

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI KANKER USUS BESAR DENGAN NORMALISASI GHOSTWEIGHT

Galih Restu Baihaqi^{*1}, Budi Darma Setiawan², Lailil Muflikhah³

^{1,2,3}Universitas Brawijaya, Malang

Email: ¹galihrestubaihq@gmail.com, ²s.budidarma@ub.ac.id, ³lailil@ub.ac.id

*Penulis Korespondensi

(Naskah masuk: 25 November 2024, diterima untuk diterbitkan: 13 April 2025)

Abstrak

Kanker usus besar merupakan salah satu kanker yang dapat menyebabkan kematian. Jenis kanker ini merupakan kanker peringkat kedua terbanyak pada wanita dan peringkat ketiga terbanyak pada pria. Akhir-akhir ini, pendekatan *Deep Learning* (DL) banyak digunakan untuk melakukan proses-proses dalam dunia medis. Salah satu metode yang terkenal yaitu *Convolutional Neural Network* (CNN). CNN tentunya harus memiliki akurasi yang tinggi untuk dapat diterapkan pada kasus ini. Dataset yang digunakan adalah dataset Lung and Colon Cancer Histopathological Images yang berfokus pada kanker ususnya saja. Salah satu cara yang dapat digunakan untuk meningkatkan akurasi pada CNN adalah dengan menormalisasi bobot. Untuk ini, metode yang diusulkan adalah *Ghost Weight Normalization* (GWN) dengan normalisasi L1 yang terinspirasi dari *GhostNet*. Metode ini bekerja dengan cara melakukan pembagian bobot utuh menjadi beberapa bagian yang dinamakan GW dan kemudian dinormalisasi untuk setiap GW-nya, lalu digabung kembali menjadi bobot utuh seperti semula. Pendekatan ini terbukti dapat meningkatkan akurasi CNN dengan sangat baik, yaitu mengalami penambahan akurasi sebesar 14% yang semula CNN biasa memperoleh akurasi sebesar 0.8 menjadi 0.94, presisi 0.8 menjadi 0.94 dan F1-score 0.8 menjadi 0.94. GWN juga dapat mengungguli gaya normalisasi biasa, yaitu normalisasi pada bobot tanpa membaginya menjadi GW. Ukuran GW yang efisien adalah 4 dengan perolehan akurasi, presisi, dan f1-score masing-masing 0.94, dengan epoch 8 dan rata-rata untuk waktu proses training-nya pada setiap epoch-nya adalah 259 detik.

Kata kunci: CNN, Ghost Weight Normalization, Kanker Usus Besar, Klasifikasi

CONVOLUTIONAL NEURAL NETWORK IMPLEMENTATION FOR COLON CANCER CLASSIFICATION WITH GHOSTWEIGHT NORMALIZATION

Abstract

Colon cancer is one of the cancers that can cause death. This type of cancer is the second most common cancer in women and the third most common in men. Lately, Deep Learning (DL) approaches have been widely used to perform processes in the medical world. One of the well-known methods is Convolutional Neural Network (CNN). The method should have high accuracy to be applied in this case. The dataset used is the Lung and Colon Cancer Histopathological Images dataset which focuses on Colon Cancer only. One way that can be used to improve accuracy on CNN is by normalizing the weights. Our proposed method is Ghost Weight Normalization (GWN) with L1 normalization inspired by GhostNet. This method works by dividing the whole weight into several parts called GW and then normalized for each GW, then merged back into the whole weight as before. This approach proved to be able to improve the accuracy of CNN very well, which experienced an increase in accuracy by 14% from the usual CNN accuracy of 0.8 to 0.94, precision 0.8 to 0.94, and f1-score 0.8 to 0.94. GWN can also outperform the usual normalization style, which is normalizing the weights without dividing them into GWs. The efficient GW size is 4 with accuracy, precision, and f1-score of 0.94 each, with 8 epochs and the average training time for each epoch is 259 seconds.

Keywords: CNN, Classification, Colon Cancer, Ghost Weight Normalization

1. PENDAHULUAN

Kanker usus besar merupakan salah satu kanker yang umum dan berbahaya, bahkan dapat

mengakibatkan kematian. Kanker usus besar merupakan kanker peringkat kedua terbanyak yang didiagnosis oleh wanita setelah kanker payudara dan

peringkat ketiga paling banyak pada pria setelah kanker prostat dan paru – paru (SUOMINEN et al., 2024). Akhir – akhir ini, pendekatan *Deep Learning* (DL) memberikan kontribusi dan potensi yang besar dalam menganalisis gambar-gambar medis, termasuk kanker usus besar. Namun, tantangan terbesar dalam penerapan DL pada bidang medis yaitu membutuhkan akurasi yang tinggi.

Convolutional Neural Network (CNN) merupakan salah satu jenis *Neural Network* yang banyak dilakukan untuk tugas-tugas klasifikasi pada gambar (NUGROHO & YULIA, 2021; SETIYONO et al., 2023). Salah satu penelitian yang menggunakan CNN dengan arsitektur VGG16 dalam mengklasifikasikan penyakit kulit memperoleh akurasi 82,14% (LUBIS & YULIARTO, 2023). Pada penelitian lainnya (WAHID et al., 2021), CNN digunakan untuk mengklasifikasikan kanker usus besar memperoleh akurasi sebesar 88.26%. Untuk meningkatkan akurasi CNN, salah satunya adalah dengan cara menormalisasi bobot.

Normalisasi bobot adalah salah satu proses untuk menormalkan bobot pada suatu *layer* yang dapat membantu menstabilkan distribusi bobot (LI & SUN, 2021; WU et al., 2020; YUAN et al., 2022). Salah satu jenis normalisasi yang banyak digunakan adalah Normalisasi L1. Normalisasi L1 bekerja dengan cara membagi suatu nilai dengan jumlah absolut pada nilai tersebut (ZHOU et al., 2022). Pada sebuah penelitian (ROY et al., 2020) normalisasi L1 digunakan untuk memangkas jaringan asli dan dapat memangkas sekitar 80% filter dibandingkan dengan jaringan aslinya.

Model untuk menormalisasi bobot ini terinspirasi oleh modul *GhostNet* (GN) yang menggunakan setengah dari *channel* bobot untuk diproses, lalu setengah dari *channel*-nya lagi dilakukan *cheap operation* yang bertujuan untuk menghemat komputasi (HAN et al., 2020). Berbeda cara kerja dengan GN, GWN bekerja dengan membagi matriks bobot utuh menjadi beberapa bagian yang dinamakan GW. Setiap GW dilakukan normalisasi L1 untuk menormalkan bobotnya. Kemudian, bobotnya disatukan lagi menjadi matriks bobot baru.

Oleh karena itu, penelitian ini bertujuan untuk mengklasifikasikan kanker usus besar menggunakan CNN dengan normalisasi bobot L1 menggunakan pendekatan *Ghost Weight Normalization* untuk meningkatkan akurasi model klasifikasi.

2. PENELITIAN TERKAIT

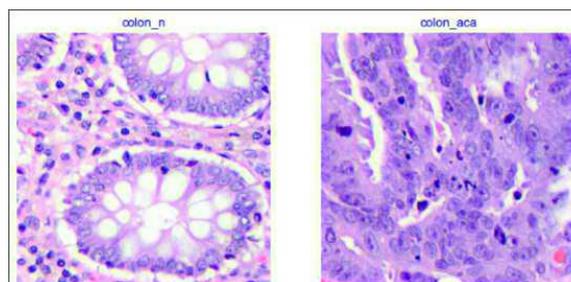
Banyak sekali penelitian yang menggunakan CNN sebagai metode klasifikasi. Pada sebuah penelitian (ELNGAR et al., 2021), membahas tentang bagaimana cara kerja dan penggunaan CNN *based* dengan penggunaan CNN 2 *layer*, memberikan hasil yang baik dalam melakukan proses klasifikasi. Klasifikasi menggunakan CNN banyak diterapkan terhadap data – data gambar dan tidak hanya berfokus

pada gambar – gambar penyakit. Misalnya pada penelitian (FARID NAUFAL & FERDIANA KUSUMA, 2021), CNN diaplikasikan untuk mengklasifikasikan wajah pengguna masker dan CNN memberikan performa yang bagus dengan menghasilkan akurasi di atas 0.9. Selain pada manusia, CNN juga dapat diaplikasikan untuk mengklasifikasikan tanaman obat dan memberikan akurasi di atas 0.9 juga (SETIYONO et al., 2023). Selain itu, CNN juga banyak diaplikasikan untuk mengklasifikasikan penyakit. Misalnya pada sebuah penelitian (ISWANTORO & Handayani UN, 2022), CNN digunakan untuk mengklasifikasikan penyakit pada tanaman jagung memperoleh akurasi 94%. Selain penyakit pada tanaman, CNN juga banyak digunakan untuk mengklasifikasikan penyakit pada manusia. Misalnya, CNN model ResNet memberikan akurasi di atas 80% dalam mengklasifikasikan penyakit kanker pada usus besar (SARWINDA et al., 2021). Selain itu, CNN dapat mengungguli model Machine Learning Tradisional Seperti KNN dan SVM dalam mengklasifikasikan Citra (NAUFAL, 2021).

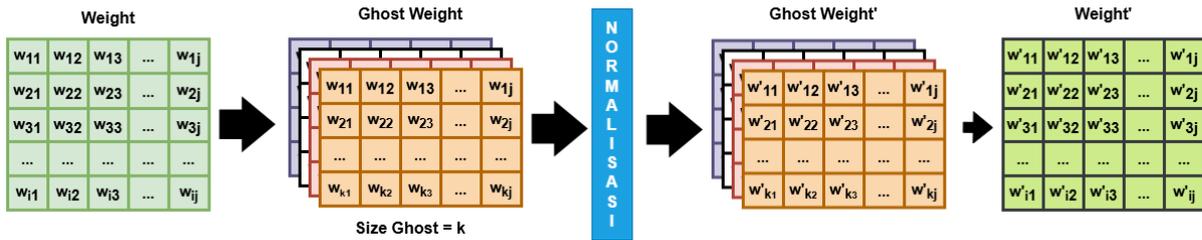
Banyak cara untuk meningkatkan performa model klasifikasi. Salah satunya adalah dengan cara melakukan normalisasi. Salah satu metode normalisasi yang banyak digunakan adalah normalisasi L1. Pada sebuah penelitian, (ROY et al., 2020), L1 digunakan untuk VGG-16 yang dilatih pada *dataset* CIFAR10, memberikan hasil yang baik dengan penurunan 1% pada akurasinya setelah memangkas 80% filter dibandingkan dengan menggunakan jaringan asli. Penelitian lainnya, Normalisasi L1 digunakan untuk menormalisasikan matriks dan dibandingkan dengan L2, akurasi yang dihasilkan sama, akan tetapi L1 mengungguli L2 dari segi probabilitas perolehan akurasi tertinggi (MISHRA & SANODIYA, 2022). Penelitian lainnya (WEN et al., 2021), Menggunakan L1 untuk menormalisasi bobot dan hasilnya membuktikan bahwa dengan melakukan normalisasi dapat mengurangi kesalahan generalisasi dan dapat mengurangi *overfitting* serta mempercepat konvergensi suatu algoritma.

3. METODE PENELITIAN

3.1. Dataset



Gambar 1. Dataset



Gambar 2. Arsitektur Ghost Weight Normalization

Dataset yang digunakan adalah dataset Lung and Colon Cancer Histopathological Images yang diperoleh dari Kaggle dan berfokus pada dataset *colon* (usuk besar) dengan total data sebanyak 10.000 yang terdiri dari 2 kelas yaitu kanker kolorektal dengan kode "colon_aca" dan kanker jinak dengan kode "colon_n".

3.2. Ghost Weight Normalization

Ghost Weight Normalization (GWN) adalah arsitektur yang terinspirasi dari arsitektur *GhostNet* yang bekerja dengan cara membagi bobot utuh sebelum dilakukan normalisasi. GWN berfokus pada bobot yang cara kerjanya dengan membagi ukuran bobot dengan ukuran tertentu, disebut dengan *Size_Ghost*, untuk membentuk GW. Kemudian, pada setiap GW dilakukan normalisasi dan setelah itu GW hasil normalisasi di-*concat* (digabung) untuk mengembalikan bentuk bobot seperti semula. Arsitektur usulan dari GW dapat dilihat pada Gambar 2.

3.3. Normalisasi L1

Normalisasi L1 merupakan salah satu dari beberapa jenis normalisasi. Cara kerjanya adalah dengan cara membagi bobot ke *i* dengan jumlah dari absolut seluruh bobot. Seluruh bobot yang dimaksud adalah seluruh bobot pada setiap GW. Rumus dari normalisasi L1 dapat dilihat pada Persamaan 1.

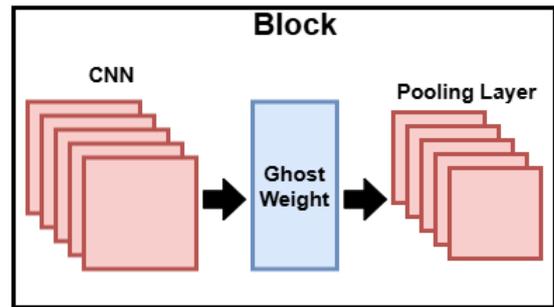
$$W'_i = \frac{W_i}{\sum |W_j|} \tag{1}$$

3.4. Arsitektur Model

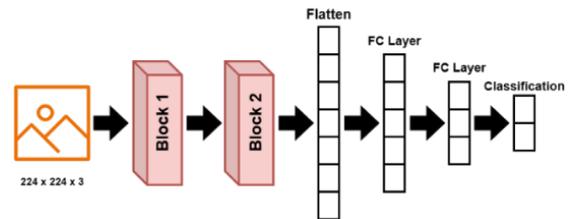
Arsitektur yang digunakan pada penelitian ini dapat dilihat pada Gambar 4. Arsitekturnya terdiri dari 2 *block* CNN, lalu *Layer flatten* dan *FullyConnected Layer* sampai *Layer* Klasifikasi.

Untuk *block* CNN yang disebutkan dapat dilihat pada Gambar 3, yaitu setiap *block* terdiri dari *layer* CNN dan *layer* GWN lalu *Pooling Layer*.
 Pengujian *epoch* dilakukan dengan besaran 4 dan 8 dan ukuran GW 2, 4 dan 8 pada kedua *block* untuk menguji pengaruh banyaknya GW. Untuk *dataset*-nya, dibagi menjadi 3 bagian yaitu data pelatihan, validasi dan tes dengan besaran 80%:10%:10% sehingga untuk data yang digunakan pada data pelatihan adalah 8.000 data, sementara pada

data validasi dan pengujian sebanyak 1.000 data. Untuk mengukur akurasi, disajikan dengan *Confusion Matrix*.



Gambar 3. Block CNN



Gambar 4. Arsitektur Model

4. HASIL DAN PEMBAHASAN

Jumlah filter pada *layer* CNN *block* pertama adalah 128 dan *block* kedua adalah 256 dengan *maxpooling* (2 x 2).

4.1. Hasil Pengujian Pertama

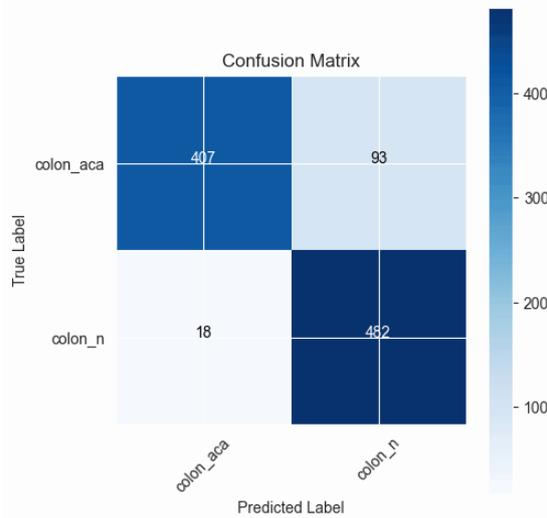
Pada pengujian pertama, dilakukan pengujian *epoch* untuk ketiga model. Model yang digunakan adalah CNN biasa (Tanpa GWN), Model CNN dengan Bobot Normalisasi L1 langsung (WN) dan metode usulan yaitu CNN menggunakan GWN, dengan GW = 2. Hasil yang diperoleh dapat dilihat pada Tabel 1.

Tabel 1. Hasil Pengujian *Epoch*

Epoch	Model	Akurasi	Presisi	F1-Score
4	CNN	0.8	0.8	0.8
	CNN-WN	0.88	0.9	0.88
	CNN-GWN	0.92	0.92	0.92
8	CNN	0.76	0.77	0.76
	CNN-WN	0.87	0.88	0.87
	CNN-GWN	0.94	0.94	0.94

Hasil menunjukkan bahwa model yang memiliki akurasi, presisi dan f1-score tertinggi dari ketiganya adalah model CNN yang dilakukan normalisasi GWN dengan *epoch* 8 dengan nilai yang

diperoleh adalah 0.94. Untuk hasil dari *confusion matrix* model CNN-GWN ditunjukkan pada Gambar 5. Lalu waktu yang dibutuhkan pada proses *training*, model CNN-GWN memiliki waktu yang lebih lama, namun dapat mengungguli CNN-WN walau sangat tipis. Ini karena ada proses pembedaan GW pada setiap proses *training*-nya dan ditunjukkan pada Gambar 6.



Gambar 5. Confusion Matrix Epoch 5



Gambar 6. Waktu Training

4.2. Hasil Pengujian Kedua

Pengujian kedua dilakukan untuk menguji besaran GW pada GWN yang efektif dalam melakukan pembagian bobot. Untuk *epoch* yang digunakan pada proses *training* pengujian kedua adalah 8 yang ditentukan berdasarkan hasil pengujian *epoch* pada pengujian pertama. Untuk ukuran *Ghost Weight* yang diuji adalah 2, 4 dan 8 pada kedua *block*. Akurasi yang diperoleh ditunjukkan pada Tabel 2.

Tabel 2. Hasil Pengujian Ukuran GW

Jumlah GW	Akurasi	Presisi	F1-Score
2	0.94	0.94	0.94
4	0.94	0.94	0.94
8	0.78	0.78	0.78

Membagi bobot menjadi GW sebesar 2 dan 4 memiliki akurasi yang sama yaitu 0.94. Namun, hasil terburuk ada pada GW sebesar 8 dengan perolehan akurasi 0.78. Ini membuktikan bahwa pengaruh

pembagian bobot menjadi GW yang terlalu banyak juga dapat mengakibatkan akurasinya menurun, ini dapat disebabkan karena terlalu banyak menormalisasi bobot pada satu bobot utuh. Adapun perolehan waktu *training* yang dihasilkan oleh ketiga pengujian, membagi *Ghost Weight* dengan besaran 4 lebih efektif karena memiliki waktu *training* yang lebih cepat dan memiliki akurasi yang tinggi yaitu 0.94. Untuk waktu *training* yang dihasilkan ditampilkan pada grafik Gambar 7.



Gambar 7. Perbandingan Waktu Training Pada GW

5. KESIMPULAN

CNN merupakan salah satu metode yang dapat digunakan untuk melakukan klasifikasi terhadap data-data gambar. CNN dapat dimanfaatkan untuk mengklasifikasikan penyakit kanker usus besar. Untuk dapat meningkatkan akurasi pada CNN, perlu melakukan modifikasi terhadap arsitektur daripada CNN biasa. Salah satu cara yang dapat dilakukan adalah dengan menormalisasi bobot dari CNN. Metode normalisasi yang diusulkan dalam penelitian ini yaitu dengan menggunakan normalisasi L1 dengan perlakuan yang berbeda yaitu membagi bobot utuh menjadi *Ghost Weight* untuk kemudian dinormalisasi pada setiap *Ghost Weight*-nya. Berdasarkan hasil yang diperoleh terbukti dapat meningkatkan akurasi CNN biasa. Akurasi yang semula pada pengujian CNN terbaik yaitu memperoleh akurasi 0.8, dengan ditambahkan *Ghost Weight Normalization* meningkat menjadi 0.94. Selain itu untuk perolehan presisi dan f1-score juga menunjukkan angka 0.94 yang jauh lebih baik daripada tanpa menggunakan teknik normalisasi. Metode yang diusulkan juga dapat mengungguli metode normalisasi tanpa pembagian *Ghost Weight*.

Ke depannya, penelitian ini akan mencoba untuk melakukan pengujian dengan mengubah cara menormalisasi bobotnya, misalnya dengan Normalisasi Mean, L2 dan lain – lain. Selain itu, model – model deep learning lainnya dapat dicoba untuk memperoleh akurasi yang lebih tinggi lagi dengan memanfaatkan *layer-layer* yang lebih kompleks.

DAFTAR PUSTAKA

- ELNGAR, A. A., ARAFA, M., FATHY, A., MOUSTAFA, B., MAHMOUD, O., SHABAN, M., & FAWZY, N. 2021. Image Classification Based On CNN: A Survey. *Journal of Cybersecurity and Information Management (JCIM)*, 6(1), 18. <https://doi.org/10.5281/zenodo.4897990>
- FARID NAUFAL, M., & FERDIANA KUSUMA, S. 2021. Pendeteksi Citra Masker Wajah Menggunakan CNN Dan Transfer Learning. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 8(6), 1293–1300. <https://doi.org/10.25126/jtiik.202185201>
- HAN, K., WANG, Y., TIAN, Q., GUO, J., XU, C., & XU, C. 2020. GhostNet: More Features from Cheap Operations. *CVPR*, 1580–1589.
- ISWANTORO, D., & Handayai UN, D. 2022. Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Universitas Batanghari Jambi*, 22(2), 900. <https://doi.org/10.33087/jiubj.v22i2.2065>
- LI, C., & SUN, L. 2021. Multi-label Anomaly Classification Based on Electrocardiogram. In H. and C. L. and G. Y. and X. C. Siuly Siuly and Wang (Ed.), *Health Information Science* (pp. 171–178). Springer International Publishing.
- LUBIS, C., & YULIARTO, D. 2023. Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network (CNN) Dengan Arsitektur VGG16. *JURNAL SISTEM INFORMASI DAN TEKNIK KOMPUTER*, 8(1).
- MISHRA, S., & SANODIYA, R. K. 2022. Scatter Matrix Normalization for Unsupervised Domain Adaptation. *9th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering, UPCON 2022*. <https://doi.org/10.1109/UPCON56432.2022.9986396>
- NAUFAL, M. F. 2021. Analisis Perbandingan Algoritma SVM, KNN, Dan CNN Untuk Klasifikasi Citra Cuaca. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 8(2), 311–318. <https://doi.org/10.25126/jtiik.202184553>
- NUGROHO, B., & YULIA, E. 2021. Kinerja Metode CNN Untuk Klasifikasi Pneumonia Dengan Variasi Ukuran Citra Input. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 8(3), 533–538. <https://doi.org/10.25126/jtiik.202184515>
- ROY, S., PANDA, P., SRINIVASAN, G., & RAGHUNATHAN, A. 2020. Pruning Filters while Training for Efficiently Optimizing Deep Learning Networks. *2020 International Joint Conference on Neural Networks (IJCNN)*.
- SARWINDA, D., PARADISA, R. H., BUSTAMAM, A., & ANGGIA, P. 2021. Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer. *Procedia Computer Science*, 179, 423–431. <https://doi.org/10.1016/j.procs.2021.01.025>
- SETIYONO, B., RIV'AN ARIF, M., AINI, Q. Q., SOEGIANTO, T. H., OHANNA, J., ANDREAN, R., GUNAWAN, F., & RIZKIA, A. P. 2023. Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 10(2), 385–392. <https://doi.org/10.25126/jtiik.2023106809>
- SUOMINEN, M., SUBASI, M. E., & SUBASI, A. 2024. Chapter 9 - Automated detection of colon cancer from histopathological images using deep neural networks. In A. Subasi (Ed.), *Applications of Artificial Intelligence in Healthcare and Biomedicine* (pp. 243–287). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-443-22308-2.00014-7>
- WAHID, R. R., NISA', C., AMALIYAH, R. P., & PUSPANINGRUM, E. Y. 2021. Lung and colon cancer detection with convolutional neural networks on histopathological images. *PROCEEDINGS OF THE 7TH INTERNATIONAL CONFERENCE ON SCIENCE AND TECHNOLOGY*.
- WEN, M., XU, Y., ZHEN, Y., YANG, Z., & WANG, X. 2021. Sparse Deep Neural Networks Using L1 Weight Normalization. *Statistica Sinica*, 31(3), 1397–1414. <https://www.jstor.org/stable/27034823>
- WU, X., DOBRIBAN, E., REN, T., WU, S., LI, Z., GUNASEKAR, S., WARD, R., & LIU, X. 2020. Implicit Regularization and Convergence for Weight Normalization. In H. Larochelle, M. Ranzato, R. Hadsell, M. F. Balcan, & H. Lin (Eds.), *Advances in Neural Information Processing Systems* (Vol. 33, pp. 2835–2847). Curran Associates, Inc. https://proceedings.neurips.cc/paper_files/paper/2020/file/1de7d2b90d554be9f0db1c338e80197d-Paper.pdf
- YUAN, X., SHEN, X., MEHTA, S., LI, T., GE, S., & ZHA, Z. 2022. Structure injected weight normalization for training deep networks. *Multimedia Systems*, 28(2), 433–444. <https://doi.org/10.1007/s00530-021-00793-7>
- ZHOU, W., LIU, A., WU, L., & CHEN, X. 2022. A L1 normalization enhanced dynamic window method for SSVEP-based BCIs. *Journal of Neuroscience Methods*, 380.

<https://doi.org/10.1016/j.jneumeth.2022.109688>