

**AUGMENTASI PADA ARSITEKTUR GHOSTNET
UNTUK KLASIFIKASI CITRA PRODUK
GROCERY STORE DATASET**

SKRIPSI



**UIN SUNAN AMPEL
S U R A B A Y A**

Disusun Oleh:

**FITRIYA MAWADAH WAROHMAH
09020622027**

**PROGRAM STUDI SISTEM INFORMASI
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL
SURABAYA
2026**

PERNYATAAN KEASLIAN

Saya yang bertanda tangan dibawah ini.

NAMA : FITRIYA MAWAFAH WAROHMAH
NIM : 09020622027
PROGRAM STUDI : SISTEM INFORMASI
ANGKATAN : 2022

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul **“AUGMENTASI PADA ARSITEKTUR GHOSTNET UNTUK KLASIFIKASI CITRA PRODUK GROCERY STORE DATASET”** Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi sesuai dengan ketentuan yang berlaku.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 29 Februari 2026

Yang Menyatakan,



(Fitriya Mawadah Warohmah)

NIM:09020622027

LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

NAMA : FITRIYA MAWADAH WAROHMAH
NIM : 09020622027
JUDUL : AUGMENTASI PADA ARSITEKTUR GHOSTNET
UNTUK KLASIFIKASI CITRA PRODUK GROCERY
STORE DATASET

Ini telah diperiksa dan disetujui untuk diujikan.

Surabaya, 12 Februari 2026

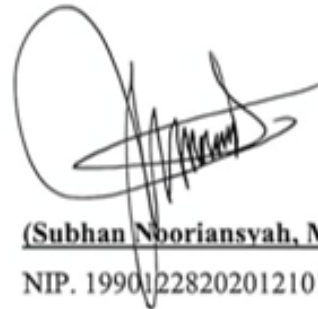
Dosen Pembimbing 1



(Bavu Adhi Nugroho, Ph.D.)

NIP. 197905182014031001

Dosen Pembimbing 2



(Subhan Nboriansyah, M.Kom.)

NIP. 199012282020121010

LEMBAR PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi Fitriya Mawadah Warohmah ini telah dipertahankan

Di depan tim penguji skripsi

Di Surabaya, 09 Maret 2026

Mengesahkan,

Dewan Penguji

Dosen Penguji I



(Khalid, M. Kom)

NIP. 197906092014031002

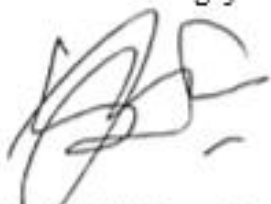
Dosen Penguji II



(Ahmad Yusuf, M. Kom)

NIP. 199001202014031003

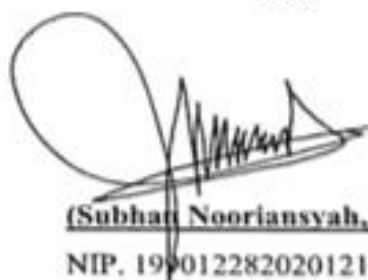
Dosen Penguji III



(Bayu Adhi Nugroho, Ph.D.)

NIP. 197905182014031001

Dosen Penguji IV



(Subhan Nooriansyah, M. Kom.)

NIP. 199012282020121010

Mengetahui,

Dekan Fakultas Sains dan Teknologi

UIN Sunan Ampel Surabaya



(Dr. Asep Saepul Hamdani, M.Pd.)

NIP. 196507312000031002

LEMBAR PERSETUJUAN PUBLIKASI



**KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN**

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpus@uinsby.ac.id

**LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : Fitriya Mawadah Warohmah
NIM : 09020622027
Fakultas/Jurusan : Sains dan Teknologi / Sistem Informasi
E-mail address : fitriyamawadah123@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Sekripsi Tesis Desertasi Lain-lain (.....)

yang berjudul :

Augmentasi pada Arsitektur Ghostnet untuk Klasifikasi Citra
Produk Grocery Store Dataset

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 03- April - 2026

Penulis

(Fitriya Mawadah .W.)

nama terang dan tanda tangan

ABSTRAK

AUGMENTASI PADA ARSITEKTUR GHOSTNET UNTUK KLASIFIKASI CITRA PRODUK GROCERY STORE DATASET

Oleh:

Fitriya Mawadah Warohmah

Perkembangan teknologi deep learning telah mendorong peningkatan kinerja sistem klasifikasi citra, termasuk dalam pengenalan produk ritel yang memiliki tingkat kemiripan visual tinggi. Salah satu arsitektur Convolutional Neural Network (CNN) ringan yang menjanjikan adalah GhostNet, yang dirancang untuk menghasilkan representasi fitur yang kaya dengan komputasi yang efisien. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi performa GhostNet dalam mengklasifikasikan Grocery Store Dataset yang terdiri dari 81 kelas fine-grained. Metode yang digunakan meliputi n-fold cross validation dengan nilai n sebesar 5 dan 7, pengaturan jumlah epoch hingga 30, serta penerapan teknik augmentasi data untuk meningkatkan kemampuan generalisasi model. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil eksperimen menunjukkan bahwa GhostNet mampu memberikan performa yang kompetitif dan melampaui model baseline DenseNet-169. Konfigurasi terbaik diperoleh pada skenario dengan augmentasi data, 7-fold cross validation, dan 30 epoch, dengan akurasi tertinggi sebesar 86,899%, presisi 87,930%, recall 86,899%, dan F1-score 86,813%. Hasil ini menunjukkan bahwa GhostNet efektif dalam menangani klasifikasi citra produk ritel dengan kompleksitas tinggi, serta memiliki potensi besar untuk diterapkan pada sistem identifikasi produk ritel yang efisien dan ringan.

Kata Kunci: GhostNet, klasifikasi citra, Grocery Store Dataset, *deep learning*, augmentasi data

ABSTRACT

AUGMENTATION OF ARCHITECTURE DEEP LEARNING FOR PRODUCT IMAGE CLASSIFICATION ON THE GROCERY STORE DATASET

By:

Fitriya Mawadah Warohmah

The rapid development of deep learning technology has significantly improved image classification performance, particularly in retail product recognition tasks involving high visual similarity. One promising lightweight Convolutional Neural Network (CNN) architecture is GhostNet, which is designed to generate rich feature representations with low computational cost. This study aims to implement and evaluate the performance of GhostNet for classifying the Grocery Store Dataset, which consists of 81 fine-grained classes. The proposed method employs n-fold cross validation with n values of 5 and 7, training epochs of up to 30, and data augmentation techniques to enhance model generalization. Model performance is evaluated using accuracy, precision, recall, and F1-score metrics. Experimental results demonstrate that GhostNet achieves competitive performance and outperforms the baseline DenseNet-169 model. The best performance is obtained under the augmented data scenario with 7-fold cross validation and 30 training epochs, achieving a highest accuracy of 86.899%, along with a precision of 87.930%, recall of 86.899%, and an F1-score of 86.813%. These findings indicate that GhostNet is effective for fine-grained retail product image classification and has strong potential for deployment in efficient and lightweight retail identification systems.

Keywords: *GhostNet, image classification, Grocery Store Dataset, deep learning, data augmentation*

DAFTAR ISI

LEMBAR PERSETUJUAN PEMBIMBING	i
LEMBAR PENGESAHAN TIM PENGUJI SKRIPSI.....	ii
LEMBAR PERSETUJUAN PUBLIKASI	iii
PERNYATAAN KEASLIAN	iv
MOTTO.....	v
UCAPAN TERIMA KASIH.....	vi
KATA PENGANTAR	viii
ABSTRAK.....	ix
<i>ABSTRACT</i>	x
DAFTAR ISI.....	xi
DAFTAR GAMBAR	xiv
DAFTAR TABEL	xvi
BAB I	18
PENDAHULUAN.....	18
1.1 Latar Belakang.....	18
1.2 Rumusan Masalah	21
1.3 Tujuan Penelitian.....	21
1.4 Batasan Masalah	21
1.5 Manfaat Penelitian	22
BAB II.....	24
TINJAUAN PUSTAKA.....	24
2.1 Tinjauan Penelitian Terdahulu	24
2.2 Teori Dasar	29
2.2.1 Klasifikasi Citra.....	30
2.2.2 Deep Learning.....	32
2.2.3 Convolutional Neural Network (CNN).....	34
2.2.4 Ghostnet	36
2.2.5 Hyperparameter	38
2.2.6 Augmentasi	40
2.2.7 Training Model	41
2.2.8 Cross Entropy Loss.....	42
2.2.9 Confusion Matrix	43
2.3 Integrasi Keilmuan.....	45

BAB III	48
METODE PENELITIAN.....	48
3.1 Tahapan Penelitian.....	48
3.1.1 Perumusan Masalah.....	48
3.1.2 Studi Literatur	49
3.1.3 Pengumpulan Data.....	49
3.1.4 Klasifikasi.....	52
3.1.5 Skenario Penelitian.....	55
3.1.6 Evaluasi dan Analisis Data	57
3.2 Spesifikasi Perangkat	58
BAB IV	60
HASIL DAN PEMBAHASAN.....	60
4.1 Hasil Pengumpulan Data.....	60
4.1.1 Distribusi Kelas	61
4.2 Pre-Processing	63
4.2.1 Resize.....	63
4.2.2 Hasil Random Crop.....	64
4.2.3 Hasil Horizontal Flip.....	65
4.2.4 Hasil Color Jitter	66
4.2.5 Hasil Normalize.....	68
4.3 Modeling	69
4.3.1 Skenario I (n_fold = 5, epoch = 10)	70
4.3.2 Skenario I (n_fold = 5, epoch = 20)	71
4.3.3 Skenario I (n_fold = 5, epoch = 30)	73
4.3.4 Skenario I (n_fold = 7, epoch = 10)	74
4.3.5 Skenario I (n_fold = 7, epoch = 20)	76
4.3.6 Skenario I (n_fold = 7, epoch = 30)	78
4.3.7 Skenario II (n_fold = 5, epoch = 10).....	79
4.3.8 Skenario II (n_fold = 5, epoch = 20).....	81
4.3.9 Skenario II (n_fold = 5, epoch = 30).....	82
4.3.10 Skenario II (n_fold = 7, epoch = 10).....	83
4.3.11 Skenario II (n_fold = 7, epoch = 20).....	84
4.3.12 Skenario II (n_fold = 7, epoch = 30).....	86
4.3.13 Perbandingan Hasil Train, Val, Test	87
4.4 Evaluasi Hasil.....	88

4.4.1 Hasil Keseluruhan Model.....	88
4.4.2 Evaluasi Hasil Skenario I (n_fold = 5, epoch = 10).....	90
4.4.3 Evaluasi Hasil Skenario I (n_fold = 5, epoch = 20).....	92
4.4.4 Evaluasi Hasil Skenario I (n_fold = 5, epoch = 30).....	93
4.4.5 Evaluasi Hasil Skenario I (n_fold = 7, epoch = 10).....	94
4.4.6 Evaluasi Hasil Skenario I (n_fold = 7, epoch = 20).....	95
4.4.7 Evaluasi Hasil Skenario I (n_fold = 7, epoch = 30).....	97
4.4.8 Evaluasi Hasil Skenario II (n_fold = 5, epoch = 10).....	98
4.4.9 Evaluasi Hasil Skenario II (n_fold = 5, epoch = 20).....	99
4.4.10 Evaluasi Hasil Skenario II (n_fold = 5, epoch = 30).....	100
4.4.11 Evaluasi Hasil Skenario II (n_fold = 7, epoch = 10).....	101
4.4.12 Evaluasi Hasil Skenario II (n_fold = 7, epoch = 20).....	103
4.4.13 Evaluasi Hasil Skenario II (n_fold = 7, epoch = 30).....	104
4.5 Analisis Hasil.....	105
4.5.1 Analisis Alat dan Runtime.....	112
BAB V.....	115
KESIMPULAN DAN SARAN.....	115
5.1 Kesimpulan.....	115
5.2 Saran.....	116
DAFTAR PUSTAKA.....	117



 UIN SUNAN AMPEL
 S U R A B A Y A

DAFTAR GAMBAR

Gambar 2. 1 Dataset GroceryStore	29
Gambar 2. 2 Arsitektur Deep Learning	34
Gambar 2. 3 Arsitektur CNN.....	35
Gambar 2. 4 Arsitektur Ghostnet.....	36
Gambar 2. 5 Ghost Module	38
Gambar 2. 6 Original Gambar	40
Gambar 2. 7 Resize(256x256)	40
Gambar 2. 8 Random Crop	40
Gambar 2. 9 Horizontal Flip	40
Gambar 2. 10 Color Jitter	40
Gambar 2. 11 Normalized	40
Gambar 3. 1 Tahapan Penelitian.....	48
Gambar 3. 2 Alur Pre-Processing Data.....	54
Gambar 4. 1 Distribusi Kelas Fine-Grained Training dan Testing.....	62
Gambar 4. 2 Original.....	64
Gambar 4. 3 Random Crop.....	64
Gambar 4. 4 Original.....	65
Gambar 4. 5 Hasil Horizontal Flip.....	65
Gambar 4. 6 Original.....	66
Gambar 4. 7 Color jitter.....	67
Gambar 4. 8 Hasil RGB Gambar Original.....	67
Gambar 4. 9 Hasil RGB dengan Color Jitter	67
Gambar 4. 10 Sebelum Normalize(Original)	69
Gambar 4. 11 Hasil Normalize.....	69
Gambar 4. 12 Validation Error Skenario I N_fold = 5, Epoch = 10	71
Gambar 4. 13 Validation Error Skenario I N_fold = 5, Epoch = 20	72
Gambar 4. 14 Validation Error Skenario I N_fold = 5, Epoch = 30	74
Gambar 4. 15 Validation Error Skenario I N_fold = 7, Epoch = 10	76
Gambar 4. 16 Validation Error Skenario I N_fold = 7, Epoch = 20	77
Gambar 4. 17 Validation Error Skenario I N_fold = 7, Epoch = 30	79
Gambar 4. 18 Validation Error Skenario II N_fold = 5, Epoch = 10.....	80
Gambar 4. 19 Validation Error Skenario II N_fold = 5, Epoch = 20.....	81
Gambar 4. 20 Validation Error Skenario II N_fold = 5, Epoch = 30.....	83
Gambar 4. 21 Validation Error Skenario II N_fold = 7, Epoch = 10.....	84
Gambar 4. 22 Validation Error Skenario II N_fold = 7, Epoch = 20.....	85

Gambar 4. 23 Validation Error Skenario II N_fold = 7, Epoch = 30.....	87
Gambar 4. 24 Perbandingan Train, Val, Test.....	88
Gambar 4. 25 Distribusi Skenario I Accuracy, Precision, Recall, F1-Score N_fold = 5 dan Epoch = 10.....	92
Gambar 4. 26 Distribusi Skenario I Accuracy, Precision, Recall, F1-Score N_fold = 5 dan Epoch = 20.....	93
Gambar 4. 27 Distribusi Skenario I Accuracy, Precision, Recall, F1-Score N_fold = 5 dan Epoch = 30.....	94
Gambar 4. 28 Distribusi Skenario I Accuracy, Precision, Recall, F1-Score N_fold = 7 dan Epoch = 10.....	95
Gambar 4. 29 Distribusi Skenario I Accuracy, Precision, Recall, F1-Score N_fold = 7 dan Epoch = 20.....	96
Gambar 4. 30 Distribusi Skenario I Accuracy, Precision, Recall, F1-Score N_fold = 7 dan Epoch = 30.....	98
Gambar 4. 31 Distribusi Skenario II Accuracy, Precision, Recall, F1-Score N_fold = 5 dan Epoch = 10.....	99
Gambar 4. 32 Distribusi Skenario II Accuracy, Precision, Recall, F1-Score N_fold = 5 dan Epoch = 20.....	100
Gambar 4. 33 Distribusi Skenario II Accuracy, Precision, Recall, F1-Score N_fold = 5 dan Epoch = 30.....	101
Gambar 4. 34 Distribusi Skenario II Accuracy, Precision, Recall, F1-Score N_fold = 7 dan Epoch = 10.....	102
Gambar 4. 35 Distribusi Skenario II Accuracy, Precision, Recall, F1-Score N_fold = 7 dan Epoch = 20.....	104
Gambar 4. 36 Distribusi Skenario II Accuracy, Precision, Recall, F1-Score N_fold = 7 dan Epoch = 30.....	105

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu.....	24
Tabel 2. 2 Klasifikasi Citra GroceryStore Dataset	30
Tabel 2. 3 Hyperparameter (<i>Sumber(Klasson et al., 2019)</i>).....	39
Tabel 2. 4 Confusion Matrix	43
Tabel 3. 1 Dataset Grocery Store	50
Tabel 3. 2 Skenario Penelitian.....	56
Tabel 3. 3 Spesifikasi Perangkat	58
Tabel 4. 1 Dataset Grocery Store (Klasson, 2019).....	60
Tabel 4. 2 Skenario N_fold = 5 dan Epoch = 10.....	70
Tabel 4. 3 Skenario N_fold = 5 dan Epoch = 20.....	72
Tabel 4. 4 Skenario N_fold = 5 dan Epoch = 30.....	73
Tabel 4. 5 Skenario N_fold = 7 dan Epoch = 10.....	75
Tabel 4. 6 Skenario N_fold = 7 dan Epoch = 20.....	76
Tabel 4. 7 Skenario N_fold = 7 dan Epoch = 30.....	78
Tabel 4. 8 Skenario N_fold = 5 dan Epoch = 10.....	79
Tabel 4. 9 Skenario N_fold = 5 dan Epoch = 20.....	81
Tabel 4. 10 Skenario N_fold = 5 dan Epoch = 30.....	82
Tabel 4. 11 Skenario N_fold = 7 dan Epoch = 10.....	83
Tabel 4. 12 Skenario N_fold = 7 dan Epoch = 20.....	85
Tabel 4. 13 Skenario II N_fold = 7 dan Epoch = 30	86
Tabel 4. 14 Hasil Original Split.....	89
Tabel 4. 15 Hasil Model Menggunakan Cross Validation	89
Tabel 4. 16 Evaluasi Hasil Skenario N_fold = 5 dan Epoch = 10.....	91
Tabel 4. 17 Evaluasi Hasil Skenario N_fold = 5 dan Epoch = 20.....	92
Tabel 4. 18 Evaluasi Hasil Skenario N_fold = 5 dan Epoch = 30.....	93
Tabel 4. 19 Evaluasi Hasil Skenario N_fold = 7 dan Epoch = 10.....	95
Tabel 4. 20 Evaluasi Hasil Skenario N_fold = 7 dan Epoch = 20.....	96
Tabel 4. 21 Evaluasi Hasil Skenario N_fold = 7 dan Epoch = 30.....	97
Tabel 4. 22 Evaluasi Hasil Skenario N_fold = 5 dan Epoch = 10.....	98
Tabel 4. 23 Evaluasi Hasil Skenario N_fold = 5 dan Epoch = 20.....	99
Tabel 4. 24 Evaluasi Hasil Skenario N_fold = 5 dan Epoch = 30.....	101
Tabel 4. 25 Evaluasi Hasil Skenario N_fold = 7 dan Epoch = 10.....	102
Tabel 4. 26 Evaluasi Hasil Skenario N_fold = 7 dan Epoch = 20.....	103
Tabel 4. 27 Evaluasi Hasil Skenario N_fold = 7 dan Epoch = 30.....	104
Tabel 4. 28 Runtime pada Skenario I (Baseline tanpa Augmentasi).....	113



UIN SUNAN AMPEL
S U R A B A Y A

DAFTAR PUSTAKA

- Abu Talib, M. A., Setumin, S., Abu Bakar, S. J., Che Ani, A. I., & Cahyani, D. E. (2025). Systematic review of a lightweight convolutional neural network architectures on edge devices. *International Journal of Reconfigurable and Embedded Systems (IJRES)*, 14(2), 339. <https://doi.org/10.11591/ijres.v14.i2.pp339-352>
- Brosch, C., Bouwens, A., Bast, S., Haab, S., & Krieger, R. (2023). *Creation and Evaluation of a Food Product Image Dataset for Product Property Extraction*. 488–495. <https://doi.org/10.5220/0012132400003541>
- Cao, C., Zhou, F., Dai, Y., Wang, J., & Zhang, K. (2024). A Survey of Mix-based Data Augmentation: Taxonomy, Methods, Applications, and Explainability. In *ACM Computing Surveys* (Vol. 57, Issue 2). Association for Computing Machinery. <https://doi.org/10.1145/3696206>
- Cao, Z., Wang, K., Wen, J., Li, C., Wu, Y., Wang, X., & Yu, W. (2024). Fine-grained image classification on bats using VGG16-CBAM: a practical example with 7 horseshoe bats taxa (CHIROPTERA: Rhinolophidae: Rhinolophus) from Southern China. *Frontiers in Zoology*, 21(1). <https://doi.org/10.1186/s12983-024-00531-5>
- Cubuk, E. D., Zoph, B., Shlens, J., & Le, Q. v. (2020). Randaugment: Practical automated data augmentation with a reduced search space. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, 2020-June*, 3008–3017. <https://doi.org/10.1109/CVPRW50498.2020.00359>
- Han, K., Wang, Y., Tian, Q., Guo, J., Xu, C., & Xu, C. (2020). *GhostNet: More Features from Cheap Operations*. <http://arxiv.org/abs/1911.11907>
- Hao, R., Namdar, K., Liu, L., Haider, M. A., & Khalvati, F. (2021). A Comprehensive Study of Data Augmentation Strategies for Prostate Cancer Detection in Diffusion-Weighted MRI Using Convolutional Neural Networks. *Journal of Digital Imaging*, 34(4), 862–876. <https://doi.org/10.1007/s10278-021-00478-7>

- Kandel, I., & Castelli, M. (2020). The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset. *ICT Express*, 6(4), 312–315. <https://doi.org/10.1016/j.ict.2020.04.010>
- Klasson, M., Zhang, C., & Kjellström, H. (2019). *A Hierarchical Grocery Store Image Dataset with Visual and Semantic Labels*. <http://arxiv.org/abs/1901.00711>
- Kohavi, R. (n.d.). *A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection*. [http://roboticsStanfordedu/"ronnyk](http://roboticsStanfordedu/)
- Krichen, M. (2023). Convolutional Neural Networks: A Survey. *Computers*, 12(8). <https://doi.org/10.3390/computers12080151>
- Kumar, S., Asiamah, P., Jolaoso, O., & Esiowu, U. (2025). *Enhancing Image Classification with Augmentation: Data Augmentation Techniques for Improved Image Classification*. <http://arxiv.org/abs/2502.18691>
- Lamm, B., & Keuper, J. (2024). *Retail-786k: a Large-Scale Dataset for Visual Entity Matching*. <http://arxiv.org/abs/2309.17164>
- Li, S., Sultonov, F., Tursunboev, J., Park, J. H., Yun, S., & Kang, J. M. (2022). Ghostformer: A GhostNet-Based Two-Stage Transformer for Small Object Detection. *Sensors*, 22(18). <https://doi.org/10.3390/s22186939>
- Peng, J., Xiao, C., & Li, Y. (2021). *RP2K: A Large-Scale Retail Product Dataset for Fine-Grained Image Classification*. <http://arxiv.org/abs/2006.12634>
- Perez, L., & Wang, J. (2017). *The Effectiveness of Data Augmentation in Image Classification using Deep Learning*. <http://arxiv.org/abs/1712.04621>
- Pradasyah, A., & Baita, A. (2025). Comparative Study of Support Vector Regression and Long Short-Term Memory for Stock Price Prediction. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 9, Issue 4). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Wang, Z., Wang, P., Liu, K., Wang, P., Fu, Y., Lu, C.-T., Aggarwal, C. C., Pei, J., & Zhou, Y. (2025). *A Comprehensive Survey on Data Augmentation*. <http://arxiv.org/abs/2405.09591>

- Wei, X.-S., Song, Y.-Z., mac Aodha, O., Wu, J., Peng, Y., Tang, J., Yang, J., & Belongie, S. (2021). *Fine-Grained Image Analysis with Deep Learning: A Survey*. <http://arxiv.org/abs/2111.06119>
- Yu, T., & Zhu, H. (2020). *Hyper-Parameter Optimization: A Review of Algorithms and Applications*. <http://arxiv.org/abs/2003.05689>



UIN SUNAN AMPEL
S U R A B A Y A