

Myopia Identification by Fundus Photo Image Classification Using Convolutional Neural Network

Giffari Ilham Laksono ^{1*}, Sri Winarno ^{2*}

* Teknik Informatika, Universitas Dian Nuswantoro
111202113507@mhs.dinus.ac.id ¹, sri.winarno@dsn.dinus.ac.id ²

Article Info

Article history:

Received 2025-08-01

Revised 2025-08-28

Accepted 2025-09-03

Keyword:

CNN, Classification,
Deep Learning,
EfficientNet-B0,
Miopia

ABSTRACT

Myopia is a significant vision problem worldwide, requiring early detection to prevent further damage. This study aims to develop an image classification model using a Convolutional Neural Network (CNN) to identify myopia based on fundus images. The dataset used was 124,749 fundus images, divided into 80% for training and 20% for testing. The applied architecture was EfficientNetB0, chosen for its ability to achieve high performance with efficient computation. Experimental results showed that this model successfully achieved a classification accuracy of 97% in distinguishing between myopic and non-myopic images. These findings demonstrate the potential of CNN, especially EfficientNetB0, as a diagnostic tool for automatic myopia identification, which can accelerate the detection process and improve the accuracy of clinical diagnosis.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Ketika mata tidak dapat melihat objek dengan jelas pada jarak jauh, disebut miopia atau rabun jauh. Kondisi ini ditandai dengan kondisi dimana cahaya yang memasuki mata terfokus di depan retina sehingga membuat objek yang jauh terlihat kabur[1]. Miopia atau rabun jauh adalah penyakit mata yang paling umum di seluruh dunia[2]. Prevelansi miopia meningkat pesat, dan ini telah menjadi masalah kesehatan masyarakat yang penting[3]. Data dari World Health Organization (WHO) sebanyak 285 juta penduduk dunia menderita gangguan penglihatan[4]. Miopia berkembang pada anak usia sekolah dan akan stabil pada usia remaja[5]. Faktor keturunan merupakan faktor penting penyebab miopia[6]. Masalah perilaku meliputi, namun tidak terbatas pada kebiasaan membaca sambil berbaring, membaca dalam cahaya redup, atau membaca terlalu berdekatan[7]. Deteksi dini sangat penting untuk mencegah gangguan penglihatan pada anak-anak, yang semakin meningkat akibat penggunaan gadget yang berlebihan[8].

Mendeteksi gangguan penglihatan melalui vision screening dapat dilakukan secara rutin dan direkomendasikan WHO untuk mendeteksi gangguan

penglihatan secara efisien[9]. Seorang profesional kesehatan mata biasanya melakukan pemeriksaan mata menggunakan teknik refraksi optik, yang mengukur kemampuan mata untuk melihat objek pada berbagai jarak. Namun, metode ini memerlukan alat diagnostik yang sering terbatas dan kunjungan langsung ke dokter. Kelainan refraksi yang tidak terkoreksi merupakan penyebab utama gangguan penglihatan dan penyebab kebutaan kedua[10]. Dengan kemajuan teknologi, analisis gambar medis, terutama foto fundus mata, telah menjadi teknik yang menjanjikan untuk mendeteksi berbagai gangguan penglihatan, termasuk miopia. Gambar yang diambil dari bagian dalam mata, terutama retina, yang memberikan informasi penting tentang kondisi kesehatan mata secara keseluruhan dikenal sebagai fundus foto.

Banyak penelitian berfokus pada pengembangan kecerdasan buatan, khususnya dalam bidang pembelajaran mesin dan deep learning, untuk mengembangkan sistem otomatis yang dapat mendeteksi miopia melalui analisis foto fundus. Foto fundus dipilih karena memberikan gambaran langsung tentang kondisi retina, yang sangat relevan untuk mendeteksi kelainan miopia, sementara metode lain seperti autorefractor tidak dapat memberikan gambaran mendalam tentang struktur mata. Deep learning

adalah teknik pembelajaran mesin yang menggunakan jaringan saraf tiruan dengan fungsi mirip otak manusia untuk memproses data besar[11][13]. Salah satu metode yang menjanjikan adalah penggunaan Convolutional Neural Network (CNN), sebuah jenis algoritma deep learning yang sangat baik untuk pengolahan gambar. Convolutional Neural Network (CNN), sebagai salah satu arsitektur deep learning untuk supervised learning sehingga metode ini dapat mempelajari sendiri dan mencari sendiri fitur atau ciri yang dapat membantu mengidentifikasi citra dan dapat menangani variasi deformasi pada gambar input seperti translasi, rotasi, dan skala[12]. Sebagai pembandingan, model CNN ini diuji terhadap metode tradisional seperti pemeriksaan refraksi optik yang dilakukan oleh profesional medis. CNN dipilih karena sangat efisien dalam memproses dan mengklasifikasikan data gambar. Berbeda dengan algoritma pembelajaran mesin seperti K-Nearest Neighbor atau Decision Trees, yang mengandalkan fitur yang harus dipilih secara manual oleh seorang ahli, CNN dapat secara otomatis mempelajari dan mengekstrak fitur-fitur penting dalam gambar tanpa memerlukan intervensi manusia. CNN sangat berguna untuk mengklasifikasikan kondisi mata pada gambar fundus karena dapat mengenali pola dalam gambar dengan sangat akurat. Identifikasi yang dilakukan pada sebuah citra memang sudah cukup lama dikembangkan, salah satunya yaitu dengan cara membedakan tekstur pada citra tersebut[14].

Beberapa penelitian sebelumnya, CNN telah digunakan untuk klasifikasi gambar fundus mata. Penelitian [15] menemukan kelainan refraksi menggunakan arsitektur CNN VGG-16. Namun, hasil F1-Score untuk label miopia masih rendah (di bawah 0,10), yang menunjukkan bahwa model tidak dapat membedakan pola miopia khusus. Studi lain yang menggabungkan CNN dengan algoritma lain, seperti model hibrida CNN-KNN[12], menunjukkan bahwa CNN meningkatkan akurasi dalam diagnosis penyakit mata tertentu, tetapi belum berkonsentrasi pada deteksi miopia secara khusus. Untuk klasifikasi penyakit mata, ResNet-50 juga digunakan dengan hasil yang baik, tetapi jumlah parameter yang terbatas dan kebutuhan komputasi tetap menjadi masalah[11]. Keterbatasan penelitian ini menunjukkan bahwa penelitian khusus tentang deteksi miopia dengan dataset berukuran besar dan arsitektur yang lebih efisien seperti EfficientNetB0 masih jarang dilakukan. Oleh karena itu, diharapkan bahwa penelitian ini diharapkan dapat memberikan model komputasi yang lebih ringan dan akurat untuk mendukung penggunaan diagnosis miopia berbasis gambar fundus.

CNN telah banyak digunakan dalam berbagai aplikasi medis, seperti mendeteksi glaukoma, miopia, retinopati diabetik, dan penyakit mata lainnya. CNN bekerja dengan mengekstraksi fitur penting gambar, seperti tepi dan tekstur, kemudian memprosesnya untuk menghasilkan prediksi mengenai kondisi mata. Keunggulan CNN terletak pada kemampuan untuk mempelajari fitur yang relevan secara otomatis tanpa intervensi manusia yang kompleks,

yang memungkinkannya mendeteksi penyakit mata dengan akurasi yang tinggi dan dalam waktu yang lebih cepat.


Meskipun teknologi CNN telah digunakan secara luas dalam berbagai aplikasi medis, masalah utama dalam mendeteksi miopia melalui foto fundus adalah bahwa untuk melatih model CNN, diperlukan dataset gambar yang besar dan berkualitas tinggi. Gambar fundus yang tidak jelas atau terdistorsi dapat menyulitkan model CNN untuk menemukan ciri-ciri miopia. Akibatnya, pengumpulan dan penyusunan dataset gambar yang representatif dan berkualitas tinggi sangat penting.

Gambar fundus mata akan dianalisis untuk mengidentifikasi ciri-ciri khas miopia, seperti perubahan pada bentuk atau ukuran cakram optik dan pembuluh darah retina yang dapat menunjukkan adanya miopia. Selain itu, penelitian ini berkonsentrasi pada peningkatan kinerja model CNN dengan menggunakan berbagai teknik pra-pemrosesan gambar, seperti normalisasi dan augmentasi data. Teknik-teknik ini dapat membantu model CNN menjadi lebih tahan terhadap variabilitas gambar. Oleh karena itu, diharapkan sistem yang dibuat dapat digunakan secara efektif untuk mengawasi dan menentukan miopia di klinik mata dan fasilitas kesehatan yang lebih terpencil yang mungkin tidak memiliki akses langsung ke dokter mata.

Penggunaan sistem otomatis berbasis CNN yang mendeteksi miopia melalui gambar fundus memungkinkan diagnosa dan pengobatan penyakit mata yang lebih cepat, akurat, dan efisien berkat kemajuan dalam teknologi pengolahan citra dan kecerdasan buatan. Diharapkan bahwa penerapan sistem ini akan meningkatkan kualitas dan aksesibilitas perawatan mata, terutama di wilayah dengan keterbatasan sumber daya medis.

II. METODE


Metode yang digunakan dapat dilihat pada Gambar 1.



Gambar 1. Flowchart metode EfficientNetB0

Program ini dimulai dengan memuat dataset pelatihan dan validasi, lalu preprocessing menerapkan augmentasi data untuk meningkatkan variasi. Model CNN dibangun dengan menggunakan arsitektur EfficientNetB0 sebagai base model, yang kemudian dilatih menggunakan optimizer Adam dan binary cross-entropy loss. Setelah pelatihan awal, model fine-tuned dengan membuka beberapa layer untuk melatih lebih lanjut dengan learning rate kecil. Selanjutnya, model dievaluasi dengan menghitung confusion matrix dan laporan klasifikasi, diikuti dengan menampilkan prediksi sampel gambar.


Proses ini melibatkan looping pada epoch pelatihan, fine-tuning, evaluasi data validasi, dan prediksi gambar. CNN digunakan agar dapat mengklasifikasi penyakit mata. Model tersebut dapat digambarkan pada Gambar 2.



Gambar 2. Arsitektur CNN

A. *EfficientNetB0*

Arsitektur CNN yang digunakan adalah EfficientNetB0, yang telah terbukti efisien dalam hal komputasi dan akurasi dalam pengolahan gambar. Dalam makalah berjudul "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks", EfficientNetB0 adalah salah satu model arsitektur deep learning yang dikembangkan oleh tim penelitian Google. Dengan menggunakan teknik pemodelan kompleks, EfficientNetB0 mengoptimalkan tiga dimensi utama, kedalaman jaringan (depth), resolusi gambar (resolution), dan jumlah kanal pada setiap lapisan untuk mengimbangi akurasi dan efisiensi komputasi. Model ini memiliki keunggulan dalam hal efisiensi karena menghasilkan kinerja yang lebih baik dibandingkan model lain dengan jumlah parameter yang lebih sedikit. Ini menjadikannya ideal untuk aplikasi yang membutuhkan komputasi rendah tetapi akurasi tinggi. Arsitektur EfficientNetB0 dapat dilihat pada gambar 3.



Gambar 3. Arsitektur EfficientNetB0

Untuk memungkinkan pengolahan data gambar yang lebih cepat dan pembelajaran yang lebih efektif, EfficientNetB0 menggunakan teknik Mobile Inverted Bottleneck Convolution (MBConv) dengan koneksi residual di bagian arsitektur. Dengan jumlah parameter yang lebih sedikit dan penggunaan sumber daya yang lebih efisien, EfficientNetB0 telah menjadi model pilihan di banyak aplikasi, terutama di perangkat dengan keterbatasan. Salah satu keunggulan utama dari EfficientNetB0 adalah kemampuannya untuk memberikan kinerja tinggi dalam hal pengenalan gambar dan klasifikasi dengan konsumsi daya dan waktu komputasi yang lebih rendah dibandingkan model deep learning lainnya seperti ResNet dan DenseNet. Parameter yang digunakan dalam metode ini dapat dilihat melalui Tabel I.

TABEL 1
HYPERPARAMETER


Parameter	Configuration
Arsitektur Dasar	EfficientNetB0 (pretrained)
Input Gambar	224x224x3
Optimizer	Adam
Learning Rate Awal	Default (0.001)
Learning Rate Fine-tune	0.00001 (1e-5)
Loss Function	Binary Crossentropy
Activation Output	Sigmoid
Activation Hidden	ReLU
Dropout Layer 1	0.5
Dense Layer	128 unit (ReLU)
Dropout Layer 2	0.3
Batch Size	32
Jumlah Epoch (awal)	20
Jumlah Epoch (Fine-tune)	10
Callbacks	Earlystopping
Data Augmentation	Flip, Rotate, Zoom
Preprocessing Dataset	image_dataset_from_directory

B. *Dataset*

Dataset berjumlah 124.749 yang terbagi menjadi 2 kelas, 63.294 kelas miopia dan 61.500 kelas normal. Penelitian ini memaparkan perbedaan mata miopia dan normal. Dataset yang digunakan merupakan dataset publik yang didapatkan dari Kaggle agar sesuai dengan penelitian sebelumnya yang menggunakan metode VGG-16 untuk klasifikasi berlabel miopia. Klasifikasi ini dapat membantu mendeteksi penyakit mata secara tepat dan akurat. Distribusi kelas dalam dataset ini cukup seimbang antara miopia dan normal, namun perlu dicatat bahwa dataset ini hanya mencakup gambar fundus dengan kualitas tertentu, yang dapat memengaruhi kinerja model pada gambar dengan kualitas rendah. Citra foto fundus dapat dilihat pada gambar 4.

TABEL II
SUMBER DAN DETAIL DATASET

Detail Dataset	
Nama	Myopia Image Dataset
Jumlah Data	124.749
Label	Myopia, Normal
URL	https://www.kaggle.com/datasets/kellysanderson/myopia-image-dataset



Gambar 4. Fundus miopia dan normal

C. Preprocessing

Pada penelitian ini, preprocessing dilakukan menggunakan bahasa pemrograman Python dan pustaka machine learning TensorFlow karena memiliki ekosistem pengolahan data dan gambar yang kuat dan mendukung berbagai model jaringan saraf tiruan. Tujuan dari preprocessing adalah untuk memastikan bahwa data dapat dikenali dan diproses dengan baik oleh model CNN yang digunakan. Ini dicapai melalui standarisasi ukuran gambar, pelabelan otomatis, dan optimasi pipeline data.

Sistem ini menggunakan Convolutional Neural Network (CNN), jenis arsitektur deep learning yang unggul dalam klasifikasi gambar. CNN menggunakan lapisan konvolusi, pooling, dan aktivasi non-linear untuk mengekstraksi fitur spasial dari gambar. Pendekatan transfer learning menggunakan arsitektur EfficientNetB0, yang telah dilatih sebelumnya menggunakan dataset ImageNet, digunakan untuk mempercepat dan menyederhanakan pelatihan. Model ini dikenal memiliki jumlah parameter yang banyak dan kinerja yang tepat, sehingga sangat cocok untuk digunakan dalam klasifikasi dua kelas, seperti normal dan miopia.

Dalam penelitian ini, proses preprocessing dilakukan dengan memuat kumpulan gambar dari direktori yang telah dikategorikan ke dalam label normal dan miopia. Dataset gambar secara otomatis dilabeli dengan angka biner yang didasarkan urutan abjad. Selain itu, normalisasi dan ukuran gambar diubah menjadi 224 x 224 piksel, yang memenuhi persyaratan ukuran input EfficientNetB0. Agar proses pelatihan menjadi lebih efektif, dataset dikelompokkan ke dalam batch dan diproses melalui prefetching. Untuk meningkatkan keberagaman data, diterapkan augmentasi acak seperti rotasi, zoom, dan flipping. Ini memungkinkan model untuk mempelajari karakteristik berbagai variasi visual.

Proses pelatihan model menjadi lebih konsisten dan akurat berkat preprocessing yang dirancang secara terstruktur. Dengan augmentasi data, kemampuan generalisasi pada data baru akan ditingkatkan. Penggunaan prefetch dan ukuran batch yang tepat juga membantu mengurangi beban memori selama pelatihan. Proses preprocessing ini secara keseluruhan memajukan model CNN, terutama EfficientNetB0, untuk belajar dan menghasilkan klasifikasi miopia yang dapat diandalkan.

III. HASIL DAN PEMBAHASAN

A. Pembagian Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari lebih dari 124.000 gambar fundus mata dan terdiri dari dua kelas, miopia dan normal. Dataset dibagi menjadi dua bagian utama, yaitu data pelatihan dan data pengujian, menggunakan struktur direktori yang sesuai dengan format pada TensorFlow. Pembagian dilakukan secara manual ke dalam folder train dan val, masing-masing dengan label miopia dan normal. Metode ini memungkinkan sistem untuk mengelompokkan data secara otomatis dan memberi label biner yang didasarkan pada nama folder yang berada dalam urutan alfabet. Penggunaan batch dan resizing gambar fundus mata secara otomatis juga membantu menyesuaikan data dengan persyaratan input model EfficientNetB0.

B. Dataset Pelatihan

Dataset pelatihan, yang terdiri dari ribuan gambar fundus mata untuk masing-masing kelas, disimpan dalam direktori train. Setiap gambar diubah ukurannya menjadi 224 x 224 piksel, dan 32 gambar disusun dalam kumpulan. Selama pemanggilan dataset, TensorFlow memberikan label biner kepada masing-masing kelas, seperti miopia = 0 dan normal = 1, sesuai dengan urutan alfabet. Untuk meningkatkan efisiensi pelatihan, dataset ini di-prefetch secara otomatis. Ini memungkinkan paralelisme antara eksekusi model dan pemrosesan data, sehingga proses pelatihan secara keseluruhan dipercepat.

Data augmentation diterapkan pada dataset pelatihan untuk meningkatkan kemampuan generalisasi model. Augmentasi ini dilakukan secara on-the-fly di dalam model menggunakan layer keras. Ini mencakup flip horizontal, rotation acak sebesar 10%, dan zoom sebesar 10% terhadap gambar fundus mata asli. Berikutnya. Dengan augmentasi ini, model dilatih untuk mengenali fitur dari berbagai sudut dan skala, sehingga tidak terlalu bergantung pada pola tertentu dalam dataset awal. Ini telah ditunjukkan untuk menangani perubahan alami dalam gambar fundus mata manusia, seperti pencahayaan, posisi, dan ekspresi.

C. Dataset Pengujian

Dataset pengujian atau validasi disimpan di direktori val. Data pelatihan memiliki struktur folder yang sama. Tidak ada augmentasi pada dataset ini, sehingga hasil evaluasi benar-benar menunjukkan kemampuan model untuk menangani data yang belum pernah dilihat sebelumnya. Selama pelatihan, data pengujian digunakan sebagai metrik validasi untuk memantau akurasi dan kehilangan model. Ini juga berfungsi sebagai dasar untuk menerapkan mekanisme penundaan dini. Dengan demikian, model tidak akan dilatih terlalu banyak, yang dikenal sebagai overfitting, dan akan berhenti ketika kinerja validasi tidak lagi meningkat.


Setelah model dilatih dan disesuaikan, proses evaluasi model juga dilakukan pada dataset pengujian ini. Untuk

seluruh batch gambar validasi, model melakukan prediksi. Hasil prediksi dibandingkan dengan label asli untuk menghitung akurasi, precision, recall, dan skor F1. Karena dataset pengujian ini mewakili kondisi nyata yang akan dihadapi ketika model diterapkan dalam skenario diagnostik, mereka sangat penting sebagai tolok ukur performa akhir model. Oleh karena itu, distribusi data dan kualitasnya sangat memengaruhi validitas evaluasi model pada tahap ini.

D. Hasil Evaluasi Model

Setelah pelatihan selesai, model dievaluasi dengan dataset pengujian untuk mengevaluasi kemampuan untuk mendeteksi gambar fundus mata dengan kondisi normal atau miopia. Proses evaluasi dilakukan dengan train-test split dengan pembagian sebanyak 80% dataset pelatihan dan 20% dataset pengujian. Hasil pelatihan menunjukkan bahwa setelah melakukan fine-tuning pada lapisan atas EfficientNetB0, model menunjukkan akurasi validasi yang tinggi dan stabil. Penggunaan EarlyStopping terbukti efektif dalam mencegah model melebihi-lebihkan data latih, sehingga akurasi validasi tidak menurun meskipun pelatihan dilakukan dalam beberapa titik waktu. Selain itu, proses fine-tuning meningkatkan kinerja model dengan mengaktifkan kembali sebagian lapisan EfficientNet agar dapat belajar pola khusus.

Evaluasi model dilakukan dengan menggunakan metrik precision, recall, F1-score, dan AUC untuk memberikan gambaran yang lebih komprehensif tentang performa model dalam klasifikasi miopia. Grafik akurasi dan kehilangan untuk menunjukkan tren yang seimbang antara data pelatihan dan validasi, grafik akurasi menunjukkan kemampuan model untuk belajar dari data secara progresif, sementara grafik kehilangan menunjukkan penurunan nilai kesalahan seiring waktu. Hal ini menunjukkan bahwa model tidak mengalami overfitting atau underfitting yang signifikan, dan mereka dapat dengan mudah digeneralisasi ke data baru. Hasil pelatihan yang cukup optimal dihasilkan oleh kombinasi arsitektur EfficientNetB0, augmentasi data, dan regularisasi dropout.




Gambar 5. Grafik accuracy

Hasil evaluasi lebih lanjut menunjukkan bahwa model memiliki performa seimbang di kedua kelas (miopia dan normal), dengan nilai F1 yang seimbang. Confusion matrix

dan laporan klasifikasi menunjukkan jumlah prediksi benar dan salah untuk masing-masing kelas, yang membantu dalam menentukan jenis kesalahan yang sering terjadi.

	precision	recall	f1-score	support
Normal	0.96	0.99	0.97	12660
Miopia	0.99	0.96	0.97	12300
accuracy			0.97	24960
macro avg	0.97	0.97	0.97	24960
weighted avg	0.97	0.97	0.97	24960

Gambar 6. F1-score



Gambar 7. Confusion matrix


Sebagai tambahan, visualisasi gambar fundus mata contoh dari dataset validasi dan hasil prediksinya dilakukan. Sembilan gambar fundus mata menunjukkan label asli dan hasil prediksi model, bersama dengan pewarnaan judul untuk menunjukkan apakah prediksi benar atau salah. Kemampuan model untuk mengklasifikasikan gambar fundus mata secara akurat ditunjukkan dalam visualisasi ini. Terakhir, model yang telah dilatih dan dievaluasi disimpan dalam bentuk.h5. Ini memungkinkan penggunaan kembali untuk pengujian lanjutan atau penerapan pada aplikasi berbasis AI dalam bidang kesehatan mata.



Gambar 8. Visualisasi hasil pengujian



Gambar 9. Visualisasi hasil pengujian



Gambar 10. Visualisasi hasil pengujian

IV. KESIMPULAN

Berdasarkan hasil implementasi dan evaluasi yang telah dilakukan, sistem klasifikasi citra untuk deteksi miopia yang berbasis Convolutional Neural Network (CNN) dan pendekatan pembelajaran transfer yang menggunakan arsitektur EfficientNetB0 dapat dianggap stabil dan berhasil membedakan gambar fundus mata dengan kondisi normal dan miopia. Proses preprocessing seperti pembagian dataset, augmentasi gambar, normalisasi ukuran gambar, dan pelabelan otomatis sangat penting untuk kualitas pelatihan model. Dengan menggunakan teknik augmentasi gambar seperti rotasi, flipping, dan zoom, kemampuan generalisasi model terhadap variasi visual yang ada di dataset menjadi lebih baik. Untuk klasifikasi biner, model CNN dibangun dengan menambahkan lapisan global average pooling, lapisan tebal, dropout, dan sigmoid pada output. Selain itu, model CNN dilatih dalam dua tahap: pelatihan awal dan penyesuaian khusus. Hasil evaluasi yang dilakukan menggunakan laporan klasifikasi dan matrix confusion menunjukkan bahwa model mampu membuat prediksi yang akurat terhadap data validasi dan mencapai nilai akurasi, precision, recall, dan F1-score yang tinggi. Selain itu, visualisasi prediksi pada gambar fundus mata menunjukkan bahwa model memiliki kemampuan untuk secara konsisten membedakan gambar fundus mata normal dan miopia. Dengan temuan ini, sistem ini dapat dikembangkan lebih lanjut sebagai alat bantu untuk diagnosis awal miopia secara otomatis berbasis citra. Ini juga dapat diterapkan di bidang medis dan sistem screening berbasis kecerdasan buatan.

DAFTAR PUSTAKA

- [1] J. Ilmiah Kesehatan Sandi Husada, S. Faktor Risiko Kelainan Miopia Di Rumah Sakit Pertamina Bintang Amin, T. Lestari, T. Triwahyuni, and R. Syuhada, "Risk Factors for Myopia Abnormalities at the Bintang Amin Pertamina Hospital," Juni, vol. 11, no. 1, pp. 305–312, 2020, doi: 10.35816/jiskh.v10i2.275.
- [2] A. Sufina Ginting and E. Suhaymi, "Artikel Penelitian Dampak Penggunaan Gadget Terhadap Kejadian Miopia Siswa-Siswi Madrasah Aliyah Negeri 2 Langkat Tahun 2022," vol. 5, 2024, [Online]. Available: <https://jurnal.umsu.ac.id/index.php/JPH>
- [3] X. Zou et al., "Relationship between dry eye disease and myopia: A systematic review and meta-analysis," Heliyon, vol. 10, no. 19, Oct. 2024, doi: 10.1016/j.heliyon.2024.e38674.
- [4] A. Saputra, F. Doringin, M. Wahyu Budiana, A. Refraksi Optisi, and O. Gapopin, "Gambaran Status Refraksi Di Sekolah Smk Kesehatan Letris Indonesia 2 Kota Tangerang Selatan." vol. 5, 2024, [Online]. Available: <https://jurnal.umsu.ac.id/index.php/JPH>
- [5] I. S. Primadiani, F. L. Rahmi, S. P. Ilmu, K. Mata, and J. H. Soedarto, "Faktor-Faktor Yang Mempengaruhi Progresivitas Miopia Pada Mahasiswa Kedokteran," vol. 6, no. 4, pp. 1505–1517, 2017.
- [6] S. Atika Salsabila et al., "Literature Review: Hubungan Antara Faktor Genetik, Gaya Hidup, dan Prevalensi Miopia."
- [7] R. Putri Zahra Lubis and M. Sarirah, "Risiko Miopia Terhadap Jarak Pandang Dekat Pada Mahasiswa Fakultas Kedokteran Universitas Muhammadiyah Sumatera Utara," vol. 5, 2024, [Online]. Available: <https://jurnal.umsu.ac.id/index.php/JPH>
- [8] N. Puspitasari et al., "Gambaran Kelainan Refraksi Pada Siswa/I Di Sdn Padaulun Kecamatan Majalaya Tahun 2024."
- [9] M. Marlina Simarmata, F. Doringin, N. Aulia Khofifah, and Z. Rahma Aulia, "Upaya Pencegahan Miopia Pada Anak-Anak Sekolah Dalam Rangka Hari Kesehatan Nasional Di Jakarta Convention Center."
- [10] A. P. Sambulele, I. H. M. Najoran, and W. P. Supit, "Gambaran Kejadian Miopia pada Mahasiswa Fakultas Kedokteran Universitas Sam Ratulangi," Medical Scope Journal, vol. 7, no. 1, pp. 85–90, Jul. 2024, doi: 10.35790/msj.v7i1.55450.
- [11] E. Hartati, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Model Resnet-50."
- [12] A. Sandy Wardhani, F. Tri Anggraeny, and A. Mustika Rizki, "Penerapan Model Hibrida Cnn-Knn Untuk Klasifikasi Penyakit Mata," 2024.
- [13] C. Jatmoko and H. Lestiawan, "Seminar Nasional Riset dan Inovasi Teknologi (SEMNAS RISTEK) 2024 Jakarta," 2024.
- [14] E. F. Nurona Cahya et al., "SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)." [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [15] M. S. Qulub and S. Agustin, "Identifikasi Penyakit Mata Dengan Klasifikasi Citra Foto Fundus Menggunakan Convolutional Neural Network (CNN)," 2024