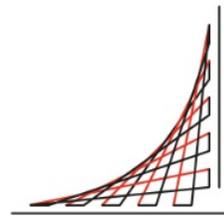




**Universidad del  
Rosario**



**ESCUELA  
COLOMBIANA  
DE INGENIERÍA  
JULIO GARAVITO**

# **Detección de Keratitis con Ayuda de Aprendizaje Profundo**

**Stiven Rodríguez Santana**

**Trabajo Dirigido**

**Tutor**

**Ph.D. Oscar Julián Perdomo Charry**

**UNIVERSIDAD DEL ROSARIO  
ESCUELA COLOMBIANA DE INGENIERÍA JULIO GARAVITO  
PROGRAMA DE INGENIERÍA BIOMÉDICA  
BOGOTÁ, COLOMBIA**

**2021**

# Detección de Keratitis con Ayuda de Aprendizaje Profundo

**Stiven Rodríguez Santana**

Trabajo Dirigido presentado como requisito para aplicar al título de:  
**Ingeniero Biomédico**

Tutor:  
Ph.D. Oscar Julián Perdomo Charry

Grupo de Investigación:  
Grupo de Investigación GIBIOME

UNIVERSIDAD DEL ROSARIO  
ESCUELA COLOMBIANA DE INGENIERÍA JULIO GARAVITO  
PROGRAMA DE INGENIERÍA BIOMÉDICA  
BOGOTÁ, COLOMBIA  
2021

*To my family, who brought me right till this  
point*

# Agradecimientos

Agradezco a la gran cantidad de compañeros y personas que conocí a lo largo de mi formación como profesional, los cuales cada uno en su momento me apoyaron, y de alguna u otra forma me permitieron llegar ha este punto en mi formación como profesional y persona. Agradezco a los diferentes profesores los cuales marcaron mi camino de formación, y en especial a el profesor Oscar Julián Perdomo Charry, mi tutor con el cual sin su presencia, ayuda y guía, esta tesis no hubiera sido posible.

Por ultimo agradezco a mi familia, los cuales siempre estuvieron presentes, y me dieron la posibilidad, de formarme como persona y futuro ingeniero.

## Resumen

La keratitis es una de las principales causas de inflamación de la córnea, producida por una infección, lesión o enfermedad, que conlleva a visión borrada, disminución de la visión y en algunos casos hasta la ceguera. La keratitis en estado avanzados es bastante difícil de tratar, por lo que los esfuerzos se han centrado en el diagnóstico temprano de keratitis, aumentando la posibilidad de éxito en los tratamientos existentes. Para el diagnóstico de keratitis tradicionalmente está a cargo de un especialista en el este campo, capaz de identificar características asociadas a la keratitis. Actualmente, el uso de algoritmos basados en Deep Learning como herramienta potencial para ayudar en un diagnóstico automático temprano, ha podido soportar la toma de decisiones clínicas y en algunos casos aumentando la velocidad en los diagnósticos en zonas de difícil acceso. Por tanto, en este documento se presenta la exploración sistemática de diferentes algoritmos basados en Deep Learning usando imágenes de polo anterior de ojos, para generar un diagnóstico automático en la detección de keratitis.

**Palabras clave:** Keratitis, Deep learning, diagnostico, tratamiento, ceguera..



# Tabla de Contenidos

<b>Agradecimientos</b>	<b>IV</b>
<b>Abstract</b>	<b>V</b>
<b>Índice de Figuras</b>	<b>IX</b>
<b>Índice de Tablas</b>	<b>XI</b>
<b>1 INTRODUCCIÓN</b>	<b>1</b>
<b>2 OBJETIVOS</b>	<b>7</b>
2.1 General . . . . .	7
2.2 Específicos . . . . .	7
<b>3 METODOLOGÍA</b>	<b>8</b>
3.1 Fase 1: Procesamiento y análisis de imágenes oculares de córnea empleadas para la detección de Queratitis . . . . .	8
3.2 Fase 2: Implementación de modelos basados en aprendizaje profundo para la extracción y clasificación de imágenes de ojos. . . . .	9
3.3 Fase 3: Selección del mejor modelo obtenido según los criterios evaluados y la visualización cómoda de los resultados del análisis de la imágenes evaluadas.	10
<b>4 RESULTADOS</b>	<b>11</b>
4.1 Resultados estadísticos de los modelos generados . . . . .	11
4.2 Análisis cualitativo de los resultados obtenidos . . . . .	14
<b>5 DISCUSIÓN</b>	<b>21</b>
<b>6 CONCLUSIONES</b>	<b>25</b>
<b>7 TRABAJOS FUTUROS</b>	<b>26</b>
<b>Bibliografía</b>	<b>27</b>



# Índice de Figuras

<b>1-1</b>	Ojos con presencia de Keratits [1] . . . . .	1
<b>1-2</b>	Representacion grafica de filtros en redes neuronales[11] . . . . .	5
<b>3-1</b>	Imagen de los diferentes bio-marcadores presentes en la base de datos [2] . .	9
<b>4-1</b>	Reultados de imagen 1 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada . . . . .	14
<b>4-2</b>	Resultados de imagen 2 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada . . . . .	14
<b>4-3</b>	Resultados de imagen 3 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada . . . . .	15
<b>4-4</b>	Resultados de imagen 4 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada . . . . .	15
<b>4-5</b>	Resultados de imagen 5 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada . . . . .	15
<b>4-6</b>	Resultados de imagen 6 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada . . . . .	16
<b>4-7</b>	Resultados de imagen 7 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada . . . . .	16
<b>4-8</b>	Resultados finales del modelo en imagen 1, imagen analizada con mapa de calor, imagen original . . . . .	17
<b>4-9</b>	Resultados finales del modelo en imagen 2, imagen analizada con mapa de calor, imagen original . . . . .	17
<b>4-10</b>	Resultados finales del modelo en imagen 3, imagen analizada con mapa de calor, imagen original . . . . .	18
<b>4-11</b>	Resultados finales del modelo en imagen 4, imagen analizada con mapa de calor, imagen original . . . . .	18

---

<b>4-12</b> Resultados finales del modelo en imagen 5, imagen analizada con mapa de calor, imagen original . . . . .	19
<b>4-13</b> Resultados finales del modelo en imagen 6, imagen analizada con mapa de calor, imagen original . . . . .	19
<b>4-14</b> Resultados finales del modelo en imagen 7, imagen analizada con mapa de calor, imagen original . . . . .	20
<b>5-1</b> Imagen de training en modelo 5, máscara generada ideal, mascara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada	22
<b>5-2</b> Imagen de training en modelo 5, máscara generada ideal, mascara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada	22
<b>5-3</b> Imagen de training en modelo 5, mascara generada ideal, mascara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada	23
<b>5-4</b> Imagen sana de test en modelo 2, mascara generada ideal, mascara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada	23

# Índice de Tablas

<b>4-1</b>	Representación de los conjuntos y sub-conjuntos generados . . . . .	11
<b>4-2</b>	Modelos propuestos y sus parámetros con los mejores resultados obtenidos durante entrenamiento . . . . .	12
<b>4-3</b>	Índice Jaccard obtenido en los 7 modelos propuestos . . . . .	12
<b>4-4</b>	Los 5 índices de Jaccard más bajos de cada modelo en entrenamiento . . . . .	13
<b>4-5</b>	Los 5 índices de Jaccard más altos de cada modelo en entrenamiento . . . . .	13
<b>4-6</b>	Los 5 índices de Jaccard más bajos de cada modelo en el conjunto de prueba . . . . .	13
<b>4-7</b>	Los 5 índices de Jaccard más altos de cada modelo en el conjunto de prueba . . . . .	14



# 1 INTRODUCCIÓN

La queratitis se define como la respuesta inflamatoria en el tejido ocular, la cual puede tener diferentes causas de origen, pero que tienen como factor común, conllevar a la ceguera en caso de no ser tratada. Es una de las principales causas de ceguera en el mundo causando entre 1.5 y 2 millones casos anuales [2]. Existe una tendencia en la aparición de este tipo de infecciones en personas de jóvenes, las cuales en muchos casos terminan en ceguera volviéndolo una problemática actual y no únicamente presente en personas de edad avanzada. La aparición de queratitis depende de la presencia de diferentes factores que puede aumentar el riesgo de la aparición de esta patología en los ojos humanos entre los cuales se pueden encontrar; contusiones oculares, infecciones oculares y algunos factores tanto geográficos como ambientales [3].



**Figura 1-1:** Ojos con presencia de Keratits [1]

Además de la presencia de factores de riesgo se necesita la presencia de un agente infeccioso el cual conlleva finalmente a la respuesta inflamatoria del tejido ocular, los cuales pueden ser diferentes tipos de bacterias, virus y hongos. La respuesta inflamatoria dependiendo de la causa de su origen puede presentar diferentes características. La queratitis Bacteriana es característica por presentar secreción purulenta o mucopurulenta, lesión redonda u ovalada en la córnea con un infiltrado estromal subyacente y circundante edema corneal. La queratitis por hongos se caracteriza por una resequedad, lesión levantada irregular con bordes plumosos,

lesiones satélite y endotelial exudado. La queratitis Viral se puede clasificar como epitelial la cual es producto de virus vivos y estroma causado por una respuesta inmunitaria a la infección vírica. Pero todas estas generalmente causando la presencia una lesión corneal dendrítica y estroma. Además, normalmente esta respuesta inflamatoria con frecuencia causa una inflamación del estroma en forma de disco y reacción de la cámara anterior [4],[5][6].

La queratitis es una patología que tiende a aumentar el daño causado con el paso del tiempo, por lo que en sus primeras etapas presenta pequeños síntomas como pueden ser pequeñas inflamaciones en los ojos que no representan un gran inconveniente en las personas que lo sufren por lo que generalmente la persona que lo padece no le presta mayor atención permitiendo un avance por parte de la patología, una vez avanzada la infección, esta puede empeorar rápidamente, al combinarse con cualquier otro factor de riesgo empieza a presentar mayor daño en el tejido ocular. Complicando el tratamiento y causando en la mayoría de los casos ceguera e incluso perforación en la córnea. La detección temprana de la queratitis ha sido una de las mejores formas de luchar contra esta patología, aunque por las características anteriormente mencionadas, esto normalmente no sucede, los últimos esfuerzos relacionados con la investigación en queratitis se centran mayormente en cómo realizar esta detección temprana [7].

La detección de esta patología, desde hace años se basa principalmente en bio-marcadores morfológicos, los cuales son característicos en cualquier tipo de esta patología, lo que permiten la detección de este tipo de inflamación producto de la queratitis, mientras que otros tipos de bio-marcadores pueden ser basados en un análisis de las células que componen el tejido analizado como pueden ser la acumulación de células de glóbulos blancos en los vasos sanguíneos intraoculares. El uso de iluminaciones con diferentes filtros también es una herramienta que ha demostrado brindar ventajas para el análisis de tejidos sospechosos de presentar queratitis, ya que un diferente espectro de luz puede facilitar una mejor identificación de diferentes bio-marcadores, que de otra forma pueden presentar más dificultades para su correcta identificación. Estos métodos manuales generalmente logran buenos resultados logrando un buen diagnóstico sobre los pacientes analizados pero como desventaja de este tipo de procedimientos requieren un gran esfuerzo en su procesamiento mecánico tanto por el factor humano requerido, como por parte de los equipos requeridos para la obtención y procesamiento de muestra, los cuales aumentan el costo y el tiempo requerido para la implementación de este tipo de método, retrasando el diagnóstico y a sí mismo el posible comienzo del tratamiento para esta patología [8][9].

La escasez de recursos humanos es uno de los grandes problemas en el diagnóstico de esta patología ya que se requiere expertos en el campo de análisis de córnea, que interpreten los resultados ofrecidos por los bio-marcadores, en donde se estima la existencia de 200.000 profesionales oftalmólogos en el mundo, los cuales al ser tan pocos no logran cubrir todo el

campo de acción donde puede ser requeridos, generando en la mayoría de los casos el retraso en el inicio de tratamientos. Sumado a la limitada oferta de recurso humano en ese campo existe una predicción de una reducción de este número para los próximos años, tendencia que puede afectar una más a países en vía de desarrollo por la falta de expertos, combinado a que son justamente estos los que en su mayoría son países de climas tropicales, los que presentan mayor cantidad de factores de riesgo para la aparición y avance de queratitis [10]. En alguna parte del mundo como puede ser el sur, este y sud-este asiático la queratitis es considerada una epidemia debido a la gran cantidad de personas afectadas por este cada año [2].

La aplicación nueva técnicas de comunicación y transmisión de datos desde hace años en una parte importante del desarrollo del tratamiento de datos, especialmente dentro del sector salud ya que a podido brindar nuevas herramientas, que han sido ampliamente implementada en diferentes campos como la tomografía computarizada, resonancia magnética y análisis de imágenes patológicas. Las nuevas herramientas disponibles para el procesamiento de información a traído una mayor facilidad con la que se puede trabajar con la información en ambientes digitales, lo que a permitido crear toda una industria en la comercialización de este tipo de tecnologías, la cual ha generado con el paso del tiempo, sistemas para una fácil y estandarizada recolección de datos e imágenes en diferentes instituciones. Cambiando el panorama anterior donde la única información disponible para estudios era la propia recolectada por la institución o individuos interesados en el desarrollo del estudio ha permitido, guardar información de diversas partes del mundo creando, grandes bases de datos las cuales respetando todos los derechos de uso y parámetros éticos puede ser utilizada por diferentes institutos, con la finalidad de desarrollar sus propios estudios [11].

Estas grandes bases de datos ahora pueden ser usadas por campos de inteligencia artificial los cuales, por sus características, tienden a necesitar una gran cantidad de datos para la generación de modelos que cumplan con las expectativas sobre estos, los cuales a pesar de que continúan en surgimiento y que no han dejado de dar nuevos aportes en una amplia cantidad de campos, entre ellos el de la salud en el cual se muestra un gran potencial para su amplia implementación en diferentes campos. Gracias a estas bases de datos se han desarrollado diferentes modelos capaces de detectar la presencia de patologías de interés, como puede ser detección de cáncer en la piel, la cual fue pioneros en la implementación de este tipo de tecnologías en el sector salud [11][12].

Durante los últimos años se ha usado IA para la detección de cáncer en la piel, paros cardiacos y accidente cerebrovascular neuronal demostrando un gran potencial en la predicción y análisis de datos e imágenes. Mientras que en el campo oftalmólogo este tipo de programas ha podido exitosamente detectar degeneraciones en el tejido óptico [1]. Gracias a los últimos avances en inteligencia artificial especialmente en la rama de “*Deep Learning*” se ha observado, la capacidad de este tipo de procesamiento para general buenos resultados en la detección

de patrones específicos en imágenes reemplazando métodos tradicionales de diagnóstico de queratitis principalmente en zonas con baja presencia profesionales cualificados para realizar diagnósticos, se aprecia el impacto que puede tener la aplicación de estas nuevas tecnología [13]. En años recientes se ha visto como cada vez más estudios intentan explotar el potencial de esta tecnología en el campo de diagnóstico automático basado en imágenes [7].

En diferentes estudios han mostrado como se usa inteligencia artificial para la detección de bio-marcadores morfológicos y de reflexión de luz, en imágenes con en luz blanca y luz azul demostrando el potencial de estas herramientas en la detección temprana de queratitis [8]. En el otros estudios se usa aprendizaje profundo para el directo diagnóstico de la enfermedad con el uso de imágenes obtenidas con smartphones en luz blanca, demostrando una vez más las posibilidades del uso de inteligencia artificial para la detección temprana de queratitis [10]. El número creciente de estudios explorando como implementar IA en el diagnostico automático de imágenes muestran la relativa facilidad con la que se pueden generar modelos que logren un impacto en zonas donde, por diversos factores, no se cuenta con todos los medios ideales para continuar con diagnósticos de forma tradicional.

El *Deep Learning* es una rama de la inteligencia artificial la cual, basa la mayor parte de su funcionamiento en redes neuronales convolucionales ya que estas han tenido resultados especialmente sobresalientes en el análisis de imágenes, donde gracias a su predisposición a la simplificación de la información aportada por las imágenes procesadas logra la identificación patrones característicos lo que permite su uso en proyectos de procesamiento automatizado [14].

El *Deep Learning* logra identificar patrones, después de completar algunas fases que le permiten al modelo, predeterminar algunas características los cuales será claves en la búsqueda de patrones visuales específicos, donde se busca que los patrones específicos definidos sean los característicos de la patología que se desea identificar [15].

El proceso para la obtención del modelo comienza con una fase de *“training”* donde se expone una estructura neuronal preestablecida a imágenes previamente catalogadas. La estructura neuronal ya viene con valores predeterminados donde en base a un proceso repetitivo, y las imágenes aportadas, los valores predeterminados de la estructura neuronal cambian, buscando que los nuevos valores ajustados, generen filtros dentro del modelo los cuales sean los ideales para la identificación de los patrones requeridos, donde estos pueden dar como resultado procesos de reflexión, traslación rotación, acercamiento entre otros que facilitan la identificación de los patrones visuales asociados a la patología [15].

Los filtros generados tienen como función la identificación de patrones específicos de diferentes complejidades asociados a la patología, que se tiene como objetivo en el estudio, estos cambios en los valores de la estructura son generalmente hechos de manera aleatoria, por lo que el



de resolución de imágenes, afectando al modelo en gran medida a la predicción que pueda generar el modelo, si no se cuenta con imágenes de calidades similares a las usadas en su entrenamiento . Por otro lado, el hecho de que las mejores redes sean las más grandes, impide que las mejores estructuras sean ampliamente utilizadas [19].

La implementación de este tipo de tecnología, aunque presenta grandes ventajas también presenta varios inconvenientes que se deben tener en cuenta. Los beneficios que una amplia implementación de este tipo de tecnologías, hacen que cada vez existan más proyectos intentando explotar el potencial de esta tecnología. Si se logra una mayor implementación de técnicas basadas en IA para el diagnóstico de queratitis, se abre la posibilidad para redistribuir todo el recurso humano encargado de diagnóstico a tareas que aun esta por fuera del alcance de la IA como pueden ser las intervenciones quirúrgicas, ampliando la oferta de este tipo de procedimientos, y de esta forma facilitando la obtención de estos procedimientos para las personas que lo necesiten y disminuyendo el porcentaje de personas que pueden llegar a perder la vista por queratitis [18].

## **2 OBJETIVOS**

### **2.1. General**

Generar un método basado en aprendizaje profundo para el procesamiento y análisis automático de imágenes oculares para la detección de queratitis.

### **2.2. Específicos**

1. Procesar y analizar imágenes oculares de córnea empleadas para la detección de queratitis.
2. Implementar un mínimo de 3 modelos basados en aprendizaje profundo para la extracción y clasificación de imágenes de córnea.
3. Validar el rendimiento del método comparado con el experto en la predicción de queratitis.

# 3 METODOLOGÍA

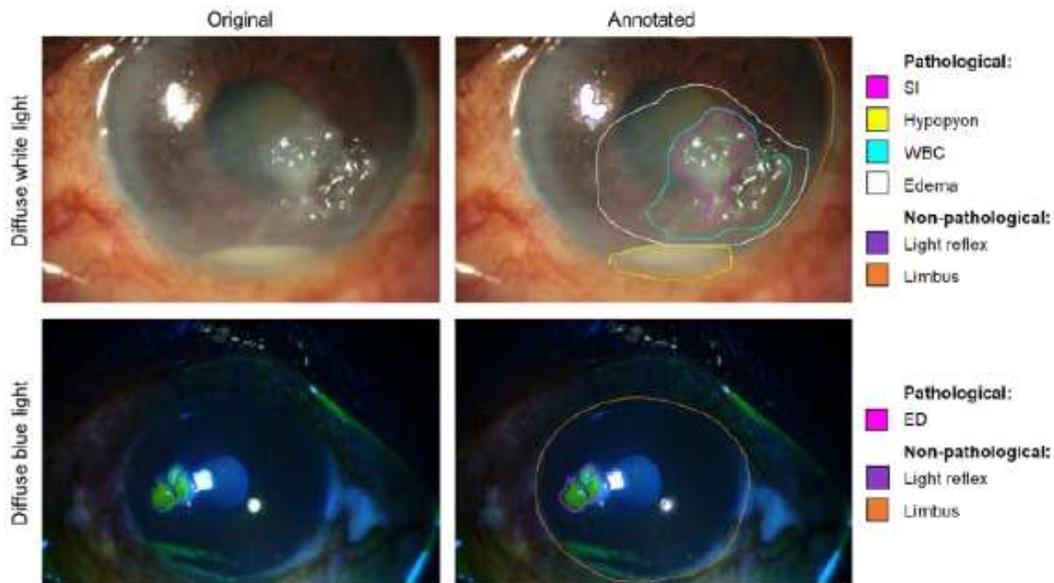
En el presente trabajo, se busca la generación de un método basado en aprendizaje profundo para el procesamiento y análisis automático de imágenes oculares para la detección de Queratitis. La metodología del proyecto está enfocada en tres fases, enfocadas en diferentes conceptos y herramientas, donde cada fase de diferentes se compone de actividades la cuales permitirán el cumplimiento de la fase a desarrollar:

## 3.1. Fase 1: Procesamiento y análisis de imágenes oculares de córnea empleadas para la detección de Queratitis

Una de las principales características de la queratitis es la inflamación en la Córnea, por lo que puede ser identificada de manera visual, dando la oportunidad de ser identificada dicha enfermedad, gracias a la base de datos utilizada la cual consta 132 imágenes de ojos proporcionado por “*the University of Michigan Kellogg Eye Center (MI, USA) and Aravind Eye Care System (Madurai, India)*” generada entre los años 2016 – 2018 [20]. Estas fotografías son de polo anterior, las fotografías del polo anterior de los ojos, las cuales se pueden captar parpados, conjuntiva, cornea iris y cristalino. Las imágenes de los ojos vienen en imágenes con luz blanca y luz azul, donde para el propósito de esta tesis se descarta las imágenes de luz azul que este tipo de luz solo ayudaría a identificar queratitis con un origen concreto, mas no una identificación general de los diferentes tipos de queratitis existentes, según las indicaciones del experto oftalmólogo de la clínica Barraquer. Adicionalmente, la base de datos viene con diferentes mascarar para cada imagen, las cuales contienen diferentes características y bio-marcadores, las cuales pueden indicar la presencia de queratitis o pueden ser interpretados como señales de una alta probabilidad para la presencia de queratitis. Dentro de los factores identificados en las diferentes mascarar se encuentran:

- *Stromal Infiltrate* (SI): esta condición es una reacción inflamatoria con infiltrados que ocurren en el estroma anterior.
- *Epithelial Defect* (ED): son áreas focales de pérdida epitelial (capa corneal más externa)

- *Accumulation of White Blood Cells* (WBCs): puede ser una respuesta normal del sistema inmunitario, y puede servir como indicador de inflamaciones e infecciones.
- *Corneal Swelling* (CS - corneal edema): acumulación de líquido en la córnea.



**Figura 3-1:** Imagen de los diferentes bio-marcadores presentes en la base de datos [2]

Aunque la base de datos contiene, diferentes mascarar para cada imagen marcada con un número, en ninguna parte de la base de datos de asocia la el numero presente en la máscara a alguno de los factores de riesgo mencionados previamente. Por recomendación del experto oftalmólogo de la Clínica Barraquer este creo unas nuevas máscaras de manera manual, con ayuda del programa *labelbox* para cada una de las 132 imágenes de luz blanca, presentes en la base de datos. Para lo cual primero se estandarizo el formato de las imágenes en formato “.png” con el objetivo de poder usar el programa *labelbox* sin ningún inconveniente. Esta estandarización además facilitara el uso de estas imágenes, en procesos de aprendizaje profundo.

### 3.2. Fase 2: Implementación de modelos basados en aprendizaje profundo para la extracción y clasificación de imágenes de ojos.

Una vez obtenidas las imágenes y sus máscaras correspondientes a la identificación de factores de riesgo en cada una de ellas se identificó un total de 130 imágenes con presencia de queratitis

y 3 imágenes sin presencia de queratitis. Debido a la gran cantidad de imágenes con presencia de queratitis sobre, las que no tienen presencia de queratitis, se optó por únicamente la aplicación de modelos de segmentación sobre, modelos de clasificación. Se catalogó como ojo sin presencia de queratitis cuando la máscara resultante del modelo de Deep Learning proporcionara una imagen totalmente negra, al no identificar ninguna estructura asociada a la presencia de queratitis. Se entrenarán diferentes modelos variando los parámetros de:

- Tasa de Aprendizaje
- Número de Épocas
- Tamaño del Batch

Se escoge variar estos parámetros ya que según diferentes estudios estos permiten, realizar una mejor generalización por parte de los modelos entrenados[21].

### **3.3. Fase 3: Selección del mejor modelo obtenido según los criterios evaluados y la visualización cómoda de los resultados del análisis de la imágenes evaluadas.**

Una vez entrenados diferentes modelos de basados en aprendizaje profundo se analizará sus métricas estadísticas, las cuales serán:

- Precisión
- Pérdida
- Índice jaccard

Se usa la precisión y perdida para evaluar la red ya que por medio de estas métricas ya que son las que reflejan con mayor fidelidad el desempeño del modelo[16]. Mientras que por otro lado el índice Jaccard son ayuda para medir de forma cuantitativa la similitud entre dos imágenes, siendo un valor de 1 cuando son imágenes idénticas y disminuye a medida que sean más diferentes, ideal para evaluar el desempeño de las máscaras generadas[22].

Posterior a esto se identificará cuál de los modelos presenta los mejores resultados, en la predicción de la presencia de queratitis en las imágenes analizadas, y se seleccionará una única estructura como resultado de esta tesis, para la cual se pueda visualizar de manera sencilla un porcentaje asociado a la probabilidad de Queratitis en la imagen analizada.

## 4 RESULTADOS

### 4.1. Resultados estadísticos de los modelos generados

La base de datos definida en la sección 3 es dividida en dos grupos de forma aleatoria, donde 125 imágenes serán usadas para la fase de entrenamiento de los modelos. Allí se emplearán 113 directamente para el entrenamiento del modelo, siendo usadas para variar los parámetros internos de las redes neuronales y las 12 restante para validar el modelo al calcular parámetro de *accuracy* y *loss* al final de cada época. Finalmente, las 7 imágenes restantes serán usadas en el conjunto de prueba para comparar los resultados entre los diferentes modelos.

Estos grupos dividieron de esa forma debido a la pequeña cantidad de imágenes disponibles para el desarrollo de esta tesis, dándole aproximadamente el 95 % correspondiente a 125 a la fase de training, dándole mayor posibilidad a los modelos de generar buenas generalizaciones, grupo al que posteriormente se le asignó el 1 % correspondiente a 12 imágenes del grupo de training a el subgrupo de training-validación. Dejando un total de 113 imágenes en grupo training-aprendizaje[16][21].

Numero de imágenes total	132
imágenes test	7
imágenes training	125
imágenes training-aprendizaje	113
imágenes training-validacion	12

**Tabla 4-1:** Representación de los conjuntos y sub-conjuntos generados

Durante la tarea de entrenamiento de los modelos para la segmentación automática de lesiones relacionadas con Queratitis, se exploraron sistemáticamente diferentes configuraciones con una tasa de aprendizaje fija y variando los hiper-parámetros de:

- Tamaño de Batch.
- Número de épocas.

A continuación, en las tablas 4-2 - 4-7 se presentan los 7 mejores modelos propuestos para segmentación de lesiones de Queratitis con sus hiper-parámetros durante el entrenamiento como:

Modelo	Numero de épocas	Tamaño de Batch
Modelo 1	67	4
Modelo 2	72	3
Modelo 3	64	2
Modelo 4	70	2
Modelo 5	80	2
Modelo 6	90	2
Modelo 7	100	2

**Tabla 4-2:** Modelos propuestos y sus parámetros con los mejores resultados obtenidos durante entrenamiento

La generación de los modelos por un lado se con un numero de exploración de *batch size* entre 4 y 2 para los 3 primeros modelos, donde se vio como el modelo con 2 lograba una mejor aproximación a valores de perdida bajos, donde debido a el costo computacional, se detuvo el entrenamiento cuando ya no presentaba ninguna mejora en más de 10 épocas. Posterior a esto de realizo una exploración de diferentes épocas con *batch size* de 2, dando como resultado 7 modelos generados.

Modelo	Índice Jaccard promedio en entrenamiento	Índice Jaccard promedio en prueba
Modelo 1	0.526	0.367
Modelo 2	0.594	0.341
Modelo 3	0.563	0.337
Modelo 4	0.517	0.359
Modelo 5	0.639	0.288
Modelo 6	0.588	0.316
Modelo 7	0.467	0.301

**Tabla 4-3:** Índice Jaccard obtenido en los 7 modelos propuestos

A continuación, se muestran 5 puntajes de diferentes modelos, mostrando su peor y mejor desempeño en diferentes imágenes, cada puntaje hace referencia a una imagen evaluada a la cual se le saca el índice Jaccard, y no están relacionados entre sí. Los puntajes solo están enumerados para dar orden, y poder referenciar cualquier puntaje en específico de ser necesario.

si el puntaje es 0 significa que no hay similitud entre las imágenes generadas y las esperadas, y 1 que las dos imágenes anteriormente dichas son idénticas.

Modelo	Puntaje 1	Puntaje 2	Puntaje 3	Puntaje 4	Puntaje 5
Modelo 1	0	0	0	0.002	0.007
Modelo 2	0	0	0.022	0.035	0.050
Modelo 3	0	0	0	0	0
Modelo 4	0	0	0	0	0
Modelo 5	0	0	0.021	0.084	0.084
Modelo 6	0	0	0.113	0.124	0.139
Modelo 7	0	0	0	0.0282	0.068

**Tabla 4-4:** Los 5 índices de Jaccard más bajos de cada modelo en entrenamiento

Modelo	Puntaje 1	Puntaje 2	Puntaje 3	Puntaje 4	Puntaje 5
Modelo 1	0.897	0.873	0.866	0.850	0.842
Modelo 2	0.895	0.885	0.884	0.872	0.858
Modelo 3	0.908	0.904	0.890	0.880	0.876
Modelo 4	0.876	0.876	0.875	0.840	0.836
Modelo 5	0.922	0.901	0.886	0.886	0.879
Modelo 6	0.928	0.875	0.874	0.864	0.863
Modelo 7	0.858	0.845	0.832	0.831	0.785

**Tabla 4-5:** Los 5 índices de Jaccard más altos de cada modelo en entrenamiento

Modelo	Puntaje 1	Puntaje 2	Puntaje 3	Puntaje 4
Modelo 1	0	0	0.183	0.327
Modelo 2	0	1.57e-04	1.339e-01	3.086e-01
Modelo 3	0	0.049	0.163	0.327
Modelo 4	0	0	0.132	0.289
Modelo 5	0	0	0.083	0.383
Modelo 6	0	0.015	0.134	0.354
Modelo 7	0	0.0036	0.115	0.199

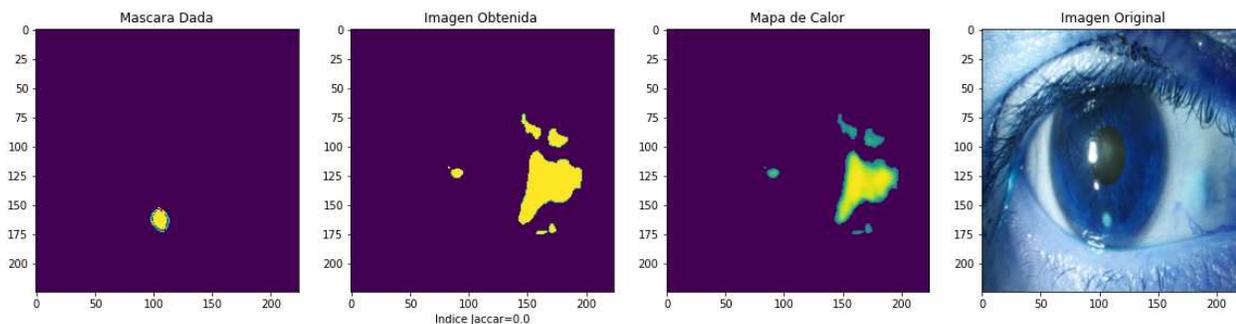
**Tabla 4-6:** Los 5 índices de Jaccard más bajos de cada modelo en el conjunto de prueba

Modelo	Puntaje 1	Puntaje 2	Puntaje 3	Puntaje 4
Modelo 1	0.772	0.752	0.611	0.327
Modelo 2	6.963e-01	6.305e-01	6.204e-01	3.086e-01
Modelo 3	0.667	0.593	0.561	0.327
Modelo 4	0.736	0.710	0.647	0.289
Modelo 5	0.644	0.496	0.412	0.383
Modelo 6	0.672	0.541	0.495	0.354
Modelo 7	0.644	0.587	0.560	0.200

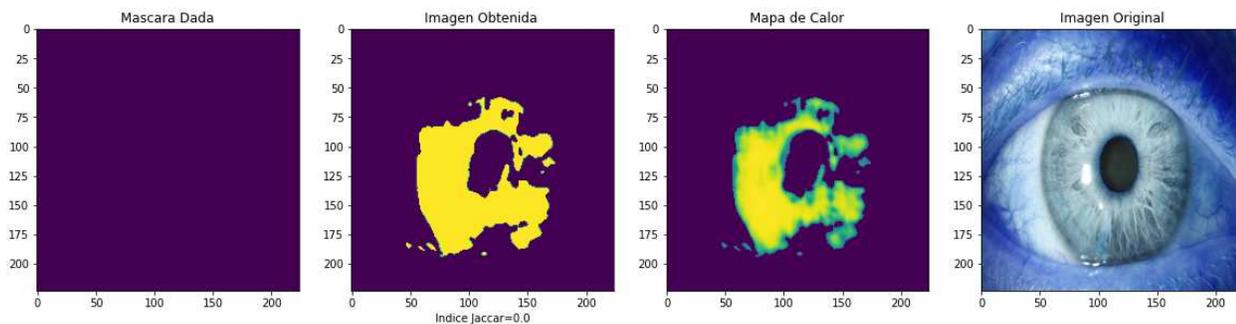
**Tabla 4-7:** Los 5 índices de Jaccard más altos de cada modelo en el conjunto de prueba

## 4.2. Análisis cualitativo de los resultados obtenidos

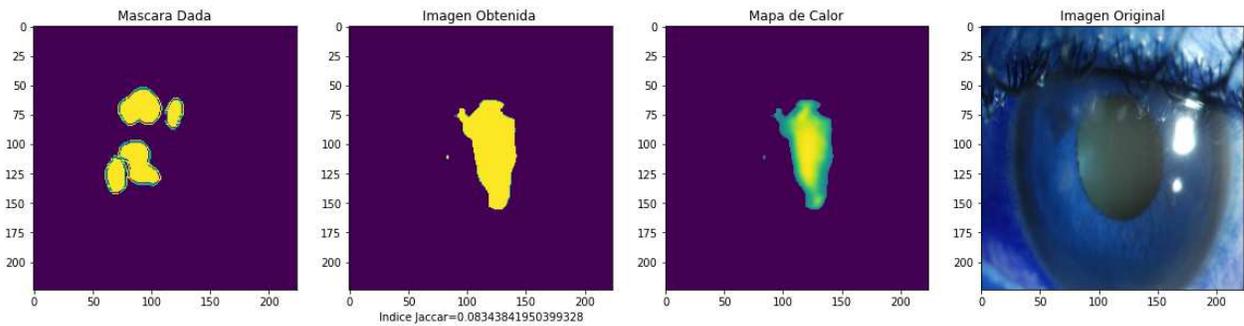
En esta subsección se reporta un análisis cualitativo de las 7 imágenes del conjunto de test. Este análisis fue desarrollado en conjunto con expertos de la Clínica Barraquer.



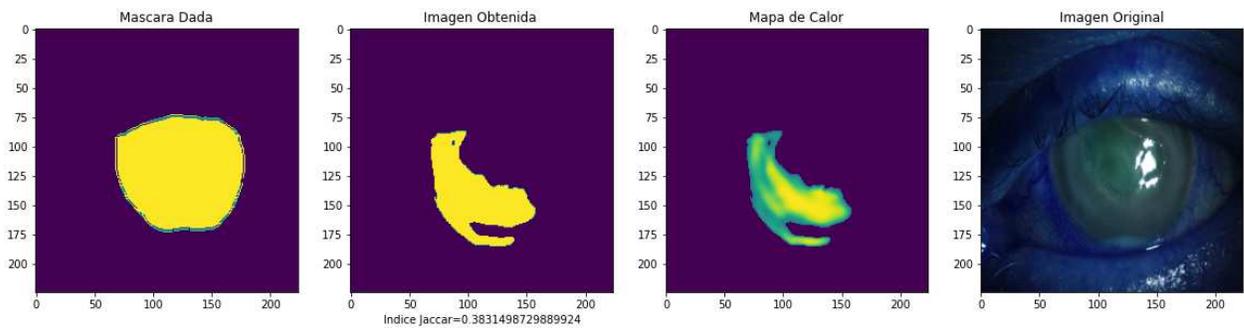
**Figura 4-1:** Resultados de imagen 1 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada



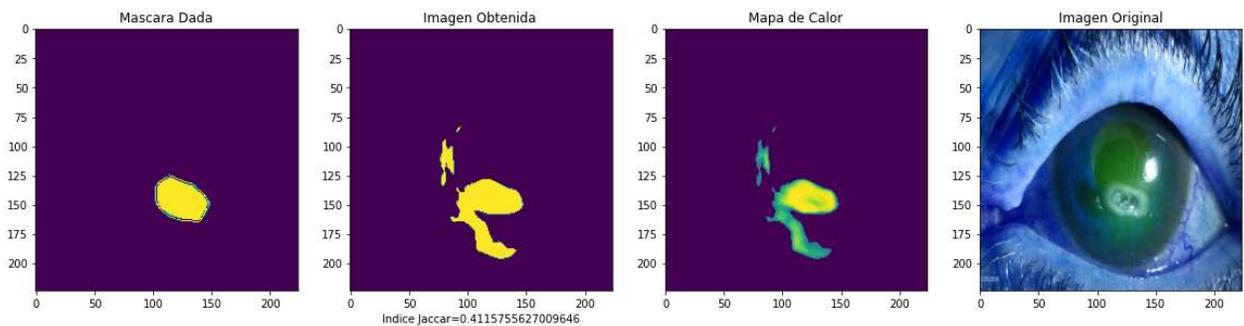
**Figura 4-2:** Resultados de imagen 2 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada



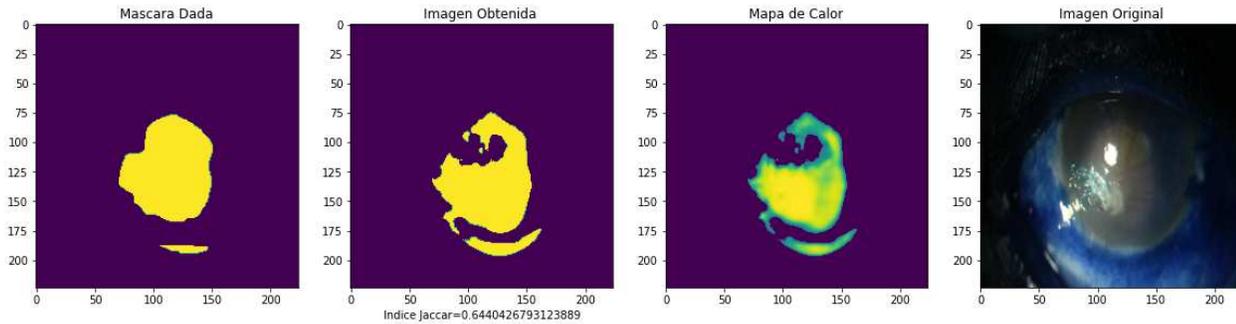
**Figura 4-3:** Resultados de imagen 3 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada



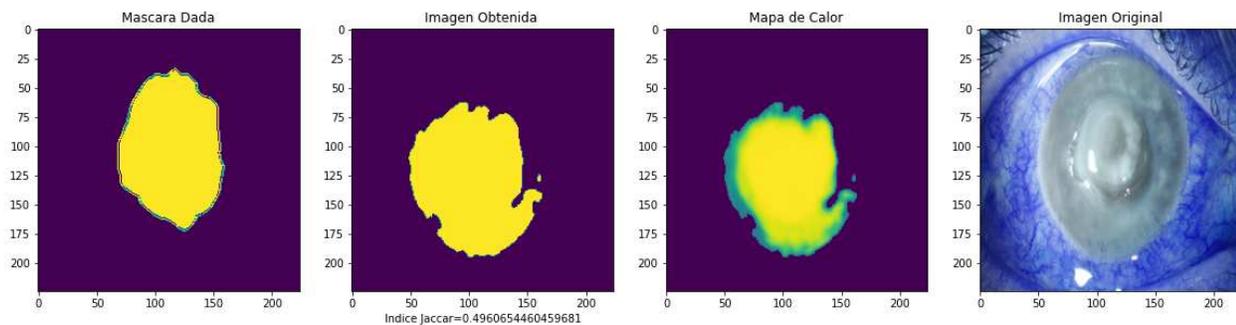
**Figura 4-4:** Resultados de imagen 4 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada



**Figura 4-5:** Resultados de imagen 5 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada

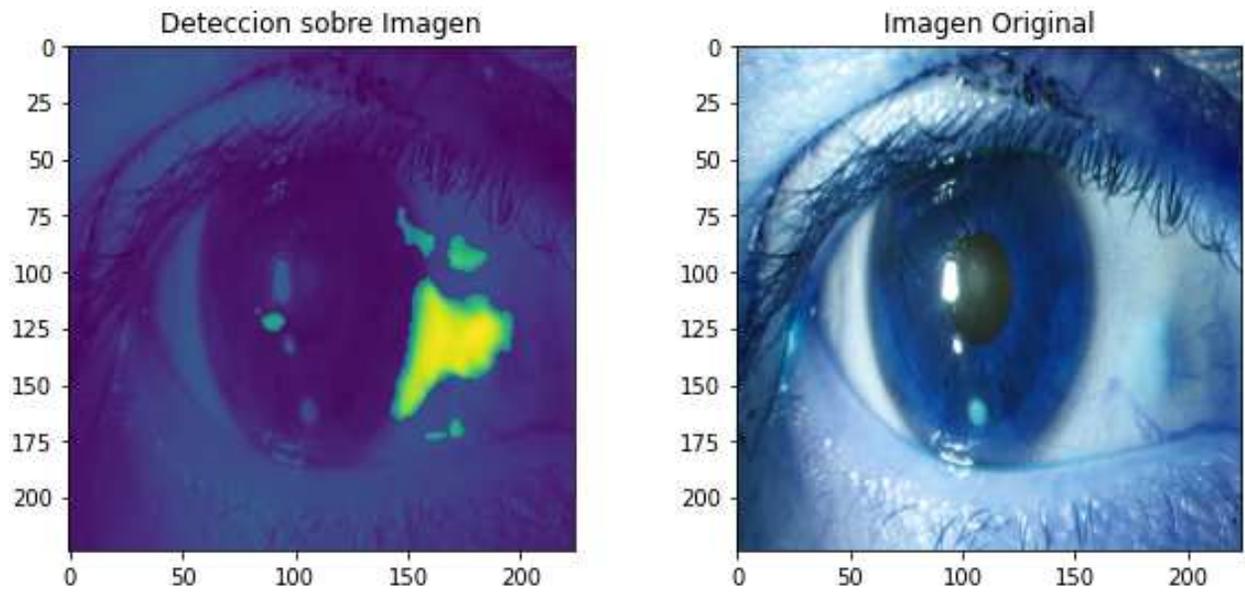


**Figura 4-6:** Resultados de imagen 6 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada

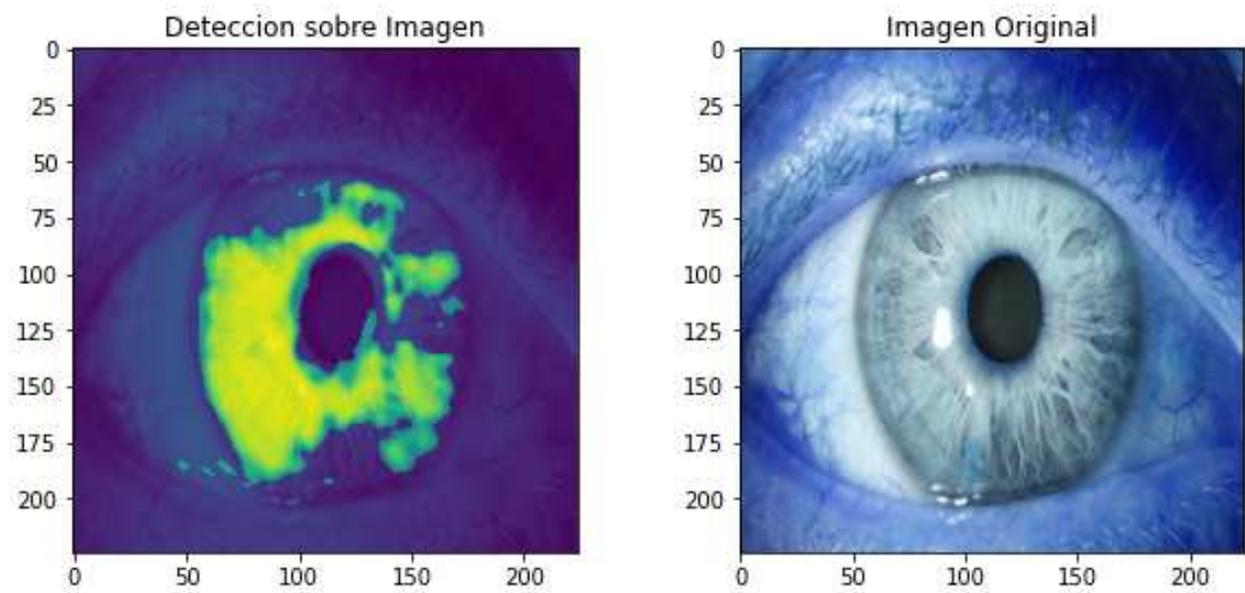


**Figura 4-7:** Resultados de imagen 7 de test en modelo 5, mascara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada

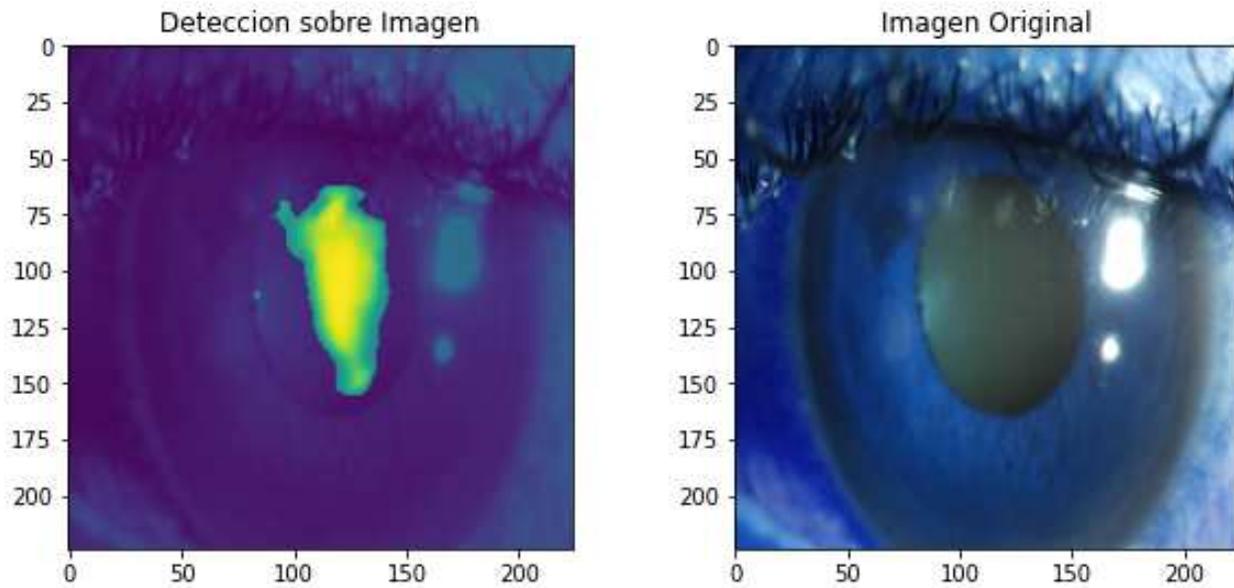
Por otro lado, con ayuda de los expertos de la Clínica Barraquer se procedió a evaluar si la detección realizada concuerda con otras lesiones no segmentadas de la base de datos o corresponde a problemas en la iluminación de las imágenes o ruidos de artefactos. Las siguientes figuras presentan la ubicación de la detección y la imagen original en formato RGB.



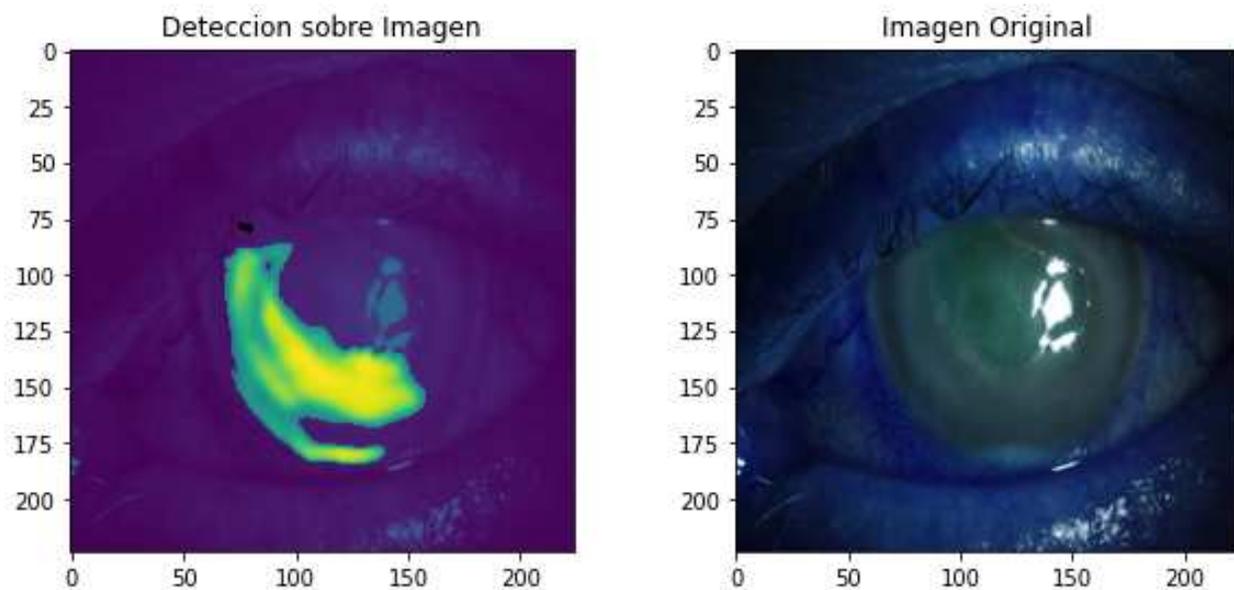
**Figura 4-8:** Resultados finales del modelo en imagen 1, imagen analizada con mapa de calor, imagen original



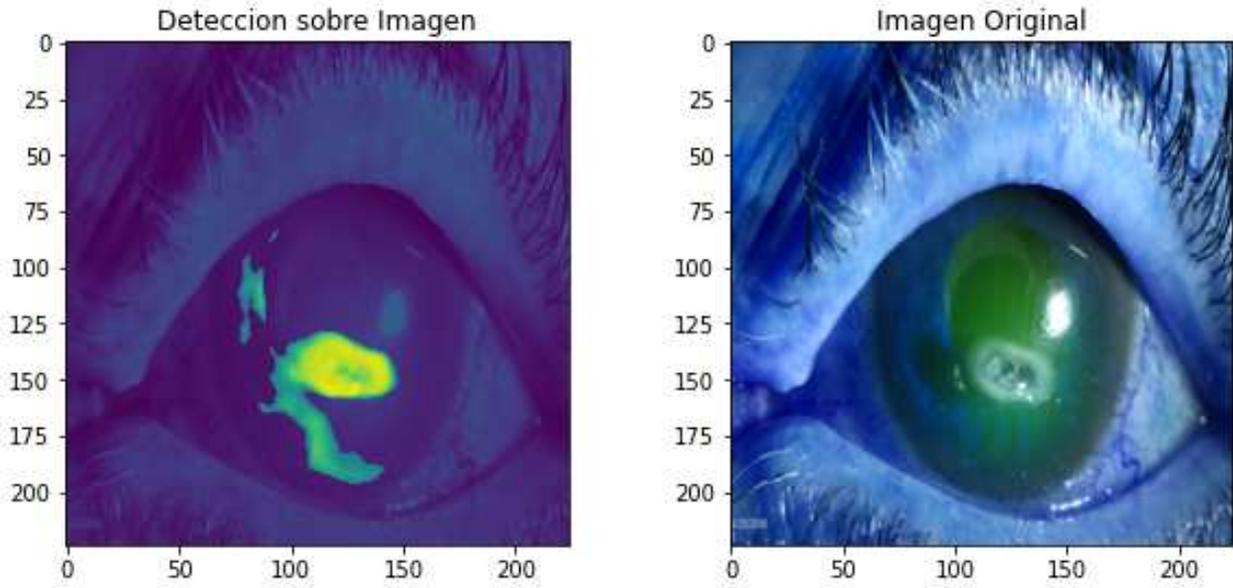
**Figura 4-9:** Resultados finales del modelo en imagen 2, imagen analizada con mapa de calor, imagen original



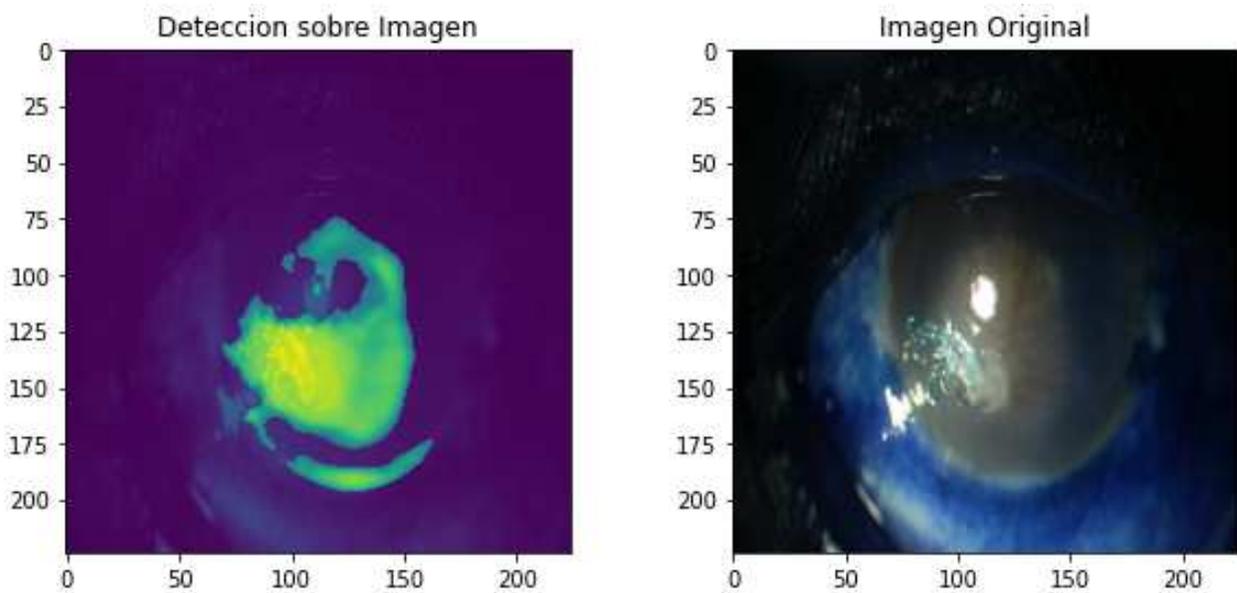
**Figura 4-10:** Resultados finales del modelo en imagen 3, imagen analizada con mapa de calor, imagen original



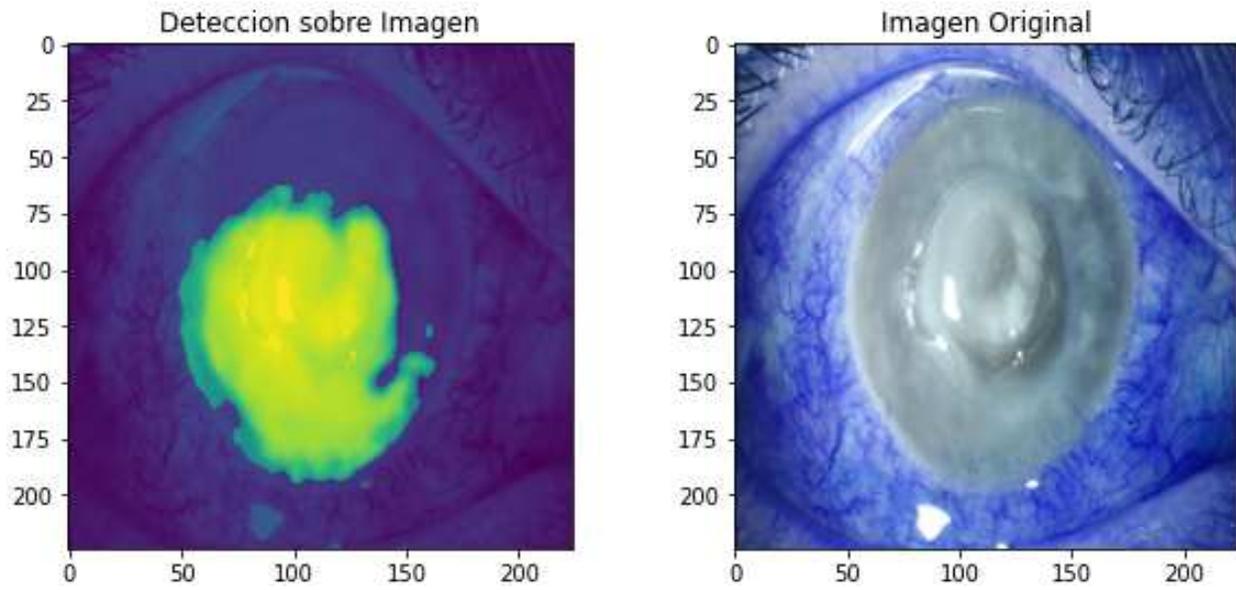
**Figura 4-11:** Resultados finales del modelo en imagen 4, imagen analizada con mapa de calor, imagen original



**Figura 4-12:** Resultados finales del modelo en imagen 5, imagen analizada con mapa de calor, imagen original



**Figura 4-13:** Resultados finales del modelo en imagen 6, imagen analizada con mapa de calor, imagen original



**Figura 4-14:** Resultados finales del modelo en imagen 7, imagen analizada con mapa de calor, imagen original

## 5 DISCUSIÓN

Los modelos presentados en este trabajo dirigido tienen la habilidad de procesar automáticamente una imagen de polo posterior del ojo como entrada, y realizar un análisis basado en modelos de aprendizaje profundo, dando como resultado una imagen blanco y negro o mapa de calor, la cual resalta las zonas identificadas como de interés, como se presentó en las figuras **4-8** - **4-14**.

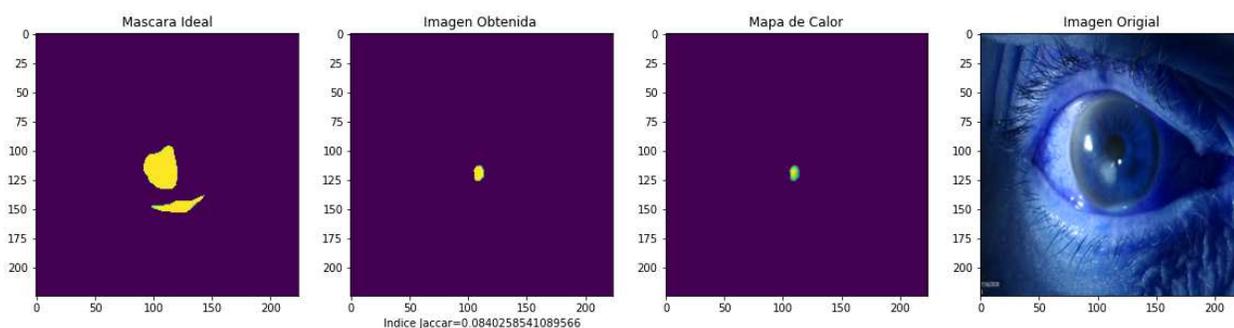
Las imágenes resultantes presentadas en las figuras **4-1** - **4-7**, son útiles para que los oftalmólogos puedan evidenciar la localización de la lesión comparada con la imagen original. Además, se presenta un mapa de calor, el cual no solo ayuda a señalar los lugares con posibilidad de presencia de queratitis, sino una vez identificada la zona, marca con color verde las zonas que presentan características con queratitis, pero con menor posibilidad de su presencia, y de un color amarillo más marcado fuerte, las zonas con mayores posibilidades de presencia de queratitis dentro de la zona previamente marcadas.

Al analizar las zonas marcadas como con presencia de queratitis en ningún momento el modelo tiende a segmentar partes del ojo como el iris, por lo que se hipotetiza que los modelos entrenados no detectan estructuras diferentes para las que fueron entrenados, como las lesiones debido a queratitis, y de igual manera los modelos también muestran una capacidad para ignorar el color más oscuro presente en la pupila, o su cambio de todo con respecto al iris, por lo que también se deduce que para la identificación de queratitis, no solo tiene en cuenta la presencia de bordes, además la presencia de los reflejos presentes en la mayoría de las imágenes procesadas tampoco muestran un mayor inconveniente para el diagnóstico automático .

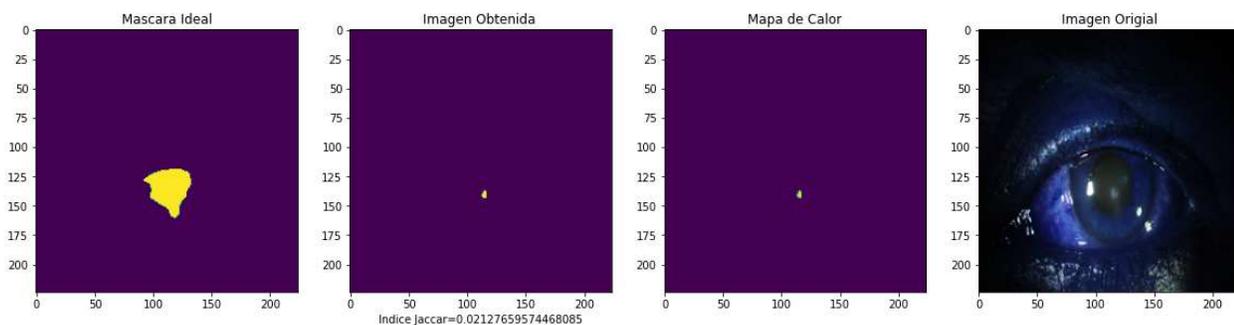
Estos modelos son una herramienta potencial que pueden ayudar a los expertos en la toma de decisiones con respecto a la presencia de queratitis, ya que logra identificar diferentes zonas donde se identifican como de alta probabilidad de presencia de queratitis. En el caso de que no se identifique ninguna estructura en la imagen analizada como posible zona con presencia de queratitis la imagen se catalogara como imagen control o sin queratitis.

Al analizar los resultados de la tabla **4-3**, podemos comparar el promedio del Índice Jaccard para las imágenes procesadas tanto en el conjunto de entrenamiento, como en el conjunto de prueba. Por otro lado, no se logra identificar un modelo sobresaliente con respecto a

los otros, según sus resultados. El índice Jaccard es uno de los principales datos que se usaron para juzgar el rendimiento de los modelos generados en esta tesis, el cual puede dar un puntaje teniendo en cuenta la similitud entre dos imágenes, esto es de utilidad ya que se puede comparar los resultados obtenidos con las imágenes suministradas por el experto, dando como resultado un valor cuantitativo sobre la similitud entre el resultado esperado, y el generado por el modelo.

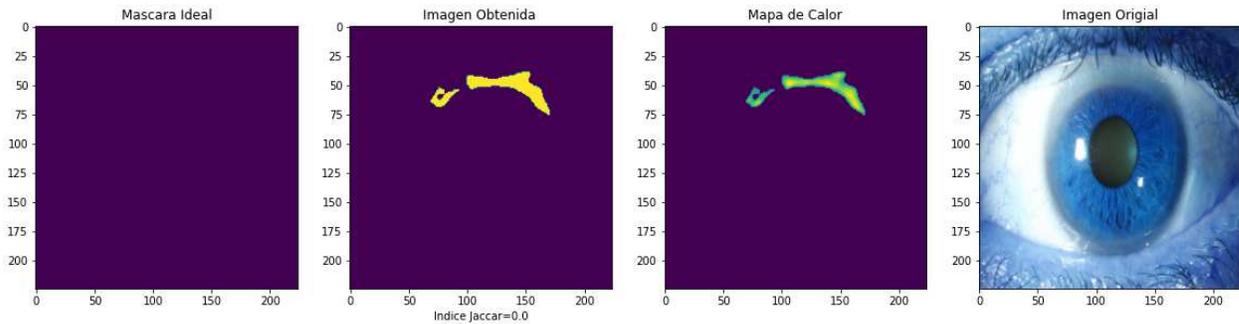


**Figura 5-1:** Imagen de training en modelo 5, máscara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada



**Figura 5-2:** Imagen de training en modelo 5, máscara generada ideal, máscara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada

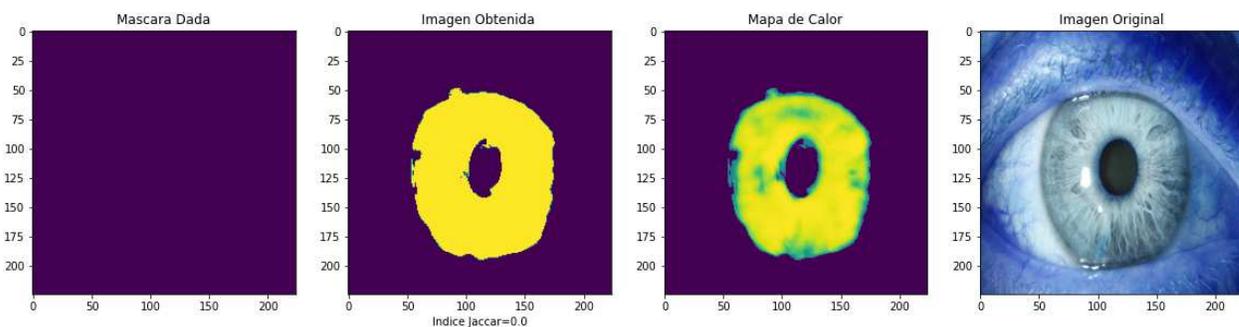
Lamentablemente basados en la segmentación se evidencia que no se logra detectar de forma correcta la lesión, como se puede ver en las figuras 5-1 y 5-2. La métrica de desempeño en segmentación, al no lograr una marcación toda la estructura identificada por la máscara ideal, hace que su puntaje Jaccard este en 0.084 el cual es supremamente bajo, y afecta la apreciación del rendimiento del modelo en su promedio, situación que se repite en varias imágenes en los diferentes modelos. Sin embargo, usando nuestro modelo de segmentación, como un modelo de detección, este sería un acierto o verdadero positivo.



**Figura 5-3:** Imagen de training en modelo 5, mascara generada ideal, mascara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada

Otro inconveniente en la apreciación del rendimiento del modelo, evidenciado en la figura 5-3 donde el modelo identifica una cicatriz en el tejido ocular, señalado por el experto, la cual es identificado como queratitis, generando un diagnóstico erróneo, pero mostrando el potencial del modelo para la identificación de estructuras “anormales” de manera general sobre el tejido ocular.

Uno de los problemas más importantes a tener en cuenta durante el desarrollo de la tesis fue la sobre representación de las imágenes “con queratitis” sobre las “sin queratitis”. Este problema se debe a la dificultad, en la obtención de estas imágenes debido a el dolor o incomodidad que puede generar la toma de imágenes en las personas que presenten esta enfermedad, por lo que la generación de bases de datos de esta enfermedad, son bastante escasos, y en la mayoría no son de libre uso. Por lo que se plantea el uso de una base de datos adicional, con el objetivo de tener más datos en la selección de un modelo final. Ya que se requieren más imágenes, debido a que solo se usaron 7 imágenes en la fase de test, limitando la posibilidad de algún modelo para mostrar la generalización que puede llegar a presentar, dando la posibilidad a algún modelo evaluado a destacarse en este aspecto, reflejado en un puntaje Jaccard promedio mayor.



**Figura 5-4:** Imagen sana de test en modelo 2, mascara generada ideal, mascara generada por el modelo, mapa de calor generado por el modelo, imagen original analizada

Adicionalmente se ve una asociación constante en todos los modelos, en la asociación de la presencia del color gris y la presencia de queratitis, asociación ejemplificada de manera más clara en la figura **5-3**, ya que la imagen es la única imagen sana disponible para su uso en la fase de test, donde esta es de ojos de color gris, encerrando toda el iris, sin segmentar la pupila.

Por último, los modelos obtenidos que, aunque como objetivo principal busca la detección de queratitis en las imágenes analizadas, también logra identificar estructuras “anormales” en el ojo, como pueden ser la presencia de cicatrices sobre este, por lo que muestra su potencial uso, en la identificación de otras patologías oculares, que se caractericen por la aparición de estructuras o malformaciones en el tejido ocular.

## 6 CONCLUSIONES

A continuación, listamos las conclusiones obtenidas a lo largo del desarrollo de este trabajo dirigido.

- El uso de modelos de inteligencia artificial, en específico modelos basados en aprendizaje profundo, ayudan en la segmentación y detección automática de Queratitis usando imágenes de polo posterior del ojo.
- El entrenamiento de los modelos requieren un número extensivo de imágenes para obtener métricas de desempeño considerables. En nuestros experimentos, evaluamos el desempeño de estos modelos con un número reducido de imágenes para entrenamiento. A pesar de los buenos resultados obtenidos, limitamos bastante el número de imágenes del conjunto de prueba, dificultando la capacidad para generalizar de los modelos con imágenes heterogéneas al conjunto de entrenamiento.
- Una baja cantidad de imágenes en el conjunto de validación puede dificultar la correcta evaluación de la capacidad para generalizar de los modelos generados, aspecto más importante buscado en los modelos propuestos en este trabajo dirigido.
- Aunque el índice Jaccard sirve para cuantificar la similitud entre dos imágenes, es un parámetro que aun presenta varios inconvenientes, en la estimación de la confiabilidad de la predicción para los modelos presentados en esta tesis, en especial cuando las imágenes presentan problemas de iluminación u otros ruidos asociados a una mala adquisición de las imágenes.

## 7 TRABAJOS FUTUROS

En primera instancia quiere adquirir una base de datos adicional para lograr una evolución de los modelos generados en esta tesis, buscado uno que sobresalga, para usarlo como base en trabajos adicionales.

Se señala que los modelos generados en esta tesis logran realizar una segmentación de zonas de interés por lo que, una vez establecido la zona posiblemente afectada, se puede usar un modelo como base para la continuación del diagnóstico automático de queratitis, ya que una vez identificada la zona con presencia de queratitis se puede, eliminar el resto de las zonas de no interés. Posterior a esto se puede realizar un estudio ahora enfocado en la identificación del origen de la queratitis segmentado, sea de origen bacteriana, viral o por hongos, esta vez con la ayuda de una base de datos más específica, con el objetivo final de facilitar aún más el diagnóstico temprano de queratitis y así el comienzo de un tratamiento lo más pronto posible, evitando de esta manera todas las consecuencias que puede traer esta enfermedad por un la falta de un diagnóstico y la demora en el comienzo de un tratamiento adecuado en contra de esta patología.

Como se mencionó anteriormente los modelos actuales ya presentan una predisposición a no solo a la identificación de queratitis, y estructuras anormales, como se comprobó con una imagen con una cicatriz, por lo que se puede usar estos modelos en la búsqueda de otras patologías oculares que también se manifiesten de manera fisiológica.

# Bibliografía

- [1] Mo Tiwari, Chris Piech, Medina Baitemirova, Namperumalsamy V Prajna, Muthiah Srinivasan, Prajna Lalitha, Natacha Villegas, Niranjana Balachandar, Janice T Chua, Travis Redd, et al. Differentiation of active corneal infections from healed scars using deep learning. *Ophthalmology*, 2021.
- [2] Ning Hung, Andy Kuan-Yu Shih, Chihung Lin, Ming-Tse Kuo, Yih-Shiou Hwang, Wei-Chi Wu, Chang-Fu Kuo, Eugene Yu-Chuan Kang, and Ching-Hsi Hsiao. Using slit-lamp images for deep learning-based identification of bacterial and fungal keratitis: Model development and validation with different convolutional neural networks. *Diagnostics*, 11(7):1246, 2021.
- [3] Richard A White Jennifer L Smith Seth R Flaxman Holly Price Jost B Jonas Jill Keeffe e† Janet Leasher† Kovin Naidoo† Konrad Pesudovs† Serge Resnikoff † Hugh R Taylor† Rupert R A Bourne\*, Gretchen A Stevens\*. Causes of vision loss worldwide, 1990–2010: a systematic analysis. *The lancet global health*, 1(6):339–349, 2013.
- [4] Shelda Sajeev and Mallika Prem Senthil. Classifying infective keratitis using a deep learning approach. In *2021 Australasian Computer Science Week Multiconference*, pages 1–4, 2021.
- [5] Mary E. Benton, Angela H.; Marquart. The role of pneumococcal virulence factors in ocular infectious diseases. *Archives of Ophthalmology*,, 101(10):1545–1548, 1983.
- [6] Eric M. Kidd<sup>3</sup> M. Srinivasan<sup>4</sup> Namperumalsamy V. Prajna<sup>4</sup> Nisha Acharya<sup>2</sup> Thomas Lietman<sup>2</sup> Christine M. Toutain-Kidd<sup>1</sup>, Travis C. Porco<sup>2</sup> and Michael E. Zegans<sup>1</sup>. Evaluation of fungal keratitis using a newly developed computer program, optscore, for grading digital corneal photographs. *Ophthalmic Epidemiology*, 21(1):24–32, 2014.
- [7] Po-Ying Wu, Huai-Wen Chang, and Wei-Li Chen. Neurotrophic keratitis in autoimmune polyglandular syndrome type 1: a case report. *BMC ophthalmology*, 21(1):1–6, 2021.
- [8] Jessica Loo, Matthias F Kriegel, Megan M Tuohy, Kyeong Hwan Kim, Venkatesh Prajna, Maria A Woodward, and Sina Farsiu. Open-source automatic segmentation of ocular structures and biomarkers of microbial keratitis on slit-lamp photography images

- using deep learning. *IEEE journal of biomedical and health informatics*, 25(1):88–99, 2020.
- [9] \* Marcel Belloso MD \* Thomas C. Prager PhD MPH † Mark C. Vital, MD and MD\* Jeffrey D. Lanier. Classifying the severity of corneal ulcers by using the “1, 2, 3” rule. *Cornea*, 26(5):16–20, 2007.
- [10] Zhongwen Li, Jiewei Jiang, Kuan Chen, Qianqian Chen, Qinxiang Zheng, Xiaotian Liu, Hongfei Weng, Shanjun Wu, and Wei Chen. Preventing corneal blindness caused by keratitis using artificial intelligence. *Nature Communications*, 12(1):1–12, 2021.
- [11] Yesheng Xu, Ming Kong, Wenjia Xie, Runping Duan, Zhengqing Fang, Yuxiao Lin, Qiang Zhu, Siliang Tang, Fei Wu, and Yu-Feng Yao. Deep sequential feature learning in clinical image classification of infectious keratitis. *Engineering*, 2020.
- [12] Ross Girshick Shaoqing Ren, Kaiming He and Jian Sun. Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, pages 91–99, 2015.
- [13] Jiayu Hong, Xiaoqing Liu, Youwen Guo, Hao Gu, Lei Gu, Jianjiang Xu, Yi Lu, Xinghuai Sun, Zhengqiang Ye, Jian Liu, et al. A novel hierarchical deep learning framework for diagnosing multiple visual impairment diseases in the clinical environment. *Frontiers in Medicine*, 8, 2021.
- [14] Hao Gu, Youwen Guo, Lei Gu, Anji Wei, Shirong Xie, Zhengqiang Ye, Jianjiang Xu, Xingtao Zhou, Yi Lu, Xiaoqing Liu, et al. Deep learning for identifying corneal diseases from ocular surface slit-lamp photographs. *Scientific reports*, 10(1):1–11, 2020.
- [15] Xinming Zhang, Gang Ding, Chi Gao, Chao Li, Bingliang Hu, Chenming Zhang, and Quan Wang. Deep learning for three types of keratitis classification based on confocal microscopy images. In *Proceedings of the 2020 3rd International Conference on Signal Processing and Machine Learning*, pages 91–97, 2020.
- [16] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT press, 2016.
- [17] Glen Bennet Hermon and Durgansh Sharma. Unique lion identification using triplet loss and siamese networks. *Rev. d’Intelligence Artif.*, 34(6):693–700, 2020.
- [18] Radhika Rampat, Rashmi Deshmukh, Xin Chen, Daniel SW Ting, Dalia G Said, Harminder S Dua, and Darren SJ Ting. Artificial intelligence in cornea, refractive surgery, and cataract: Basic principles, clinical applications, and future directions. *Asia-Pacific journal of ophthalmology (Philadelphia, Pa.)*, 10(3):268, 2021.

- 
- [19] Darren Shu Jeng Ting, Valencia HX Foo, Lily Wei Yun Yang, Josh Tjunrong Sia, Marcus Ang, Haotian Lin, James Chodosh, Jodhbir S Mehta, and Daniel Shu Wei Ting. Artificial intelligence for anterior segment diseases: emerging applications in ophthalmology. *British Journal of Ophthalmology*, 105(2):158–168, 2021.
- [20] J. Loo. Slit-net. <https://github.com/jessicaloohw/SLIT-Net>, 2021.
- [21] Fengxiang He Tongliang Liu Dacheng Tao. Control batch size and learning rate to generalize well: Theoretical and empirical evidence.
- [22] Robert K. Colwell Tsung-Jen Shen Anne Chao, Robin L. Chazdon. Un nuevo método estadístico para la evaluación de la similitud en la composición de especies con datos de incidencia y abundancia\*. *Ecology Letters*, 8:148–159, 2004.