

DETEKSI PENYAKIT GLAUKOMA PADA CITRA FUNDUS RETINA DENGAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)

DETECTION OF GLAUCOMA DISEASE ON RETINAL FUNDUS IMAGE WITH CONVOLUTIONAL NEURAL NETWORK (CNN) METHOD

Rheyndy Atalya Setiadi¹, Magdalena A. Ineke Pakkereng²

Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana^{1,2}
672022168@student.uksw.edu

ABSTRACT

This research discusses the automatic detection of glaucoma disease from retinal fundus images using the Convolutional Neural Network (CNN) method with a transfer learning and fine-tuning approach based on the EfficientNetB0 architecture. The dataset used in this study is the Standardized Multi-Channel Dataset for Glaucoma (SMDG-19), which consists of 12,316 retinal fundus images with a resolution of 512×512 pixels. The research process includes preprocessing stages such as resizing, rescaling, and data augmentation to increase data variation and reduce overfitting. The model was trained using the Adam optimizer. The training results showed a validation accuracy of 89.02%, while the evaluation on the test data achieved an accuracy of 87.29%, precision of 87.04%, recall of 78.04%, and an F1-score of 82.54%. These results indicate that the CNN method with the EfficientNetB0 architecture can effectively detect glaucoma and has the potential to be used as an accurate early diagnosis support system in the field of ophthalmology.

Keywords: Glaucoma, Retinal Fundus Image, Convolutional Neural Network (CNN), EfficientNetB0, Transfer Learning

ABSTRAK

Penelitian ini membahas mengenai deteksi penyakit glaukoma pada citra fundus retina secara otomatis menggunakan metode Convolutional Neural Network dengan pendekatan transfer learning dan fine-tuning pada arsitektur EfficientNetB0, dan menggunakan dataset dari Standardized Multi-Channel Dataset for Glaucoma (SMDG-19) dengan total 12.316 citra fundus retina beresolusi 512×512 piksel. Proses penelitian ini meliputi tahap preprocessing berupa resizing, rescaling serta data augmentation untuk meningkatkan variasi dan mengurangi overfitting. Model ini dilatih dengan Adam optimizer. Hasil pelatihan menunjukkan akurasi validasi mencapai 89,02% dan evaluasi pada data uji menghasilkan akurasi 87,29%, presisi 87,04%, recall 78,04% dan F1-Score sebesar 82,54%. Hasil ini menunjukkan bahwa metode CNN dengan arsitektur EfficientNetB0 mampu mendeteksi glaukoma secara efektif dan berpotensi digunakan sebagai sistem pendukung diagnosis dini yang akurat di bidang oftalmologi.

Kata Kunci: Glaukoma, Citra Fundus Retina, Convolutional Neural Network, EfficientNetB0, Transfer Learning

PENDAHULUAN

Dalam bidang kesehatan, penggunaan teknologi telah mengalami kemajuan pesat seiring dengan meningkatnya kemampuan komputasi dan metode *machine learning*, terutama pada pengolahan citra medis. Teknologi tersebut digunakan untuk mendeteksi penyakit dan memberikan peluang besar untuk peningkatan deteksi dini berbagai penyakit, termasuk penyakit mata glaukoma. Glaukoma merupakan penyakit mata yang ditandai dengan kerusakan progresif pada saraf optik (*nervus optikus*) dan kehilangan sel ganglion retina, sebagian besar

disebabkan oleh peningkatan tekanan intraokular (IOP) namun juga ada faktor-faktor lain seperti gangguan sirkulasi mikro, stress oksidatif, dan predisposisi genetik (Weinreb et al., 2014). Glaukoma termasuk salah satu penyakit yang menyebabkan kebutaan permanen di dunia, dengan perkiraan lebih dari 70 juta manusia di seluruh dunia menderita penyakit glaukoma dan setidaknya 10% di antaranya mengalami kebutaan permanen. Pada tahun 2040 diperkirakan penderita penyakit glaukoma secara global akan mencapai 111,8 juta orang, dengan angka tertinggi di Asia dan Afrika (Tham et al., 2014).

Glaukoma sering kali tidak menunjukkan gejala pada tahap awal, sehingga dengan menggunakan pendekatan berbasis citra fundus retina menjadi salah satu metode yang berpotensi untuk mendeteksi penyakit ini secara *non-invasive*.

Salah satu metode machine learning yang potensial dalam mendeteksi penyakit glaukoma adalah dengan pendekatan *Convolutional Neural Network (CNN)*. CNN merupakan tipe jaringan saraf buatan yang umum dimanfaatkan untuk mengolah data visual. Teknologi ini mampu mengidentifikasi dan mengenali berbagai elemen ataupun pola yang ada pada suatu gambar (Mulyasari et al., 2024).

Keunggulan utama dari CNN dalam mendeteksi penyakit glaukoma terdapat pada kemampuannya dalam mempelajari fitur-fitur penting secara otomatis dari data mentah tanpa perlu melewati proses ekstraksi manual, seperti pada struktur *disc optic* dan *optic cup* yang menjadi indikator utama glaukoma (Chakravarty & Sivaswamy, 2016). Selain itu, CNN memiliki sifat *end-to-end learning* yang memungkinkan pelatihan model secara efisien dari data mentah hingga hasil klasifikasi, serta memiliki skalabilitas tinggi yang dapat diterapkan pada data besar dan beragam (Cahya et al., 2021). Keunggulan tersebut menjadikan CNN menjadi metode yang sangat berpotensi untuk membantu deteksi dini penyakit glaukoma secara otomatis, cepat dan akurat.

Penelitian-penelitian sebelumnya telah membuktikan potensial CNN dalam klasifikasi berbagai penyakit mata melalui citra fundus retina dengan menggunakan arsitektur *AlexNet* untuk membangun sistem klasifikasi otomatis yang dapat mendeteksi penyakit glaukoma, retinopati diabetik, dan katarak, dengan tingkat akurasi sebesar 87,78% (Indraswari et al., 2022). Sementara itu, penelitian lain menerapkan arsitektur VGG-19 untuk mendeteksi 8 jenis penyakit mata, termasuk glaukoma dan berhasil mencapai tingkat akurasi hingga 96% (Mulyani et al., 2024).

Hal ini membuktikan bahwa CNN mampu untuk mengekstraksi fitur-fitur penting dari citra fundus secara efisien dan akurat, sehingga sangat potensial untuk diterapkan dalam sistem deteksi dini penyakit mata secara otomatis. Proses deteksi penyakit glaukoma dengan CNN biasanya melewati beberapa tahapan, seperti *preprocessing* citra (seperti normalisasi dan augmentasi), pelatihan model dengan dataset citra retina, validasi model dan evaluasi performa menggunakan matrix seperti akurasi, sensitivitas dan spesifisitas (Mulyasari et al., 2024). Selain itu, beberapa studi juga menggabungkan CNN dengan teknik klasifikasi lainnya, seperti *Support Vector Machine (SVM)* atau *Random Forest* untuk meningkatkan tingkat akurasi model (Chakravarty & Sivaswamy, 2016).


Walaupun CNN menawarkan Tingkat akurasi yang tinggi, ada pun tantangan dalam penerapannya terutama berkaitan dengan variasi kualitas citra fundus, perbedaan anatomi retina antar individu dan keterbatasan data latih yang representatif. Oleh karena itu, penting untuk melakukan optimasi arsitektur CNN, penerapan teknik augmentasi citra, serta penggunaan *transfer learning* untuk meningkatkan generalisasi model pada berbagai kondisi citra (Firdaus et al., 2022).

Dengan semakin berkembangnya teknologi *deep learning*, CNN menjadi pendekatan yang sangat berpotensi dalam pengembangan sistem deteksi glaukoma yang cerdas, akurat dan otomatis. Pendekatan ini tidak hanya mempercepat proses *screening*, tetapi juga dapat membantu tenaga medis dalam pengambilan keputusan secara lebih objektif dan efisien, serta mendukung sistem kesehatan digital di masa depan lebih cerdas dan terkoneksi.

METODE

Penelitian akan dilakukan melalui beberapa tahap yaitu perumusan masalah, pengumpulan data, pembuatan model, implementasi model dan evaluasi hasil

penelitian. Tahapan ini diilustrasikan dalam Gambar 1.



Gambar 1. Tahap Penelitian

Tahap pertama adalah perumusan masalah, penelitian ini bertujuan untuk mengembangkan sistem berbasis *deep learning*, khususnya menggunakan *Convolutional Neural Network* untuk mendeteksi penyakit mata glaukoma melalui citra fundus retina secara otomatis dan akurat. Permasalahan ini muncul karena glaukoma sering kali tidak menunjukkan gejala pada tahap awal, sehingga deteksi dini melalui citra retina sangat penting untuk mencegah kebutaan. Penelitian ini mengidentifikasi bagaimana keunggulan CNN dapat mendeteksi penyakit glaukoma pada citra fundus retina secara efektif.

Tahap kedua adalah pengumpulan data, dataset yang digunakan pada penelitian ini bersumber dari platform *Kaggle*, yaitu dataset *Standardized Multi-Channel Dataset for Glaucoma (SMDG-19)*. Dataset ini terdiri dari lebih dari 12.000 citra fundus retina berwarna dengan resolusi 512×512 piksel, dan telah dilabeli sebagai *glaucoma*, *non-glaucoma*, atau *suspect*. Dataset ini dipilih karena memiliki keragaman citra yang cukup tinggi dan telah distandarkan untuk keperluan pelatihan model *machine learning*.

Pada tahap ketiga dilakukan pengolahan data. Dataset yang diperoleh dari *Kaggle* pada awalnya belum terklasifikasi ke dalam kategori tertentu, sehingga dibutuhkan proses penggolongan citra retina menjadi dua kelas, yaitu *glaucoma* dan *non-glaucoma*. Setelah proses klasifikasi, seluruh citra kemudian di proses ulang dengan mengubah ukurannya/*resize* menjadi 224x224 piksel. Langkah ini bertujuan untuk menyeragamkan dimensi data sehingga sesuai dengan kebutuhan arsitektur model CNN serta memastikan data siap digunakan dalam proses pelatihan dan pengujian model.

Tahap keempat adalah implementasi model, pada proses ini dilakukan menggunakan data uji yang telah dipisahkan secara *stratified* dari dataset awal. Pengujian ini mencakup penghitungan *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, dilakukan juga visualisasi prediksi model untuk mengamati apakah area *disc optic* dan *optic cup* menjadi fokus klasifikasi melalui metode *Grad-CAM*. Pemanfaatan transfer learning ini bertujuan untuk mempercepat pelatihan dan meningkatkan akurasi model, terutama karena dataset medis biasanya terbatas dalam jumlah. *Layer* terakhir dari arsitektur diubah menjadi *layer* klasifikasi *binary* (*glaucoma* dan *non-glaucoma*), dengan aktivasi *softmax* atau *sigmoid* tergantung pada jenis output.

Tahap kelima adalah evaluasi, yaitu proses menginterpretasikan hasil prediksi model berdasarkan *confusion matrix*. Dari matriks tersebut akan dihitung matriks evaluasi utama seperti akurasi keseluruhan, sensitivitas (*recall*), presisi serta *F1-Score* sehingga dapat memberikan *insight* apakah model mampu mendeteksi glaukoma secara konsisten dan dapat diandalkan untuk diterapkan dalam sistem pendeteksi otomatis di dunia nyata.

HASIL DAN PEMBAHASAN

Proses perumusan masalah dimulai dengan mengidentifikasi bagaimana

membangun sistem deteksi otomatis penyakit glaukoma melalui citra fundus retina dengan tingkat akurasi yang tinggi menggunakan pendekatan *deep learning* berbasis *Convolutional Neural Network*. Glaukoma menjadi salah satu penyebab kebutaan permanen di dunia dan sulit dideteksi pada tahap awal karena tidak menimbulkan gejala yang signifikan. Secara umum, proses diagnosis glaukoma oleh dokter dilakukan dengan memeriksa rasio *optic cup* terhadap *disc optic*. Namun proses ini sangat bergantung pada pengalaman dan waktu pemeriksaan dokter, sehingga diperlukan sistem yang mampu mendeteksi glaukoma secara otomatis, cepat dan akurat. Penelitian ini difokuskan untuk memanfaatkan kemampuan CNN dan mengusulkan pemanfaatan *transfer learning* dengan menggunakan arsitektur *EfficientNetB0* yang didasarkan pada pertimbangan bahwa arsitektur ini mampu menyeimbangkan kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*) model melalui mekanisme *compound scaling*.

Tahap pengumpulan data, pada penelitian ini dataset yang digunakan bersumber dari platform Kaggle dengan judul "*Standardized Multi-Channel Dataset for Glaucoma (SMDG-19)*". Dataset ini merupakan hasil standarisasi dari 19 dataset publik yang berbeda dan digunakan secara luas untuk pengembangan model AI dalam bidang oftalmologi. Dataset ini berisi 12.449 citra fundus retina berwarna dengan resolusi 512×512 piksel dan file metadata dalam format CSV yang berisi informasi diagnosis seperti glaukoma, non-glaukoma, *suspect*, sumber dataset dan keterangan pasien anonim. Pada dataset mentah tersebut, label belum dipisahkan secara eksplisit ke dalam dua kategori numerik (0 dan 1). Sehingga, dilakukan proses penyesuaian metadata untuk menghasilkan label biner. Label 1 untuk glaukoma, label 0 untuk non-glaukoma dan label -1 untuk *suspect*, untuk label *suspect* dikeluarkan dari dataset pelatihan. Setelah pembersihan, dataset

akhir terdiri dari 12.316 gambar valid dengan distribusi glaukoma berjumlah 4.767 gambar dan non-glaukoma sebanyak 7.549 gambar.

Tahap pengolahan data bertujuan untuk menyiapkan citra agar sesuai dengan arsitektur CNN, tahap ini mencakup beberapa proses penting seperti semua gambar di-*resize* menjadi 224×224 piksel, seluruh citra juga di-*rescale* dalam rentang nilai 0 hingga 1, langkah ini membantu mempercepat proses pembelajaran karena data berada pada skala yang seragam.



Gambar 2. Citra Dataset

Dataset dibagi secara *stratified* menjadi *train* 70%, *validation* 20%, dan *test* 10% pembagian ini bertujuan untuk menghindari *data leakage* dan memastikan proporsi label tetap seimbang di setiap *subset*. Kemudian juga dilakukan augmentasi untuk memperbanyak variasi data pelatihan dan mengurangi risiko *overfitting*. Teknik augmentasi yang diterapkan meliputi, ditunjukkan pada Tabel 1.

Tabel 1. Augmentasi Data

Jenis Augmentasi	Nilai Parameter
Rotasi	20°
Zoom	0.15
Pergeseran Horizontal	10%
Pergeseran Vertikal	10%
Flip Horizontal	True
Shear Range	0.1
Brightness Range	(0.8, 1.2)

Proses implementasi model dilakukan menggunakan *Google Colaboratory* dengan lingkungan *Python* 3.10 dan *TensorFlow* 2.15. arsitektur CNN yang digunakan berbasis *EfficientNetB0*,

dipilih karena efisiensinya dalam mempelajari pola visual kompleks dengan jumlah parameter yang relatif kecil. Pada tahap training awal model *EfficientNetB0* diimpor dengan bobot pra-latihan dari dataset *ImageNet* menggunakan parameter *include_top=False*. Seluruh lapisan pada *base model* pada awalnya dibekukan agar bobot aslinya tidak berubah selama proses pelatihan awal (*feature extraction phase*). Proses pelatihan awal dilakukan menggunakan *loss function binary crossentropy*, yang sesuai untuk klasifikasi biner. Optimasi dilakukan dengan algoritma *Adam optimizer* dengan *learning rate* awal sebesar 0.001. selama pelatihan, digunakan dua *callback function*, yaitu *EarlyStopping* untuk menghentikan pelatihan secara otomatis jika tidak terjadi peningkatan akurasi validasi dalam 5 *epoch* berturut-turut, dan *ModelCheckpoint* untuk menyimpan model terbaik berdasarkan nilai *validation loss* terendah. Training awal ini model dilatih selama 12 *epoch* di mana hasil terbaik menunjukkan akurasi validasi sebesar 82,9% dan *validation loss* sebesar 0.3663, dengan nilai presisi mencapai 80,9% dan *recall* sebesar 68,8%.

```

EPOCHS_HEAD = 12
history1 = model.fit(
    train_generator,
    epochs=EPOCHS_HEAD,
    validation_data=val_generator,
    class_weight=class_weights,
    callbacks=cb
)

```

Gambar 3. Konfigurasi Training Awal

Epoch	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss	Precision	Recall
1	0.7084	0.7783	0.5812	0.4247	0.6522	0.8138
2	0.7367	0.8080	0.4902	0.4091	0.6878	0.8643
3	0.7816	0.8386	0.3839	0.3819	0.8088	0.8881
4	0.7981	0.8193	0.4813	0.3876	0.8848	0.8889
5	0.8020	0.8120	0.4283	0.4168	0.8701	0.8842
6	0.8112	0.8162	0.4227	0.3861	0.8858	0.7921
7	0.8088	0.8118	0.3882	0.3863	0.8871	0.8863
8	0.8044	0.8296	0.4287	0.3738	0.8888	0.7999
9	0.8048	0.8280	0.4160	0.3864	0.8523	0.8881
10	0.8038	0.8187	0.4081	0.4080	0.7361	0.7946
11	0.8157	0.8386	0.3849	0.3712	0.8847	0.8823
12	0.8186	0.8189	0.3881	0.3881	0.7888	0.7888


Gambar 4. Hasil Pelatihan Training Awal

Setelah tahap training awal selesai, dilakukan proses *fine-tuning* untuk mengoptimalkan performa model. Pada tahap ini, sebanyak 142 lapisan terakhir dari total 238 lapisan *EfficientNetB0* dibuka (*unfreeze*) agar bobot-bobot jaringan tersebut dapat diperbarui dan disesuaikan dengan karakteristik citra fundus retina. *Learning rate* agar pembaruan bobot berlangsung secara bertahap dan tidak mengganggu stabilitas bobot pra-latihan dari *base model*. *Fine-tuning* dilakukan selama 25 *epoch*, dengan tetap menggunakan *callbacks* seperti pada tahap training awal.

Selama proses *fine-tuning*, terjadi peningkatan performa yang cukup signifikan dibandingkan tahap awal. Pada *epoch* pertama, akurasi validasi meningkat menjadi 83,8%, dan terus mengalami peningkatan hingga mencapai titik optimal pada *epoch* ke-12 dengan akurasi validasi sebesar 89.02% dan nilai *validation loss* sebesar 0.3716. Pada tahap ini, model juga mencapai nilai presisi sebesar 92,95% dan *recall* sebesar 77,48%. Hal ini menunjukkan kemampuan yang seimbang antara ketepatan klasifikasi dan sensitivitas terhadap kasus glaukoma. Selain itu, akurasi pelatihan mencapai 94,92% yang menandakan bahwa model berhasil belajar secara mendalam dari pola-pola struktural citra retina.

Epoch	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss	Precision	Recall
1	76,97%	83,82%	0,5462	0,3997	68,68%	74,50%
3	85,33%	86,04%	0,3900	0,3708	81,06%	82,53%
6	88,49%	86,58%	0,3444	0,3589	85,96%	84,52%
9	90,59%	87,61%	0,2982	0,3639	87,71%	88,52%
12	92,14%	89,02%	0,2713	0,3716	92,95%	77,48%
15	93,84%	87,93%	0,2493	0,3825	89,68%	77,76%
18	94,92%	87,55%	0,2321	0,4046	93,06%	93,85%

Gambar 5. Hasil Pelatihan *Fine-Tuning*



Gambar 6. Confusion Matrix

Secara keseluruhan, implementasi model *EfficientNetB0* dengan strategi *transfer learning* dan *fine-tuning* berhasil memberikan peningkatan performa yang signifikan. Model akhir mencapai akurasi validasi sebesar 89,02%, akurasi pelatihan sebesar 94,92% serta *precision* 92,95% dan *recall* sebesar 77,48%. Hasil ini menunjukkan bahwa model mampu mengenali pola karakteristik glaukoma secara efektif dan dapat diandalkan untuk mendukung sistem deteksi dini penyakit glaukoma berbasis citra fundus retina.

SIMPULAN

Penelitian ini berhasil menguji model deteksi penyakit glaukoma berbasis citra fundus retina menggunakan *Convolutional Neural Network* dengan pendekatan *transfer learning* dan *fine-tuning*. Model ini menunjukkan performa yang baik dalam mengklasifikasikan citra retina menjadi glaukoma dan non-glaukoma. Hasil pelatihan awal menghasilkan akurasi sebesar 81,39% yang kemudian meningkat secara signifikan setelah dilakukan *fine-tuning* hingga mencapai performa terbaik dengan 89,02% pada data akurasi validasi. Evaluasi pada data uji menunjukkan nilai akurasi sebesar 87,29%, *precision* 87,04%, *recall* 78,04% dan *F1-Score* 82,54%, dengan hasil *Confusion Matrix* menunjukkan bahwa model mampu mendeteksi glaukoma secara cukup akurat dan konsisten pada citra retina. Secara keseluruhan, model ini memiliki potensi untuk digunakan sebagai sistem pendukung diagnosis dini glaukoma, sehingga dapat membantu tenaga medis dalam proses deteksi otomatis, akurat dan efisien.

DAFTAR PUSTAKA

- Arif, Z., et al. (2023). Classification of eye diseases in fundus images using convolutional neural network (CNN) method with EfficientNet architecture. *JRTI (Jurnal Riset Tindakan Indonesia)*, 8(1), 125–131.
- Cahya, F. N., Hardi, N., Riana, D., & Hadiyanti, S. (2021). Klasifikasi penyakit mata menggunakan convolutional neural network (CNN). *Sistemasi: Jurnal Sistem Informasi*, 10(3), 378–389.
- Chakravarty, A., & Sivaswamy, J. (2016). Glaucoma classification with a fusion of segmentation and image-based features. *Computerized Medical Imaging and Graphics*, 55, 28–41.
- Firdaus, D. H., Imran, B., Bakti, L. D., & Suryadi, E. (2022). Klasifikasi penyakit katarak berdasarkan citra menggunakan metode convolutional neural network (CNN) berbasis web. *Jurnal Kecerdasan Buatan dan Teknologi Informasi*, 1(3), 18–26.
- Fuadah, Y. N., et al. (2022). Glaucoma classification based on fundus images processing with convolutional neural network. *Jurnal Teknik Informatika (JUTIF)*, 3(3), 717–722.
- Indraswari, R., Herulambang, W., & Rokhana, R. (2022). Deteksi penyakit mata pada citra fundus menggunakan convolutional neural network (CNN). *Techno.COM*, 21(2), 378–389.
- Islami, F., Sumijan, & Defit, S. (2024). Penerapan convolutional neural network untuk klasifikasi citra retina. *JPPIPA: Jurnal Penelitian Pendidikan IPA*, 10(8), 4606–4613.
- Mehta, P., et al. (2021). Automated detection of glaucoma with interpretable machine learning using clinical data and multimodal retinal images. *American Journal of Ophthalmology*, 231, 154–169.
- Mulyani, R. E., et al. (2024). Penerapan algoritma convolutional neural network (CNN) deteksi kesehatan mata. *Jurnal Ilmiah Informatika*, 9(2), 142–155.
- Mulyasari, C. R., Hadiana, A. I., & Komarudin, A. (2024). Deteksi penyakit diabetes, katarak dan glaukoma pada citra fundus retina mata manusia menggunakan CNN dengan arsitektur AlexNet. *JUMANJI*, 8(1), 53–68.

- Nairda, D. P., & Suyanto. (2023). Klasifikasi keparahan penyakit glaukoma pada citra fundus retina dengan deep k-nearest neighbor dan CNN. *e-Proceedings of Engineering*, 10(6), 5404–5410.
- Niati, E., & Sitohang, S. (2022). Sistem pakar diagnosa penyakit mata glaukoma dengan metode teorema Bayes. *Computer and Science Industrial Engineering (COMASIE)*, 7(5), 117–124.
- Qulub, M. S., & Agustin, S. (2024). Identifikasi penyakit mata dengan klasifikasi citra foto fundus menggunakan convolutional neural network. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(5), 11034–11039
- Tham, Y.-C., et al. (2014). Global prevalence of glaucoma and projections of glaucoma burden through 2040. *Ophthalmology*, 121(11), 2081–2090.
- Weinreb, R. N., Aung, T., & Medeiros, F. A. (2014). The pathophysiology and treatment of glaucoma: A review. *JAMA*, 311(18), 1901–1911.