Indonesian Journal of Computer Science
ISSN 2302-4364 (*print*) dan 2549-7286 (*online*)
Jln. Khatib Sulaiman Dalam, No. 1, Padang, Indonesia, Telp. (0751) 7056199, 7058325
Website: ijcs.stmikindonesia.ac.id | E-mail: ijcs@stmikindonesia.ac.id

Implementasi *Deep Classifier* untuk Diagnosis Penyakit Glaukoma pada Citra Retina Mata

Dhimas Arief Dharmawan[1], Raden Achmad Chairdino Leuveano[2], Andiko Putro Suryotomo[3], Michel Pierce Tahya[4], Sayang Sani[5]
Email dhimas.arief@upnyk.ac.id[1,*], raden.achmad@upnyk.ac.id[2], andiko.ps@upnyk.ac.id[3]
[1,3,4,5]Jurusan Informatika, Fakultas Teknik Industri, Universitas Pembangunan Nasional Veteran Yogyakarta
[2] Jurusan Teknik Industri, Fakultas Teknik Industri, Universitas Pembangunan Nasional Veteran Yogyakarta

Informasi Artikel

Diterima : 5 Sep 2023
Direview : 8 Sep 2023
Disetujui : 28 Okt 2023

Kata Kunci

Citra retina, DRISHTI-GS deep learning, glaukoma, ORIGA

Abstrak

Penerapan deep learning untuk diagnosis glaukoma dari gambar retina merupakan bidang yang berkembang pesat dalam pencitraan medis. Penelitian ini menyelidiki keampuhan model pembelajaran mendalam dengan menggunakan dua set data uji yang berbeda: DRISHTI-GS dan ORIGA, yang menjelaskan potensi dan tantangan dalam tugas medis yang kritis ini. Dalam kasus dataset DRISHTI-GS, model deep learning menunjukkan kinerja yang bervariasi di seluruh zaman. Epoch awal menunjukkan akurasi yang rendah dan kehilangan yang tinggi, tetapi peningkatan yang signifikan terjadi antara epoch 40 dan 70, mencapai akurasi sekitar 96% pada epoch 100. Hal ini menunjukkan potensi deep learning dalam mendiagnosis glaukoma dari gambar retina DRISHTI-GS. Sebaliknya, dataset ORIGA menunjukkan kemajuan yang lebih konsisten. Model ini terus meningkatkan akurasi, mencapai 97,54% pada epoch 80, dengan penurunan kerugian yang terjadi secara bersamaan, yang mengindikasikan konvergensi yang kuat. Hal ini menggarisbawahi kemahiran model dalam diagnosis dataset ORIGA, menyoroti janji klinisnya. Singkatnya, penelitian ini menunjukkan kelayakan deep learning untuk diagnosis glaukoma dari gambar retina, dengan hasil yang menjanjikan pada dataset DRISHTI-GS dan ORIGA.

Keywords

Deep learning, DRISHTI-GS, glaucoma, retinal image, ORIGA

Abstract

The application of deep learning for glaucoma diagnosis from retinal images is a rapidly advancing area in medical imaging. This study investigates the efficacy of deep learning models using two distinct test datasets: DRISHTI-GS and ORIGA, shedding light on the potential and challenges in this critical medical task. In the case of the DRISHTI-GS dataset, the deep learning model showed varying performance across epochs. Initial epochs exhibited modest accuracy and high loss, but significant improvement occurred between epochs 40 and 70, reaching an accuracy of approximately 96% by epoch 100. This demonstrates the potential of deep learning in diagnosing glaucoma from DRISHTI-GS retinal images. Conversely, the ORIGA dataset displayed more consistent progress. The model steadily improved accuracy, reaching 97.54% by epoch 80, with a concurrent decrease in loss, indicating robust convergence. This underscores the model's proficiency in ORIGA dataset diagnosis, highlighting its clinical promise. In summary, this study showcases the feasibility of deep learning for glaucoma diagnosis from retinal images, with promising results on both DRISHTI-GS and ORIGA datasets.

Attribution-ShareAlike 4.0 International License

A. Pendahuluan

Salah satu penyakit mata yang banyak diderita di dunia dan sekaligus menjadi salah satu penyebab utama kebutaan adalah glaukoma. Sebagai contoh, sebanyak 40% kebutaan di Singapura diakibatkan oleh glaukoma dan lebih dari tiga juta warga Amerika Serikat terkena penyakit tersebut. Selain itu, glaukoma adalah penyebab utama kebutaan di Afrika, Amerika dan Asia [1]. Parahnya lagi, kebutaan akibat glaukoma bersifat hampir permanen, atau dengan kata lain sulit untuk dapat disembuhkan. Hal ini dikarenakan saraf mata pada penderita glaukoma pada umumnya telah rusak akibat tekanan intraokular berlebih pada bola mata. Kerusakan saraf mata pada penderita glaukoma biasanya disebabkan oleh faktor usia [2].

Selain risiko yang ditimbulkan, sedikitnya gejala awal yang ditampakkan semakin membuat glaukoma menjadi penyakit yang berbahaya. Oleh sebab itu, pemeriksaan kondisi mata secara rutin oleh dokter mata merupakan langkah yang sangat dianjurkan untuk mencegah seseorang dari menderita glaukoma [3]. Pemeriksaan kondisi mata pada umumnya dilakukan oleh dokter dengan mengamati kondisi mata pasien, khususnya kondisi pusat syaraf mata atau Optic Disc (OD), melalui citra retina pasien. Pemeriksaan glaukoma pada umumnya dilakukan secara periodik, di mana dokter akan mengamati apakah terdapat perubahan pada kondisi OD dari waktu ke waktu yang mengindikasikan seorang pasien terjangkit glaukoma.

Sayangnya, pemeriksaan manual semacam ini menjadi tidak efektif apabila melibatkan citra retina dalam jumlah yang besar. Di samping itu, metode non-kuantitatif ini berpotensi memunculkan interpretasi klinis yang subyektif dan terkadang kurangnya sensitivitas citra yang diperlukan untuk mendeteksi perubahan struktur halus mata yang terjadi pada tahap awal glaukoma juga menjadi tantangan tersendiri [4]. Untuk membantu dokter dalam mendiagnosis glaukoma, beberapa sistem bantu berbasis komputer telah dikembangkan. Sistem-sistem ini pada umumnya menggunakan citra retina sebagai masukannya, serta melibatkan tahap segmentasi optic cup dan OD untuk kemudian dilakukan pengukuran rasio diameter keduanya. Namun begitu, sistem-sistem tersebut mempunyai akurasi yang kurang memadai dan tahap segmentasi optic cup dan OD yang dikenal akan kerumitannya kerap menjadi salah satu penyebabnya [5][6].

Dewasa ini, kemunculan jaringan deep learning telah memberikan terobosan di berbagai masalah klasifikasi citra, salah satunya pada deteksi glaukoma secara otomatis. Namun, klasifikasi citra menggunakan deep learning bukanlah tanpa masalah. Pada banyak kasus, deep learning lebih dimanfaatkan sebagai sebuah black box, di mana dirinya akan memberikan sebuah keluaran atas masukan yang diberikan, tanpa penjelasan bagaimana masukan yang diberikan diproses hingga menghasilkan keluaran tersebut. Hal semacam ini tentu patut dihindari, khususnya di bidang medis, sebab pada umumnya pasien membutuhkan penjelasan mengapa dirinya didiagnosis terjangkit suatu penyakit, termasuk salah satunya adalah glaukoma. Bahkan, dokter sebagai pihak yang menggunakan sistem tersebut juga perlu mendapatkan penjelasan atas masukan yang diberikan sistem terkait hasil diagnosis sebelum menegakkan diagnosis akhir dan menyampaikannya ke pasien.
Gagasan utama penelitian ini adalah untuk mengimplementasikan jaringan deep learning untuk diagnosis glaukoma secara otomatis disertai dengan penjelasan

visual atas hasil diagnosis yang diberikan. Hal ini dapat dicapai dengan menerapkan algoritma deep learning guna otomatisasi seluruh tahap yang diperlukan pada proses perancangan seperti tahap pemrosesan citra, ekstraksi fitur dan klasifikasi fitur untuk mendapatkan hasil diagnosis, yakni glaukoma atau normal, serta dilanjutkan dengan tahap pengembangan model visualisasi untuk menjelaskan hasil diagnosis yang diberikan oleh jaringan deep learning. Algoritma deep learning akan menerima masukan berupa citra retina dan sebagian darinya akan digunakan pada proses pelatihan (citra pelatihan) dengan target berupa hasil diagnosis dari dokter. Pada akhir penelitian, algoritma yang sudah dilatih akan digunakan untuk mendiagnosis glaukoma pada sejumlah citra retina baru (citra pengujian). Model visualisasi diharapkan mampu memberikan penjelasan visual atas diagnosis yang diberikan oleh sistem. Akurasi sistem dapat tergambarkan melalui percobaan skala laboratorium atau simulasi (TKT 3) yakni dengan cara menghitung rasio jumlah citra retina yang terdiagnosis sama oleh algoritma deep learning terlatih dan dokter terhadap jumlah citra pengujian.

B. Tinjauan Pustaka

Berdasarkan studi pustaka yang kami lakukan, dalam sepuluh tahun terakhir terdapat sejumlah sistem komputer guna diagnosis glaukoma secara otomatis yang telah dikembangkan. Pada umumnya, sebagaimana yang terangkum oleh bagan pada Gambar 1, sebuah sistem diagnosis glaukoma dirancang melalui sejumlah tahap, seperti tahap pra-pengolahan citra retina, segmentasi OD, ekstraksi dan seleksi fitur glaukoma berdasarkan area OD dan terakhir adalah tahap klasifikasi berdasarkan fitur yang didapatkan [7]. Tahap pra-pengolahan citra berguna untuk meningkatkan kontras, kecerahan dan ketajaman dari citra retina menggunakan beberapa metode seperti peregangan kontras dan ekualisasi histogram adaptif. Tujuannya adalah agar objek yang akan dianalisis pada tahap selanjutnya dapat dibedakan dari area sekitarnya dengan lebih mudah [8]-[10].

Selanjutnya, tahap segmentasi OD dilakukan guna mendapatkan area yang dibuthukan pada tahap ekstraksi fitur. OD merupakan objek citra yang diinginkan pada pendeteksian glaukoma. Untuk itu, tujuan dari segmentasi ini ialah menghilangkan area selain OD dan hanya berfokus pada area OD. Pada umumnya, tahap ini dilakukan menggunakan beberapa metode seperti binerisasi dengan algoritma Otsu [11], active contour modelling (ACM) [12][13][14], transformasi watershed [15][16] dan klasifikasi superpiksel [17][18]. Berdasarkan area OD yang didapatkan, selanjutnya dilakukan tahap ekstraksi sejumlah fitur yang mampu membedakan OD penderita glaukoma dan OD pasien sehat. Metode ekstraksi fitur tersebut digunakan untuk mengetahui perbedaan luasan area OD normal dan OD glaukoma, di antaranya adalah fitur berdasarkan transformasi Gabor [19], transformasi Wavelet [20], entropi [21], fraktal [22] dan intensitas keabuan citra yang sering terjadi atau biasa disebut gray level co-occurrence matrix (GLCM) [23].

Lebih lanjut, beberapa peneliti juga mengusulkan untuk dilakukannya tahap seleksi fitur menggunakan beberapa teknik seperti principle component analysis (PCA) [24], linear discriminant analysis (LDA) [25] dan locality sensitive discriminant analysis (LSDA) [26]. Seleksi fitur dapat diaplikasikan setelah

diperoleh fitur-fitur dari tahapan sebelumnya, yaitu ekstraksi fitur. Pada tahap akhir, untuk dapat mengklasifikasikan citra retina normal dan glaukoma, dibutuhkan metode klasifikasi. Klasifikasi sendiri dibagi menjadi dua macam, yaitu ditentukan targetnya atau tanpa menentukan target. Beberapa metode klasifikasi diantaranya seperti support vector machine (SVM) [27], K-Nearest Neighbor (KNN) [28] dan artificial neural neatwork (ANN) [29][30] telah banyak digunakan guna klasifikasi fitur yang didapatkan di proses sebelumnya.

Baru-baru ini, telah diusulkan beberapa prosedur perancangan sistem komputer guna diagnosis glaukoma yang lebih efisien, yakni dengan cara tidak melibatkan tahap segmentasi OD [31-33] pada proses perancangan. Tidak digunakannya tahap segmentasi OD tidak hanya membuat sistem memiliki beban komputasi yang lebih rendah, namun juga dapat mengurangi kesalahan diagnosis sebab tahap segmentasi OD sendiri bukan merupakan tahap yang mudah untuk dilakukan dan kesalahan segmentasi sangat mungkin terjadi. Sebagai contoh, kerap kali terdapat sejumlah bagian citra retina yang sebenarnya bukan termasuk area OD turut tersegmentasi, maupun sebaliknya, bagian citra retina yang sebenarnya termasuk area OD justru tidak tersegmentasi dengan baik. Lebih-lebih, citra retina yang memiliki banyak patologis seperti microaneurysm, haemorhages dan exudates menjadikan kesulitan tersendiri dalam melakukan segmentasi OD. Kesalahan segmentasi OD tidak dapat dipungkiri menjadi salah satu penyebab rendahnya tingkat akurasi sistem dalam mendiagnosis glaukoma.

Meskipun tahap segmentasi OD sudah tidak dilibatkan, proses perancangan sistem-sistem tersebut masih terlalu banyak membutuhkan campur tangan manusia (human intervention), khususnya pada tahap yang menjadi inti dari sistem tersebut, yakni ekstraksi fitur. Dalam hal ini, pihak perancang sistem perlu menentukan sejumlah fitur yang dinilai mampu merepresentasikan ciri citra retina milik penderita glaukoma dan ciri citra retina pasien sehat. Namun, kerap kali fitur-fitur yang digunakan hanya mewakili sebagian ciri yang ada, dan mengabaikan ciri-ciri lainnya yang mungkin justru merupakan ciri pembeda utama antara citra retina glaukoma dan citra retina sehat. Untuk mendapatkan fitur yang mampu mewakili sebagian besar ciri pembeda tersebut, dibutuhkan sejumlah pakar dengan keahlian yang berbeda-beda, misalnya keahlian di bidang kedokteran dan algoritma komputer. Hal ini dapat menjadi faktor penghambat terutama pada proses perancangan sistem dengan jumlah masukan berupa citra retina yang banyak dan beragam, sebab setiap citra dapat memiliki ciri yang berbeda-beda. Oleh sebab itu, perancangan sebuah sistem komputer yang mampu mengolah citra retina secara otomatis untuk pada akhirnya mendapatkan hasil diagnosis yang akurat tentunya sangat diharapkan.

C. Metodologi Penelitian

Secara garis besar, metode yang diusulkan terdiri dari tiga tahap, yaitu tahap persiapan, tahap implementasi algoritma, dan tahap pengujian.

1. Tahap Persiapan

Tahap persiapan data terdiri atas dua sub-tahap, yaitu Studi Pustaka dan Akuisisi Data Citra Retina. Kedua sub-tahap tersebut diuraikan sebagai berikut.

a. Studi Pustaka
Tahap studi pustaka dilakukan untuk mengetahui perkembangan penelitian terkait beserta masing-masing kelebihan dan kekurangannya. Tahap ini dilakukan dengan meninjau sejumlah penelitian terkait dan memetakan masing-masing metode yang digunakan, kelebihan dan kekurangannya. Luaran dari tahapan ini adalah peta jalan (road map) penelitian seperti ditampilkan pada bagian tinjauan pustaka.

b. Akuisisi Citra Retina
Tahap akuisisi citra retina akan dilakukan dengan mengunduh citra retina dari basis data ORIGA [34] dan DRISHTI-GS [35]. Hal ini sebagaimana yang dilakukan pada penelitian-penelitian sebelumnya [36]. Selanjutnya, akan dilakukan pembagian citra hasil akusisi menjadi data pelatihan dan pengujian. Tahap ini dilakukan guna menyediakan citra untuk keperluan pelatihan dan pengujian arsitektur deep learning. Tahap ini akan dilakukan dengan mengikuti prosedur pembagian data pelatihan dan pengujian pada penelitian oleh [36].

2. Tahap Implementasi Algoritma

a. Pelatihan Arsitektur Deep Learning untuk Deteksi Glaukoma
Tahap pelatihan arsitektur deep learning diperlukan guna memmpelajari struktur lokal citra, mendapatkan fitur yang dapat mewakili anatomi citra retina glaukoma dan normal dan selanjutnya mengelompokkan fitur-fitur tersebut ke dalam kelas yang sesuai secara otomatis. Proses pelatihan dilakukan menggunakan citra retina pada basis data pelatihan dan dengan target pelatihan berupa hasil diagnosis dari dokter. Perlu dicatat bahwa basis data ORIGA dan DRISHTI-GS juga menyediakan hasil diagnosis dari dokter untuk citra yang bersesuaian. Proses pelatihan akan dilakukan pada beberapa arsitektur deep learning pra-terlatih (menggunakan konsep transfer learning), seperti arsitektur dan EfficientNetB0 [37]. Hal ini bertujuan untuk mendapatkan arsitektur yang paling sesuai untuk keperluan diagnosis glaukoma. Tahap ini dilakukan dengan bantuan Google Colab.

3. Tahap Pengujian

Pada tahap ini, arsitektur deep learning terlatih akan digunakan untuk mendiagnosis glaukoma pada citra retina yang berasal dari basis data pengujian. Tahap ini dilakukan dengan bantuan Google Colab.

D. Tahap Implementasi Algoritma

Penelitian ini mendapatkan masukan atau input berupa citra retina dan dibangun melalui serangkaian tahap untuk pada akhirnya dapat mendiagnosis glaukoma, seperti tahap pra-pemrosesan citra, pelatihan jaringan deep learning, dan pengembangan model visualisasi untuk menjelaskan hasil diagnosis yang diberikan oleh jaringan deep learning. Penerapkan algoritma deep learning dilakukan guna otomatisasi seluruh tahap yang diperlukan pada proses perancangan seperti tahap pemrosesan citra, ekstraksi fitur, dan klasifikasi fitur untuk mendapatkan hasil diagnosis, yakni glaukoma atau normal, serta dilanjutkan

dengan tahap pengembangan model visualisasi untuk menjelaskan hasil diagnosis yang diberikan oleh jaringan deep learning. Algoritma deep learning akan menerima masukan berupa citra retina dan sebagian darinya akan digunakan pada proses pelatihan (citra pelatihan) dengan target berupa hasil diagnosis dari dokter. Algoritma yang sudah dilatih akan digunakan untuk mendiagnosis glaukoma pada sejumlah citra retina baru (citra pengujian). Gambar 1 adalah satu contoh citra dari masing-masing dataset yang digunakan.

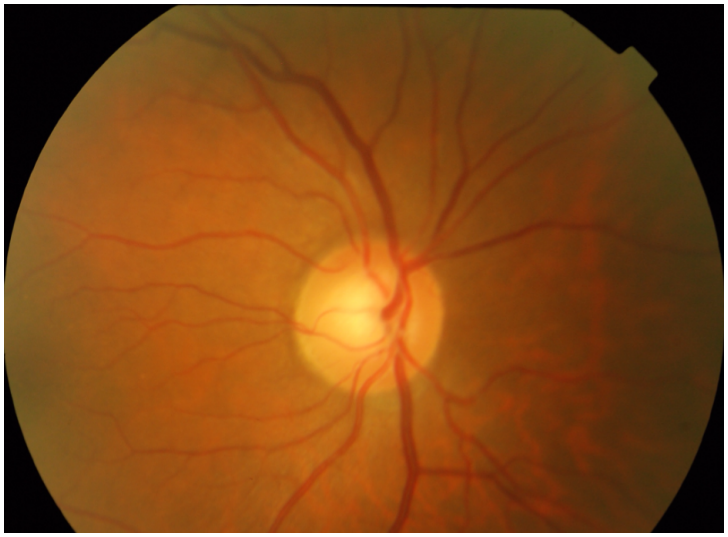

Gambar 1. Citra Retina dari Dataset DRISHTI-GS

Selain digunakan Dataset DRISHTI-GS di atas, penelitian ini menggunakan dataset lainnya dengan contoh citra yang ditunjukkan pada Gambar 2.

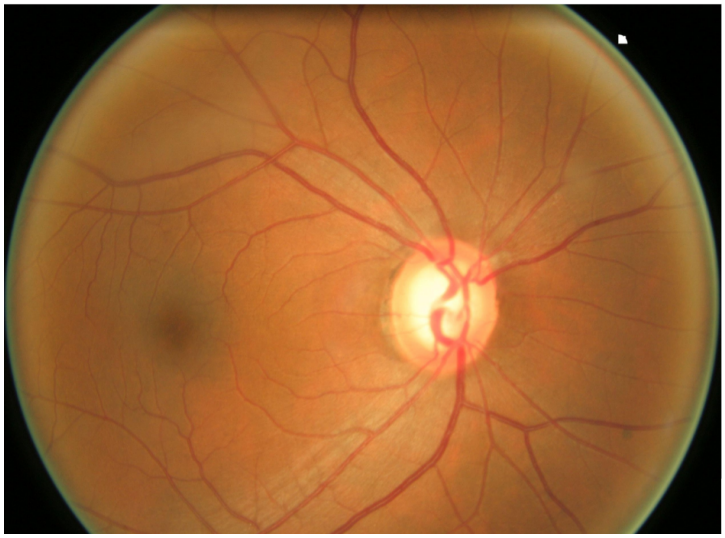

Gambar 2. Citra Retina dari Dataset ORIGA

Dari kedua dataset di atas, proses penerapan algoritma deep learning dilakukan di mana menerima masukan berupa citra retina dan sebagian darinya akan digunakan pada proses pelatihan (citra pelatihan) dengan target berupa hasil

diagnosis dari dokter. Parameter default yang digunakan ialah nilai learning rate sebesar 0,001. Untuk dataset DRISHTI-GS diperoleh hasil seperti pada Tabel 1.

Tabel 1. Hasil Penerapan Algoritma Deep learning pada Dataset DRISHTI-GS

Epoch	Loss	Accuracy
10	1,160542	0,360000
20	0,891194	0,500000
30	1,041918	0,400000
40	0,516883	0,860000
50	0,697968	0,700000
60	1,160505	0,440000
70	0,492223	0,820000
80	0,197483	0,940000
90	0,295310	0,940000
100	0,220255	0,960000

Tabel yang disediakan menawarkan wawasan yang berharga mengenai implementasi deep learning untuk mendiagnosis glaukoma pada gambar retina dari dataset uji DRISHTI-GS. Tabel ini melacak kemajuan pelatihan model pembelajaran mendalam selama beberapa zaman. Khususnya, metrik kerugian terus menurun seiring berjalannya pelatihan, yang menunjukkan kemampuan model untuk meminimalkan kesalahan prediksi. Penurunan substansial dalam kerugian dari epoch 10 ke epoch 80 menandakan pembelajaran yang signifikan dan pengenalan pola dalam data.

Secara bersamaan, akurasi model terus meningkat, mulai dari 0,36 pada epoch 10 dan secara bertahap meningkat menjadi 0,96 pada epoch 100. Perkembangan ini menunjukkan peningkatan kemampuan model dalam mengidentifikasi kasus glaukoma dengan benar. Untuk memastikan bahwa model dapat menggeneralisasi dengan baik, sangat penting untuk memantau kinerjanya pada dataset validasi, yang menunjukkan bahwa kinerjanya menjadi stabil di sekitar epoch 80, yang menunjukkan titik potensial untuk menghentikan pelatihan untuk mencegah overfitting.

Menentukan jumlah epoch pelatihan yang optimal sangat penting untuk menyeimbangkan kinerja dan waktu pelatihan secara efektif. Batas akurasi yang diamati sebesar 0,96 cukup menjanjikan, namun mencapai akurasi yang sangat tinggi dapat menimbulkan kekhawatiran tentang overfitting. Oleh karena itu, evaluasi lebih lanjut, seperti validasi silang atau pengujian pada dataset independen, diperlukan untuk memvalidasi kinerja model di dunia nyata.

Singkatnya, wawasan ini menyoroti sifat iteratif dan progresif dari pelatihan model deep learning. Model ini menunjukkan harapan dalam mendiagnosis glaukoma dari gambar retina, tetapi kegunaan klinisnya memerlukan pertimbangan tambahan, termasuk sensitivitas, spesifisitas, dan validasi dunia nyata yang ketat. Adapun hasil penerapan algoritma deep learning dengan menggunakan Dataset ORIGA ditunjukkan pada Tabel 2.

Tabel 2. Hasil Penerapan Algoritma Deep learning pada Dataset ORIGA

Epoch	Loss	Accuracy
10	0,409804	0,829231
20	0,385015	0,844615
30	0,332515	0,887692
40	0,274496	0,883077
50	0,164256	0,932308
60	0,330988	0,863077
70	0,138769	0,944615
80	0,071475	0,975385
90	0,099231	0,956923
100	0,158482	0,930769

Tabel 2 di atas memberikan beberapa wawasan menarik terkait implementasi deep learning untuk mendiagnosis glaukoma pada gambar retina dari dataset uji ORIGA. Pada awalnya, kita melihat bahwa seiring berjalannya waktu (epoch), model mengalami penurunan nilai kerugian (loss) yang stabil. Ini mengindikasikan bahwa model semakin baik dalam meminimalkan perbedaan antara nilai yang diprediksi dan nilai sebenarnya. Secara bersamaan, akurasi model juga meningkat, dimulai dari sekitar 0,83 dan mencapai 0,93 pada epoch ke-50. Hal ini menunjukkan bahwa model semakin mahir dalam mengklasifikasikan gambar retina sebagai glaukoma atau normal "non-glaukoma".

Selanjutnya, penting untuk mencermati stabilitas dan potensi overfitting. Dalam kasus ini, penurunan kerugian (loss) dan peningkatan akurasi terjadi bersamaan, menunjukkan bahwa model sedang mempelajari pola-pola yang berguna dari data tanpa tanda-tanda overfitting. Namun, yang paling menarik adalah perbaikan yang signifikan antara epoch ke-60 dan ke-80. Kerugian (loss) menurun secara signifikan, dan akurasi meningkat hingga 97,54%. Ini mengindikasikan bahwa model membuat kemajuan besar selama periode tersebut.

Dalam konteks medis, akurasi sebesar ini sangat mengesankan. Namun, penting untuk mempertimbangkan dampak dari false positives dan false negatives dalam konteks klinis. Model ini mempertahankan akurasi yang tinggi dari epoch ke-80 hingga epoch ke-100, menunjukkan bahwa perbaikan yang dicapai selama pelatihan bersifat konsisten. Akhirnya, nilai kerugian (loss) pada epoch ke-100 adalah 0,1585, yang sangat rendah, menunjukkan bahwa prediksi model sangat mendekati label sebenarnya pada dataset uji.

Secara keseluruhan, Tabel 2 menunjukkan bahwa model deep learning membuat kemajuan yang baik dalam mendiagnosis glaukoma pada gambar retina dari dataset uji ORIGA. Ini ditunjukkan oleh penurunan kerugian (loss) yang stabil dan peningkatan akurasi, yang mengindikasikan bahwa model belajar dengan efektif dari data dan tampil baik dalam hal akurasi klasifikasi. Namun, sebelum pertimbangan untuk aplikasi klinis dunia nyata, penting untuk memvalidasi kinerja model lebih lanjut, mungkin dengan metrik evaluasi tambahan dan pengujian pada dataset terpisah.

E. Kesimpulan

Dalam penelitian ini, kami mengusulkan metode Deep Classifier untuk mendeteksi glaukoma pada gambar retina. Eksperimen yang dilakukan pada dua dataset yang berbeda, DRISHTI-GS dan ORIGA, yang melibatkan klasifikasi gambar retina ke dalam kategori "Normal" dan "Glaukoma", menunjukkan keefektifan metode yang diusulkan. Berdasarkan hasil penelitian, sistem kami mencapai akurasi terbaik sebesar 95% untuk dataset DRISHTI-GS dan 97% untuk dataset ORIGA selama pengujian.

Temuan ini menunjukkan bahwa deep learning, dikombinasikan dengan teknik klasifikasi yang dapat dijelaskan, menjanjikan diagnosis glaukoma yang akurat dari gambar retina. Kemampuan untuk mencapai tingkat akurasi yang tinggi pada kedua dataset, terutama akurasi 97% pada ORIGA, menggarisbawahi potensi kegunaan klinis dari pendekatan kami. Deteksi glaukoma dini sangat penting untuk mencegah kehilangan penglihatan, dan kinerja metode kami yang kuat menunjukkan relevansinya untuk aplikasi dunia nyata dalam bidang oftalmologi.

Penelitian dan validasi lebih lanjut diperlukan untuk mengevaluasi kemampuan generalisasi dan ketahanan model di berbagai populasi pasien dan pengaturan klinis. Selain itu, aspek penjelasan dari pengklasifikasi kami berkontribusi pada interpretabilitas hasil diagnostik, meningkatkan kepercayaan praktisi medis. Sebagai kesimpulan, Deep Classifier yang kami usulkan menyajikan jalan yang menjanjikan untuk memajukan diagnosis glaukoma, yang berpotensi meningkatkan hasil pasien dan efisiensi perawatan kesehatan di bidang oftalmologi.

F. Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada LPPM UPN Veteran Yogyakarta yang telah memfasilitasi penelitian ini sehingga penelitian ini dapat terselesaikan dengan baik.

G. Referensi

[1] J. Shiffman, Four Challenges That Global Health Networks Face, Int. J. Heal. Policy Manag. 6 (2017) 183–189.

[2] K. Evangelho, C.A. Mastronardi, A. de-la-Torre, Experimental Models of Glaucoma: A Powerful Translational Tool for the Future Development of New Therapies for Glaucoma in Humans-A Review of the Literature, Medicina (Kaunas). 55 (2019).

[3] R. Thomas, K. Loibl, R.S. Parikh, Evaluation of a glaucoma patient, Indian J. Ophthalmol. 59 (2011) S43–S52.

[4] F. Topouzis, E. Anastasopoulos, Glaucoma—The Importance of Early Detection and Early Treatment, US Ophthalmic Rev. 02 (2007) 12.

[5] S.A. Hussain, a N. Holambe, Automated Detection and Classification of Glaucoma from Eye Fundus Images: A Survey, Int. J. Comput. Sci. Inf. Technol. 6 (2015) 1217–1224.

[6] Y. Hagiwara, J.E.W. Koh, J.H. Tan, S. V. Bhandary, A. Laude, E.J. Ciaccio, L. Tong, U.R. Acharya, Computer-aided diagnosis of glaucoma using fundus images: A review, Comput. Methods Programs Biomed. 165 (2018) 1–12.

[7] M. Singh, M. Singh, J. Virk, Glaucoma detection techniques: a review, Int. J. Comput. Sci. Commun. 6 (2) (2015) 66–76.

[8] S.M. Pizer , E.P. Amburn , J.D. Austin , R. Cromarrtie , A. Geselowitz , T. Greer , B.terHaar Romeny , J.B. Zimmerman , K. Zuiderveld , Adaptive histogram equalization and its variations, Comput.Vis. Graph. Image Process. 39 (3) (1987) 355–368 .

[9] C. B. Anusorn, W. Kongprawechnon, T. Kondo, S. Sintuwong, KanokvateTungpimolrut, Image Processing Techniques for Glaucoma Detection Using the Cup-to-Disc Ratio, Thammasat International Journal of Science and Technology, Vol. 18, No. 1, (2013), 22-34.

[10] PSJ. Kumar, S. Banerjee, A Survey on Image Processing Techniques for Glaucoma Detection, International Journal of Advanced Research in Computer Engineering & Technology (IJARCET) Volume 3 Issue 12, (2014), 4006-4073.

[11] A. de la Fuente-Arriaga, E.M. Felipe-Riverón, E. Garduño-Calderón, Application of vascular bundle displacement in the optic disc for glaucoma detection using fundus images, Comput. Biol. Med. 47 (2014) 27–35.

[12] G.D. Joshi , J. Sivaswamy , S.R. Krishnadas , Optic disc and cup segmentation from monocular color retinal images for glaucoma assessment, IEEE Trans. Med. Imaging 30 (6) (2011) 1192–1205 .

[13] P.S. Mittapalli , G.B. Kande , Segmentation of optic disc and optic cup from digital fundus images for the assessment of glaucoma, Biomed. Signal Process. Control 24 (2016) 34–46 .

[14] Y. Xu , S. Lin , D.W.K. Wong , J. Liu , D. Xu , Efficient reconstruction-based optic cup localization for glaucoma screening, in: Proceedings of the Interna- tional Conference on Medical Image Computing and Computer-Assisted Inter- vention, 2013, pp. 445–452 .

[15] R.P. Rajaiah, R.J. Britto, Optic disc boundary detection and cup segmentation for prediction of glaucoma, Int. J. Sci. Eng. Technol. Res. 3 (10) (2014) 2665–2672.

[16] A,Diaz, S. Morales, V. Naranjo, P. Alcocer, A. Lanzagorta, Glaucoma Diagnosis by Means of Optic Cup Feature Analysis in Color Fundus Images, 2016 24th European Signal Processing Conference (EUSIPCO), 2055-2059.

[17] J. Cheng, J. Liu, Y. Xu, F. Yin, D.W.K. Wong, N.M. Tan, D. Tao, C.Y. Cheng, T. Aung, T.Y. Wong, Superpixel classification based optic disc and optic cup segmentation for glaucoma screening, IEEE Trans. Med. Imaging 32 (6) (2013) 1019–1032.

[18] A.G.Praveena, P.Kumar, GLAUCOMA SCREENING USING SUPER PIXEL CLASSIFICATION BASED ON OPTIC DISC AND OPTIC CUP SEGMENTATION, International Journal of Engineering Research and General Science Volume 3, Issue 1, (2015), 1192-1202 127

[19] Y. Hayashi, T. Nakagawa, Y. Hatanaka, A. Aoyama, M. Kakogawa, T. Hara, H. Fujita, T. Yamamoto, Detection of retinal nerve fiber layer defects in retinal fundus images using Gabor filtering, Soc. Photo Opt. Instrum. Eng. 6514 (2007) 65142Z 8 pages.

[20] S. Dua, U.R. Acharya, P. Chowriappa, V.S. Sree, Wavelet-based energy features for glaucomatous image classification, IEEE Trans. Inf. Technol. Biomed. 16 (1) (2012) 80–87.

[21] J. Zilly , J.M. Buhmann , D. Mahapatra , Glaucoma detection using entropy sampling and ensemble learning for automatic optic cup and disc segmentation, Comput. Med. Imaging Graph. 55 (2017) 28–41 .

[22] R. Kolar, Jan J, Detection of glaucomatous eye via color fundus images using fractal dimensions, Radio Eng. 17 (3) (2008) 109–114.

[23] S. Karthikeyan, N. Rengarajan, Performance Analysis Of Gray Level Cooccurrence Matrix Texture Features For Glaucoma Diagnosis , American Journal of Applied Sciences 11 (2): (2014) 248-257.

[24] R. Bock, J. Meier, L.G. Nyul, J. Hornegger, G. Michelson, Glaucoma risk index: automated glaucoma detection from color fundus images, Med. Image Anal. 14 (2010) 471–481.

[25] R.P. Rajaiah, R.J. Britto, Optic disc boundary detection and cup segmentation for prediction of glaucoma, Int. J. Sci. Eng. Technol. Res. 3 (10) (2014) 2665–2672.

[26] U. Raghavendra, S.V. Bhandary, A. Gudigar, U.R. Acharya, Novel expert system for glaucoma identification using non-parametric spatial envelope energy spectrum with fundus images, Biocybern. Biomed. Eng. (2017).

[27] U.R. Acharya , S. Bhat , J.E.W. Koh , S.V. Bhandary , H. Adeli , A novel algorithm to detect glaucoma risk using texton and local configuration pattern features extracted from fundus images, Comput. Biol. Med. 88 (2017) 72–83.

[28] T.R. Kausu, V.P. Gopi, K.A. Wahid, W. Doma, S.I. Niwas, Combination of clinical and multiresolution features for glaucoma detection and its classification using fundus images, Biocybern. Biomed. Eng. (2018), doi: 10.1016/j.bbe.2018. 02.003.

[29] J. Nayak, U.R. Acharya, P.S. Bhat, N. Shetty, T.C. Lim, Automated diagnosis of glaucoma using digital fundus images, J. Med. Syst. 33 (5) (2009) 337–346.

[30] U.R. Acharya, S. Bhat, J.E.W. Koh, S.V. Bhandary, H. Adeli, A novel algorithm to detect glaucoma risk using texton and local configuration pattern features extracted from fundus images, Comput. Biol. Med. 88 (2017) 72–83.

[31] S. Saleh, R. A. Chairdino Leuveano, M. N. Ab Rahman, B. Md Deros, and N. R. Dzakiyullah, "Prediction of CO2 Emissions Using an Artificial Neural Network: The Case of the Sugar Industry," Advanced Science Letters, vol. 21, no. 10, pp. 3079-3083, Oct. 2015. DOI: 10.1166/asl.2015.6488

[32] S. Maheshwari, R.B. Pachori, V. Kanhangad, S.V. Bhandary, U.R. Acharya, Iterative variational mode decomposition based automated detection of glaucoma using fundus images, Comput. Biol. Med. 88 (2017) 142–149.

[33] K.P. Noronha, U.R. Acharya, K.P. Nayak, R.J. Martis, S.V. Bhandary, Automated classification of glaucoma stages using higher order cumulant features, Biomed. Signal Process. Control 10 (2014) 174–183.

[34] Z. Zhang et al., "ORIGA-light: An online retinal fundus image database for glaucoma analysis and research," 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology, Buenos Aires, Argentina, 2010, pp. 3065-3068, doi: 10.1109/IEMBS.2010.5626137.

[35] J. Sivaswamy, S. R. Krishnadas, G. Datt Joshi, M. Jain and A. U. Syed Tabish, "Drishti-GS: Retinal image dataset for optic nerve head(ONH) segmentation," 2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI), Beijing, China, 2014, pp. 53-56, doi: 10.1109/ISBI.2014.6867807.

[36] L. Listyalina, I. Mustiadi, and D. A. Dharmawan, "Joint Dice and Intersection over Union Losses for Deep Optical Disc Segmentation," in 2020 3rd International Conference on Biomedical Engineering (IBIOMED), 2020, pp. 49–54.

[37] C. H. Patel, D. Undaviya, H. Dave, S. Degadwala and D. Vyas, "EfficientNetB0 for Brain Stroke Classification on Computed Tomography Scan," 2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC), Salem, India, 2023, pp. 713-718, doi: 10.1109/ICAAIC56838.2023.10141195.