



DIAGNÓSTICO AUTOMATIZADO DE GLAUCOMA MEDIANTE HERRAMIENTAS DE MACHINE LEARNING APLICADAS A DATOS DE PUPILOMETRÍA CROMÁTICA

Manuel Zamorano Canales¹, Carlos Navarro Clavería^{1,2,4}, Iván Plaza Rosales^{3,4}

¹ Departamento de Ingeniería Eléctrica, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile.

² Laboratory of Scientific Image Analysis (SCIAN-Lab), Facultad de Medicina, Universidad de Chile.

³ Departamento de Tecnología Médica, Facultad de Medicina de la Universidad de Chile.

⁴ Laboratorio de Neurosistemas, Departamento de Neurociencia, Facultad de Medicina de la Universidad de Chile.

RESUMEN

El glaucoma es una enfermedad ocular crónica que daña el nervio óptico y es la principal causa de ceguera irreversible en el mundo, afectando al 3.54% de la población global entre 40 y 80 años [1] y al 2% de la población en Chile. Debido a su progresión lenta y la ausencia de síntomas en etapas tempranas, su diagnóstico suele ser tardío y asociado a un importante daño estructural. La pupilometría cromática surge como una técnica prometedora para analizar la respuesta pupilar a estímulos lumínicos, lo que podría revelar disfunciones en etapas tempranas del glaucoma [2]. Este trabajo tuvo como objetivo desarrollar una herramienta de diagnóstico automatizado, utilizando *machine learning* para identificar patrones en datos de pupilometría cromática.

MATERIALES Y MÉTODO

Se implementó un *setup* de pupilometría cromática con un sistema de registro comercial (*Pupil Lab*) y un sistema de estimulación lumínica de confección propia. Los estímulos fueron luces rojo, verde, azul y blanco, en formato *flash* (1 segundo a 250 lux) y *rampa* (1 minuto, con aumento a 250 lux en los primeros 20 segundos). El estudio se realizó con 40 individuos: 20 pacientes con glaucoma y 20 controles sanos. El preprocesamiento de los datos incluyó la segmentación de señales y la aplicación de filtros, mientras que la extracción de características (Figura 1) se enfocó en parámetros estadísticos relevantes.

Ejemplo de extracción de características sobre una de las señales

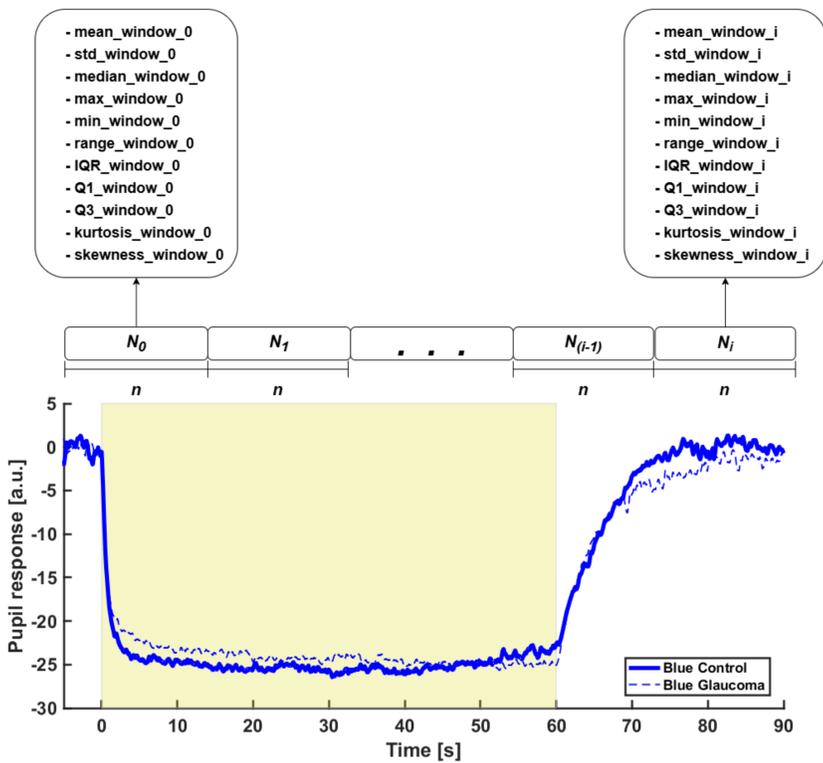


Figura 1: Respuesta pupilar media al estímulo de luz azul en rampa (1 min, con incremento inicial de 20s hasta 250 lux). Grupo control (línea azul continua) y glaucoma (línea azul discontinua).

Además, se experimentó con técnicas de aumento de datos. Los modelos predictivos probados incluyen *XGBoost* y un modelo *dummy* como referencia. Se evaluaron ventanas de 15, 25, 50, 100 y 150 muestras para la segmentación de las señales. Se desarrollaron y evaluaron tres enfoques experimentales:

- Caso base:** Se utilizó el conjunto de datos original, sin modificaciones adicionales.
- Selección de ventanas:**
 - Se seleccionaron los primeros 20 segundos de las señales.
 - Se extrajeron ventanas aleatorias, acumulando un total de 20 segundos de señal.
- Aislamiento de características:**
 - Se seleccionaron exclusivamente los estímulos tipo *flash*, limitados a los primeros 20 segundos.
 - Se seleccionaron sólo las respuestas a estímulos tipo *rampa*.

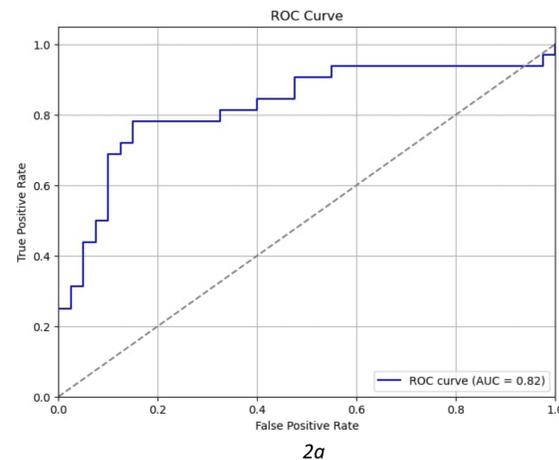
RESULTADOS Y DISCUSIÓN

Mejores desempeños en enfoques experimentales para detección de glaucoma

Enfoque experimental	Muestras por ventana	Filtrado de señales	Aumento de datos	Accuracy
Caso Base	100	si	si	69,44%
Primeros 20 segundos	25	no	si	68,75%
20 segundos aleatorios	25	no	no	66,67%
Sólo flash	50	si	si	72,22%
Sólo rampa	150	si	no	79,17%

Tabla 1: Accuracy, representa el porcentaje de clasificaciones correctas del modelo en cada configuración. Los enfoques "Sólo flash" y "Sólo rampa" lograron los mejores resultados.

Curva ROC y Matriz de Confusión del Mejor Modelo (Enfoque con Estímulos Tipo Rampa)



True label \ Predicted label	Control	Glaucoma
Control	34 (85,00%)	6 (15,00%)
Glaucoma	9 (28,12%)	23 (71,88%)

Figura 2a: Curva ROC que muestra la capacidad del modelo para distinguir glaucoma de control. Figura 2b: Matriz de confusión que indica el rendimiento en clasificaciones correctas por clase.

- ✓ Los resultados (Tabla 1, Figuras 2a y 2b) sugieren que la pupilometría cromática, combinada con técnicas de *machine learning*, es prometedora para la detección temprana del glaucoma.
- ✓ La segmentación y filtrado de señales demostraron ser factores clave para mejorar la precisión del modelo.
- ✓ Los enfoques con estímulos tipo *flash* y el uso de aumento de datos también mejoraron los resultados, destacando la importancia de un preprocesamiento adecuado y de la elección de características.

Trabajo futuro:

- Es fundamental optimizar la recolección de datos y aumentar la diversidad de muestras para mejorar la robustez del modelo.
- Futuras investigaciones deberían enfocarse en ampliar y mejorar el conjunto de datos para aumentar la generalización del modelo.
- Se espera que estos avances permitan desarrollar una herramienta diagnóstica confiable y eficaz para el glaucoma.

REFERENCIAS

- [1] Tham, Y.-C., Li, X., Wong, T., Quigley, H., Aung, T., y Cheng, C., "Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis", *Ophthalmology*, vol. 121, pp. 2081–2090, November 2014.
- [2] Arévalo-López, C., Gleitze, S., Madariaga, S., y Plaza-Rosales, I., "Pupillary response to chromatic light stimuli as a possible biomarker at the early stage of glaucoma: a review", *International Ophthalmology*, vol. 43, pp. 343–356, January 2023.

FINANCIAMIENTO

Fondo Concursable de Investigación DETEM 2022 – 570372
Iniciativa Científica Milenio ICN09_015

AGRADECIMIENTOS

Servicio de Oftalmología del HCUCH