

Klasifikasi Otomatis Tingkat Kerusakan Retak Bangunan pada Citra Digital Menggunakan *MobileNetV2* dan Augmentasi Data

Ricky Putra Sardika¹, Wijang Widhiarso²

¹Program Studi Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

²Program Studi Magister Sistem Informasi, Universitas Multi Data Palembang, Palembang, Indonesia

Email : rickyputrasardika_2226250129p@mhs.mdp.ac.id, wijang@mdp.ac.id

Article Information

Article history

Received 07 April 2025

Revised 10 May 2025

Accepted 11 June 2025

Available 30 June 2025

Keywords

MobileNetV2

Classification

Data Augmentation

Optimizer

Corresponding Author:

Ricky Putra Sardika,
Universitas Multi Data Palembang,
Email:
rickyputrasardika_2226250129p
@mhs.mdp.ac.id

Abstract

Crack detection in buildings is a crucial step in maintaining structural integrity at an early stage and preventing further damage. This study aims to improve the accuracy of crack severity classification in digital images by applying five on-the-fly data augmentation techniques (flip, rotate, zoom, translation, and contrast) combined with the MobileNetV2 architecture. The augmentation techniques are performed dynamically during the training process without storing the transformed images, making the process more efficient in terms of storage, computation time, and adaptability to data variations. This study utilized a dataset of 900 images and achieved a classification accuracy of 93%, which is higher than the previous approach using MobileNetV1 with offline augmentation that only reached 89%. Previous research was limited to static augmentation approaches and less efficient CNN architectures. This study addresses those limitations by integrating dynamic augmentation and a lightweight architecture. It contributes to enhancing the efficiency and accuracy of crack image classification models in the context of limited data and low-computation systems, with strong potential for implementation in automated detection systems on mobile or edge computing devices.

Keywords : *MobileNetV2, classification, data augmentation, optimizer.*

Abstrak

Deteksi retakan pada bangunan merupakan langkah penting dalam menjaga integritas struktur secara dini dan mencegah kerusakan lebih lanjut. Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi tingkat keparahan retak bangunan pada citra digital dengan menerapkan lima teknik augmentasi data secara *on-the-fly* (*flip, rotate, zoom, translation, dan contrast*) yang dikombinasikan dengan arsitektur *MobileNetV2*. Teknik augmentasi dilakukan secara dinamis selama proses pelatihan tanpa menyimpan hasil transformasi, sehingga lebih efisien dalam hal penyimpanan, waktu komputasi, dan adaptif terhadap variasi data. Penelitian ini menggunakan dataset sebanyak 900 citra dan menghasilkan akurasi klasifikasi sebesar 93%, lebih tinggi dibandingkan pendekatan sebelumnya yang menggunakan *MobileNetV1* dengan augmentasi *offline* yang hanya mencapai 89%. Penelitian terdahulu masih terbatas pada pendekatan augmentasi statis dan arsitektur CNN yang kurang efisien. Penelitian ini mengatasi keterbatasan tersebut dengan mengintegrasikan pendekatan dinamis dan arsitektur ringan. Penelitian ini berkontribusi pada peningkatan efisiensi dan akurasi model klasifikasi citra retakan dalam konteks data terbatas dan sistem komputasi rendah, serta potensinya untuk diimplementasikan dalam sistem deteksi otomatis pada perangkat *mobile* atau *edge computing*.

Kata Kunci : *MobileNetV2, Klasifikasi, Augmentasi Data, Optimizer*

Copyright©2025 Ricky Putra Sardika, Wijang Widhiarso
This is an open access article under the [CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.



1. Pendahuluan

Keberadaan gedung dan rumah bertujuan untuk mendukung tercapainya fungsi utama pemanfaatan ruang secara optimal, termasuk pemenuhan terhadap kebutuhan sarana dan prasarana penunjang (Andi et al., 2023). Salah satu aspek penting yang perlu diperhatikan selama masa penggunaan bangunan adalah kondisi strukturnya, mengingat potensi kerusakan dapat terjadi baik pada bangunan lama maupun bangunan baru. Salah satu bentuk kerusakan yang umum terjadi adalah keretakan, yang umumnya mulai terlihat saat bangunan mulai digunakan. Oleh karena itu, deteksi dini terhadap retakan menjadi penting guna meminimalkan kerusakan lanjutan yang bersifat struktural (Ariyanto, 2020).

Metode deteksi retakan berbasis *image processing* telah dikembangkan untuk mengatasi keterbatasan dari metode konvensional yang kurang efisien dan akurat. Dalam konteks klasifikasi citra menggunakan model *deep learning*, teknik augmentasi data menjadi penting untuk meningkatkan performa model pada tahap pelatihan dengan cara menghasilkan variasi sintetis dari dataset asli melalui transformasi tertentu (Pradika et al., 2020).

Model *deep learning* yang digunakan dalam penelitian ini adalah *MobileNetV2*, yang dirancang untuk kebutuhan komputasi terbatas seperti pada perangkat seluler, karena memiliki ukuran file model dan jumlah parameter yang kecil (Feroza et al., 2023). *MobileNetV2* merupakan pengembangan dari *MobileNetV1*, dengan kemampuan yang ditingkatkan dalam klasifikasi gambar, deteksi objek, dan aplikasi computer vision lainnya. Arsitektur ini mengedepankan efisiensi dan akurasi dengan fitur-fitur seperti *Depthwise Separable Convolution*, *Linear Bottlenecks*, *Global Average Pooling* (GAP), *Inverted Residual Blocks*, dan desain arsitektur yang efisien (Aufar & Kaloka, 2022).

Pada penelitian sebelumnya (Z. Wang et al., 2020) telah menyoroti penggunaan sembilan teknik augmentasi data menggunakan algoritma *greedy* untuk memilih kombinasi terbaik, namun hanya *rotate* yang paling optimal memberikan hasil efektif selama proses pelatihan model berlangsung. Lalu, penelitian (Y. Wang et al., 2022) menerapkan kombinasi teknik segmentasi *MA-Xnet* dan *MobileNetV2* untuk mengurangi jumlah parameter agar detail retakan yang dihasilkan lebih akurat. Namun keterbatasan didalam generalisasi dataset, waktu inferensi dan resistensi terhadap *noise* masih ada sebagai penghambat.

Penelitian sebelumnya (Asriani et al., 2023) menunjukkan beberapa arsitektur perbandingan seperti *MobileNetV1*, *Inception V3*, dan *Resnet-50* dengan teknik augmentasi data secara *offline* seperti *flip*, *rotate*, dan *contrast* untuk klasifikasi jenis keretakan seperti non retak, retak kecil, dan retak besar mendapatkan hasil terbaik dari model *MobileNetV1*.

Berdasarkan hal tersebut, penelitian ini bertujuan untuk menerapkan teknik augmentasi data secara *on-the-fly*, yaitu teknik augmentasi yang dilakukan secara dinamis

selama proses pelatihan tanpa menyimpan citra hasil augmentasi secara eksplisit dengan 5 jenis seperti *rotate*, *flip*, *translation*, *zoom*, dan *contrast*. Lalu teknik ini akan dikombinasikan dengan peningkatan versi arsitektur yang lebih unggul dari penelitian sebelumnya dengan menggunakan *MobileNetV2*. Diharapkan, pendekatan ini dapat meningkatkan model lebih *robust*, efisiensi komputasi cepat dan ringan dan akurasi yang lebih optimal dari penelitian sebelumnya untuk mempermudah dalam proses pengklasifikasian tingkat kerusakan retak bangunan pada citra digital dengan menggunakan arsitektur *MobileNetV2* dan teknik augmentasi data.

2. Kajian Terdahulu

Penelitian yang telah dilakukan (Z. Wang et al., 2020) menggunakan metode augmentasi data dua tahap untuk mendeteksi retakan pada dataset yang kecil. Tahap pertama mengevaluasi sembilan teknik augmentasi yang diterapkan, dengan teknik *rotate* terbukti paling efektif selama pelatihan. Kemudian tahap kedua menerapkan augmentasi juga saat inferensi untuk meningkatkan performa deteksi, menggunakan algoritma *greedy* untuk memilih kombinasi terbaik. Metode ini dapat meningkatkan performa model secara signifikan, mencapai *recall* 96% hanya dengan 20 gambar pelatihan, dan memberikan panduan praktis untuk aplikasi industri dengan data terbatas. Namun dari kesembilan teknik augmentasi data yang dipakai, hanya *rotate* yang efektif selama proses pelatihan model yang diujikan.

Penelitian selanjutnya yang telah dilakukan (Y. Wang et al., 2022) memperkenalkan *MA-Xnet*, model jaringan saraf untuk segmentasi retakan yang lebih efisien. Model ini menggunakan *depth-wise separable convolution* dan *bottleneck residual* untuk mengurangi jumlah parameter, serta mekanisme *dual attention* dengan *cross-skip connection* untuk menangkap detail retakan lebih akurat. Hasil yang didapat pada model tersebut menunjukkan *F1-Score* 90,53% dan *mIoU* 81,32% dengan hanya menggunakan 1/6 parameter dari model aslinya. Namun masih memiliki keterbatasan dalam generalisasi dataset, waktu inferensi dan resistensi terhadap *noise*.

Lalu pada penelitian (Asriani et al., 2023) telah menerapkan beberapa arsitektur antara lain *MobileNetV1*, *Inception V3*, dan *Resnet-50* dengan teknik augmentasi data seperti *flip*, *rotate*, dan *contrast* untuk klasifikasi jenis keretakan seperti non retak, retak kecil, dan retak besar. Dengan ketiga model yang diujikan, hasil *training* dan validasi mendapatkan hasil terbaik dari model *MobileNetV1* dengan akurasi untuk *training* sebesar 0,8924% sedangkan akurasi pada validasi sebesar 0,8899%. Akan tetapi dengan mengimplementasikan teknik augmentasi data secara *offline* yang berarti akan membuat penyimpanan pada *disk memory* bertambah serta variasi dataset menjadi konstan tidak berubah atau bersifat statis. Hal tersebut membuat konsep ringan dan efisiensi dalam komputasi model pada *MobileNet* kurang optimal.

Perbedaan dengan penelitian sebelumnya adalah penelitian ini berkontribusi dalam meningkatkan model arsitektur dari V1 menjadi V2 dan mengimplementasikan kombinasi menggunakan arsitektur *MobileNetV2* dengan lima teknik augmentasi data *on-the-fly* seperti *rotation*, *zoom*, *flip*, *translation*, serta *contrast* yang tidak menambah data secara langsung(*eksplisit*), tetapi akan menerapkan data secara dinamis saat *training*. Tujuannya agar model CNN tidak ada kendala jika memiliki dataset yang minim dan mengurangi risiko terjadinya *overfitting* yang akan membuat model CNN dapat beradaptasi dengan baik(*robust*) pada berbagai variasi data uji baru namun diharap tetap dapat memberikan kecepatan efisiensi pada komputasi, serta akurasi yang tepat.

Keretakan Bangunan

Retak adalah suatu gejala yang diakibatkan oleh suatu sebab atau kombinasi gaya yang bekerja melebihi kapasitas yang dapat diterima oleh komponen material atau bangunan itu sendiri (Aprilyanto & Yohannes, 2023).

Retak pada beton merupakan hal yang bakal terjadi dan tidak dapat dihindari. Suatu bentuk retakan harus diidentifikasi sedini mungkin agar dapat meminimalisir kerusakan yang keberlanjutan. Oleh sebab itu, perlunya mengidentifikasi berbagai macam tipe-tipe keretakan berdasarkan tingkat kerusakannya seperti retak ringan, retak sedang, dan retak berat (Ariyanto, 2020).

Augmentasi Data

Augmentasi data merupakan cara memperbanyak variasi jumlah citra. Augmentasi bertujuan agar model dapat beradaptasi dengan berbagai macam bentuk data baru yang diberikan dan menghindari resiko *underfitting* atau *overfitting* (Putri Ayuni et al., 2023). Adapun jenis-jenis augmentasi data yang akan diterapkan pada penelitian ini sebagai berikut:

1. *Rotation* adalah cara memutar citra secara acak dari rentan 0 hingga 360 derajat searah jarum jam. Bertujuan agar dapat membantu model mengenali objek meskipun dalam orientasi yang berbeda.
2. *Zoom* adalah cara memperkecil ataupun memperbesar citra tanpa mengubah ukuran gambar keseluruhan. Bertujuan agar model dapat mengenali objek dari berbagai skala.
3. *Flip* atau pembalikan adalah cara membalik citra secara vertikal ataupun horizontal. Bermaksud membuat data citra berubah-ubah dalam orientasinya.
4. *Translation* (translasi/pergeseran) adalah cara menggeser citra keatas, kebawah, ke kiri, ataupun kekanan. Bertujuan membantu model mengenali objek yang tidak selalu berada di posisi tengah pada gambar.

5. *Contrast* / kontras adalah cara mengubah terang atau gelapnya pada suatu citra. Bertujuan agar model tetap bekerja dengan baik pada pencahayaan yang bervariasi.

Pengolahan Citra Digital


Pengolahan citra digital merupakan ilmu yang membahas tentang bagaimana cara memanipulasi dan menganalisis gambar seperti meningkatkan kualitas gambar, memilih ciri pentingnya, mengubah gambar, menyimpannya secara efisien, serta mentransmisikannya dengan cepat (Munantri et al., 2020).

Deep Learning

Deep Learning adalah pembelajaran dalam yang dapat membuat komputer untuk belajar secara langsung baik melalui objek gambar, suara, ataupun data lainnya melalui jaringan saraf tiruan yang rumit, karena *deep learning* itu sendiri terinspirasi dari otak manusia (Raup et al., 2022). Maka dari itu jaringan saraf tiruan tersebut bekerja secara kompleks dalam deep learning yang memungkinkan komputer tersebut untuk “melihat” dunia layaknya seperti manusia, mengenali objek secara visual, serta mendeteksi benda disekitarnya (Rizki et al., 2023).

CNN (*Convolutional Neural Networks*)

CNN adalah metode klasifikasi citra yang mumpuni untuk mempelajari fitur-fitur penting didalam citra yang rumit secara mandiri. Kemampuan nya tersebut bergantung pada arsitektur yang digunakan (Prayoga et al., 2023). Arsitektur CNN yang dapat dilihat pada gambar 1.




Gambar 1. Arsitektur CNN

CNN memiliki ciri khusus yakni penggunaan *layer* konvolusi yang mampu menangkap pola dan fitur penting didalam gambar. Walaupun fokus utama CNN ada pada *layer* konvolusinya, CNN juga bisa mengkombinasikan gabungan dari jenis *layer* lain seperti *polling* dan *fully connected layer* untuk membangun model CNN yang lebih kompleks, dan biasa dikenal dengan sebutan *deep CNN* (UNGKAWA & HAKIM, 2023).

MobileNetV2

Arsitektur *MobileNet* merupakan salah satu dari arsitektur CNN yang dibuat khusus untuk *embedded vision application* dan perangkat *mobile*. Yang berarti memiliki keunggulan utama pada efisiensinya. *MobileNet* tersebut hanya membutuhkan daya komputasi serta memori yang lebih sedikit dibandingkan dengan arsitektur CNN lainnya seperti *VGG* atau *ResNet*. Hal itu dikarenakan arsitektur ini menggunakan *depthwise separable convolution*, yaitu suatu teknik yang memecah proses konvolusi standar menjadi dua langkah: *pointwise convolution* dan *depthwise convolution* (Fuadi & Suharso, 2022).

Pada arsitektur *MobileNetV2* merupakan pengembangan evolusi dari *MobileNetV1*, yang memiliki 2 fitur diantara lain *Linear Bottleneck* dan *Shortcut Connection* antar *Bottleneck*. Kedua fitur tersebut yang membuat proses *Training* pada *neural network* bisa berjalan secara lebih efisien dan mendapatkan akurasi yang lebih baik lagi. *MobileNetV2* adalah *pre-trained* model (model yang sudah dilatih) dalam mengklasifikasikan citra dengan menggunakan dataset yang besar. Dengan menggunakan model *pre-trained* tersebut, maka pengembang tidak perlu membangun atau melatih model dari awal sehingga tidak memakan waktu.




Gambar 2. Arsitektur *MobileNetV2*

Ada dua operasi dalam *MobileNet*, yakni *Depthwise Convolution* (DW) dan *Pointwise Convolution* (PW). Yang pertama dipakai untuk *residual block* sedangkan yang kedua untuk *down sizing*. Intinya model *MobileNetV2* pada setiap block nya memiliki *layer*, dan jika ditotal kan terdapat ± 150 *Layer* (Pane, 2024).

3. Metodologi Penelitian

Bagian ini membahas secara lengkap tentang langkah-langkah yang akan dilakukan dalam melakukan penelitian dimulai dari perumusan permasalahan hingga pengambilan kesimpulan. Diagram alir proses penelitian yang akan dilakukan telah dirancang kedalam bentuk flowchart seperti pada gambar 3.



Gambar 3. Tahapan Metodologi Penelitian

1. Identifikasi Masalah

Tahap ini merupakan langkah awal yang mendukung terbentuknya kegiatan penelitian ini. Topik masalah yang mendasari penelitian ini adalah bagaimana cara mengklasifikasikan tingkat kerusakan keretakan bangunan citra digital kedalam berbagai jenis seperti retak ringan, retak sedang, dan retak berat menggunakan MobilenetV2 dengan teknik augmentasi data

2. Studi Literatur

Tahapan ini bertujuan untuk mencari referensi atau solusi dari perumusan topik masalah yang telah diangkat pada penelitian ini, yakni dapat berupa buku, skripsi, jurnal ataupun karya ilmiah terdahulu lainnya yang memiliki topik bahasan masalah yang sama.

3. Pengumpulan *Dataset*

Penelitian ini membutuhkan dataset dan pengumpulan dataset yang digunakan berasal dari kaggle.com bersifat publik yang berisikan 40.000 citra retak berformat jpg dengan ukuran 227x227. Dataset tersebut dibagi 2 jenis folder yakni 20.000 untuk retak positif dan 20.000 untuk retak negatif.

Tabel 1. Informasi *Dataset Citra Retak Kaggle*

<i>Dataset</i>	Sumber	Format	Ukuran	Jumlah <i>Dataset</i>		Total
				Retak Positif	Retak Negatif	
Retakan	<i>Kaggle</i>	JPG	227x227	20.000	20.000	40.000

Namun hanya akan diambil dan digunakan sebanyak 900 citra yang berasal dari folder retak positif. Pembagian dataset tersebut di pisahkan secara manual dan dibagi rata sehingga terbentuk 300 citra untuk retak ringan, 300 citra untuk retak sedang, dan 300 citra untuk retak berat.

Tabel 2. Informasi *Dataset Citra Retak Yang Digunakan*

No	Retak Positif		
	Retak Ringan	Retak Sedang	Retak Berat
1	300	300	300
Total	900		

Tabel 3. Informasi Pembagian *Dataset Citra Retak*


No	Pembagian <i>Dataset</i>		
	Data Latih	Data Validasi	Data Uji
1	70%	15%	15%
2	630	135	135
Total <i>Citra Asli</i>	900		
Total <i>epoch</i> (Set Awal <i>epoch</i> = 40)	37 <i>epoch</i> * 630		
Total Keseluruhan Data Latih Setelah di Augmentasi	23.310		

Dikarenakan peneliti menggunakan teknik augmentasi data secara *on-the-fly* yang berarti jumlah data latih tersebut bergantung dari jumlah *epoch* yang digunakan. Hanya model yang bisa melihat kombinasi secara acak dari teknik augmentasi data tersebut karena tidak bersifat *eksplisit* tanpa harus menyimpan *file* nya selama proses pelatihan

model sehingga menghemat penyimpanan *memory* dengan efisiensi komputasi yang ringan nan cepat. Dengan menerapkan *optimizer ADAM* dan *SGD*, *learningRate*, dan *epoch* sebagai *hyperparameter* yang akan dipergunakan untuk mengklasifikasi jenis retak menggunakan model *MobileNetV2* dengan teknik augmentasi *on-the-fly* nantinya.

4. Perancangan

Pada tahap perancangan akan dibahas mengenai cara dataset diolah hingga terbentuknya model *MobileNetV2* agar dapat mengklasifikasikan jenis keretakan *citra* bangunan berdasarkan tingkat kerusakannya. Skema perancangan yang telah dibuat dapat dilihat pada Gambar 4.



Gambar 4. Skema Perancangan Model *MobileNetV2*

Dataset sebanyak 900 citra retak di upload dan dibuat folder secara terpisah berdasarkan kelasnya. Kemudian dataset tersebut di *preprocessing* melalui dua tahap yakni *resize* berukuran 224x224 dan *rescale* normalisasi data menjadi [0, 1]. Lalu akan dilakukan split data menjadi tiga bagian yakni data latih, data validasi, dan data uji. Untuk

melakukan teknik augmentasi data *on-the-fly*, harus dilakukan pada data latih agar model tetap *robust* beradaptasi dengan berbagai variasi keadaan dari data asli dilapangan.

Selanjutnya tahap *modelling* atau pelatihan model yang dilakukan dari data latih yang telah ditambahkan teknik augmentasi data dengan bantuan data validasi untuk mengevaluasi kinerja model agar tidak *under/overfitting*. *Optimizer ADAM* akan digunakan juga sebagai penunjang model dalam memperbaiki bobot jika terjadi *under/overfitting* dengan *learningRate* sebesar 0,001 dan 40 *epoch*.

Jika model telah terbentuk, dilakukan tahap pengujian model untuk melihat kinerja nya dalam mengklasifikasi jenis keretakan tersebut menggunakan data testing yang telah disediakan sebelumnya. Lalu akan muncul hasil klasifikasi jenis keretakan dan selesai.

5. Implementasi

Tahapan ini adalah proses penerapan untuk membuat rancangan sebelumnya menjadi kenyataan agar dapat mengklasifikasikan jenis retak citra bangunan tersebut dengan menggunakan model *MobileNetV2* dengan teknik augmentasi data *on-the-fly*.

6. Pengujian

Setelah tahapan uji coba, hasil pengujian dihitung untuk mendapatkan tingkat keberhasilan, dengan metode yang digunakan adalah *Confusion Matrix* dalam menghitung nilai *precision* yang dapat dilihat pada Persamaan (3), dan nilai *recall* pada Persamaan (4), kemudian Persamaan (5) untuk menghitung nilai *accuracy*.

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (5)$$

Keterangan:

TP: Jumlah data positif (*defect*) yang terklasifikasi dengan benar oleh sistem

TN: Jumlah data negatif (*non-defect*) yang terklasifikasi dengan benar oleh sistem

FN: Jumlah data negatif (*non-defect*) yang terklasifikasi dengan salah oleh sistem

FP: Jumlah data positif (*defect*) yang terklasifikasi dengan salah oleh sistem

4. Hasil dan Pembahasan

Pada tahap ini, peneliti akan menjabarkan secara komprehensif mengenai penerapan augmentasi data *on-the-fly* kedalam arsitektur *MobileNetV2* untuk mengklasifikasikan tingkat kerusakan retak bangunan pada *citra* digital menggunakan *optimizer ADAM*, *learningRate*, dan *epoch* sebagai *hyperparameter* selama proses *modelling*.

Melalui analisis ini, peneliti akan menunjukkan seberapa efektif *tuning hyperparameter* dari yang telah dibahas sebelumnya. Hasil dan pembahasan ini penulis harapkan dapat menjadi referensi untuk memperdalam pemahaman tentang metode yang efektif dalam menyelesaikan studi kasus yang dibahas pada topik penelitian kali ini.

4.1 ADAM

Penelitian ini sangat berfokus untuk meneliti arsitektur *MobileNetV2* dengan menerapkan teknik augmentasi *on-the-fly* menggunakan *optimizer* terbaiknya dalam topik klasifikasi retak pada *citra* bangunan berdasarkan penelitian (Aprilyanto & Yohannes, 2023) yang telah dikaji sebelumnya. Hasil yang didapat menggunakan *optimizer ADAM* dapat dilihat pada tabel 4, tabel 5 dan tabel 6.

Tabel 4. Hasil *Optimizer ADAM* Berdasarkan *LearningRate* 0,1



<i>Optimizer</i>	Set Awal <i>Epoch</i>	<i>LearningRate</i>	Akurasi	<i>Epoch</i> Akhir Berhenti
ADAM	20	0,1	91,73%	14
ADAM	30	0,1	91,11%	11
ADAM	40	0,1	85,93%	9

Tabel 5. Hasil *Optimizer ADAM* Berdasarkan *LearningRate* 0,01

<i>Optimizer</i>	Set Awal <i>Epoch</i>	<i>LearningRate</i>	Akurasi	<i>Epoch</i> Akhir Berhenti
ADAM	20	0,01	88,15%	13
ADAM	30	0,01	88,15%	8
ADAM	40	0,01	88,15%	12

Tabel 6. Hasil *Optimizer ADAM* Berdasarkan *LearningRate* 0,001


<i>Optimizer</i>	Set Awal <i>Epoch</i>	<i>LearningRate</i>	Akurasi	<i>Epoch</i> Akhir Berhenti
ADAM	20	0,001	89,63%	Full (20)
ADAM	30	0,001	91,85%	26
ADAM	40	0,001	92,59%	37
ADAM	50	0,001	90,37%	29


Gambar 5. Tampilan Hasil Grafik Akurasi *ADAM* Saat *Training* Model *MobileNetV2*

Gambar 6. Tampilan Hasil Grafik *Loss ADAM* Saat *Training* Model *MobileNetV2*

Pada gambar 5 dan 6 menampilkan bentuk grafik hasil akurasi serta *loss* selama proses *modelling* berlangsung menggunakan *ADAM*. Pelatihan model berjalan dengan sangat baik karena nilai per *epoch* tidak menunjukkan selisih yang signifikan antara *training* dengan *validation* yang berarti model *MobileNetV2* dengan teknik augmentasi data secara *on-the-fly* tidak mengalami *under/overfitting*. Sehingga model telah mempelajari data dengan sangat baik yang dibuktikan dengan data *validation* dan *testing*.

```
[8]: # ===== STEP 6: EVALUASI AKHIR =====  
  
loss, accuracy = model.evaluate(test_gen)  
print(f"\n✅ Akurasi Test Set: {accuracy*100:.2f}%")  
  
5/5 ----- 4s 697ms/step - accuracy: 0.9280 - loss: 0.2210  
  
✅ Akurasi Test Set: 92.59%
```

Gambar 7. Tampilan Hasil Evaluasi Akhir *ADAM* Saat *Testing* Model *MobileNetV2*



Gambar 8. Tampilan *Confusion Matriks* Menggunakan *ADAM*

Dengan hasil *confusion matriks* tersebut, *optimizer ADAM* membantu model dalam mengklasifikasikan jenis keretakan dengan sangat baik dan menghasilkan akurasi yang cukup tinggi sebesar 93%.

4.2 Perbandingan Penelitian Terdahulu

Setelah didapat hasil terbaik pada penelitian ini dengan menggunakan *MobileNetV2* dan kelima teknik augmentasi data secara *on-the-fly* sebesar 93%. Maka penulis akan membandingkan hasil tersebut dengan penelitian rujukan yang telah dipilih. Hasil tersebut dapat dilihat pada tabel 8.

Tabel 8. Perbandingan Hasil

Metode	Arsitektur	Teknik Augmentasi Data	Jenis Penerapan	Jumlah Dataset	Akurasi
Jurnal Asriani	<i>MobileNetV1</i>	<i>Flip, Rotate, Contrast</i>	<i>Offline</i>	25.445	89%
Penulis	<i>MobileNetV2</i>	<i>Flip, Rotate, Contrast, Translation, Zoom</i>	<i>On-the-fly</i>	900	93%

Pada Tabel 8 telah memberikan kemajuan terhadap hasil akurasi pada penelitian sebelumnya. Peningkatan dengan arsitektur *MobileNetV2* dengan kombinasi tambahan dari kelima teknik augmentasi data secara *on-the-fly* tersebut dinilai sangat signifikan dalam meningkatkan performa model untuk klasifikasi tingkat keparahan retak bangunan pada citra digital. Hal tersebut dikarenakan performa *MobileNetV2* merupakan hasil peningkatan dari *MobileNetV1* karena ada proses tahapan fitur seperti *Inverted Residual* dan *Linier Bottleneck* yang membuat nya cepat dan memiliki akurasi yang tinggi. Lalu augmentasi data secara *on-the-fly* membuat model tersebut lebih *robust* terhadap kondisi dari variasi data tanpa adanya kemungkinan *overfitting* dan tidak perlu membutuhkan *disk* penyimpanan sebagai penampung dataset augmentasi yang malah membuat kinerja selama proses pelatihan akan lama.

Namun, penelitian ini memiliki beberapa keterbatasan yang perlu dipertimbangkan. Pertama dari segi pengolahan pada dataset, jika penerapan kelas dalam klasifikasi ditambah yang akan mempengaruhi total jumlah keseluruhan dataset nantinya, maka performa pelatihan model untuk mengenali pola yang lebih kompleks akan melambat walau tidak secara signifikan. Kedua, implementasi model arsitektur *MobileNetV2* sangat memerlukan *tuning hyperparameter* yang tepat agar dapat mempertahankan kualitas model selama proses pelatihan berlangsung.

Oleh karena itu, untuk penelitian selanjutnya, disarankan untuk menggunakan arsitektur *MobileNetV3* dengan menambah kelas pada klasifikasinya. Dengan performa *V3* membuat proses aktivasi dan akurasi model meningkat dengan tetap memperhatikan *hyperparameter* yang tepat. Hal tersebut dapat membentuk model yang lebih optimal dengan tujuan agar dapat menyesuaikan dengan kondisi nyata di lapangan nantinya.

5. Kesimpulan

Hasil penelitian berhasil menunjukkan bahwasanya penerapan arsitektur *MobileNetV2* yang dikombinasikan dengan lima teknik augmentasi data secara *on-the-fly* (*flip*, *rotate*, *zoom*, *translation*, dan *contrast*) mampu meningkatkan akurasi untuk klasifikasi tingkat keparahan retak bangunan pada citra digital hingga 93%. Hasil tersebut menunjukkan peningkatan yang signifikan dibandingkan penelitian sebelumnya yang menggunakan arsitektur *MobileNetV1* dan augmentasi *offline* dengan akurasi yang diperoleh sebesar 89%.

Keunggulan performa model didukung oleh pemanfaatan CNN modern dengan efisiensi fitur arsitektur *MobileNetV2* melalui mekanisme *Inverted Residual* dan *Linear Bottleneck*, serta kombinasi dari augmentasi secara *on-the-fly* yang memungkinkan pelatihan model berlangsung lebih optimal dan adaptif tanpa menimbulkan beban penyimpanan ataupun risiko *overfitting*. Sehingga sangat potensial untuk diaplikasikan dalam sistem deteksi kerusakan otomatis pada infrastruktur bangunan, terutama di perangkat *mobile* atau *edge computing*.

Keterbatasan dari penelitian ini tentu ada jika jumlah kelas klasifikasi ditambah akan berpengaruh dalam kecepatan komputasi selama pelatihan karena jumlah dataset nya semakin banyak. Selain itu kebutuhan terhadap *tuning hyperparameter* yang optimal untuk menjaga stabilitas performa model. Cakupan data klasifikasi dalam pengembangan lebih jauh seperti penambahan nama keretakan berdasarkan jenis tingkat kerusakan yang telah dideteksi belum diuji secara menyeluruh.

Secara keseluruhan, hasil penelitian ini telah memberikan dampak yang signifikan dalam pengembangan sistem klasifikasi kerusakan bangunan yang efisien dan akurat. Temuan ini membuka peluang besar untuk pengembangan sistem pemantauan otomatis lebih lanjut berbasis citra digital di lingkungan nyata dan dapat menjadi pondasi penting untuk penelitian kedepan dengan kompleksitas yang lebih luas.

6. Ucapan Terima Kasih

Kami mengucapkan rasa syukur terhadap Tuhan YME serta terima kasih kepada semua pihak terutama kepada *co-author* dan lembaga Universitas Multi Data Palembang karena telah mendukung dalam penelitian ini.

7. Pernyataan Penulis

Penulis menyatakan bahwa tidak ada konflik kepentingan terkait publikasi artikel ini. Penulis menyatakan bahwa data dan makalah bebas dari plagiarisme serta penulis bertanggung jawab secara penuh atas keaslian artikel.

Bibliografi

- Andi, A., Mahendra, B., & Ridwan, M. (2023). Perencanaan Konstruksi Bangunan Gedung Enam Lantai. *Akselerasi: Jurnal Ilmiah Teknik Sipil*, 5(1), 66–73.
- Aprilyanto, J., & Yohannes, Y. (2023). Implementasi Arsitektur VGG-Unet Dalam Melakukan Segmentasi Keretakan pada Citra Bangunan. *MDP Student Conference*, 2(1), 257–264. <https://doi.org/10.35957/mdp-sc.v2i1.4311>
- Ariyanto, A. S. (2020). ANALISIS JENIS KERUSAKAN PADA BANGUNAN GEDUNG BERTINGKAT (Studi Kasus pada Gedung Apartemen dan Hotel Candiland Semarang). *Bangun Rekaprima*, 6(1), 45. <https://doi.org/10.32497/bangunrekaprima.v6i1.1929>
- Asriani, F., Pamudji, G., Susilawati, H., & Anggoro, F. T. (2023). Aplikasi Convolutional Neural Networks (CNN) Untuk Klasifikasi Retakan Beton. *Dinamika Rekayasa*, 19(1), 9–17. <http://dinarek.unsoed.ac.id>
- Aufar, Y., & Kaloka, T. P. (2022). Robusta coffee leaf diseases detection based on MobileNetV2 model. *International Journal of Electrical and Computer Engineering*, 12(6), 6675–6683. <https://doi.org/10.11591/ijece.v12i6.pp6675-6683>
- Feroza, A. Z., Adiwijaya, N. O., & Putra, B. T. W. (2023). Development of a Web-based Application by Employing a Convolutional Neural Network (CNN) to Identify Pests and Diseases on Pakcoy (*Brassica rapa* subsp. *chinensis*). *Pertanika Journal of Science and Technology*, 31(6), 2873–2885. <https://doi.org/10.47836/pjst.31.6.13>
- Fuadi, A., & Suharso, A. (2022). Perbandingan Arsitektur Mobilenet Dan Nasnetmobile Untuk Klasifikasi Penyakit Pada Citra Daun Kentang. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(3), 701–710. <https://doi.org/10.29100/jupi.v7i3.3026>
- Munantri, N. Z., Sofyan, H., & Florestiyanto, M. Y. (2020). Aplikasi Pengolahan Citra Digital Untuk Identifikasi Umur Pohon. *Telematika*, 16(2), 97. <https://doi.org/10.31315/telematika.v16i2.3183>
- Pane, N. A. (2024). Klasifikasi Kerusakan Pada Ban Menggunakan CNN Dengan Arsitektur MobileNet. *Universitas Medan Area*.
- Pradika, S. I., Nugroho, B., & Puspaningrum, E. Y. (2020). Pengenalan Tulisan Tangan Huruf Hijaiyah Menggunakan Convolution Neural Network Dengan Augmentasi Data. *Prosiding Seminar Nasional Informatika Bela Negara*, 1, 129–136. <https://doi.org/10.33005/santika.v1i0.35>
- Prayoga, A., Maimunah, Sukmasetya, P., Muhammad Resa Arif Yudianto, & Rofi Abul Hasani. (2023). Arsitektur Convolutional Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta. *Journal of Applied Computer Science and Technology*, 4(2), 82–89. <https://doi.org/10.52158/jacost.v4i2.486>

- Putri Ayuni, D., Jasril, Irsyad, M., Yanto, F., & Sanjaya, S. (2023). Augmentasi Data Pada Implementasi Convolutional Neural Network Arsitektur Efficientnet-B3 Untuk Klasifikasi Penyakit Daun Padi. *ZONAsi: Jurnal Sistem Informasi*, 5(2), 239–249. <https://doi.org/10.31849/zn.v5i2.13874>
- Raup, A., Ridwan, W., Khoeriyah, Y., Supiana, S., & Zaqiah, Q. Y. (2022). Deep Learning dan Penerapannya dalam Pembelajaran. *JIIP - Jurnal Ilmiah Ilmu Pendidikan*, 5(9), 3258–3267. <https://doi.org/10.54371/jiip.v5i9.805>
- Rizki, F., Kharisma Putra, M. P., Assuja, M. A., & Ariany, F. (2023). Implementasi Deep Learning Lenet Dengan Augmentasi Data Pada Identifikasi Anggrek. *Jurnal Informatika Dan Rekayasa Perangkat Lunak*, 4(3), 357–366. <https://doi.org/10.33365/jatika.v4i3.3652>
- UNGKAWA, U., & HAKIM, G. AL. (2023). Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(3), 731. <https://doi.org/10.26760/elkomika.v11i3.731>
- Wang, Y., Wang, J., Wang, C., Wen, X., Yan, C., Guo, Y., & Cao, R. (2022). MA-Xnet: Mobile-Attention X-Network for Crack Detection. *Applied Sciences (Switzerland)*, 12(21). <https://doi.org/10.3390/app122111240>
- Wang, Z., Yang, J., Jiang, H., & Fan, X. (2020). CNN training with twenty samples for crack detection via data augmentation. *Sensors (Switzerland)*, 20(17), 1–17. <https://doi.org/10.3390/s20174849>