

Analisis Visualisasi Feature Map Lapisan Konvolusi AlexNet untuk Klasifikasi Diabetic Retinopathy pada Citra Fundus Retina

Nurul Maulidiyah *¹
I Gde Eka Dirgayussa ²

^{1,2} Program Studi Teknik Biomedis, Fakultas Teknologi Industri, Institut Teknologi Sumatera
*e-mail: nurul.maulidiyah@bm.itera.ac.id ¹

Abstrak

Diabetic Retinopathy (DR) merupakan komplikasi diabetes yang menjadi penyebab utama kebutaan pada populasi usia produktif. Sistem deteksi otomatis berbasis Convolutional Neural Network (CNN) telah terbukti efektif dalam mengklasifikasikan DR, namun interpretabilitas internal model masih menjadi tantangan dalam penerapan klinis. Penelitian ini menyajikan analisis mendalam terhadap visualisasi feature map pada lima lapisan konvolusi arsitektur AlexNet (Conv. 1 hingga Conv. 5) yang dilatih pada dataset APTOS 2019 untuk klasifikasi binary Diabetic Retinopathy versus Non-Diabetic Retinopathy. Observasi dilakukan secara komparatif antara citra fundus retina DR dan Non-DR untuk memahami bagaimana setiap lapisan konvolusi mengekstrak dan mentransformasi representasi fitur. Hasil menunjukkan bahwa lapisan awal (Conv. 1–2) mengekstrak fitur tingkat rendah berupa tepi, orientasi, dan tekstur dasar, sementara lapisan lebih dalam (Conv. 3–5) membangun representasi semantik yang semakin abstrak dan diskriminatif. Perbedaan pola aktivasi yang signifikan antara citra DR dan Non-DR teridentifikasi sejak lapisan Conv. 3, dan semakin terdefinisi pada Conv. 4–5, yang mengonfirmasi kemampuan AlexNet dalam mengekstrak fitur patologis retina secara hierarkis. Penelitian ini memberikan kontribusi pada aspek explainability model deep learning untuk aplikasi medis, khususnya dalam memberikan dasar interpretasi visual yang mendukung kepercayaan klinisi terhadap sistem CAD berbasis CNN.

Kata kunci: AlexNet, Convolutional Layer, Diabetic Retinopathy, Feature Map Visualization

Abstract

Diabetic Retinopathy (DR) is a diabetes complication and the leading cause of blindness in the working-age population. Convolutional Neural Network (CNN)-based automated detection systems have proven effective in classifying DR; however, model interpretability remains a challenge in clinical deployment. This study presents an in-depth analysis of feature map visualizations across five convolutional layers of the AlexNet architecture (Conv. 1 to Conv. 5), trained on the APTOS 2019 dataset for binary classification of Diabetic Retinopathy versus Non-Diabetic Retinopathy. Observations were conducted comparatively between DR and Non-DR fundus retinal images to understand how each convolutional layer extracts and transforms feature representations. Results indicate that early layers (Conv. 1–2) extract low-level features such as edges, orientations, and basic textures, while deeper layers (Conv. 3–5) build increasingly abstract and discriminative semantic representations. Significant differences in activation patterns between DR and Non-DR images are identifiable from Conv. 3 onward, becoming more defined in Conv. 4–5, confirming AlexNet's ability to hierarchically extract retinal pathological features. This study contributes to the explainability of deep learning models for medical applications, specifically providing a visual interpretive basis that supports clinician confidence in CNN-based CAD systems.

Keywords: AlexNet, Convolutional Layer, Diabetic Retinopathy, Feature Map Visualization

PENDAHULUAN

Diabetic Retinopathy (DR) adalah komplikasi mikrovaskular diabetes mellitus yang menjadi penyebab utama kebutaan yang dapat dicegah pada populasi usia produktif di seluruh dunia. Menurut International Diabetes Federation, lebih dari 93 juta penderita diabetes mengalami gangguan penglihatan akibat DR, dengan proyeksi peningkatan signifikan seiring bertambahnya prevalensi diabetes global (Sun et al., 2022). Deteksi dini dan akurat merupakan kunci untuk mencegah progresi penyakit menuju kebutaan permanen.

Kemajuan deep learning, khususnya Convolutional Neural Network (CNN), telah merevolusi analisis citra medis retina. CNN mampu mengekstrak fitur secara hierarkis dari citra fundus retina

berwarna tanpa memerlukan ekstraksi fitur manual, sehingga memungkinkan klasifikasi DR dengan akurasi tinggi (LeCun et al., 2015). Arsitektur AlexNet, sebagai salah satu pionir CNN modern, telah terbukti mampu mencapai akurasi kompetitif dalam klasifikasi DR, termasuk 96,10% pada dataset APTOS 2019 dengan metode 10-Fold Cross Validation (Narayanan et al., 2020).

Namun demikian, sifat "black box" model deep learning menjadi hambatan signifikan dalam penerimaan klinisi terhadap sistem Computer-Aided Diagnosis (CAD). Klinisi membutuhkan pemahaman tentang bagaimana model membuat keputusan klasifikasi—fitur apa yang dianggap penting dan mengapa—sebelum dapat mempercayai rekomendasi sistem otomatis dalam praktik klinis (Selvaraju et al., 2020). Kurangnya interpretabilitas ini mendorong kebutuhan penelitian pada aspek explainability model CNN.

Visualisasi feature map lapisan konvolusi merupakan salah satu pendekatan paling mendasar dan intuitif dalam explainability CNN. Dengan mengobservasi output setiap lapisan konvolusi, peneliti dapat memahami transformasi representasi data yang terjadi secara hierarkis—dari fitur tingkat rendah seperti tepi dan tekstur pada lapisan awal, hingga fitur semantik tingkat tinggi pada lapisan dalam yang berkorespondensi dengan konsep visual yang dapat diinterpretasikan (Krizhevsky et al., 2012). Pendekatan ini berbeda dari metode post-hoc seperti Grad-CAM yang bekerja setelah keputusan dibuat; visualisasi feature map mengungkap proses internal model secara langsung.

Penelitian ini bertujuan untuk: (1) menganalisis dan memvisualisasikan feature map pada kelima lapisan konvolusi AlexNet (Conv. 1–5) secara komparatif antara citra fundus DR dan Non-DR, (2) mengidentifikasi perbedaan pola aktivasi yang terjadi pada setiap lapisan sebagai representasi proses ekstraksi fitur patologis retina, dan (3) memberikan interpretasi klinis atas visualisasi tersebut sebagai kontribusi pada aspek explainability sistem CAD berbasis CNN untuk deteksi DR. Penelitian ini diharapkan dapat menjembatani kesenjangan antara performa model yang tinggi dengan kepercayaan klinisi dalam mengadopsi sistem AI untuk skrining DR.

METODE

Dataset dan Model

Dataset yang digunakan dalam penelitian ini adalah APTOS 2019 Blindness Detection dari platform Kaggle, yang terdiri dari 3.722 citra fundus retina berwarna resolusi tinggi: 1.830 citra Non-Diabetic Retinopathy (Non-DR) dan 1.892 citra Diabetic Retinopathy (DR). Model AlexNet yang digunakan merupakan model terlatih hasil 10-Fold Cross Validation dengan akurasi terbaik 96,10% menggunakan citra original tanpa preprocessing tambahan, sebagaimana dideskripsikan dalam penelitian sebelumnya.

Arsitektur AlexNet

AlexNet terdiri dari delapan lapisan yang dapat dilatih: lima lapisan konvolusi (Conv. 1–5) dan tiga lapisan fully connected. Spesifikasi kelima lapisan konvolusi yang dianalisis adalah sebagai berikut. Conv. 1 menggunakan 96 filter berukuran 11×11 dengan stride 4 dan diikuti Local Response Normalization (LRN) serta max pooling 3×3 stride 2. Conv. 2 menggunakan 256 filter berukuran 5×5 dengan padding 2, juga diikuti LRN dan max pooling. Conv. 3, Conv. 4, dan Conv. 5 masing-masing menggunakan 384, 384, dan 256 filter berukuran 3×3 dengan padding 1, di mana Conv. 5 diikuti max pooling 3×3 stride 2. Seluruh lapisan konvolusi menggunakan fungsi aktivasi ReLU. Input model berukuran $227 \times 227 \times 3$ piksel.

Prosedur Visualisasi Feature Map

Visualisasi feature map dilakukan dengan mengekstrak output aktivasi setiap lapisan konvolusi menggunakan teknik forward hook pada model AlexNet yang telah terlatih. Empat sampel citra dipilih secara representatif—dua citra dengan label DR dan dua citra dengan label Non-DR—yang sebelumnya telah melalui preprocessing resizing ke ukuran 227×227 piksel. Untuk setiap citra, feature map dari Conv. 1 hingga Conv. 5 divisualisasikan sebagai gambar

grayscale ternormalisasi. Visualisasi difokuskan pada empat filter pertama tiap lapisan untuk memudahkan perbandingan antar kelas. Observasi dilakukan secara kualitatif dengan membandingkan pola aktivasi antara citra DR dan Non-DR pada masing-masing lapisan konvolusi.

Tinjauan Literatur Terkait

Penelitian-penelitian terdahulu yang relevan dengan visualisasi fitur CNN untuk DR dirangkum pada Tabel 1 berikut.

Tabel 1. Ringkasan Penelitian Terkait Visualisasi Fitur CNN pada Klasifikasi DR

Penulis (Tahun)	Arsitektur	Fokus Visualisasi	Dataset
Krizhevsky et al. (2012)	AlexNet	Feature maps Conv1–Conv5; visualisasi filter menunjukkan detektor tepi, tekstur, dan pola warna	ImageNet
Das et al. (2023)	26 model CNN (DRFEC)	Visualisasi feature extraction per lapisan konvolusi pada citra fundus DR	Kaggle EyePACS
Selvaraju et al. (2020)	ResNet, VGG (Grad-CAM)	Gradient-weighted class activation mapping untuk lokalisasi region keputusan model	ImageNet, PASCAL VOC
Bala et al. (2024)	CTNet (CNN-Transformer)	Visualisasi attention map dan convolutional feature pada klasifikasi DR	APTOS 2019, IDRiD
MDPI Computers (2025)	ResNet-50, ViT, SwinV2	Grad-CAM & Attention-Rollout untuk perbandingan interpretabilitas CNN vs ViT pada DR	APTOS 2019, Messidor
Elkenawy et al. (2026)	AlexNet	Visualisasi fitur lapisan konvolusi untuk klasifikasi penyakit retina (4 kelas)	IDRiD, HRF

HASIL DAN PEMBAHASAN


Ringkasan Karakteristik Feature Map Per Lapisan Konvolusi

Sebelum membahas observasi visual secara detail, Tabel 2 merangkum karakteristik fitur yang diekstrak pada setiap lapisan konvolusi AlexNet untuk kedua kelas citra dan Gambar 3 menggambarkan Visualisasi *Observation Image of Convolutional Layer Features* AlexNet pada Citra *Diabetic Retinopathy* (kiri) dan *Non-Diabetic Retinopathy* (kanan)

Tabel 2. Karakteristik Feature Map AlexNet Per Lapisan Konvolusi pada Citra DR dan Non-DR

Lapisan	Fitur yang Diekstrak	Karakteristik pada DR	Karakteristik pada Non-DR
Conv. 1	Tepi, orientasi, warna dasar	Batas pembuluh darah tampak lebih kompleks; area lesi terdeteksi sebagai tepi tidak beraturan	Pola tepi lebih seragam; batas optic disc terlihat jelas dan teratur
Conv. 2	Tekstur, gradien, pola lokal	Tekstur tidak homogen di area hemorrhage; pola mikroaneurisma mulai terdeteksi sebagai titik kontras tinggi	Tekstur retina lebih homogen; gradien halus dan konsisten di seluruh area
Conv. 3	Kombinasi tekstur-bentuk	Aktivasi tinggi pada area lesi (exudate, hemorrhage); peta fitur lebih tersebar dan tidak teratur	Aktivasi lebih terpusat di area optic disc; distribusi fitur lebih teratur
Conv. 4	Fitur semantik tingkat menengah	Representasi abstrak lesi mulai terbentuk; area perdarahan menghasilkan pola aktivasi yang khas	Pola aktivasi lebih terpusat; fitur pembuluh darah normal teridentifikasi

Conv. 5	Fitur semantik tingkat tinggi	Fitur diskriminatif DR terbentuk sempurna; model mengidentifikasi kombinasi lesi sebagai penanda DR	Representasi retina sehat yang terkonsolidasi; pola global yang bersih dan teratur
---------	-------------------------------	---	--



Gambar 1. Visualisasi Observation Image of Convolutional Layer Features AlexNet pada Citra Diabetic Retinopathy (kiri) dan Non-Diabetic Retinopathy (kanan)

Conv. 1 — Ekstraksi Fitur Tingkat Rendah

Lapisan konvolusi pertama (Conv. 1) menggunakan 96 filter berukuran 11×11 yang dirancang untuk mendeteksi fitur visual tingkat rendah seperti tepi, orientasi garis, dan variasi warna dasar. Pada citra DR, feature map Conv. 1 menampilkan pola tepi yang lebih kompleks dan tidak beraturan, terutama di area yang bersesuaian dengan pembuluh darah yang melebar dan lesi retina. Area perdarahan dan eksudat pada citra DR menghasilkan respons aktivasi yang kuat karena perbedaan kontras yang tajam dengan jaringan retina sekitarnya. Sebaliknya, pada citra Non-DR, Conv. 1 menghasilkan feature map yang lebih seragam dengan pola tepi yang teratur, mencerminkan struktur retina yang normal—batas optic disc yang jelas dan distribusi pembuluh darah yang konsisten. Observasi ini konsisten dengan temuan Krizhevsky et al. (2012) yang menunjukkan bahwa filter Conv. 1 AlexNet bertindak sebagai detektor tepi dan warna yang sangat mirip dengan filter Gabor dalam visi komputer tradisional.

Conv. 2 — Pola Tekstur dan Gradien Lokal

Lapisan kedua (Conv. 2) membangun representasi yang lebih kompleks dengan mengombinasikan output Conv. 1 melalui 256 filter berukuran 5×5. Pada tahap ini, model mulai mendeteksi pola tekstur dan gradien lokal yang lebih spesifik. Pada citra DR, feature map Conv. 2 menunjukkan ketidakhomogenan tekstur yang jelas—area microaneurysm dan hemorrhage menghasilkan aktivasi titik-titik kontras tinggi yang tersebar, sementara area eksudat menghasilkan respons yang lebih tersebar dan terang. Tekstur retina pada citra DR secara keseluruhan lebih heterogen dibandingkan Non-DR. Pada citra Non-DR, feature map Conv. 2 memperlihatkan tekstur yang lebih homogen dan teratur, dengan gradien yang halus dan konsisten di seluruh area retina. Temuan ini selaras dengan penelitian Das et al. (2023) yang menunjukkan bahwa lapisan awal CNN secara efektif mendeteksi perbedaan tekstur pada citra fundus DR tanpa memerlukan ekstraksi fitur manual.

Conv. 3 — Kombinasi Fitur Tekstur-Bentuk

Conv. 3 dengan 384 filter berukuran 3×3 merupakan lapisan transisi penting di mana model mulai mengintegrasikan informasi tekstur dan bentuk. Pada tahap ini, perbedaan antara citra DR dan Non-DR mulai tampak lebih signifikan. Feature map Conv. 3 pada citra DR menunjukkan aktivasi yang lebih tersebar dan tidak beraturan, dengan area high-activation yang berkorespondensi dengan lokasi lesi retina. Kombinasi tepi-tekstur yang kompleks akibat kehadiran hemorrhage, microaneurysm, dan eksudat menghasilkan pola aktivasi yang khas dan berbeda dari retina normal. Pada citra Non-DR, aktivasi Conv. 3 lebih terpusat di area anatomis yang konsisten seperti optic disc dan arcade pembuluh darah utama, mencerminkan struktur retina yang teratur. Perbedaan distribusi aktivasi antara kedua kelas pada Conv. 3 ini memberikan indikasi awal bahwa model mulai membangun representasi yang diskriminatif antara DR dan Non-DR.

Conv. 4 — Representasi Fitur Semantik Menengah

Pada lapisan keempat (Conv. 4, 384 filter 3×3), model telah membangun representasi semantik tingkat menengah yang semakin abstrak. Feature map pada Conv. 4 tidak lagi merepresentasikan fitur visual yang mudah diinterpretasikan secara langsung, namun mengkodekan kombinasi fitur kompleks yang telah terbukti diskriminatif untuk klasifikasi. Pada citra DR, aktivasi Conv. 4 menunjukkan pola yang khas untuk kondisi patologis—respons terhadap kombinasi lesi multiple seperti keberadaan area hemorrhage yang berdekatan dengan eksudat, atau jaringan microaneurysm yang luas. Pada citra Non-DR, aktivasi Conv. 4 lebih terpusat dan terstruktur, mencerminkan representasi retina sehat yang lebih sederhana secara semantik. Penelitian Bala et al. (2024) pada arsitektur CTNet mengonfirmasi bahwa lapisan konvolusi menengah memainkan peran krusial dalam memisahkan representasi fitur patologis dari retina normal, bahkan lebih efektif dibandingkan mekanisme attention pada Vision Transformer untuk kasus DR.

Conv. 5 — Fitur Semantik Diskriminatif Tingkat Tinggi

Lapisan konvolusi terakhir (Conv. 5, 256 filter 3×3) menghasilkan representasi paling abstrak dan diskriminatif sebelum diteruskan ke lapisan fully connected untuk klasifikasi akhir. Feature map Conv. 5 merepresentasikan "konsep" visual tingkat tinggi yang telah dipelajari model selama pelatihan. Pada citra DR, Conv. 5 menghasilkan pola aktivasi yang mencerminkan keberadaan kombinasi lesi patologis secara global—model pada tahap ini telah mengintegrasikan seluruh informasi dari lapisan sebelumnya untuk menghasilkan representasi diskriminatif yang kuat. Karakteristik aktivasi Conv. 5 pada citra DR tampak lebih tersebar dan beragam, sesuai dengan keragaman lesi yang dapat ditemukan pada retina penderita DR. Pada citra Non-DR, Conv. 5 menghasilkan representasi yang lebih terkonsolidasi dan bersih, mencerminkan kesederhanaan struktur retina normal dibandingkan retina yang mengalami kerusakan patologis. Temuan ini konsisten dengan hasil Elkenawy et al. (2026) yang menunjukkan bahwa lapisan konvolusi dalam AlexNet mampu mengekstrak fitur diskriminatif yang efektif untuk membedakan berbagai kondisi patologis retina.

Implikasi Klinis dan Explainability

Analisis visualisasi feature map Conv. 1 hingga Conv. 5 mengungkap mekanisme hierarkis yang digunakan AlexNet dalam mengklasifikasikan DR, memberikan wawasan penting bagi interpretasi klinis. Proses ekstraksi fitur berlangsung secara progresif: dari deteksi tepi dan tekstur dasar (Conv. 1–2), melalui kombinasi fitur lokal yang semakin kompleks (Conv. 3), hingga representasi semantik diskriminatif (Conv. 4–5) yang secara implisit menyandikan konsep klinis seperti keberadaan dan distribusi lesi retina. Dari perspektif klinis, temuan ini mengonfirmasi bahwa AlexNet tidak hanya belajar pola statistik superfisial, tetapi mengembangkan representasi internal yang berkorelasi dengan fitur patologis yang relevan secara medis—meskipun tanpa label eksplisit tentang jenis lesi.

Visualisasi ini juga mengidentifikasi Conv. 3 sebagai lapisan kritis di mana separasi representasi antara DR dan Non-DR mulai terbentuk secara signifikan. Temuan ini dapat

memandu pengembangan sistem CAD berbasis CNN di masa depan, misalnya dengan menerapkan mekanisme attention pada lapisan Conv. 3–5 untuk lebih menonjolkan fitur yang relevan secara klinis. Pendekatan ini juga membuka peluang untuk mengembangkan visualisasi yang lebih interaktif sebagai alat bantu interpretasi bagi klinisi, sejalan dengan tren penelitian terkini yang menggunakan Grad-CAM dan Attention-Rollout sebagaimana dilaporkan oleh peneliti dari MDPI Computers (2025). Perbedaan pola aktivasi yang konsisten antara kedua kelas juga memperkuat kepercayaan terhadap keandalan model AlexNet sebagai basis sistem CAD untuk deteksi DR.

KESIMPULAN

Penelitian ini menyajikan analisis komprehensif terhadap visualisasi feature map pada lima lapisan konvolusi AlexNet (Conv. 1–5) untuk klasifikasi Diabetic Retinopathy versus Non-Diabetic Retinopathy pada dataset APTOS 2019. Hasil observasi mengungkap mekanisme ekstraksi fitur hierarkis yang berlangsung secara progresif: lapisan awal (Conv. 1–2) mendeteksi tepi, tekstur, dan gradien dasar; lapisan tengah (Conv. 3) mengintegrasikan fitur tersebut menjadi representasi tekstur-bentuk dengan separasi kelas yang mulai signifikan; dan lapisan dalam (Conv. 4–5) membangun representasi semantik diskriminatif tingkat tinggi yang secara implisit menyandikan keberadaan dan distribusi lesi patologis retina.

Perbedaan pola aktivasi yang konsisten antara citra DR dan Non-DR pada seluruh lapisan konvolusi mengonfirmasi bahwa AlexNet tidak hanya belajar pola statistik, tetapi mengekstrak fitur yang berkorelasi dengan kondisi patologis retina yang relevan secara klinis. Lapisan Conv. 3 teridentifikasi sebagai titik kritis di mana representasi diskriminatif mulai terbentuk secara signifikan. Temuan ini berkontribusi pada aspek explainability model deep learning untuk aplikasi medis, memberikan dasar interpretasi visual yang mendukung kepercayaan klinisi terhadap sistem CAD berbasis CNN. Untuk penelitian selanjutnya, disarankan untuk mengintegrasikan metode Grad-CAM atau Attention-Rollout pada lapisan Conv. 3–5 sebagai visualisasi yang lebih informatif secara klinis, serta memperluas analisis ke arsitektur CNN modern seperti ResNet dan EfficientNet.

DAFTAR PUSTAKA

- Bala, R., Sharma, A., & Goel, N. (2024). CTNet: Convolutional transformer network for diabetic retinopathy classification. *Neural Computing and Applications*, 36, 4787–4809. <https://doi.org/10.1007/s00521-023-09394-7>
- Das, D., Biswas, S. K., & Bandyopadhyay, S. (2023). Detection of diabetic retinopathy using convolutional neural networks for feature extraction and classification (DRFEC). *Multimedia Tools and Applications*, 82, 29943–30001. <https://doi.org/10.1007/s11042-022-14165-4>
- Elkenawy, E. M., Khodadadi, N., Gaber, K. Sh., Khodadadi, E., Alhussan, A. A., Khafaga, D. S., & Eid, M. M. (2026). Automated retinal disease classification using deep learning and AlexNet with statistical models analysis. *PLOS ONE*, 21(1), e0338415. <https://doi.org/10.1371/journal.pone.0338415>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems (NIPS)*, 25, 1097–1105.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- MDPI Computers. (2025). Interpretable deep learning for diabetic retinopathy: A comparative study of CNN, ViT, and hybrid architectures. *Computers*, 14(5), 187. <https://doi.org/10.3390/computers14050187>

-
- Narayanan, B. N., Hardie, R. C., De Silva, M. S., & Kueterman, N. K. (2020). Hybrid machine learning architecture for automated detection and grading of retinal images for diabetic retinopathy. *Journal of Medical Imaging*, 7(3), 034501. <https://doi.org/10.1117/1.JMI.7.3.034501>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2020). Grad-CAM: Visual explanations from deep networks via gradient-based localization. *International Journal of Computer Vision*, 128, 336–359. <https://doi.org/10.1007/s11263-019-01228-7>
- Sun, H., Saeedi, P., Karuranga, S., Pinkepank, M., Ogurtsova, K., Duncan, B. B., et al. (2022). IDF Diabetes Atlas: Global, regional and country-level diabetes prevalence estimates for 2021 and projections for 2045. *Diabetes Research and Clinical Practice*, 183, 109119. <https://doi.org/10.1016/j.diabres.2021.109119>
- Zeiler, M. D., & Fergus, R. (2014). Visualizing and understanding convolutional networks. In *European Conference on Computer Vision (ECCV) 2014, Lecture Notes in Computer Science*, vol. 8689. Springer.