

Implementasi Pendekatan Algoritma *Deep Learning* CNN untuk Identifikasi Citra Pasien Keratitis

Implementation of CNN Deep Learning Algorithm Approach for Keratitis Patient Image Identification

MUHAMMAD ASYHAR AGMALARO^{1*}, WISNU ANANTA KUSUMA¹,
LUTFAH RIF'ATI², PRAMITA ANDARWATI², ANTON SURYATAMA²,
ROSY ALDINA³, HERA DWI NOVITA³, OVI SOFIA³

Abstrak

Insiden keratitis secara global berkisar antara 0.4 sampai 5.2 per 10,000 orang setiap tahunnya. Penanggulangan gangguan penglihatan akibat keratitis secara dini dan akurat dapat mencegah kebutaan akibat kekeruhan kornea. Keratitis dapat diidentifikasi oleh dokter spesialis mata dengan bantuan *slitlamp* sebagai instrumen dasar pemeriksaan spesialisik organ mata di fasilitas layanan sekunder. Pada fasilitas layanan primer tidak tersedia dokter spesialis mata dan juga *slitlamp*. Hal ini menyebabkan terjadinya keterlambatan diagnosis dan penanganan terhadap pasien-pasien keratitis di puskesmas atau daerah-daerah dengan fasilitas serta akses ke dokter spesialis mata yang terbatas. Penelitian ini bertujuan untuk mengembangkan model identifikasi keratitis menggunakan metode *convolutional neural network* (CNN) dan data latih berupa citra yang dihasilkan oleh gawai pintar dan dikombinasikan dengan citra *slitlamp*. Akurasi pelatihan dari model yang dikembangkan adalah 92% dengan layer *dropout* ditetapkan dengan nilai 0.3. Rata-rata akurasi validasinya adalah 83% sehingga dapat dikatakan pelatihan model yang dikembangkan tidak mengalami *overfitting*. Adapun hasil pengujian dengan data baru mencapai akurasi sebesar 90%. Selanjutnya parameter model terbaik disematkan ke dalam aplikasi yang berjalan di sistem operasi berbasis Android, namun fungsionalitas serta kinerja UX/UI dari aplikasi perlu ditingkatkan untuk memfasilitasi model agar dapat digunakan secara sempurna.

Kata Kunci: CNN, diagnosis, kebutaan, keratitis, pengolahan citra, *slitlamp*

Abstract

The incidence of keratitis globally ranges from 0.4 to 5.2 per 10,000 people annually. Keratitis can only be identified by an ophthalmologist using a slitlamp as a fundamental instrument for specific eye examination in secondary care facilities. In primary care facilities, eye specialists and slitlamps are not available. This causes delay in the diagnosis and treatment of keratitis patients in public health centers or areas with limited facilities and access to doctors/ophthalmologists. This research aims to develop a keratitis identification model using the convolutional neural network (CNN) method and training data consisting of images produced by smartphones and combined with slitlamp images. The training accuracy of the developed model is 92% with a dropout layer set at 0.3, and the average validation accuracy is 83%, indicating that the model training did not experience overfitting. The testing results with new data achieved an accuracy of 90%. Next, the parameters of the best model will be integrated into an application running on the Android operating system. However, the application's functionality and UX/UI performance need to be improved to facilitate seamless use of the model.

Keywords: blindness, CNN, diagnose, image processing, keratitis, slitlamp

¹ Departemen Ilmu Komputer, FMIPA, Institut Pertanian Bogor, Bogor 16680

² Badan Riset dan Inovasi Nasional, Jakarta Pusat 10340

³ Departemen Oftalmologi, RSUD Dr. Saiful Anwar Malang, Malang 65111 0341 – 362101

* Penulis Korespondensi: Tel/Faks: 0251-8625584; Surel: agmalaro@apps.ipb.ac.id

PENDAHULUAN

Pada tahun 2019 diperkirakan terdapat 2.2 miliar orang mengalami gangguan penglihatan dan kebutaan. Berdasarkan survei *Rapid Assessment of Avoidable Blindness* (RAAB) angka kebutaan Indonesia mencapai 3%, menempatkan Indonesia menjadi negara dengan angka kebutaan tertinggi di Asia Tenggara. Insiden keratitis secara global sekitar 0.4 sampai 5.2 per 10,000 orang setiap tahunnya. Insiden keratitis lebih tinggi pada negara berkembang dibandingkan negara maju. Penanggulangan gangguan penglihatan akibat keratitis merupakan salah satu usaha penting di bidang kesehatan dan kedokteran, namun saat ini hanya dapat diidentifikasi oleh pakar atau didiagnosis oleh dokter spesialis mata yang memiliki fasilitas dan akses kesehatan yang lengkap. Hal ini menyebabkan terjadinya keterlambatan dalam penanganan terhadap pasien-pasien di puskesmas atau daerah-daerah dengan fasilitas serta akses ke dokter/pakar yang terbatas.

Usaha pencegahan dalam kesehatan dapat menjadi solusi alternatif dalam penundaan ataupun penghambatan progresivitas terjadinya keratitis. Pelayanan kesehatan yang berbasis pada usaha preventif dapat meminimalkan tingkat risiko kesehatan dan juga penghematan pembiayaan kesehatan. Usaha yang dapat dilakukan, seperti skrining dan deteksi dini, dapat menurunkan tingkat morbiditas dari suatu penyakit (Tehamen *et al.* 2019). Deteksi keratitis memerlukan keahlian khusus dan alat diagnostik yang tidak murah, sehingga di lapangan terjadi hambatan dalam menemukan kasus keratitis. Keterbatasan infrastruktur dan sumber daya manusia yang ahli merupakan hambatan yang harus segera ditemukan solusinya. Teknologi informasi dapat menjadi salah satu solusi, yaitu dengan mengembangkan program khusus sebagai alat bantu diagnosis berbasis teknologi informasi. Solusi ini berupa model yang dihasilkan melalui pembelajaran mesin sebagai alat bantu skrining, sehingga dapat mengidentifikasi dan mendiagnosis gangguan penglihatan mata akibat keratitis melalui citra yang diambil dengan alat sederhana seperti citra gawai pintar yang mungkin dimiliki oleh tenaga kesehatan di puskesmas atau fasilitas kesehatan primer di banyak daerah di Indonesia.

Dengan kemajuan teknologi, kemampuan pembelajaran mesin dan kecerdasan buatan, mendorong berkembangnya penelitian berbasis komputasi untuk mengidentifikasi dan mendiagnosis gangguan penglihatan mata seperti *diabetic retinopathy*, *glaucoma*, *age-related macular degeneration* (AMD), katarak, dan juga keratitis (Li *et al.* 2021). Beberapa penelitian mengenai penggunaan pembelajaran mesin khususnya dengan pendekatan *deep learning* pada penyakit-penyakit mata telah terbukti efektif dan akurat untuk mendeteksi gangguan penglihatan dan kesehatan mata tersebut melalui foto digital fundus (Liu *et al.* 2018, Liu *et al.* 2019). Beberapa penelitian yang dilakukan untuk deteksi keratitis dengan pendekatan menggunakan algoritma pembelajaran mesin antara lain penelitian yang dilakukan oleh Kuo, *et al.* (2020 dan 2022). Penelitian tersebut bertujuan untuk mengeksplorasi potensi model *deep learning* dalam mendiagnosis keratitis Pseudomonas (gangguan penglihatan keratitis yang diakibatkan oleh bakteri) dengan menggunakan gambar mata eksternal yang bersumber dari sumber terbuka dan citra *slitlamp* (Gu *et al.* 2020). Ada sebanyak 8 algoritma, yaitu ResNet50, DenseNet121, ResNeXt50, SE-ResNet50, dan EfficientNets B0 hingga B3, diadopsi sebagai model *backbone* untuk melatih dan mendapatkan model ensambel terbaik. Akurasi yang terbaik dari studi ini yaitu di rentang 68–72%. Selanjutnya Ji *et al.* (2022) melakukan studi dengan menggunakan metode ResNet50 untuk menghasilkan klasifikasi terhadap citra keratitis yang bersumber dari *slitlamp*. Hasil percobaan menunjukkan bahwa akurasi rata-rata mencapai 84.89% dalam jaringan multi-atribut. Akurasi tertinggi dapat mencapai 89.51%. Penelitian lain yang serupa melakukan identifikasi bakteri atau jamur yang menimbulkan keratitis menggunakan citra segmen anterior. Sejumlah 594 citra sebagai data primer bersumber dari 80 pasien yang digunakan untuk pelatihan menggunakan metode ResNet-50 serta LGM dan MAM menunjukkan akurasi yang jauh lebih tinggi di angka rata-rata 84.5% bila dibandingkan dengan set data sekunder dari sumber terbuka (*open source*) di angka rata-rata 68% (Won *et al.* 2023).

Penelitian ini mencoba melakukan pelatihan pada sebuah model pembelajaran mesin menggunakan algoritma *convolutional neural network* (CNN) terhadap citra-citra yang dihasilkan oleh gawai pintar dan dikombinasikan dengan citra *slitlamp* untuk mengidentifikasi apakah citra tersebut masuk ke kelas keratitis atau non-keratitis. Hasil dari model pembelajaran tersebut apabila menghasilkan akurasi yang baik, diharapkan dapat dimanfaatkan dan disematkan ke dalam gawai pintar menjadi sebuah aplikasi untuk mengidentifikasi keratitis secara langsung, sehingga membantu tenaga kesehatan di berbagai faskes primer yang tersebar di seluruh pelosok Indonesia.

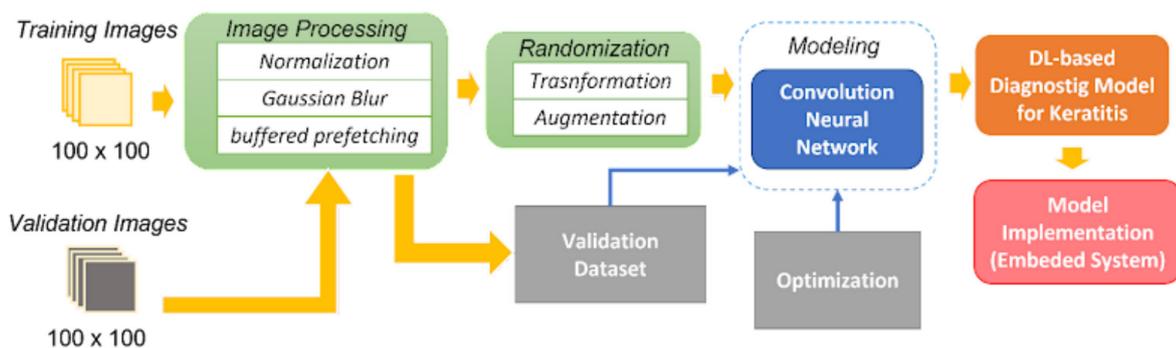
METODE

Studi ini merupakan penelitian yang bersifat non-intervensi eksploratif dengan melakukan pengolahan citra/foto digital yang diambil dari pasien di poliklinik spesialis mata di RSUD Saiful Anwar (RSSA) Malang. Pengambilan data untuk keperluan penelitian dilakukan dengan persetujuan direksi RSSA, dan sudah melalui persetujuan etik (*ethical approval*) dengan SK Klirens Etik nomor 001/KE.03/SK/01/2023. Sampel yang digunakan merupakan citra/foto digital pada area mata pasien dengan diagnosis keratitis dan non-keratitis yang tersimpan di poliklinik spesialis mata di RSUD Saiful Anwar sebanyak 500 sampel data citra menggunakan perangkat *slitlamp* dan atau gawai pintar yang bersifat retrospeksi dan merupakan hasil prosedur rutin poliklinik spesialis mata RSSA Malang. Pembentukan model pembelajaran mesin CNN dilakukan dengan tahapan seperti yang terlihat pada Gambar 1.

Pengumpulan Data Citra

Citra sampel tanpa identitas akan digunakan untuk melatih model *deep learning* dalam mendiagnosis keratitis. Dalam penelitian ini, idealnya pembuatan model *deep learning* yang dihasilkan adalah model yang melalui proses pembelajaran terhadap pola dari citra/foto digital yang diperoleh dari gawai saja. Setiap pasien diambil fotonya menggunakan gawai dan *slitlamp*. *Slitlamp* hanya digunakan sebagai *gold standard* untuk proses verifikasi diagnosis keratitis. Pembuatan dan konstruksi model *deep learning* pada tahap awal ini hanya menggunakan foto yang diambil dengan menggunakan *slitlamp* dan gawai pintar dengan prosedur dan panduan praktik klinis yang disesuaikan (IDI 2014), sehingga citra yang dihasilkan kedua instrumen memiliki tingkat kualitas yang sama. Pengambilan citra sudah sesuai prosedur yang berlaku. Setiap pasien yang berobat ke poli mata akan dilakukan pengambilan citra matanya menggunakan *slitlamp* sebagai instrumen diagnosis *gold standard*.

Dalam melakukan pengambilan citra, mata pasien dilakukan pembersihan kotoran terlebih dahulu agar tidak menjadi *noise* dalam proses pembuatan model *deep learning*. Apabila hasil diagnosis dari citra yang diambil adalah normal, maka citra diberi label kelas non-keratitis. Jika diagnosis dari citra adalah abnormal, maka setelah dokter yang memeriksa memastikan terdapat lesi penanda kelainan keratitis, selanjutnya citra tersebut akan diberi label kelas keratitis. Penandaan ciri khusus keratitis ini penting untuk pemodelan dari semua citra yang terkumpul.



Gambar 1 Struktur pengembangan model deep learning untuk diagnostik keratitis

Praproses Data Citra

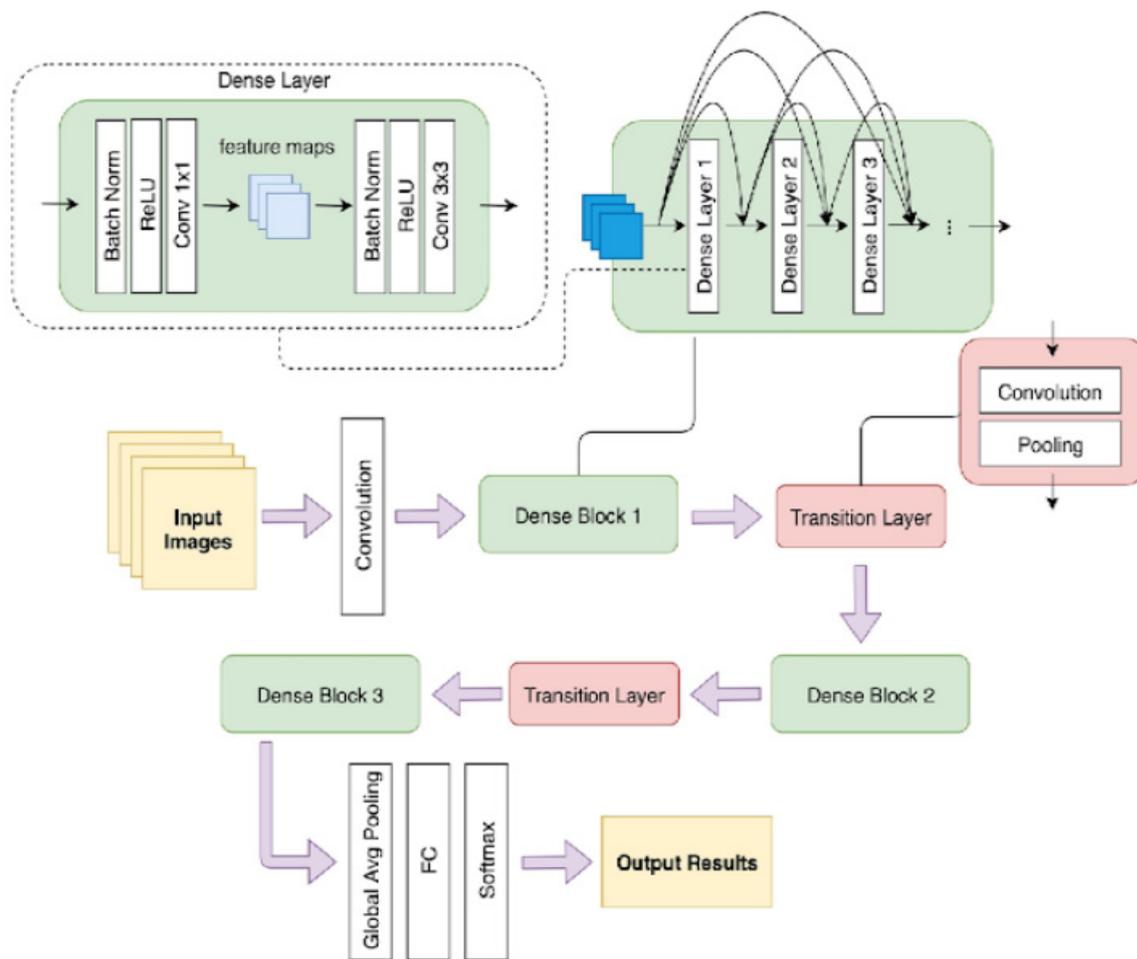
Pembuatan model *deep learning* dengan algoritma CNN hanya menggunakan informasi label (keratitis dan non-keratitis) saja. Informasi pribadi dari pasien tidak digunakan karena tidak berhubungan langsung untuk menghasilkan model pembelajaran CNN. Semua informasi yang terpampang pada citra di setiap subyek seperti tanggal dan informasi *footnote* lainnya akan di-*crop* agar citra yang dihasilkan dapat digunakan sebagai *input* model pembelajaran mesin. Setiap citra subyek penelitian ini akan dilakukan proses *resizing* sehingga memiliki ukuran yang seragam. Pada penelitian ini citra yang di-*resizing* memiliki bentuk *wide* dengan perbandingan *width* dan *height* adalah 4:3. Setelah itu dilakukan normalisasi dan juga transformasi sederhana agar informasi yang tidak perlu dan dampak *noise* dari citra mentah (*raw image*) terhadap pembuatan model DL dapat diminimalisir. Untuk normalisasi data, nilai RGB dari setiap citra dihitung untuk mendapatkan standar deviasi dan nilai rata-rata untuk menormalkan setiap piksel dalam rentang 0 hingga 1. Teknik *denoising* citra dengan *Gaussian blur*, digunakan untuk mengurangi detail gambar ke level tertentu dan membuat mesin pembelajaran tidak terpengaruh oleh banyaknya *noise* pada citra. Selanjutnya dilakukan konfigurasi set data untuk meningkatkan performa pelatihan dengan menggunakan *buffered prefetching* sehingga dapat menghasilkan data dari *disk* tanpa I/O yang diblokir dan tumpang tindih antara pemrosesan data dan eksekusi model saat pelatihan.

Setelah praproses dilakukan, selanjutnya dilakukan proses randomisasi berupa transformasi dan augmentasi data sebelum memasuki proses pembelajaran model. Transformasi dan augmentasi data digunakan untuk membantu model mempelajari lebih banyak variasi pola dari citra. Pendekatan menggunakan augmentasi menghasilkan tambahan citra secara *artificial*, sehingga model pembelajaran memiliki sifat generalisasi yang lebih baik.

Perancangan Model Deep Learning untuk Diagnosis Keratitis

Pemodelan *machine learning* menggunakan metode CNN merupakan salah satu pengembangan dari jaringan syaraf tiruan yang terinspirasi dari jaringan syaraf manusia dan biasa digunakan pada data citra untuk mendeteksi, mengenali, dan mengidentifikasi kelas dari suatu objek. Metode CNN merupakan bagian dari *deep neural network* yang dirancang khusus untuk memproses citra digital dalam bentuk data piksel. Struktur algoritma pada CNN memiliki *neuron* yang didesain untuk bekerja layaknya *lobus frontal*, khususnya area *visual cortex* yang bertanggung jawab untuk memproses informasi dalam bentuk rangsangan visual. Bagian *artificial* untuk layer pemrosesan informasi pada CNN disebut dengan istilah *convolution*. Dalam melakukan pelatihan model CNN, data citra yang diakuisisi dibagi ke dalam dua set data yaitu *training* dan *testing/validation*. Set data *training* digunakan untuk melatih model CNN, sehingga dapat mengidentifikasi citra yang masuk ke kelas keratitis dan non-keratitis. Selain itu set data validasi digunakan untuk melihat dan memahami performansi model yang sudah dilakukan proses pembelajaran. Fungsi dari proses validasi juga dapat mengetahui apakah model yang dihasilkan dapat mengidentifikasi kelas dengan akurat pada data-data yang tidak disertakan dalam proses pembelajaran dan tidak terjadi *overfitting*. Arsitektur model CNN yang digunakan pada penelitian ini terlihat pada Gambar 2.

Penelitian secara empiris dilakukan dengan *hyper-parameter* dari model CNN berupa *learning rate*, jumlah *layer dense*, *growth rate*, dan *batch size* diatur sedemikian sehingga dapat menyesuaikan hasil validasi, yang bertujuan untuk menghasilkan model yang optimal. Algoritma optimasi (*optimizer*) yang digunakan pada model CNN penelitian ini adalah algoritma ADAM. ADAM adalah algoritma berupa *adaptive learning rate*, algoritma ini menghitung dan mengoptimasi *learning rate* individu untuk parameter yang berbeda. ADAM menggunakan estimasi gradien momen pertama dan kedua untuk mengadaptasi *learning rate* setiap bobot jaringan saraf. Fungsi *loss* yang digunakan untuk proses validasi model CNN pada penelitian ini adalah *cross-entropy*.



Gambar 2 Arsitektur model CNN

Pada penelitian ini digunakan suatu *framework/platform end-to-end* untuk *machine learning* berbasis *open source*, yaitu tensorflow dan tensorlite. Hal ini bertujuan untuk menghasilkan model yang dapat dimanfaatkan dan diimplementasikan dengan lebih mudah ke perangkat *portable (embedded)*.

Validasi dan Ukuran Performansi Model

Five-fold cross validation merupakan metode yang digunakan pada penelitian ini untuk melihat performa model kecerdasan buatan diagnostik keratitis. Citra yang diklasifikasikan sebagai keratitis pada proses *training* berjumlah 200 citra dan non-keratitis berjumlah 250 citra. 50 citra sisanya dengan jumlah masing-masing seimbang digunakan untuk proses validasi. Indeks performansi model berupa *diagnostic accuracy* (PPV dan NPV) keratitis, *sensitivity*, *specitivity*, dihitung pada model DL yang dihasilkan saat proses pembelajaran. Ukuran performansi ini menjadi acuan apakah model siap di-*embed* ke perangkat *portable (gawai)* atau masih perlu dilakukan percobaan empiris untuk menghasilkan model yang lebih baik dan lebih optimal dalam mengidentifikasi kelas keratitis dan non-keratitis.

Implementasi

Model hasil pembelajaran mesin menggunakan metode CNN yang optimal, selanjutnya diimplementasikan/di-*embed* ke sebuah aplikasi yang berjalan di perangkat *portable* dengan sistem operasi Android. Pada proses pembuatan model di tahapan sebelumnya, harus dipastikan bahwa model selain memiliki kinerja yang baik dalam identifikasi keratitis, juga harus efisien dan tidak membutuhkan banyak sumber daya komputasi, sehingga dapat berjalan di perangkat *portable*. Pada penelitian ini pengembangan aplikasi *mobile* untuk implementasi hasil model DL untuk identifikasi keratitis adalah menggunakan *clean architecture* (Khan, 2023).

HASIL DAN PEMBAHASAN

Akuisisi dan Praproses Data

Set data yang digunakan terdiri atas dua jenis, yaitu data citra keratitis dan non-keratitis. Data keratitis diambil dari Poliklinik Mata RSSA. Contoh sampel data citra yang sudah diakuisisi dapat dilihat pada Gambar 3.

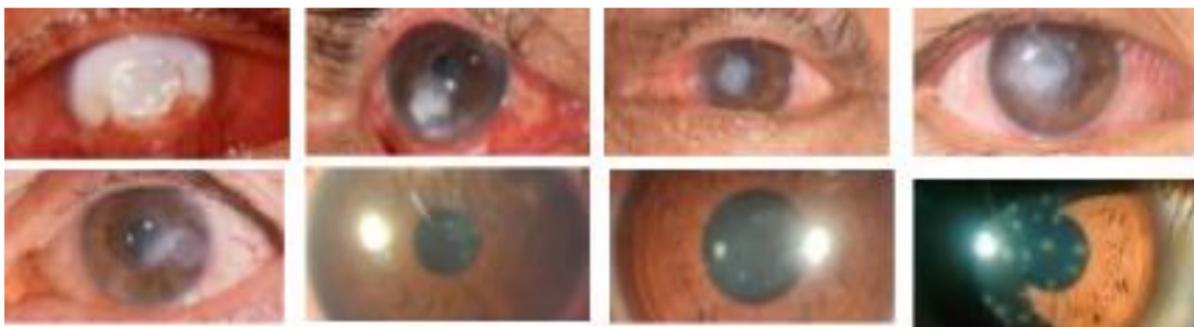
Dari sampel tersebut, terlihat bahwa citra memiliki ukuran yang tidak seragam. Sampel yang diambil dengan *slitlamp* memiliki fitur dan warna yang berbeda dari citra yang diambil dengan foto biasa. Praproses data dilakukan untuk menyeragamkan ukuran citra. Hal ini diperlukan karena masukan model untuk model NN maupun CNN harus memiliki dimensi yang sama. Proses penyeragaman ini menggunakan aplikasi *resizing* citra dengan ukuran seragam dalam bentuk *wide* (ukuran 183 x 96 piksel). Hasil penyeragaman ukuran citra dapat dilihat pada Gambar 4.

Pada representasi histogram, terlihat bahwa fitur citra pada kelas keratitis dan non-keratitis menghasilkan perbedaan bentuk, sehingga dapat menjadi landasan asumsi awal bahwa distribusi frekuensi nilai intensitas piksel pada masing-masing kelas memiliki pola yang berbeda (Gambar 5).

Pada penelitian ini ada sebanyak 500 data citra yang berhasil dikumpulkan, dengan komposisi kelas yaitu 240 citra keratitis dan 260 citra non-keratitis. Sebanyak 80% data citra digunakan untuk data latih, sedangkan 20% ditetapkan secara acak sebagai data uji/validasi. Data dibagi dengan proporsi untuk *training set* adalah sebanyak 400 Citra dan *validation set* adalah sebanyak 100 citra dengan proporsi dari pengacakan kelas keratitis dan non-keratitis dilakukan secara seimbang.



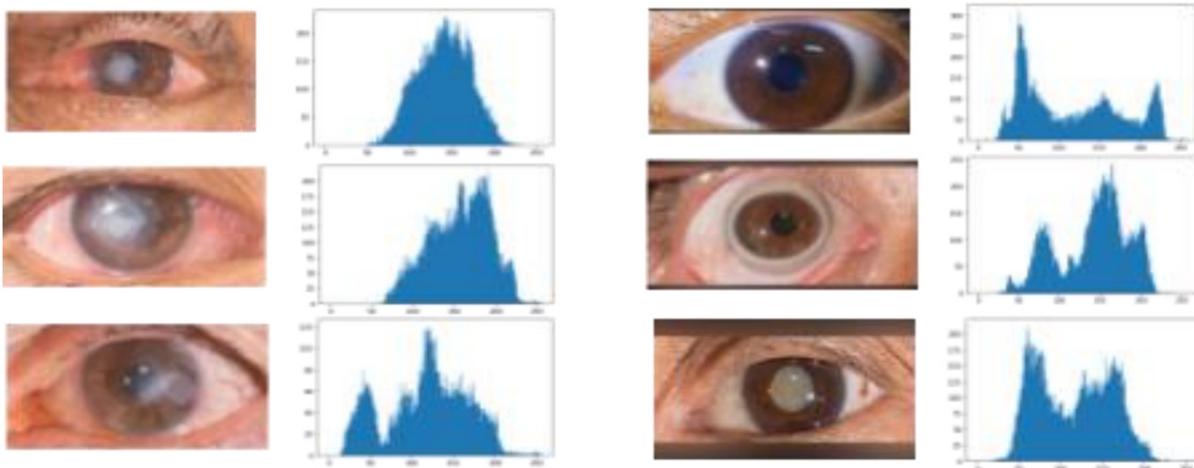
Gambar 3 Data citra keratitis



Gambar 4 Penyeragaman ukuran citra dalam bentuk *wide* (183 x 96)

Perancangan Pemodelan CNN

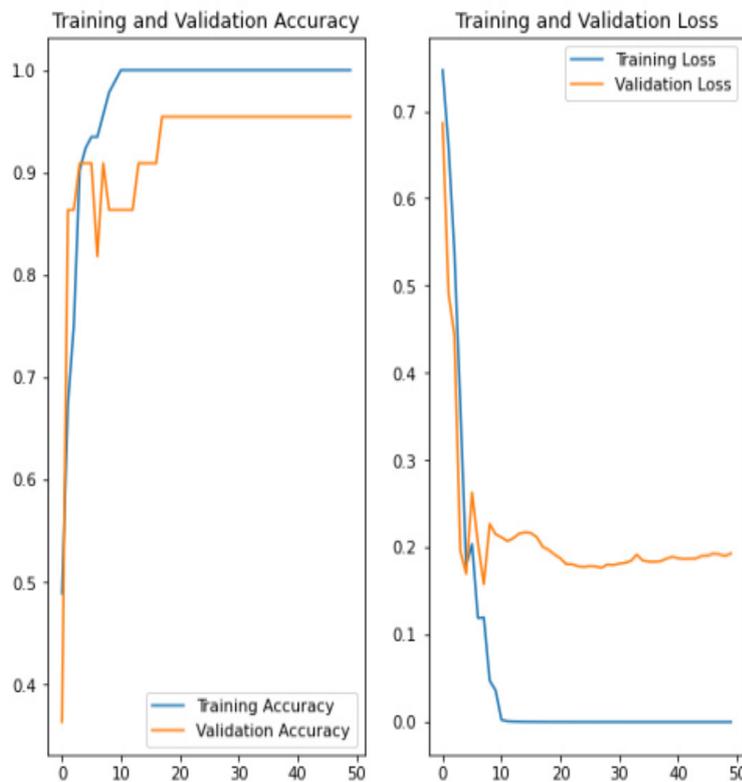
Pada tahap percobaan awal, arsitektur model CNN yang digunakan untuk identifikasi citra keratitis dan non-keratitis adalah model Lenet. *Batch-size* yang digunakan adalah 1. Dengan demikian, pada proses pelatihan ukuran data hanya 1 yang melewati jaringan. Dikarenakan nilai piksel RGB berada di rentang [0, 255], maka untuk nilai tersebut dinormalisasi ke [0,1], agar prediksi yang dihasilkan lebih baik. Arsitektur model CNN ini terdiri dari 3 jaringan konvolusi, dengan ukuran ukuran kernel 3x3. Setiap konvolusi ditambahkan layer *max pooling* untuk *down sampling* data. Pada pelatihan model ini belum dilakukan *tuning parameter*. Hasil kinerja model CNN ini dapat dilihat pada Gambar 6 yang menunjukkan perbandingan akurasi dan *loss* saat pelatihan dan validasi. Terlihat bahwa model CNN tidak mengalami *overfitting*, meskipun terdapat perbedaan antara akurasi model saat pelatihan dan validasi, namun tidak terlalu besar.



(a) Keratitis

(b) Non-keratitis

Gambar 5 Perbandingan nilai histogram citra keratitis vs non-keratitis



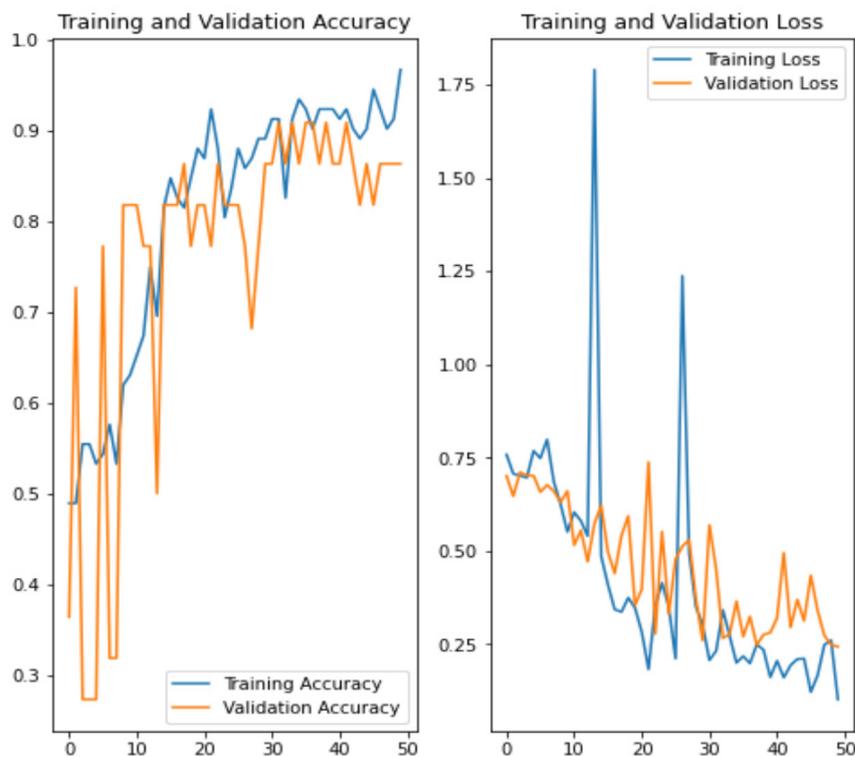
Gambar 6 Perbandingan kinerja model saat pelatihan dan validasi

Augmentasi data untuk *flip + random*, dan *zoom + random rotate* dilakukan untuk menambahkan variasi data (Gambar 7). Selain ditambah augmentasi data, ditambahkan juga lapisan *dropout* untuk optimasi proses pembelajaran model. Hasil kinerja model CNN dengan augmentasi dan *dropout* dapat dilihat pada Gambar 8 yang menunjukkan perbandingan akurasi dan *loss* saat pelatihan dan validasi. Terlihat bahwa hasil akurasi model CNN dengan augmentasi dan *dropout* saat pelatihan dan validasi hampir sama. Langkah pengujian ini menunjukkan bahwa penambahan variasi data dengan augmentasi dan *dropout* dapat memperbaiki kinerja model CNN.

Pada tahap percobaan selanjutnya ada penambahan jumlah data citra yang berhasil dikumpulkan, yaitu sejumlah 350 citra untuk non-keratitis. Dengan menggunakan parameter model yang sudah dilatih sebelumnya, pada saat dilakukan proses *training* ulang, akurasi yang dihasilkan mencapai rentang 91-93%, namun akurasi validasi rata rata sebesar 87%. Hal ini diinterpretasikan bahwa model pembelajaran dengan data yang sudah ditambahkan tidak *overfit*.



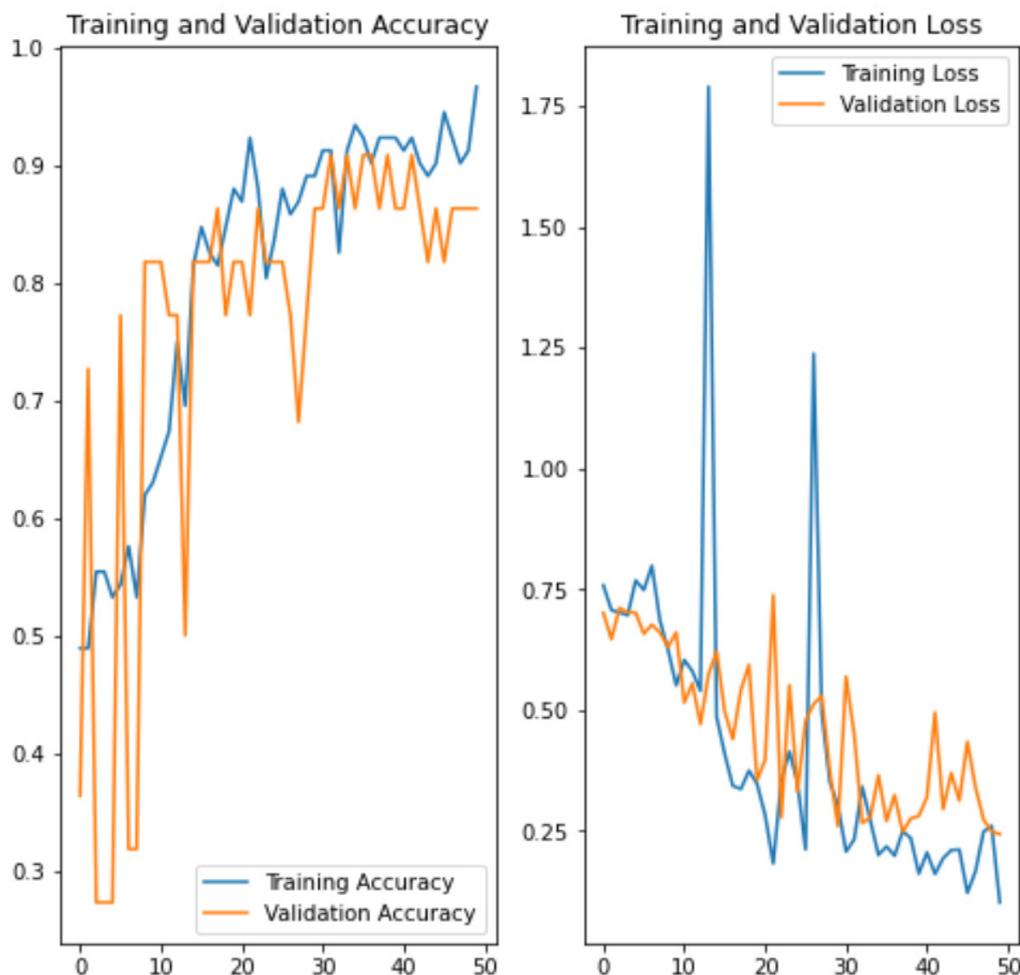
Gambar 7 Variasi data citra dengan augmentasi



Gambar 8 Kinerja model CNN dengan augmentasi dan dropout

Selanjutnya dilakukan percobaan menggunakan model yang ada terhadap data uji yang merupakan data yang tidak digunakan pada proses pelatihan/pembelajaran jaringan CNN dalam menghasilkan model tersebut. Pada data citra baru tersebut akan dimasukkan ke model dalam skema data uji sebagai validasi untuk pembelajaran mesin CNN dengan total bobot parameter model CNN yang sudah dilatih adalah sebanyak 3,562,914. Pada Gambar 9 terlihat bahwa akurasi *training* yang dilakukan kembali oleh model menggunakan parameter sebelumnya meningkat di angka di atas 98% dan juga nilai fungsi *loss* juga menurun mulai di *epoch* ke-15. Namun untuk akurasi validasi nilainya tidak naik signifikan mengikuti akurasi *training* dan juga fungsi *loss* validasi berbanding terbalik dengan fungsi *loss training*. Hal ini memperlihatkan potensi model *overfitting*, model cukup baik dalam memprediksi kelas pada data latih namun tidak baik untuk memprediksi kelas pada data baru.

Optimasi *hyperparameter/optimizer* dan penambahan layer *dropout* dengan nilai hasil empiris yaitu 0.3 dilakukan untuk meningkatkan performa model citra *wide* dan untuk menghindari *overfitting*. Setelah dilatih ulang, pola dari konvergensi nilai akurasi *training* dan *validasi* begitu juga dengan nilai fungsi *loss* mengalami perbaikan dibandingkan sebelumnya, walaupun tidak signifikan. Hasil akurasi *training* maksimal adalah 92% dan akurasi validasi rata-rata 83%. Dari 50 data (yang belum di *training* sebelumnya) untuk kelas non-keratitis dan keratitis didapatkan hasil uji yang seimbang. Uji model menunjukkan akurasi 90% dengan salah klasifikasi citra aktual adalah keratitis diprediksi menjadi non-keratitis sejumlah 3 citra, sedangkan citra aktual non-keratitis diprediksi dan salah diklasifikasikan sebagai keratitis sebanyak 2 citra. Berdasarkan hasil ini, maka model yang dihasilkan dapat ditransformasikan ke model *lite* agar bisa disematkan ke dalam aplikasi berbasis android.



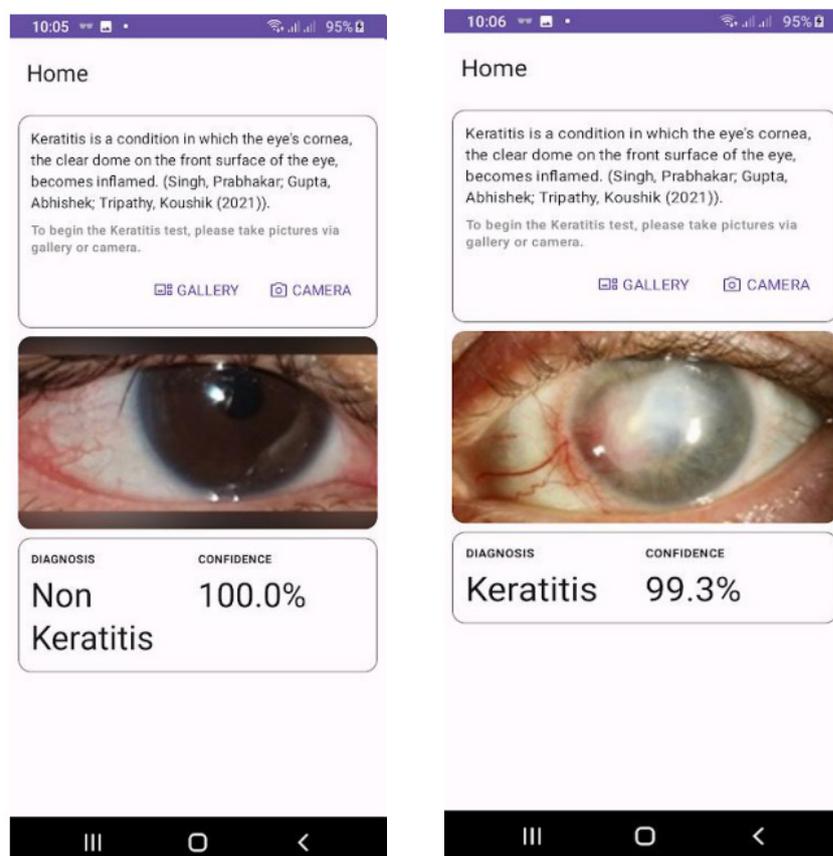
Gambar 9 Kinerja model CNN dengan data uji baru

Implementasi Model CNN

Model yang telah dikembangkan akan diimplementasikan menjadi sebuah aplikasi yang berjalan pada sistem operasi Android. Model CNN disematkan ke dalam aplikasi dan digunakan pada perangkat bergerak (gawai) yang memiliki kemampuan menangkap/mengolah citra secara mumpuni sesuai dengan spesifikasi dari gawai. Sistem operasi Android juga didukung oleh berbagai penyedia pihak ketiga dalam bentuk pustaka perangkat lunak (*library*) salah satunya adalah *tensorflow lite* yang memfasilitasi model CNN untuk melakukan deteksi keratitis dan non-keratitis. Aplikasi dikembangkan menggunakan bahasa pemrograman Kotlin dengan menggunakan Android Studio sebagai *integrated development environment* (IDE). Dari sisi arsitektur, diterapkan *clean architecture* yang akan memisahkan kode sumber menjadi beberapa lapisan (*layer*) agar pengembangan menjadi lebih fleksibel dan tidak saling terikat pada setiap lapisannya. Berikut adalah tampilan antarmuka purwarupa aplikasi (Gambar 10).

SIMPULAN

Penelitian ini berhasil melakukan perancangan model berbasis pembelajaran mesin CNN untuk mendeteksi citra keratitis dan non-keratitis. Setelah dilakukan optimasi *hyperparameter optimizer* dengan layer *dropout* ditetapkan dengan nilai 0.3, percobaan terhadap citra memiliki akurasi maksimal untuk *training* adalah 92%, sedangkan akurasi validasinya memiliki rata-rata 83%, sehingga dapat dikatakan pelatihan model pembelajaran mesin tidak mengalami *overfitting*. Untuk data baru hasil pengujian menunjukkan akurasi sebesar 90% dengan salah klasifikasi citra aktual adalah keratitis diprediksi menjadi non-keratitis sejumlah 3 citra, sedangkan citra aktual non-keratitis diprediksi dan salah diklasifikasikan sebagai keratitis sebanyak 2 citra. Parameter model terbaik berhasil disematkan ke dalam sebuah aplikasi yang berjalan di sistem operasi berbasis Android namun fungsionalitas, serta kinerja UX/UI dari aplikasi perlu ditingkatkan untuk memfasilitasi model agar dapat digunakan secara sempurna.



Gambar 10 Implementasi model CNN pada aplikasi berbasis Android

UCAPAN TERIMA KASIH

Dana untuk penelitian ini berasal dari DIPA Badan Riset dan Inovasi Nasional. Data citra tersimpan disediakan oleh kolaborator dari Departemen Oftalmologi RSSA Malang, dan proses penyusunan model *deep learning* dilaksanakan dengan dukungan fasilitas komputer di IPB Bogor.

KONTRIBUSI *AUTHORSHIP*

Agmalaro, M.A(MAA), Kusuma, W.A(WAK), dan Rif'ati, L(LR) adalah penulis utama, sedangkan Andarwati, P (PA), Suryatma, A (AS), Aldina, R(RA) , Novita, D.H(DHN), dan Sofia, O(OS) adalah penulis anggota. MAA dan WAK berperan penting dalam pemrosesan data citra dan pemodelan serta validasinya, LR adalah koordinator penelitian secara keseluruhan dan pencari dana. PA dan AS mempersiapkan penulisan proposal dan perizinan etik, AR, DHN, dan OS adalah para penyusun protokol dan pengumpul data klinis. Semua pihak berkontribusi aktif dalam finalisasi artikel ini.

PERNYATAAN *INFORMED CONSENT*

Persetujuan pasien diabaikan karena sifat retrospektif dari penelitian ini, di mana informasi identifikasi dalam gambar *slitlamp* telah dihapus dari semua peserta sehingga pelabelan terhadap pasien tidak digunakan.

PERNYATAAN KETERSEDIAAN DATA

Data tidak tersedia untuk umum karena masalah privasi. Permintaan untuk mengakses kumpulan data harus ditujukan ke Rumah Sakit Afiliasi Universitas Brawijaya RSUD Dr. Saiful Anwar Malang Departemen Oftalmologi.

CONFLICTS OF INTEREST

Para penulis menyatakan tidak ada konflik kepentingan dalam melakukan penelitian ini.

DAFTAR PUSTAKA

- Gu H, Guo Y, Gu L, Wei A, Xie S, Ye Z, Xu J, Zhou X, Lu Y, Liu X, Hong J. 2020. Deep learning for identifying corneal diseases from ocular surface slit-lamp photographs. *Scientific Reports*, 10(1): <https://doi.org/10.1038/s41598-020-75027-3>.
- Ikatan Dokter Indonesia (IDI). 2014. *Panduan Praktik Klinis bagi Dokter di Fasilitas Pelayanan Kesehatan Primer*. 2nd ed. Jakarta: Ikatan Dokter Indonesia.
- Ihsan G dan Irfani I. 2017. Karakteristik klinis keratitis pada anak di pusat mata nasional rumah sakit mata cicendo. <https://perpustakaanrsmcicendo.com> [diunduh 20 Juni 2023].
- Ji Q, Jiang Y, Qu L, Yang Q, Zhang H. 2022. An image diagnosis algorithm for keratitis based on deep learning. *Neural Process Letter* 54, 2007–2024: <https://doi.org/10.1007/s11063-021-10716-2>.
- Kuo MT, Hsu B Y, Yin YK, Fang PC, Lai HY, Chen A, Yu MS, Tseng VS. 2020. A deep learning approach in diagnosing fungal keratitis based on corneal photographs. *Scientific Reports*, 10(1): <https://doi.org/10.1038/s41598-020-71425-9>.
- Kuo MT, Hsu BWY, Lin YS, Fang PC, Yu HJ, Hsiao YT, Tseng VS. 2022. Deep learning approach in image diagnosis of pseudomonas keratitis. *Diagnostics* 12(12): 2948: <http://dx.doi.org/10.3390/diagnostics12122948>.

- Liu J, Pan Y, Li M, Chen Z, Tang L, lu C, Wang J. 2018. Applications of deep learning to mri images: a survey big data mining and analytics. *Big Data Mining and Analytics*, 1(1):1–18: <https://doi.org/10.26599/BDMA.2018.9020001>.
- Liu HY, Hopping GC, Vaidyanathan U, Ronquillo YC, Hoopes PC, Moshirfar M. 2019. Polymerase Chain Reaction and Its Application in the Diagnosis of Infectious Keratitis. *Med Hypothesis Discov Innov Ophthalmol*, 8(3):152–155.
- Li Z, Jiang J, Chen K, Chen Q, Zheng Q, Liu X, Weng H, Wu S, Chen W. 2021. Preventing corneal blindness caused by keratitis using artificial intelligence. *Nature Communication*. 12(1):3738. doi: 10.1038/s41467-021-24116-6.
- Tehamen M, Rares L, Supit W. 2019. Gambaran penderita infeksi mata di rumah sakit mata manado provinsi sulawesi utara periode juni 2017 - juni 2019. *E-CliniC*, 8(1):5–9.
- Won YK, Lee H, Kim Y, Han G, Chung TY, Ro YM, Lim DH. 2023. Deep learning-based classification system of bacterial keratitis and fungal keratitis using anterior segment images. *Front Med*. 10:1162124: <https://doi.org/10.3389/fmed.2023.1162124>.