

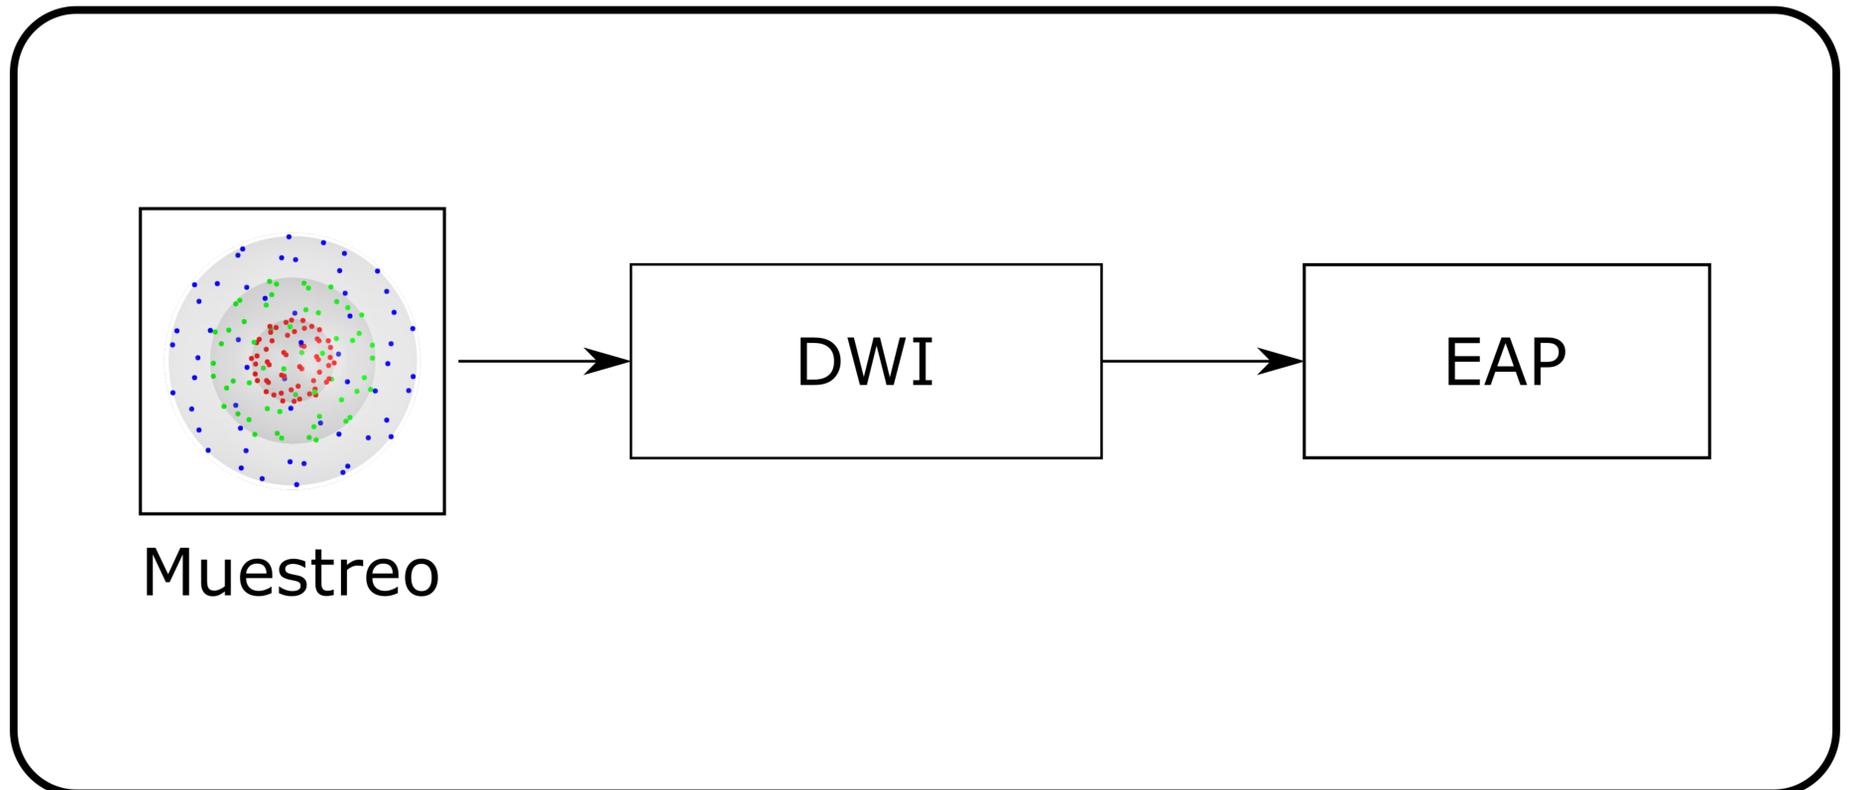


Transferencia de calidad a imágenes de resonancia magnética de difusión mediante aprendizaje profundo: una nota de precaución

Justino R. Rodríguez Galván¹, Carmen Martín Martín¹, Antonio Tristán Vega¹, Santiago Aja Fernández¹, Carlos Alberola López¹

¹E.T.S. Ingenieros de la Telecomunicación, Universidad de Valladolid, Valladolid.

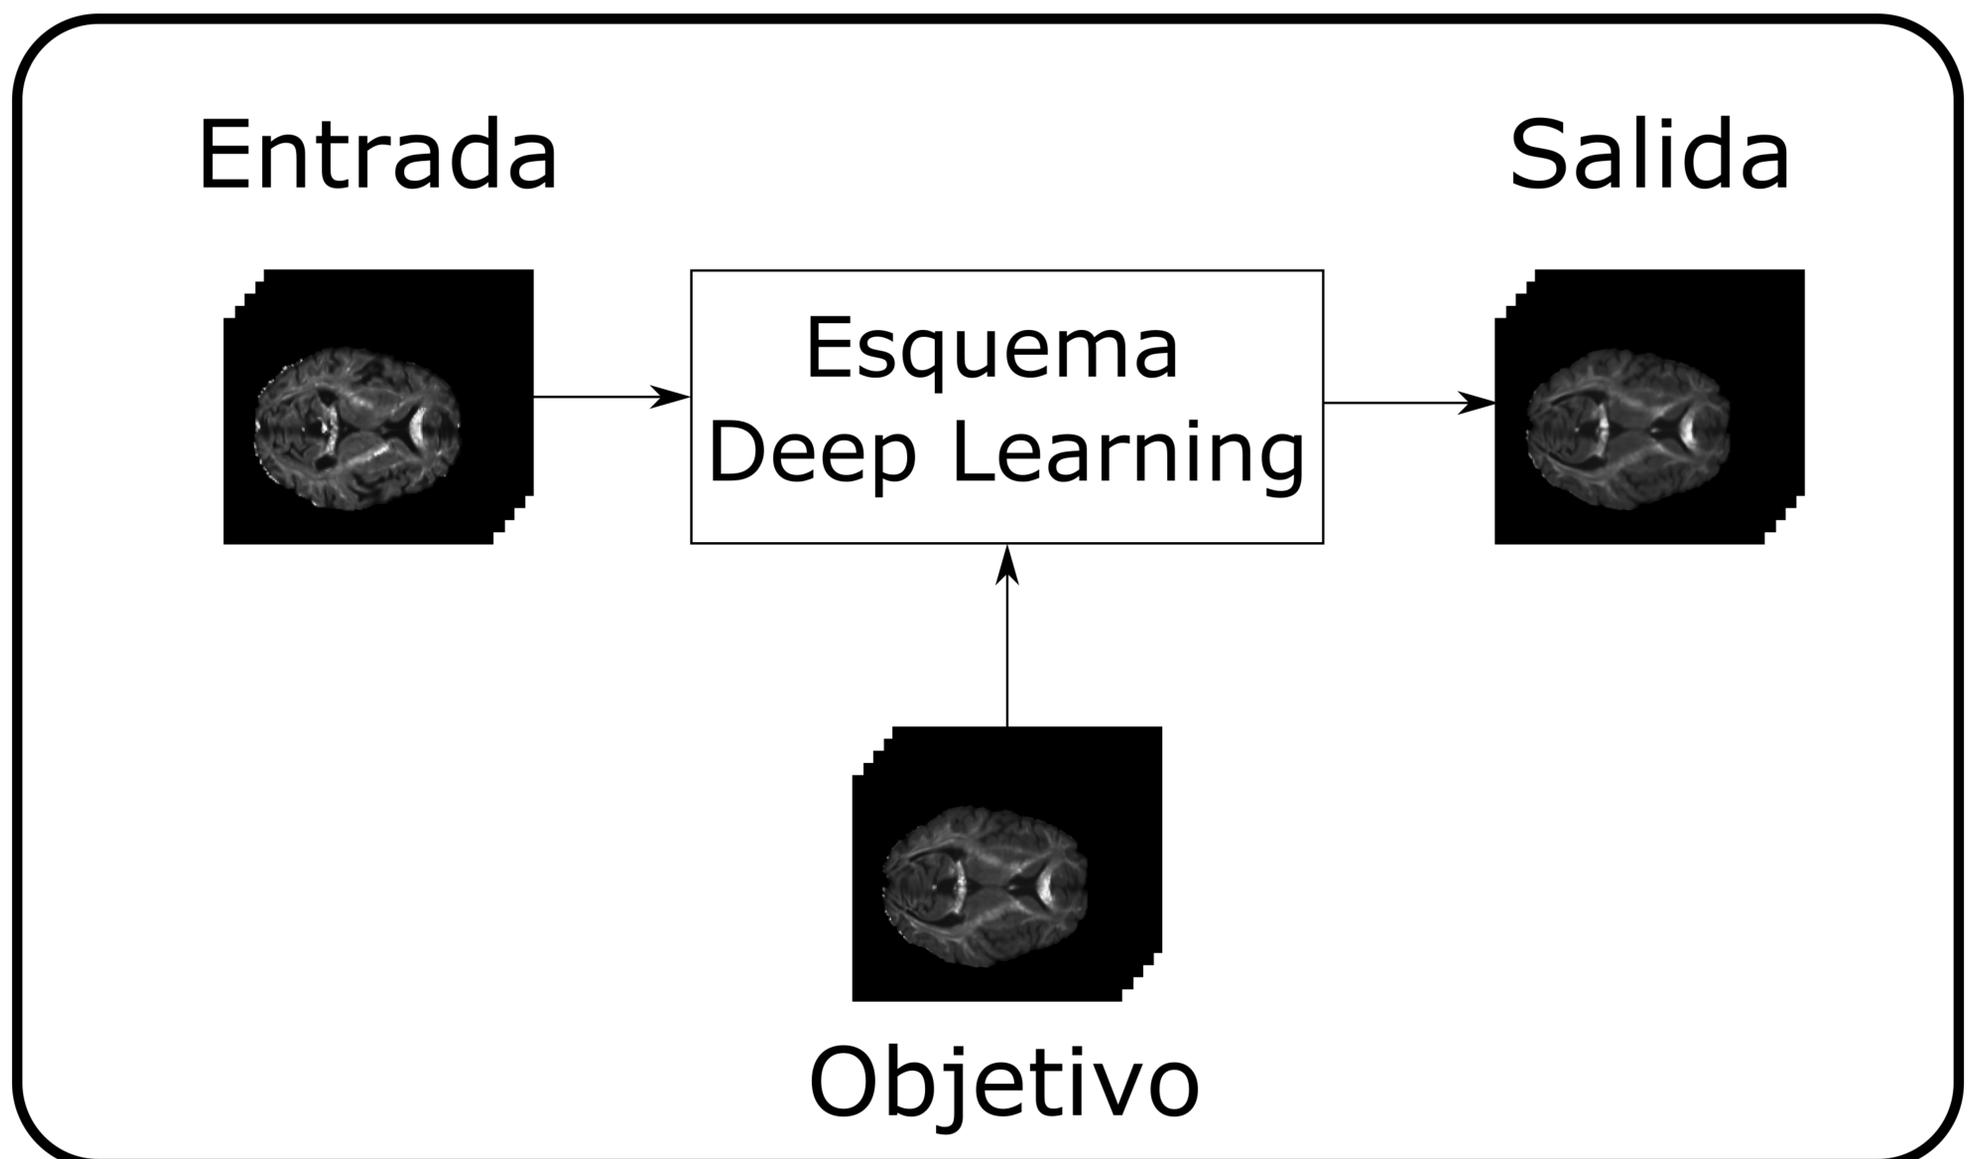
Introducción



- Resonancia Magnética de Difusión (dMRI) mide el movimiento aleatorio (browniano) de las partículas de agua en tejidos.
- El muestreo en la adquisición se hace mediante gradientes colocados sobre superficies esféricas concéntricas (shells) de diferente radio (b-valor [s/mm^2]).
- Si el muestreo es suficientemente denso se podrá estimar el EAP (*Ensemble Average Propagator*).
- De éste propagador se podrán extraer parámetros escalares, tales como las probabilidades de retorno a eje, origen o plano (RTAP, RTOP, RTPP, por sus siglas en inglés).
- Tanto el muestreo denso como la obtención de muestras para b-valores altos necesitan de mucho tiempo tiempo, por lo que se buscan soluciones para este problema.

Objetivo

¿Mejora el *Deep Learning* la capacidad diagnóstica de mapas paramétricos dMRI?



- El esquema deep learning realiza las imágenes tomadas con b-valor inferior para asemejarlas a las versiones con b-valor superior.
- Tras el realce, se compararán mediante métricas estándar de imagen la salida con el objetivo a fin de comprobar la precisión de la reconstrucción.
- Finalmente, se compararán entrada y salida para el diagnóstico.

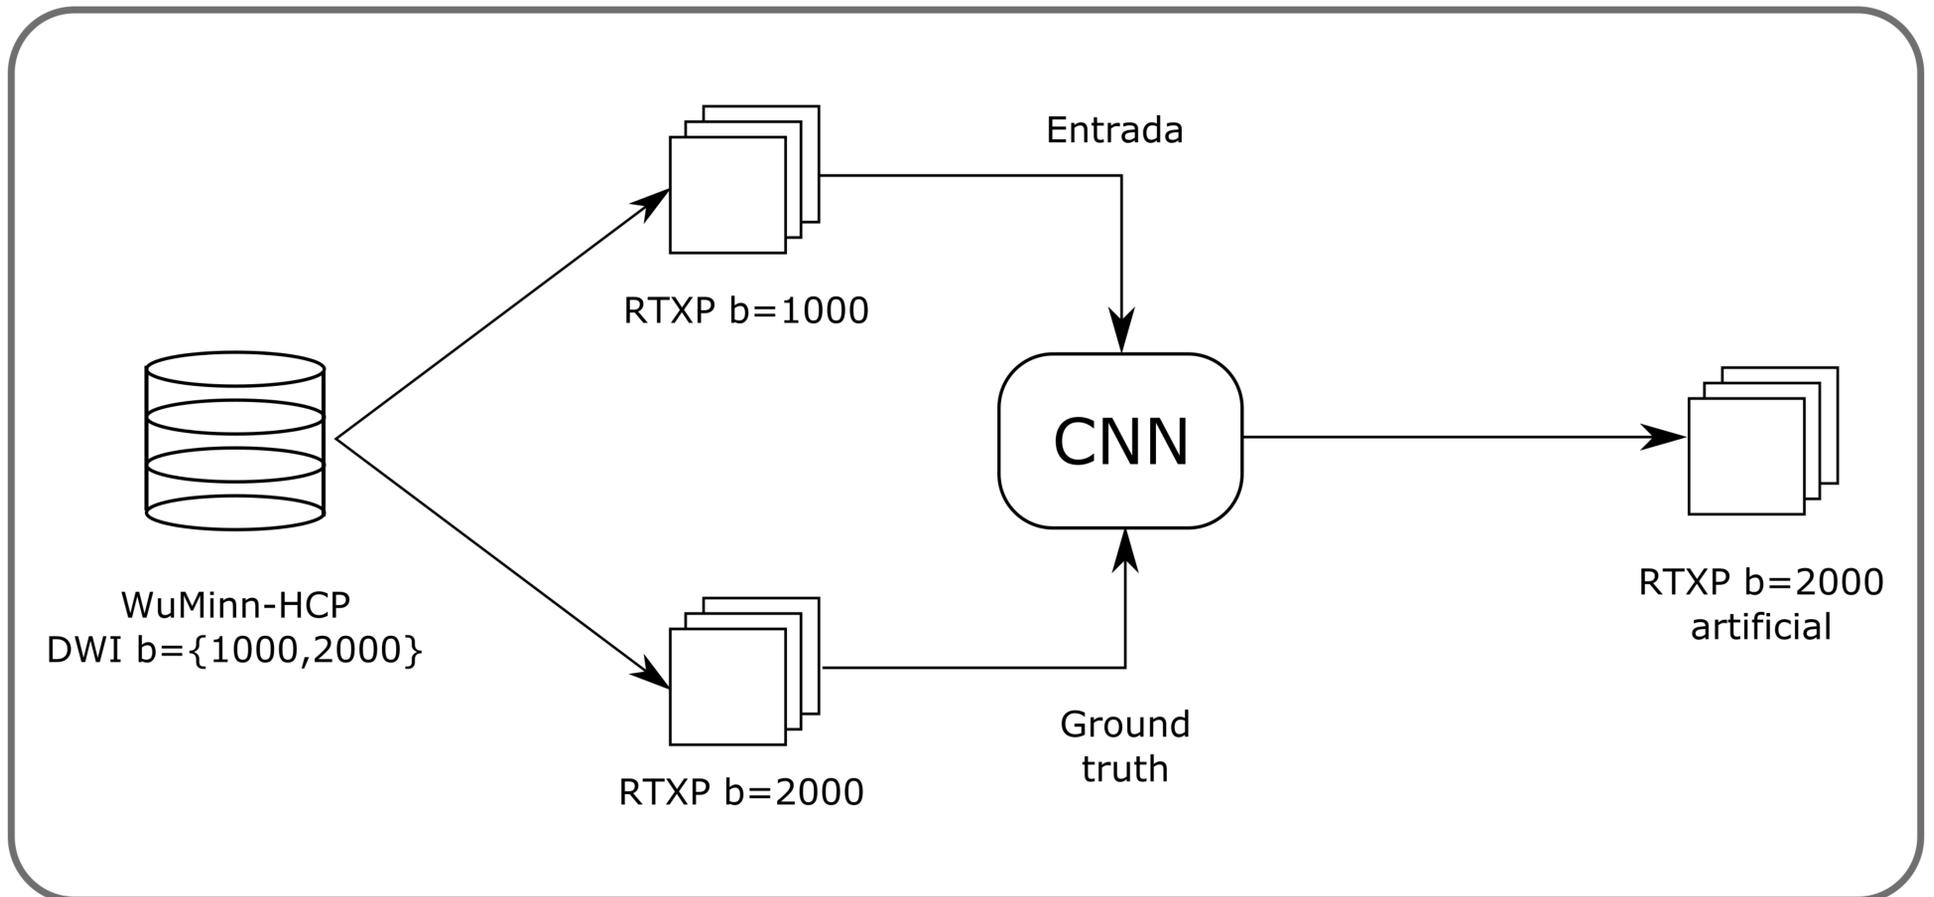
Material

1. Base de datos 1 (BD1): WuMinn-HCP¹, formada por 84 sujetos sanos, con b-valores (b) 1000, 2000 y 3000 s/mm².
 - Obtención de parámetros escalares RTAP, RTOP y RTPP.
 - División en subconjuntos de entrenamiento (60%), validación (20%) y test (20%).
 - Conjunto de validación utilizado para mecanismo de parada temprana.
2. Base de datos 2 (BD2): Propia, formada por 50 controles y 51 casos con migraña episódica para b = 1000 s/mm².
 - Obtención de parámetros similar a BD1.
 - Uso al completo en red entrenada para aumento de b.

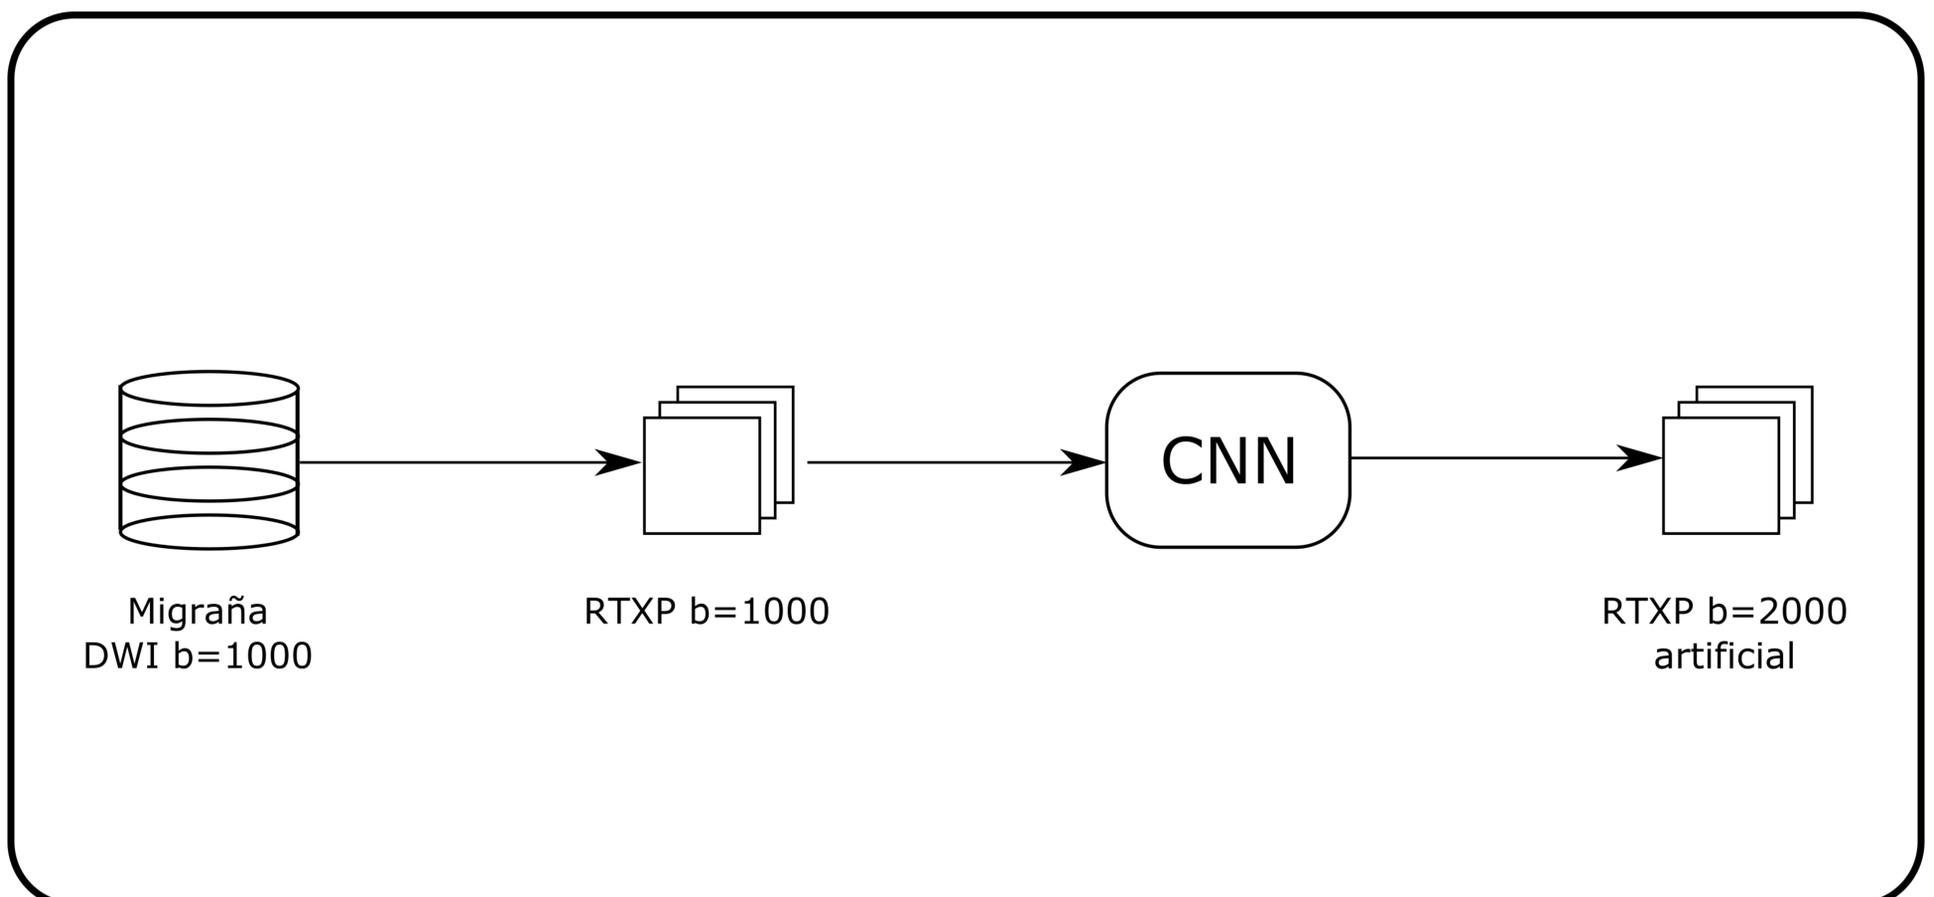
Material

1. Base de datos 1 (BD1): WuMinn-HCP¹, formada por 84 sujetos sanos, con b-valores (b) 1000, 2000 y 3000 s/mm².
 2. Base de datos 2 (BD2): Propia, formada por 50 controles y 51 casos con migraña episódica para b = 1000 s/mm².
- Obtención de parámetros RTXP de ambas BBDD.
 - Refinado mediante DL de b=1000 a b=2000.
 - Comparación entre imágenes reales y sintéticas mediante test Mann-Whitney.

Método I

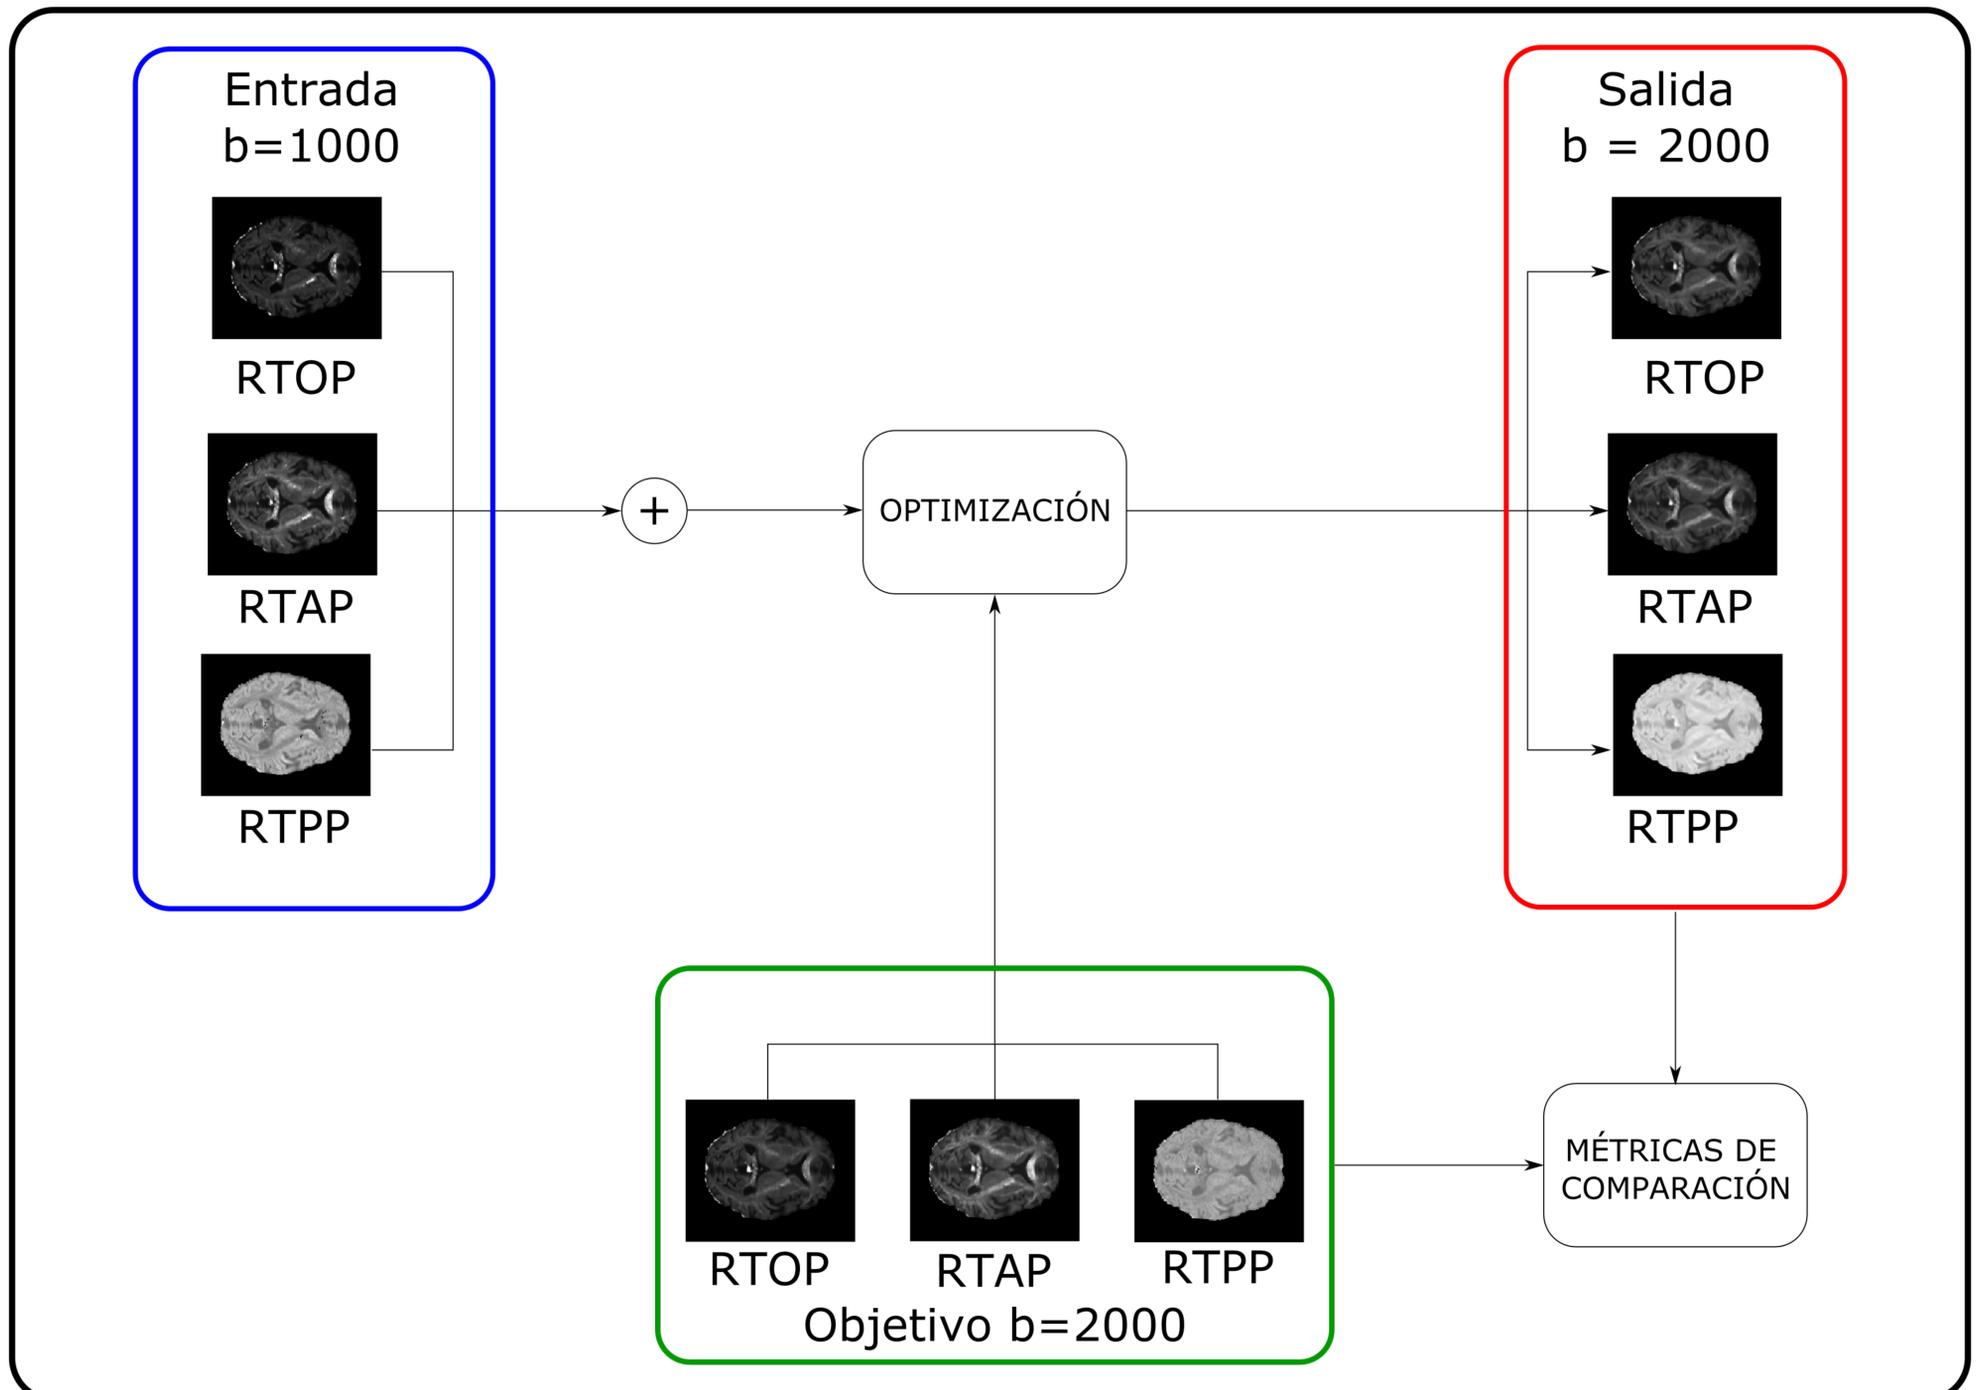


Entrenamiento usando BD1, comprobando métricas de imagen entre ground truth y salida.



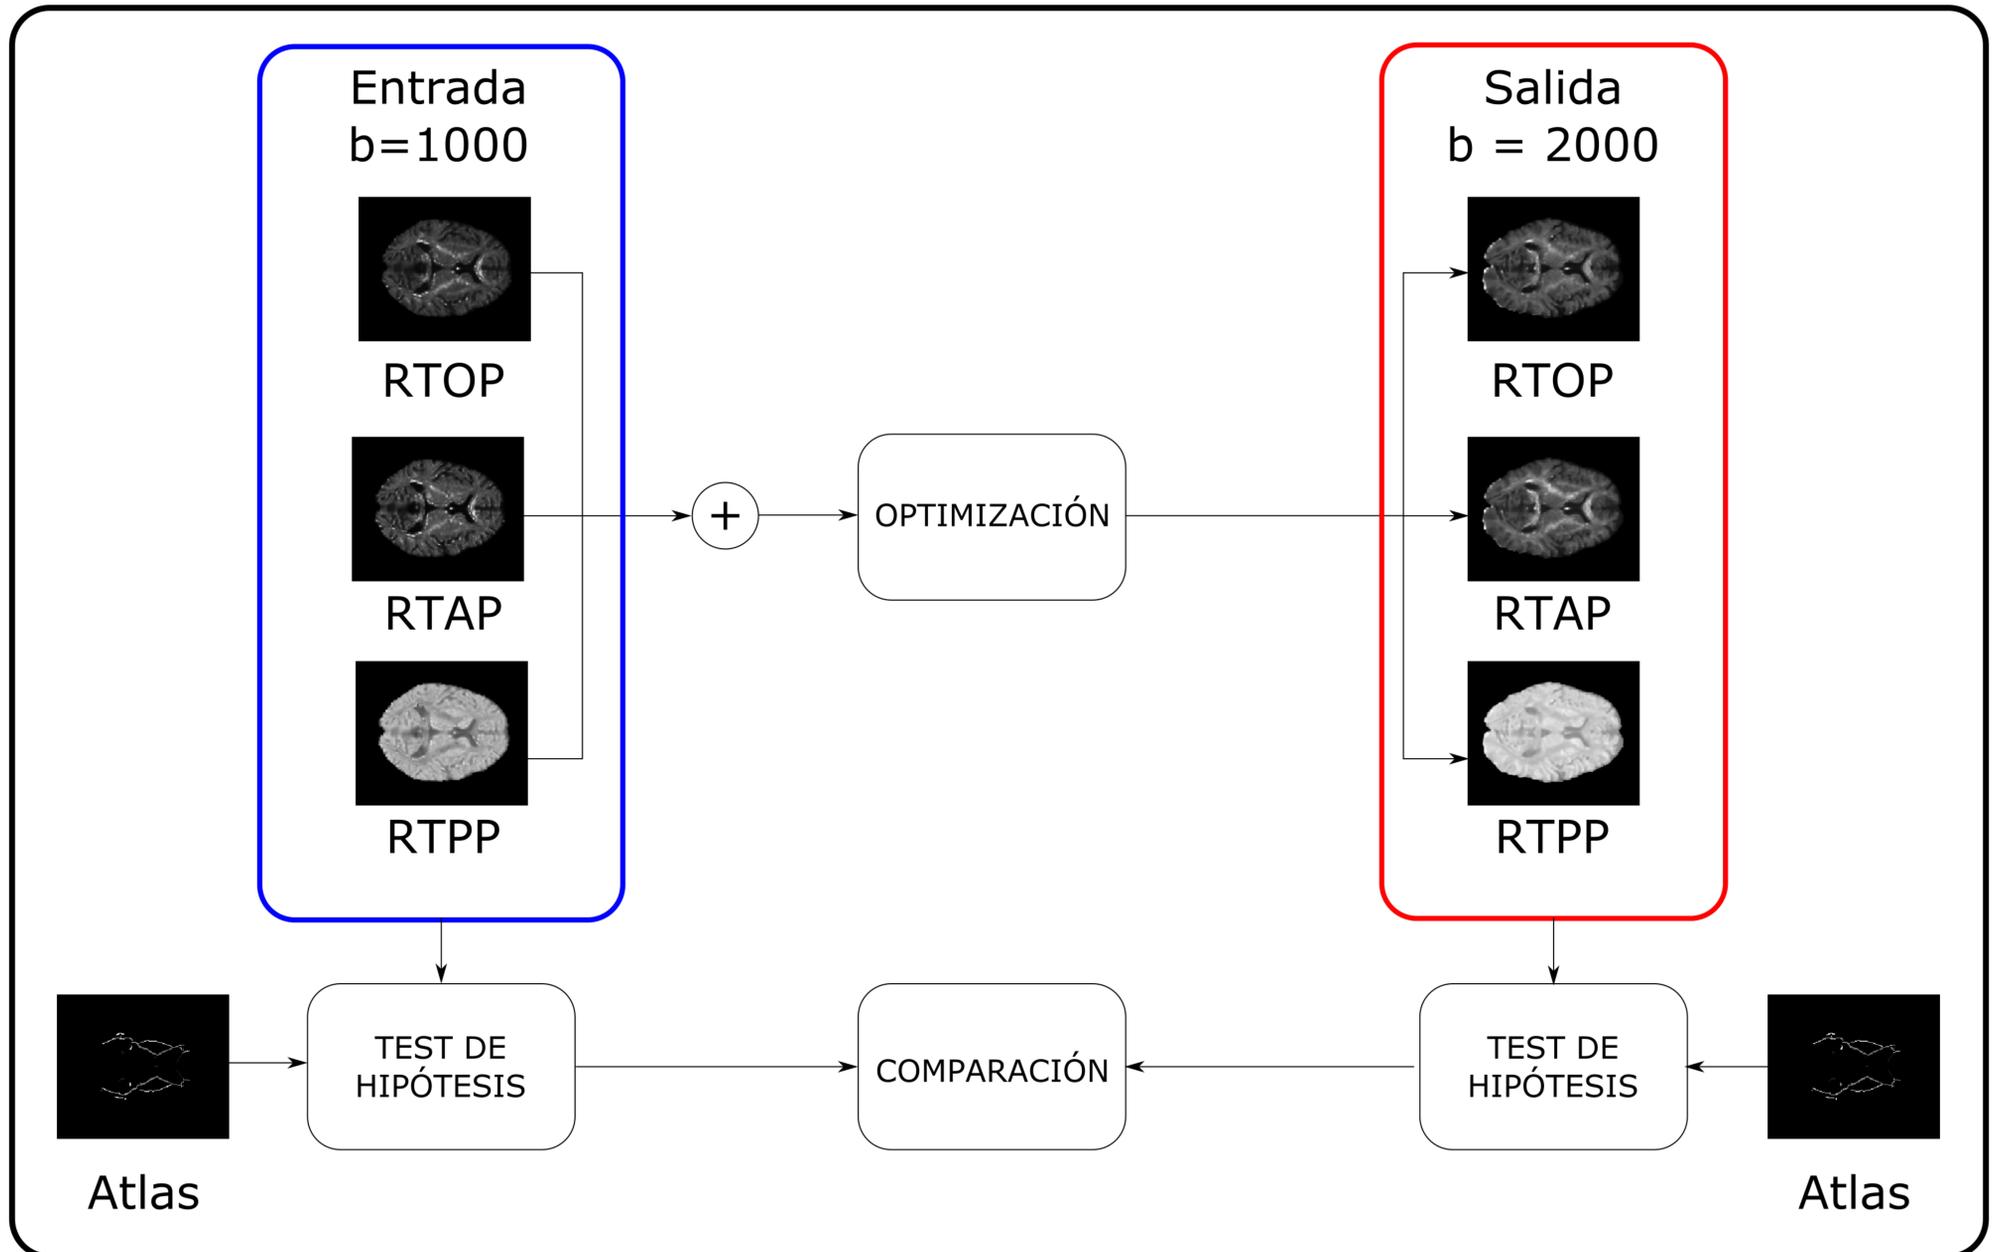
Uso de BD2 para comprobación de diagnóstico mediante test Mann-Whitney entre entrada y salida de la red.

Método II



- Arquitectura DL basada en síntesis² modificada para usar TensorFlow como Backend.
- Síntesis de características de entradas en la entrada de función objetivo.
- Comparación de síntesis con cada una de los parámetros objetivo, en este caso mapas paramétricos RTAP, RTOP y RTPP.
- Comparación de imágenes en salida.

Método III



- A la entrada, pacientes y controles de BD2.
- Test de hipótesis para encontrar diferencias entre pacientes y controles.
- Atlas JHU-WM³ como referencia.
- Test Mann-Whitney.
- Comparación de diferencias entre conjunto entrada y conjunto salida.

Resultados

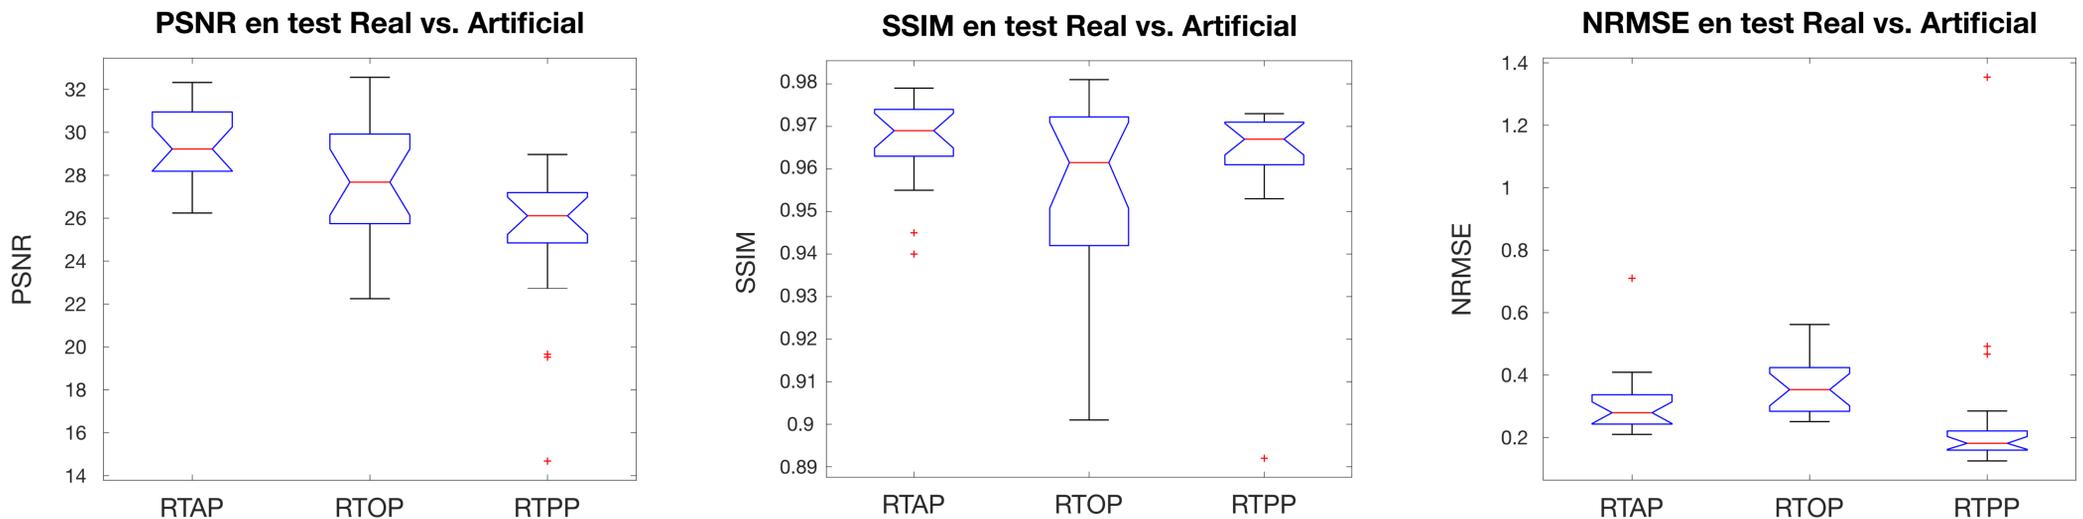


Figura 1. Boxplots de la distribución de métricas entre imágenes reales y producidas por la red.

	PSNR	SSIM	NRMSE
RTAP	29,3760	0,9664	0,3072
RTOP	27,5448	0,9548	0,3668
RTPP	24,9439	0,9621	0,2802

Tabla 1. Valores medios para métricas de calidad de imagen entre imágenes reales y producidas por la red.

		Sintéticos					
		p<0,05	p>0,05	p<0,05	p>0,05	p<0,05	p>0,05
Reales	p<0,05	5	12	3	6	3	2
	p>0,05	0	31	2	37	5	38

Tabla 2. Test Mann-Whitney para RTAP (azul), RTOP (verde), RTPP (rojo).

- Rodeado en azul el conjunto que más diferencias significativas ($p < 0,05$) consigue con respecto al otro. Destaca RTAP, donde el conjunto sintético no consigue diferencias en regiones adicionales.

Conclusiones

- Pérdida de diferencias para $b=2000$ respecto a $b=1000$ aun con valores de $SSIM > 0,95$.
- El entrenamiento utilizando controles puede hacer perder sensibilidad, aunque la imagen sintética proporciona valores conservadores.
- La imagen sintética debe ser empleada con precaución y en grupos de mayor tamaño.
- Existe una limitación en la base de datos, al no tener muestreos para $b=2000$.

Referencias

1. Van Essen, D. C., Smith, S. M., Barch, D. M., Behrens, T. E., Yacoub, E., Ugurbil, K., & Wu-Minn HCP Consortium. The WU-Minn human connectome project: an overview. *Neuroimage*. 2013; 80: 62-79.
2. Chartsias, A., Joyce, T., Giuffrida, M. V., & Tsaftaris, S. A. Multimodal MR synthesis via modality-invariant latent representation. *IEEE transactions on medical imaging*, 2017; 37(3): 803-814.
3. Mori, S., Wakana, S., Van Zijl, P. C., & Nagae-Poetscher, L. M. *MRI atlas of human white matter*. Elsevier. 2005.