

Evaluasi Efektivitas Teknik Regularisasi Dalam Mengurangi Overfitting pada Model CNN

Stefanus Eko Prasetyo¹, Haerrudin², Elvis^{3*}

¹²³ Teknologi Informasi, Ilmu Komputer, Universitas Internasional Batam, Batam, Indonesia

¹ stefanus@uib.ac.id, ² haerrudin@uib.ac.id, ^{3*} 2232068.elvis@uib.edu

ABSTRACT – This research aims to evaluate and compare the effectiveness of various regularization techniques, such as L1 and L2 regularization, dropout, and data augmentation, both individually and in combination, in addressing overfitting in Convolutional Neural Network (CNN) models within limited dataset scenarios. Dataset limitation is a major challenge that causes CNN models to tend toward overfitting, where the performance on training data 97.95% accuracy significantly exceeds the validation accuracy 67%. This study utilizes a consistent basic CNN architecture and the CIFAR-10 dataset. The results for individual regularization techniques show that data augmentation is the most optimal technique in separate testing. The model with data augmentation achieved the highest validation accuracy of 78.18% and the lowest generalization gap of 2.31% among all tested techniques. Meanwhile, it was found that using extreme regularization rates in L1/L2 techniques can lead to underfitting because weights are forced toward zero, causing the model to lose its learning capacity. The most superior model performance was achieved through a combined approach. The combination of data augmentation and L2 regularization yielded the highest validation accuracy of 79.89% with the smallest generalization gap of 0.38%. Thus, it is concluded that a combination of regularization techniques is the most effective strategy for improving CNN model generalization in environments with limited datasets.

Keywords: Convolutional Neural Network; CIFAR-10; Data Augmentation; Generalization Gap Overfitting; Regularization Techniques.

ABSTRAK – Penelitian ini bertujuan mengevaluasi dan membandingkan efektivitas berbagai teknik regularisasi seperti regularisasi L1 dan L2, *dropout*, dan augmentasi data, baik secara terpisah maupun kombinasi, dalam mengatasi *overfitting* pada model *Convolutional Neural Network* (CNN) dalam skenario *dataset* terbatas. Keterbatasan *dataset* merupakan tantangan utama yang menyebabkan model CNN cenderung mengalami *overfitting*, di mana performa pada data pelatihan 97.95% akurasi jauh melebihi akurasi validasi 67%. Penelitian ini menggunakan arsitektur CNN dasar yang konsisten dan *dataset* CIFAR-10. Hasil pengujian teknik regularisasi tunggal menunjukkan bahwa augmentasi data adalah teknik yang paling optimal pada pengujian terpisah. Model dengan augmentasi data mencapai akurasi validasi tertinggi 78.18% dan kesenjangan generalisasi terendah 2.31% di antara semua teknik yang diuji. Sementara itu, ditemukan bahwa penggunaan tingkat regularisasi yang terlalu ekstrem pada teknik regularisasi L1/L2 dapat menyebabkan *underfitting* karena bobot dipaksa mendekati nol sehingga model kehilangan kapasitas belajar. Pencapaian kinerja model yang paling superior diperoleh melalui pendekatan kombinasi. Kombinasi antara augmentasi data dan regularisasi L2 menghasilkan akurasi validasi tertinggi sebesar 79.89% dengan kesenjangan generalisasi paling kecil, yaitu 0.38%. Dengan demikian, disimpulkan bahwa pendekatan kombinasi teknik regularisasi adalah strategi paling efektif untuk meningkatkan generalisasi model CNN pada lingkungan dengan *dataset* terbatas.

Kata Kunci: Convolutional Neural Network; CIFAR-10; Data Augmentation ; Generalization Gap; Overfitting; Regularization Techniques.

1. PENDAHULUAN

Pengembangan *Convolutional Neural Network* (CNN) bermula dari upaya mereplika sistem penglihatan biologis. Konsep fundamental CNN berakar dari penelitian terhadap korteks visual otak kucing [1], yang menginspirasi pengembangan jaringan saraf tiruan yang menyerupai sistem penglihatan, menghasilkan model CNN awal seperti LeNet-5 pada tahun 1998 [2].

Akan tetapi, kinerja model awal kurang optimal pada gambar yang kompleks karena keterbatasan efisiensi komputasi perangkat keras saat itu. Akibatnya, CNN sempat dikalahkan oleh metode *machine learning* lainnya.

Kebangkitan CNN sebagai teknologi dominan untuk tugas klasifikasi, segmentasi, dan deteksi objek, terjadi berkat terobosan AlexNet pada tahun 2012 yang mengimplementasikan operasi konvolusi di atas GPU (*Graphics Processing Unit*). Langkah ini secara drastis meningkatkan efisiensi komputasi, mengatasi masalah keterbatasan daya komputasi [3].

Kebutuhan daya komputasi yang tinggi ini berbanding lurus dengan kebutuhan model CNN akan *dataset* pelatihan yang masif dan beragam untuk mempelajari fitur gambar secara efektif. Kebutuhan data



tersebut esensial dikarenakan semakin besar kompleksitas model dan semakin tinggi kerumitan tugas yang ingin dicapai, semakin banyak data serta daya komputasi yang dibutuhkan [4], [5], [6].

Sayangnya, keterbatasan *dataset* akan membuat CNN cenderung mengalami *overfitting*. *Overfitting* adalah situasi di mana model memiliki performa yang sangat baik pada *dataset* pelatihan, namun kinerjanya menjadi buruk ketika digunakan pada *dataset* yang belum pernah dilihat. Hal ini dikarenakan model tidak mampu melakukan generalisasi dengan baik selama proses latihan [7], [8].

Kondisi ini menjadi tantangan utama dalam pengembangan model CNN di lingkungan dengan *dataset* terbatas [9]. Untuk mengurangi tingkat *overfitting* dan meningkatkan generalisasi, berbagai teknik regularisasi telah dikembangkan seperti, regularisasi L1 (*Lasso*) dan L2 (*Ridge*), *dropout*, dan augmentasi data. Variasi teknik yang beragam ini menimbulkan pertanyaan mendasar seperti teknik mana yang paling optimal untuk skenario *dataset* terbatas? Selain itu, bagaimana potensi kombinasi dari teknik-teknik tersebut? Oleh karena itu, penelitian ini bertujuan untuk menguji dan membandingkan performa teknik regularisasi secara terpisah dan dikombinasikan dalam meningkatkan generalisasi model CNN pada *dataset* terbatas.

2. DASAR TEORI

A. Convolutional Neural Network

Kelas khusus dari arsitektur *deep learning* yang dirancang untuk memproses data dengan topologi yang berbentuk *grid*. CNN berkerja melalui tiga jenis lapisan utama, yaitu lapisan konvolusional, lapisan *pooling*, dan lapisan *fully connected*. Keunggulan utama CNN terletak pada kemampuannya melakukan ekstraksi fitur secara otomatis melalui *kernel* yang mampu mengidentifikasi pola spasial seperti tepi, tekstur, dan bentuk. Namun, karena kepadatan parameter yang tinggi terutama pada lapisan *fully connected* CNN secara inheren rentan terhadap variasi yang tinggi, sehingga cenderung menghafal *noise* pada data pelatihan daripada mempelajari fitur yang dapat digeneralisasi ketika jumlah data terbatas [2], [10]

B. Overfitting

Overfitting adalah masalah mendasar dalam *machine learning* di mana sebuah model mencapai akurasi tinggi pada data pelatihan, namun gagal memberikan performa yang baik pada data validasi yang belum pernah dilihat sebelumnya. Hal ini terjadi karena model cenderung menghafal *dataset* daripada belajar fitur spasial sehingga menghasilkan kemampuan generalisasi yang buruk [11].

C. L1 Regularization

Regularisasi L1 merupakan bagian dari regularisasi struktural yang beroperasi dengan membatasi parameter internal model selama fase pelatihan. Teknik ini, yang sering disebut sebagai bagian dari penghalusan bobot, bekerja dengan cara menambahkan istilah penalti ke dalam fungsi *loss* berdasarkan besaran bobotnya. Secara spesifik, regularisasi L1 mendorong terjadinya sparsitas

dengan memaksa bobot-bobot yang kurang signifikan mendekati nilai nol [12], [13].

D. L2 Regularization

Regularisasi L2 juga merupakan bentuk regularisasi struktural yang membatasi parameter internal model melalui penambahan penalti pada fungsi *loss* selama proses pelatihan. Berbeda dengan L1, regularisasi L2 lebih menekankan pada penghalusan bobot (*weight smoothing*). Tujuan utamanya adalah untuk mencegah satu neuron individu memberikan pengaruh yang tidak proporsional terhadap *output* model, sehingga menjaga stabilitas prediksi [6], [7].

E. Dropout

Dropout berfungsi sebagai teknik stokastik dalam kategori regularisasi struktural yang secara acak menonaktifkan neuron selama fase pelatihan. Prosedur ini dilakukan untuk mencegah terjadinya adaptasi yang kompleks antar neuron. Dengan demikian, *dropout* memastikan bahwa setiap neuron tidak menjadi terlalu bergantung satu sama lain dalam merepresentasikan fitur tertentu [14], [15].

F. Data Augmentation

Regularisasi pada tingkat data melalui augmentasi data berfokus pada peningkatan kualitas dan volume *dataset* daripada mengubah arsitektur model. Strategi ini meningkatkan ukuran dan keberagaman *dataset* pelatihan secara buatan dengan menerapkan berbagai transformasi acak, seperti rotasi, pergeseran, dan pembalikan horizontal. Dengan memaparkan jaringan pada variasi tersebut, augmentasi data memaksa model untuk mempelajari invariansi spasial, yang memastikan bahwa identitas suatu objek dikenali secara konsisten tanpa memedulikan orientasi atau posisinya di dalam bingkai [16], [17]

3. METODOLOGI


Untuk mereplikasi skenario *dataset* terbatas, penelitian ini menggunakan CIFAR-10, *dataset* berskala kecil. *Dataset* ini terdiri dari 60.000 gambar berwarna berukuran 32x32 piksel yang terbagi ke dalam 10 kelas yang berbeda seperti yang ditunjukkan pada Gambar 1. Hal ini menyebabkan setiap kelas hanya memiliki sekitar 6.000 gambar. Dari total tersebut, dilakukan pembagian sebesar 80% untuk pelatihan dan 20% untuk validasi. Pembagian ini bertujuan untuk menciptakan kondisi dimana jumlah sampel yang tersedia untuk melatih model menjadi semakin sedikit, sehingga potensi terjadinya *overfitting* meningkat.



Gambar 1. *dataset* CIFAR-10

Setelah penetapan *dataset*, satu arsitektur dasar CNN dirancang dan diterapkan secara konsisten pada seluruh skenario pengujian. Pendekatan ini bertujuan memastikan objektivitas perbandingan dan menghindari bias yang timbul akibat perbedaan arsitektur model.

Selanjutnya, setiap teknik regularisasi akan melalui proses *hyperparameter tuning* untuk mendapatkan konfigurasi optimal yang mampu meningkatkan generalisasi sambil tetap mempertahankan tingkat akurasi validasi yang tinggi. Pada tahap akhir, kinerja setiap skenario diukur dan dianalisis secara komparatif guna menarik kesimpulan mengenai efektivitas dan konfigurasi optimal dari setiap teknik regularisasi yang diuji.




Gambar 2. Flowchart Framework Penelitian

Arsitektur CNN dasar yang dirancang dalam penelitian ini terdiri dari tiga blok konvolusi, yang masing-masing menggunakan filter 3x3. Pemilihan ukuran filter 3x3 didasarkan pada studi terdahulu [18] yang menunjukkan bahwa penggunaan filter konvolusi yang lebih kecil dapat meningkatkan kedalaman jaringan dan mengurangi jumlah parameter model, dibandingkan dengan penggunaan filter 5x5. Setelah blok konvolusi, arsitektur ini diikuti oleh lapisan fully connected untuk tugas klasifikasi sederhana [19]. Proses pelatihan dilakukan sebanyak 100 *epoch* dengan menggunakan *optimizer adam* dengan *learning rate* 0.001 rincian dari arsitektur model disajikan pada Tabel 1 dan Gambar 3.

Tabel 1. Arsitektur Model CNN Dasar

Layer (type)	Output Shape	Param
Conv2D	(None, 30, 30, 32)	896

MaxPooling2D	(None, 15, 15, 32)	0
Conv2D	(None, 13, 13, 64)	18.496
MaxPooling2D	(None, 6, 6, 64)	0
Conv2D	(None, 4, 4, 64)	36.928
Flatten	(None, 1024)	0
Dense	(None, 64)	65.600
Dense (Output)	(None, 10)	650



Gambar 3. Visualisasi Model CNN Dasar

Untuk mengisolasi dan mengukur dampak dari setiap teknik regularisasi, lima skenario pengujian dirancang dan akan dibandingkan secara komparatif. Kelima skenario ini akan diuji menggunakan arsitektur CNN yang sama:

a. Menguji Model Tanpa Teknik Regularisasi

Pada skenario ini, model akan dilatih tanpa menerapkan teknik regularisasi tambahan. Hasil pengujian ini akan digunakan untuk menetapkan tolak ukur kinerja dasar dan tingkat *overfitting* alami yang timbul pada arsitektur CNN yang sama saat dihadapkan pada *dataset* terbatas.

b. Menguji Model dengan *Dropout*

Pada skenario ini, model akan dilatih dengan menambahkan lapisan *dropout*. Lapisan *dropout* akan diaplikasikan setelah lapisan *fully connected* pertama, karena lapisan ini memiliki sejumlah besar parameter dan rentan terhadap *overfitting* [20]. Tingkat *dropout* kemudian akan diuji pada berbagai konfigurasi untuk menemukan tingkat *dropout* yang paling cocok [21], [22].

c. Menguji Model dengan Teknik Regularisasi L1 & L2

Pada skenario ini, model akan mengaplikasikan regularisasi L1 dan L2 pada bobot jaringan [23]. Hal ini bertujuan untuk menguji dampak penekanan bobot yang kurang penting menggunakan L1 dan dampak pencegahan bobot menjadi terlalu besar menggunakan L2 dalam mengurangi tingkat *overfitting* [12].

d. Menguji Model dengan Augmentasi Data

Pada skenario ini, model akan dilatih menggunakan *dataset* yang diperkaya melalui augmentasi data yang berpotensi meningkatkan generalisasi model secara signifikan [24]. Mengingat *dataset* CIFAR-10 berisi objek yang terpengaruh oleh rotasi, maka parameter rotasi diatur pada $\pm 15^\circ$ [25]. Selain itu, diterapkan pula transformasi acak lainnya dalam rentang 10%, meliputi pergeseran gambar secara horizontal maupun vertikal, serta fitur perbesaran dan pengecilan (*zoom-in/out*). Sebagai tambahan, dilakukan pembalikan gambar secara horizontal (*horizontal flip*) secara acak untuk memperkaya variasi sampel selama proses pelatihan.

e. Menguji Model dengan Kombinasi Teknik


Dalam skenario ini, model akan mengaplikasikan kombinasi dua teknik. Kombinasi ini terdiri dari teknik

regularisasi tunggal paling optimal setelah *hyperparameter tuning* dan satu teknik generalisasi lainnya yang diterapkan secara berurutan.

4. HASIL DAN PEMBAHASAN

Bagian Hasil Penelitian ini menyajikan temuan yang diperoleh dari kelima skenario pengujian yang telah dirancang. Metrik kinerja model meliputi *training accuracy* (akurasi latihan), *validation accuracy* (akurasi validasi), dan *generalization gap* (kesenjangan generalisasi) untuk mengukur rasio generalisasi model terhadap data baru, metrik-metrik ini akan disajikan dan dibahas untuk mengukur dampak teknik regularisasi terhadap model CNN dalam upaya mengurangi *overfitting* pada skenario *dataset* terbatas seperti CIFAR-10.


a. Model Tanpa Teknik Regularisasi



Gambar 4. Plot Akurasi untuk Model Tanpa Regularisasi

Hasil pengujian pada Gambar 4. menunjukkan adanya *overfitting* yang ekstrem pada model yang tidak menerapkan teknik regularisasi. Pada *epoch* terakhir, model mencapai akurasi latihan sebesar 97.95% namun hanya menghasilkan akurasi validasi sebesar 67%. Hal ini menandakan bahwa model memiliki kesenjangan generalisasi sebesar 30.95%, yang menegaskan kerentanan model CNN terhadap *overfitting* pada skenario keterbatasan *dataset*.

b. Model dengan *dropout*




Gambar 5. Plot Akurasi untuk Model dengan Dropout

Tabel 2. Metrik untuk Model CNN dengan *Dropout*

Rate	Training Accuracy	Validation Accuracy	Generalization Gap
0.3	92.85%	70.13%	22.72%
0.4	89.99%	70.75%	19.24%
0.5	89.37%	71.47%	17.9%
0.6	87.02%	71.33%	15.69%
0.7	84.94%	69.90%	15.04%
0.8	78.76%	69.85%	8.91%

Berdasarkan Gambar 5 dan Tabel 2, tingkat *dropout rate* yang paling optimal untuk *dataset* CIFAR-10 adalah 0.5. Meskipun tingkat *dropout* 0.6 menawarkan kesenjangan generalisasi yang lebih rendah, tingkat 0.5, dipilih karena menunjukkan akurasi validasi yang sedikit lebih tinggi. Keputusan ini didasarkan pada prinsip bahwa akurasi validasi adalah metrik utama untuk mengevaluasi kinerja model pada data yang belum pernah dilihat. Temuan ini didukung oleh penelitian terbaru [14] yang menunjukkan bahwa *dropout rate* 0.5 yang paling efektif dalam menyeimbangkan dinamika pelatihan dan meningkatkan stabilitas model. Tingkat ini menghasilkan akurasi validasi sebesar 71.47% dan kesenjangan generalisasi sebesar 17.9%. Kinerja ini jauh lebih optimal dalam menekan *overfitting* dan meningkatkan akurasi jika dibandingkan dengan model tanpa teknik regularisasi.

c. Model dengan regularisasi $L1$ dan $L2$




Gambar 6. Plot Akurasi untuk Model dengan $L1$

Tabel 3. Metrik untuk Model dengan $L1$

Rate	Training Accuracy	Validation Accuracy	Generalization Gap
0.00001	95.92%	66.65%	29.72%
0.0001	89.41%	70.29%	19.12%
0.0002	80.30%	70.90%	9.4%
0.0005	68.20%	63.15%	5.05%
0.001	55.54%	51.74%	3.8%

Berdasarkan hasil pengujian yang disajikan pada Gambar 6 dan Tabel 3, tingkat optimal untuk $L1$ ditetapkan pada 0.0002, yang menghasilkan akurasi validasi sebesar 70.90% dengan kesenjangan generalisasi sebesar 9.4%.

Temuan ini menunjukkan bahwa penerapan $L1$ secara signifikan mengurangi kesenjangan generalisasi dibandingkan teknik *dropout*. Hal ini terjadi karena sifat regularisasi $L1$ yang mampu menekan bobot yang kurang relevan menjadi nol, berbeda dengan *dropout* yang bekerja melalui mekanisme pemutusan neuron secara stokastik atau acak. Dengan demikian, regularisasi $L1$ memberikan kontrol yang struktural yang lebih stabil dalam memitigasi *overfitting* pada model ini.




Gambar 7. Plot Akurasi untuk Model dengan $L2$

Tabel 4. Metrik untuk Model dengan $L2$

Rate	Training Accuracy	Validation Accuracy	Generalization Gap
0.00001	96.96%	67.06%	29.9%
0.0001	95.33%	68.45%	26.88%
0.001	82.23%	73.78%	8.45%
0.002	78.65%	73.16%	5.49%
0.005	69.83%	69.06%	0.77%

Berdasarkan hasil pengujian pada Gambar 7 dan Tabel 4, regularisasi $L2$ dengan tingkat optimal 0.001 terbukti lebih unggul dalam menekan *overfitting* dan meningkatkan akurasi dibandingkan teknik *dropout* maupun $L1$, dengan capaian akurasi validasi 73,78% dan kesenjangan generalisasi 8,45%. Keunggulan ini terjadi karena $L2$ menerapkan penghalusan bobot yang mencegah dominasi neuron tertentu tanpa memaksa bobot menjadi nol. Berbeda dengan $L1$ yang membuang bobot tertentu atau *dropout* yang bekerja secara acak, $L2$ menjaga stabilitas fitur dengan mempertahankan distribusi bobot yang merata, sehingga model mampu mempelajari pola data secara konsisten.


d. Model dengan Augmentasi Data



Gambar 8. Plot Akurasi untuk Model dengan Augmentasi Data

Berdasarkan hasil pengujian pada Gambar 8, penggunaan augmentasi data memberikan akurasi validasi sebesar 78.18% dengan kesenjangan generalisasi sebesar 2.31%. Hasil ini menunjukkan bahwa augmentasi data memberikan dampak positif yang jauh lebih signifikan dalam meningkatkan akurasi dan mengurangi *overfitting* dibandingkan teknik regularisasi struktural yang diuji secara terpisah. Temuan ini membuktikan bahwa kuantitas dan keberagaman data lebih menentukan kemampuan generalisasi serta akurasi model, sehingga menegaskan kembali bahwa kualitas *dataset* adalah faktor yang tidak dapat diabaikan dalam membangun model *deep learning* yang kuat.

e. Model dengan Augmentasi Data dan L1




Gambar 9. Plot Akurasi untuk Model dengan Augmentasi Data dan Regularisasi L1

Tabel 5. Metrik untuk Model dengan Augmentasi Data dan L1

Rate	Training Accuracy	Validation Accuracy	Generalization Gap
0.001	49.51%	50.84%	1.33%
0.0005	56.40%	57.18%	0.78%
0.0002	66.01%	69.92%	3.91%
0.00001	78.00%	78.93%	0.93%
0.00002	76.61%	77.92%	1.31%

Berdasarkan hasil pengujian yang disajikan pada Gambar 9 dan Tabel 5, model yang mengimplementasikan kombinasi augmentasi data dan regularisasi L1 dengan tingkat 0.00001 menghasilkan akurasi validasi sebesar 78.93% dan kesenjangan generalisasi yang sangat sempit sebesar 0.93%.

Hasil ini menunjukkan bahwa pendekatan gabungan tersebut lebih unggul dibandingkan dengan teknik augmentasi data yang berdiri sendiri. Meskipun sebelumnya augmentasi data berfungsi sebagai metode individu yang paling efektif, integrasinya dengan regularisasi L1 lebih jauh menyempurnakan performa model dengan menyeimbangkan keragaman data dan batasan bobot struktural secara efektif.




Gambar 10. Plot Akurasi untuk Model dengan Augmentasi Data dan Regularisasi L2

Tabel 6. Metrik untuk Model CNN dengan Augmentasi Data dan L2

Rate	Training Accuracy	Validation Accuracy	Generalization Gap
0.001	71.89%	74.94%	3.05%
0.002	68.11%	70.43%	2.32%
0.005	62.00%	63.61%	1.61%
0.0001	77.37%	79.28%	1.86%
0.00001	79.51%	79.89%	0.38%
0.00002	77.43%	76.17%	1.26%

Berdasarkan hasil pengujian yang disajikan pada Gambar 10 dan Tabel 6, model yang mengimplementasikan kombinasi augmentasi data dan regularisasi L2 dengan tingkat optimal 0.00001 menghasilkan akurasi validasi sebesar 79.89% dan kesenjangan generalisasi minimal sebesar 0.38%. Performa ini terbukti lebih unggul dibandingkan dengan semua skenario yang telah diuji sebelumnya.



Gambar 11. Plot Akurasi untuk Model dengan Augmentasi Data dan Dropout

5. KESIMPULAN

Dalam pengujian teknik regularisasi secara terpisah, augmentasi data terbukti paling optimal dengan menghasilkan akurasi validasi tertinggi 78.18% dan kesenjangan generalisasi terendah 2.31%. Hal ini menunjukkan keseimbangan terbaik antara penekanan *overfitting* dan mempertahankan kapasitas prediksi. Lebih lanjut, penelitian ini menyimpulkan bahwa penggunaan tingkat regularisasi yang terlalu ekstrem pada teknik regularisasi L1/L2 dapat menyebabkan *underfitting* karena bobot dipaksa mendekati nol sehingga model kehilangan kapasitas belajar, sehingga menyoroti pentingnya *hyperparameter tuning* yang cermat.

Pencapaian kinerja model yang paling superior diperoleh melalui pendekatan kombinasi. Kombinasi antara augmentasi data dan regularisasi L2 menghasilkan puncak akurasi validasi tertinggi sebesar 79.89% dengan kesenjangan generalisasi paling kecil, yaitu 0.38%. Oleh karena itu, disimpulkan bahwa pendekatan kombinasi teknik regularisasi adalah strategi paling efektif untuk meningkatkan generalisasi model CNN. Bagi para peneliti dan praktisi yang mengimplementasikan CNN pada *dataset* terbatas, temuan ini menyarankan bahwa menggabungkan transformasi tingkat data dengan batasan bobot struktural sangat penting untuk memaksimalkan akurasi sekaligus memastikan model

Tabel 7. Metrik untuk Model CNN dengan Augmentasi Data dan Dropout

Rate	Training Accuracy	Validation Accuracy	Generalization Gap
0.3	76.61%	77.41%	0.8%
0.4	76.19%	78.15%	1.96%
0.5	74.96%	78.15%	3.19%
0.6	73.15%	77.09%	3.94%
0.7	70.07%	74.80%	4.73%
0.8	65.24%	72.52%	7.28%

Berdasarkan hasil pengujian yang disajikan pada Gambar 11 dan Tabel 7, model yang mengimplementasikan kombinasi augmentasi data dan *dropout* dengan tingkat 0.4 menghasilkan akurasi validasi sebesar 78.15% dengan kesenjangan generalisasi sebesar 1.96%. Meskipun efektif, performa ini tidak melampaui kombinasi augmentasi data dan regularisasi L2, yang berhasil mencapai kesenjangan yang jauh lebih rendah sebesar 0.38%.

Temuan ini menunjukkan bahwa augmentasi dan L2 bersifat sangat komplementer, augmentasi meningkatkan variasi data sementara L2 membatasi kompleksitas model melalui penghalusan bobot. Sebaliknya, kombinasi augmentasi dan dropout tampaknya menimbulkan *noise* stokastik yang berlebihan, yang mengganggu stabilitas fitur di dalam arsitektur CNN pada skenario *dataset* yang terbatas.

tetap kuat terhadap data yang belum pernah dilihat sebelumnya.

DAFTAR PUSTAKA

- [1] D. H. Hubel and T. N. Wiesel, "Receptive fields, binocular interaction and functional architecture in the cat's visual cortex," *J Physiol*, vol. 160, no. 1, pp. 106–154, 1962, doi: 10.1113/jphysiol.1962.sp006837.
- [2] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2323, 1998, doi: 10.1109/5.726791.
- [3] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, "Review of Image Classification Algorithms Based on Convolutional Neural Networks," pp. 1–51, 2021.

- [4] A. Younesi, M. Ansari, M. Fazli, A. Ejlali, M. Shafique, and J. Henkel, "A Comprehensive Survey of Convolutions in Deep Learning: Applications, Challenges, and Future Trends," *IEEE Access*, vol. 12, pp. 41180–41218, 2024, doi: 10.1109/ACCESS.2024.3376441.
- [5] M. C.-L. Elvira G. Rincón-Flores, Gildardo Sanchez-Ante, Ed., "What AI Can Do: Strengths and Limitations of Artificial Intelligence," CRC Press, 2023.
- [6] M. Soni, *Deep Learning*. Poorav Publications, 2024. [Online]. Available: <https://books.google.com.sg/books?id=0fUxEQAAQBAJ>
- [7] Z. Xia, "Overfitting of CNN model in cifar-10: Problem and solutions," *Applied and Computational Engineering*, vol. 37, no. 1, pp. 212–221, Feb. 2024, doi: 10.54254/2755-2721/37/20230511.
- [8] A. Yan and N. Wiliani, "Analisis Pengaruh Dropout Layer pada Convolutional Neural Networks untuk Klasifikasi Gambar Sticky notes," vol. 13, no. 3, pp. 707–714, 2025.
- [9] L. Brigato and L. Iocchi, "A Close Look at Deep Learning with Small Data," Mar. 2020, [Online]. Available: <http://arxiv.org/abs/2003.12843>
- [10] M. Faris and A. Hakim, "CNN model for the small data in vehicle miniature classification," *2023 1st International Conference on Advanced Engineering and Technologies (ICONNIC)*, no. October, pp. 368–372, 2023, doi: 10.1109/ICONNIC59854.2023.10467559.
- [11] C. Aliferis and G. Simon, *Overfitting, Underfitting and General Model Overconfidence and Under-Performance Pitfalls and Best Practices in Machine Learning and AI*. 2024. doi: 10.1007/978-3-031-39355-6_10.
- [12] M. Kitahashi and H. Handa, "Application of Evolutionary Multiobjective Optimization in L1-Regularization of CNN," *2019 IEEE Congress on Evolutionary Computation, CEC 2019 - Proceedings*, pp. 2129–2135, 2019, doi: 10.1109/CEC.2019.8789899.
- [13] V. Vandenbussche and A. O. Kazakci, *The Regularization Cookbook: Explore practical recipes to improve the functionality of your ML models*. Packt Publishing, 2023. [Online]. Available: <https://books.google.com.sg/books?id=gFHNEAAAQBAJ>
- [14] O. Harris, M. Andrews, P. G. Allen, and C. Science, "Effects and results of dropout layer in reducing overfitting with convolutional Neural Networks (CNN)," vol. 13, no. 02, pp. 836–853, 2024, [Online]. Available: <https://doi.org/10.30574/wjaets.2024.13.2.0584>
- [15] J. Brownlee, *Better Deep Learning: Train Faster, Reduce Overfitting, and Make Better Predictions*. Machine Learning Mastery, 2018. [Online]. Available: <https://books.google.com.sg/books?id=T1-nDwAAQBAJ>
- [16] T. Kumar, R. O. B. Brennan, S. Member, A. Mileo, and M. Bendeche, "Image Data Augmentation Approaches : A Comprehensive Survey and Future Directions," vol. 12, no. September, 2024, [Online]. Available: <https://doi.org/10.48550/arXiv.2301.02830>
- [17] A. Mumuni and F. Mumuni, "Data augmentation: A comprehensive survey of modern approaches," *Array*, vol. 16, no. November, p. 100258, 2022, doi: 10.1016/j.array.2022.100258.
- [18] O. M. Khanday, S. Dadvandipour, and M. A. Lone, "Effect of filter sizes on image classification in CNN: A case study on CFIR10 and fashion-MNIST datasets,"

- LAES International Journal of Artificial Intelligence*, vol. 10, no. 4, pp. 872–878, 2021, doi: 10.11591/ijai.v10.i4.pp872-878.
- [19] Purwono, A. Ma'arif, W. Rahmani, H. I. K. Fathurrahman, A. Z. K. Frisky, and Q. M. U. Haq, "Understanding of Convolutional Neural Network (CNN): A Review," *International Journal of Robotics and Control Systems*, vol. 2, no. 4, pp. 739–748, 2022, doi: 10.31763/ijrcs.v2i4.888.
- [20] I. Nathan, "CNN Complexity Reduction," pp. 1–25, 2022, [Online]. Available: <https://arxiv.org/html/2501.15547v1>
- [21] T. Measures, "Evaluating the Learning Procedure of CNNs through a Sequence of Prognostic Tests Utilising Information Theoretical Measures," 2022, [Online]. Available: <https://doi.org/10.3390/e24010067>
- [22] B. A. Skourt, A. El Hassani, and A. Majda, "Mixed-pooling-dropout for convolutional neural network regularization," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 8, pp. 4756–4762, 2022, doi: 10.1016/j.jksuci.2021.05.001.
- [23] Z. Zhu, "Systematic Optimization of Overfitting Problem in Machine Learning," *Highlights in Science, Engineering and Technology*, vol. 111, pp. 353–359, 2024, doi: 10.54097/3tkzrj84.
- [24] L. Nanni, M. Paci, and S. Brahnam, "Comparison of Different Image Data Augmentation Approaches," 2021, [Online]. Available: <https://doi.org/10.3390/jimaging7120254>
- [25] N. Nakamura and D. Maeda, "Efficient Parameters for Rotation Processing of Data Augmentation," no. c, pp. 62–65, 2020, [Online]. Available: https://www.iaria.org/conferences2020/file/eKNOW20/eKNOW_60042.pdf