



UNIVERSITAT POLITÈCNICA DE CATALUNYA
BARCELONATECH
Escola d'Enginyeria de Barcelona Est

TRABAJO DE FINAL DE GRADO

Grado en Ingeniería en Ingeniería Biomédica

**USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL PARA LA
OPTIMIZACIÓN DE LA POTENCIA DE LENTES
INTRAOCULARES PARA PACIENTES QUE SUFREN
CATARATAS**



Memoria y Anexos

Autor/a: CLAUDIA HIGUERO MORALES
Director/a: EDUARDO SOUDAH PRIETO
Co-Director/a: Nombre del/de la Co-Director/a (si existe)
Ponente: Sólo si el Director/a no es profesor/a de la Escuela
Convocatoria: JUNIO 2021

Resumen

En este proyecto se pretende crear una red neuronal que optimice la posición de la lente efectiva en las operaciones de cataratas. Hoy en día para intentar averiguar la posición efectiva de la lente se siguen utilizando fórmulas creadas en los años 70 basadas en la potencia de la lente intraocular.

El objetivo principal de este trabajo ha consistido en calcular la posición efectiva de la lente usando redes neuronales. Para ello, hemos realizado comparaciones estadísticas entre una fórmula de tercera generación, Hoffer Q, que usa principalmente la longitud axial y la profundidad de la cámara anterior pre-cirugía, y varios tipos de redes neuronales creadas a partir de diferentes entradas.

Los resultados obtenidos no han sido del todo satisfactorios, ya que se han encontrado unas tasas de error bastante altas para el objetivo buscado. Aún así, este estudio supone un avance respecto a lo anteriormente establecido porque no se había llevado a cabo el uso de técnicas de inteligencia artificial para averiguar la posición efectiva de la lente (ELP) o profundidad de la cámara anterior (ACD).

Las tasas de error se han debido principalmente a la falta de ejemplos en las muestras obtenidas. Por lo que podría ser interesante que el resultado buscado, reuniendo todas las muestras en un mismo archivo, fuera también el tipo de lente que mejor se adaptara al paciente junto con la posición donde quedara esta dentro del ojo.

Abstract

This project aims to present a neural network that optimises the power of intraocular lenses in cataract surgery. Many formulas have been used and created since the 1970s to try to find out the effective position of the lens after the patient has undergone surgery. Researchers over the generations have developed formulas using different measurement parameters of the eye and different constants.

We have focused on the study of different neural networks to find an improvement over existing formulas. Therefore, we have made statistical comparisons between a third generation formula such as the Hoffer Q, which mainly uses axial length and pre-surgery anterior chamber depth, and various types of neural networks created by testing different types of inputs.

The results obtained have not been entirely satisfactory, as the error rates have been found to be quite high for the intended purpose. Even so, this study represents an advance with respect to what has been previously established because the use of artificial intelligence techniques to find out the effective lens position (ELP) or anterior chamber depth (ACD) had not been carried out.

The error rates mentioned in the previous paragraph were mainly due to the lack of examples in the samples obtained, which were separated by lens type. Therefore, it could be interesting that the result sought, by gathering all the samples in the same file, would also be the type of lens that best suits the patient together with the position of the lens inside the eye.

Índice de Figuras

Figura 1: Estructura de una red neuronal _____	10
Figura 2: Estructura del ojo _____	11
Figura 3: Ficha de una biometría _____	15
Figura 4: Máquina de biometría IOLMASTER 700 _____	16
Figura 5: Diagrama de cajas y bigotes lente 1 _____	19
Figura 6: Diagrama de cajas y bigotes lente 3 _____	20
Figura 7: Tabla de parámetros lente 3 _____	21
Figura 8: Tabla de parámetros para la red neuronal _____	22
Figura 9: Tabla estadística de la lente 3 _____	23
Figura 10: Diagramas de sexo y lado del ojo de la lente 3 _____	23
Figura 11: Ejemplo de clasificación de la red neuronal con la lente 3 _____	24
Tabla 12: Tabla de parámetros para la red neuronal _____	28
Tabla 13: Tabla estadística de la lente 1 _____	29
Figura 14: Diagramas de sexo y lado del ojo de la lente 1 _____	30
Figura 15: Ejemplo de clasificación de la red neuronal con la lente 1 _____	30
Figura 16: Tabla de resultados de la lente 3 _____	31
Figura 17: Tabla de resultados de la segunda red de la lente 3 _____	32

Figura 18: Tabla de resultados lente 1 _____ 33

Figura 19: Tabla de resultados red neuronal 2 de la lente 3 _____ 34

Índice

RESUMEN	I
ABSTRACT	I
ÍNDICE DE FIGURAS	II
1. INTRODUCCIÓN	7
1. MARCO TEÓRICO	9
1.1. INTELIGENCIA ARTIFICIAL	9
1.1.1. REDES NEURONALES	10
1.2. ESTRUCTURA DEL OJO	11
1.2.1. CATARATAS.....	13
1.3. BIOMETRÍA.....	14
2. PLANIFICACIÓN DEL PROYECTO	16
3. DESARROLLO DEL PROYECTO	18
3.1. EXTRACCIÓN Y TRATAMIENTO DE DATOS	18
3.2. CREACIÓN DE REDES NEURONALES	22
3.3. PRUEBAS Y RESULTADOS	31
4. CONCLUSIONES	35
5. BIBLIOGRAFÍA	37
6. ANEXOS	38
6.1. Anexo 1.....	38
6.2. Anexo 2.....	41
6.2.1. Anexo 2.1: Diagramas lente 1	41
6.2.2. Anexo 2.2: Diagramas lente 3	45
6.3. Anexo 3.....	48

1. INTRODUCCIÓN

La operación de catarata es una de las cirugías más comunes, realizándose 22 millones de ellas anualmente en el mundo. Esta cifra estaría creciendo debido al aumento de la esperanza de vida a causa de las mejoras en la calidad de vida y los avances médicos y tecnológicos.

La primera extracción de catarata se realizó en París, en el año 1747, por el cirujano francés Jacques Daviel. Sin embargo, hay escritos que sugieren haber realizado algún tipo de operación en torno al 600 a.C. por un cirujano indio llamado Sushruta. Desde aquel entonces las cirugías han mejorado hasta ser consideradas una de las más exitosas en medicina debido a la simpleza de la operación y el tratamiento.

En una de estas mejoras, entran en juego las lentes intraoculares debido a que la operación no resultaba del todo satisfactoria por las dioptrías resultantes de dejar el ojo sin cristalino. Nos situamos en el siglo XX, en concreto 1949, donde un ayudante del Dr. Ridley le mencionó la idea de reemplazar un cristalino por otro. El material usado fue polimetilmetacrilato, habiendo observado el doctor que no producía ningún tipo de rechazo cuando trataba a combatientes de la II Guerra Mundial de incrustaciones. Fue a partir de ese año que realizó un total de 1000 implantes con un éxito superior al 70%.

Una parte muy importante para llevar a cabo este tipo de cirugía es el examen preoperatorio para calcular la potencia efectiva de la lente o profundidad de la cámara anterior, a partir de ahora ELP o ACD, y así evitar la sorpresa refractiva postoperatoria. Actualmente, esta potencia se calcula a través de unas fórmulas después de medir los distintos diámetros del ojo mediante biometría. Estas tienen su origen en los años 60 cuando se desarrollaron las primeras fórmulas teóricas para poder calcular la potencia, sucediéndose varias generaciones en las que intentaban mejorar el cálculo de la ELP utilizando distintos métodos y parámetros del ojo.

Mediante este trabajo queremos explorar el uso de técnicas de inteligencia artificial con el objetivo de optimizar los métodos de cálculo de la ELP. Comprobaremos con una muestra de datos de ojos de distintos pacientes, a través de la creación de redes neuronales, las aproximaciones de la ELP.

Sin embargo, no podemos olvidar que las fórmulas de última generación, de las que más tarde hablaremos, ya se acercan bastante a los valores encontrados en las biometrías realizadas después de la cirugía. También que hay más factores a tener en cuenta, que puede que las fórmulas estén teniéndolos como puede ser el propio diseño de la lente, ya que para cada lente vienen unas constante preestablecidas por el fabricante para diferentes fórmulas y que la red neuronal creada no lo tenga en cuenta y simplemente utilice los valores medidos del paciente.

1. MARCO TEÓRICO

1.1. INTELIGENCIA ARTIFICIAL

Se define a la Inteligencia Artificial según La Real Academia de la Lengua Española como: *“Disciplina científica que se ocupa de crear programas informáticos que ejecutan operaciones comparables a las que realiza la mente humana, como el aprendizaje o el razonamiento lógico”* [1]. Esta definición es muy similar a la que propuso uno de los padres de la inteligencia artificial (IA) que dice así: *“La inteligencia artificial es la ciencia de construir máquinas para que hagan cosas que, si las hicieran los humanos, requerirían inteligencia.”* (ALFONSO GALIPIENSO 2003)

El origen de la inteligencia artificial se remonta a 1956 en Dartmouth donde John McCarthy propuso el concepto de IA en un taller en el que se reunían diez investigadores considerados de los más sobresalientes en el área de redes neuronales y el estudio de la inteligencia. Aquí, se dedicaban a presentar aplicaciones y juegos de razonamiento. Sin embargo, ya en la II Guerra Mundial se creó ‘Colossus’, considerado el primer ordenador electrónico que fue capaz de acortar la guerra al menos en dos años al ser capaz de descifrar los mensajes que los alemanes emitían en código morse. Estaba basada en la idea de la máquina de Turing y hecha por más de 1500 tubos de vacío.

Desde entonces la inteligencia artificial tiene varias áreas de aplicación y vamos a explicar de manera rápida algunas de ellas:

- Sistema experto: se intenta emular a un experto humano en una disciplina concreta.
- Aprendizaje automático o machine learning: como su propio nombre indica es la capacidad de un software para aprender por sí solo.
- Aprendizaje profundo o Deep learning: es un tipo de aprendizaje automático que intenta aprender de un nivel alto de datos abstracto.

1.1.1. REDES NEURONALES

Una red neuronal nace de la necesidad de imitar el comportamiento que tienen las neuronas en nuestro cerebro y la manera en la que están conectadas y aprenden. Una red neuronal tiene esta forma:

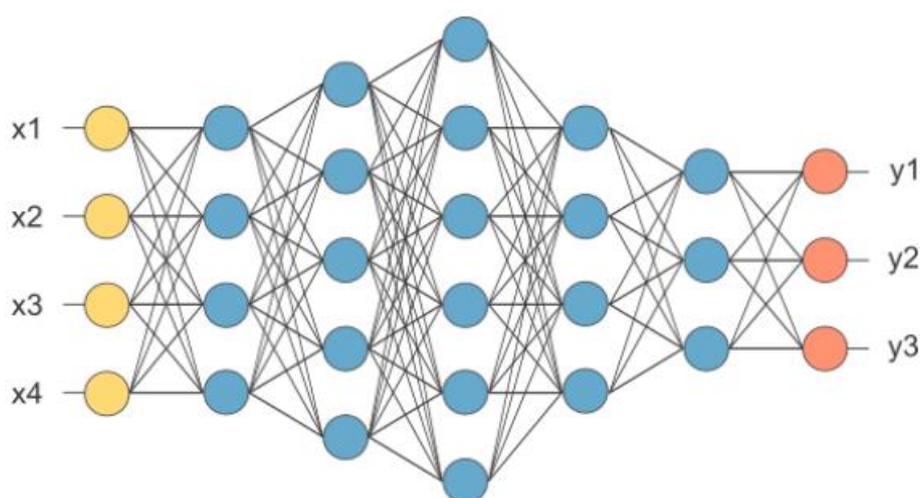


Figura 1: Estructura de una red neuronal

Como se puede ver en la figura 1, la estructura de una red neuronal se puede representar como un grafo cuyas neuronas son nodos y las aristas son las conexiones que se establecen entre ellas. En este caso, tendríamos cuatro entradas y tres salidas con varias capas intermedias que suelen ser para aproximar y clasificar los datos que queremos obtener como salida. En el apartado de CREACIÓN DE REDES NEURONALES se explica de manera breve pero concisa las capas por las que pasa, en este caso, nuestra red neuronal para llegar a la aproximación de un parámetro numérico.

Los usos de las redes neuronales alcanzan un amplio rango desde la gestión empresarial, la predicción, el uso en el hogar hasta el uso en vehículos autónomos. Por supuesto, en el uso de la medicina ha sido bastante útil ya que ha servido y sirve para la predicción de enfermedades y para dar asistencia médica virtualmente. Según estudios recientes, la clasificación de enfermedades y predicción de mortalidad con el uso de redes neuronales tienen una precisión entre el 81,7% y el 99,8%. (Torra 2017)

1.2. ESTRUCTURA DEL OJO

El ojo es el principal órgano de la vista. Es un globo hueco de forma casi esférica que contiene líquidos (humores). Su anatomía se compone de varias partes: párpados, globos oculares, aparato lagrimal y músculos extraoculares, que se pueden dividir en tres partes, la parte externa, la parte media y la parte interna.

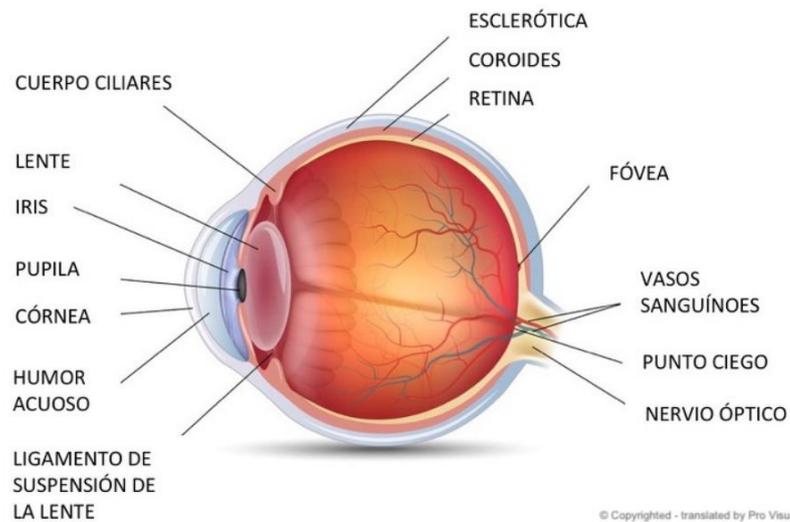


Figura 2: Estructura del ojo

En la parte externa del ojo encontramos:

- La órbita del ojo: cuenca ósea en la que se encuentra el ojo y que está compuesta por 7 huesos y músculos extraoculares que permiten los movimientos. Su función es la de proteger
- La esclera: es una capa de tejido espesa y resistente que está conectada a los músculos de la órbita y recubren la superficie del globo ocular.
- La conjuntiva: membrana mucosa transparente que ayuda a lubricar el ojo y recubren la esclera y la parte interna de los párpados.
- El aparato lagrimal: cuya función es la lubricación del ojo y compuesta por tres capas que son la glándula lagrimal, la glándula de Meibomio y el conducto lagrimal.

- La córnea: estructura que cubre el iris y que tiene como función la protección permitiendo el paso de la luz.

En la parte media del ojo encontramos:

- Cristalino: su función es la de proyectar las imágenes a la retina, permite enfocar y proteger a la retina de la radiación UV.
- Cuerpo ciliar: su función es la de producir el humor acuoso y mejorar el enfoque y la nitidez.
- El iris: controla la cantidad de luz que entra dilatando o contrayendo la pupila.
- La pupila: es el agujero que se encuentra en el centro del iris y que junto con el iris se contrae o se dilata.
- Humor vítreo: es un líquido de forma gelatinosa que rellena el espacio interior del ojo.

En la parte interna del ojo encontramos:

- La retina: su función es la transmisión de los impulsos eléctricos al cerebro, habiendo transformado los estímulos luminosos mediante fotorreceptores.
- La mácula: la encargada de que veamos pequeños detalles y el movimiento
- Retina periférica: su función es la visión periférica y lateral.
- Nervio óptico: es el encargado de enviar los impulsos eléctricos al cerebro, y por lo tanto, el responsable de la visión.

Así, se consigue el funcionamiento del ojo que recibe estímulos luminosos a través de la retina de manera invertida, a su vez, estos estímulos se convierten en impulsos nerviosos que llegan al cerebro a través de los nervios y que se encarga de transformar en imagen.

Esto sería el correcto funcionamiento del ojo, pero con el envejecimiento o ciertas enfermedades se puede desarrollar el riesgo de cataratas que explicaremos más en profundidad lo que es y las implicaciones que tiene. (Mas Vision 2020)

1.2.1. CATARATAS

La catarata es un problema en el cristalino del ojo en el que se acumulan proteínas que van reduciendo la claridad de la imagen, puesto que para que la retina reciba una imagen clara el cristalino tiene que ser transparente. Es un tipo de afección que va aumentando lentamente causando el deterioro gradual de la vista, aunque depende de cada persona e incluso de ojo a ojo. También puedes desarrollar una catarata en un ojo y en el otro no.

El tratamiento que se aplica a la catarata es la cirugía en caso de que la pérdida de visión afecte a la vida diaria. En este caso, el cristalino se extrae y se puede hacer de dos maneras.

- Facoemulsificación, donde se realiza una incisión pequeña en le borde de la córnea y se extrae el cristalino por medio de una sonda que produce ondas ultrasónicas que ablandan y rompen el cristalino. Este tipo de cirugía es la más típica en la actualidad.
- Cirugía extracapsular: se realiza una incisión mas grande y se extrae el centro opaco del cristalino de una sola parte y el resto se aspira.

Después de la extracción del cristalino se introduce una lente intraocular cuya función es la de enfocar la luz sobre la retina. El periodo de recuperación después de la cirugía va de dos a seis semanas, por lo que se trata de una intervención segura y sencilla, que no suele producir complicaciones. (Dr. Ariel Prado-Serrano 2009)

1.3. BIOMETRÍA

Una de las técnicas de detección de catarata y que es la que hemos usado es la biometría. Es un método no invasivo que mide de manera muy precisa las características anatómicas del ojo. Es usada para seleccionar la potencia de la lente intraocular adecuada. Existen dos tipos de biometrías:

- Biometría ultrasónica: utiliza un haz de ultrasonidos de alta frecuencia que calcula las distancia que hay dentro del ojo, chocan con las estructuras haciendo eco y siendo recogidas e interpretadas por la máquina. Este tipo de biometría es de contacto y al contrario que la biometría de interferometría de coherencia parcial si sirve para diagnosticar una hemorragia o catarata madura. (Royo 2015)
- Biometría mediante interferometría de coherencia parcial, técnica poco agresiva que no entra en contacto con el ojo del paciente por lo que no necesitaría anestesia. Esta se basa en la utilización de haces de luz que entran en todas las estructuras del ojo. Al no establecer contacto con el ojo del paciente se hace más difícil diagnosticar cierto tipo de patologías como una catarata madura o una hemorragia.
Con este método se puede medir la longitud axial, el radio corneal y la ACD. Además, también es capaz de detectar si el ojo es el derecho o el izquierdo evitando así errores.

En la siguiente figura se muestra la ficha que aporta la máquina de biometría, en nuestro caso la IOLMASTER 700, y como se puede comprobar aporta las medidas de los parámetros que hemos mencionado antes y los tipos de lente y la refracción. (Zeiss s.f.)

Preoperative Data:							
AL: 23.26 mm *				Refraction:			
K1: 42.94 D @ 92°				Visual Acuity:			
K2: 43.55 D @ 2°				Eye Status: phakic			
opt. ACD: 3.08 mm				Target Ref: plano			
OD right							
TECNIS ZCB00		SN60WF		TECNIS MFL ZMA00 (S)		TECNIS MFL ZMB00	
A Const:	119.3	A Const:	119	A Const:	119.1	A Const:	119.3
IOL (D)	REF (D)	IOL (D)	REF (D)	IOL (D)	REF (D)	IOL (D)	REF (D)
24.0	-0.88	24.0	-1.18	24.0	-1.08	24.0	-0.88
23.5	-0.53	23.5	-0.82	23.5	-0.72	23.5	-0.53
23.0	-0.19	23.0	-0.47	23.0	-0.37	23.0	-0.19
22.5	0.15	22.5	-0.12	22.5	-0.03	22.5	0.15
22.0	0.49	22.0	0.22	22.0	0.31	22.0	0.49
21.5	0.82	21.5	0.56	21.5	0.65	21.5	0.82
21.0	1.15	21.0	0.90	21.0	0.98	21.0	1.15
Preoperative Data:							
AL: 23.28 mm				Refraction:			
K1: 43.38 D @ 74°				Visual Acuity:			
K2: 43.95 D @ 164°				Eye Status: phakic			
opt. ACD: 3.20 mm				Target Ref: plano			
OS left							
TECNIS ZCB00		SN60WF		TECNIS MFL ZMA00 (S)		TECNIS MFL ZMB00	
A Const:	119.3	A Const:	119	A Const:	119.1	A Const:	119.3
IOL (D)	REF (D)	IOL (D)	REF (D)	IOL (D)	REF (D)	IOL (D)	REF (D)
23.5	-0.88	23.5	-1.17	23.5	-1.07	23.5	-0.88
23.0	-0.53	23.0	-0.82	23.0	-0.72	23.0	-0.53
22.5	-0.19	22.5	-0.47	22.5	-0.38	22.5	-0.19
22.0	0.14	22.0	-0.12	22.0	-0.03	22.0	0.14
21.5	0.47	21.5	0.22	21.5	0.30	21.5	0.47
21.0	0.80	21.0	0.55	21.0	0.64	21.0	0.80
20.5	1.13	20.5	0.89	20.5	0.97	20.5	1.13

Figura 3: Ficha de una biometría

2. PLANIFICACIÓN DEL PROYECTO

Para todo desarrollo de un proyecto hace falta una planificación previa. En este caso, se realizó en base a la consecución del objetivo, la creación de una red neuronal para la optimización de las lentes intraoculares en la operación de catarata. Para ello se realizaron una serie de reuniones en las que trabajamos y marcamos unas metas a corto plazo para ir desarrollando progresivamente el trabajo. Al principio, marcamos el objetivo de la recogida de datos para la creación de la base de datos, con lo que ello conlleva: extracción, filtración y eliminación de datos redundantes.

El primer paso fue la extracción de datos, que se produjo en el departamento de Oftalmología en el Hospital de la Santa Creu i Sant Pau, con la máquina de biometría IOLMASTER 700.



Figura 4: Máquina de biometría IOLMASTER 700

Una vez obtenidos, se procedió al segundo paso que consistió en la filtración y eliminación de datos redundantes con los parámetros seleccionados, que eran de interés para la red neuronal, seleccionados por el oftalmólogo Ignacio Miras Salvador.

Realizado este proceso se fijaron otras reuniones con el Dr Eduardo Soudah Prieto y Francisco Javier Garate Vidiella para seguir con los pasos que fueron conseguir el software que íbamos a utilizar. En este caso, el software utilizado es Neural Designer, programa informático de machine learning que se basa en las redes neuronales. Se creó a partir de la librería de código abierto OpenNN¹. Otro programa usado para la visualización del código Python generado es el Visual Studio Code, un editor de código fuente.

Posteriormente, se han realizado una serie de reuniones en las que se ha ido comprobando el avance del proyecto fijando unas directrices, que más tarde explicaremos, para comprobar si la red neuronal daba los resultados esperados.

¹ OpenNN: biblioteca escrita en C++ que implementa redes neuronales.

3. DESARROLLO DEL PROYECTO

3.1. EXTRACCIÓN Y TRATAMIENTO DE DATOS

Se trata de la obtención de una muestra de ojos antes y después de la operación de catarata. La extracción de datos se llevó a cabo en el Departamento de Oftalmología en el Hospital de la Santa Creu i Sant Pau, mencionado anteriormente.

En un primer momento se extrajeron todos los datos de la máquina, siendo 2636 pacientes distintos. Sin embargo, el archivo Excel constaba de 5623 filas, lo que significa tanto datos redundantes como falta de ellos, puesto que algunos pacientes no tenían la operación realizada o se habían hecho varias biometrías debido a fallos técnicos como puede ser el movimiento del paciente.

De esos datos, nos quedamos con 104 pacientes, como se explica en el Anexo 1 Ese documento se hizo a partir de una primera selección de los parámetros más útiles. La primera selección de parámetros fue de 14. Sin embargo, como iremos viendo a lo largo de este documento no todos los hemos seleccionado para la creación de las redes neuronales.

Se observó que había 4 tipos de lente intraocular, de las cuales escogimos trabajar con dos, uno con el tipo de lente 1 (Alcon SA60AT) y otro con el tipo de lente 3 (AMO ZA9003); creándose 2 datasets. Esto se debe a que en función de los parámetros de cada ojo la máquina de biometría calcula a través de las fórmulas desarrolladas en el apartado 2.4 el tipo de lente que mejor se va a adaptar a ese ojo. Por lo tanto, necesitamos separarlas para que clasifique mejor. Otra de las razones por las que solo se crean 2 datasets, y no más, aun habiendo 4 tipos de lentes, es que de los 104 pacientes seleccionados había muy pocos a los que hubieran puesto de los otros dos tipos de lente (tipo de lente 2: ICB, tipo de lente 4: Micropure 123).

Los dos archivos constan de una biometría pre y post cirugía, lo que significa que aparte de los 14 parámetros seleccionados que corresponden a las biometrías previas, hay que

añadirle 10 parámetros más de las biometrías post. Estas serían: acquisition date, lens, vitreous, axial length, radio 1, radio 2, anterior chamber Depth, length thickness, central corneal thickness, White to White.

Una vez realizado este proceso se pasó a la parte analítica para comprobar la variabilidad de los datos. Además, se hicieron en Visual Studio Code unos diagramas de cajas y bigotes (boxplot). El parámetro más interesante para la eliminación de outliers es la longitud axial o axial length porque es el principal determinante del famoso error de refracción. Los resultados obtenidos fueron los siguientes:

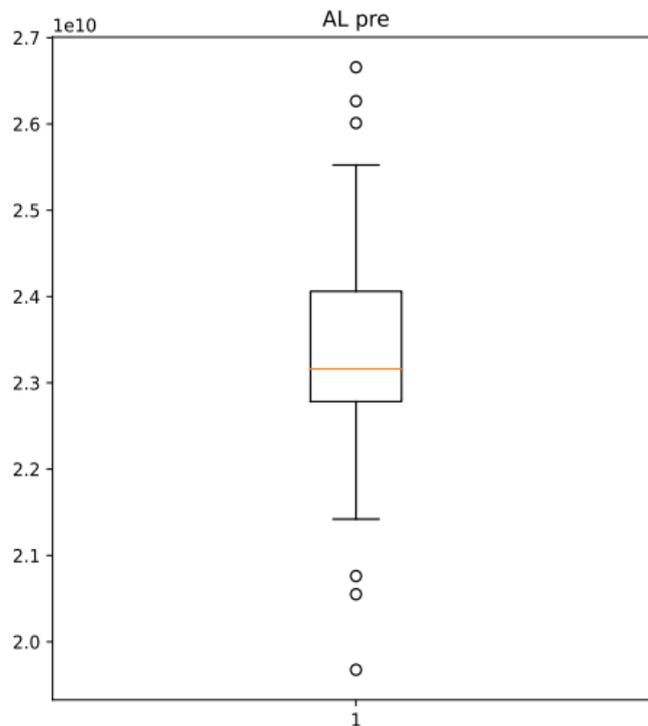


Figura 5: Diagrama de cajas y bigotes lente 1

Como podemos apreciar para la lente 1 hay varios valores atípicos de la longitud axial que han sido eliminados para el entrenamiento más correcto posible de las redes neuronales. Los valores se agrupan aproximadamente entre 23×10^9 y 24×10^9

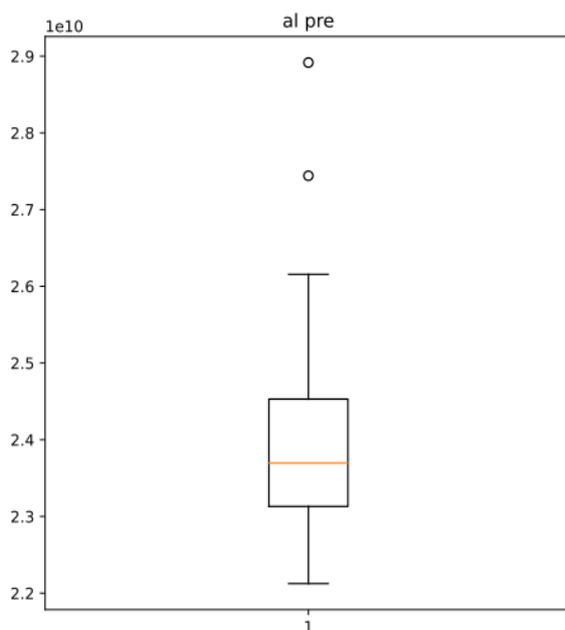


Figura 6: Diagrama de cajas y bigotes lente 3

Como en la lente anterior, en esta también hay varios valores atípicos, aunque son menos y de valores bastante mayores a los agrupados ya que, estos lo hacen aproximadamente entre 23×10^9 y $24,5 \times 10^9$.

Estos diagramas también los hemos usado para comprobar la variabilidad de los datos después de la cirugía, ya que, aunque se supone que de todos los parámetros solo varía la profundidad de la cámara anterior (ACD), al realizar la operación todos los parámetros medidos varían ligeramente. Esto lo podemos observar en los diagramas de los Anexo 2.1: Diagramas lente 1 y Anexo 2.2: Diagramas lente 3

En este proceso también hemos buscado el resultado del ACD postoperatorio implementando una de las muchas fórmulas existentes. En concreto una de última generación que usa tan solo dos parámetros: la longitud axial o axial length y la profundidad

de la cámara anterior o anterior chamber depth. La fórmula tiene esta forma y se llama fórmula de Hoffer Q:

$$ACD_{postop} = pACD + 0.3(AL - 23.5) + \tan^2 k + 0.1 * M(23.5 - AL)^2 * \tan(0.1(G - A)^2) - 0.94166$$

Siendo k, M y G constantes establecidas por dicho autor, estableciéndose una relación entre M y G con la longitud axial, de esta manera:

$$M = \begin{cases} 1 \\ -1 \end{cases} \quad G = \begin{cases} 28 \\ 23,5 \end{cases} \quad \begin{matrix} \text{si } AL \leq 23mm \\ \text{si } AL > 23mm \end{matrix}$$

pACD es una constante propia de cada lente, pero los resultados obtenidos se alejaban más aún de los reales con lo que se usó la profundidad de la cámara anterior previa a la cirugía, siendo los resultados que más se acercaban.

He seleccionado unos ejemplos para comprobar el valor real del ACD postoperatorio y la cifra esperada con la fórmula de Hoffer Q. Como podemos comprobar ningún valor calculado es realmente el valor que obtenemos después de la cirugía, aunque sí se acercan bastante algunos de ellos.

ACDPOST	HOFFER Q	ERROR COMETIDO HOFFER Q
4.416698187	4.26639414	0.150304044
4.345952583	4.52230146	-0.176348881
4.175846975	4.14358401	0.032262965
4.322235264	4.18664175	0.135593517
4.56896467	4.46947715	0.099487519
4.170724395	4.44213393	-0.271409531
3.757014032	4.04639373	-0.289379699
4.135682938	4.58596522	-0.450282279
4.128914419	4.14274477	-0.013830348
3.923935724	3.39579527	0.528140458
4.361286919	3.44691695	0.914369973
4.285172036	3.63338812	0.651783912
4.102431225	4.68314858	-0.580717352
5.681673474	4.88519319	0.796480281
3.780114226	3.329485	0.450629222
3.851603319	3.31262256	0.538980764
4.485089653	5.19274668	-0.707657027
4.430208431	4.91344369	-0.483235261
4.566307593	4.40673941	0.159568184
3.977220767	4.29477579	-0.317555025

Figura 7: Tabla de parámetros lente 3

3.2. CREACIÓN DE REDES NEURONALES

Una de las primeras redes neuronales que quisimos crear fue una red que nos devolviera el valor que anteriormente habíamos calculado en el Excel siguiendo la fórmula Haigis. Esto significa usar como parámetros de entrada la longitud axial y la profundidad de la cámara anterior pre-cirugía y como salida la profundidad de la cámara anterior post-cirugía. De esta manera:

8	AL	Numeric	0	Input
9	R1	Numeric	0	Unused
10	R2	Numeric	0	Unused
11	ACD	Numeric	0	Input
12	LT	Numeric	0	Unused
13	CCT	Numeric	0	Unused
14	W2W	Numeric	0	Unused
15	LIO	Numeric	0	Unused
16	Acquisition_Date POST	Numeric	0	Unused
17	LSPOST	Categorical	0	Unused
18	VSPOST	Categorical	0	Unused
19	ALPOST	Numeric	0	Unused
20	R1POST	Numeric	0	Unused
21	R2POST	Numeric	0	Unused
22	ACDPOST	Numeric	0	Target
23	LTPOST	Numeric	2	Unused
24	CCTPOST	Numeric	0	Unused
25	W2WPOST	Numeric	0	Unused

Input columns

2

Target columns

1

Unused columns

22

Figura 8: Tabla de parámetros para la red neuronal

Con este software también podemos hacer tratamiento de datos previo a la creación de las redes neuronales, ya que nos ofrece los datos estadísticos y sus distribuciones entre otros datos que nos puedan interesar. Los datos estadísticos son una información que nos resulta útil para comprobar la distribución de nuestra muestra, en este caso de la lente 3:

	Minimum	Maximum	Mean	Deviation
AL	22.125	28.917	23.982	1.318
ACD	2.257	3.965	3.024	0.375
ACDPOST	3.745	5.771	4.427	0.479

Figura 9: Tabla estadística de la lente 3

Como se puede ver el valor con mayor desviación es la longitud axial, como también se podía observar en el diagrama de cajas y bigotes, habiendo “outliers”. En esta primera creación de la red neuronal hemos decidido no borrar esos datos para comprobar la aproximación que hace.

Otro tipo de información que nos resulta interesante observar es la distribución de los ojos, si son ojos derechos (diestros) o izquierdo (sinistro) y el sexo de las personas operadas.

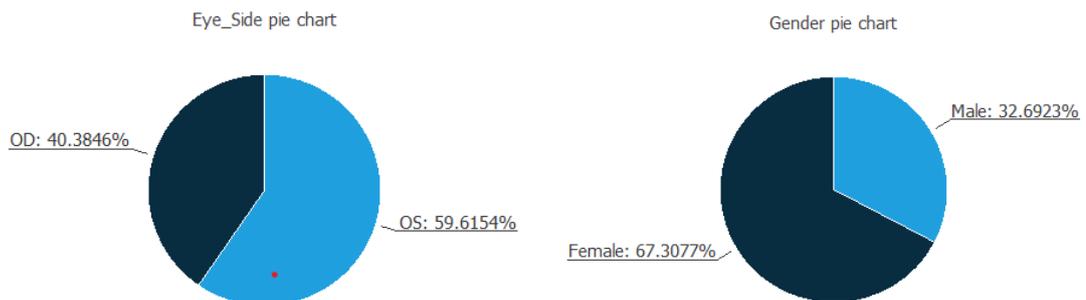


Figura 10: Diagramas de sexo y lado del ojo de la lente 3

Como se puede observar los ojos siniestros y el sexo femenino predominan en esta muestra de datos más adelante comprobaremos la muestra de los datos para la lente 1 y veremos si se mantiene esta tendencia.

Volviendo ya a la creación de nuestra red neuronal el software selecciona los ejemplos que va a usar y los divide en tres: training samples (muestra de aprendizaje o entrenamiento), selection samples (muestra de selección) y testing samples (muestra de testeo).

Los clasifica de esta manera:

Training samples	Selection samples	Testing samples	Unused samples
32	10	10	0
61.5%	19.2%	19.2%	0%

Figura 11: Ejemplo de clasificación de la red neuronal con la lente 3

El primero de todos, training samples, busca un grupo de parámetros que ajuste la red neuronal a todo el conjunto obteniendo la mínima pérdida posible.

- El segundo, selection samples, tiene como objetivo encontrar la estructura de la red con la mejor generalización posible, lo que quiere decir que minimiza el error del conjunto de datos seleccionado.
- El tercero, testing samples, compara las salidas de nuestra red con el objetivo de un conjunto independiente.

Hecho esto, obtenemos el código Python que iremos explicando capa a capa:

```
import numpy as np

def scaling_layer(inputs):
    outputs = [None] * 2

    outputs[0] = inputs[0]
    outputs[1] = inputs[1]

    return outputs
```

Para empezar, tenemos la capa de escalado que sirve para que las entradas tengan un rango adecuado. Se conecta a las entradas de la red y contiene algunas estadísticas como la media o la desviación. Suelen generar resultados parecidos, ya que son métodos lineales. Entre los métodos más usados en el escalado están:

- El método de escalado máximo y mínimo.
- El método de escalado media y desviación estándar.
- El método de escalado de la desviación estándar.

```
def perceptron_layer_0(inputs):
    combinations = [None] * 3

    combinations[0] = 0.165466 -0.758057*inputs[0] +0.329407*inputs[1]
    combinations[1] = -0.1745 -0.702637*inputs[0] -0.505249*inputs[1]
    combinations[2] = 0.844543 -0.776855*inputs[0] -0.795959*inputs[1]

    activations = [None] * 3

    activations[0] = np.tanh(combinations[0])
    activations[1] = np.tanh(combinations[1])
    activations[2] = np.tanh(combinations[2])

def perceptron_layer_1(inputs):
    combinations = [None] * 1

    combinations[0] = 0.378967 +0.652832*inputs[0] -0.0185547*inputs[1] -0.0925293*inputs[2]

    activations = [None] * 1

    activations[0] = combinations[0]

    return activations
```

En esta segunda capa tenemos la capa de perceptrón, la más importante de la red. Son las capas que hacen que la red aprenda: reciben la información de las entradas y se combina con un sesgo y un grupo de ponderaciones para dar lugar a una salida.

La función de activación define la salida a través de la función de combinación, que crea un valor de entrada de la red. Así se determina la función que representa la red neuronal. Las funciones de activación pueden ser varias:

- Función de activación lineal.
- Función de activación tangente hiperbólica.
- Función de activación logístico.
- Función de activación lineal rectificada.

```
def unscaling_layer(inputs):  
    outputs = [None] * 1  
    outputs[0] = inputs[0]*0.5944149494+4.434675217  
    return outputs
```

Esta tercera capa, la de desescalada, como su propio nombre indica sirve para desescalar y producir las unidades originales. Estas se conectan con la capa del perceptrón, conteniendo estadísticas sobre las salidas. Estas estadísticas pueden ser:

- Método de desescalada mínimo y máximo.
- Método de desescalada media y desviación estándar.
- Método de desescalada desviación estándar.
- Método de desescalada logarítmico.

```
def bounding_layer(inputs):
    outputs = [None] * 1
    outputs[0] = inputs[0]
    return outputs
```

Por último, tenemos la capa de delimitación, que consiste en la limitación de la salida entre dos valores. Esta está conectada a las salidas de la capa de desescalado.

```
def neural_network(inputs):
    outputs = [None] * len(inputs)
    outputs = scaling_layer(inputs)
    outputs = perceptron_layer_0(outputs)
    outputs = perceptron_layer_1(outputs)
    outputs = unscaling_layer(outputs)
    outputs = bounding_layer(outputs)
    return outputs
```

Por lo tanto, llegamos a la formación de nuestra red neuronal con esas capas. Por último, para utilizar nuestra red y comprobar que funcione habría que meterle, en nuestro caso, dos parámetros de entrada y llamar a la función de la red neuronal de la siguiente manera:

```
sample = [24.343829, 3.31351329]
outputs = neural_network(sample)
print(outputs)
```

El resto de redes neuronales serían igual, solo que con más inputs dependiendo de los parámetros de entrada que queramos introducir. De igual manera a la hora de comprobar la red tendríamos que introducir tantos valores como inputs hayamos establecido, es decir en “sample” tendríamos que introducir esos valores. (Neural Designer s.f.)

Vamos a analizar ahora los datos de la lente 1 y a introducir otro ejemplo de red neuronal con más parámetros de entrada.

	Name	Type	Missing	Use
1	Acquisition_Date	Numeric	0	Unused
2	Eye_Side	Binary	0	Unused
3	DOB	Numeric	0	Unused
4	Pat_ID	Numeric	0	Unused
5	Gender	Binary	0	Unused
6	LS	A Constant	0	Unused
7	VS	Binary	0	Unused
8	AL	Numeric	0	Input
9	R1	Numeric	0	Input
10	R2	Numeric	0	Input
11	ACD	Numeric	0	Input
12	LT	Numeric	0	Input
13	CCT	Numeric	0	Input
14	W2W	Numeric	0	Input
15	LIO	Numeric	0	Unused
16	Acquisition_Date POST	Numeric	0	Unused
17	LS POST	Binary	0	Unused
18	VS POST	Binary	0	Unused
19	ACD POST	Numeric	0	Target

Input columns

7

Target columns

1

Unused columns

11

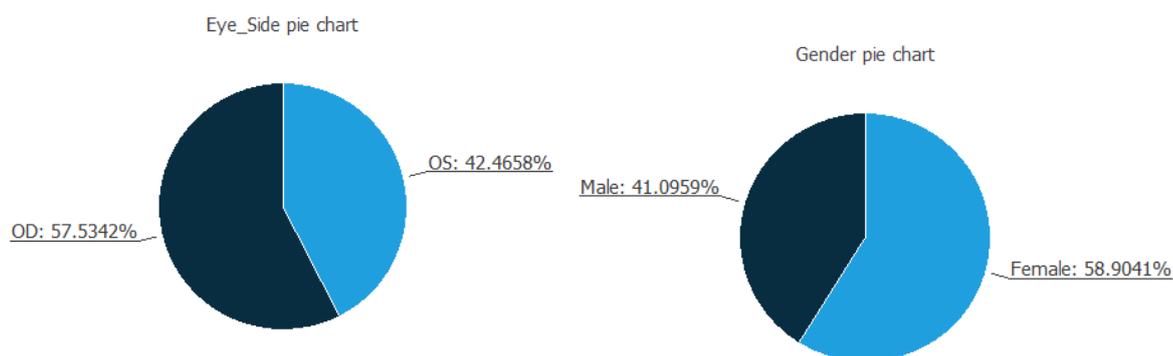
Tabla 12: Tabla de parámetros para la red neuronal

Como vemos, otra de las redes que hemos creado es utilizando los siete parámetros numéricos para comprobar si así se producía una aproximación mas certera. Como hemos hecho con la lente 3 aquí también observaremos el comportamiento estadístico.

	Minimum	Maximum	Mean	Deviation
AL	19.676	26.657	23.322	1.174
R1	7.062	8.530	7.830	0.265
R2	6.967	8.387	7.659	0.269
ACD	2.040	4.063	2.916	0.364
LT	3.638	6.130	4.867	0.472
CCT	0.466	0.651	0.552	0.037
W2W	10.631	12.700	11.821	0.471
ACD POST	3.840	5.029	4.433	0.223

Tabla 13: Tabla estadística de la lente 1

Viendo la figura 13 podemos comprobar que como ocurría anteriormente la mayor desviación la tiene la longitud axial, mientras que la desviación de la profundidad de la cámara anterior es aproximadamente la mitad, lo que quiere decir que los valores oscilan en un intervalo más cerrado. Como antes, vamos a observar datos de interés como son el sexo de los pacientes y el lado al que pertenece cada ojo.



Figuraa 14: Diagramas de sexo y lado del ojo de la lente 1

En este tipo de lente, predomina también el género femenino pero el ojo derecho. Aunque no vayamos a usarlo en esta red son datos bastante interesantes de analizar y ver su distribución.

Training samples	Selection samples	Testing samples	Unused samples
44	15	14	0
61.6%	19.2%	19.2%	0%

Figura 15: Ejemplo de clasificación de la red neuronal con la lente 1

A pesar de que hay más ejemplos en esta muestra, el reparto entre los tres tipos de clasificadores es aproximadamente el mismo.

Una vez realizado este análisis vamos a generar el código python que hemos explicado anteriormente pero con más entradas y como salida la misma, la profundidad de la camara anterior después de la cirugía. El código generado lo adjuntaremos en el Anexo 3.

3.3. PRUEBAS Y RESULTADOS

Aquí vamos a comprobar el resultado de nuestras dos redes neuronales explicadas anteriormente, y compararemos los valores de las fórmulas con los que hemos obtenido de la red neuronal.

ACDPOST	HOFFER Q	ACD_REDNEURONAL	ERROR HOFFER Q	ERROR RED	E_RELATIVO RED	E_RELATIVO HOFFER Q
4.416698187	4.266394143	4.3379157571217219	0.150304044	0.07878243	1.783740399	3.403086143
4.345952583	4.522301464	4.337915757121719	0.176348881	0.008036826	0.184926681	4.057772781
4.175846975	4.143584010	4.337915757121721	0.032262965	0.162068782	3.881099645	0.772608891
4.322235264	4.186641747	4.337915757121723	0.135593517	0.015680493	0.362786664	3.137115606
4.568964670	4.469477151	4.337915757121721	0.099487519	0.231048913	5.05692054	2.177463084
4.170724395	4.442133926	4.3379157571217215	0.271409531	0.167191362	4.00868881	6.507491392
3.757014032	4.046393731	4.337915757121721	0.289379699	0.580901725	15.4617928	7.702385366
4.135682938	4.585965217	4.337915757121719	0.450282279	0.202232819	4.88994979	10.88773694
4.128914419	4.142744767	4.337915757121726	0.013830348	0.209001338	5.06189562	0.3349633
3.923935724	3.395795266	4.3379157571217215	0.528140458	0.413980033	10.55012269	13.45945742
4.361286919	3.446916946	4.3379157571217215	0.914369973	0.023371162	0.535877651	20.96560006
4.285172036	3.633388124	4.337915757121731	0.651783912	0.052743721	1.230842558	15.21021575
4.102431225	4.683148577	4.337915757121719	0.580717352	0.235484532	5.740121387	14.15544393
5.681673474	4.885193193	4.337915757121719	0.796480281	1.343757717	23.65073817	14.01840997
3.780114226	3.329485004	4.33791575712173	0.450629222	0.557801531	14.75620835	11.92104775
3.851603319	3.312622555	4.337915757121731	0.538980764	0.486312438	12.62623375	13.99367275
4.485089653	5.192746680	4.33791575712172	0.707657027	0.147173896	3.281403657	15.77799067
4.430208431	4.913443692	4.33791575712172	0.483235261	0.092292674	2.083258052	10.90773196
4.566307593	4.406739409	4.337915757121721	0.159568184	0.228391836	5.001674356	3.494468578
3.977220767	4.294775792	4.337915757121726	0.317555025	0.36069499	9.069021089	7.984344938
		media error abs:	0.399879589	0.279847461	6.460865133	9.043450365

Figura 16: Tabla de resultados de la lente 3

Esta tabla muestra 20 ojo extraídos de los 52 que han sido operados con la lente 3, a los que hemos calculado una cifra aproximada de la profundidad de la cámara anterior con la fórmula Hoffer Q y con la creación de una red neuronal. Con esta red lo que queríamos era imitar el comportamiento de la fórmula, usando los mismos parámetros que son la longitud axial y la profundidad de la cámara anterior pre-cirugía.

Como se puede apreciar entre la columna del resultado a través de la fórmula y a través de la red hay bastante diferencia y no podríamos decir que la red se dedique a imitar la fórmula, en algunos casos notamos hasta 1 punto de diferencia entre uno y otra.

Analizando el valor obtenido con la red neuronal respecto del obtenido con la biometría comprobamos que se comete un error alto para un parámetro que tiene que ser bastante preciso, es decir, una diferencia de por ejemplo 0.162, como ocurre en la tercera fila, nos

dice que el valor obtenido a través de la red no nos sería muy útil a la hora de estimar la posición donde va a quedar la lente.

Si bien podemos ver que la media de los errores es menor en la red neuronal que en la obtención del parámetro mediante la fórmula, es un porcentaje muy alto para la precisión que necesitamos.

Ahora vamos a comprobar cómo funcionaría la red neuronal con siete parámetros numéricos de entrada respecto de la anterior, comparando el parámetro de salida con el obtenido por biometría.

ACDPOST	ACD_REDNEURONAL	ERROR RED	E_RELATIVO RED	ACD_RED2	ERROR RED2	E_RELATIVO RED2
4.416698187	4.3379157571217219	0.07878243	1.783740399	4.22055948002979	0.196138707	4.440844691
4.345952583	4.337915757121719	0.008036826	0.184926681	4.220554938161216	0.125397645	2.885389163
4.175846975	4.337915757121721	0.162068782	3.881099645	4.2205514662273105	0.044704491	1.070549077
4.322235264	4.337915757121723	0.015680493	0.362786664	4.220545177953451	0.101690086	2.352719827
4.568964670	4.337915757121721	0.231048913	5.05692054	4.220486611513789	0.348478058	7.627068355
4.170724395	4.3379157571217215	0.167191362	4.00868881	4.220467812242058	0.049743417	1.192680516
3.757014032	4.337915757121721	0.580901725	15.4617928	4.220551731487764	0.463537699	12.33792835
4.135682938	4.337915757121719	0.202232819	4.88994979	4.220550674489681	0.084867736	2.052085176
4.128914419	4.337915757121726	0.209001338	5.06189562	4.220517267072398	0.091602848	2.218569793
3.923935724	4.3379157571217215	0.413980033	10.55012269	4.220569079722073	0.296633356	7.559587531
4.361286919	4.3379157571217215	0.023371162	0.535877651	4.2205689072951476	0.140718012	3.226524976
4.285172036	4.337915757121731	0.052743721	1.230842558	4.220543783987777	0.064628252	1.50818337
4.102431225	4.337915757121719	0.235484532	5.740121387	4.220563420155958	0.118132195	2.879565523
5.681673474	4.337915757121719	1.343757717	23.65073817	4.220573178201963	1.461100296	25.71602016
3.780114226	4.33791575712173	0.557801531	14.75620835	4.220564095716384	0.44044987	11.65176086
3.851603319	4.337915757121731	0.486312438	12.62623375	4.220562914906897	0.368959596	9.57937683
4.485089653	4.33791575712172	0.147173896	3.281403657	4.2205047982646455	0.264584855	5.899209942
4.430208431	4.33791575712172	0.092292674	2.083258052	4.2205330820525715	0.209675349	4.732855174
4.566307593	4.337915757121721	0.228391836	5.001674356	4.2205483165098	0.345759276	7.571966396
3.977220767	4.337915757121726	0.36069499	9.069021089	4.2205007745166165	0.243280008	6.116834387
	media error:	0.279847461	6.460865133		0.273004088	6.130986005

Figura 17: Tabla de resultados de la segunda red de la lente 3

Observando la figura 17 vemos los valores obtenidos con la red neuronal con 7 parámetros de entrada, que sería la columna que pone 'acd_red2'. De esta tabla, como de la anterior podemos deducir que son valores bastante parecidos entre sí, es decir, entre los valores de la primera red neuronal y entre los valores de la segunda red.

De igual manera, la segunda red neuronal también comete un error bastante alto, aunque en comparación con la primera disminuye alrededor de un 0.3% no podríamos decir que obtenemos buenos resultados con esta red tampoco.

Después de haber comprobado con la lente 3 los resultados que se obtenían creando dos tipos de redes, una que imitara a la fórmula usando dos parámetros de entrada y la otra con los siete parámetros numéricos que encontramos en nuestra muestra de ojos, vamos a comprobar lo mismo, pero con la lente 1. Con esta muestra de datos esperamos un menor error a la hora de aproximar la profundidad de la cámara anterior o posición efectiva de la lente, ya que, encontramos alrededor de 20 ojos más, pudiendo así entrenar con más precisión la red.

ACD POST	HOFFER Q	ACD RED	ERROR RED	ERROR HOFFERQ	E_RELATIVO RED	E_RELATIVOHOFFERQ
4.40556	4.117406781	3.848473175219855	0.557086825	0.288153219	12.64508541	6.540671765
4.74072	4.350652769	3.848473175219855	0.892246825	0.390067231	18.8209138	8.228016651
4.14798	3.747930926	3.848288030618815	0.299691969	0.400049074	7.22500999	9.644431121
4.67645	4.021060563	3.848374053164479	0.828075947	0.655389437	17.70736235	14.01467859
4.75842	4.634725538	3.8483835579738126	0.910036442	0.123694462	19.12476078	2.599486006
4.33218	4.306002096	3.8483096844214875	0.483870316	0.026177904	11.16921078	0.604266305
4.43889	4.471996199	3.848284239323121	0.590605761	0.033106199	13.30525786	0.745821568
4.10519	2.956154226	3.848399747913012	0.256790252	1.149035774	6.255258638	27.98983175
4.38315	4.171908977	3.8482403160130945	0.534909684	0.211241023	12.20377318	4.819388408
3.95591	3.384410856	3.8483381012430606	0.107571899	0.571499144	2.719270629	14.44671754
3.84026	3.115711233	3.8483618218955886	0.008101822	0.724548767	0.210970661	18.86718001
4.50433	4.194747259	3.8482979064030243	0.656032094	0.309582741	14.56447671	6.87300311
4.45109	4.208586711	3.848306707615566	0.602783292	0.242503289	13.54237484	5.448177615
4.30788	1.662534078	3.848687143130912	0.459192857	2.645345922	10.65936973	61.40714045
4.35324	4.045208862	3.848280699220975	0.504959301	0.308031138	11.59962007	7.075905257
4.24159	3.838228134	3.8482870645385088	0.393302935	0.403361866	9.272535428	9.509685425
4.43671	3.729496114	3.8482813616750917	0.588428638	0.707213886	13.26272482	15.94005211
4.49589	3.799164516	3.8482754053519264	0.647614595	0.696725484	14.40459163	15.49694241
4.17338	3.674080969	3.848288096610304	0.325091903	0.499299031	7.789654989	11.96390051
4.26158	3.581918317	3.848294922969732	0.413285077	0.679661683	9.697930745	15.9485844
		media error	0.502983922	0.553234364	11.30900765	12.90819405

Figura 18: Tabla de resultados lente 1

Al contrario de lo que habíamos pensado, el error relativo aumenta en ambos casos, tanto para el valor creado por la red neuronal como por la fórmula de Hoffer Q, incluso para la red aumenta casi el doble. Aun así, podríamos decir que la red neuronal estima ligeramente mejor que la fórmula, en concreto 1,6% aproximadamente respecto de los errores relativos.

Vamos a proceder ahora, como antes, viendo qué resultados nos aporta establecer más parámetros de entrada respecto a la red ya obtenida y al valor real del ACD.

ACD POST	ACD RED	ERROR RED	E_RELATIVO RED	ACD RED 2	ERROR RED2	E_RELATIVO RED2
4.40556	3.848473175219855	0.557086825	12.64508541	3.58220675583609	0.823353244	18.68895768
4.74072	3.848473175219855	0.892246825	18.8209138	3.5840503696014525	1.15666963	24.39860676
4.14798	3.848288030618815	0.299691969	7.22500999	3.5806691224460367	0.567310878	13.67679877
4.67645	3.848374053164479	0.828075947	17.70736235	3.582916908449286	1.093533092	23.38382943
4.75842	3.8483835579738126	0.910036442	19.12476078	3.581887417981664	1.176532582	24.72527818
4.33218	3.8483096844214875	0.483870316	11.16921078	3.582173232773844	0.750006767	17.31245625
4.43889	3.848284239323121	0.590605761	13.30525786	3.581502908161638	0.857387092	19.31534892
4.10519	3.848399747913012	0.256790252	6.255258638	3.582308736898411	0.522881263	12.73707826
4.38315	3.8482403160130945	0.534909684	12.20377318	3.5817915979538446	0.801358402	18.28270541
3.95591	3.8483381012430606	0.107571899	2.719270629	3.7557632314788707	0.200146769	5.059436856
3.84026	3.8483618218955886	0.008101822	0.210970661	3.5815416903851185	0.25871831	6.736999829
4.50433	3.8482979064030243	0.656032094	14.56447671	3.5809402891524647	0.923389711	20.50004575
4.45109	3.848306707615566	0.602783292	13.54237484	3.581051275155545	0.870038725	19.54664419
4.30788	3.848687143130912	0.459192857	10.65936973	3.603059172509502	0.704820827	16.36119919
4.35324	3.848280699220975	0.504959301	11.59962007	3.5852148424170407	0.768025158	17.64261005
4.24159	3.8482870645385088	0.393302935	9.272535428	3.585826146889281	0.655763853	15.46033099
4.43671	3.8482813616750917	0.588428638	13.26272482	3.580906313783541	0.855803686	19.28915088
4.49589	3.8482754053519264	0.647614595	14.40459163	3.5811605100419923	0.91472949	20.34590459
4.17338	3.848288096610304	0.325091903	7.789654989	3.585122635183025	0.588257365	14.09546614
4.26158	3.848294922969732	0.413285077	9.697930745	3.5852320759569603	0.676347924	15.87082547
0						
	media error	0.502983922	11.30900765		0.758253738	17.17148368

Figura 19: Tabla de resultados red neuronal 2 de la lente 3

Como podemos seguir viendo, el error incluso ha aumentado creando una red con siete entradas numéricas. También podemos decir que los valores oscilan poco entre sí, como pasaba en los ejemplos anteriores.

Por lo tanto, como hemos comentado en las otras redes, no se puede decir que esta red sea muy precisa en cuanto al cálculo de la profundidad de la cámara anterior, incluso empeora respecto a la red que solo utiliza los dos parámetros de entrada.

Hay que tener en cuenta, que estas cuatro redes neuronales se han creado a partir de las muestras con todos sus datos. Dicho con otras palabras, no se han eliminado los outliers vistos en los diagramas de cajas y bigotes. Si bien hay que decir que no afectan significativamente a la formación de la red, ya que, al haber pocos ejemplos como hemos comentado y vamos a comentar en el siguiente apartado, quitando también los outliers nos quedamos con una muestra aún más pequeña y que por lo tanto no va a entrenar bien el parámetro que queremos obtener.

4. Conclusiones

Tal y como hemos descrito en el apartado... el objetivo de este trabajo se centra en la optimización de las lentes intraoculares mediante técnicas de inteligencia artificial, en este caso se han usado técnicas de inteligencia artificial (redes neuronales). Aunque en el apartado 3 solo se describe la creación de cuatro redes, dos para cada muestra de datos que tenemos, han sido creadas más redes con el fin de ver cómo afectaban otro tipo de parámetros como podían ser los binarios, es decir los de sexo o lado del ojo. Los resultados no han sido muy esclarecedores tampoco con esas redes ya que, tenemos la misma cantidad de ejemplos para cada lente.

Hoy en día, las fórmulas propuestas para averiguar qué tipo de lente y su posición efectiva están bastante desarrolladas, como hemos podido comprobar en los casos expuestos en el apartado 3, los errores no eran mucho más altos que en los de las redes neuronales, teniendo en cuenta que el cálculo que hemos hecho de esta fórmula se hace grosso modo.

Como primera conclusión que podemos sacar de este trabajo es que hacen falta más ejemplos de cirugías de catarata para que la red neuronal trabaje y entrene mejor ya que, como bien se ha dicho a lo largo de del desarrollo de este, necesitamos de una precisión que roce lo exacto para calcular donde queda la lente. Si bien es verdad que no podemos asegurar una mejor respuesta de la creación de una red con más ejemplos en la muestra. Claramente, habría que comprobarlo.

Una conclusión que resulta interesante también de la realización de este trabajo es la creación de las redes neuronales con los datos de las lentes en un mismo archivo Excel. Es decir, en este proyecto hemos trabajado con los 2 tipos de lente más usadas por separado, pero utilizar todas en un mismo archivo y obtener antes de la cirugía tanto el tipo de lente que conviene mejor usar para cada paciente como la posición efectiva de esta. Es una cuestión que se ha planteado durante la realización de este proyecto, ya que como se explica en el APARTADO... la máquina de biometría ofrece una ficha en la que según los parámetros y mediciones de cada paciente te recomienda el tipo de lente con la que mejor

se quedaría en cuanto a dioptrías. Aunque esto también es una elección del propio oftalmólogo que hablará con y conocerá al paciente y la vida cotidiana que puede llevar y qué es lo que mejor le vendría.

5. Bibliografía

- ALFONSO GALIPIENSO, MARIA ISABEL, CAZORLA QUEVEDO, MIGUEL ANGEL, COLOMINA PARDO, OTTO, ESCOLANO RUIZ, FRANCISCO, LOZANO ORTEGA, MIGUEL ANGEL. *Inteligencia artificial: modelos, técnicas y áreas de aplicación*. 2003.
- Dr. Ariel Prado-Serrano, Dra. Nayat Guadalupe Nava-Hernández. «Cálculo del poder dióptrico de lentes intraoculares.» *Mex Oftalmol*, 2009.
- Dr. Veena Bhardwaj, Associate Professor. «NCBI.» 5 de Oct de 2013.
[https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3843406/#:~:text=The%20Axial%20Length%20\(AL\)%20is,membrane%20%5B2%2C3%5D](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3843406/#:~:text=The%20Axial%20Length%20(AL)%20is,membrane%20%5B2%2C3%5D).
- Hamid Gharaee, Mojtaba Abrishami, Masoud Shafiee, and Asieh Ehsaei. «NBCI.» 18 de Abril de 2014.
[https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4003087/#:~:text=The%20white%2Dto%2Dwhite%20\(,%2D%20and%20megalocornea%5B1%5D](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4003087/#:~:text=The%20white%2Dto%2Dwhite%20(,%2D%20and%20megalocornea%5B1%5D).
- <https://www.masvision.es/blog/curiosidades/ojo-partes-funciones/>. s.f.
- Mas Vision*. 4 de Diciembre de 2020. <https://www.masvision.es/blog/curiosidades/ojo-partes-funciones/>.
- Matthew T. Feng,^a Michael W. Belin,^{a,*} Renato Ambrósio, Jr.,^b Satinder P.S. Grewal,^c Wang Yan,^d Mohamed S. Shaheen,^e Charles McGhee,^f Naoyuki Maeda,^g Tobias H. Neuhann,^h H. Burkhard Dick,ⁱ Saleh A. Alageel,^j and Andreas Steinmuellerk. «NBCI.» 30 de Abril de 2011.
[https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3729361/#:~:text=Anterior%20chamber%20depth%20\(ACD\)%20is%20an%20established%20anterior%20segment%20biometric,pr eoperative%20importance%20for%20intraocular%20surgery](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3729361/#:~:text=Anterior%20chamber%20depth%20(ACD)%20is%20an%20established%20anterior%20segment%20biometric,pr eoperative%20importance%20for%20intraocular%20surgery).
- Neural Designer*. s.f. <https://www.neuraldesigner.com/learning/tutorials/neural-network#PerceptronLayer>.
- Royo, Laura Jiménez. «Biometría y cálculo de lentes intraoculares.» Trabajo final de grado, Zaragoza, 2015.
- Torra, Ana Eddy Monsalve. «Sistemas de Ayuda a la Decisión Clínica en Enfermedades de Diagnóstico Complejo.» Tesis Doctoral, Alicante, 2017.
- Zeiss*. s.f. <https://www.zeiss.es/meditec/aplicaciones/oftalmologia-y-optometria/cirugia-de-cataratas/-optical-biometry/-introduccion-a-la-biometria-optica.html>.

6. ANEXOS

6.1. Anexo 1

DATASHEET

OBJETIVO

Calcular la distancia focal donde se debe colocar la lente intraocular para pacientes con cataratas mediante redes neuronales y comprobar si hay una mejora respecto a las fórmulas ya existentes.

DATASET:

Se han estudiado 104 pacientes, de los cuales 50 están operados de ambos ojos, con las biometrías realizadas pre y post operación con una diferencia de entre 1 y 10 meses. Estas, se han realizado con la máquina IOLMASTER 700, en el Departamento de Oftalmología de Hospital de la Santa Creu i Sant Pau. El documento Excel contiene 309 filas y 16 columnas, cuyos atributos serán los siguientes:

ATRIBUTOS

- 1- Fecha (dd/mm/aaaa)
- 2- Eye Side (OS= 1; OD= 0)
- 3- Nacimiento (dd/mm/aaaa)
- 4- Gender (male = 1; female = 0)
- 5- Lens (phakic = 1; pseudophakic = 0)
- 6- Vitreous (VitreousOnly = 0; Untreated = 1; postVitreotomy = 2)
- 7- Axial Length
- 8- Radio 1
- 9- Radio 2
- 10- Anterior Chamber Depth
- 11- Lens Thickness
- 12- Central Corneal Thickness
- 13- White to white
- 14- LIO (Alcon SA60AT = 1; ICB = 2; AMO ZA9003 = 3; Micropure 123 = 4)

RANGOS DE MEDI	
AL (Axial Length)	14 - 38 mm
R1 – R2 (Corneal Radius)	5 – 11 mm
ACD (Anterior Chamber Depth)	0.7 – 8 mm
LT (Lens Thickness)	1 – 10 mm (phakic eye) 0.13 – 2.5 mm (pseudophakic eye)
CCT (Central Corneal Thickness)	0.2 – 1.2 mm<
W2W (White To White)	8 – 16 mm

Axial length: distancia desde la superficie corneal hasta un pico de interferencia correspondiente al epitelio pigmentario de la retina o membrana de Bruchee. (Dr. Veena Bhardwaj 2013)

R1 – R2: son los radios corneales de la cara anterior y posterior de la córnea.

Anterior chamber depth: es un parámetro biométrico establecido del segmento anterior. (Matthew T. Feng,a Michael W. Belin,a,* Renato Ambrósio, Jr.,b Satinder P.S. Grewal,c Wang Yan,d Mohamed S. Shaheen,e Charles McGhee,f Naoyuki Maeda,g Tobias H. Neuhann,h H. Burkhard Dick,i Saleh A. Alageel,j and Andreas Steinmuellerk 2011)

Lens Thickness: grosor del cristalino, el cual crece a medida que aumenta la edad.

Central Corneal Thickness: espesor central de la córnea, es la diferencia entre las dos caras de la córnea.

White to White: El diámetro corneal de blanco a blanco (WTW) es la distancia horizontal entre los bordes del limbo corneal. (Hamid Gharaee, Mojtaba Abrishami, Masoud Shafiee, and Asieh Ehsaei 2014)

IOL: lente intraocular de las que hay cuatro tipos:

- Alcon SA60AT: tipo de lente formada por una pieza, coincidiendo con los diámetros de las anteriores. Comercializada por Alcon.
- ICB: es un tipo de lente formada por una sola pieza con un diámetro total de 13.0mm y un diámetro óptico de 6.0 mm. Comercializada por Johnson & Johnson Vision.

- AMO ZA9003: to de lente formada por tres piezas, coincidiendo en los diámetros con la ICB. También está comercializada por Johnson & Johnson Vision.
- Micropure 123: tipo de lente formada por una sola pieza con un diámetro total de 11.0mm y un diámetro óptico de 6.0 mm. Comercializada por Medicalmix

Bibliografía

ALFONSO GALIPIENSO, MARIA ISABEL, CAZORLA QUEVEDO, MIGUEL ANGEL, COLOMINA PARDO, OTTO, ESCOLANO RUIZ, FRANCISCO, LOZANO ORTEGA, MIGUEL ANGEL. *Inteligencia artificial: modelos, técnicas y áreas de aplicación*. 2003.

Dr. Ariel Prado-Serrano, Dra. Nayat Guadalupe Nava-Hernández. «Cálculo del poder dióptrico de lentes intraoculares.» *Mex Oftalmol*, 2009.

Dr. Veena Bhardwaj, Associate Professor. «NCBI.» 5 de Oct de 2013.
[https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3843406/#:~:text=The%20Axial%20Length%20\(AL\)%20is,membrane%20%5B2%2C3%5D](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3843406/#:~:text=The%20Axial%20Length%20(AL)%20is,membrane%20%5B2%2C3%5D).

Hamid Gharaee, Mojtaba Abrishami, Masoud Shafiee, and Asieh Ehsaei. «NBCI.» 18 de Abril de 2014.
[https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4003087/#:~:text=The%20white%2Dto%2Dwhite%20\(,%2D%20and%20megalocornea%5B1%5D](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4003087/#:~:text=The%20white%2Dto%2Dwhite%20(,%2D%20and%20megalocornea%5B1%5D).

<https://www.masvision.es/blog/curiosidades/ojo-partes-funciones/>. s.f.

Mas Vision. 4 de Diciembre de 2020. <https://www.masvision.es/blog/curiosidades/ojo-partes-funciones/>.

Matthew T. Feng,^a Michael W. Belin,^{a,*} Renato Ambrósio, Jr.,^b Satinder P.S. Grewal,^c Wang Yan,^d Mohamed S. Shaheen,^e Charles McGhee,^f Naoyuki Maeda,^g Tobias H. Neuhann,^h H. Burkhard Dick,ⁱ Saleh A. Alageel,^j and Andreas Steinmuellerk. «NBCI.» 30 de Abril de 2011.
[https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3729361/#:~:text=Anterior%20chamber%20depth%20\(ACD\)%20is%20an%20established%20anterior%20segment%20biometric,pr eoperative%20importance%20for%20intraocular%20surgery](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3729361/#:~:text=Anterior%20chamber%20depth%20(ACD)%20is%20an%20established%20anterior%20segment%20biometric,pr eoperative%20importance%20for%20intraocular%20surgery).

Neural Designer. s.f. <https://www.neuraldesigner.com/learning/tutorials/neural-network#PerceptronLayer>.

Royo, Laura Jiménez. «Biometría y cálculo de lentes intraoculares.» Trabajo final de grado, Zaragoza, 2015.

Torra, Ana Eddy Monsalve. «Sistemas de Ayuda a la Decisión Clínica en Enfermedades de Diagnóstico Complejo.» Tesis Doctoral, Alicante, 2017.

Zeiss. s.f. <https://www.zeiss.es/meditec/aplicaciones/oftalmologia-y-optometria/cirugia-de-cataratas/-optical-biometry-/introduccion-a-la-biometria-optica.html>.

<https://medicalmix.com/productos/lentes-intraoculares/lente-monofocal/lente-micropure-123-170/?p=4159>

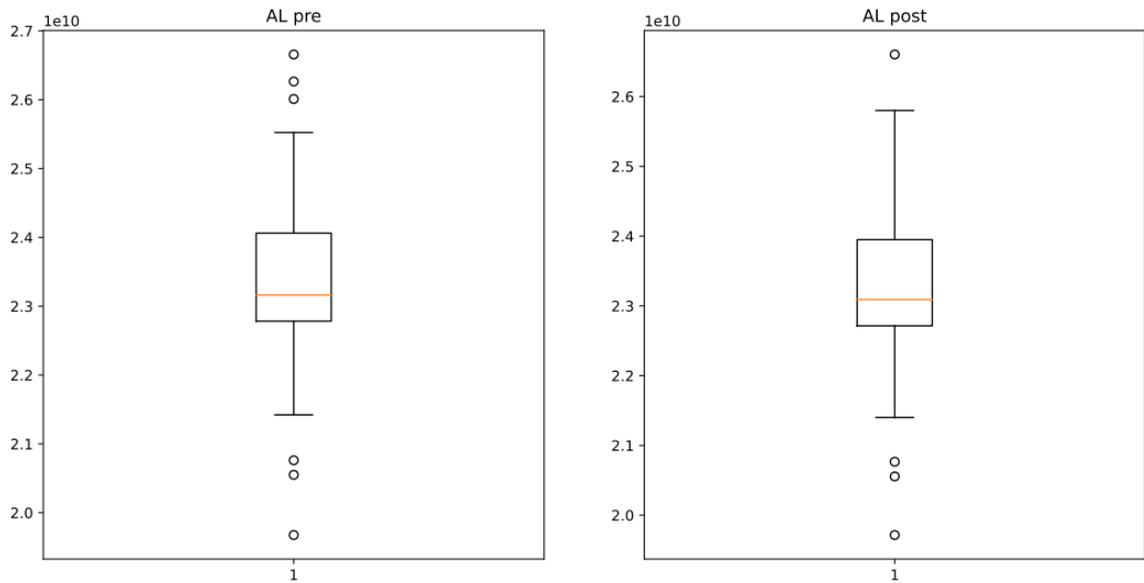
<https://www.dc-ophthalmology.com/products/227>

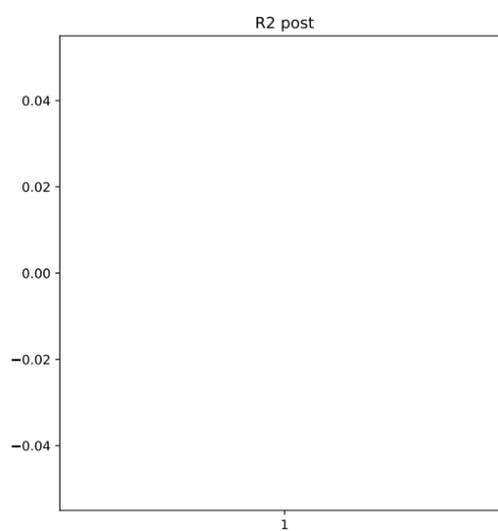
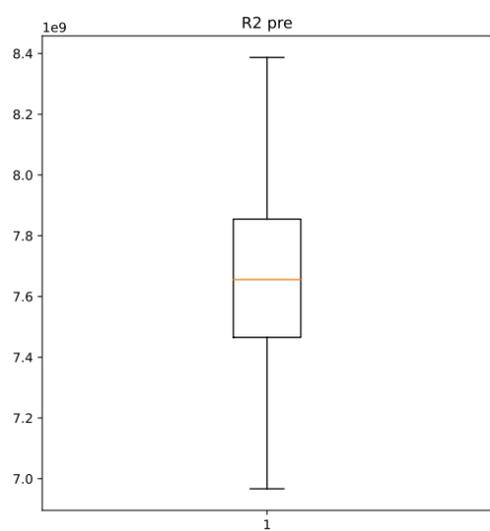
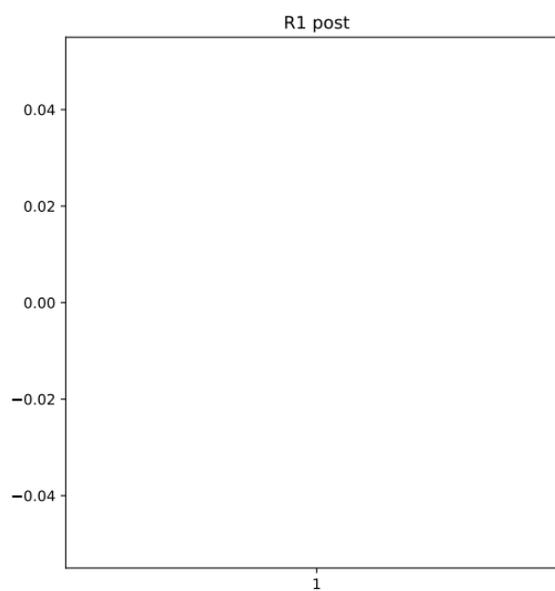
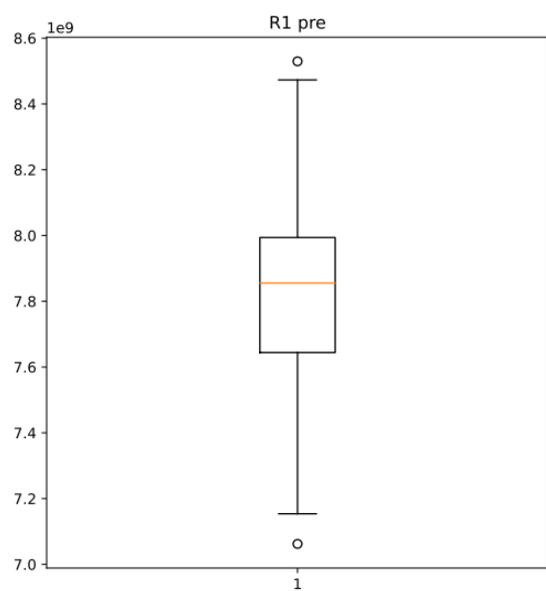
http://embed.widencdn.net/pdf/plus/alcon/ileeqhd0cs/10-500-123_us_en.pdf?u=4rq9d

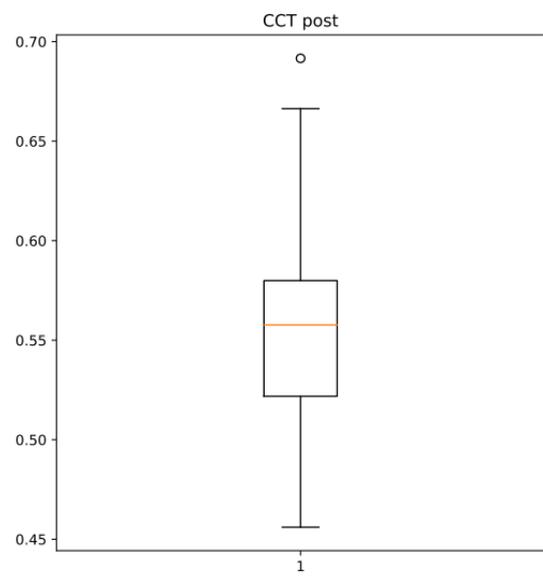
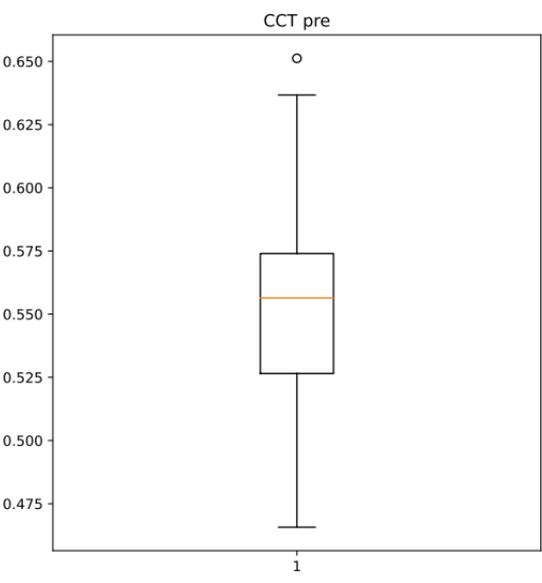
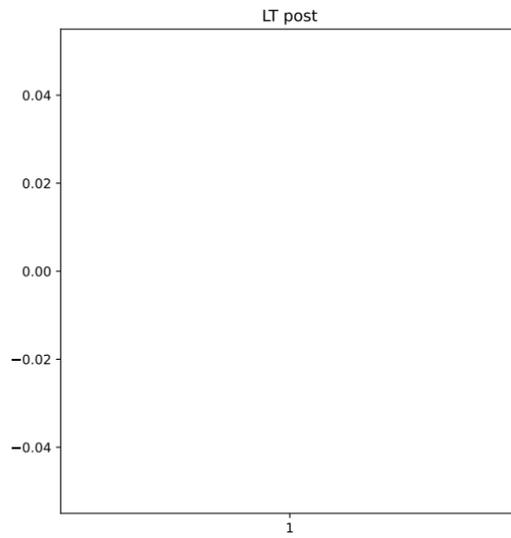
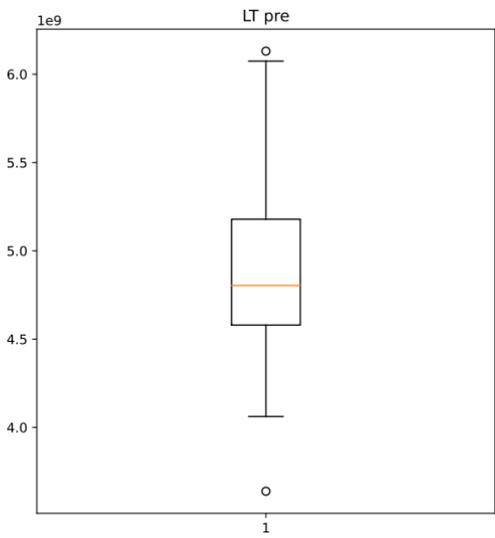
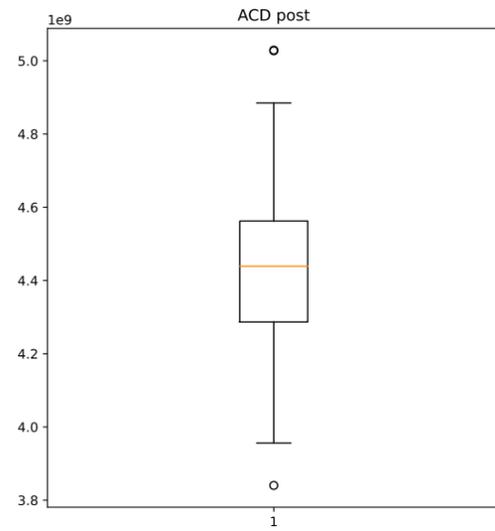
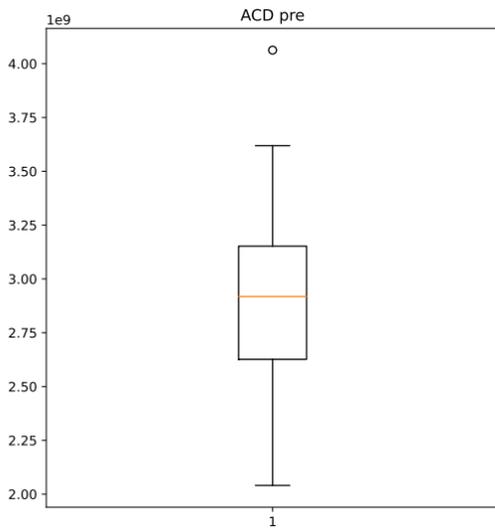
<https://www.precisionlens.net/products/ji-vision-products/lenses/tecnis-monofacol-model-za9003/>

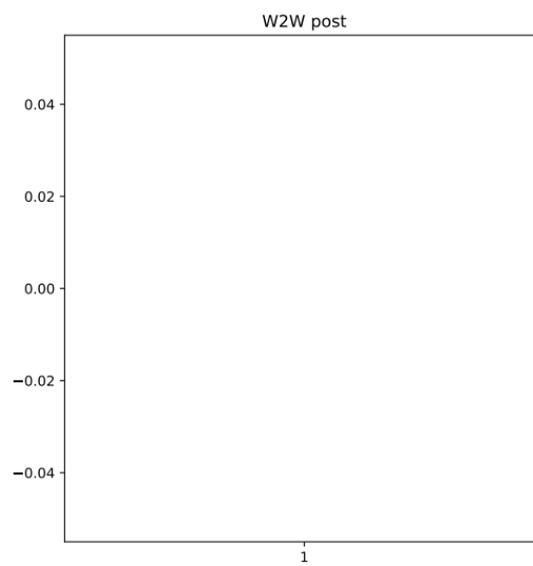
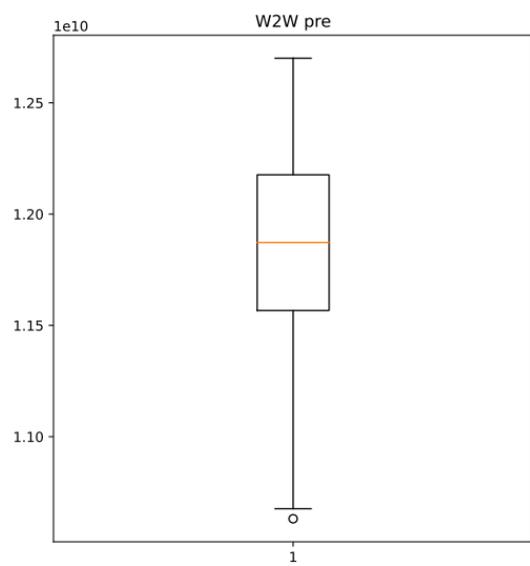
6.2. Anexo 2

6.2.1. Anexo 2.1: Diagramas lente 1

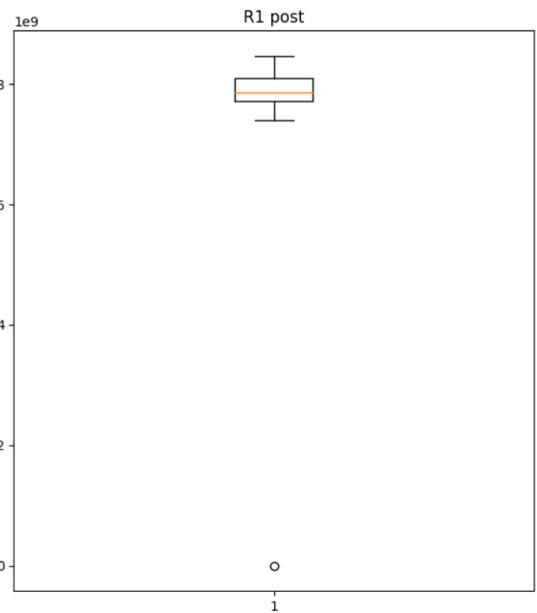
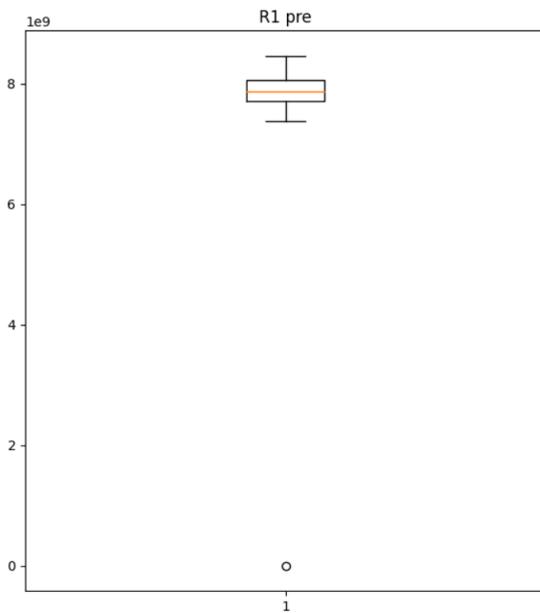
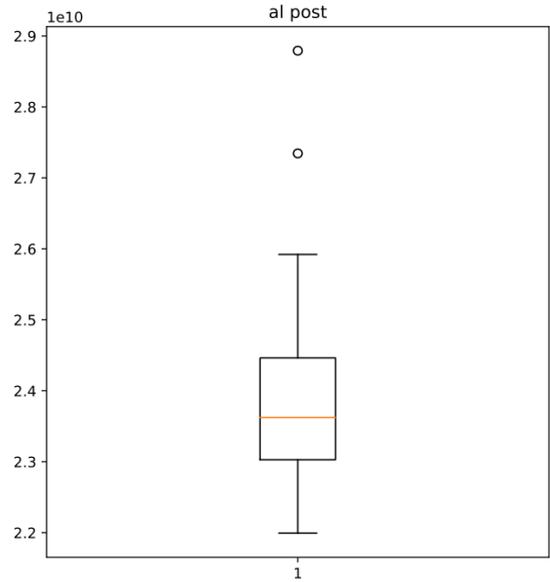
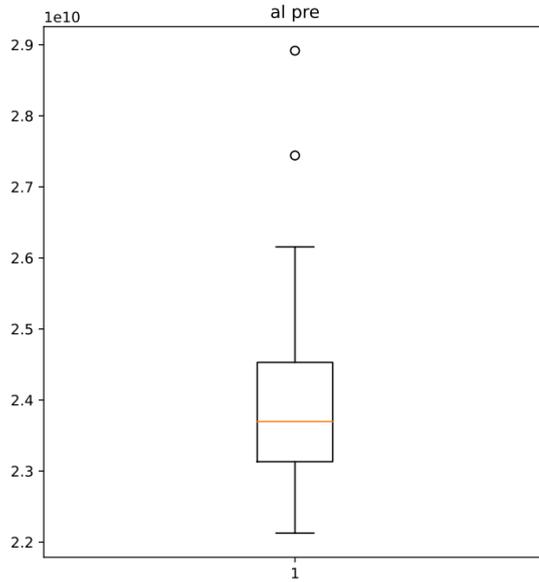


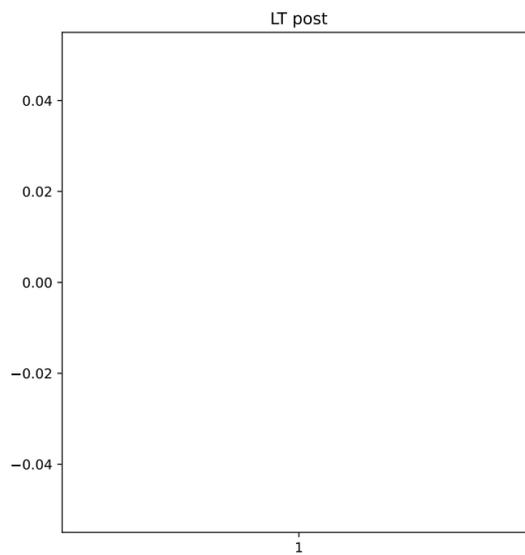
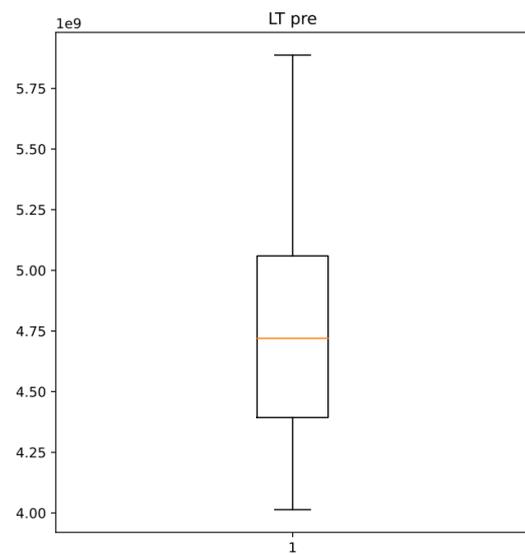
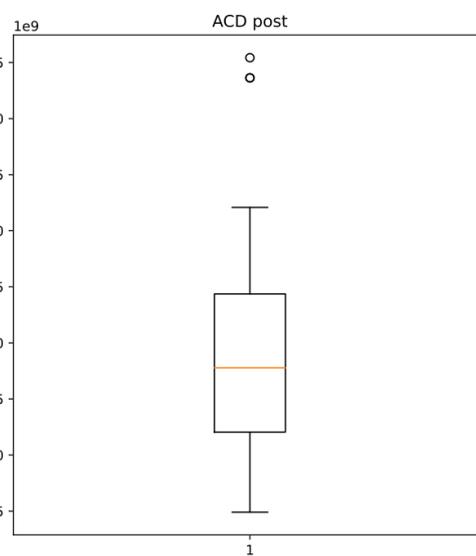
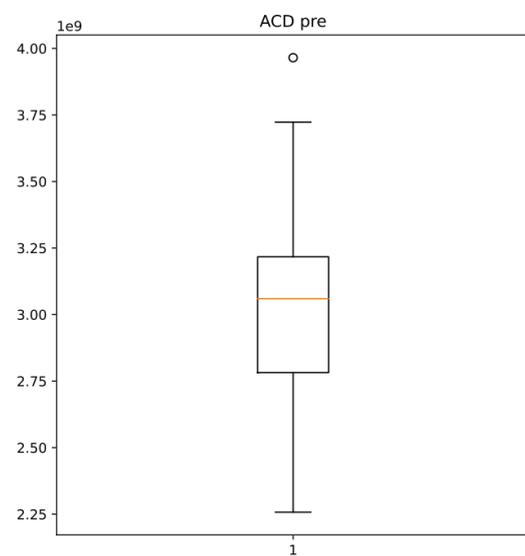
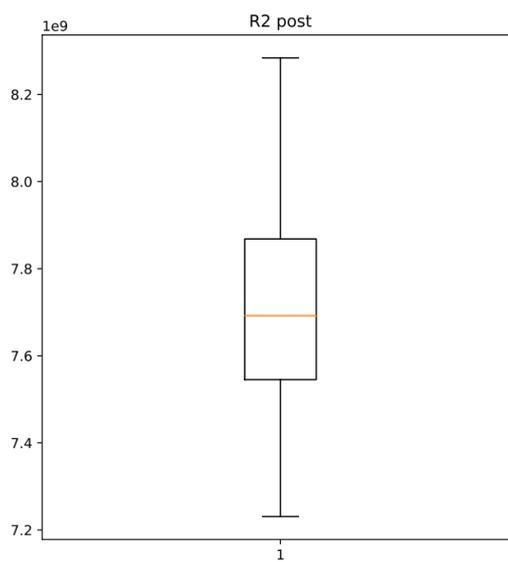
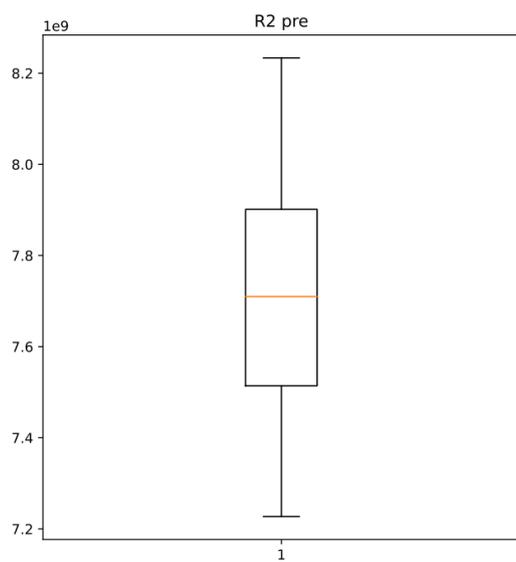


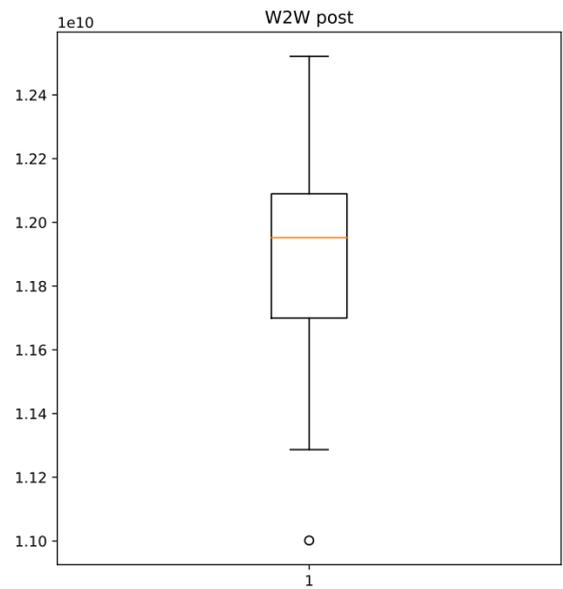
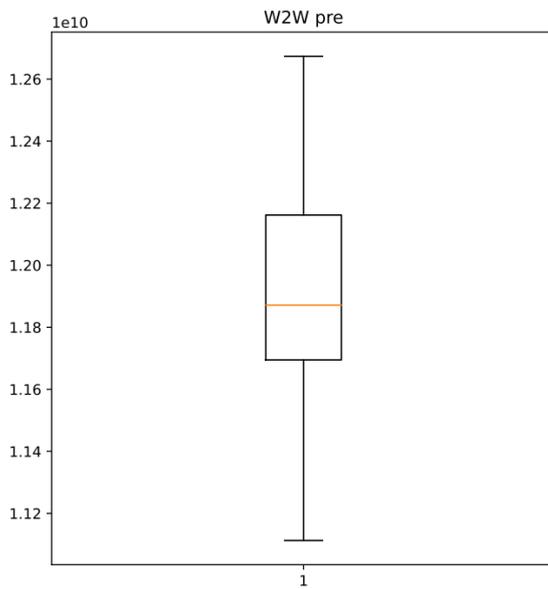
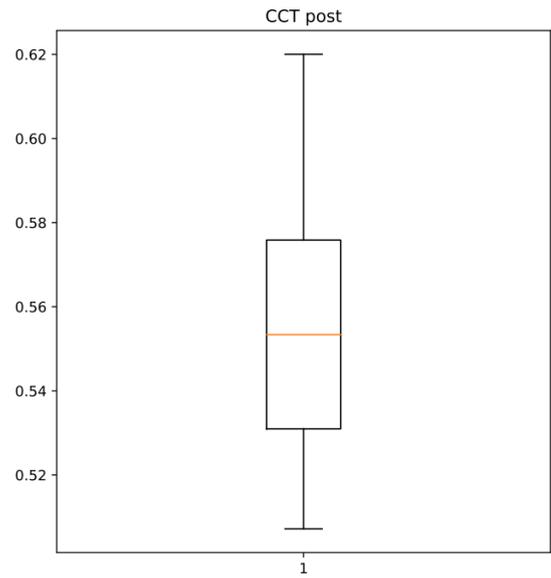
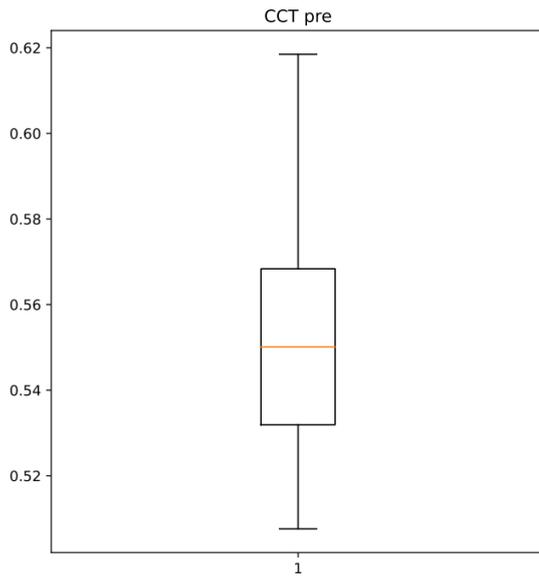




6.2.2. Anexo 2.2: Diagramas lente 3







6.3. Anexo 3

```
'''
```

```
Artificial Intelligence Techniques SL  
artelnics@artelnics.com
```

Your model has been exported to this python file.
You can manage it with the 'neural network' method.
Example:

```
sample = [input_1, input_2, input_3, input_4, ...]  
outputs = neural_network(sample)
```

```
Inputs Names:  
AL
```

```
R1  
R2  
ACD  
LT  
CCT  
W2W
```

Notice that only one sample is allowed as input. Batch of inputs are not yet implement, however you can loop through neural network function in order to get multiple outputs.

```
'''
```

```
import numpy as np
```

```
def scaling_layer(inputs):
```

```
    outputs = [None] * 7
```

```
    outputs[0] = inputs[0]  
    outputs[1] = inputs[1]  
    outputs[2] = inputs[2]  
    outputs[3] = inputs[3]  
    outputs[4] = inputs[4]  
    outputs[5] = inputs[5]  
    outputs[6] = inputs[6]
```

```
    return outputs;
```

```
def perceptron_layer_0(inputs):
```

```
    combinations = [None] * 3
```

```
    combinations[0] = -0.859253 -0.693542*inputs[0]  
+0.754456*inputs[1] +0.643311*inputs[2] +0.164063*inputs[3] -  
0.61731*inputs[4] -0.644226*inputs[5] +0.634338*inputs[6]
```

```

    combinations[1] = 0.933167 -0.0494995*inputs[0] -
0.688904*inputs[1] +0.0078125*inputs[2] +0.463989*inputs[3] -
0.188843*inputs[4] -0.440857*inputs[5] +0.137451*inputs[6]
    combinations[2] = 0.366333 +0.364441*inputs[0]
+0.511658*inputs[1] +0.443787*inputs[2] -0.0494385*inputs[3] -
0.753967*inputs[4] -0.264404*inputs[5] +0.669312*inputs[6]

    activations = [None] * 3

    activations[0] = np.tanh(combinations[0])
    activations[1] = np.tanh(combinations[1])
    activations[2] = np.tanh(combinations[2])

    return activations;

def perceptron_layer_1(inputs):

    combinations = [None] * 1

    combinations[0] = -0.92981 +0.0339966*inputs[0]
+0.325928*inputs[1] -0.147583*inputs[2]

    activations = [None] * 1

    activations[0] = combinations[0]

    return activations;

def unscaling_layer(inputs):

    outputs = [None] * 1

    outputs[0] = inputs[0]*0.5944149494+4.434675217

    return outputs

def bounding_layer(inputs):

    outputs = [None] * 1

    outputs[0] = inputs[0]

    return outputs

def neural_network(inputs):

    outputs = [None] * len(inputs)

    outputs = scaling_layer(inputs)
    outputs = perceptron_layer_0(outputs)
    outputs = perceptron_layer_1(outputs)

```

```
outputs = unscaling_layer(outputs)
outputs = bounding_layer(outputs)

return outputs;
```