



UNIVERSIDADE DA CORUÑA

**PROYECTO FIN DE CARRERA
DE
INGENIERÍA EN INFORMÁTICA**

Departamento de Tecnologías de la Información y las Comunicaciones

**OPTIMIZACIÓN Y ANÁLISIS DEL RENDIMIENTO DE
SISTEMAS CONEXIONISTAS NEUROGLIALES**

Autor

Pablo Mesejo Santiago

Directores

Ana Belén Porto Pazos

Óscar Ibáñez Panizo



UNIVERSIDADE DA CORUÑA



CONTENIDO

- Introducción.
- Objetivos.
- Antecedentes.
- Desarrollo del entorno de simulación.
- Primera Fase. Análisis de la eficiencia.
 - Experimentación.
- Segunda Fase. Optimización.
 - Experimentación.
- Conclusiones.
- Trabajos Futuros.

1. INTRODUCCIÓN (I)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

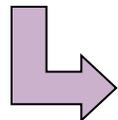
7. Conclusiones

8. Trabajos Futuros

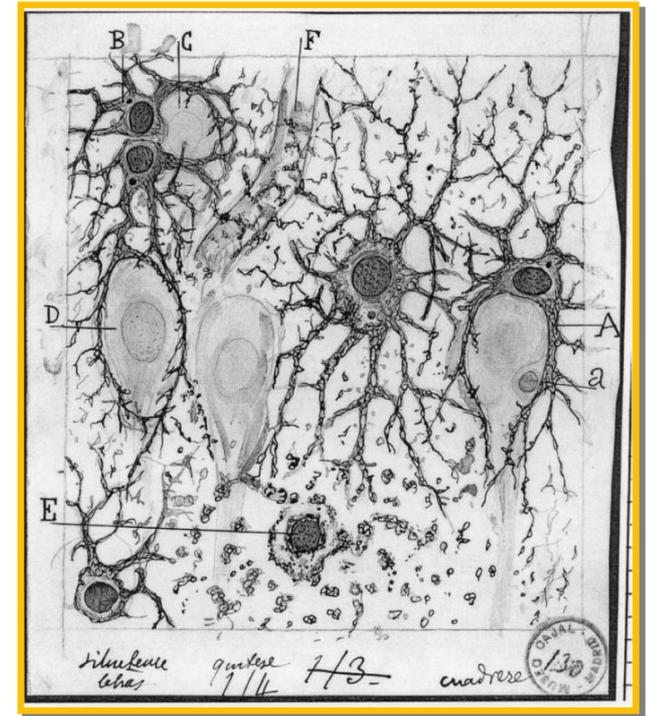
- Mayor proporción de glía:
 - Zonas del cerebro donde tienen lugar procesos cognitivos de alto nivel (aprendizaje, memoria).
 - Especies más evolucionadas escala filogenética.

- **Descubrimiento Reciente:** Papel fundamental de los **astrocitos** del Sistema Glial en el procesamiento de la información en el Sistema Nervioso.

- En 2004 se incorporan los astrocitos artificiales a RNA



Nacen las **Redes NeuroGliales Artificiales** (RNGA)



1. INTRODUCCIÓN (II)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

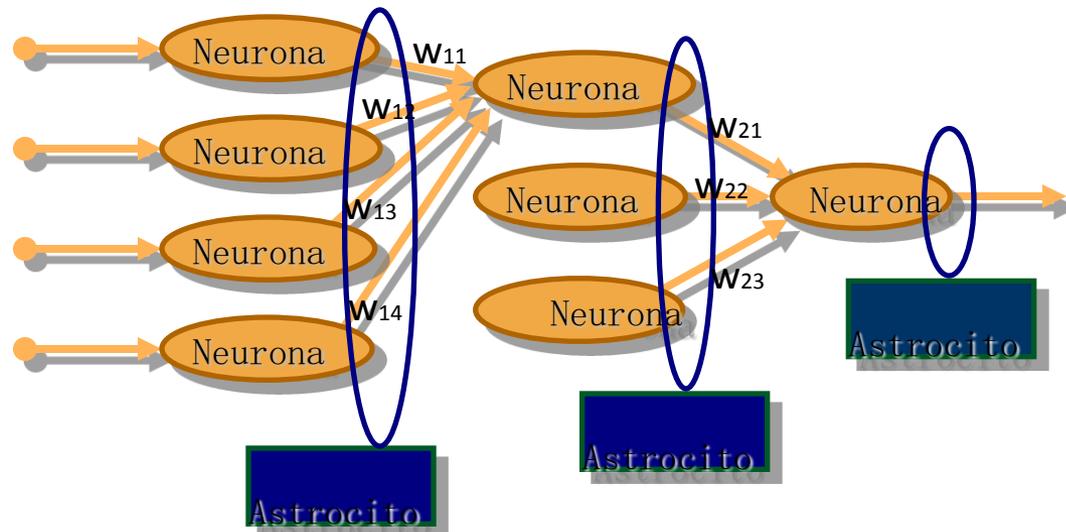
7. Conclusiones

8. Trabajos Futuros

- **RNGA:** neuronas artificiales (RNA) + astrocitos artificiales + Algoritmos Genéticos (AG).

- Introducción de elementos de control, por cada capa, que simulan los astrocitos:

➤ Refuerzan conexiones de neuronas activas y debilitan conexiones de neuronas inactivas, en base al número de veces que la neurona se activa al introducir X veces un determinado patrón.



1. INTRODUCCIÓN (y III)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

● Método Híbrido de Aprendizaje:



● No supervisado: basada en el comportamiento observado de astrocitos.

➤ Cada patrón se presenta a la red **X iteraciones** (ciclo de patrón). Inspirado en la lentitud de la influencia astrocítica.

➤ Modificación de los pesos en un % según el número de **activaciones** de las neuronas.

● Supervisado: AG (según el ECM de la red calculado en la fase no supervisada).

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

2. OBJETIVOS (I)

- Proyecto de Investigación y Desarrollo compuesto por dos fases.

- Objetivos Generales:

- Mejorar los modelos conexionistas actuales: encontrar un mejor método de resolución de problemas de predicción y clasificación (**Inteligencia Artificial**).

- Profundizar en el funcionamiento del Sistema Nervioso (**Neurociencia**).

- Objetivos Específicos:

- Estudiar la influencia de los astrocitos artificiales en el procesamiento de la información (**RNGA vs RNA**).

- Analizar dicha influencia cuando aumenta la **complejidad** de los problemas abordados y de la arquitectura de las redes analizadas.

- Realizar una **optimización** automática de la configuración de los parámetros característicos de la glía artificial en RNGA.

2. OBJETIVOS (y II)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno
de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

● Para alcanzar dichos objetivos:

➤ Aplicación técnica *cross-validation* 5x2cv:

- Garantiza resultados no dependen del orden de presentación de los patrones.

➤ Comparar los resultados obtenidos aplicando *5x2 cross-validation* a cuatro problemas:

- Clasificación: Flor de Iris | Señales de la Ionosfera.
- Predicción: Cáncer de Mama | Enfermedades Coronarias.

➤ Emplear test estadísticos para verificar los resultados

- Test t de Student para muestras apareadas.
- Test de Wilcoxon de los rangos signados.

3. ANTECEDENTES

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

- Metodología desarrollada de RGA probada, hasta el momento, únicamente con problemas sencillos.
- Colaboración con el *Laboratorio de Electrofisiología Celular de astrocitos y neuronas*. Instituto de Neurobiología Ramón y Cajal del CSIC en Madrid.
- No existen publicaciones ni estudios de otros grupos que trabajen en esta línea de investigación.
 - Lo más próximo realizado en este respecto son modelizaciones matemáticas que no usan el conocimiento sobre los astrocitos directamente en las implementaciones.

4. DESARROLLO DEL ENTORNO DE SIMULACIÓN (I)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

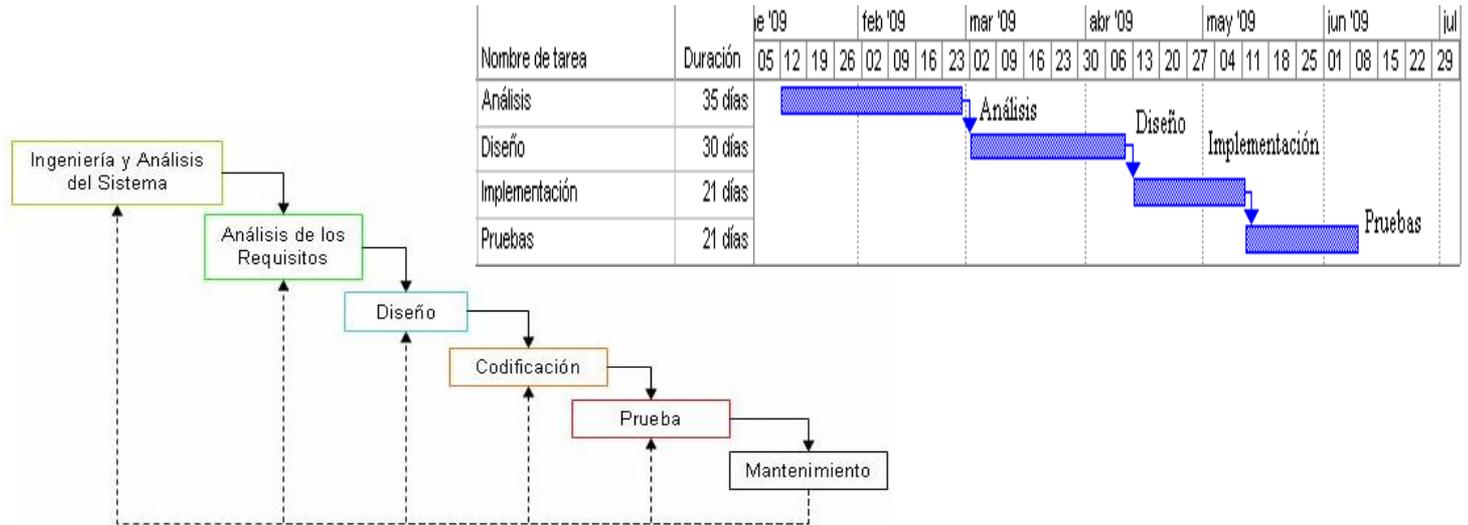
6. Segunda Fase

6.1. Experimentación.

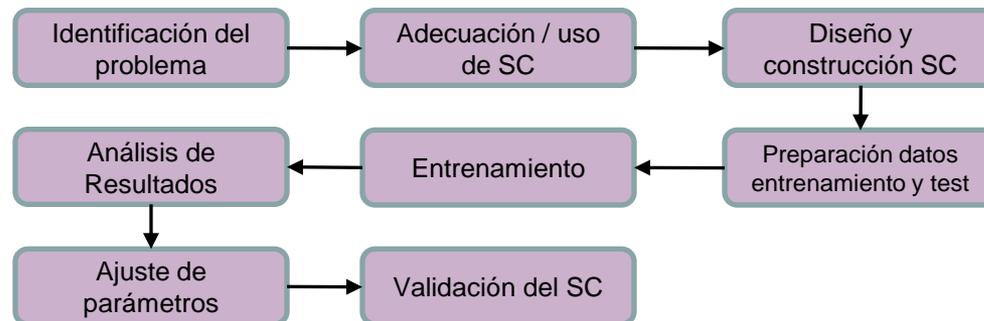
7. Conclusiones

8. Trabajos Futuros

● Metodología de desarrollo software:



● Metodología de diseño y construcción de SC:



4. DESARROLLO DEL ENTORNO DE SIMULACIÓN (II)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

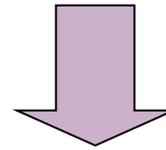
7. Conclusiones

8. Trabajos Futuros

- Para analizar las RNGA (nuevos Sistemas Conexionistas) y compararlos con otros ya existentes.

↳ Elevado número de pruebas

↳ Muy alto coste computacional



- Necesidad de paralelizar el mayor número posible de procesos:

- ✗ Centros de supercomputación, CESGA (FinisTerae y SVG).
- ✗ Scripts en Shell de Unix.
- ✗ Ficheros de parámetros.
- ✗ Estructura de directorios.
- ✗ Herramientas de análisis automático de datos en MATLAB.
- ✗ Análisis estadístico en MATLAB y R.

4. DESARROLLO DEL ENTORNO DE SIMULACIÓN (III)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

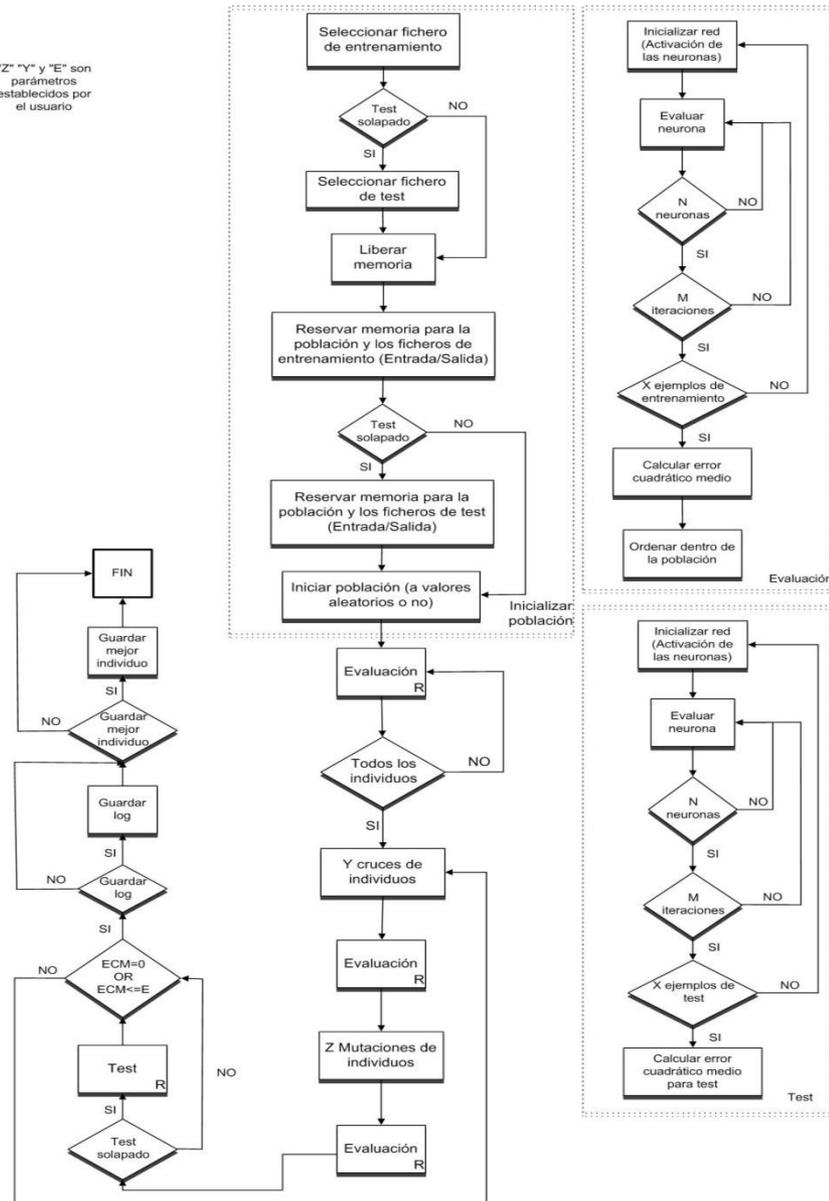
7. Conclusiones

8. Trabajos Futuros

Optimización y adaptación a lenguaje C de una herramienta de diseño, entrenamiento y test escrita en Delphi para su uso en el CESGA.

Optimizaciones realizadas en el modo de compilación y en el envío de trabajos disminuyeron los tiempos de ejecución de 50 a 9 horas.

Z *Y* y *E* son parámetros establecidos por el usuario



1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

4. DESARROLLO DEL ENTORNO DE SIMULACIÓN (y IV)

- 500 - 1000 ficheros de resultados en cada problema.

- Herramientas de Análisis de Datos:

- ↗ Implementadas en MATLAB.

- ↗ Vuelcan los resultados en EXCEL.

- Modos de Análisis

- ↗ Modo 1: Media de los menores ECM de test (visión preliminar influencia glía artificial).

- ↗ Modo 2: Media de los ECM de test (100 casos) con el mejor individuo obtenido en la fase de entrenamiento en un tiempo t (el mismo para RNA que para RNGA).

- ↗ Modo 3: Dado un tiempo t capturar la media de los ECM de test en instantes múltiplo de t (evolución del error respecto del tiempo)

5. PRIMERA FASE: Análisis de la Eficiencia de RNGA vs RNA

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

- Datos tomados del UCI.

- **Comparación de Eficiencia:** Cada simulación para RNA y RNGA parte de los mismos parámetros AG, arquitectura de red, misma semilla de generación de números aleatorios, mismos conjuntos de entrenamiento y test, y mismas poblaciones.

- Parámetros AG:

- Tamaño población: 100 individuos Iris, 150 Cáncer, Corazón e Ionosfera (más complejos).

- Selección: técnica de Montecarlo.

- Tasa de cruces 90%; Tasa de mutaciones 10%.

- Parámetros RNGA:

- Algoritmo Glial. Existen 6 diferentes (Alvarellos, 2007).

- Iteraciones y Activaciones: 4-2, 6-2, 6-3 y 8-3.

- Porcentaje Incremento y Decremento: 25% y 50%.

5.1. EXPERIMENTACIÓN (I). Flor de Iris.

- Clasificación Flor de Iris en sus 3 especies: Setosa, Virgínica y Versicolor.

CLASIFICACIÓN DE FLOR DE IRIS	
PATRONES DE ENTRADA	150
ARQUITECTURAS EMPLEADAS	4-5-3
GENERACIONES	30000 (RNA) y 5000 (RNGA)
ALGORITMOS UTILIZADOS	Glía Atenuación y Glía No Atenuación Sin Límite de Pesos
SIMULACIONES	100 (RNA: 10 poblaciones x 10 conjuntos) y 800 (RNGA: 100 x 4 combinaciones iteración-activación x 2 algoritmos)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

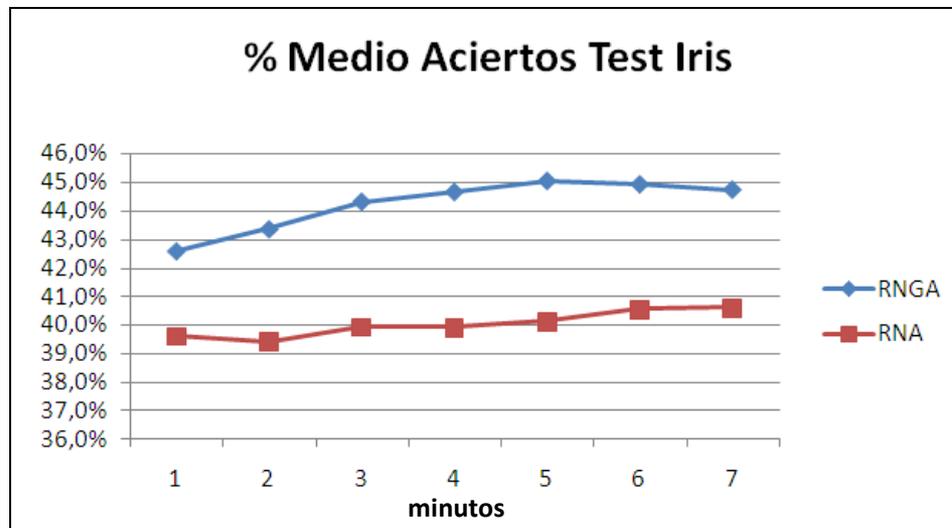
8. Trabajos Futuros

5.1. EXPERIMENTACIÓN (II). Flor de Iris. Resultados.

- 1. Introducción
- 2. Objetivos
- 3. Antecedentes
- 4. Desarrollo del entorno de simulación
- 5. Primera Fase.
5.1. Experimentación
- 6. Segunda Fase
6.1. Experimentación.
- 7. Conclusiones
- 8. Trabajos Futuros

● Resultados RNGA vs RNA (5 minutos de entrenamiento):

	RNGA	RNA	DIFERENCIAS RNGA-RNA
MEDIA ERROR ENTRENAMIENTO	0,42	0,46	
MEDIA % ACIERTOS TEST	45,09%	40,13%	4,96%
DESVIACIÓN TÍPICA ERRORES TEST	0,13	0,15	
MÍNIMO ERROR ENTRENAMIENTO	0,19	0,28	



	p-valor ($\alpha = 0.05$)
Wilcoxon	1.045e-06
t-test	1.855e-07

5.1. EXPERIMENTACIÓN (III). Enfermedades Coronarias.

- Detección de la presencia de enfermedad de corazón.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

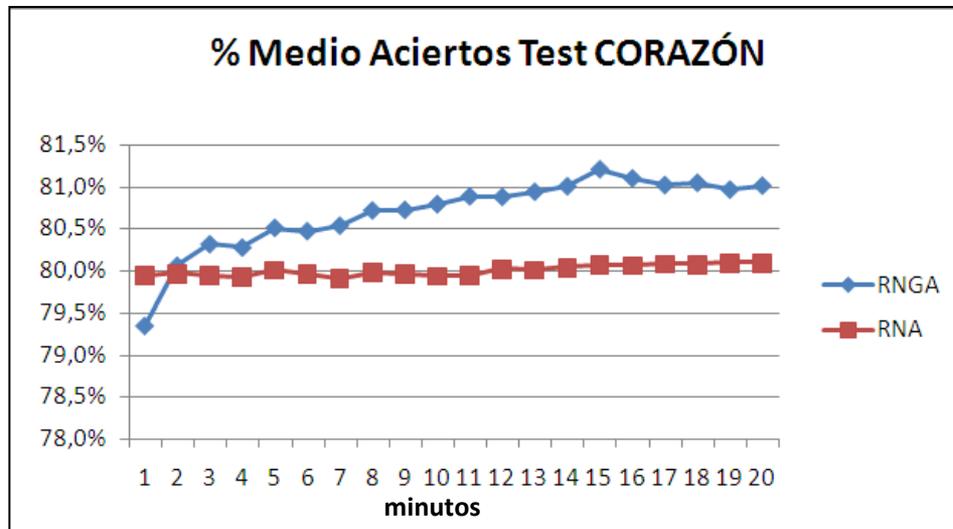
PREDICCIÓN DE ENFERMEDADES CORONARIAS	
PATRONES DE ENTRADA	303
ARQUITECTURAS EMPLEADAS	13-4-1
GENERACIONES	30000 (RNA) y 5000 (RNGA)
ALGORITMOS UTILIZADOS	Glía Atenuación y Glía No Atenuación Sin Límite de Pesos
SIMULACIONES	100 (RNA: 10 poblaciones x 10 conjuntos) y 800 (RNGA: 100 x 4 combinaciones iteración-activación x 2 algoritmos)

5.1. EXPERIMENTACIÓN (IV). Enfermedades Coronarias. Resultados.

- 1. Introducción
- 2. Objetivos
- 3. Antecedentes
- 4. Desarrollo del entorno de simulación
- 5. Primera Fase.
- 5.1. Experimentación**
- 6. Segunda Fase
- 6.1. Experimentación.
- 7. Conclusiones
- 8. Trabajos Futuros

● Resultados RNGA vs RNA (15 minutos de entrenamiento):

	RNGA	RNA	DIFERENCIAS RNGA-RNA
MEDIA ERROR ENTRENAMIENTO	0,10	0,12	
MEDIA % ACIERTOS TEST	81,21%	80,07%	1,14%
DESVIACIÓN TÍPICA ERRORES TEST	0,02	0,03	
MÍNIMO ERROR ENTRENAMIENTO	0,05	0,07	



	p-valor ($\alpha = 0.05$)
Wilcoxon	3.9e-04
t-test	9.0e-06

5.1. EXPERIMENTACIÓN (V). Cáncer de Mama.

- Predicción de enfermedad de Cáncer de Mama.

PREDICCIÓN DE CÁNCER DE MAMA	
PATRONES DE ENTRADA	699
ARQUITECTURAS EMPLEADAS	9-7-1, 9-7-3-1, 9-7-5-1, 9-9-5-3-1 y 9-12-8-4-1
GENERACIONES	30000 (RNA) y 5000 (RNGA)
ALGORITMOS UTILIZADOS	Glía Atenuación
SIMULACIONES	500 (RNA: 10 poblaciones x 10 conjuntos x 5 arquitecturas) y 2000 (RNGA: 100 x 4 combinaciones iteración-activación x 5 arquitecturas)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

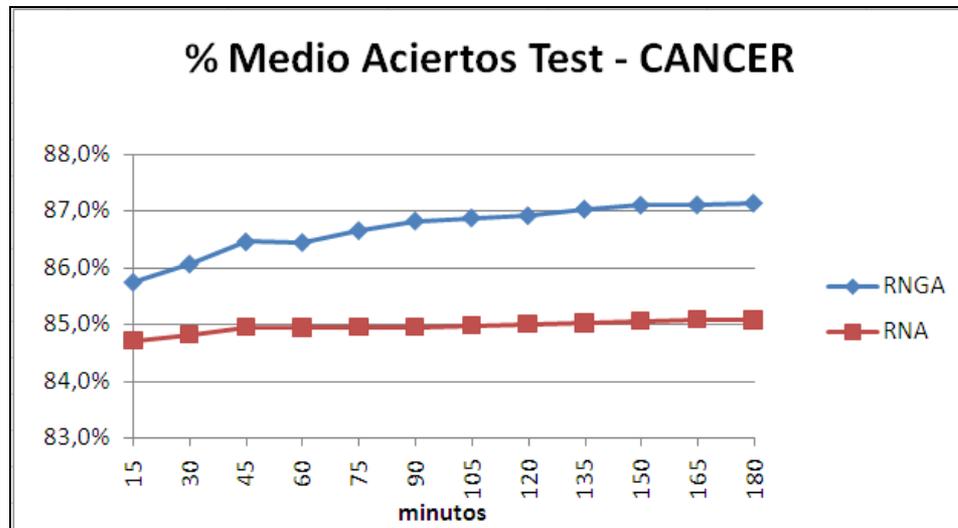
8. Trabajos Futuros

5.1. EXPERIMENTACIÓN (VI). Cáncer de Mama. Resultados.

- 1. Introducción
- 2. Objetivos
- 3. Antecedentes
- 4. Desarrollo del entorno de simulación
- 5. Primera Fase.
- 5.1. Experimentación**
- 6. Segunda Fase
- 6.1. Experimentación.
- 7. Conclusiones
- 8. Trabajos Futuros

● Resultados RNGA vs RNA (1h 45 minutos de entrenamiento con una capa oculta):

	1 CAPA OCULTA		
	RNGA	RNA	
MEDIA ERROR ENTRENAMIENTO	0,07	0,10	
MEDIA % ACIERTOS TEST	86,96%	84,98%	1,98%
DESVIACIÓN TÍPICA ERRORES TEST	0,12	0,12	
MÍNIMO ERROR ENTRENAMIENTO	0,01	0,05	

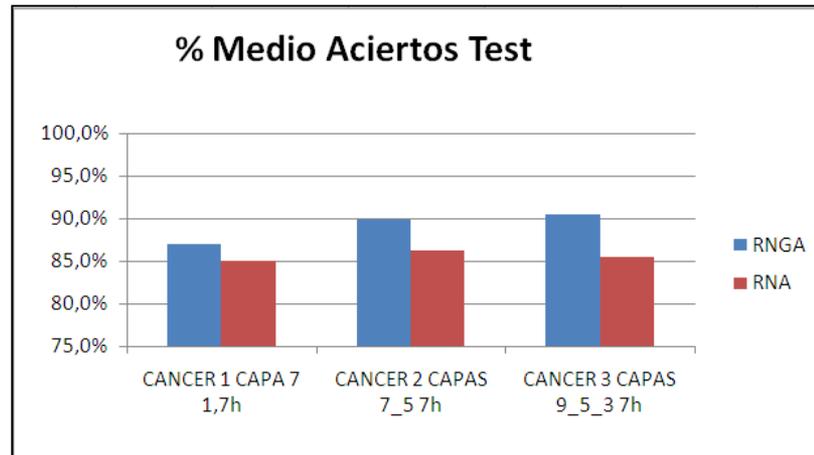


	p-valor (α = 0.05)
Wilcoxon	5.64e-11
t-test	1.33e-11

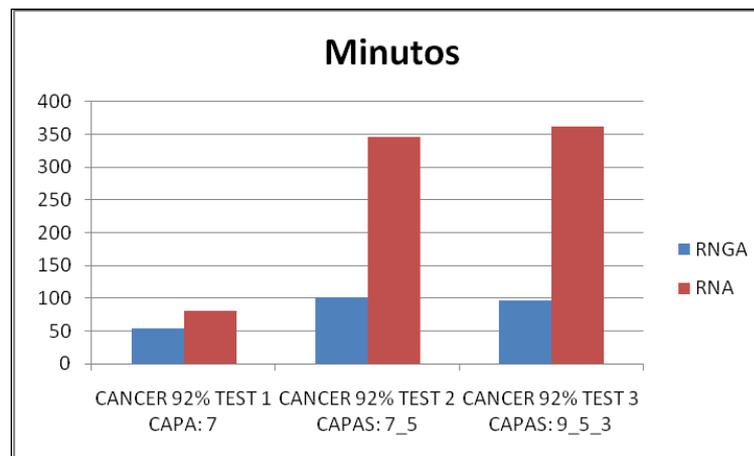
5.1. EXPERIMENTACIÓN (VII). Cáncer de Mama. Resultados. Estudio de Complejidad.

- 1. Introducción
- 2. Objetivos
- 3. Antecedentes
- 4. Desarrollo del entorno de simulación
- 5. Primera Fase.
5.1. Experimentación
- 6. Segunda Fase
6.1. Experimentación.
- 7. Conclusiones
- 8. Trabajos Futuros

● Resultados RNGA vs RNA (7 horas de entrenamiento con **dos y tres capas ocultas**):



Dos capas	p-valor ($\alpha = 0.05$)
Wilcoxon	2.25e-09
t-test	3.11e-26



Tres capas	p-valor ($\alpha = 0.05$)
Wilcoxon	2.2e-16
t-test	2.05e-36

5.1. EXPERIMENTACIÓN (VIII). Señales de Ionosfera.

- Clasificación de mediciones de radar de la capa de la ionosfera.

CLASIFICACIÓN DE SEÑALES DE LA IONOSFERA	
PATRONES DE ENTRADA	351
ARQUITECTURAS EMPLEADAS	34-9-1, 34-9-4-1, 34-9-8-1, 34-9-6-3-1 y 34-12-8-4-1
GENERACIONES	30000 (RNA) y 5000 (RNGA)
ALGORITMOS UTILIZADOS	Glía Atenuación
SIMULACIONES	500 (RNA: 10 poblaciones x 10 conjuntos x 5 arquitecturas) y 2000 (RNGA: 100 x 4 combinaciones iteración-activación x 5 arquitecturas)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

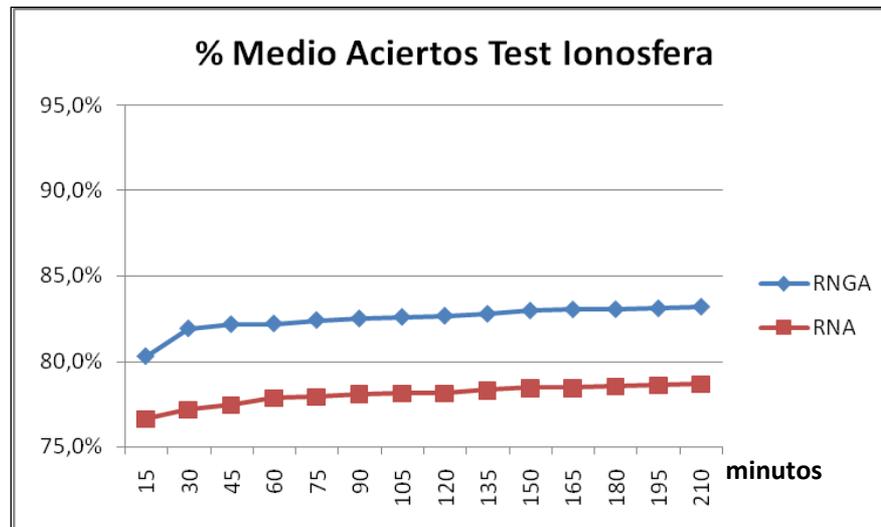
8. Trabajos Futuros

5.1. EXPERIMENTACIÓN (IX). Señales de Ionosfera. Resultados.

- 1. Introducción
- 2. Objetivos
- 3. Antecedentes
- 4. Desarrollo del entorno de simulación
- 5. Primera Fase.
- 5.1. Experimentación**
- 6. Segunda Fase
- 6.1. Experimentación.
- 7. Conclusiones
- 8. Trabajos Futuros

● Resultados RNGA vs RNA (2 horas de entrenamiento con **una capa oculta**):

	1 CAPA OCULTA		
	RNGA	RNA	
MEDIA ERROR ENTRENAMIENTO	0,07	0,15	
MEDIA % ACIERTOS TEST	83,28%	78,11%	5,17%
DESVIACIÓN TÍPICA ERRORES TEST	0,03	0,04	
MÍNIMO ERROR ENTRENAMIENTO	0,02	0,06	

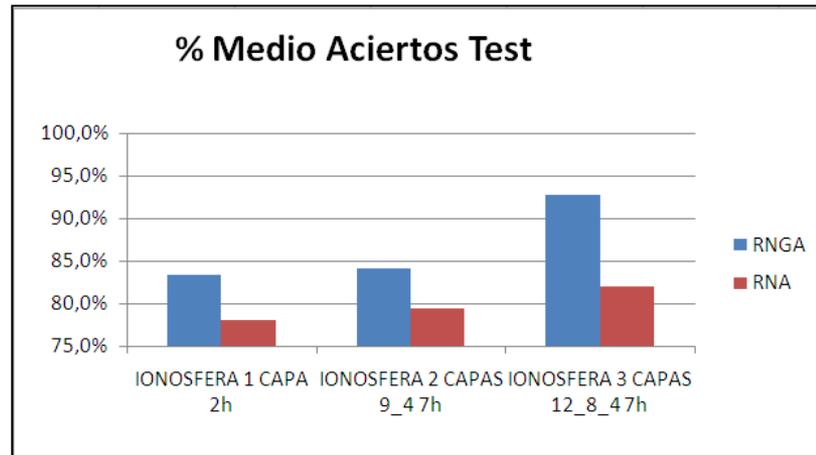


	p-valor ($\alpha = 0.05$)
Wilcoxon	1.55e-15
t-test	2.37e-21

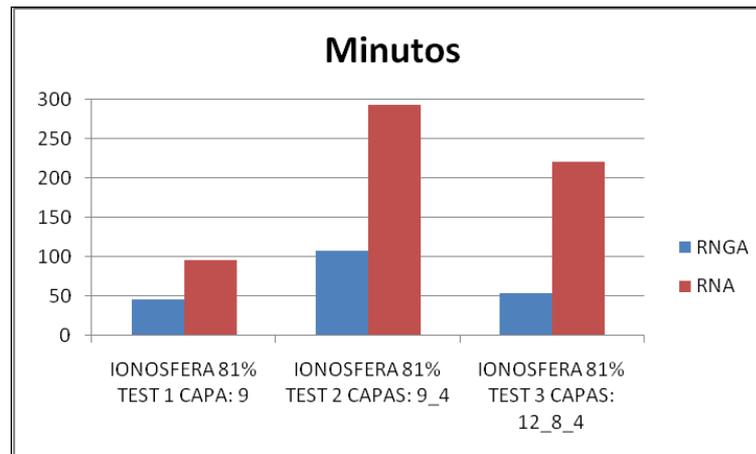
5.1. EXPERIMENTACIÓN (X). Señales de Ionosfera. Resultados. Estudio de Complejidad.

- 1. Introducción
- 2. Objetivos
- 3. Antecedentes
- 4. Desarrollo del entorno de simulación
- 5. Primera Fase.
5.1. Experimentación
- 6. Segunda Fase
6.1. Experimentación.
- 7. Conclusiones
- 8. Trabajos Futuros

● Resultados RNGA vs RNA (7 horas de entrenamiento con **dos y tres capas ocultas**):



Dos capas	p-valor ($\alpha = 0.05$)
Wilcoxon	1.3e-12
t-test	1.81e-15

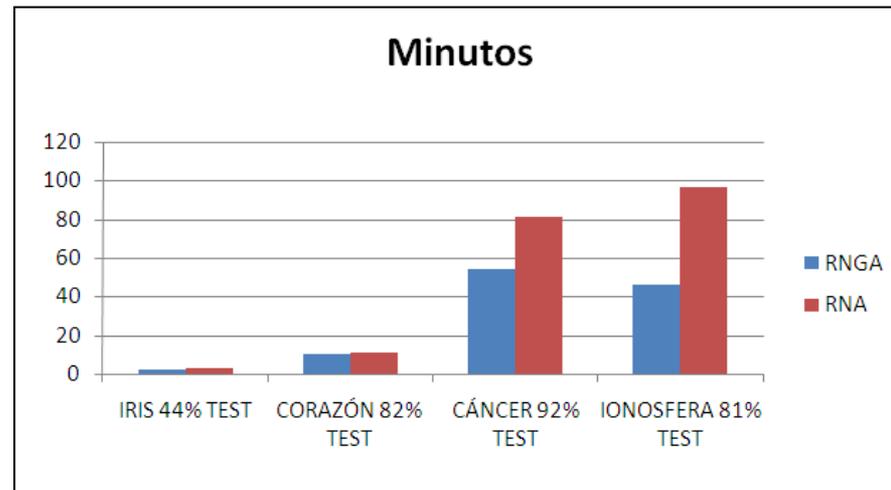
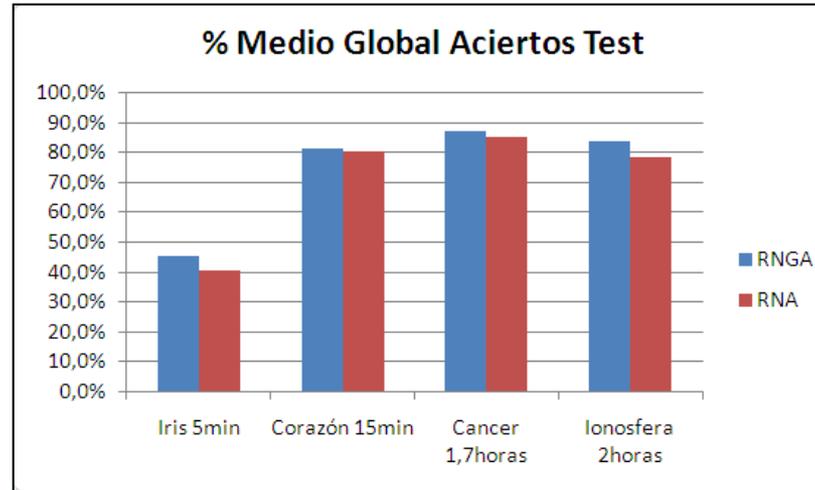


Tres capas	p-valor ($\alpha = 0.05$)
Wilcoxon	2.2e-16
t-test	4.3e-29

5.1. EXPERIMENTACIÓN (y XI). Resultados. Comparativa Global.

- 1. Introducción
- 2. Objetivos
- 3. Antecedentes
- 4. Desarrollo del entorno de simulación
- 5. Primera Fase.
5.1. Experimentación
- 6. Segunda Fase
- 6.1. Experimentación.
- 7. Conclusiones
- 8. Trabajos Futuros

● Resultados RNGA vs RNA:



6. SEGUNDA FASE (I). Optimización de RNGA mediante AG.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

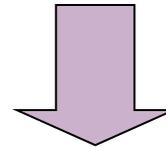
7. Conclusiones

8. Trabajos Futuros

- **Segunda Fase del Proyecto:** Estudio preliminar sobre la selección automática de los parámetros inherentes a las RNGA.

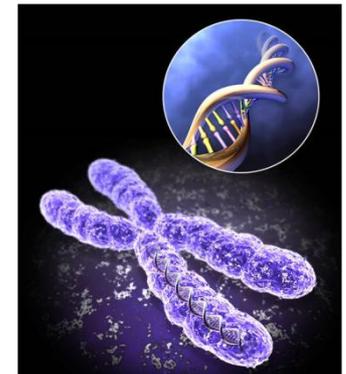
↗ Múltiples combinaciones

- Algoritmos Gliales.
- Combinaciones iteración-activación.
- Porcentajes de decremento e incremento.



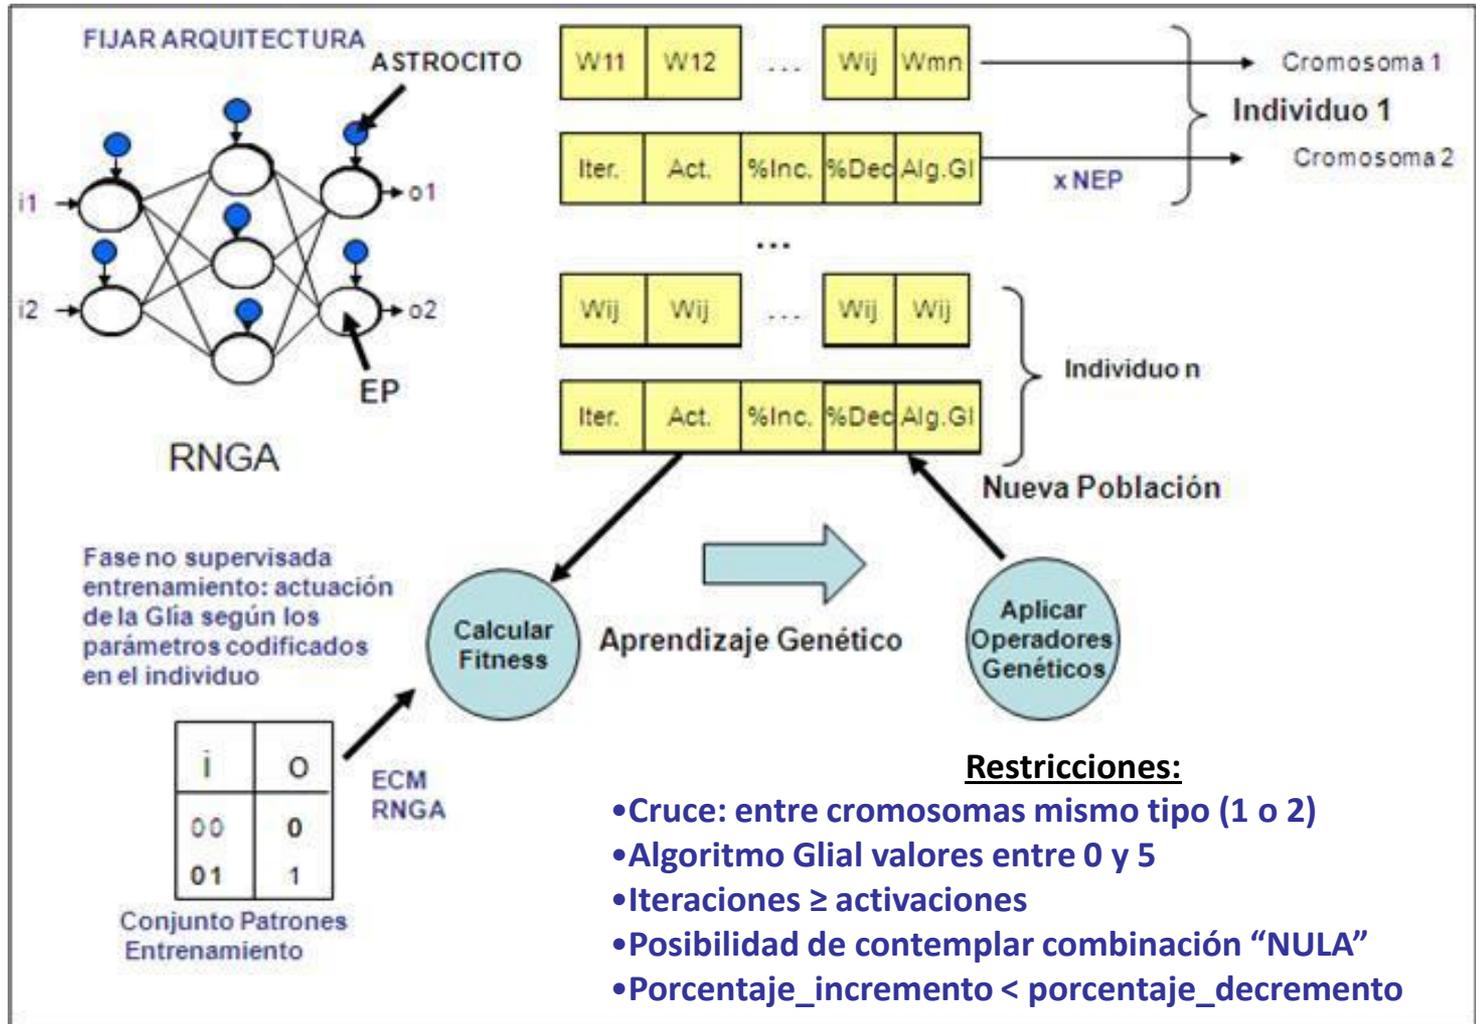
Excesivo número de pruebas

Se recurre a técnicas de Computación Evolutiva (CE):
Algoritmos Genéticos (AG)



6. SEGUNDA FASE (II). Optimización de RNGA mediante AG. Metodología.

- 1. Introducción
- 2. Objetivos
- 3. Antecedentes
- 4. Desarrollo del entorno de simulación
- 5. Primera Fase.
 - 5.1 Experimentación
- 6. Segunda Fase**
 - 6.1. Experimentación.
- 7. Conclusiones
- 8. Trabajos Futuros



6. SEGUNDA FASE (III). Optimización de RNGA mediante AG. Metodología.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

- Características primera versión implementada de la metodología:
 - ↗ Un cromosoma de parámetros para toda la red.
 - ↗ No se considera la posibilidad de combinación NULA.
 - ↗ Combinaciones iteración-activación con $3 \leq \text{iteración} \leq 9$ e iteraciones \geq activaciones.
 - ↗ Porcentajes de incremento y decremento: números enteros múltiplos de 10 entre 10 y 90, teniendo en cuenta que $\text{porcentaje_incremento} < \text{porcentaje_decremento}$.

- Proceso de optimización de las RNGA:
 - ↗ Empleo del AGCC.
 - Ajuste de sus parámetros.
 - ↗ Inclusión del Operador SBX.
 - Ajuste de sus parámetros.
 - ↗ Pruebas con Iris y Cáncer.

6. SEGUNDA FASE (IV). Optimización de RNGA mediante AG. Metodología.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

6. Segunda Fase

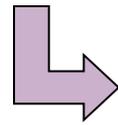
6.1. Experimentación.

7. Conclusiones

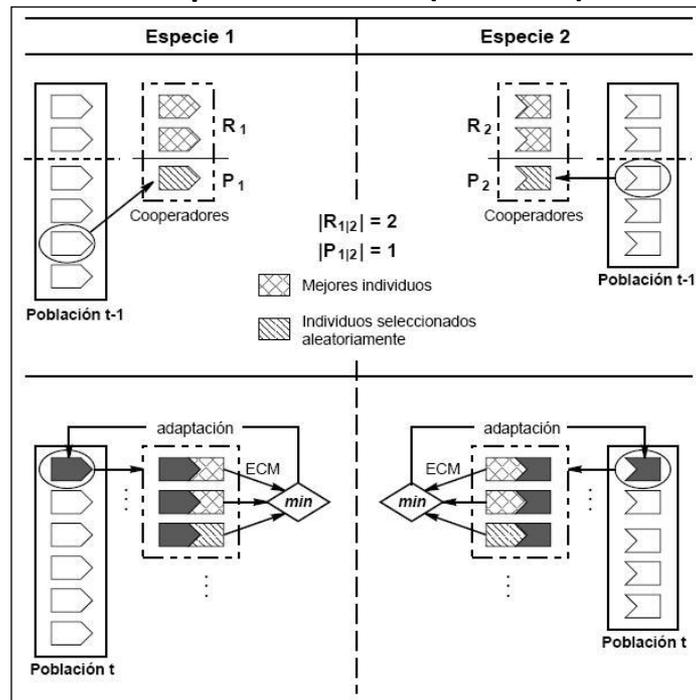
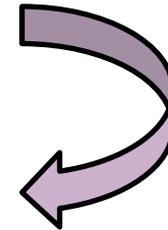
8. Trabajos Futuros

● Características del problema a resolver:

- ↪ Espacio de búsqueda complejo.
- ↪ Problema descomponible.
- ↪ Diferentes tipos de valores y conceptos.
- ↪ Fuerte interdependencia de los componentes de la solución.



Algoritmo Genéticos Coevolutivos Cooperativos (AGCC)



6. SEGUNDA FASE (y V). Optimización de RNGA mediante AG. Metodología.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1 Experimentación

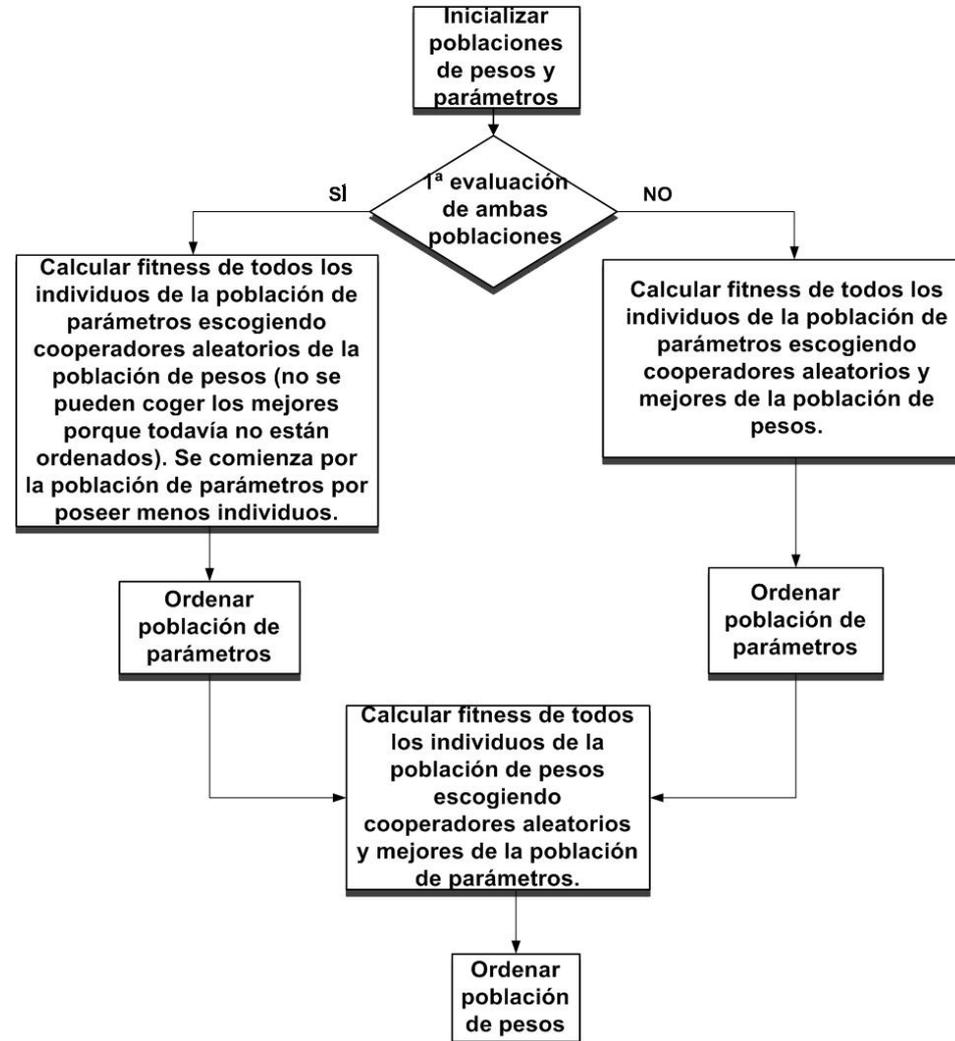
6. Segunda Fase

6.1. Experimentación.

7. Conclusiones

8. Trabajos Futuros

- Diagrama de flujo resumido del proceso de evaluación:



6.1. EXPERIMENTACIÓN (I). Ajuste del AGCC.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

- **Ajuste de parámetros del AGCC** con el problema de Ionosfera y 1 capa oculta: 540 simulaciones.

Cruce Coevolutivo	Mutación Coevolutivo	Tamaño población pesos	Tamaño población parámetros	Número cooperantes aleatorios	Número cooperantes mejores	Tipo fitness
90	1	50	10	1	1	Mínimo
	10	100	25	2	2	Media
		150	30	3	3	máximo

- **Conclusiones extraídas del ajuste:**

- ↗ Los mejores resultados se obtienen con los fitness mínimo y media.
- ↗ Porcentajes de cruce y mutación del AGCC: 90% y 10%.
- ↗ Número de individuos: 150 (pesos) y 50 (parámetros).
- ↗ Número de cooperantes: 3 mejores y 3 aleatorios.
- ↗ Es necesario un mucho mayor tiempo de convergencia (7500 generaciones como mínimo, 70 horas en lugar de 20 horas).

6.1. EXPERIMENTACIÓN (II). Operador SBX.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

- Operador para cromosomas de codificación real y sin punto de cruce que combina los genes de los padres en una determinada proporción para obtener los hijos.
 - ↗ Rapidez de convergencia.
 - ↗ Evitar la pérdida de diversidad en la población (equilibrio entre exploración y explotación).
- Simulaciones con Ionosfera (2 capas ocultas) y Cáncer (3 capas ocultas):
 - ↗ Parámetro η : A mayores valores de η más parecidas serán las soluciones hijas a los padres, A menores valores mayor variabilidad y diversidad. Pruebas con 0.1, 0.3, 0.5, 0.6 y 1.
 - ↗ TOTAL: 5000 simulaciones para comprobar la pertinencia de introducir el nuevo operador.

6.1. EXPERIMENTACIÓN (III). Operador SBX.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

● Resultados de ajuste del operador SBX:

DIFERENCIAS RESULTADOS PARA IONOSFERA 9_4		$\eta = 0,3$		$\eta = 0,5$	
		SIN GLÍA	CON GLÍA	SIN GLÍA	CON GLÍA
MODO 1	% aciertos test	4,64%	1,32%	3,77%	1,21%
	media tiempo para alcanzar el mínimo (en minutos)	-93,6	-65,1	-105,3	-46,5
MODO 2 (7 horas)	% aciertos test	4,45%	1,12%	3,58%	1,12%
DIFERENCIAS RESULTADOS PARA CÁNCER 9_5_3		$\eta = 0,3$		$\eta = 0,1$	
		SIN GLÍA	CON GLÍA	SIN GLÍA	CON GLÍA
MODO 1	% aciertos test	3,94%	0,05%	4,12%	0,25%
	media tiempo para alcanzar el mínimo (en minutos)	-12,6	13,2	-25,8	3,3
MODO 2 (7 horas)	% aciertos test	4,34%	0,14%	4,28%	0,02%

6.1. EXPERIMENTACIÓN (IV). Flor de Iris.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

● Problema de Clasificación de Flor de Iris.

↻ Una única capa oculta con 5 neuronas.

↻ 100 simulaciones (10 poblaciones x 10 conjuntos)

- Antes: 8 simulaciones de RNGA por conjunto-población.
- Ahora: Una única ejecución equivalente que experimenta con todas las combinaciones posibles (7560 combinaciones).

Modo 1		RNGA	RNGA AGCC	
	PORCENTAJE MEDIO ACIERTOS TEST		48,88%	50,32%
DESVIACIÓN TÍPICA		0,11	0,19	
TIEMPO MEDIO EMPLEADO PARA ALCANZAR EL MÍNIMO (en minutos)		2,8	35,9	

6.1. EXPERIMENTACIÓN (y V). Cáncer de Mama.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

● Problema de Predicción de Cáncer de Mama.

↻ Una única capa oculta con 7 neuronas.

↻ 100 simulaciones (10 poblaciones x 10 conjuntos)

■ Antes: 4 simulaciones de RNGA por conjunto-población.

■ Ahora: Una única ejecución equivalente que experimenta con todas las combinaciones posibles.

Modo 1		RNGA	RNGA AGCC	
	PORCENTAJE MEDIO ACIERTOS TEST	87,85%	91,00%	3,15%
DESVIACIÓN TÍPICA	0,11	0,11		
TIEMPO MEDIO EMPLEADO PARA ALCANZAR EL MÍNIMO (en minutos)	90,6	82,8		

7. CONCLUSIONES (I). Primera Fase.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno
de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

Análisis de Eficiencia:

- Las RNGA consiguen en un menor tiempo un mayor porcentaje de aciertos en el test que las RNA para los cuatro problemas aquí estudiados.

Estudio de Complejidad:

- A mayor complejidad de los problemas y de las arquitecturas para resolverlos → los resultados para las RNGA son significativamente mejores en:
 - ↯ Porcentaje de aciertos en test.
 - ↯ Error de entrenamiento.
 - ↯ Tiempo para alcanzar estos valores.

7. CONCLUSIONES (II). Segunda Fase. Optimización.

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

- Se ha diseñado una nueva metodología para la optimización de RNGA.
- Se implementó una versión preliminar de la misma empleando el operador SBX y Algoritmos Genéticos Coevolutivos Cooperativos (AGCC).
- Se experimentó con dos problemas de diferente complejidad.
 - Los resultados muestran que este sistema de optimización mejora ligeramente los obtenidos en el caso de Flor de Iris y, en mayor medida, en Cáncer de Mama (problema de mayor complejidad que el anterior).
- El modo de proceder del AGCC, en colaboración con la RNGA, emula con mayor fidelidad el funcionamiento cerebral, actuando, al igual que la glía biológica, de modo diferente dependiendo de la información a procesar.

7. CONCLUSIONES (y III)

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

- Los resultados obtenidos gracias a este proyecto son parte de un trabajo de investigación que podría proporcionar importantes beneficios en:

➤ **Inteligencia Artificial**, al mejorar el rendimiento de Sistemas Conexionistas orientados a clasificación y predicción.

➤ **Neurociencia**, ya que permiten afianzar los descubrimientos sobre la importante participación de los astrocitos del sistema Glial en el procesamiento de la información en el sistema nervioso.

8. TRABAJOS FUTUROS

1. Introducción

2. Objetivos

3. Antecedentes

4. Desarrollo del entorno de simulación

5. Primera Fase.

5.1. Experimentación

6. Segunda Fase

6.1. Experimentación

7. Conclusiones

8. Trabajos Futuros

- Realizar *Data Mining* de los datos obtenidos por el AGCC con el objetivo de encontrar patrones comunes en las configuraciones de parámetros resultantes.
- Emplear un **cromosoma por cada elemento de procesado**.
- Considerar **combinaciones NULAS** de parámetros de la glía artificial.
- Aplicar una *aproximación evolutiva de nichos*: una de las que mayor éxito han demostrado en la resolución de problemas multimodales.



UNIVERSIDADE DA CORUÑA

**PROYECTO FIN DE CARRERA
DE
INGENIERÍA EN INFORMÁTICA**

Departamento de Tecnologías de la Información y las Comunicaciones

**OPTIMIZACIÓN Y ANÁLISIS DEL RENDIMIENTO DE
SISTEMAS CONEXIONISTAS NEUROGLIALES**

Autor

Pablo Mesejo Santiago

Directores

Ana Belén Porto Pazos

Óscar Ibáñez Panizo

