

# Mecanismos de atención de segundo orden para la segmentación de lesiones de cáncer de próstata en secuencias de resonancia magnética biparamétrica

---

**Mateo Gerónimo Ortiz Cruzate**

**Director:** Fabio Martínez Carrillo, PhD.

**Codirector:** Juan Olmos Rojas PhD (c).

BIVL<sup>2</sup>ab, Universidad Industrial de Santander, Bucaramanga, Colombia.





# Agenda

---

1. Introducción y fundamentos.
1. Trabajos relacionados.
1. Problema de investigación.
1. Método propuesto.
1. Resultados.
1. Conclusiones y trabajo futuro.


# 1. Introducción y fundamentos

- Cáncer de próstata y su diagnóstico



## Cáncer de próstata (PCa)

- Es la **segunda causa** de muerte por cáncer en hombres en el mundo.
- Más de **1,4 millones** de casos y **370 mil** muertes en 2020.
- Se proyecta un **aumento** de hasta **96%** en incidencia y **136%** en mortalidad para 2050.



## Ruta diagnóstica



Biopsi  
a


- Prueba del Antígeno Prostático Específico (PSA): Análisis de sangre que mide los niveles de una proteína producida por la próstata.

[3] Schröder et. al. (2014) "The European randomized study of screening for prostate cancer-prostate cancer mortality at 13 years of follow-up" Lancet.

[4] (2024) "EAU Guidelines," European Association of Urology (EAU) Annual Congress Paris 2024. Available at: <https://uroweb.org/guidelines>.

[5] Louie, et al.(2015) "Do prostate cancer risk models improve the predictive accuracy of PSA screening? A meta-analysis." Annals of Oncology.

## Ruta diagnóstica



- Prueba del Antígeno Prostático Específico (PSA): Análisis de sangre que mide los niveles de una proteína producida por la próstata.
- Examen Digital Rectal (DRE): Examen físico invasivo para detectar anomalías en la próstata.

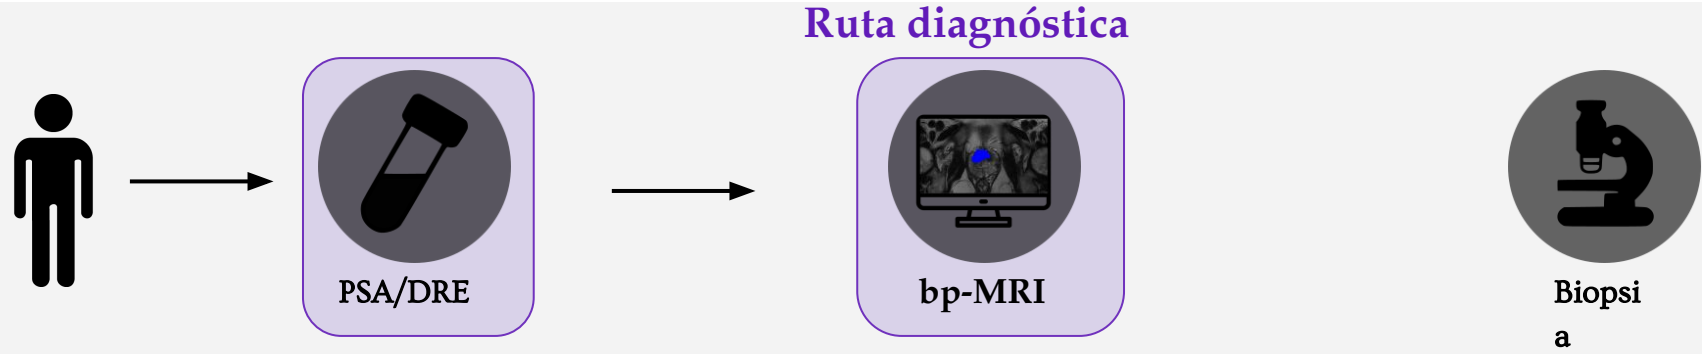
## Ruta diagnóstica




El uso exclusivo de PSA y DRE, además de ser **invasivo**, aumenta el riesgo de pasar por **alto** lesiones csPCa, lo que puede llevar a **diagnósticos incorrectos**.

El uso de PSA/DRE puede conducir a un sobrediagnóstico en aproximadamente el 40-50 % de los casos<sup>3</sup>.







- La **resonancia magnética (MRI)**, utilizada como prueba previa a la biopsia, ha reducido las biopsias innecesarias en un **23%** y ha mejorado la **detección** del PCa.



T2W



DWI




ADC


- **Imágenes ponderadas en T2 (T2W):** Permiten una observación detallada de la anatomía de la glándula prostática.
- **Imágenes ponderadas por difusión (DWI):** Detectan anomalías evaluando el movimiento de las moléculas de agua (difusión) dentro de los tejidos.
- **Mapas de coeficiente de difusión aparente (ADC):** Cuantifican la difusión del agua.



T2W





DWI



ADC



- T2W y ADC: Áreas hipointensas
- DWI: Áreas hiperintensas.



CZ Zona central  
PZ Zona periférica


- Zona Central (CZ): Presenta **baja** prevalencia de cáncer, predominando afecciones benignas como la hiperplasia prostática.
- Zona Periférica (PZ): Representa el **70–80%** del volumen prostático y origina cerca del **85%** de los casos de PCa.

## Ruta diagnóstica




El análisis **depende del criterio del especialista**, requiere mucho tiempo y un alto nivel de experiencia, lo que genera variabilidad en la interpretación.

## 2. Trabajos relacionados



### U-Net


- La entrada de la red es la **bp-MRI** (T2W, ADC, DWI)



### U-Net

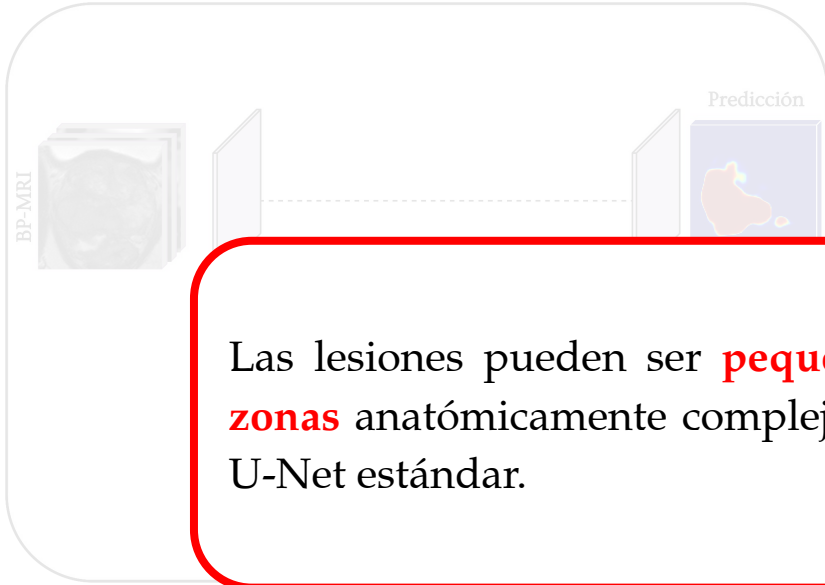
- La entrada de la red es la **bp-MRI** (T2W, ADC, DWI)
- El **codificador** reduce la resolución espacial de la imagen hasta un embebido compacto.






### U-Net

- La entrada de la red es la **bp-MRI** (T2W, ADC, DWI)
- El **codificador** reduce la resolución espacial de la imagen hasta un embebido compacto.
- El **decodificador** utiliza este embebido para reconstruir la segmentación.



Las lesiones pueden ser **pequeñas**, de **bajo contraste** o ubicarse en **zonas** anatómicamente complejas, lo que **limita** el desempeño de una U-Net estándar.

- La entrada de la red es la **bp-MRI** (T2W, ADC, DWI)
- El **codificador** reduce la resolución



## U-Net

- La entrada de la red es la **bp-MRI** (T2W, ADC, DWI)
- El **codificador** reduce la resolución espacial de la imagen hasta un embebido compacto.
- El **decodificador** utiliza este embebido para reconstruir la segmentación.

**Atención**



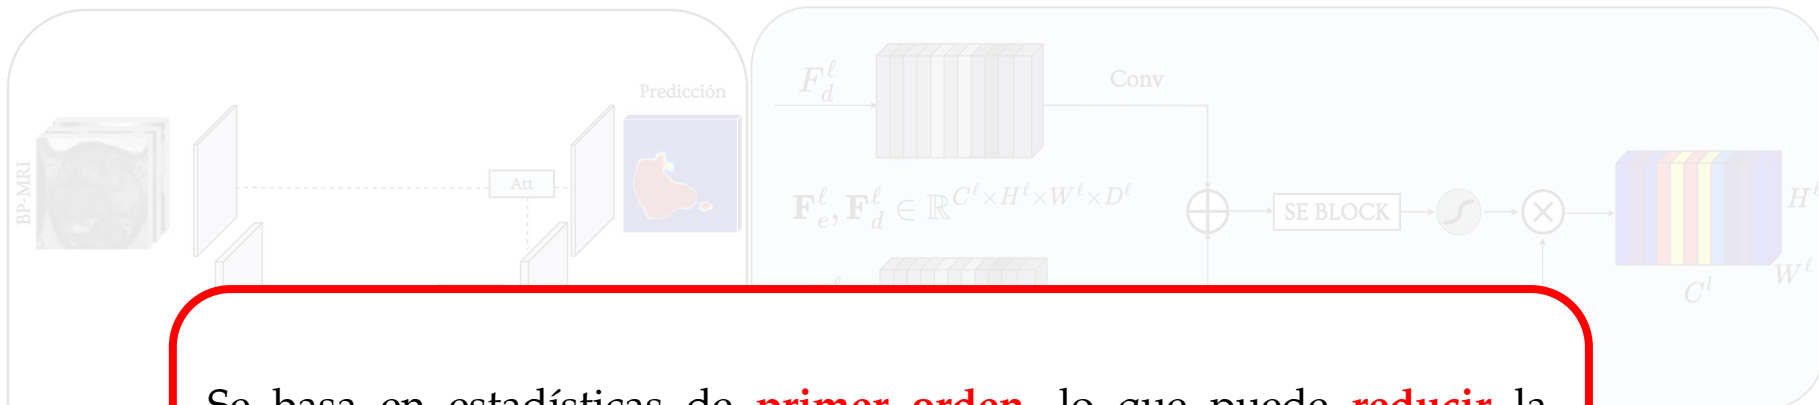
## Trabajos relacionados: Attention U-Net



- Filtra información irrelevante, lo que **reduce el ruido** y refina los mapas de características.



## Trabajos relacionados: Squeeze and Excitation



Se basa en estadísticas de **primer orden**, lo que puede **reducir** la sensibilidad a regiones pequeñas o sutiles de interés. También puede generar una alta **dependencia** a la distribución de los datos.

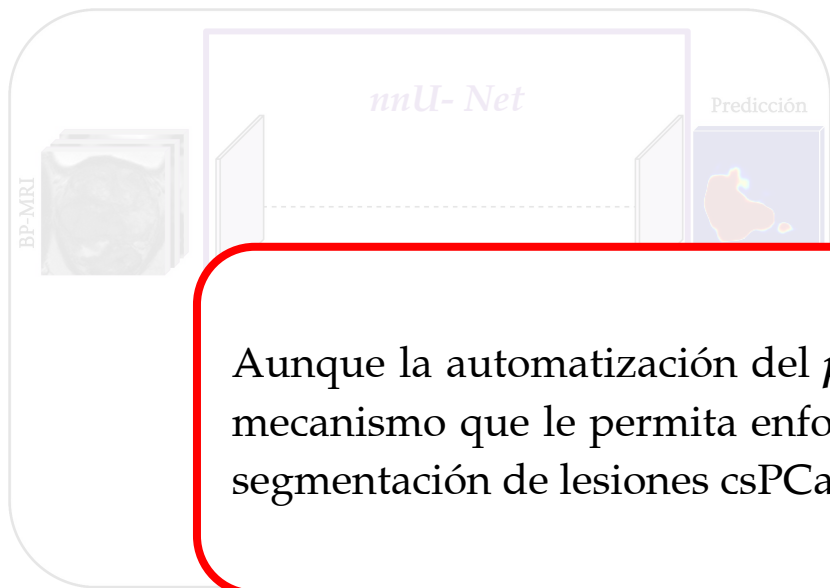
$$s_c = \frac{1}{C} \sum_{i=1}^C (g(z_i; W)) = \frac{1}{C} \sum_{i=1}^C (W_2 \phi(W_1 z_i))$$

$$\tilde{x}_c = F_{scale}(u_c, s_c) = s_c u_c$$

- Prioriza regiones relevantes al **recalibrar canales** de los bancos de características.

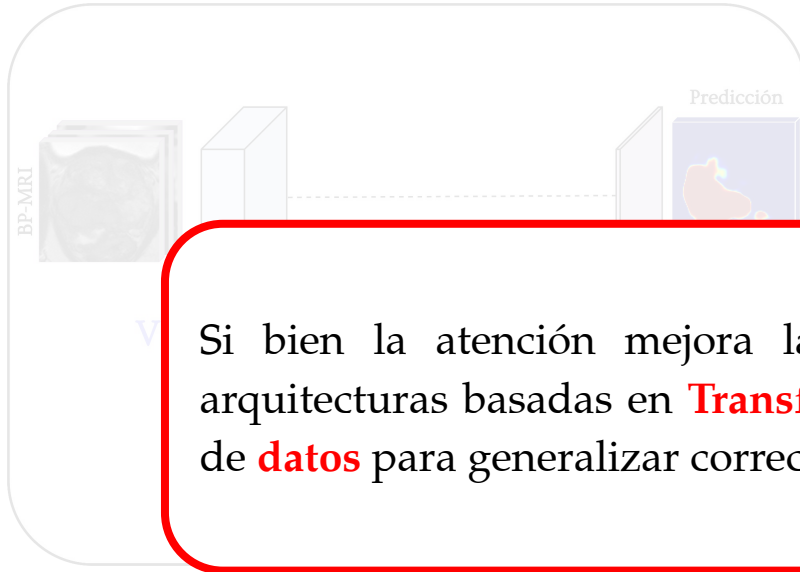


## Trabajos relacionados: nnU-Net



Aunque la automatización del *pipeline* es efectiva, la **red carece** de un mecanismo que le permita enfocarse en las regiones relevantes para la segmentación de lesiones csPCa.

- *Framework* automatizado para la segmentación médica basado en U-Net.
- Ajusta automáticamente su arquitectura, lo según
- Incorporan máscaras probabilísticas zonales.



- Captura dependencias globales: modela relaciones a larga distancia entre regiones de la imagen.

Si bien la atención mejora la representación de las bp-MRI, las arquitecturas basadas en **Transformers** requieren **grandes volúmenes de datos** para generalizar correctamente.





Estos métodos son apropiados dado el desafío de la cantidad limitada de datos. Sin embargo:


- Las arquitecturas que integran métodos de atención basados en transformers **requieren grandes volúmenes de datos** para generalizar adecuadamente.
- Enfoques basados en estadísticos de primer orden presentan **alta sensibilidad a la distribución de los datos** y pueden inducir **pérdida de información** durante la compresión de características.




## 2. Trabajos relacionados

- Descriptores de segundo orden






- El **SPD Pooling** genera matrices simétricas definidas positivas (SPD), que resumen las correlaciones entre características como descriptores de segundo orden.
- Las matrices SPD pertenecen a un espacio **distinto** al euclidiano, la **variedad Riemanniana**.



- Una SPD representa un **punto** en la variedad Riemanniana.
- Este espacio es **curvo**, y **no euclidiano**.
- Deben ser operadas mediante **geodésicas**.





Los descriptores de **segundo orden**:


- En tareas de segmentación han sido **poco explorados** en la literatura, y su aplicación en el contexto específico de la **segmentación de lesiones de cáncer de próstata** es **nula**.
- Han demostrado ser una buena opción para trabajar **con pocos datos**.
- No reducen **abruptamente** la información, como los de **primer orden**.

### 3. Problema de investigación



## Problema de investigación

- Las representaciones generadas por herramientas computacionales suelen **ignorar el aprendizaje de relaciones entre características** dentro de la arquitectura, lo que limita su capacidad de generalización.
- Esta limitación incrementa la necesidad de **grandes volúmenes de datos anotados**, los cuales son escasos en la práctica clínica por su alto costo y tiempo requerido.





## Pregunta de investigación

---

¿Cómo integrar **descriptores de segundo orden** mediante un **módulo de atención** entre representaciones profundas biparamétricas para la segmentación de lesiones clínicamente significativas de cáncer de próstata?





## Objetivo General

---


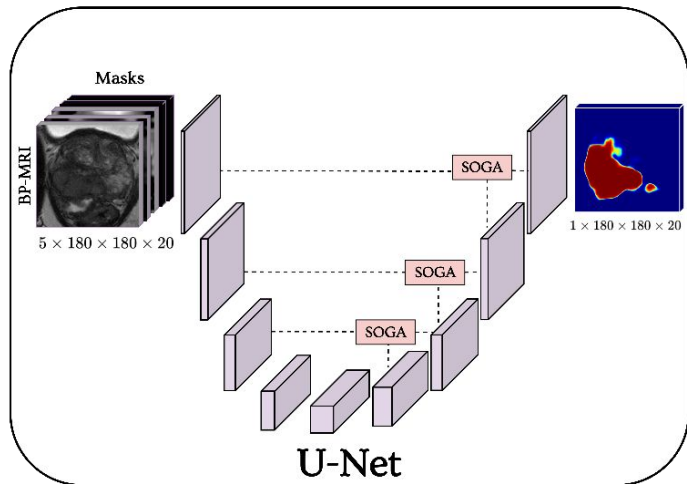
Desarrollar un mecanismo de atención que integre **descriptores de segundo orden** para soportar la segmentación de lesiones clínicamente significativas de cáncer de próstata (csPCa) en secuencias de resonancia magnética biparamétrica (bp-MRI).



## 4. Método propuesto


- Second Order Geometric Attention Module




# Método propuesto

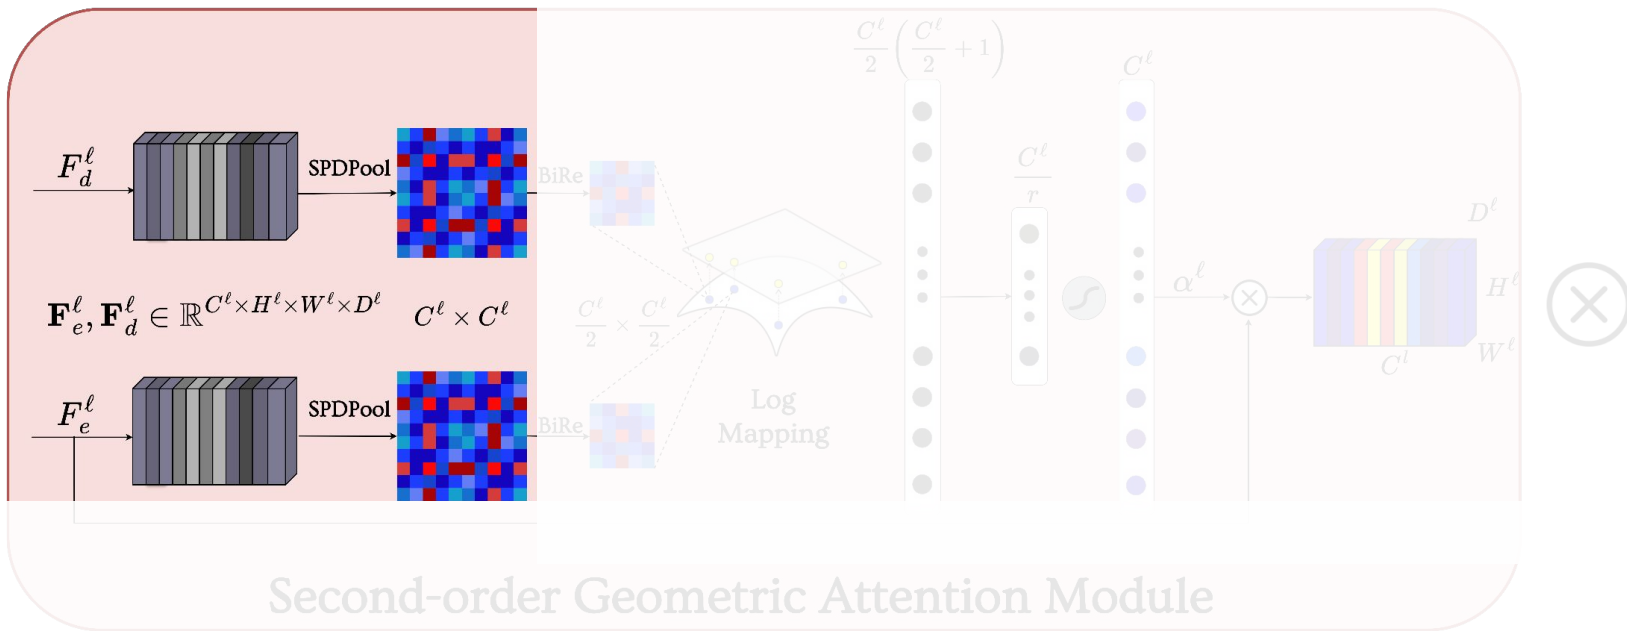







- Donde  $F_e^l$  y  $F_d^l$  son representaciones del encoder y decoder, respectivamente.
- $\alpha^l$  Son los coeficientes de atención aprendidos que ponderan las características.










## Módulo Riemanniano


- Cálculo de una nueva SPD (*BiMap*):



$$\mathbf{S}_{\ell} = f_{BiMap}(\mathbf{S}_{\ell-1}) = \mathbf{W}_k \mathbf{S}_{\ell-1} \mathbf{W}_k^{\top}$$

- **BiMap**: aprende descriptores SPD más compactos.

- Regularización de eigenvalores (*ReEig*):



$$\mathbf{S}_{\ell} = f_{ReEig}(\mathbf{S}_{\ell-1}) = \mathbf{U}_{\ell-1} \max(\varepsilon \mathbf{I}, \mathbf{\Sigma}_{\ell-1}) \mathbf{U}_{\ell-1}^{\top}$$

$$\mathbf{S}_{\ell-1} = \mathbf{U}_{\ell-1} \mathbf{\Sigma}_{\ell-1} \mathbf{U}_{\ell-1}^{\top}$$


- **ReEig**: Regulariza las matrices SPD.

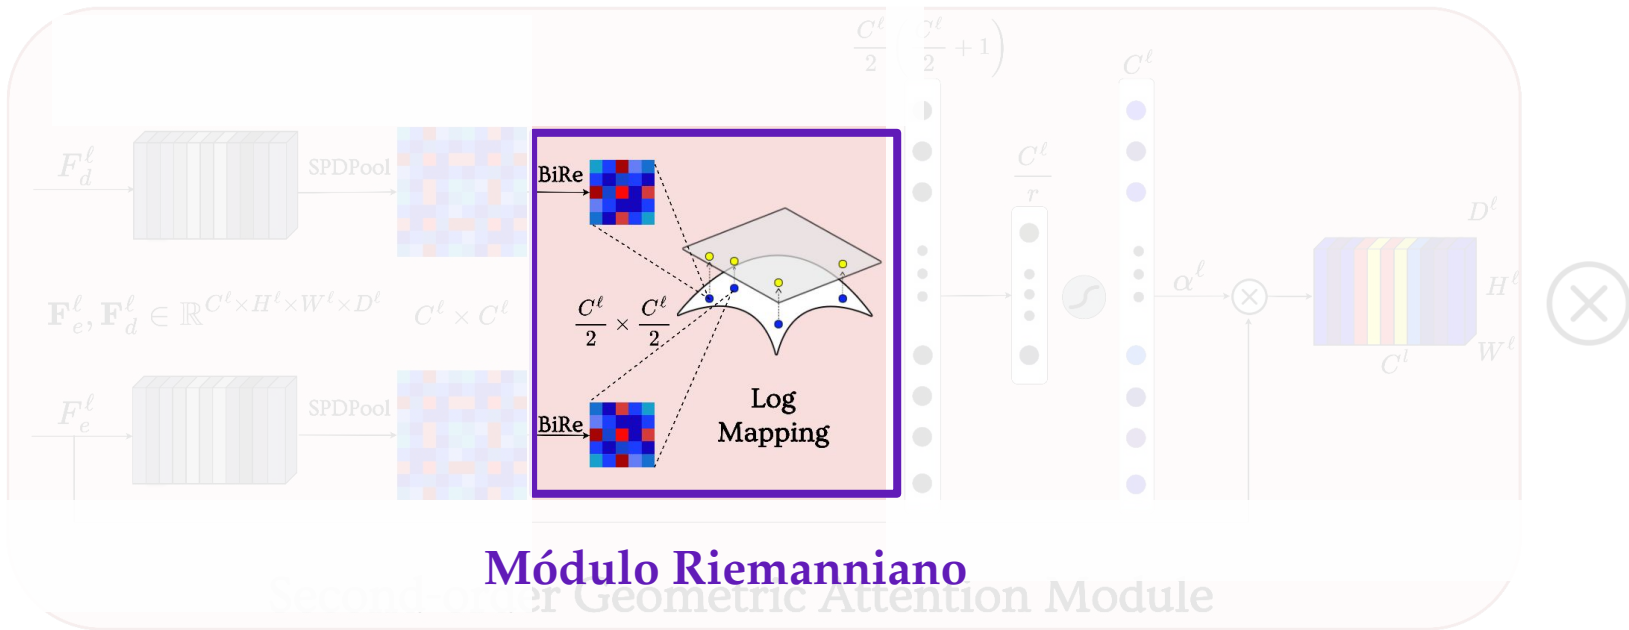
La concatenación de estas capas se conoce como BiRe.

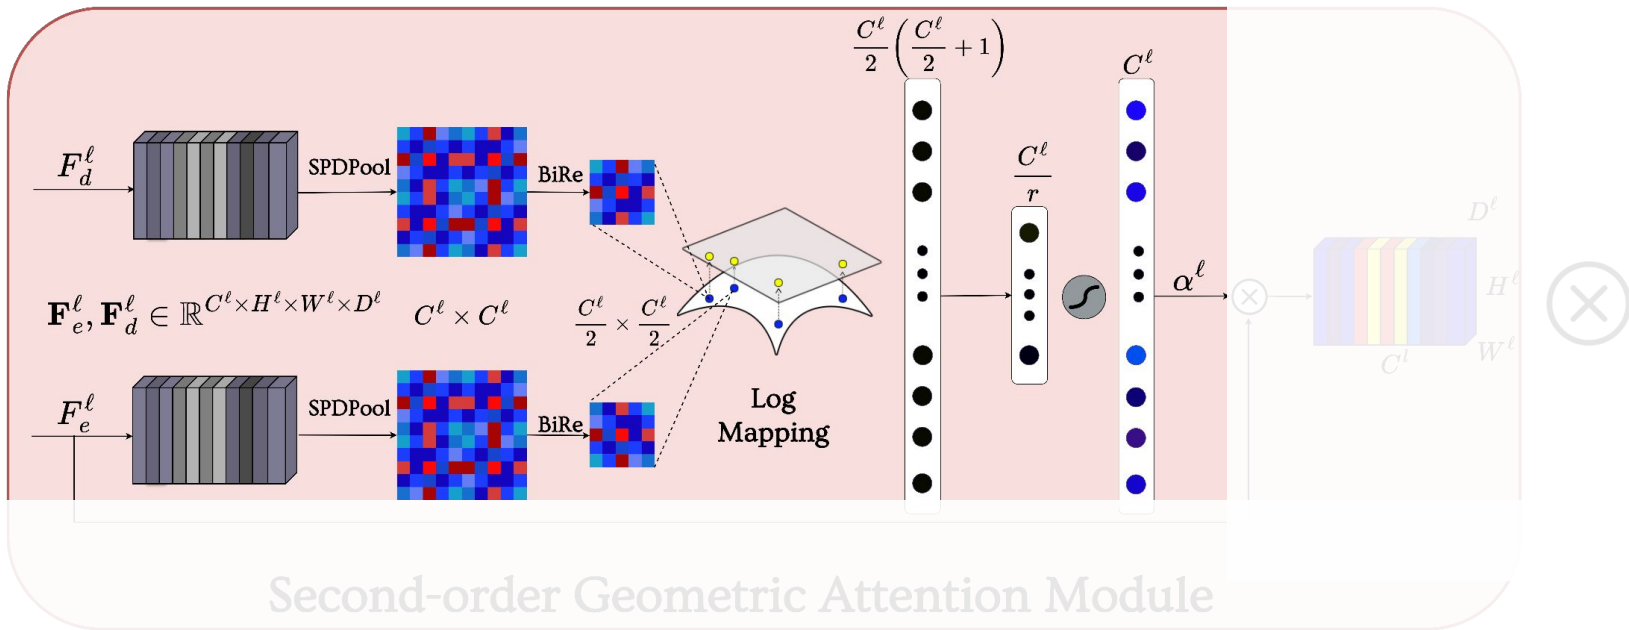
- Proyección al espacio euclidiano (*Mapeo Logarítmico*)


$$\mathbf{S}_\ell = f_{LogEig}(\mathbf{S}_{\ell-1}) = \mathbf{U}_{\ell-1} \log(\Sigma_{\ell-1}) \mathbf{U}_{\ell-1}^\top$$


- Permite mapear las matrices SPD del espacio Riemanniano a un espacio **euclídeo** manteniendo su estructura geométrica.









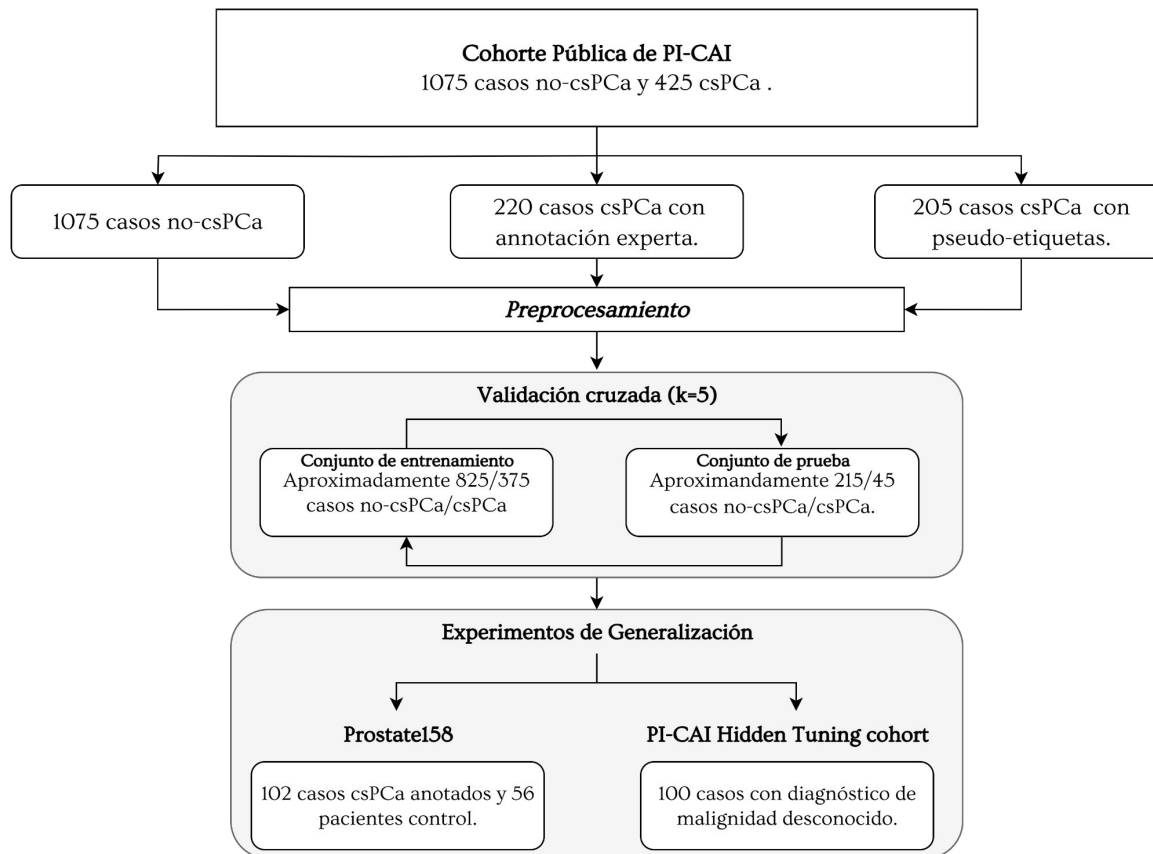


- Donde  $F_e^l$  y  $F_d^l$  son representaciones del encoder y decoder, respectivamente.
- $\alpha^l$  Son los coeficientes de atención aprendidos que ponderan las características.

## 4. Método propuesto

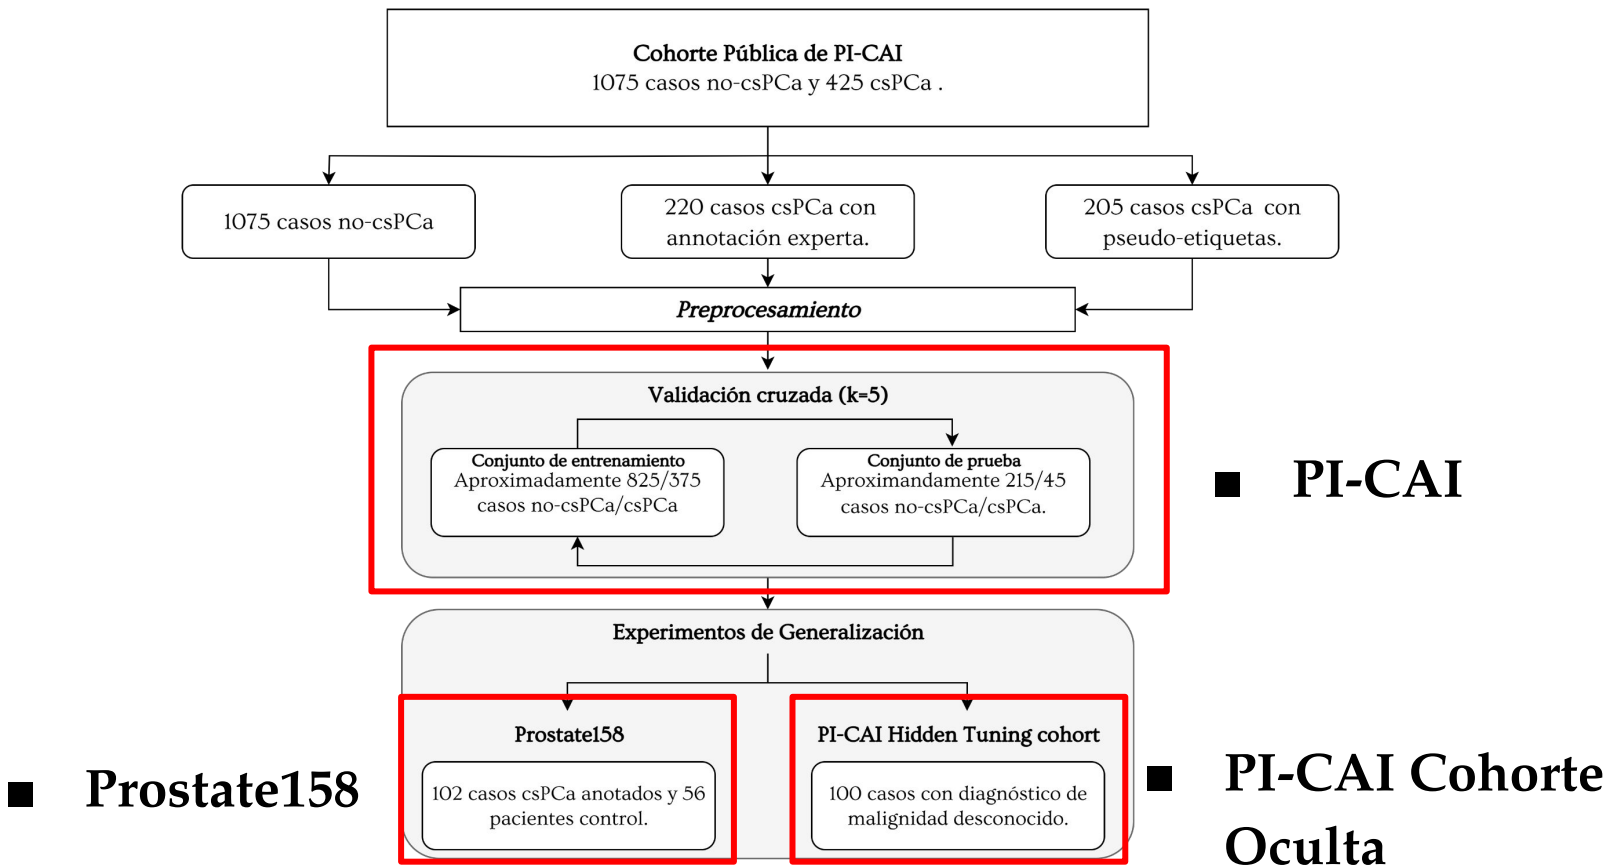
- Datos

# Método propuesto: Configuración experimental





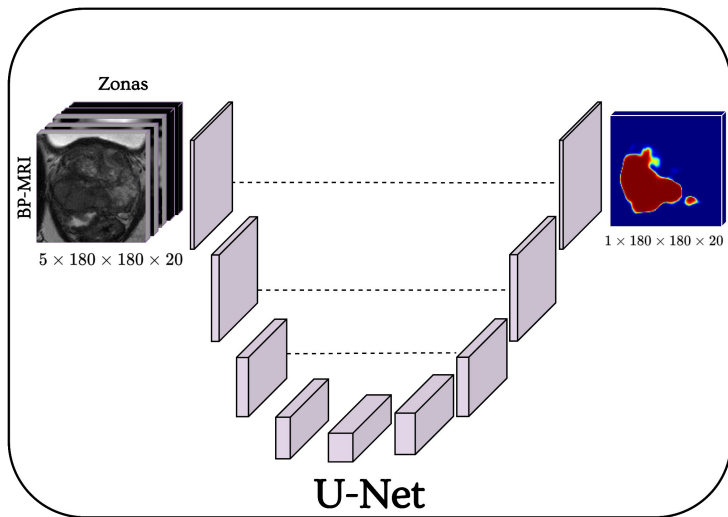
# Método propuesto: Configuración experimental



## 4. Método propuesto

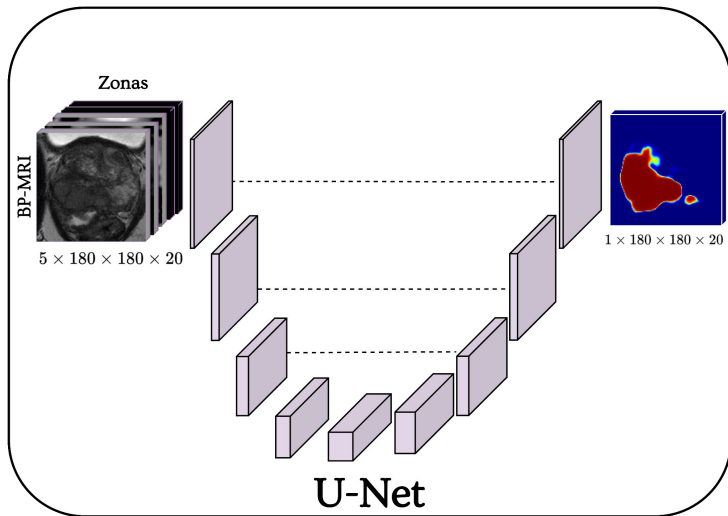
- Configuración experimental

## Baseline: *nnU-Net framework*



- 200 Épocas.
- Suma del coeficiente de dice y la entropía cruzada como función de pérdida.
- Tasa de aprendizaje de 0.001
- 1 Bloque BiRe para el **modulo Riemanniano**.

## Baseline: *nnU-Net framework*



- Baseline: nnU-Net estándar.
- FOA: First-order Attention (SE).
- SOA: Second-order Attention (sin BiRes).
- **SOGA\***: Second-order Geometric Attention.



## Método propuesto: Configuración experimental - métricas

---



AP (Average Precision): mide la capacidad de **localizar** lesiones.



AUC-ROC: evalúa la **discriminación** entre lesión y no lesión.



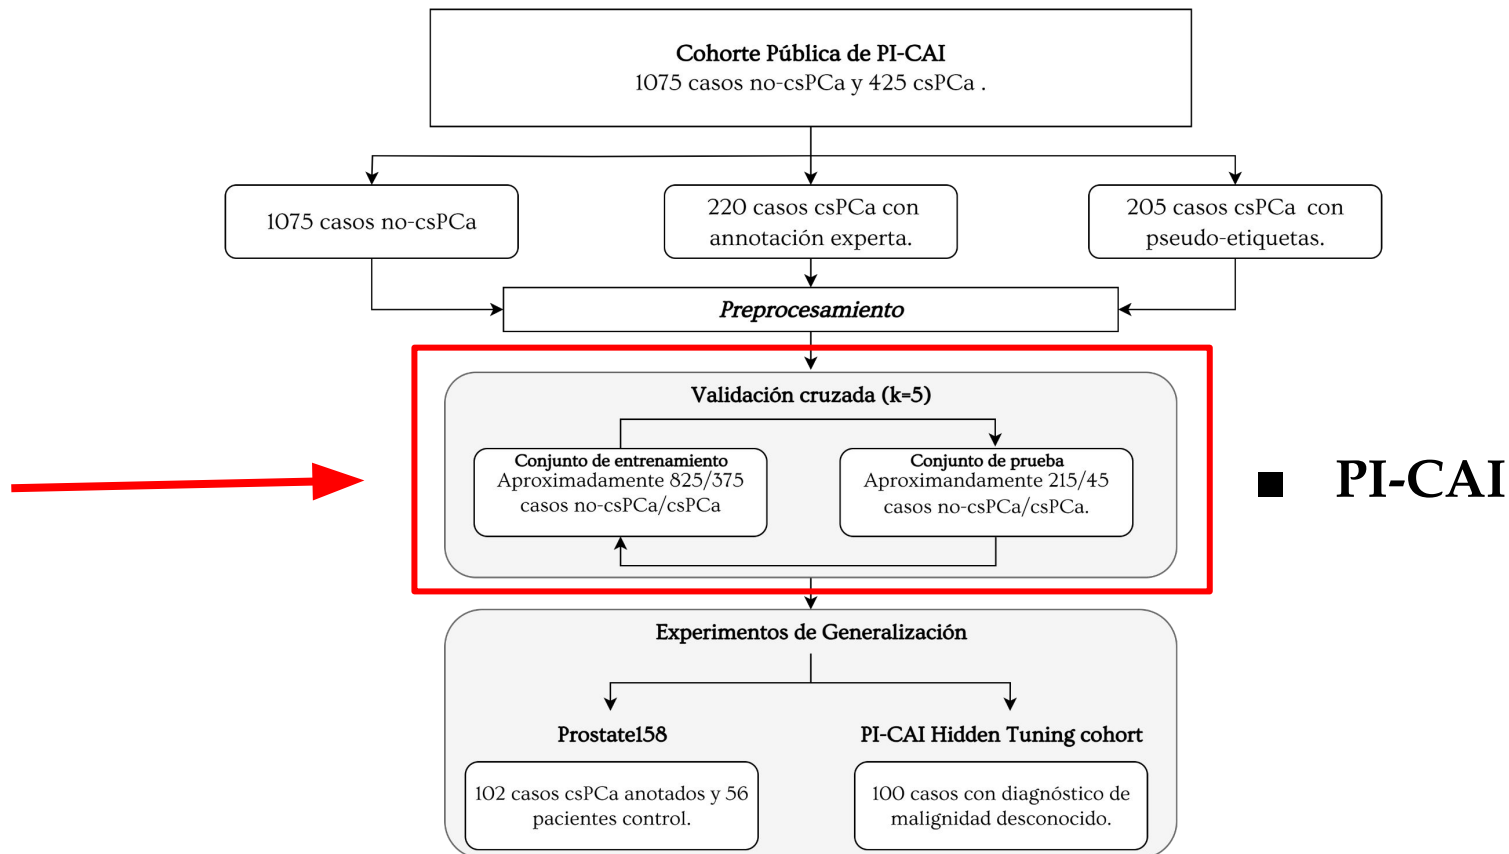
Dice Score: cuantifica la **superposición** predicha vs. real.



Sensibilidad@1FP: Sensibilidad de lesiones detectadas permitiendo como máximo **1 falso positivo por caso**.

## 5. Resultados

- 5K-Fold de PI-CAI

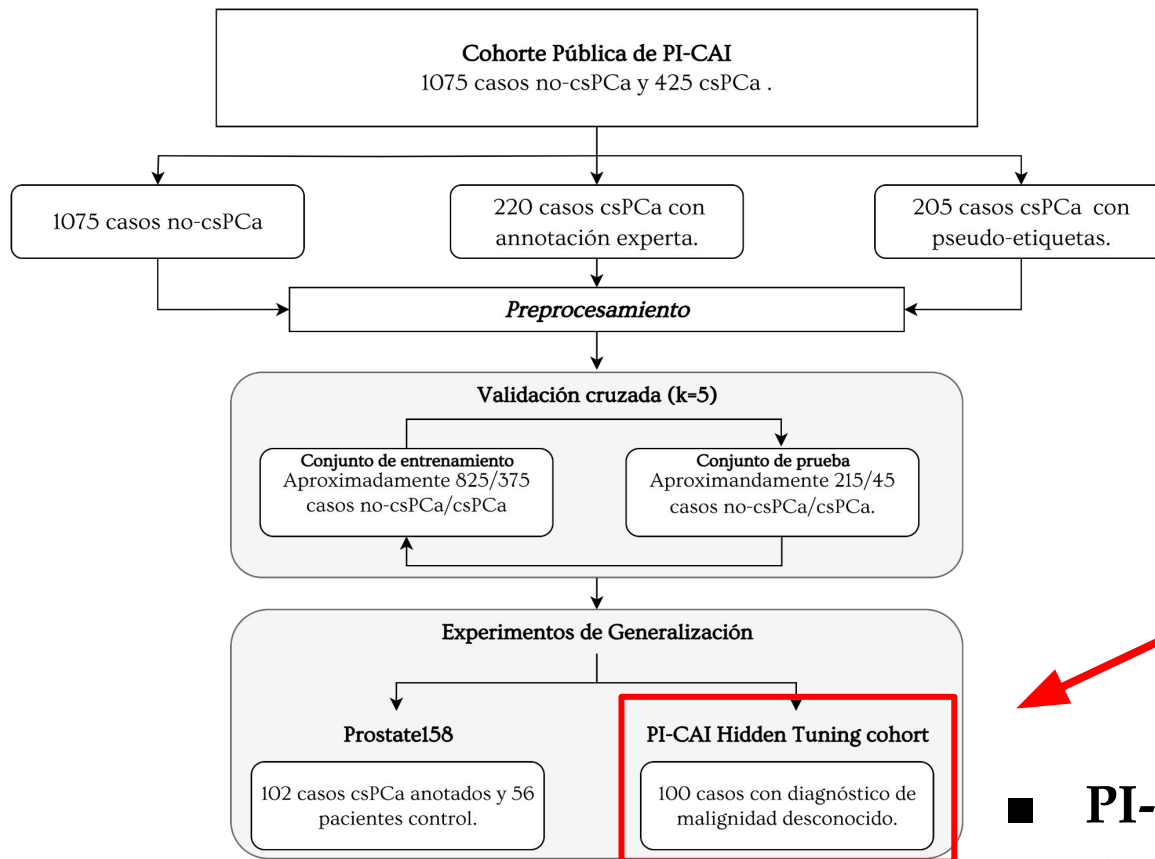


Modelo	AUC-ROC	AP(%)	SEN@1FP(%)	DSC (%)
<b>U-Net</b>	$0.76 \pm 0.03$	$0.31 \pm 0.05$	$0.61 \pm 7.5$	$0.34 \pm 0.09$
U-Net FOA	$0.70 \pm 0.04$	$0.21 \pm 0.08$	$0.49 \pm 0.11$	$0.25 \pm 0.08$
U-Net SOA	<b><math>0.85 \pm 0.02</math></b>	<b><math>0.38 \pm 0.05</math></b>	$0.73 \pm 0.07$	$0.22 \pm 0.26$
U-Net SOGA*	$0.82 \pm 0.03$	$0.35 \pm 0.08$	<b><math>0.74 \pm 0.06</math></b>	<b><math>0.42 \pm 0.04</math></b>
<i>nnUNet framework</i>				
<b>Baseline</b>	$0.83 \pm 0.04$	$0.33 \pm 0.09$	$0.82 \pm 0.04$	<b><math>0.47 \pm 0.03</math></b>
UNETR	$0.82 \pm 0.03$	$0.35 \pm 0.08$	$0.82 \pm 0.02$	$0.49 \pm 0.03$
<b>Swin UNETR</b>	$0.80 \pm 0.03$	$0.34 \pm 0.07$	<b><math>0.83 \pm 0.04</math></b>	<b><math>0.50 \pm 0.03</math></b>
<b>FOA</b>	<b><math>0.83 \pm 0.03</math></b>	$0.36 \pm 0.07$	$0.81 \pm 0.05$	$0.51 \pm 0.03$
<b>SOA</b>	$0.82 \pm 0.04$	$0.35 \pm 0.10$	<b><math>0.83 \pm 0.07</math></b>	$0.51 \pm 0.02$
<b>SOGA*</b>	<b><math>0.83 \pm 0.03</math></b>	<b><math>0.37 \pm 0.05</math></b>	$0.82 \pm 0.02$	<b><math>0.52 \pm 0.02</math></b>

- El método propuesto aumentó el rendimiento de la U-Net estándar.
- Al integrarse en la nnU-Net, el **SOGA** mejoró su desempeño en métricas como el AP y DSC.



## Resultados: PI-CAI Cohorte Oculta



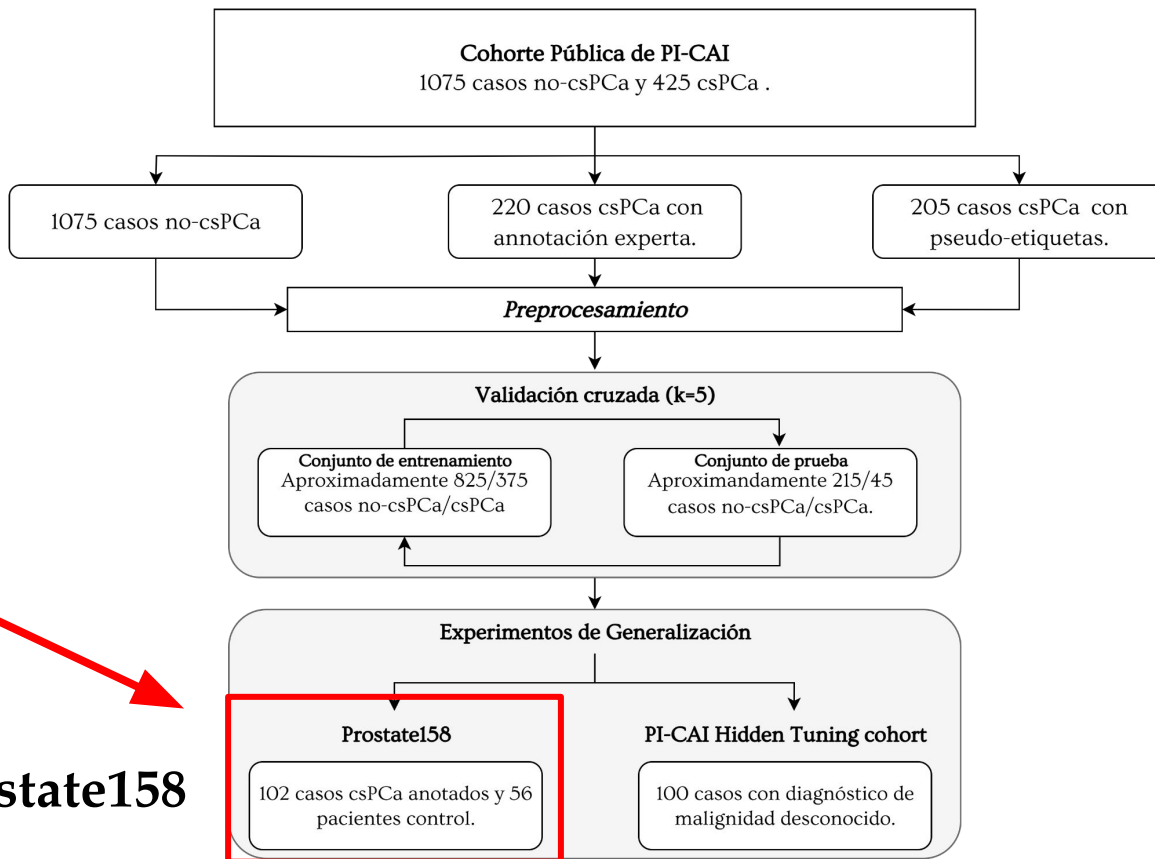
■ **PI-CAI Cohorte Oculta**



## Resultados: PI-CAI Cohorte Oculta

Modelo	AUC-ROC	AP(%)
Baseline	0.78	0.37
UNETR	0.75	0.47
Swin UNETR	<b>0.78</b>	<b>0.54</b>
FOA	0.76	0.40
SOA	0.71	0.44
SOGA*	0.77	0.46

- El método propuesto **augmentó** en 9 puntos el AP con respecto al Baseline.
- La Swin UNETR obtuvo el mejor desempeño entre todos los modelos evaluados.



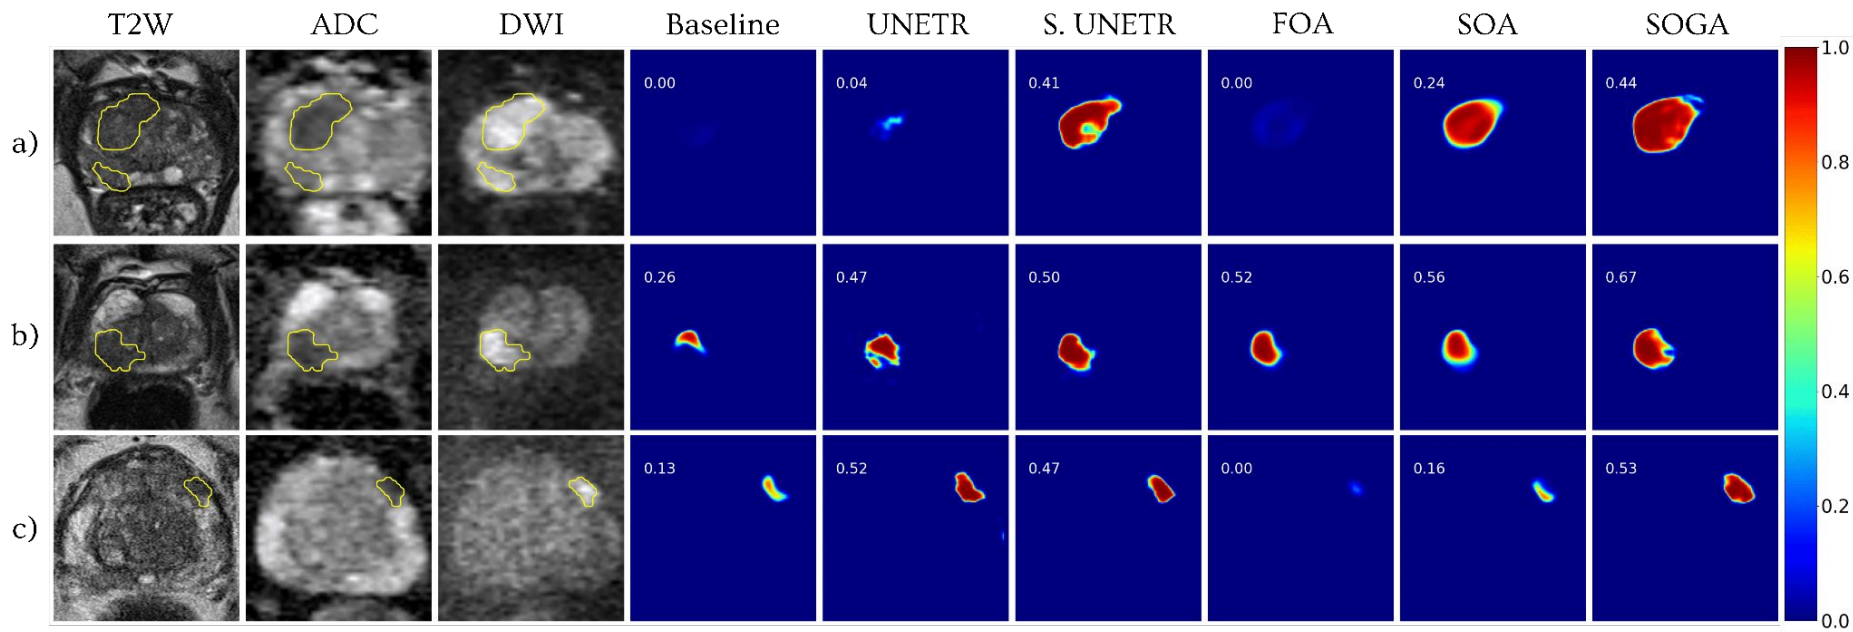
## ■ Prostate158

Modelo	AUC-ROC	AP(%)	SEN@1FP(%)	DSC (%)
Baseline	0.62	0.15	0.23	0.12
UNETR	0.73	0.29	0.38	0.23
Swin UNETR	0.70	0.27	0.38	0.23
FOA	0.67	0.18	0.31	0.18
SOA	0.72	0.29	0.43	0.24
<b>SOGA*</b>	<b>0.75</b>	<b>0.37</b>	<b>0.52</b>	<b>0.31</b>

- El **SOGA** sobresale en todas las métricas evaluadas en esta cohorte externa.
- Esto sugiere una mayor capacidad para aprender patrones con respecto al resto de modelos.

Métrica	Baseline	UNETR	S. UNETR	FOA	SOA	SOGA*
<i>Pequeñas</i>						
<b>DSC</b>	0.10	0.14	0.11	0.11	0.18	<b>0.22</b>
<b>AP</b>	0.04	0.15	0.12	0.08	0.25	<b>0.38</b>
<b>SEN@1FP</b>	<b>0.14</b>	<b>0.28</b>	0.20	0.17	0.31	<b>0.50</b>
<i>Medianas</i>						
<b>DSC</b>	0.17	0.28	0.28	0.24	0.30	<b>0.33</b>
<b>AP</b>	0.26	0.38	0.36	0.33	0.42	<b>0.44</b>
<b>SEN@1FP</b>	0.28	0.41	0.41	0.37	0.48	<b>0.50</b>
<i>Medianas</i>						
<b>DSC</b>	0.16	0.26	0.31	0.24	0.29	<b>0.40</b>
<b>AP</b>	0.24	0.37	<b>0.47</b>	0.27	0.35	0.43
<b>SEN@1FP</b>	0.25	0.43	0.50	0.36	0.48	<b>0.57</b>

- El **SOGA** obtiene una mejora significativa en las lesiones pequeñas, pasando de 0.04 a 0.38 (+850%) de AP, con respecto al Baseline.
- Esta mejora también se ve reflejada en las lesiones medianas, sobresaliendo en todas las métricas.



## 6. Conclusiones y trabajo futuro



## Conclusiones

---

- Se propuso un método de segmentación 3D que integra descriptores de segundo orden y un módulo Riemanniano para soportar la **detección de lesiones csPCa**.
- Las representaciones geométricas de secuencias bp-MRI dentro de la variedad Riemanniana mejoraron la **capacidad de capturar patrones discriminativos de la red**, reduciendo el **sesgo** asociado a la procedencia de los datos e incrementando su capacidad de **generalización**.
- La segmentación y detección automática de lesiones de cáncer de próstata clínicamente significativas representa aún un **desafío** para las arquitecturas de aprendizaje profundo.





- Evaluación en diferentes escenarios de escasez de datos: Por ejemplo, con distintas **proporciones** de datos de entrenamiento.
- Expandir el **SOGA**, pasar la atención de a nivel de canales a nivel **espacial**.
- Extender este módulo a arquitecturas modernas como las fundacionales, ya sea implementándolo o fusionándolo.



- Ortiz, M., Olmos, J., Martínez, F. (2025). Mecanismos de atención de segundo orden para la segmentación de lesiones de cáncer de próstata en secuencias de resonancia magnética biparamétrica. *En Innengiate-c 2025, Universidad Autónoma de Bucaramanga (UNAB)*. **Aceptado y presentado.**








**Octubre 9 - Bucaramanga, Colombia**

- Ortiz, M., Olmos, J., Martínez, F. (2025). A Second-Order Attention Mechanism For Prostate Cancer Segmentation and Detection in Bi-Parametric MRI. *In 28th Iberoamerican Congress on Pattern Recognition (CIARP 2025) Springer Proceedings*. **Aceptado.**



**25 - 28 Noviembre - Bogotá, Colombia**



## Detección de lesiones de próstata utilizando atención guiada por descriptores de segundo orden en estudios biparamétricos.

---

**Estudiante:** Mateo Gerónimo Ortiz Cruzate


**Director:** Fabio Martínez Carrillo, PhD.

**Codirector:** Juan A. Olmos Rojas PhD (c)

# Thank you!

# Supplemental Materials


## Attention Gate



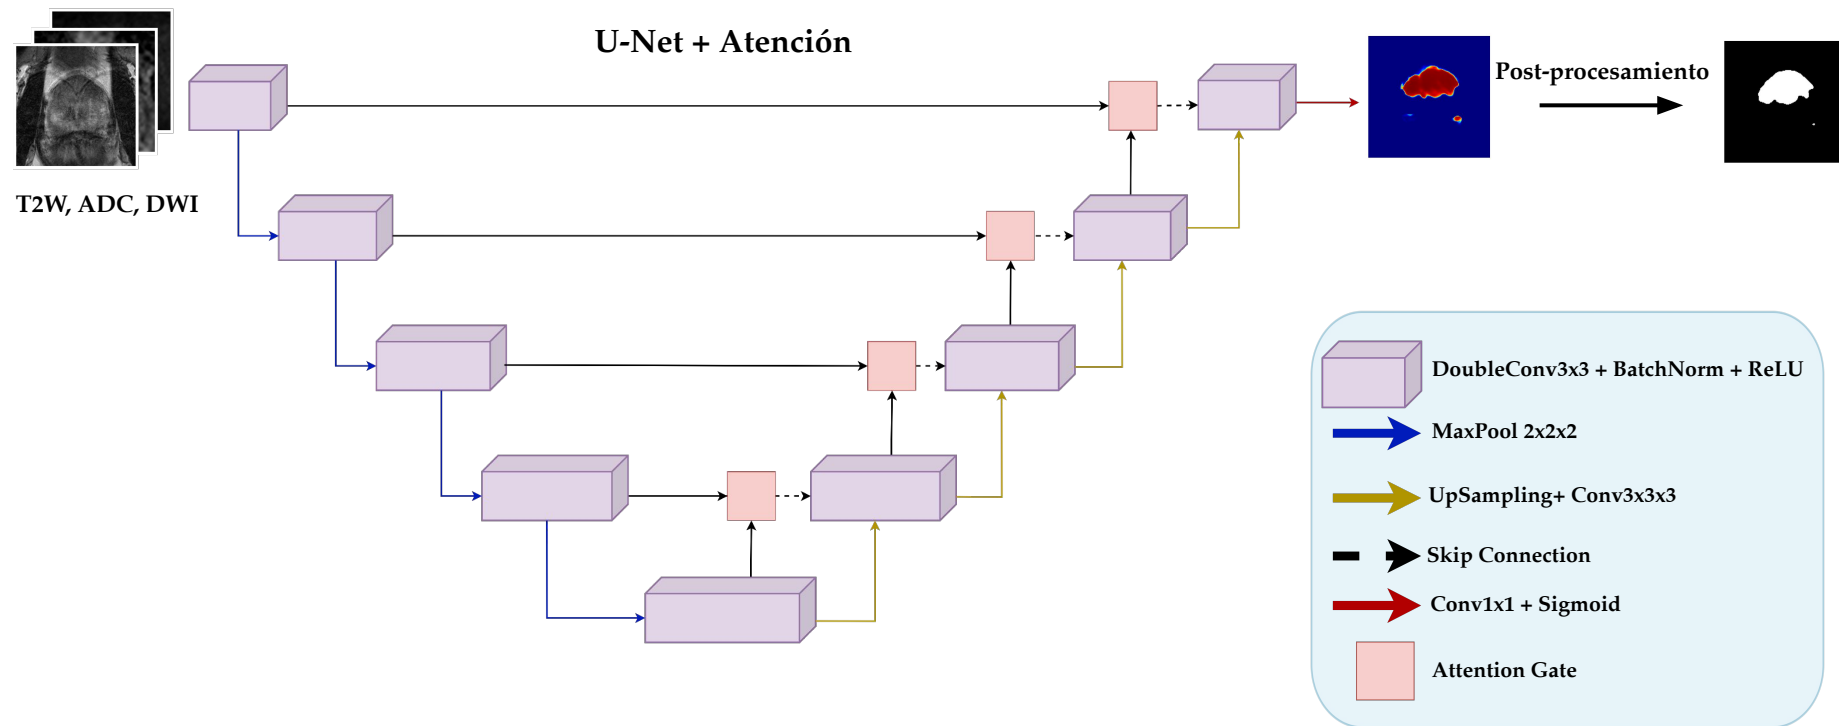
- Refuerza los canales más relevantes al **recalibrar** dinámicamente sus activaciones.
- Introduce mejoras en el rendimiento con un impacto mínimo en el costo computacional.
- Puede generar una **pérdida significativa** de información y una **alta dependencia** a la distribución de los mapas de características.

[8] O. Oktay, J. Schlemper, L. L. Folgoc, M. Lee, M. Heinrich, K. Misawa, K. Mori, S. McDonagh, N. Y. Hammerla, B. Kainz *et al.*, "Attention U-Net: Learning where to look for the pancreas," *arXiv preprint arXiv:1804.03999*, 2018.

J. Hu, L. Shen y G. Sun, "Squeeze-and-Excitation Networks," en *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, UT, EE. UU., 2018, pp. 7132–7141.



## U-Net + Atención





# Aprendizaje Riemanniano

Output:  $\mathbf{X}_K = f^{(K)}(\mathbf{X}_{K-1})$

Forward:  $f((x_\theta, t))$ ,  $f = f^{(l)} \circ f^{(l-1)} \circ \dots \circ f^{(1)}$ ,


Euclidean Gradient descent :

$$\Theta_K = \Theta_K - \alpha \frac{\partial L^{(K)}}{\partial \Theta_K}$$

$$\frac{\partial L^{(K)}}{\partial \Theta_K} = \frac{\partial L^{(K+1)}}{\partial \mathbf{X}_K} \frac{\partial f^{(K)}}{\partial \Theta_K}$$

$$\tilde{\nabla} L_{W_k^t}^{(k)} = \nabla L_{W_k^t}^{(k)} - \nabla L_{W_k^t}^{(k)} (W_k^t)^\top W_k^t$$


$$\mathbf{W}_K^{t+1} = \Gamma \left( \mathbf{W}_K^t - \alpha \tilde{\nabla} L_{\mathbf{W}_K^t}^{(K)} \right)$$








PROSTATE158<sup>7</sup>.



PI-CAI Challenge dataset<sup>8</sup>.



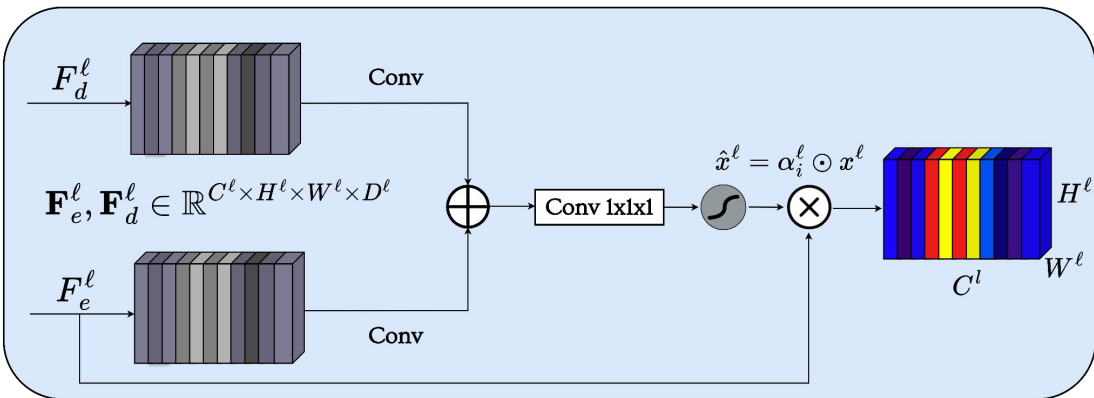
- Uno de los principales problemas al estratificar las lesiones de cáncer de próstata es el **desequilibrio de clases** y la **cantidad limitada** de datos.

[7] Armato et al. (2023) "PROSTATEx Challenges for computerized classification of prostate lesions from multiparametric magnetic resonance images" Journal of Medical Imaging.

[8] Saha et al. (2023) "Artificial intelligence and radiologists at prostate cancer detection in MRI—the PI-CAI challenge." Medical Imaging with Deep Learning (MIDL) conference.



## Trabajos relacionados: Attention U-Net



$$q_{att}^l = \psi^T \sigma_1 (W_x^T x_i^l + W_g^T g_i + b_g) + b_\psi$$
$$\alpha_i^l = \sigma_2 (q_{att}^l(x_i^l, g_i; \Theta_{att}))$$


- **Prioriza** regiones **relevantes** para la tarea de aprendizaje.
- **Filtra** información irrelevante, lo que **reduce** el **ruido** y refina los mapas de características.
- **Capacidad limitada para capturar relaciones espaciales globales.**




# Descriptores

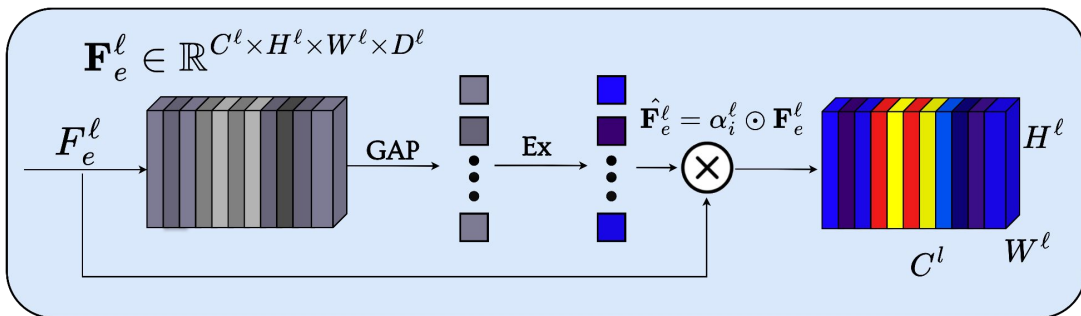
Un descriptor es una medida basada en un estadístico que **resume** o caracteriza **propiedades** de los datos o de una **representación**.

## Media



## Correlaciones





## Compresión

$$z_c = \mathbf{F}_{sq}(\mathbf{u}_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j)$$

## Recalibración

$$\mathbf{s} = \mathbf{F}_{ex}(\mathbf{z}, \mathbf{W}) = \sigma(g(\mathbf{z}, \mathbf{W})) = \sigma(\mathbf{W}_2 \delta(\mathbf{W}_1 \mathbf{z}))$$


$$\tilde{\mathbf{x}}_c = \mathbf{F}_{scale}(\mathbf{u}_c, \mathbf{s}_c) = \mathbf{s}_c \mathbf{u}_c$$

- Prioriza regiones relevantes al **recalibrar canales** de los bancos de características.
- Puede generar una alta **dependencia** a la distribución de los datos.
- Se basa en estadísticas de **primer orden** (promedios globales), lo que puede **reducir** la sensibilidad a regiones pequeñas o sutiles de interés.




## Trabajos relacionados

**Modelos guiados por atención:** Implementan atención en arquitecturas tipo U-Net o adoptan directamente arquitecturas basadas en transformers.



- Arquitecturas tipo Transformer.
- Atención basada en descriptores de **primer orden**.

**Modelos informados por zonas:** Incorporan las zonas prostáticas como mapas probabilísticos o binarios, comúnmente en la entrada.



J. A. Alzate-Grisales, A. Mora-Rubio, F. García-García, R. Tabares-Soto, y M. De La Iglesia-Vayá, "Sam-UNETR: Clinically significant prostate cancer segmentation using transfer learning from large model," *IEEE Access*, vol. 11, pp. 118217–118228, 2023.

A. Karagöz, M. E. Seker, M. Yergin, T. A. Kan, M. S. Kartal, E. Karaarslan, D. Alis, and I. Oksuz, "Prostate lesion estimation using prostate masks from biparametric MRI," *arXiv preprint arXiv:2301.09673*, Jan. 2023.

## Módulo Riemanniano

- Cálculo de una nueva SPD (*BiMap*):


$$\mathbf{S}_\ell = f_{BiMap}(\mathbf{S}_{\ell-1}) = \mathbf{W}_k \mathbf{S}_{\ell-1} \mathbf{W}_k^\top$$

- Regularización (*ReEig*):

$$\mathbf{S}_\ell = f_{ReEig}(\mathbf{S}_{\ell-1}) = \mathbf{U}_{\ell-1} \max(\varepsilon \mathbf{I}, \mathbf{\Sigma}_{\ell-1}) \mathbf{U}_{\ell-1}^\top$$


donde,

$$\mathbf{S}_{\ell-1} = \mathbf{U}_{\ell-1} \mathbf{\Sigma}_{\ell-1} \mathbf{U}_{\ell-1}^\top$$



- Proyección al espacio euclidiano (*Mapeo Logarítmico*)

$$\mathbf{S}_\ell = f_{LogEig}(\mathbf{S}_{\ell-1}) = \mathbf{U}_{\ell-1} \log(\mathbf{\Sigma}_{\ell-1}) \mathbf{U}_{\ell-1}^\top$$



- **BiMap**: aprende descriptores SPD **más compactos**.
- **ReEig**: Regulariza las matrices SPD asegurando que las proyecciones permanezcan en la variedad Riemanniana.

- **LogEig**: Permite mapear las matrices SPD del espacio Riemanniano a un espacio euclídeo manteniendo su estructura geométrica.

- El resultado definitivo de la biopsia se considera el método de referencia (*Gold Standard*) para el diagnóstico<sup>2</sup>.
- Este procedimiento consiste en un examen histológico que permite confirmar si una región sospechosa corresponde a una lesión de cáncer de próstata clínicamente significativo (**csPCa**) o por el contrario es un paciente control (**non-csPCa**).

