



## Klasifikasi Sampah Menggunakan Ensemble DenseNet169

Ulfah Nur Oktaviana<sup>1</sup>, Yufis Azhar<sup>2</sup><sup>1,2</sup>Informatika, Teknik, Universitas Muhammadiyah Malang<sup>1</sup>ulfanuroktaviana575@webmail.umm.ac.id, <sup>2</sup>yufis@umm.ac.id

### Abstract

Garbage is a big problem for the sustainability of the environment, economy, and society, where the demand for waste increases along with the growth of society and its needs. Where in 2019 Indonesia was able to produce 66-67 million tons of waste, which is an increase from the previous year of 2 to 3 million tons of waste. Waste management efforts have been carried out by the government, including by making waste sorting regulations. This sorting is known as 3R (reduce, reuse, recycle), but most people do not sort their waste properly. In this study, a model was developed that can sort out 6 types of waste including: cardboard, glass, metal, paper, plastic, trash. The model was built using the transfer learning method with a pretrained model DenseNet169. Where the optimal results are shown for the classes that have been oversampling previously with an accuracy of 91%, an increase of 1% compared to the model that has an unbalanced data distribution. The next model optimization is done by applying the ensemble method to the four models that have been oversampled on the training dataset with the same architecture. This method shows an increase of 3% to 5% while the final accuracy on the test of dataset is 96%.

*Keywords: DenseNet169, ensemble, oversampling, garbage.*

### Abstrak

Sampah menjadi permasalahan besar bagi keberlanjutan lingkungan, ekonomi, dan masyarakat, dimana tuntutan sampah meningkat seiring dengan pertumbuhan masyarakat dan kebutuhannya. Pada tahun 2019 Indonesia mampu menghasilkan sampah dengan jumlah 66-67 juta ton dimana angka ini naik dari tahun sebelumnya sebesar 2 hingga 3 juta ton sampah. Upaya pengelolaan sampah telah dilakukan oleh pemerintah diantaranya dengan membuat peraturan pemilahan sampah. Pemilahan tersebut dikenal dengan 3R (reduce, reuse, recycle), namun sebagian besar masyarakat tidak memilah sampah dengan benar. Pada penelitian ini dikembangkan model yang dapat memilah 6 jenis sampah diantaranya : *cardboard, glass, metal, paper, plastic, trash*. Model dibangun menggunakan metode *transfer learning* dengan *pretrained* model DenseNet169. Dimana hasil optimal ditunjukkan terhadap kelas yang telah dilakukan *oversampling* sebelumnya dengan *accuracy* sebesar 91% meningkat sebesar 1 % dibandingkan dengan model yang memiliki distribusi data yang tidak seimbang. Pengoptimalan model selanjutnya dilakukan dengan menerapkan metode ensemble pada lima model yang sudah dilakukan *oversampling* pada dataset pelatihan dengan arsitektur yang sama. Metode ini menunjukkan peningkatan sebesar 3% hingga 5% dimana *accuracy* akhir pada dataset *test* sebesar 96%.

Kata kunci: DenseNet169, ensemble, oversampling, sampah.

### 1. Pendahuluan

Sampah merupakan barang/benda/bahan yang digunakan secara biasa atau khusus dan tidak memiliki nilai, yang dihasilkan dalam lingkungan produksi, kerusakan barang selama proses manufaktur, dan barang berlebihan dimana Sebagian besar sampah didominasi oleh sampah rumah tangga [1]. Sampah menjadi ancaman besar bagi keberlanjutan lingkungan, ekonomi, dan masyarakat, dimana tuntutan produksi sampah meningkat seiring dengan pertumbuhan masyarakat dan kebutuhannya, maka dibutuhkan lahan yang luas untuk

pengelolaan sampah. Disebutkan oleh penelitian yang dilakukan di Semarang, Jakarta, Yogyakarta, dan Magelang pada tahun 2018 arus sampah pada awalnya dikumpulkan di TPS (Tempat Pengumpulan Sementara) yang kemudian akan dipilah menjadi 3R (*reduce, reuse, recycle*) pembagian jenis sampah dilakukan sebelum sampah dikirim menuju TPA (tempat pembuangan akhir). Dimana Sebagian besar proses pengumpulan masih dilakukan secara manual oleh petugas dikarenakan Sebagian besar masyarakat yang tidak memilah sampah secara baik dan benar [2]. Upaya

serupa telah dilakukan pemerintah dimana kini telah terdapat peraturan pemerintah dalam pemilahan jenis sampah. Mengingat berbagai macam jenis sampah yang memiliki karakteristik dan penanganan yang berbeda pula yang telah diatur dalam Peraturan Pemerintah Nomor 81 Tahun 2012 [3].

Menurut data dari Kementerian Lingkungan Hidup Indonesia tahun 2017 mampu menghasilkan sampah dengan jumlah 175.000 ton per hari atau sebanyak 64 juta ton sampah setiap tahunnya [4] sedangkan pada tahun, 2019 sampah di Indonesia sebesar 66-67 juta ton, dimana jumlah tersebut naik sebanyak 2 hingga 3 juta ton dari tahun sebelumnya [1]. Berdasarkan permasalahan tersebut diperlukan sistem yang dapat mengklasifikasikan sampah sehingga, mempercepat dalam pengelolaannya, yang ditawarkan dalam penelitian ini. Perkembangan teknologi memungkinkan untuk melakukan klasifikasi gambar melalui pengenalan pola dari citra yang diinputkan dengan menggunakan *artificial intelligence*. Perkembangan *artificial intelligence* telah melahirkan berbagai terobosan baru seperti *Deep Learning*. Salah satu metode yang unggul dalam *Deep Learning* yaitu CNN (*Convolutional Neural Network*) [5]. CNN dibentuk dengan menggunakan beberapa *layers* untuk melakukan tugas klasifikasi gambar, aritektur *layer* dari CNN diantaranya : (1) *Input Layer*, (2) *Convolution Layer*, (3) *ReLU (Rectified Linear Unit)*, (4) *Pooling*, (5) *Fully Connected Layer*, (6) *Softmax Layer*. CNN yang dilatih dengan jumlah dataset yang besar akan menghasilkan bobot model dan bias selama pelatihan, bobot ini nantinya bisa ditransfer ke model jaringan lainnya untuk menyelesaikan permasalahan yang berbeda. Dimana model baru dapat dibangun dengan *pre-trained* bobot. Metode ini dikenal pula dengan sebutan *Transfer Learning*, banyak contoh dari metode ini diantaranya : *LeNet*, *AlexNet*, *VGG*, *GoogleNet*, *ResNet*, dan lainnya [6].

Terdapat beberapa penelitian terkait yang membahas klasifikasi jenis sampah menggunakan CNN dan metode *Transfer Learning* adapun pada penelitian [7] Identifikasi Sampah dan Bahan Daur Ulang Menggunakan CNN (*Convolutional Neural Network*) dimana sistem dikembangkan menggunakan dua CNN dengan keduanya menggunakan *Transfer Learning* dengan arsitektur dasar *AlexNet*. Pada model CNN pertama dilatih dan diuji dengan menggunakan kumpulan data dalam ruangan *TrashNet benchmark* yang mampu mencapai *accuracy* sebesar 93,6%. Sedangkan pada model kedua dilatih dan diuji dengan menggunakan dataset luar ruangan dari Gary Thung dan Midy Yang dimana terdiri atas enam kelas diantaranya : *glass*, *paper*, *cardboard*, *plastic*, *metal*, dan *trash*. Dengan total keseluruhan dataset 2527 gambar. Hasil akhir pada model kedua mencapai *accuracy* secara keseluruhan sebesar 92%.

Pada penelitian lainnya [8] tentang Klasifikasi Limbah Padat Menggunakan DCNN (*Deep Convolutional Neural Network*) dilakukan klasifikasi jenis sampah dengan menggunakan arsitektur DCNN yang terbagi atas 2 model. Model pertama terdiri atas empat *layer* dan model kedua menggunakan lima *layers*. Model dilatih dengan dataset yang terdiri atas empat kelas diantaranya : *plastic*, *kaca*, *sampah organis*, dan *kertas*. Dimana masing-masing kelas terdiri atas 100 gambar yang memiliki mode RGB, sebelum dilakukan *training* gambar terlebih dahulu dilakukan *resize* dengan ukuran 224 X 224 piksel. Kemudian dibagi menjadi 70% data latih dan 30% data validasi. Hasil penelitian pada arsitektur DCNN dengan empat *layers* mendapatkan *accuracy* sebesar 61% sedangkan pada DCNN dengan lima *layer* menghasilkan *accuracy* sebesar 70%. Peningkatan jumlah *layer* juga meningkatkan hasil *accuracy* klasifikasi. Namun, ketepatan kedua arsitektur dalam menentukan klasifikasi sampah plastik jika dibandingkan dengan sampah lain lebih rendah. Dimana tingkat klasifikasi *accuracy* sampah plastik sebesar 37% dan 56,7% dalam arsitektur DCNN 4 *layer* dan DCNN lima *layer*. Sedangkan, tingkat *accuracy* pada klasifikasi sampah organik yaitu sebesar 83% dan 76,7% dengan arsitektur masing-masing DCNN 4 *layer* dan DCNN lima *layer*.

Penelitian lain yang dilakukan oleh [9] mendapatkan hasil *accuracy* yang lebih tinggi dibandingkan penelitian terkait sebelumnya. Dimana didalam penelitian Pemilahan Sampah Menggunakan Teknik *Deep Learning*, menggunakan CNN dengan metode *transfer learning* diantaranya : *ResNet50*, *DenseNet169*, *VGG16*, dan *AlexNet*. Mendapatkan nilai *accuracy* dengan masing-masing model yaitu : 93,4%, 94,9%, 91,7%, dan 89,3%. Model tersebut dilatih dengan menggunakan dataset dari Gary Thung dan Mindy Yang. Dimana awalnya dataset terdiri atas enam kelas dengan jumlah 2527 gambar. Namun, dikarenakan ukuran dataset yang kecil pada penelitian ini menambahkan lebih banyak gambar yang dikumpulkan dari *Google Images*, hingga mendapatkan jumlah dataset terakhir sebesar 4163 gambar, dengan distribusi gambar pada masing-masing kelas sebagai berikut : *cardboard* sebanyak 651, *glass* 769, *metal* 819 *paper* 909, *plastic* 878, dan *trash* sebanyak 137 gambar. Dari pelatihan dengan menggunakan dataset tersebut didapatkan hasil klasifikasi terbaik yaitu menggunakan arsitektur *pretrained* model *DenseNet169* yaitu sebesar 94,9%. Dikarenakan dataset masih dalam keadaan *imbalance* maka menyebabkan hasil *precision*, dan *recall* dengan menggunakan arsitektur *DenseNet169* pada kelas yang memiliki jumlah gambar minoritas lebih kecil jika dibandingkan *precision* dan *recall* dari kelas mayoritas.

Berdasarkan latar belakang diatas penelitian ini bertujuan untuk melakukan optimasi klasifikasi jenis sampah dengan beberapa metode diantaranya : melakukan preprocessing dataset sebelum pelatihan

dimana dilakukan *balancing class* terlebih dahulu sebelum pelatihan dengan menggunakan teknik augmentasi, kemudian dilakukan pelatihan sebanyak lima model menggunakan CNN dengan metode *pretrained* model DenseNet169 yang sama. Dari kelima bobot model yang didapatkan akan dilakukan sistem *voting* pada hasil klasifikasi untuk meningkatkan *accuracy*. Teknik yang diterapkan pada penelitian ini juga dikenal sebagai *ensemble learning*.

**2. Metode Penelitian**

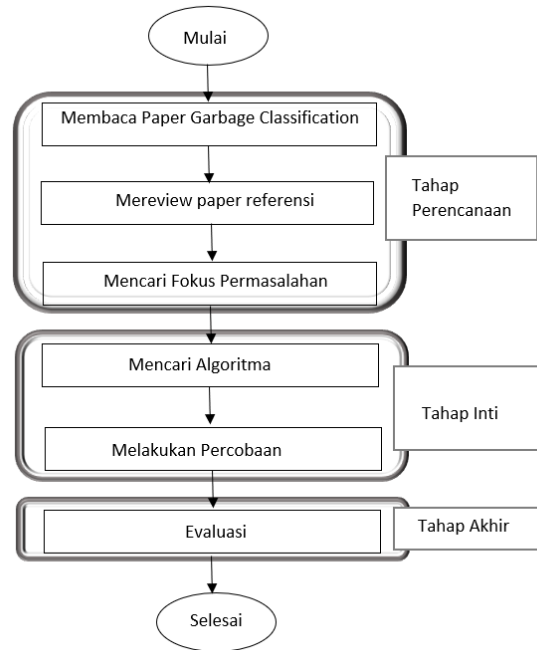
**2.1. Alur Penelitian**

Pada alur penelitian berisi tentang bagaimana sebuah penelitian dilakukan, pada penelitian ini terdapat tiga tahapan, diantaranya: tahap perencanaan, tahap inti, dan tahap akhir. Pada tahap perencanaan dilakukan pencarian tema terkait *garbage classification*. Kemudian dilanjutkan untuk mengevaluasi paper referensi. Dari beberapa paper referensi didapatkan dataset pelatihan masih menggunakan dataset yang *imbalance*, menyebabkan kurang optimal hasil akhir dari klasifikasi. Dimana kelas yang memiliki jumlah dataset mayoritas akan cenderung lebih bagus, dibandingkan dengan kelas minoritas. Tahap berikutnya adalah tahap perencanaan dimana dilakukan pengumpulan dataset dan mencari metode yang dapat menyeimbangkan distribusi dataset pada masing-masing kelas. Metode *balancing class* yang digunakan dalam penelitian ini yaitu augmentasi. Setelah dilakukan augmentasi tahap selanjutnya yaitu tahap inti, disini dilakukan pelatihan model menggunakan metode *transfer learning* dengan *pretrained* model DenseNet169 dengan tambahan arsitektur penulis. Sedangkan, untuk meningkatkan performa dari model, metode kedua yang diterapkan yaitu ensemble. Pada tahap ini dilakukan penggabungan hasil pelatihan dari 5 model usulan yang memiliki arsitektur yang sama. Dilanjutkan dengan tahap evaluasi performa model menggunakan *classification report* untuk melihat performa hasil klasifikasi dari masing-masing kelas yang serta grafik *training loss* dan *validation loss* untuk mengetahui keadaan model. Detail. Langkah dari alur penelitian dapat dilihat pada Gambar 1.

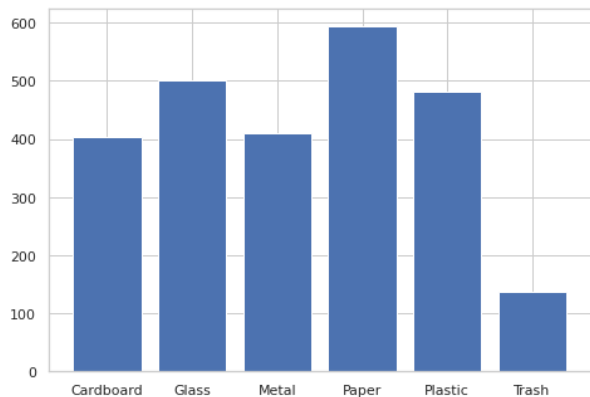
**2.2. Dataset**

Penelitian ini menggunakan dataset yang digunakan pada penelitian [7], [9]. Dimana dataset ini diambil dari Gary Thung dan Mindy Yang’s dataset berisi jenis sampah yang dikategorikan menjadi enam kelas diantaranya : *cardboard* 403 gambar, *glass* 501 gambar, *metal* 410 gambar, *paper* 594 gambar, *plastic* 482 gambar, dan *trash* 137 gambar. Sample dataset asli yang digunakan dalam penelitian ini dapat dilihat pada Gambar 3. Jumlah total keseluruhan dataset sebesar 2527 gambar dengan format JPG. Distribusi gambar pada dataset ini masih belum seimbang karena jumlah


gambar yang berbeda pada masing-masing kelas yang dapat dilihat detailnya pada Gambar 2.



Gambar 1. Alur Penelitian

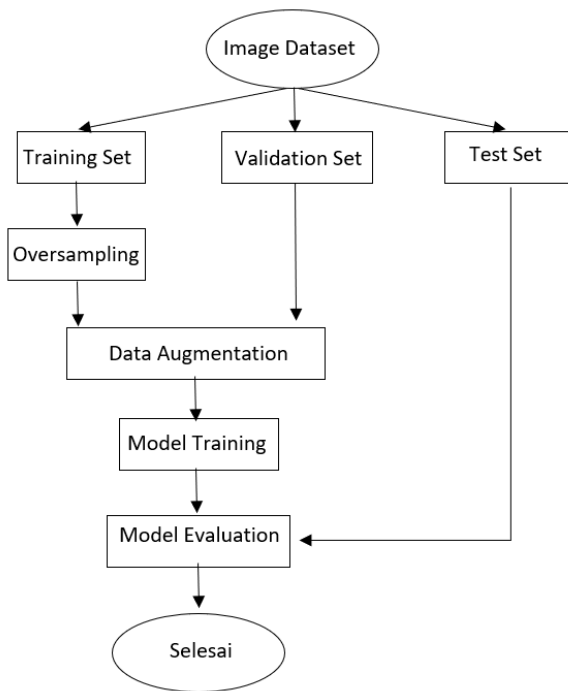


Gambar 2. Distribusi dataset



Gambar 3. Sample Data Asli 6 Label

**2.3. Metode Yang Diusulkan**

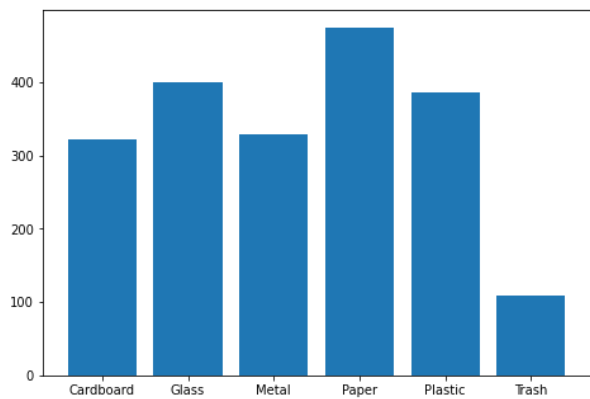


Gambar 4. Arsitektur model yang diusulkan


Hasil dari penelitian ini adalah model yang mampu mengklasifikasi jenis sampah pada dataset dimana alur metode dapat dilihat pada Gambar 4. Sebuah model yang memiliki jaringan neuron terlalu sedikit akan menyebabkan kesulitan jaringan dalam menemukan pola hubungan antara citra dan label yang menyebabkan *underfitting*. Kasus kedua adalah ketika model belajar terlalu ketat sehingga jaringan neuron akan mempelajari fitur palsu daripada fitur yang sesuai pada gambar, kondisi ini disebut *Overfitting*. maka untuk mengatasi permasalahan tersebut dalam memverifikasi *accuracy* diperlukan sebuah konsep pelatihan *training*, *testing*, dan *validasi* yang mampu menangani data yang tidak terlihat pada masa depan. hal ini berarti dataset harus dibagi kedalam tiga kategori diantaranya : (1) *training-set* untuk mempelajari pola gambar yang sesuai dengan masing-masing label, (2) *validation-set*, bekerja setelah pola dipelajari untuk melakukan pengecekan apakah terjadi *overfitting* atau *underfitting*, (3) *test-set*, karena kinerja model divalidasi menggunakan *validation-set* maka dibutuhkan set ketiga untuk menghindari bias dan melaporkan perkiraan klasifikasi yang tidak bias dari kinerja model [10]. Berdasarkan konsep tersebut dalam penelitian ini langkah pertama dataset pada bagi menjadi *training-set* sebesar 80%, *validation-set* sebesar 10%, dan *test-set* sebesar 10%.

Dataset yang memiliki distribusi kelas yang tidak merata akan menyebabkan ketidakefektifan ketika melatih model. Maka diperlukan metode untuk menyeimbangkan jumlah dataset pada *training-set* pada masing-masing kelas. Salah satu metode yang dapat digunakan adalah melakukan *oversampling*. Teknik ini

akan memodifikasi distribusi data latih untuk menyelesaikan permasalahan ketidak seimbangan kelas. Teknik ini bekerja dengan cara melakukan duplikasi sample acak dari kelas minoritas sehingga memiliki jumlah sama dengan kelas mayoritas [11]. Langkah kedua pada penelitian ini dilakukan *balancing class* pada *training\_set* dengan metode *oversampling*. Dimana dataset pada kelas minoritas akan dilakukan augmentasi berupa *rotation\_range* dengan nilai 45, *width\_shift\_range* dengan nilai 0.2, *height\_shift\_range* dengan nilai 0.2, *shear\_range* dengan nilai 0.2, *zoom\_range* dengan nilai 0.2, *horizontal\_flip* dengan nilai *True*, dan *fill\_mode* dengan nilai *reflect*. Kemudian hasil dari augmentasi disimpan menjadi dataset pelatihan. jumlah dataset pada *training\_set* setelah dilakukan *oversampling* menjadi seimbang dimana jumlah dataset masing-masing kelas yaitu 475 gambar, dengan jumlah akhir *training\_set* sebesar 2.850 gambar. Perbedaan distribusi dataset *training\_set* dapat dilihat pada Gambar 5 dan 6.



Gambar 5. Training\_set sebelum balancing class



Gambar 6. Training\_set setelah balancing class

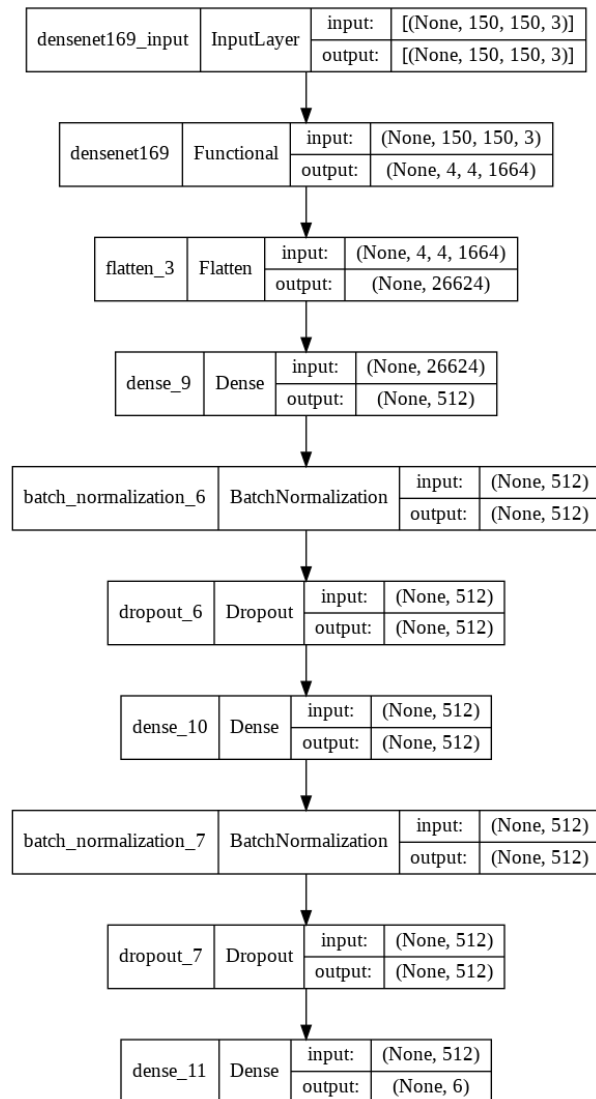
Langkah selanjutnya adalah melakukan augmentasi pada dataset *training* dan *validation*. Pada pengenalan image terkadang terdapat beberapa tantangan dan permasalahan seperti ketika melakukan klasifikasi gambar yang memiliki sudut pandang, pencahayaan, latar belakang, skala, dan lainnya. oleh karenanya, diperlukan teknik data augmentasi yang dapat mengatasi

permasalahan tersebut. Menurut penelitian sebelumnya [12] augmentasi sendiri merupakan salah satu metode yang dilakukan untuk menghindari adanya *overfitting* dengan memanfaatkan dataset *training*. karena banyak informasi yang dapat diekstraksi dari dataset *training*. peningkatan ini secara *artificial* dapat diartikan sebagai melakukan peningkatan dataset pelatihan, dengan mengubah gambar sedemikian rupa sehingga label tetap dipertahankan. Pada teknik augmentasi kedua juga dilakukan *resizing* gambar dengan ukuran 150x150 untuk langkah seterusnya sama dengan langkah sebelumnya perbedaannya terletak pada penyimpanan gambar dimana pada langkah ini tidak dilakukan penyimpanan data hasil augmentasi sebagai dataset utama yang akan dilatih atau *balancing class*.

Model selanjutnya dilakukan *training* dengan menggunakan metode *transfer learning* dengan *pretrained* model DenseNet169. Arsitektur ini memiliki keistimewaan dimana setiap *layer* terhubung ke setiap *layer* lainnya secara *feed-forward*. Setiap lapisan akan mendapatkan *feature maps* dari lapisan sebelumnya. Oleh karenanya fitur tidak hilang walau melewati banyak *layer*. Dalam arsitektur DenseNet terjadi pengurangan parameter karena fungsi yang digunakan berulang [9]. Selain menggunakan *pretrained* model DenseNet169 pada *proposed method* juga ditambahkan arsitektur penulis. Arsitektur tersebut terdiri atas beberapa *layer* yang diberikan pada bagian *Fully Connected Later* diantaranya : (1) *Dense Layer* 512 dengan *activation* *relu*, (2) *BatchNormalization layer*, (3) *Dropout layer* sebesar 0.5, (4) *Dense Layer* 512 dengan *activation* *relu*, (5) *BatchNormalization layer*, (6) *Dropout layer* sebesar 0.5, dan diakhiri dengan (7) *Dense layer* dengan *output* terdiri atas 6 kelas. Rincian arsitektur penulis ditunjukkan pada Gambar 7. Penambahan *Dropout* pada model dapat menurunkan terjadinya *overfitting*, meningkatkan *accuracy* model, serta mempercepat selama proses pelatihan [1]. Sedangkan, *BatchNormalization* merupakan teknik yang digunakan didalam *very deep neural network* untuk menstandarisasikan input untuk setiap *mini-batch* dan meningkatkan generalisasi kemampuan jaringan. Teknik ini memiliki efek menstabilkan proses pembelajaran dan mengurangi jumlah pelatihan epoch selama pelatihan dan mempercepat konvergensi model [13], [14].

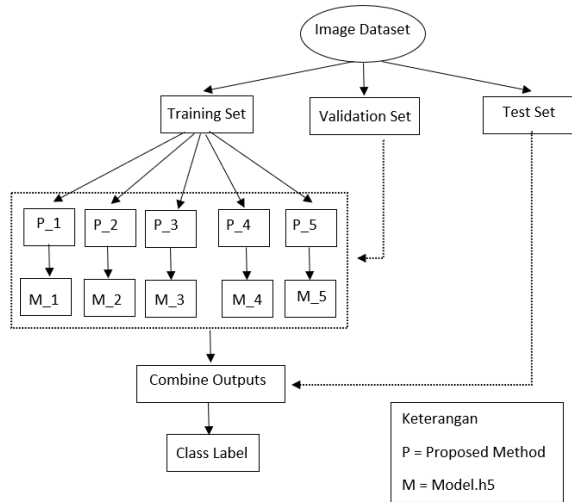
*Optimizer* yang digunakan yaitu adam (*Adaptive Moment Estimation*). Algoritma adam digunakan untuk melakukan pembaruan pada bobot dan jaringan. Adam merupakan algoritma yang populer pada bidang *deep learning* karena mampu mencapai hasil yang baik dengan proses pelatihan yang cepat [15]. Sedangkan parameter kedua yaitu *learning\_rate* dimana pada model ini menggunakan *learning\_rate* sebesar 0.0001. sebuah penelitian [16] menyebutkan *learning rate* yang kecil menghabiskan waktu yang lebih lama selama pelatihan untuk menemukan *optimum point* dan dapat pula menempel pada *local minima*. Sedangkan *learning rate*

yang besar memiliki kemungkinan melewati *optimum point* dan tidak pernah konvergen.



Gambar 7. Proposed Method Architecture

Pelatihan model dilakukan dengan *epochs* sebesar 50 diterapkan pula teknik *callback*, dimana pada penelitian ini menggunakan dua jenis *callback* yang memiliki fungsi berbeda. Pada *callback* pertama memanfaatkan *EarlyStopping* untuk memonitor kinerja model pada setiap pelatihan [17] pada masing-masing *epoch* menggunakan parameter *val\_loss* dengan nilai *patience* sebesar 15 yang artinya model akan dilatih jika dalam 15 *epoch* *val\_loss* tidak mengalami peningkatan maka pelatihan akan dihentikan. *Callback* kedua memanfaatkan *ModelCheckpoint* untuk mengawasi kinerja model secara *realtime*, dimana ketika kinerja model pada *epoch* terbaru jauh lebih buruk jika dibandingkan *epoch* sebelumnya, maka hasil dari *epoch* terbaru tidak akan disimpan. Teknik ini hanya akan menyimpan model terbaik dari keseluruhan *epochs*, sehingga akan mengurangi penggunaan memori [18].

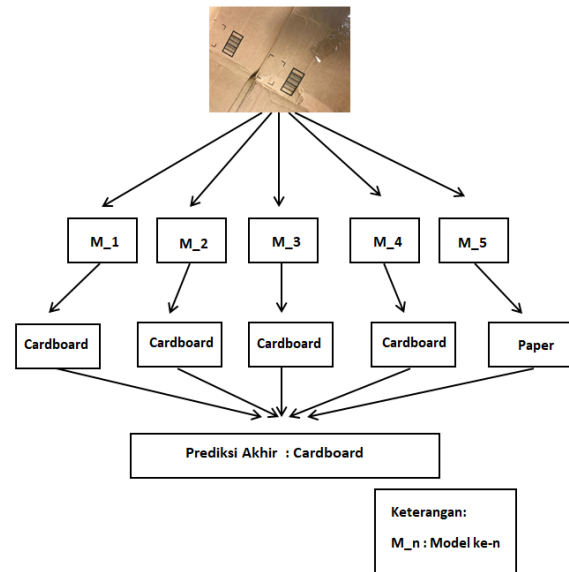


Gambar 8. Arsitektur ensemble yang diusulkan

*Proposed method* yang menggunakan metode *pretrained* model DenseNet169 dengan tambahan layer usulan pada *Fully Connected Layer* seperti pada Gambar 7, dilatih sebanyak lima kali. Selanjutnya hasil pelatihan model akan disimpan dengan ekstensi file H5. Tahap terakhir, kelima model berekstensi H5 akan diterapkan Metode ensemble untuk mendapatkan hasil yang lebih optimal. Secara detail kerangka metode ensemble yang diterapkan pada penelitian ini dapat dilihat pada Gambar 8. Teknik ini terbukti mampu mencapai *accuracy* yang lebih baik berdasarkan pembelajaran berbasis ganda atau multi model. Metode ini pada dasarnya mengacu pada teknik menggunakan beberapa jenis model (dimana jumlah model tergantung dengan kasus klasifikasi), kemudian menggabungkan hasil dari prediksi masing-masing model melalui sistem *voting* atau rata-rata sebagai label akhir klasifikasi [19]–[21]. Sistem *voting* yang dimaksud yaitu mengambil hasil prediksi yang paling banyak muncul dari kelima model yang kemudian hasil prediksi terbanyak akan menjadi hasil akhir klasifikasi. Secara detail ilustrasi dari sistem *voting* pada metode ensemble dapat dilihat pada Gambar 9.

#### 2.4. Skenario Pengujian

Dataset pada penelitian ini menggunakan berbagai macam jenis sampah dengan total 6 kelas seperti pada Gambar 2, yang dibagi menjadi 3 bagian, diantaranya : data *training-set*, *validation-set*, dan *test-set*. Dimana dalam pengujian performa dari masing-masing model dan analisa performa metode ensemble digunakan data *test-set*. Pengujian dilakukan dengan menggunakan *classification report* untuk melihat ketepatan prediksi model yang dibangun dan grafik *training and validation loss* untuk mengetahui keadaan model.



Gambar 9. Arsitektur ensemble yang diusulkan


### 3. Hasil dan Pembahasan

Pada bab ini mengulas mengenai hasil dan pembahasan dari metode usulan dan performanya dibandingkan dengan metode yang sebelumnya digunakan pada penelitian lainnya. Parameter pengujian berupa *classification report* yang memberikan nilai *accuracy*, *precision*, dan *recall* dari masing-masing kelas. *Classification accuracy* ditentukan dengan presentasi gambar yang diklasifikasikan dengan benar, *precision* merepresentasikan ketepatan prediksi dari klasifikasi, sedangkan *recall* merepresentasikan keefektifan algoritma dalam memprediksi dan melakukan klasifikasi [22]. Serta grafik *accuracy* dan *loss* selama pelatihan untuk melihat performa model apakah mengalami *overfitting*, *underfitting*, ataukah *good fit*. Kondisi *Underfitting* terjadi ketika *training loss* dan *validation loss* bernilai tinggi. Selanjutnya, kondisi *Overfitting* terjadi apabila *training loss* bernilai rendah sedangkan *validation loss* bernilai tinggi. Kondisi terakhir yaitu *Good Fit* dimana *training loss* maupun *validation loss* bernilai sama rendahnya. Selain hal itu kinerja model buruk juga dapat diindikasikan dengan celah yang terjadi antara *training\_set* dengan *test\_set* yang dihasilkan selama pelatihan [23].

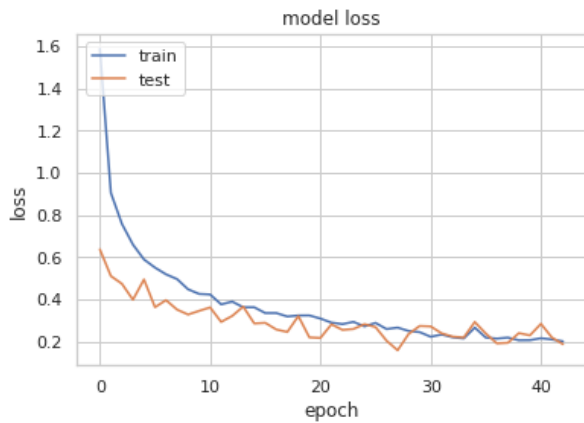
#### 3.1. Pengujian model dengan *imbalance class* dan *balance class*

Performa model yang dilatih dengan menggunakan dataset mentah tanpa adanya *preprocessing* dataset berupa *balancing class*. Dilihat pada Gambar 10 diindikasikan mengalami *overfitting*. Hal tersebut dikarenakan terdapat *gap* antara *training loss* dan *validation loss* yang terjadi pada *epoch* ke-10 hingga ke-40 dimana nilai *training loss* rendah sedangkan *validation loss* tinggi. Berbanding terbalik dengan

model yang sebelumnya telah diseimbangkan distribusi datanya dengan menggunakan *oversampling*, jika dilihat pada Gambar 11 memiliki kondisi performa model yang lebih baik dan termasuk dalam kategori *good fit* hal ini dapat disimpulkan dari kondisi grafik *training loss* dan *validation loss* yang memiliki nilai sama rendahnya serta tidak terdapat *gap* diantara keduanya.



Gambar 10. Accuracy dan Loss pada model dengan *imbalance class*



Gambar 11. Accuracy dan Loss pada model dengan *balance class*

Evaluasi performa lainnya dapat dilihat dengan menggunakan hasil *classification report* dimana jika dilihat pada Gambar 12 nilai *accuracy* pada model yang menggunakan dataset *imbalance* mencapai angka 90%. Sedangkan, performa klasifikasi dari masing-masing kelas yang ditunjukkan dari nilai *precision*, *recall*, dan *f1-score* pada kelas dengan distribusi data minoritas memiliki nilai lebih rendah jika dibandingkan dengan kelas mayoritas lainnya.

Perbedaan performa terlihat berbanding terbalik dengan model yang sebelumnya telah dilakukan *balancing class*. Dimana pada model dengan menggunakan *imbalance class* nilai *precision*, *recall*, dan *f1-score* berturut turut sebesar 73%, 73%, dan 73% pada kelas minoritas yaitu *trash*. Hasil lebih baik ditunjukkan pada Gambar 13 model dengan menerapkan *balancing class* dengan nilai *precision*, *recall*, dan *f1-score* pada kelas kelas yang sama sebesar 93%, 88%, 91%. Dimana nilai

akhir *accuracy* 91% mengalami kenaikan sebesar 1% dari performa model sebelumnya. Perbandingan *accuracy* dapat dilihat secara detail pada Tabel 1.

Tabel 1. Perbandingan Accuracy Sebelum dan Sesudah Balancing Class

Model	Accuracy
Model With Imbalance Class	90%
Model With Balance Class	91%

	precision	recall	f1-score	support
cardboard	0.97	0.88	0.92	41
glass	0.98	0.86	0.92	51
metal	0.89	0.95	0.92	41
paper	0.89	0.93	0.91	60
plastic	0.85	0.92	0.88	49
trash	0.73	0.73	0.73	15
accuracy			0.90	257
macro avg	0.88	0.88	0.88	257
weighted avg	0.90	0.90	0.90	257

Gambar 12. Classification Report model dengan *imbalance class*

	precision	recall	f1-score	support
cardboard	0.98	0.95	0.97	60
glass	0.82	0.92	0.87	60
metal	0.90	0.87	0.88	60
paper	0.94	0.97	0.95	60
plastic	0.90	0.87	0.88	60
trash	0.93	0.88	0.91	60
accuracy			0.91	360
macro avg	0.91	0.91	0.91	360
weighted avg	0.91	0.91	0.91	360

Gambar 13. Classification Report model dengan *balance class*

### 3.2. Performa Metode Ensemble

Metode ensemble pada penelitian ini menggabungkan lima *proposed method* yang memiliki arsitektur seperti pada Gambar 7. Sehingga menghasilkan lima file berekstensi H5 dimana sebelum dilatih telah dilakukan penyeimbangan distribusi data menggunakan *oversampling*. Dari lima pelatihan model dengan arsitektur *proposed method* yang sama didapatkan nilai *accuracy* pada *test set* yang berbeda. Secara detail ditunjukkan pada Tabel 2. Dimana pada pelatihan pertama memiliki nilai *accuracy* paling tinggi yaitu 93% dibandingkan dengan pelatihan setelahnya dengan nilai *accuracy* sebesar 91%.

Tabel 2. Accuracy lima model

Model	Accuracy
Proposed Method_Model 1	93%
Proposed Method_Model 2	91%
Proposed Method_Model 3	91%
Proposed Method_Model 4	91%
Proposed Method_Model 5	91%

Hasil metode ensemble menunjukkan peningkatan yang signifikan setelah dilakukan penggabungan lima model dan melakukan *voting* terhadap hasil prediksi dari keseluruhan model. Dimana hasil akhir klasifikasi merupakan kelas terbanyak yang muncul dari

keseluruhan model. Kenaikan *accuracy* terjadi sebesar 3% hingga 5% dari model tunggal, dengan performa *accuracy* akhir pada metode ensemble sebesar 96%. Sehingga, metode ensemble yang diterapkan mampu meningkatkan *accuracy* pada dua penelitian sebelumnya dengan dataset serupa yang memiliki *accuracy* masing-masing sebesar 93,6% dan 94,9% [7], [9] menjadi 96%. Seiring dengan peningkatan *accuracy* parameter lain juga mengalami peningkatan diantaranya *precision*, *recall*, dan *f1-score* dari masing-masing kelas. Secara detail dapat dilihat pada Gambar 14. Terjadi peningkatan nilai *precision* lima dari enam kelas. Sedangkan, penurunan ditunjukkan pada kelas *glass* sebesar 2%. Hal yang selaras juga ditunjukkan pada *recall* dimana kelas *cardboard*, *glass*, *paper*, *plastic*, dan *trash* mengalami kenaikan sedangkan pada kelas *metal* mengalami penurunan sebesar 2%. Parameter evaluasi terakhir pada *classification report* yaitu *f1-score* dimana mengalami kenaikan pada keseluruhan kelas.

	precision	recall	f1-score	support
cardboard	1.00	1.00	1.00	41
glass	0.96	0.94	0.95	51
metal	0.97	0.93	0.95	41
paper	1.00	0.95	0.97	60
plastic	0.91	1.00	0.95	49
trash	0.94	1.00	0.97	15
accuracy			0.96	257
macro avg	0.96	0.97	0.97	257
weighted avg	0.97	0.96	0.97	257

Gambar 14. Classification Report menggunakan metode ensemble

#### 4. Kesimpulan

Teknik pengenalan citra menggunakan pola CNN (*Convolutional Neural Network*) dengan menggunakan menggunakan metode *transfer learning* DenseNet169 tidak serta merta mampu mengklasifikasikan gambar dengan baik. Preprocessing dataset sebelum dilakukan pelatihan salah satu faktor penting dalam meningkatkan performa klasifikasi dari semua kelas. Dimana pada penelitian ini model yang menerapkan *oversampling* dengan metode augmentasi untuk menyeimbangkan distribusi pada dataset mengalami peningkatan *accuracy* dari 90% ke 91%. Selain peningkatan *accuracy* hasil *precision*, *recall* dan *f1-score* pada kelas minoritas pada hal ini yaitu kelas *trash* juga mengalami hal selaras dimana nilai secara berurutan sebesar 73%, 73%, dan 73% yang kemudian mengalami peningkatan menjadi secara berurutan sebesar 93%, 88%, dan 91%.

Penggunaan metode ensemble yang diterapkan pada model yang sebelumnya telah dilakukan *oversampling*. Dimana pada metode ini menggunakan lima model yang memiliki arsitektur *proposed* model yang sama yang dilatih sebanyak lima kali dengan nilai *accuracy* dari kelima model berturut-turut sebesar 93%, 91%, 91%, 91%, 91%. Setelah diterapkan metode ensemble dengan melakukan *voting* dari hasil prediksi klasifikasi pada masing-masing model didapatkan hasil *accuracy*

sebesar 96%. Dimana meningkat sebanyak 3% hingga 5% dari *single model*. Dengan hasil *accuracy* akhir 96% maka penelitian ini mampu memperbaiki performa model pada penelitian-penelitian sebelumnya.

#### Daftar Rujukan

- [1] Rima Dias Ramadhani, A. Nur Aziz Thohari, C. Kartiko, A. Junaidi, T. Ginanjar Laksana, and N. Alim Setya Nugraha, "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 2, pp. 312–318, 2021, doi: 10.29207/resti.v5i2.2754.
- [2] Y. A. Fatimah, K. Govindan, R. Murniningsih, and A. Setiawan, "Industry 4.0 based sustainable circular economy approach for smart waste management system to achieve sustainable development goals: A case study of Indonesia," *J. Clean. Prod.*, vol. 269, p. 122263, 2020, doi: 10.1016/j.jclepro.2020.122263.
- [3] E. Andina, "Analisis Perilaku Pemilahan Sampah di Kota Surabaya," *Aspir. J. Masal. Sos.*, vol. 10, no. 2, pp. 119–138, 2019, doi: 10.46807/aspirasi.v10i2.1424.
- [4] N. S. Khairunisa and D. R. Safitri, "Integrasi Data Sampah Sebagai Upaya Mewujudkan Zero Waste Management: Studi Kasus Di Kota Bandung," *J. Anal. Sociol.*, vol. 9, pp. 108–123, 2020, doi: 10.20961/jas.v9i0.39829.
- [5] M. Z. Alom *et al.*, "A state-of-the-art survey on deep learning theory and architectures," *Electron.*, vol. 8, no. 3, 2019, doi: 10.3390/electronics8030292.
- [6] S. T. Krishna and H. K. Kalluri, "Deep learning and transfer learning approaches for image classification," *Int. J. Recent Technol. Eng.*, vol. 7, no. 5, pp. 427–432, 2019.
- [7] R. Sultana, R. D. Adams, Y. Yan, P. M. Yanik, and M. L. Tanaka, "Trash and Recycled Material Identification using Convolutional Neural Networks (CNN)," *Conf. Proc. - IEEE SOUTHEASTCON*, vol. 2020-March, 2020, doi: 10.1109/SoutheastCon44009.2020.9249739.
- [8] A. Altikat, A. Gulbe, and S. Altikat, "Intelligent solid waste classification using deep convolutional neural networks," *Int. J. Environ. Sci. Technol.*, no. 0123456789, 2021, doi: 10.1007/s13762-021-03179-4.
- [9] G. Sai Susanth, L. M. Jenila Livingston, and L. G. X. Agnel Livingston, "Garbage Waste Segregation Using Deep Learning Techniques," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1012, p. 012040, 2021, doi: 10.1088/1757-899x/1012/1/012040.
- [10] T. Eelbode, P. Sinonquel, F. Maes, and R. Bisschops, "Pitfalls in training and validation of deep learning systems," *Best Pract. Res. Clin. Gastroenterol.*, vol. 52–53, no. xxxx, p. 101712, 2021, doi: 10.1016/j.bpg.2020.101712.
- [11] J. M. Johnson and T. M. Khoshgoftaar, "Survey on deep learning with class imbalance," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0192-5.
- [12] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [13] M. V. Rao, K. N. V. R. Sekhar, B. Jayanth, and K. Santosh, "An Automatic Garbage Classification System," vol. 8, no. 6, pp. 4–9, 2021.
- [14] C. Shi, C. Tan, T. Wang, and L. Wang, "A waste classification method based on a multilayer hybrid convolution neural network," *Appl. Sci.*, vol. 11, no. 18, 2021, doi: 10.3390/app11188572.
- [15] S. Postalçloğlu, "Performance Analysis of Different Optimizers for Deep Learning-Based Image Recognition," *Int. J. Pattern Recognit. Artif. Intell.*, vol. 34, no. 2, 2020, doi: 10.1142/S0218001420510039.
- [16] S. Dong, P. Wang, and K. Abbas, "A survey on deep learning and its applications," *Comput. Sci. Rev.*, vol. 40, p. 100379, 2021, doi: 10.1016/j.cosrev.2021.100379.
- [17] P. S. Janardhanan, "Project repositories for machine learning with TensorFlow," *Procedia Comput. Sci.*, vol. 171, no. 2019, pp. 188–196, 2020, doi: 10.1016/j.procs.2020.04.020.



- [18] B. Chen, T. Zhao, J. Liu, and L. Lin, "Multipath feature recalibration DenseNet for image classification," *Int. J. Mach. Learn. Cybern.*, vol. 12, no. 3, pp. 651–660, 2021, doi: 10.1007/s13042-020-01194-4.
- [19] H. Zheng and Y. Gu, "Encnn-upmws: Waste classification by a CNN ensemble using the UPM weighting strategy," *Electron.*, vol. 10, no. 4, pp. 1–21, 2021, doi: 10.3390/electronics10040427.
- [20] X. Dong, Z. Yu, W. Cao, Y. Shi, and Q. Ma, "A survey on ensemble learning," *Front. Comput. Sci.*, vol. 14, no. 2, pp. 241–258, 2020, doi: 10.1007/s11704-019-8208-z.
- [21] Y. Azhar, M. C. Mustaqim, and A. E. Minarno, "Ensemble convolutional neural network for robust batik classification," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1077, no. 1, p. 012053, 2021, doi: 10.1088/1757-899x/1077/1/012053.
- [22] Y. Chu, C. Huang, X. Xie, B. Tan, S. Kamal, and X. Xiong, "Multilayer hybrid deep-learning method for waste classification and recycling," *Comput. Intell. Neurosci.*, vol. 2018, 2018, doi: 10.1155/2018/5060857.
- [23] R. Doon, T. Kumar Rawat, and S. Gautam, "Cifar-10 classification using deep convolutional neural network," *1st Int. Conf. Data Sci. Anal. PuneCon 2018 - Proc.*, no. x, pp. 1–5, 2018, doi: 10.1109/PUNECON.2018.8745428.