yang tidak seimbang. Pembagian ketiga skenario utama dapat dilihat pada Tabel 1.

Tabel 1. Skenario Utama

No	Kode	Skenario
1	S1	Undersampling
2	S2	Undersampling dan augmentasi
3	S3	Augmentasi lebih pada dataset minor

Perlakuan terhadap dataset pada skenario pertama (S1) yaitu melakukan undersampling terhadap dataset. Semua kelas hanya akan digunakan 137 data citra saja dalam membuat model. Kemudian untuk skenario kedua (S2) yaitu selain teknik undersampling juga dilakukan proses augmentasi citra dengan 5 cara transformasi geometris (*widthShift*, *shareRange*, *horizontalFlip*, *verticalFlip* dan *rotationRange*). Teknik augmentasi tersebut dipilih karena sesuai penelitian sebelumnya [17], bahwa teknik tersebut lebih baik dibandingkan transformasi fotometrik. Hasil yang diperoleh dari skenario kedua tersebut masing-masing kelas saat ini terdiri dari 822 data citra.

Perlakuan data dengan skenario ketiga (S3) sedikit berbeda dengan skenario kedua, meskipun keduanya sama-sama menggunakan teknik augmentasi. Pada skenario ini diambil jumlah dataset urutan kedua paling sedikit yaitu 403 sebagai acuan semua kelas. Sehingga kelas ‘trash’ akan diaugmentasi hingga total datanya 403, dan untuk kelas yang lebih dari 403 akan diambil 403 saja. Setelah semua kelas berjumlah 403 data, kemudian dilakukan augmentasi lagi untuk seluruh kelas sehingga berjumlah 822 data citra.

2.4 Skenario Pra Pengolahan (*Preprocessing*)

Untuk mendapatkan hasil yang terbaik dalam penelitian ini menggunakan 8 skenario pada proses *preprocessing*. 8 skenario yang digunakan dalam penelitian ini dapat dilihat pada Tabel 2.

Tabel 2. Skenario Preprocessing

No	Kode	Skenario
1	F1	RGB + CLAHE + filter (<i>sharpening</i>)

2	F2	Green Channel + CLAHE + filter (<i>sharpening</i>)
3	F3	Grayscale + CLAHE + filter (<i>sharpening</i>)
4	F4	Biner + CLAHE + filter (<i>sharpening</i>)
5	W1	RGB + CLAHE
6	W2	Green Channel + CLAHE
7	W3	Grayscale + CLAHE
8	W4	Biner + CLAHE

Semua susunan skenario terdiri dari aspek channel warna dari citra masukan yaitu RGB, *Green Channel*, *Grayscale* dan *Biner*. *Green Channel* dipilih karena channel ini memiliki jumlah gangguan (*noise*) yang paling sedikit dibandingkan *Blue* dan *Red Channel* [21]. Semua skenario menggunakan metode CLAHE karena pada penelitian terdahulu telah terbukti bahwa metode ini mampu meningkatkan kualitas citra dan nilai akurasi model. Skenario dengan kode F merupakan skenario yang menggunakan metode filtering yaitu melakukan penajaman pada citra. Sedangkan skenario dengan kode W adalah skenario yang tidak melalui proses filtering.

2.5 Fine Tuning Arsitektur MobileNet

Arsitektur CNN yang digunakan pada penelitian ini adalah MobileNet. Arsitektur ini dipilih karena memiliki waktu pelatihan yang cenderung lebih cepat dengan *resource* yang kecil [12]. Secara default MobileNet memiliki susunan pada layer terakhir seperti ditunjukkan pada Tabel 3.

Tabel 3. Arsitektur MobileNet

Layer	Output Shape	Param
dropout (Dropout)	(None, 1, 1, 1024)	0
conv_preds (Conv2D)	(None, 1, 1, 1000)	1025000
reshape_2 (Reshape)	(None, 1000)	0
predictions (Activation)	(None, 1000)	0
Total params: 4,253,864		
Trainable params: 4,231,976		
Non-trainable params: 21,888		

Susunan layer terakhir semua arsitektur CNN sama yaitu dengan jumlah kelas pada Dense layer yaitu 1000 kelas. Sehingga ketika digunakan secara langsung terhadap dataset sampah dengan jumlah kelasnya adalah 6 tidak akan dapat menghasilkan model yang terbaik. Oleh sebab itu diperlukan perlakuan khusus yang disesuaikan dengan jumlah kelas yang ada pada dataset. Pada penelitian ini hasil fine tuning terhadap arsitektur MobileNet dapat dilihat pada Tabel 4.

Tabel 4. Arsitektur MobileNet Hasil Fine Tuning

Layer	Output Shape	Param
dropout (Dropout)	(None, 1, 1, 1024)	0
conv_preds (Conv2D)	(None, 1, 1, 1000)	1025000
reshape_2 (Reshape)	(None, 1000)	0
dropout_1 (Dropout)	(None, 1000)	0
dense_1 (Dense)	(None, 6)	6006
Total params: 4,259,870		
Trainable params: 4,237,982		
Non-trainable params: 21,888		

Proses *fine tuning* pada penelitian ini yaitu menambahkan 1 layer dropout, untuk mematikan beberapa node/neuron pada *hidden layer*. Kemudian pada layer terakhir dilakukan proses *replacement* terhadap *fully connected layer* dari 1000 kelas diganti dengan 6 kelas sesuai dengan jumlah kelas pada dataset yang digunakan.

3. HASIL DAN PEMBAHASAN

Satu rangkaian skenario dalam proses training terdiri dari skenario utama dikombinasikan dengan skenario *preprocessing*. Seluruh skenario percobaan dalam penelitian ini seperti ditunjukkan pada Tabel 5.

Tabel 5. Skenario Percobaan

No	Skenario	No	Skenario
1	S1 + F1	13	S1 + W1
2	S1 + F2	14	S1 + W2
3	S1 + F3	15	S1 + W3
4	S1 + F4	16	S1 + W4

5	S2 + F1	17	S2 + W1
6	S2 + F2	18	S2 + W2
7	S2 + F3	19	S2 + W3
8	S2 + F4	20	S2 + W4
9	S3 + F1	21	S3 + W1
10	S3 + F2	22	S3 + W2
11	S3 + F3	23	S3 + W3
12	S3 + F4	24	S3 + W4

Seluruh skenario percobaan seperti yang ditunjukkan pada Tabel 5 diberikan perlakuan yang sama pada proses *training* model yaitu menggunakan jumlah perulangan/*epoch* sebesar 20 kali dengan *learning rate* sebesar 0.001. Dari keseluruhan dataset yang digunakan baik untuk (S1, S2 maupun S3) dibagi dengan rasio 80:20, yaitu 80% dari total data akan digunakan dalam proses pelatihan (*training*) dan 20% nya digunakan dalam proses evaluasi (*testing*). Pembagian rasio ini dipilih sesuai dengan penelitian sebelumnya [22] dengan rasio 80:20 memberikan hasil akurasi yang terbaik. Hasil dari proses *training* menghasilkan 24 model yang dibandingkan berdasarkan parameter keakuratan sebuah model dalam mengenali suatu objek menggunakan metode *confussion metrics*. Metode evaluasi *confussion metrics* terdiri dari beberapa matrix penilaian yaitu *Accuracy*, *Recall*, *Precision* dan *F1-Score* [23]. Metode tersebut dipilih untuk menguji kinerja model pada penelitian ini karena salah satu matrix penilaiannya yaitu *accuracy* menjadi parameter utama untuk membandingkan kinerja model dari 24 skenario percobaan. Parameter evaluasi yang digunakan pada penelitian ini hanya *accuracy* saja, karena sesuai dengan kasus yang akan diselesaikan yaitu diharapkan model dapat membedakan jenis sampah dengan tepat. Sesuai penelitian sebelumnya [23] bahwa *accuracy* dapat memperlihatkan seberapa mampu model dapat membedakan setiap data pada kasus distribusi data yang tidak seimbang (*imbalanced dataset*). Hasil percobaan terhadap 24 skenario dapat dilihat pada Tabel 6.

Tabel 6. Hasil Percobaan

No	Skenario	Akurasi	No	Skenario	Akurasi
1	S1 + F1	0.6600	13	S1 + W1	0.7273
2	S1 + F2	0.7030	14	S1 + W2	0.6909
3	S1 + F3	0.6788	15	S1 + W3	0.6909
4	S1 + F4	0.7576	16	S1 + W4	0.6788
5	S2 + F1	0.9919	17	S2 + W1	0.9848
6	S2 + F2	0.9807	18	S2 + W2	0.9868
7	S2 + F3	0.9787	19	S2 + W3	0.9899
8	S2 + F4	0.9676	20	S2 + W4	0.9777
9	S3 + F1	0.9215	21	S3 + W1	0.9215
10	S3 + F2	0.8450	22	S3 + W2	0.8492
11	S3 + F3	0.8843	23	S3 + W3	0.8574
12	S3 + F4	0.8326	24	S3 + W4	0.8202

Pada Tabel 6 ditunjukkan data hasil percobaan semua skenario dalam penelitian ini dengan parameter pengujian berupa nilai akurasi *testing*. Untuk lebih detailnya akan dijelaskan dalam bentuk ilustrasi grafik pada Gambar 3.

3.1 Perbandingan Seluruh Skenario

Pada Gambar 3 ditunjukkan ilustrasi grafik nilai akurasi dari semua skenario setelah dilakukan pengujian menggunakan 20% data uji. Batang grafik yang berwarna orange merupakan seluruh skenario dengan dataset hasil undersampling (S1). Kemudian untuk warna biru merupakan skenario *undersampling* dan augmentasi seluruh kelas (S2) serta warna hijau merupakan skenario dengan dataset hasil augmentasi berlebih untuk kelas minor (S3). Dari semua kombinasi skenario yang ada, penggunaan metode *undersampling* kemudian dilakukan proses augmentasi mengungguli semua skenario dari S1 dan S3 baik dikombinasikan dengan F1-F4 maupun W1-W4.



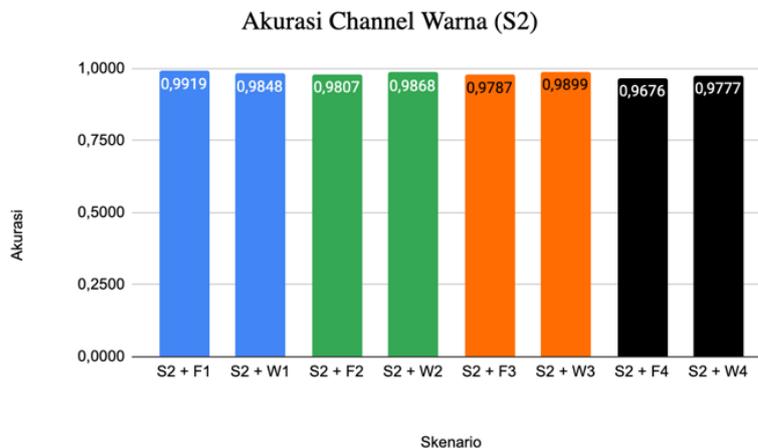
Gambar 3. Perbandingan Seluruh Skenario

Pada Gambar 3 ditunjukkan ilustrasi grafik nilai akurasi dari semua skenario setelah dilakukan pengujian menggunakan 20% data uji. Batang grafik yang berwarna orange merupakan seluruh skenario dengan dataset hasil *undersampling* (S1). Kemudian untuk warna biru merupakan skenario *undersampling* dan augmentasi seluruh kelas (S2) serta warna hijau merupakan skenario dengan dataset hasil augmentasi berlebih untuk kelas minor (S3). Dari semua kombinasi skenario yang ada, penggunaan metode *undersampling* kemudian dilakukan proses augmentasi mengungguli semua skenario dari S1 dan S3 baik dikombinasikan dengan F1-F4 maupun W1-W4.

Sedangkan untuk seluruh skenario pada dataset yang dilakukan *undersampling*, nilai akurasi tertinggi diperoleh adalah sebesar 75%. Hal tersebut sejalan dengan penelitian terdahulu yang dilakukan oleh Hasanin, dkk [16] bahwa teknik *undersampling* efektif jika perbedaan jumlah data antar kelas tidak terlalu besar. Untuk mengatasi hal tersebut, sesuai dengan hasil percobaan yang telah dilakukan bahwa dataset hasil *undersampling* dapat dilakukan proses penggandaan data untuk memperkaya variasi citra menggunakan teknik augmentasi seperti pada skenario (S2). Sedangkan untuk skenario ketiga (S3) hasilnya tidak dapat mengungguli skenario kedua (S2) karena kelas yang diaugmentasi jumlahnya tidak sama, hanya kelas yang minor atau memiliki data paling sedikit.

Hasil percobaan pada penelitian ini dari semua skenario memperoleh nilai akurasi di atas 60%. Hasil akurasi tersebut dapat menjadi penyempurna penelitian sebelumnya yang dilakukan oleh Banish, dkk [8] yang hanya stuck pada nilai 20an %. Hal tersebut terjadi karena arsitektur CNN tidak dapat digunakan secara langsung. Pada penelitian ini dilakukan proses transfer learning yaitu dengan menambahkan layer *dropout* dan mempertahankan *extraction layer* sebagai model *pre-trained* dengan membekukan layer tersebut. Setelah itu penulis melakukan *fine tuning* dengan mengganti *fully connected layer* dengan jumlah kelas 6 sesuai dengan jumlah kelas pada dataset yang penulis gunakan. Hal tersebut penting dilakukan karena secara default jumlah layer output pada semua arsitektur CNN adalah 1000 kelas.

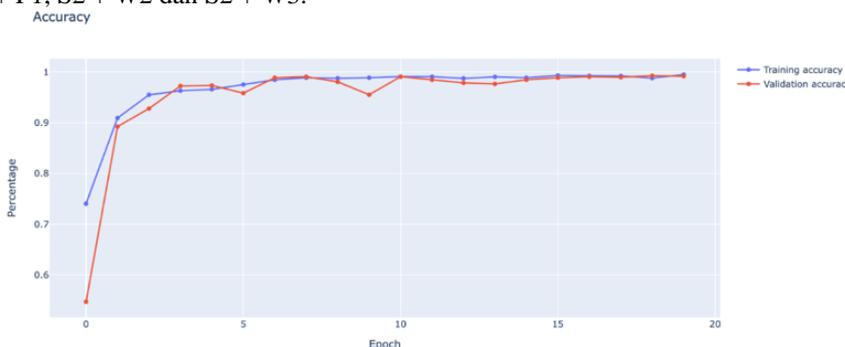
3.2 Perbandingan Channel Warna dan Filter



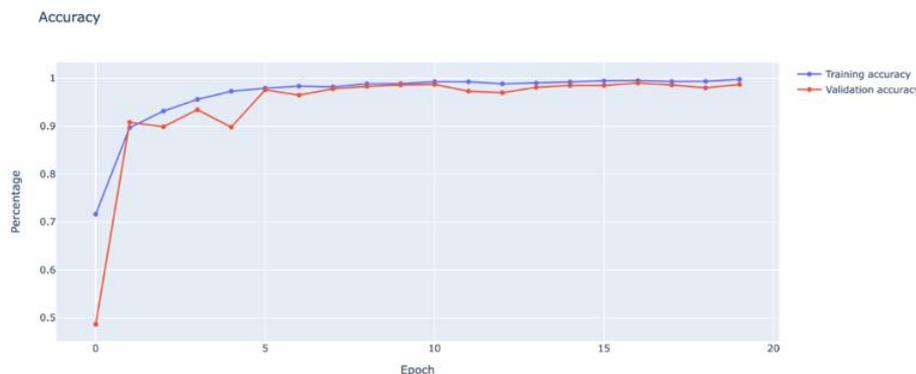
Gambar 4. Perbandingan Channel Warna

Hasil keseluruhan skenario pada dataset yang kedua (S2) mengungguli dari keseluruhan skenario yang ada. Sehingga penulis mengambil sampel hasil percobaan pada dataset yang dilakukan *undersampling* dan augmentasi untuk membandingkan dari pengaruh channel warna citra inputan. Perbandingan hasil akurasi berdasarkan channel warna dapat dilihat pada Gambar 4.

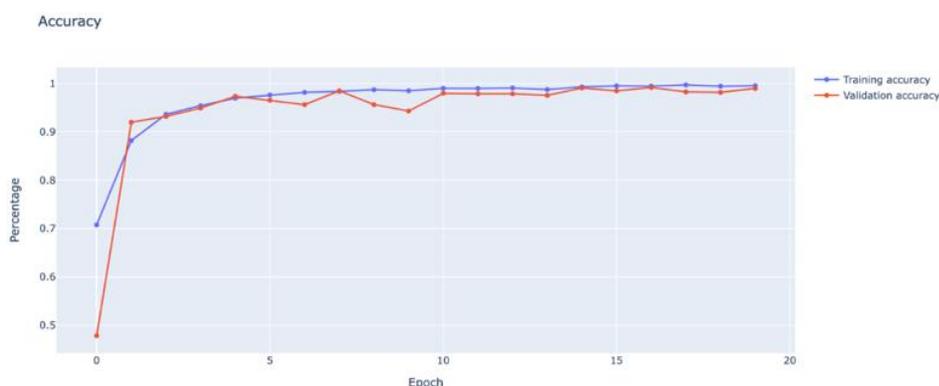
Secara berturut-turut batang grafik warna biru merupakan citra inputan dengan channel RGB, kemudian warna hijau merupakan citra dengan channel warna hijau (*green channel*), warna orange adalah citra grayscale dan warna hitam adalah untuk warna biner. Secara visual perbedaan nilai akurasi dari setiap skenario tidak terlalu berbeda secara signifikan. Kemudian dari perbandingan channel warna tersebut, 3 skenario hampir memiliki nilai akurasi yang sama yaitu skenario S2 + F1, S2 + W2 dan S2 + W3.



Gambar 5. Skenario S2 + F1



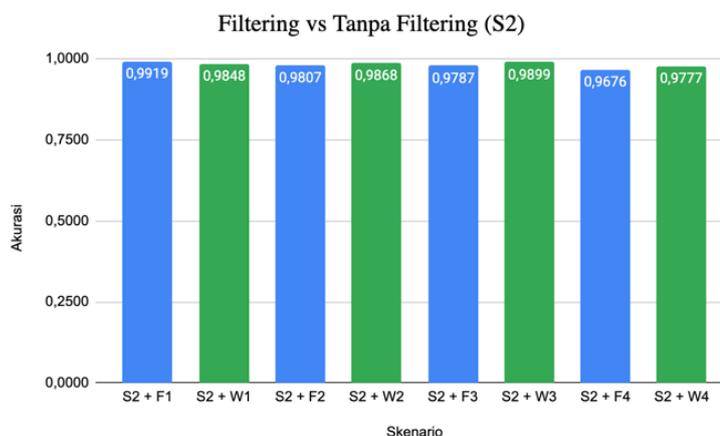
Gambar 6. Skenario S2 + W2



Gambar 7. Skenario S2 + W3

Gambar 5, Gambar 6 dan Gambar 7 berturut-turut merupakan hasil ilustrasi proses *training* model untuk skenario S2 + F1, S2 + W2 dan S2 + W3 yang memiliki nilai akurasi 3 tertinggi. Penelitian ini menggunakan jumlah epoch 20, agar dapat melihat skenario yang terbaik. Karena jika nilai epoch semakin besar maka proses training dan update nilai bobot akan semakin lama dan hasil akurasi dari setiap skenario pasti akan semakin baik. Skenario S2 + F1 terpilih menjadi skenario terbaik, karena pada epoch ke-14 nilai akurasi testing dengan training hampir sama atau bisa dikatakan kondisinya sudah menuju *converge*.

Sedangkan untuk skenario S2 + W2 dan S2 + W3 meskipun nilai akurasi nya tidak jauh berbeda dari skenario S2 + F1, akan tetapi kedua skenario tersebut dikatakan kurang baik. Karena pada epoch ke-18, ke-19 masih terjadi gerakan naik turun. Hal tersebut mengartikan bahwa dalam proses *training* masih mencari kondisi dan nilai parameter yang ideal dan diperlukan penambahan nilai epoch untuk mencapai kondisi *converge*. Semakin tinggi nilai epoch yang digunakan dalam proses training mengakibatkan resource yang digunakan semakin besar, sehingga nilai *cost computation* nya juga tinggi.



Gambar 8. Perbandingan Skenario dengan Filter

Untuk mencari skenario terbaik, penelitian ini juga melakukan perbandingan nilai akurasi berdasarkan penggunaan filter. Hasil perbandingan masih menggunakan skenario kedua (S2) seperti terlihat pada Gambar 8.

Batang grafik berwarna biru merupakan skenario yang menggunakan *sharpening filter* dan batang warna hijau merupakan skenario yang tidak menggunakan filter. Dari Gambar 8 ditunjukkan nilai akurasi tertinggi didapatkan dari citra inputan RGB yang menggunakan *sharpening filter* dengan nilai akurasi 0.9919. Sedangkan, nilai akurasi untuk channel warna hijau ($S_2 + W_2$), grayscale ($S_2 + W_3$) dan biner ($S_2 + W_4$) yang tidak melalui proses penajaman menggunakan *sharpening filter* justru lebih tinggi dibandingkan skenario yang menggunakan filter.

4. KESIMPULAN

Berdasarkan hasil penelitian dengan 24 skenario, didapatkan hasil bahwa skenario terbaik $S_2 + F_1$ yaitu dataset dilakukan proses undersampling dan augmentasi dengan 5 parameter transformasi geometris dengan tingkat akurasi 0.9919. Hasil akurasi yang diperoleh pada penelitian ini jauh lebih baik dibandingkan penelitian sebelumnya yang dilakukan oleh Banish dkk, yang hanya memperoleh akurasi 0.2200 menggunakan metode dan dataset yang sama. Teknik undersampling tidak tepat jika diterapkan pada imbalanced dataset dengan perbedaan jumlah data antar kelasnya sangat tinggi. Perbedaan jumlah data yang terlalu tinggi antar kelas pada kasus imbalanced dataset memerlukan 2 tahap perlakuan, yaitu proses undersampling dan augmentasi. Dalam dataset sampah ini citra inputan dengan perbedaan 4 channel warna tidak terlalu berpengaruh secara signifikan terhadap akurasi model. Penerapan filtering dengan penajaman citra efektif jika diterapkan pada citra RGB, sedangkan untuk channel warna yang lain seperti grayscale, green channel dan biner justru menurunkan tingkat akurasi. Implementasi proses transfer learning dan fine tuning terhadap arsitektur CNN dapat meningkatkan kinerja model secara signifikan dan dapat mencegah terjadinya overfitting.

REFERENCES

- [1] B. G. K. M. Alblooshi, S. Z. Ahmad, M. Hussain, and S. K. Singh, "Sustainable management of electronic waste: Empirical evidences from a stakeholders' perspective," *Bus Strategy Environ*, vol. 31, no. 4, 2022, doi: 10.1002/bse.2987.
- [2] R. Panca Sakti, Ulfa Sulaeman, and Abd. Gafur, "Peran Mallsampah dalam Efektivitas Pengelolaan Sampah (Studi Kasus di PT. Mallsampah Indonesia)," *Window of Public Health Journal*, vol. 2, no. 2, pp. 1004–1018, 2021, doi: 10.33096/woph.v2i2.197.
- [3] N. Istiqomah, I. Mafruhah, E. Gravitiani, and S. Supriyadi, "Konsep Reduce, Reuse, Recycle dan Replace dalam Pengelolaan Sampah Rumah Tangga di Desa Polanharjo Kabupaten Klaten," *SEMAR (Jurnal Ilmu Pengetahuan, Teknologi, dan Seni bagi Masyarakat)*, vol. 8, no. 2, pp. 30–38, 2019, doi: 10.20961/semar.v8i2.26682.
- [4] D. N. Patel, C. Dasari, A. Chembarpu, and A. Sasi, "Smart Waste Segregation using ML Techniques," *International Journal of Innovative Science and Research Technology-2019*, 2020.
- [5] Y. Chen et al., "Classification of lungs infected COVID-19 images based on inception-ResNet," *Comput Methods Programs Biomed*, vol. 225, p. 107053, 2022, doi: 10.1016/j.cmpb.2022.107053.
- [6] R. Vankdothu and M. A. Hameed, "Brain tumor MRI images identification and classification based on the recurrent convolutional neural network," *Measurement: Sensors*, vol. 24, no. August, p. 100412, 2022, doi: 10.1016/j.measen.2022.100412.
- [7] Kusri, M. R. A. Yudianto, and H. Al Fatta, "The effect of Gaussian filter and data preprocessing on the classification of Punakawan puppet images with the convolutional neural network algorithm," *International Journal of Electrical and Computer Engineering*, vol. 12, no. 4, pp. 3752–3761, 2022, doi: 10.11591/ijece.v12i4.pp3752-3761.
- [8] M. G. Banish, U. Amogha, and U. Apoorva, "Segregation of Trash for Recyclability," *Ijresm.Com*, no. 8, 2019.
- [9] C. Cheng, X. Wei, and Z. Jian, "Emotion recognition algorithm based on convolution neural network," *Proceedings of the 2017 12th International Conference on Intelligent Systems and Knowledge Engineering, ISKE 2017*, vol. 2018-January, pp. 1–5, 2017, doi: 10.1109/ISKE.2017.8258786.
- [10] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Trans Neural Netw Learn Syst*, pp. 1–21, 2021, doi: 10.1109/tnnls.2021.3084827.
- [11] F. A. Breve, "COVID-19 detection on Chest X-ray images: A comparison of CNN architectures and ensembles [Formula presented]," *Expert Syst Appl*, vol. 204, no. May, p. 117549, 2022, doi: 10.1016/j.eswa.2022.117549.
- [12] J. Huang et al., "BM-Net: CNN-Based MobileNet-V3 and Bilinear Structure for Breast Cancer Detection in Whole Slide Images," *Bioengineering*, vol. 9, no. 6, pp. 1–16, 2022, doi: 10.3390/bioengineering9060261.
- [13] S. L. Rabano, M. K. Cabatuan, E. Sybingco, E. P. Dadios, and E. J. Calilung, "Common garbage classification using mobilenet," *2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management, HNICEM 2018*, pp. 1–4, 2018, doi: 10.1109/HNICEM.2018.8666300.
- [14] K. De Angeli et al., "Class imbalance in out-of-distribution datasets: Improving the robustness of the TextCNN for the classification of rare cancer types," *J Biomed Inform*, vol. 125, no. June 2021, p. 103957, 2022, doi: 10.1016/j.jbi.2021.103957.
- [15] J. M. Durden, B. Hosking, B. J. Bett, D. Cline, and H. A. Ruhl, "Automated classification of fauna in seabed photographs: The impact of training and validation dataset size, with considerations for the class imbalance," *Prog Oceanogr*, vol. 196, no. July 2020, p. 102612, 2021, doi: 10.1016/j.pocean.2021.102612.
- [16] T. Hasanin and T. M. Khoshgoftaar, "The effects of random undersampling with simulated class imbalance for big data," *Proceedings - 2018 IEEE 19th International Conference on Information Reuse and Integration for Data Science, IRI 2018*, pp. 70–79, 2018, doi: 10.1109/IRI.2018.00018.



- [17] P. M. Blok, F. K. van Evert, A. P. M. Tielen, E. J. van Henten, and G. Kootstra, “The effect of data augmentation and network simplification on the image-based detection of broccoli heads with Mask R-CNN,” *J Field Robot*, vol. 38, no. 1, pp. 85–104, 2021, doi: 10.1002/rob.21975.
- [18] S. N. Gowda and C. Yuan, *ColorNet: Investigating the Importance of Color Spaces for Image Classification*, vol. 11364 LNCS. Springer International Publishing, 2019. doi: 10.1007/978-3-030-20870-7_36.
- [19] F. M. Hana and I. D. Maulida, “Analysis of contrast limited adaptive histogram equalization (CLAHE) parameters on finger knuckle print identification,” *J Phys Conf Ser*, vol. 1764, no. 1, 2021, doi: 10.1088/1742-6596/1764/1/012049.
- [20] F. Thabtah, S. Hammoud, F. Kamalov, and A. Gonsalves, “Data imbalance in classification: Experimental evaluation,” *Inf Sci (N Y)*, vol. 513, 2020, doi: 10.1016/j.ins.2019.11.004.
- [21] T. A. Soomro et al., “Impact of Image Enhancement Technique on CNN Model for Retinal Blood Vessels Segmentation,” *IEEE Access*, vol. 7, pp. 158183–158197, 2019, doi: 10.1109/ACCESS.2019.2950228.
- [22] I. Astuti, W. W. Ariestya, and B. Solehudin, “Deteksi Objek Daun Semanggi Secara Real Time Menggunakan CNN-Single Shot Multibox Detector (SSD),” *Jurnal Ilmiah FIFO*, vol. 14, no. 1, 2022.
- [23] M. Grandini, E. Bagli, and G. Visani, “Metrics for multi-class classification: an overview,” *arXiv preprint arXiv:2008.05756*, 2020.