

## CESS

(Journal of Computer Engineering, System and Science)

Available online: <https://jurnal.unimed.ac.id/2012/index.php/cess>

ISSN: 2502-714x (Print) | ISSN: 2502-7131 (Online)



### Penerapan Deep Learning Berbasis DenseNet Untuk Deteksi Diabetic Retinopathy Pada Citra Fundus Mata

#### *Implementation of DenseNet-Based Deep Learning for Diabetic Retinopathy Detection on Fundus Images*

Ade Maulani Bilgis<sup>1\*</sup>, Nurhadi Surojudin<sup>2</sup>, Ahmad Fauzi<sup>3</sup>

<sup>1,2,3</sup>Teknik Informatika, Universitas Pelita Bangsa

Jl. Inpeksi Kalimalang No.9, Cibatu, Cikarang Selatan, Kab Bekasi, Jawa Barat

email: <sup>1</sup>[ademaulanibilgiss@gmail.com](mailto:ademaulanibilgiss@gmail.com), <sup>2</sup>[nurhadi@pelitabangsa.ac.id](mailto:nurhadi@pelitabangsa.ac.id),

<sup>3</sup>[ahmadfauzimpd1993@gmail.com](mailto:ahmadfauzimpd1993@gmail.com)

\*Corresponding Author

#### ABSTRAK

Deteksi dini diabetic retinopathy sangat penting untuk mencegah komplikasi pada penglihatan, termasuk kebutaan permanen. Namun, proses diagnosis secara manual menggunakan citra fundus memerlukan waktu dan keahlian tinggi. Penelitian ini bertujuan untuk mengembangkan model deep learning berbasis densenet yang di fine-tune untuk mendeteksi *diabetic retinopathy* secara otomatis dari citra fundus mata. Dengan dataset sebesar 2.840 gambar yang terbagi ke dalam dua kelas yaitu DR dan NO\_DR. Model dilatih menggunakan proses preprocessing dan augmentasi data, dengan hasil evaluasi yang menunjukkan bahwa model mencapai akurasi sebesar 96% pada dua kelas yang seimbang, dan AUC 0.99. Hal itu mencerminkan kemampuan klasifikasi yang sangat baik serta sensitivitas yang tinggi, nilai recall yang tinggi mengindikasikan bahwa model mampu mengenali sebagian besar pasien yang mengalami DR. Penelitian ini menunjukkan bahwa densenet dengan fine-tune dapat menghasilkan model deteksi yang akurat dan berpotensi untuk membantu diagnosis dini *diabetic retinopathy*.

**Kata Kunci:** *Diabetic Retinopathy; Deep Learning; Densenet; Citra Fundus.*

#### ABSTRACT

Early detection of diabetic retinopathy is essential to prevent vision complications, including permanent blindness. However, manual diagnosis using fundus images requires considerable time and expert interpretation. This study aims to develop a deep learning model based on a fine-tuned DenseNet architecture to automatically detect diabetic retinopathy from retinal



This open access article is distributed under a Creative Commons Attribution (CC-BY) 4.0 license

fundus images. A dataset of 2,840 images was used, divided into two classes: DR and NO\_DR. The model was trained using preprocessing and data augmentation techniques, with evaluation results showing an accuracy of 96% across both balanced classes and an AUC of 0.99. These results indicate excellent classification performance and high sensitivity, with a high recall value suggesting that the model effectively identifies most patients with DR. This study demonstrates that a fine-tuned DenseNet can produce an accurate detection model and has strong potential to support early diagnosis of diabetic retinopathy.

**Keywords:** *Diabetic Retinopathy; Deep Learning; Densenet; Fundus Images.*

---

## 1. PENDAHULUAN

Diabetic retinopathy adalah salah satu komplikasi serius pada penderita diabetes yang ditandai dengan kerusakan pembuluh darah pada area retina akibat dari kadar gula yang terlalu tinggi dalam jangka waktu yang lama, kondisi ini dapat menyebabkan gangguan pada penglihatan sehingga menyebabkan kebutaan jika tidak terdeteksi dan ditangani secara dini [1]. Menurut WHO (World Health Organization) pada tahun 2022 ada sekitar 14% orang dewasa berusia 18 tahun ke atas mengidap penyakit ini [2]. Pada penelitian aghnaita menunjukkan bahwa satu dari tiga penderita diabetes beresiko mengalami gejala diabetic retinopathy, baik yang terdiagnosis maupun tidak, dengan perkiraan jumlah kasus yang mencapai hingga 22,27% pada tahun 2045 [3].

Diabetic retinopathy terjadi pada pembuluh darah di area retina mata. Oleh karena itu, pendeteksian diabetic retinopathy secara dini masih menjadi tantangan dalam bidang medis, metode pemeriksaannya tidak dapat dilakukan secara langsung dengan mata karena terjadinya dibagian dalam retina. Namun, pemeriksaan dapat dilakukan menggunakan kamera fundus, yaitu alat yang mampu mengambil gambar bagian dalam mata yang berguna untuk memperoleh informasi mengenai struktur internal seperti retina, makula, pembuluh darah retina, dan saraf mata [4]. Citra yang dihasilkan dari kamera fundus dapat dikenal sebagai citra fundus mata [5], biasanya dianalisis secara manual oleh dokter spesialis dengan cara mengamati gambar tersebut. Namun, metode pengamatan manual ini memiliki kekurangan, seperti memerlukan waktu yang cukup lama serta beresiko terjadi kesalahan manusia (*human error*) yang dapat memengaruhi akurasi diagnosis.

Seiring perkembangan teknologi, pendekatan berbasis kecerdasan buatan atau *Artificial Intelligence* (AI), khususnya *deep learning*, mulai diandalkan untuk membantu meningkatkan akurasi serta efisiensi dalam mendiagnosis citra medis secara otomatis. Beberapa penelitian telah dilakukan untuk mengatasi keterbatasan manual, salah satu penelitian memanfaatkan metode ekstraksi fitur manual sebelum klasifikasi menggunakan algoritma *machine learning* [6]. Meskipun pendekatan ini cukup efektif, namun masih bergantung pada proses seleksi fitur yang eksplisit. Studi lain telah menerapkan arsitektur CNN untuk melakukan ekstraksi fitur dan klasifikasi secara otomatis dari citra fundus mata [7]. Namun, penelitian tersebut belum mengoptimalkan aliran informasi antar lapisan jaringan, yang berpotensi memengaruhi akurasi pada deteksi.

Berdasarkan celah tersebut, penelitian ini bertujuan untuk menerapkan arsitektur *Dense Convolutional Network* (Densenet) untuk mendeteksi diabetic retinopathy secara otomatis. Densenet dirancang untuk membangun koneksi langsung antar beberapa lapisan jaringan, sehingga fitur dari lapisan awal tetap tersedia dan dapat digunakan oleh lapisan-lapisan berikutnya [8]. Dengan cara ini, informasi penting tidak mudah hilang selama proses

pelatihan, yang diharapkan dapat meningkatkan akurasi klasifikasi dan efisiensi sistem secara keseluruhan.

## 2. DASAR/TINJAUAN TEORI (12 PT)

### 2.1. Deep Learning

Deep learning adalah teknik pembelajaran mesin yang meniru cara kerja otak manusia dalam memproses data secara bertahap [8]. Dengan kemampuannya mengenali pola yang kompleks secara otomatis tanpa desain fitur manual, deep learning banyak diterapkan di berbagai bidang, seperti analisis data medis hingga pengenalan suara [9]. Model deep learning di latih menggunakan kumpulan data besar, sehingga memungkinkan model untuk mengidentifikasi pola atau karakteristik tertentu pada data yang berhubungan dengan kemungkinan keberhasilan pada pendeteksian [10]. Karena hal tersebut membuat deep learning menjadi metode yang sangat relevan untuk melakukan tugas pengenalan pola, termasuk dalam analisis citra medis.

### 2.2. Densenet

Densenet (*Densely Connected Convolutional Network*) merupakan salah satu arsitektur jaringan saraf konvolusional yang dirancang dengan menghubungkan setiap lapisan ke seluruh lapisan sebelumnya secara langsung. Pendekatan ini meningkatkan efisiensi aliran informasi dan pemanfaatan kembali fitur, serta membantu mengatasi permasalahan *vanishing gradient* selama proses pelatihan [8]. Arsitektur Densenet terdiri dari dua komponen utama, yaitu *dense block* dan *transition layer*. *Transition layer* berfungsi menjaga efisiensi model dan mengurangi risiko *overfitting* [9], sedangkan *dense block* memungkinkan fitur yang dihasilkan dari setiap lapisan untuk digunakan kembali oleh seluruh lapisan berikutnya, sehingga memperkuat kemampuan representasi jaringan [10].

### 2.3. Diabetic Retinopathy

Diabetic retinopathy (DR) adalah salah satu komplikasi utama dari penyakit diabetes melitus yang menyerang pembuluh darah mikro di retina, dan menjadi penyebab utama gangguan penglihatan bahkan kebutaan, terutama pada usia produktif [11]. Diabetic retinopathy memengaruhi tiga dari empat orang yang hidup dengan diabetes karena kondisi ini berkaitan erat dengan hiperglikemia kronis, yaitu kadar gula darah tinggi yang berlangsung lama, serta kelainan vaskular di retina, seperti mikroaneurisma, perdarahan retina, dan edema makula [12]. Secara global, diabetic retinopathy merupakan penyebab kebutaan yang dapat dicegah dengan melakukan pendeteksian dini melalui funduskopi atau analisis citra fundus yang berperan sangat penting untuk menegaskan diagnosis. Dengan pengelolaan yang tepat, seperti kontrol gula darah dan perawatan retina, perkembangan diabetic retinopathy dapat diperlambat dan risiko kehilangan penglihatan dapat diminimalkan [13].

### 2.4. Citra Fundus

Citra fundus merupakan hasil dari teknik pencitraan menggunakan kamera fundus untuk menangkap bagian dalam mata, terutama area fundus yang mencakup retina, saraf optikus, makula, dan pembuluh darah retina [14]. Menggunakan sinar optik khusus pencitraan fundus dan struktur retina, citra fundus secara luas digunakan untuk pemeriksaan klinis dan diagnosis penyakit mata seperti makulopati diabetic retinopathy, dan juga glaukoma [15], pada mata yang sehat, umumnya struktur fundus akan tampak jernih dengan pola pembuluh darah yang teratur. Pemeriksaan fundus sangat penting karena kelainan pada pola pembuluh darah dapat mengindikasikan penyakit pada area mata. Selain itu, citra fundus juga digunakan untuk

melakukan pemantauan penyakit sistemik seperti diabetes melitus dan hipertensi, yang dapat memengaruhi kesehatan retina [16]. Melalui analisis citra ini, gejala awal penyakit dapat dideteksi secara dini untuk mencegah kerusakan penglihatan yang lebih parah.



Gambar 1. Citra Fundus Mata

### 3. METODE


Dalam penelitian ini menggunakan Google colab, platform berbasis cloud untuk pemrograman python dan pengembangan deep learning yang dipilih karena mendukung GPU untuk mempercepat proses pelatihan pada model, serta perangkat computer dengan spesifikasi processor AMD Ryzen 3 dengan penyimpanan 512 GB NVMe SSD. Pada penelitian ini juga menggunakan data sekunder sebagai jenis data yang dianalisis, data tersebut berupa citra fundus mata yang berasal dari platform Kaggle, sebuah situs penyedia dataset public yang sering digunakan untuk memudahkan dalam penelitian akademis dan pengembangan teknologi (<https://www.kaggle.com/datasets/pkdarabi/diagnosis-of-diabetic-retinopathy>). Dataset tersebut terdiri dari 2838 citra fundus mata dengan dua kelas yaitu citra fundus yang terkena diabetic retinopathy dan juga citra fundus yang tidak terkena diabetic retinopathy.

Tabel 1. Dataset

| Nama folder | Jumlah |
|-------------|--------|
| DR          | 1.408  |
| NO_DR       | 1.430  |




NO\_DR



DR

Gambar 2. Data citra fundus mata

Untuk mempermudah pemahaman alur kerja system yang diusulkan, gambar dibawah menyajikan flowchart proses pelatihan dan evaluasi model deep learning berbasis densenet dalam mendeteksi diabetic retinopathy.



Gambar 3. Flowchart proses deteksi diabetic retinopathy

Tahapan dimulai dari proses input dataset berupa citra fundus yang telah diklasifikasikan ke dalam dua folder yaitu DR (mengindikasikan diabetic retinopathy) dan NO\_DR (normal). Selanjutnya, data masuk ke tahap *preprocessing*, yang terdiri dari resize ukuran gambar agar sesuai dengan input model (di ubah ke ukuran 224 x 224 piksel), lalu di lanjut normalisasi nilai piksel menjadi 0-1, dan pembagian data menjadi data pelatihan dan validasi (*train-test split*).

Pada tahap berikutnya, dilakukan pemodelan menggunakan densenet, yaitu dengan memanfaatkan arsitektur *pre-trained* densenet121. Proses *fine-tuning* dilakukan dengan membuka beberapa layer akhir agar model dapat menyesuaikan parameter terhadap karakteristik citra fundus diabetic retinopathy.

Setelah model selesai dibangun, tahap selanjutnya adalah pelatihan model, yang melibatkan pemilihan *optimizer*, fungsi *loss*, dan pengaturan jumlah *epochs*. Model dilatih menggunakan dataset pelatihan dan dipantau menggunakan data validasi untuk menghindari *overfitting*.

Langkah terakhir adalah evaluasi model, yang dilakukan dengan menghitung metrik kinerja seperti akurasi, precision, recall, F1-score, serta menampilkan confusion matrix dan ROC curve untuk mengukur performa klasifikasi secara keseluruhan. Proses berakhir pada tahapan evaluasi untuk menyimpulkan efektivitas model.


#### 4. HASIL DAN PEMBAHASAN

Pada penelitian ini, proses pelatihan model dilakukan selama 10 epoch dengan densenet yang telah di *fine-tune*. Hasil pelatihan menunjukkan bahwa akurasi pelatihan meningkat secara konsisten dari epoch pertama hingga terakhir, yaitu dari 64.95% menjadi 93.64%. Sementara itu, akurasi validasi juga meningkat dari 82.25% pada epoch pertama hingga mencapai 96.66% pada epoch ke-10. Hal ini menunjukkan bahwa model mampu belajar efektif tanpa overfitting yang signifikan.

```
Epoch 1/10
72/72 ----- 0s 9s/step - accuracy: 0.6495 - auc: 0.7170 - loss: 0.6372/usr/local/lib/python3.11/dist-packages/keras/src/trainers/data_adapters/py_dataset_adapter
self._warn_if_super_not_called()
72/72 ----- 891s 12s/step - accuracy: 0.6507 - auc: 0.7184 - loss: 0.6361 - val_accuracy: 0.8225 - val_auc: 0.9249 - val_loss: 0.5019
Epoch 2/10
72/72 ----- 592s 8s/step - accuracy: 0.8775 - auc: 0.9367 - loss: 0.4003 - val_accuracy: 0.8946 - val_auc: 0.9579 - val_loss: 0.3539
Epoch 3/10
72/72 ----- 623s 9s/step - accuracy: 0.9078 - auc: 0.9566 - loss: 0.3100 - val_accuracy: 0.9262 - val_auc: 0.9771 - val_loss: 0.2673
Epoch 4/10
72/72 ----- 599s 8s/step - accuracy: 0.9160 - auc: 0.9623 - loss: 0.2706 - val_accuracy: 0.9244 - val_auc: 0.9784 - val_loss: 0.2306
Epoch 5/10
72/72 ----- 604s 8s/step - accuracy: 0.9204 - auc: 0.9690 - loss: 0.2420 - val_accuracy: 0.9455 - val_auc: 0.9827 - val_loss: 0.2044
Epoch 6/10
72/72 ----- 603s 8s/step - accuracy: 0.9186 - auc: 0.9667 - loss: 0.2302 - val_accuracy: 0.9473 - val_auc: 0.9869 - val_loss: 0.1758
Epoch 7/10
72/72 ----- 596s 8s/step - accuracy: 0.9279 - auc: 0.9765 - loss: 0.2034 - val_accuracy: 0.9508 - val_auc: 0.9873 - val_loss: 0.1724
Epoch 8/10
72/72 ----- 592s 8s/step - accuracy: 0.9412 - auc: 0.9800 - loss: 0.1816 - val_accuracy: 0.9578 - val_auc: 0.9872 - val_loss: 0.1606
Epoch 9/10
72/72 ----- 592s 8s/step - accuracy: 0.9321 - auc: 0.9783 - loss: 0.1903 - val_accuracy: 0.9684 - val_auc: 0.9920 - val_loss: 0.1367
Epoch 10/10
72/72 ----- 618s 9s/step - accuracy: 0.9364 - auc: 0.9772 - loss: 0.1896 - val_accuracy: 0.9666 - val_auc: 0.9910 - val_loss: 0.1397
```

Gambar 4. Epoch

Terlihat dari gambar dibawah, loss model juga mengalami penurunan drastis, dari nilai awal sebesar 0.6 menjadi 0.1 sekian untuk data pelatihan, dan dari 0.5 menjadi 0.1 sekian untuk data validasi. Penurunan loss yang signifikan ini mencerminkan bahwa model tidak hanya meningkat dalam hal akurasi, tetapi juga stabil dalam pembelajaran.



Gambar 5. Data citra fundus mata

##### 4.1. Evaluasi Kinerja Model

Evaluasi dilakukan pada data uji sebanyak 569 citra fundus, terdiri dari 283 citra kelas NO\_DR dan 286 citra kelas DR. Berdasarkan confusion matrix pada table di bawah. Model berhasil mengklasifikasikan 273 citra NO\_DR dan 274 citra DR dengan benar, sementara hanya 22 citra diklasifikasikan salah.

Tabel 2. Confusion Matrix


|       | NO_DR | DR  |
|-------|-------|-----|
| NO_DR | 273   | 10  |
| DR    | 12    | 274 |

Tabel klasifikasi dibawah menunjukkan bahwa model mencapai nilai precision, recall, dan f1-score yang sangat tinggi, yaitu sebesar 0.96 untuk kedua kelas, yang menunjukkan keseimbangan antara kemampuan model dalam mengenali pasien dengan DR dan NO\_DR. Terlihat recall yang tinggi pada kelas DR memiliki implikasi klinis yang krusial, karena model berhasil meminimalkan kasus *false negative*, yakni pasien dengan diabetic retinopathy yang tidak terdeteksi. Hal ini sangat penting dalam konteks skrining dini, karena kasus yang tidak terdeteksi dapat berdampak pada keterlambatan pengobatan dan risiko kebutaan.

Tabel 3. Hasil evaluasi

|          | Precision | Recall | F1-Score |
|----------|-----------|--------|----------|
| NO_DR    | 0.96      | 0.94   | 0.96     |
| DR       | 0.96      | 0.96   | 0.96     |
| Accuracy | 0.96      |        |          |

Terlihat evaluasi model pada data secara keseluruhan sebesar 96%, serta nilai AUC (*Area Under Curve*) pada gambar dibawah menunjukkan sebesar 0.99. Hal ini menunjukkan bahwa model memiliki kemampuan yang sangat tinggi dalam membedakan antar citra fundus normal dan yang mengindikasikan diabetic retinopathy.



Gambar 5. ROC Curve

Meskipun performa model tergolong sangat tinggi, masih terdapat 10 citra NO\_dR yang diklasifikasikan sebagai DR dan 12 citra DR yang diklasifikasikan sebagai NO\_DR. Kesalahan ini dapat disebabkan oleh kualitas pada citra fundus yang kurang baik, pencahayaan yang tidak seragam, atau noise yang menyebabkan pola pembuluh darah menjadi tidak terbaca secara

jasas oleh model. Selain itu, Variabilitas bentuk lesi atau mikroaneurisma yang tidak konsisten antar pasien juga dapat menjadi penyebab kesalahan pada klasifikasi.

Jika dibandingkan dengan penelitian sebelumnya, model yang digunakan dalam penelitian ini menunjukkan peningkatan signifikan dibandingkan dengan pendekatan pada beberapa penelitian sebelumnya. Densenet yang digunakan dalam penelitian ini memiliki keunggulan dalam menyebarkan informasi antar layer melalui *dense block*, sehingga fitur yang dipelajari lebih representative dan mendalam. Dengan melakukan *fine-tuning* terhadap arsitektur ini model mampu mencapai akurasi yang cukup baik, walaupun ada beberapa kesalahan yang terjadi. Untuk mengatasi hal ini, ke depan dapat dipertimbangkan teknik augmentasi lanjutan, seperti *contrast enhancement* atau *multi-view ensemble*.

## 5. KESIMPULAN

Hasil penelitian ini menunjukkan bahwa arsitektur densenet yang telah melewati fine-tune mampu mendeteksi diabetic retinopathy secara akurat melalui analisis citra fundus mata. Model yang dikembangkan mampu mencapai akurasi sebesar 96%, serta AUC sebesar 0.99, yang dimana hal itu menunjukkan kinerja deteksi yang sangat baik dan seimbang antara sensitivitas. Hasil ini mengindikasikan bahwa pendekatan deep learning berbasis densenet tidak hanya mampu mengatasi keterbatasan metode manual, tetapi juga memberikan potensi implementasi nyata dalam sistem untuk mendeteksi secara otomatis sehingga dapat mendiagnosis dini diabetic retinopathy secara lebih cepat dan efisien. Sebagai saran penelitian selanjutnya, disarankan untuk menggunakan teknik augmentasi lanjutan seperti *contrast enhancement* atau *multi-view ensemble*.

## REFERENSI

- [1] M. Zahir and R. Adi Saputra, "Deteksi Penyakit Retinopati Diabetes Menggunakan Citra Mata Dengan Implementasi Deep Learning CNN," *Jurnal Teknoinfo*, vol. 18, no. 1, pp. 121–132, 2024, [Online]. Available: <https://www.kaggle.com/datasets/gunavenkatdoddi/eye-diseases-classification>
- [2] "World Health Organization (WHO); Diabetes," World Health Organization (WHO).
- [3] S. Aghnaita, R. Prastyani, and M. Rochmanti, "Pengaruh Pengingat Elektronik dalam Peningkatan Pemeriksaan Mata Retinopati Diabetik: Meta-Analisis The Effect of Electronic Reminder in Improving the Diabetic Retinopathy's Eye Examination: A Meta-Analysis," *Jurnal Manajemen Kesehatan Yayasan Rs. Dr. Soetomo*, vol. 8, no. 2, 2022.
- [4] D. Andika and D. Darwis, "Modifikasi Algoritma Gifshuffle Untuk Peningkatan Kualitas Citra Pada Steganografi," *Jurnal Ilmiah Infrastruktur Teknologi Informasi*, vol. 1, no. 2, pp. 19–23, 2020.
- [5] A. E. Suwanda and D. Juniati, "Klasifikasi Penyakit Mata Berdasarkan Citra Fundus Retina Menggunakan Dimensi Fraktal Box Counting Dan Fuzzy K-Means," *Jurnal Penelitian Matematika dan Pendidikan Matematika*, vol. 5, no. 1, 2022.
- [6] L. Costaner, Lisniawati, Guntoro, and Abdullah, "Analisis Ekstraksi Fitur untuk Deteksi Retinopati Diabetik menggunakan Teknik Machine Learning," *Sistemasi: Jurnal Sistem Informasi*, vol. 13, no. 5, 2024, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [7] M. A. Ardyansyah and Gunawansyah, "Sistem Deteksi Level Diabetic Retinopathy Melalui Citra Fundus Mata dengan Menggunakan Metode CNN (Convolutional Neural Network)," *G-Tech: Jurnal Teknologi Terapan*, vol. 7, no. 4, pp. 1673–1682, Oct. 2023, doi: 10.33379/gtech.v7i4.3332.



- [8] H. Tian *et al.*, “DenseNet model incorporating hybrid attention mechanisms and clinical features for pancreatic cystic tumor classification,” *J Appl Clin Med Phys*, vol. 25, no. 7, Jul. 2024, doi: 10.1002/acm2.14380.
- [9] A. Gupta, K. Aggarwal, R. Kumar, K. Saxena, and D. Gupta, “Predict Survival Probability for Cancer Patients using Deep Learning,” *Interantional Journal of Scientific Research in Engineering and Management*, vol. 07, no. 02, Feb. 2023, doi: 10.55041/ijrem17670.
- [10] S. F. Ahmed *et al.*, “Deep learning modelling techniques: current progress, applications, advantages, and challenges,” *Artif Intell Rev*, vol. 56, no. 11, pp. 13521–13617, Nov. 2023, doi: 10.1007/s10462-023-10466-8.
- [11] Y. Zhu and S. Newsam, “Densenet for Dense Flow,” in *International Conference on Image Processing (ICIP)*, 2017.
- [12] C. Liu and B. Wang, “Assessment of the Susceptibility of Gully Type of Debris Flow in Nuijiang Prefecture Based on Improved DenseNet,” in *Frontiers in Artificial Intelligence and Applications*, IOS Press BV, Feb. 2024, pp. 302–315. doi: 10.3233/FAIA231312.
- [13] T. H. Fung, B. Patel, E. G. Wilmot, and W. M. Amoaku, “Diabetic retinopathy for the non-ophthalmologist,” *Clinical Medicine*, vol. 22, no. 2, pp. 112–116, Mar. 2022, doi: 10.7861/clinmed.2021-0792.
- [14] B. Long, Y. Zhengli, W. Shuangquan, B. Dongwoon, and L. Jungwon, “Real Image Denoising Based on Multi-Scale Residual Dense Block and Cascaded U-Net with Block-Connection,” *Computer Vision Foundation*, 2023.
- [15] Z. Shen, H. Fu, J. Shen, and L. Shao, “Modeling and Enhancing Low-Quality Retinal Fundus Images,” *IEEE Trans Med Imaging*, vol. 40, no. 3, pp. 996–1006, Mar. 2021, doi: 10.1109/TMI.2020.3043495.
- [16] W. Wang and A. C. Y. Lo, “Diabetic retinopathy: Pathophysiology and treatments,” Jun. 20, 2018, MDPI AG. doi: 10.3390/ijms19061816.