# INFORME DEL PROYECTO REF.SV-23-GIJÓN-1-17

(AI4MAMACANCER) Modelado de la evolución del cáncer de mama mediante el procesado de imágenes de resonancia magnética mediante IA como apoyo a la medicina personalizada.

---

**Fechas inicial y final del proyecto:**
01 / 06 / 2023 al 31 / 12 / 2023

**Investigador/a Principal:**
José Ramon Villar Flecha

**Otros investigadores:**
Ángel Francisco del Río Álvarez

**Personal contratado:**
Rebeca Oliveira Suárez

**Fechas inicial y final de contratación:**
01 / 09 / 2023 al 31 / 12 / 2023

**Empresas o instituciones colaboradoras:**
Pordue University

**Redes sociales de investigadores y empresas:**

## Resumen Gráfico

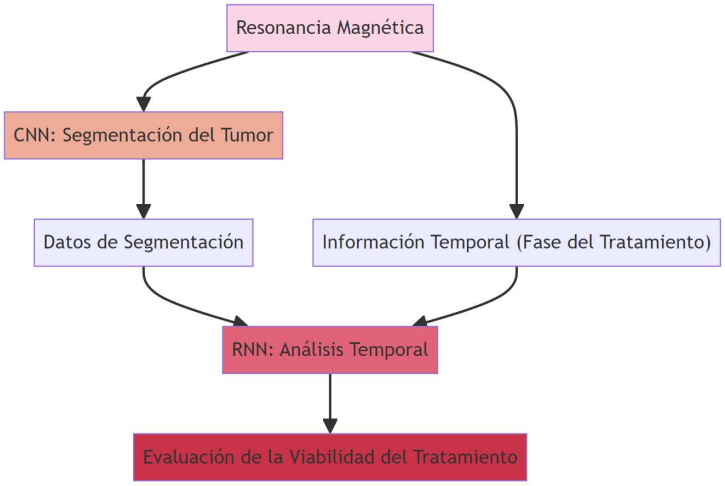


*Ilustración 1: Diagrama de flujo del proyecto*

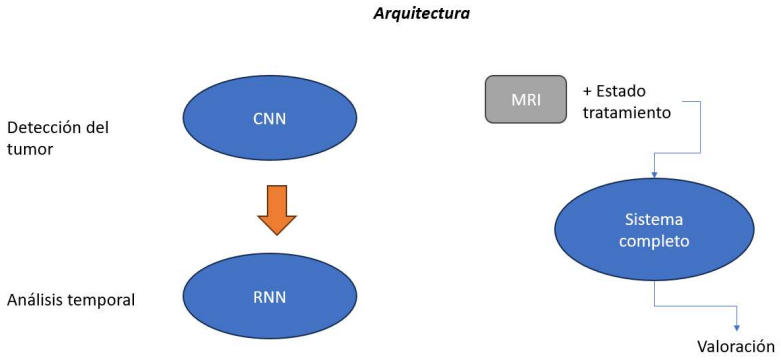


*Ilustración 2: Arquitectura de la solución*

## Memoria descriptiva del proyecto

### 1. Resumen ejecutivo

#### Antecedentes

El cáncer de mama representa uno de los mayores desafíos en el campo de la salud, con una tasa de mortalidad significativa a nivel mundial. En las últimas décadas, ha habido un esfuerzo constante por mejorar el diagnóstico, tratamiento y seguimiento de esta enfermedad. Recientemente, la inteligencia artificial (IA) ha emergido como una herramienta prometedora en la lucha contra el cáncer, ofreciendo nuevas perspectivas y enfoques en su tratamiento y comprensión.

En este contexto, nuestro proyecto se enfoca en la utilización de la IA para predecir la eficacia de los tratamientos contra el cáncer de mama, utilizando imágenes de resonancia magnética (RM) de pacientes en diferentes etapas del tratamiento. Este enfoque se basa en la integración de redes neuronales convolucionales (CNN) y redes neuronales recurrentes (RNN), buscando aprovechar la capacidad de las CNN para analizar imágenes y de las RNN para interpretar secuencias temporales.

Con anterioridad se ha estudiado profundamente la segmentación de tumores en imágenes de resonancias magnéticas haciendo uso de técnicas avanzadas de Deep Learning, normalmente apoyadas en redes neuronales convolucionales. El cáncer de mama, no se queda atrás, y debido a su mejor pronostico en relación a cánceres más agresivos, ha permitido desarrollar soluciones concretas con muy buenos resultados.

Si intentamos analizar series temporales para poder predecir la progresión de un tumor, nos encontramos con la dificultad de la falta de datos, por lo que los estudios en este sentido se reducen significativamente. Sin embargo, el análisis temporal de un tratamiento puede ser altamente significativo en la toma ágil de decisiones médicas, y de ahí la relevancia de nuestro estudio.

**Objetivo general**

El objetivo, por tanto, es emplear la inteligencia artificial para predecir la eficacia de los tratamientos contra el cáncer de mama en pacientes individuales. Utilizando una base de datos compuesta por 242 muestras de imágenes de resonancia magnética (RM) tomadas en diferentes etapas del tratamiento (antes del tratamiento, en las primeras fases, en una fase intermedia y al final del tratamiento), tu estudio busca analizar estas imágenes en sus diversas modalidades (T1 y T2, DW, DCE) para identificar patrones que puedan predecir la respuesta al tratamiento. Este enfoque tiene el potencial de personalizar los tratamientos oncológicos, mejorando así los resultados y la calidad de vida de los pacientes, al tiempo que reduce los costos y efectos secundarios asociados con terapias ineficaces.

**Metodología**

La experimentación planteada constó de dos partes:

1. Modelado y entrenamiento de una red CNN que segmente tumores mamarios en diferentes fases de tratamiento.
2. Modelado y entrenamiento de una red RNN que ofrezca un indicador de la efectividad de un tratamiento a partir de los resultados de la fase anterior, así como la indicación de la fase del tratamiento en la que se encuentre.

**Resultados**

Los resultados obtenidos en la fase de modelado del cáncer están siendo altamente prometedores debido a la aparición de disyuntivas en la línea principal de investigación, cuya resolución está arrojando luz en varios aspectos clave.

**Trabajos futuros**

La investigación no ha terminado con este proyecto. Los resultados obtenidos son esperanzadores, pero se pueden seguir mejorando.

## 2. Objetivos iniciales del proyecto y grado de consecución

En esta sección, recomendamos completar la siguiente tabla, añadiendo los apartados que se vean necesarios o quitando los que no se necesiten.

| Tipo | Objetivo | Imagen | Grado de consecución |
|---|---|---|---|
| Principal | Desarrollar un modelo de inteligencia artificial basado en redes neuronales convolucionales (CNN) y redes neuronales recurrentes (RNN) para analizar las imágenes de resonancias magnéticas (RM) en series temporales de pacientes con cáncer de mama | | 70% |
| Secundario/ Específico | Utilizar la base de datos del estudio ACRIN 6698, que consta de 242 pacientes con cáncer de mama, para entrenar y validar el modelo de IA. Esta base de datos incluye imágenes de RM tomadas en cuatro momentos diferentes del tratamiento: pre-tratamiento, primeras fases de tratamiento, fase intermedia del tratamiento, y post-tratamiento | | 100% |
| Secundario/ Específico | Explorar la posibilidad de utilización de técnicas de transfer learning en el modelo de CNN-RNN, utilizando puntos de semilla para la localización de tumores en las imágenes de RM | | 70% |
| Secundario/ Específico | Evaluar la capacidad predictiva del modelo de IA desarrollado en relación a los resultados clínicos relevantes para el cáncer de mama en diferentes fases del tratamiento | | 70% |
| Secundario/ Específico | Comparar y analizar el rendimiento del modelo de IA a medida que se incorporan las diferentes series temporales de las imágenes de RM. Esto permitirá determinar la importancia de la evolución temporal en la predicción de los resultados clínicos. | | 50% |
| Secundario/ Específico | Demostrar la viabilidad y utilidad de los biomarcadores radiómicos no invasivos basados en inteligencia artificial para mejorar las predicciones clínicas en el cáncer de mama. Esto se logrará al comparar los resultados del modelo de IA con las predicciones realizadas por médicos expertos y evaluar su capacidad para estratificar a los pacientes en grupos de riesgo de mortalidad. | | 80% |
| Secundario/ Específico | Los resultados obtenidos en cada una de las experimentaciones realizadas serán recogidos en distintas publicaciones científicas que serán sometidas a congresos y revistas científicas. | | 50% |

| | | | |
|---|---|---|---|
| Secundario/ Específico | En los casos en que sea posible se procederá a la protección de la propiedad intelectual generada de la forma más adecuada en cada caso (patentes, modelos de utilidad, registros de propiedad intelectual, etc). Para ello se contará con la ayuda y asesoramiento de la Oficina de Transferencia de los Resultados de la Investigación (OTRI) de la Universidad de Oviedo. | | 0% |
| Secundario/ Específico | Asentar una relación de colaboración entre la Universidad de Oviedo y la Universidad de Purdue (Indiana, USA). | | 100% |

## 3. Tareas realizadas:

| ID | Descripción | MESES | | | | | |
|---|---|---|---|---|---|---|---|
| | | 1 | 2 | 3 | 4 | 5 | 6 |
| **Fase 1** | **Análisis de las técnicas empleadas en la actualidad para el modelado del cáncer de mama a partir de resonancias magnéticas.** | | | | | | |
| Tarea 1.1 | Análisis de técnicas de pre-procesamiento de imágenes de resonancia magnética con el objetivo de filtrar y extraer las características relevantes a nuestra investigación | | | | | | |
| Tarea 1.2 | Análisis de técnicas que permitan la extracción de la región de interés 3D que modela el tumor a partir de un punto central determinado por un experto | | | | | | |
| **Fase 2** | **Análisis de viabilidad e implementación del modelado mediante redes neuronales** | | | | | | |
| Tarea 2.1 | Viabilidad y modelado de red de análisis de información visual a partir de redes neuronales convolucionales | | | | | | |
| Tarea 2.2 | Viabilidad y modelado de red que modele las series temporales a partir de redes neuronales recurrentes | | | | | | |
| **Fase 3** | **Comparación con los métodos actualmente en uso** | | | | | | |
| Tarea 3.1 | Desarrollo de las métricas necesarias para la comparación de la eficacia de los algoritmos desarrollados en comparación con las técnicas empleadas en la actualidad | | | | | | |
| **Fase 4** | **Desarrollo de publicaciones científicas** | | | | | | |
| Tarea 4.1 | Publicación en revistas y congresos de los resultados obtenidos | | | | | | |
| Tarea 5.1 | Desarrollo de las métricas necesarias para la comparación de la eficacia de los algoritmos desarrollados en comparación con las técnicas | | | | | | |

| | | | | | | | |
|---|---|---|---|---|---|---|---|
| | empleadas en la actualidad | | | | | | |
| **Fase 6** | **Desarrollo de publicaciones científicas** | | | | | | |
| Tarea 6.1 | Publicación en revistas y congresos de los resultados obtenidos | | | | | | |

*Figure 1. Planificación del Proyecto*

**Metodología**

La experimentación planteada constó de dos partes:

1. *Modelado y Entrenamiento de una Red CNN para Segmentación de Tumores Mamarios*

En la primera fase de nuestra investigación, nos enfocamos en el desarrollo y entrenamiento de una red neuronal convolucional (CNN) para la segmentación de tumores mamarios en imágenes de resonancia magnética (RM) obtenidas en diferentes fases del tratamiento. Inicialmente, comenzamos con el entrenamiento de una CNN clásica en 2D, utilizando las capas de la RM como un array de imágenes planas. Esta aproximación inicial nos permitió establecer una base sólida para comprender las características fundamentales de los tumores mamarios y su representación en las imágenes.

Sin embargo, a medida que avanzamos en la revisión de la literatura y en nuestros experimentos, identificamos la necesidad de capturar información más detallada y contextual de las imágenes. Por lo tanto, decidimos transitar hacia el desarrollo de una red CNN en 3D. Las redes 3D CNN utilizan filtros tridimensionales, lo que les permite recoger características y conexiones pertenecientes a diferentes planos de la resonancia magnética. Esto significa que pueden capturar información espacial y contextual más rica, crucial para una segmentación precisa de los tumores.

El proceso de transición a una 3D CNN implicó una dedicación significativa de tiempo y recursos, incluyendo la realización de numerosas pruebas y ajustes en la arquitectura de la red. Se experimentó con diferentes configuraciones de capas, funciones de activación y algoritmos de optimización para mejorar la precisión de la segmentación. Los resultados preliminares de esta fase han sido prometedores, mostrando una mejora notable en la capacidad de la red para segmentar tumores mamarios en comparación con el enfoque 2D inicial. Estos resultados formarán la base de una publicación que planeamos someter a una revista científica especializada.

2. Modelado y Entrenamiento de una Red RNN para la Evaluación de la Efectividad del Tratamiento

La segunda parte de nuestra metodología se centra en el desarrollo y entrenamiento de una red neuronal recurrente (RNN) para evaluar la efectividad del tratamiento del cáncer de mama. El objetivo de esta red es proporcionar un indicador de la eficacia del tratamiento basándose en los resultados obtenidos en la fase anterior del tratamiento y la fase actual en la que se encuentra el paciente.

Para lograr esto, la RNN se entrena con datos temporales que incluyen la evolución de las características del tumor a lo largo del tiempo, capturadas en las sucesivas imágenes de RM. Esta red es capaz de procesar secuencias de datos, lo que la hace ideal para entender y predecir patrones a lo largo del tiempo, un aspecto crucial en la evaluación del progreso del tratamiento.

La RNN utiliza los resultados de segmentación proporcionados por la CNN como entrada, lo que permite una integración efectiva de información espacial y temporal. Este enfoque combinado busca ofrecer una evaluación más precisa y detallada de la respuesta del tumor al tratamiento, lo cual es fundamental para la toma de decisiones clínicas y la personalización de los planes de tratamiento para los pacientes.

Tras una fase inicial de análisis del estado del arte, y toma de decisiones sobre los algoritmos a aplicar, se genera una arquitectura de red, y un primer prototipo. Este prototipo está en espera de que finalice la comparativa entre los dos tipos de CNN para obtener los primeros resultados.

## 4. Resultados obtenidos

Los resultados obtenidos en la segmentación 3D alcanzan un DICE de 0.82 y un recall de 0.84, si bien, estamos trabajando en una fase de post-procesamiento para intentar incrementarlos antes de continuar a la siguiente fase. En la red 2D estamos obteniendo un DICE de 0.72, aunque estamos descubriendo un amplio margen de mejora debido a que las técnicas de pos-procesamiento 2D sin significativamente mejores. Cabe señalar que ambas métricas no son directamente comparables dado las diferentes naturalezas de ambas redes. Actualmente, también estamos trabajando en un marco de estandarización que nos permita comparar los resultados de ambas redes.

## 5. Trabajos o necesidades futuras

Debido a las complicaciones encontradas que nos lleva a hacer una comparativa entre diferentes CNNs, podemos afirmar que la investigación no ha terminado. Los próximos retos a afrontar son:

1. **Mejora y Optimización de Modelos 3D CNN:** Aunque se han logrado avances significativos con la implementación de 3D CNN para la segmentación de tumores mamarios, existe un potencial considerable para mejorar y optimizar estos modelos. Esto incluye ajustar la arquitectura de la red, experimentar con diferentes técnicas de regularización y aumentación de datos, y explorar nuevos métodos para manejar el desequilibrio de clases en los datos de entrenamiento.
2. **Integración y Sincronización de CNN y RNN:** Un área clave de desarrollo futuro es la integración más efectiva de las redes CNN y RNN para proporcionar una evaluación más precisa y detallada de la respuesta del tumor al tratamiento. Esto podría incluir la sincronización de la salida de la CNN con la entrada de la RNN para mejorar la precisión en la predicción de la efectividad del tratamiento en diferentes fases.

3. **Validación Clínica y Estudios Comparativos:** Es crucial realizar estudios clínicos para validar la eficacia y la precisión de los modelos desarrollados. Esto incluye comparar los resultados de la segmentación 3D con los de la segmentación 2D y evaluar cómo cada enfoque afecta la precisión en la predicción de la efectividad del tratamiento. La validación clínica ayudará a establecer la viabilidad y la aplicabilidad de estos modelos en entornos de atención médica reales.
4. **Exploración de Transfer Learning y Modelos Preentrenados:** Investigar el uso de técnicas de transfer learning y la aplicación de modelos preentrenados podría ser un paso significativo para mejorar la eficiencia del entrenamiento y la precisión de los modelos. Esto es particularmente relevante en el campo de la imagen médica, donde la disponibilidad de grandes conjuntos de datos anotados es a menudo limitada.

## 6. Divulgación de los resultados

La morfología del data set hizo que se tuviese que aplicar un preprocesado a los datos para hacer un cambio de dominio y una reducción de la dimensionalidad de los mismos no previstas inicialmente. Esto provocó que no se pudiese abordar la fase de divulgación de los resultados.

Se espera comenzar con la misma en breve. A continuación se muestran los congresos y revistas en los que se intentará publicar los resultados.

Entre los congresos en los que se planea publicar los resultados están los siguientes:

- SOCO 2024. 19th International Conference on Soft Computing Models in Industrial and Environmental Applications.
- HAIS 2024. 19th International Conference on Hybrid Artificial Intelligence Systems.
- IEEE CBMS 2024. IEEE 37th International Symposium on Computer Based Medical Systems.
- CASEIB 2024. XLII Congreso Anual de la Sociedad Española de Ingeniería Biomédica.

Entre las revisas en las que se prevé publicar resultados de este proyecto están:

- Neurocomputing (Elsevier Science BV). Q2. Índice de impacto a 5 años en 2021 de 5,416.
- Expert Systems. (John Wiley & Sons Ltd.). Q2. Índice de impacto a 5 años en 2021 de 2,617.
- Logic Journal of the IGPL (Oxford University Press). Q2 Índice de impacto a 5 años en 2021 de 0,848.
- iScience. (Cell Pres). Q1 Índice de impacto a 5 años en 2021 de 6,233.

# Memoria económica

## 1. Gastos:

| Concepto | Gasto |
|---|---|
| Personal (IUTA) | 12.000€ |
| Fungibles | 3.000€ |
| Amortización | 1.000€ |
| Otros (Desplazamientos, Inscripciones a Congresos, etc.) | 6.000€ |
| **TOTAL GASTOS** | **19.300€** |

## 2. Ingresos:

Añade los ingresos finales que has tenido a lo largo del proyecto. Indica las empresas y las referencias de los proyectos/contratos.

| Entidad/Empresa financiadora Ref. Proyecto/Contrato | Concepto | Ingreso |
|---|---|---|
| IUTA | Ayuda IUTA: Contratación de personal | 3.800€ |
| Otras entidades / empresas financiadoras | | 0€ |
| Financiación propia | | 15.500€ |
| | **TOTAL INGRESOS** | **19.300€** |

Firmado por VILLAR FLECHA JOSE RAMON - ***0578** el día 23/01/2024 con un certificado emitido por AC FNMT Usuarios