



UNIVERSIDAD AUTÓNOMA DEL  
ESTADO DE MORELOS



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS  
INSTITUTO DE INVESTIGACIÓN EN CIENCIAS BÁSICAS Y APLICADAS

ÁREA TERMINAL DE COMPUTACIÓN

Clasificación de patrones de espectroscopía con  
métodos auto-organizables

T E S I S

QUE PRESENTA:

Enrique Raúl Olguín Rodríguez

Para obtener el Grado de  
LICENCIADO EN CIENCIAS

Director de la Tesis:  
Bruno Lara Guzmán

Sinodales:  
Gloria Koenigsberger Horowitz (UNAM)  
Jorge Hermsillo Valadez (UAEM)  
Daniel Rivera (UAEM)  
Juan Manuel Rendon (UAEM)

Cuernavaca, Morelos

Diciembre de 2015

## **Agradecimientos**

Agradesco el apoyo de mi madre Maria Isabel Rodríguez Quintero que gracias a ella yo me encuentro escribiendo este trabajo de tesis. Gracias a su esfuerzo y trabajo yo he podido continuar estudiando. Por ser mi madre, mi amiga y ser el apoyo que necesito para seguir adelante.

A mis hermanos Alicia, Paola, Jeannet y Emmanuel por compartir muchos momentos en mi vida, por las aventuras, por las alegrías y por las desgracias. Son una parte importante en mi vida.

A mi sobrina Mayte, gracias por esos momentos graciosos y felices que me has hecho pasar.

Agradesco el apoyo y ayuda de la doctora Gloria Koenigsberger, gracias a usted yo aprendí y entendí muchas cosas que me ayudaron a realizar este proyecto. Le agradezco el permitirme haber trabajado para usted.

Al doctor Bruno Lara por la paciencia y la ayuda que me otorgó en más de una ocasión para que yo aprendiera de mis errores.

Agradesco a Esau Escobar por su paciencia y ayuda durante este proyecto de tesis.

# Índice general

## CAPÍTULO

<b>1. Introducción</b>	<b>1</b>
<b>2. Astronomía</b>	<b>5</b>
2.1. Espectroscopía . . . . .	5
2.2. Estrellas Binarias . . . . .	6
2.2.1. Clasificación de Estrellas Binarias . . . . .	7
2.2.2. Espectro de una estrella binaria . . . . .	8
2.2.3. Órbita . . . . .	9
2.3. Fuerzas de marea . . . . .	11
2.3.1. TIDES . . . . .	13
2.3.2. Sistema observado . . . . .	14
<b>3. Herramientas Computacionales</b>	<b>17</b>
3.1. Redes Neuronales . . . . .	17
3.1.1. Metodos de aprendizaje . . . . .	18
3.2. Mapas Auto-organizados . . . . .	19
3.2.1. SOM . . . . .	20
3.2.2. DSOM . . . . .	21
3.2.3. SOM Circular . . . . .	22
3.2.4. Neural Gas . . . . .	23
3.3. Herramientas de análisis . . . . .	25
3.3.1. Matriz de Confusión . . . . .	25
3.3.2. Correlación . . . . .	25
<b>4. Experimentos y resultados</b>	<b>27</b>
4.1. Correlación de los datos . . . . .	27
4.1.1. Resultado matriz de correlación . . . . .	28
4.2. SOM . . . . .	29
4.2.1. Mapa SOM con nueve nodos . . . . .	29
4.2.2. Mapa SOM con dieciséis nodos . . . . .	32
4.3. DSOM . . . . .	34
4.3.1. Mapa DSOM con nueve nodos . . . . .	34

---

4.3.2. Mapa DSOM con dieciséis nodos . . . . .	36
4.4. SOMC . . . . .	39
4.4.1. Mapa SOMC con nueve nodos . . . . .	39
4.4.2. Mapa SOMC con dieciséis nodos . . . . .	41
4.5. NG . . . . .	44
4.5.1. Mapa NG con nueve nodos . . . . .	44
4.5.2. Mapa NG con dieciséis nodos . . . . .	47
<b>5. Conclusiones</b>	<b>51</b>

# RESUMEN

## Clasificación de patrones de espectroscopía con métodos auto-organizables

Enrique Raúl Olguín Rodríguez

Esta tesis esta enfocada en resolver un problema de clasificación de perfiles de líneas espectrales de una estrella binaria. Las estrellas binarias son dos cuerpos masivos que orbitan alrededor de un centro de masa en común.

Para llevar a cabo la clasificación se utilizaron Mapas Auto-organizados que son redes neuronales artificiales. Las redes neuronales artificiales son un modelo matemático aproximado del comportamiento biológico de las neuronas.

Los mapas auto-organizados que fueron contemplados para este trabajo fueron: *Self Organizing Maps*, *Dynamic Self Organizing Maps*, *Self Organizing Maps Circular* y *Neural gas*.

Se contó con un total de cuatrocientos perfiles espectrales para realizar dicho trabajo. Estos perfiles fueron obtenidos mediante un modelo matemático de la interacción entre dos cuerpos celestes (Tilda Interactions with Dissipation of Energy through Shear, TIDES).

Los resultados obtenidos en esta tesis demostrarán que los mapas auto-organizados son capaces de clasificar los perfiles de líneas espectrales presentados.

# Introducción

---

## Descripción del problema y justificación

En este proyecto de tesis se tiene como problema la clasificación de perfiles de líneas espectrales de una estrella binaria. Las estrellas binarias son un conjunto de estrellas que orbitan alrededor de un centro de masa en común. Las líneas espectrales representan la emisión de luz producida por la estrella a lo largo de un período orbital del sistema. Estos perfiles espectrales son variables y su forma depende de la fase orbital en la que se encuentran las estrellas, además de otros factores.

Para realizar la clasificación de perfiles de líneas espectrales se propone el uso de mapas auto-organizados. Los mapas auto-organizados son un tipo de red neuronal artificial de aprendizaje no supervisado.

Para solucionar este problema se requiere llevar a cabo una clasificación de datos en un espacio que aunque conocido no se tiene mayor información acerca del número de clases, grupos o características comunes.

Los siguientes mapas auto-organizados fueron considerados para llevar a cabo este trabajo: El *Self Organizing Maps (SOM)* red neuronal artificial propuesta por Kohonen (1990), el *Dynamic Self Organizing Maps (DSOM)* que es una variante del SOM propuesta por Rougier y Boniface (2011), *Neural Gas (NG)* red neuronal artificial realizada por Martinetz et al. (1991) y *Self Organizing Maps Circular (SOMC)* propuesto por nosotros que consiste en una variante del mapa SOM que posee una estructura circular.

Este trabajo se considera importante porque nos permite estudiar diferentes estructuras de los mapas auto-organizados, ver sus comportamientos y desempeños al realizar esta tarea de clasificación. También nos permitirá comparar los diferentes mapas propuestos y determinar el mapa que realiza mejor la tarea de clasificación.

Es importante saber si es posible clasificar los perfiles de líneas espectrales usando este tipo de redes neuronales artificiales.

## Hipótesis

La hipótesis de este trabajo es que utilizando métodos de aprendizaje no supervisado se puede llevar a cabo una clasificación de patrones de perfiles de líneas espectrales.

## Objetivos generales

En este trabajo se tiene por objetivo clasificar los perfiles de líneas espectrales usando redes neuronales artificiales.

## Antecedentes

La clasificación de datos mediante el uso de redes neuronales artificiales ha sido utilizada en diversas áreas de investigación.

Un ejemplo es el caso de Moreira y Costa (1996) quienes presentaron un método para la segmentación de imágenes por colores. La segmentación fue llevada a cabo agrupando píxeles en un región.

El método usa la cromaticidad de la imagen. Esto sirvió como normalizador para considerar solamente la saturación y la matiz de la imagen.

La clasificación fue realizada por un mapa neuronal SOM. El algoritmo del mapa SOM es utilizado para obtener las principales cromaticidades que se encuentran presentes en la imagen.

Otro ejemplo es el de Labib y Vemuri (2002) que describen una implementación de un sistema de detección de intrusos en la red de ethernet. Este sistema usa la estructura de SOM para llevar a cabo la clasificación y esto lo hace en tiempo real.

El método consiste en entrenar al SOM con ayuda de una aplicación llamada *tcpdump*. Esta aplicación controla y filtra los paquetes que son transportados en la red. Permitiendo así entrenar la red neuronal artificial de manera supervisada, permitiendo así clasificar tráfico regular e irregular de datos.

Weaver (2000) desarrolló una técnica usando una red neuronal artificial para la clasificación del espectro de una estrella binaria. Este espectro pertenece a un sistema descrito por Weaver y Torres-Dodgen (1995). En este trabajo se usó el espectro sin ninguna intervención exceptuando el registro de su longitud de onda. La red neuronal fue entrenada repetidamente con un conjunto de datos en donde la entrada y su correspondiente salida son especificados, es decir, la red se retroalimenta para ajustar sus pesos a una salida deseada.

La idea de comparar distintos mapas auto-organizados para observar su desempeño y resultado con respecto a los demás no es nueva, tal es el caso de Daszykowski et al. (2002). El trabajo consistió en poner a prueba el desempeño de dos nuevos métodos de clusterización como son el *Neural Gas* y *Growing Neural Gas* en comparación con el método *K-means*.

En el proceso de entrenamiento a los mapas auto-organizados ya mencionados se les presentaron dos conjuntos de datos y se observó los resultados obtenidos. Estos datos fueron espectros con una longitud de onda cercana al infrarrojo.

Se observó en los resultados obtenidos que los algoritmos *Neural Gas* y *Growing Neural Gas* desempeñaron un mejor trabajo al realizar la clasificación a comparación del método *K-means*.





# Astronomía

---

La astronomía es la disciplina que se ocupa del estudio de los cuerpos celestes, sus posiciones, movimientos y todo cuanto existe relacionado a los mismos. La astronomía es una ciencia que ha sido estudiada por el ser humano desde la antigüedad.

## 2.1. Espectroscopía

Una línea espectral es el resultado de la interacción entre las distintas longitudes de una radiación electromagnética y la absorción de energía realizada por moléculas.

La espectroscopía es el estudio de la luz blanca dispersada, lo cual permite conocer la composición química y muchos otros parámetros físicos tales como la temperatura, la densidad, la presión entre otros. Desde la antigüedad se ha estudiado la naturaleza de la luz blanca. Sin embargo no fue hasta el experimento del prisma diseñado por Issac Newton (Figura 2.1) en donde se comprobó que cualquier haz de luz blanca se puede descomponer en los colores del arcoiris. Posteriormente se comprobó que cada color corresponde a un único intervalo de longitud de onda. Además, se descubrió presencia de franjas oscuras.

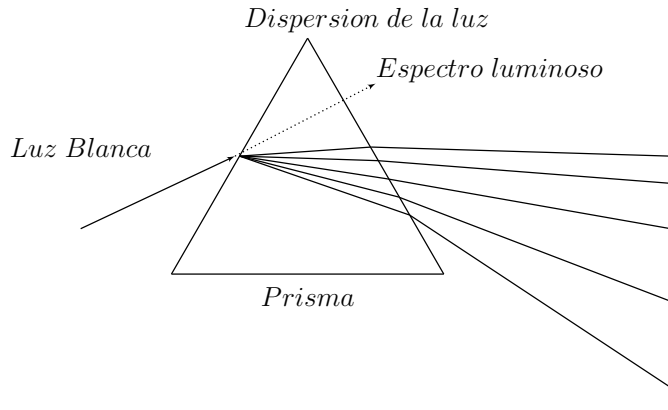


Figura 2.1: Prista de Newton

## 2.2. Estrellas Binarias

Las estrellas binarias son sistemas de dos cuerpos masivos que orbitan una alrededor de la otra (Herschel, 1802). Su movimiento se rige por las Leyes de movimiento de Newton, excepto en casos extremos en donde se requiere principios de Relatividad General (Figura 2.2).




Figura 2.2: Estrella Binaria: A) Sistema Binario con marco de referencia en el centro de masa. B) Sistema Binario con marco de referencia en estrella primaria. C) Sistema Binario

### 2.2.1. Clasificación de Estrellas Binarias

Existen muchas clasificaciones para las Estrellas Binarias algunas de ellas se encuentran descritas en Carroll (2006) y estas son clasificadas con respecto a su método de observación:

#### Binarias Visuales

Las Estrellas binarias visuales son aquellas que son fáciles de observar a través de un telescopio ordinario, este tipo de estrellas suelen estar muy cerca visualmente del observador y muy distante entre ellas; A pesar de su fácil observación, no suele ser tan fácil detectarlas debido a que sus períodos orbitales son del orden de cientos de años.

#### Binarias Eclipsantes

Estas estrellas solo son observables cuando su órbita está alineada con la nuestra de tal manera que, periódicamente, una estrella pasa por delante de la otra. Esto hace que se observen disminuciones regulares en la luminosidad (Curva de luz). Dado que su luminosidad va cambiando con el tiempo a veces pasan desapercibidas como estrellas variables (Las estrellas variables son estrellas que experimentan variación en su brillo en el transcurso del tiempo). Usualmente estas estrellas tienen un período corto por lo que son de fácil detección al observar la regularidad en sus variaciones de luminosidad.

#### Binarias Astrométricas

En este tipo de sistemas dobles sólo es visible un componente de la estrella. Se detecta que son binarias gracias al "tiron" gravitatorio ejercido por su compañera invisible. Esto produce un movimiento oscilatorio respecto al fondo de las estrellas fijas que puede ser medido por técnicas de paralaje si está lo suficientemente cerca. Como las binarias visuales, las astrométricas requieren prolongados períodos de observación. El objeto invisible suele ser un cuerpo de muy baja o nula luminosidad como un remanente estelar.

Si la compañera es lo suficientemente masiva como para causar un cambio de la posición de la estrella, entonces su presencia se puede deducir. Aunque el compañero no es visible se puede determinar las características en el sistema usando las leyes de Kepler (Figura 2.3).




Figura 2.3: Binaria Astrométrica

### Binarias espectroscópicas

Al igual que las estrellas binarias Astrométricas, las espectroscópicas también poseen una estrella invisible. La diferencia radica en el modo en que este tipo se logra detectar mediante el *desplazamiento Doppler* en el espectro del astro visible. Después de observar la estrella durante el tiempo se nota un cambio periódico en las longitudes de ondas. La explicación de este cambio de frecuencia es resultado de la órbita, las estrellas a veces se mueven hacia la Tierra o se alejan de ella. Cuando la estrella se acerca a la Tierra se genera un movimiento azul en el espectro y cuando se aleja el espectro cambia hacia el rojo. Esta técnica es de mayor precisión que la del paralaje y permite la detección de las estrellas binarias de forma más rápida. A pesar de todo algunas binarias no presentan casi ningún desplazamiento radial debido a la orientación de su órbita por lo que este método resulta inútil para éstas.

#### 2.2.2. Espectro de una estrella binaria

Un astro cuando realiza una radiación de energía, irradia diferentes ondas con diferentes longitudes, sin embargo no todas estas ondas son irradiadas fuera de la atmosfera de este astro, esto es debido a que cada astro esta compuesto de distintos elementos quimicos en su atmosfera y cuando alguna de estas ondas poseé la energia necesaria para que algún electrón pueda dar un salto en su orbita, esta será absorbida por esa molecula.

### Variación del perfil espectral

Los perfiles espectrales suelen tener variaciones en las longitudes de onda a la que teóricamente se producen. Esto es debido a un fenómeno conocido como *Efecto Doppler* y esto ocurre cuando el o los objetos observados se mueven acercándose o alejándose del observador (Figura 2.4).

Suceden dos tipos de casos el primero es cuando las longitudes de onda son menores a las longitudes de onda teóricas y se dice que el espectro se desplaza hacia el azul; El otro caso es cuando la longitudes de onda son mayores a las teóricas y se dice que el espectro se desplaza hacia el rojo.

Este efecto depende de la velocidad que tenga el objeto con respecto al observador. La relación, cuando la velocidad del objeto al observador es mucho menor a la velocidad de la luz en el vacío está dada por la ecuación:

$$V_0 = \left(1 - \frac{v}{c}\right) V_t \quad (2.1)$$

En donde  $V_0$  es la frecuencia observada,  $v$  es la velocidad del objeto relativa al observador,  $c$  es la velocidad de la luz en el vacío y  $V_t$  es la frecuencia teórica.




Figura 2.4: Variación en la componente del perfil espectral

### 2.2.3. Órbita

En Física una órbita es el recorrido o trayectoria de un cuerpo a través del espacio bajo la influencia de fuerzas de atracción o repulsión de un segundo cuerpo.

Una órbita adquiere la forma de una Cónica, es decir, de una circunferencia, de una elipse, de una parábola o de una hipérbola. La forma de una órbita depende de la ley de la Gravitación Universal formulada por Newton. Cuando dos objetos orbitan sobre sí, el periastro es el punto en el que los dos objetos se encuentran más próximos el uno al otro y el apoastro es el punto donde se encuentran más lejos.

Es necesario tener en cuenta ciertas definiciones tales como: período orbital, fase orbital, plano orbital, separación orbital y excentricidad.

- **Período orbital:**  
El período orbital es el tiempo que tarda un planeta u otro objeto en realizar una órbita completa.
- **Fase orbital:**  
Es la posición descrita de un astro para cualquier tiempo  $t$  a lo largo de su órbita.
- **Plano orbital:**  
Es el plano en donde esta inscrita la órbita.
- **Separación orbital:**  
La separación orbital de una masa  $m_1$  y un masa  $m_2$  con distancia al centro de masa  $d_1$  y  $d_2$  respectivamente, es el total de estas dos distancias (Figura 2.5).




Figura 2.5: Separación orbital

- **Excentricidad:**  
La excentricidad es un número que mide el mayor o menor achataamiento de la elipse. Es igual al cociente entre su semidistancia focal y su semieje mayor.

### 2.3. Fuerzas de marea

"La interacción gravitatoria entre dos objetos celestes implica una diferencia en la intensidad de la fuerza gravitatoria entre el extremo cercano y el lejano (en la línea del eje entre ambos), a la que denominamos fuerza de marea." (Carroll, 2006).

La fuerza de marea es un efecto importante que tiende a deformar un cuerpo extenso sometido a un campo gravitatorio no uniforme. Para entender su origen consideremos el efecto del campo gravitatorio en la Luna sobre la Tierra (Figura 2.6).




Figura 2.6: Geometría para el cálculo de la fuerza de marea.

Un objeto situado en un punto  $O$  de la Tierra está sometido al campo gravitatorio terrestre

$$\mathbf{g}_T = -\hat{r} \frac{Gm_T}{r^2} \quad (2.2)$$

y al campo gravitatorio de la Luna

$$\mathbf{g}_L = -\hat{d} \frac{Gm_L}{d^2} \quad (2.3)$$

Donde  $g_L \ll g_T$ . Para ver el efecto de esta superposición para un observador en  $O$  es preciso recordar que la Tierra cae hacia la Luna con la aceleración

$$\mathbf{a}_T = -\hat{R} \frac{Gm_L}{R^2} \quad (2.4)$$



Para nuestro observador esta aceleración equivale a un campo gravitatorio ficticio:

$$\mathbf{g}_a = -\mathbf{a}_T = \hat{R} \frac{Gm_L}{R^2} \quad (2.5)$$

El campo total en  $O$  es entonces

$$\mathbf{g}' = \mathbf{g}_T + \mathbf{g}_L + \mathbf{g}_a = -\hat{r} \frac{Gm_T}{r^2} - \hat{d} \frac{Gm_L}{d^2} + \hat{R} \frac{Gm_L}{R^2} \quad (2.6)$$

pero  $d^2 = R^2 + 2Rr \sin \alpha + r^2$ , entonces:

$$d^2 = R^2 \left( 1 + 2 \frac{r}{R} \sin \alpha + \frac{r^2}{R^2} \right) \quad (2.7)$$

Como  $R \approx 60r$  entonces que  $r^2 \ll R^2$  y al orden más bajo en  $r/R$  tenemos que:

$$d \cong R \left( 1 + \frac{r}{R} \sin \alpha \right) \quad (2.8)$$

Además  $d = (r \sin \alpha + R) \hat{R} + r \cos \alpha \hat{Z}$  y

$$\hat{d} \cong \hat{R} + \frac{r}{R} \cos \alpha \hat{Z} \quad (2.9)$$

Luego

$$\mathbf{g}' \cong -\frac{Gm_T}{r^2} \hat{r} + \frac{Gm_L}{R^2} \frac{r}{R} (2 \sin \alpha \hat{R} - \cos \alpha \hat{Z}) \quad (2.10)$$

Por lo tanto el campo gravitatorio de la Luna, descontando la aceleración producida sobre la Tierra, deja un efecto neto dado por un campo que llamamos *campo de marea* y que vale

$$\mathbf{g} = \frac{Gm_L}{R^2} \left( \frac{r}{R} \right) (2 \sin \alpha \hat{R} - \cos \alpha \hat{Z}) \quad (2.11)$$

El campo de marea (Figura 2.7.A) es simétrico respecto del plano que pasa por el centro de la Tierra y es perpendicular a  $R$  (la dirección Luna-Tierra). También es simétrico por rotaciones alrededor de  $R$ , luego la configuración completa se obtiene girando la Figura 2.7.A alrededor de  $R$ . En los puntos A y A' situados sobre el eje Luna-Tierra  $g_m$  se aleja del centro de la Tierra. En la intersección de la superficie terrestre con el plano perpendicular a  $R$  que pasa por  $O$ ,  $g_m$  se dirige hacia el centro de la Tierra. La fuerza de marea tiende pues a estirar la Tierra a lo largo de la dirección Tierra-Luna y a reducir su radio en sentido perpendicular a dicha dirección, para darle una deformación (Figura 2.7.B).




Figura 2.7: A) El campo de marea. B) La deformación que el campo de marea tiende a producir.

Esta es la versión más sencilla del problema. En realidad, es necesario tomar en cuenta la rotación, viscosidad, y muchas fuerzas adicionales. Existe un modelo computacional llamado TIDES que calcula las deformaciones como función del tiempo.

### 2.3.1. TIDES

Los datos utilizados en este proyecto de tesis son un conjunto de perfiles espectrales de una estrella binaria a lo largo de su trayectoria durante un período orbital.

Estos datos fueron obtenidos del modelo computacional llamado TIDES (Moreno et al., 2005).

TIDES es un modelo que está basado en un conjunto de ecuaciones diferenciales que describen las fuerzas a las cuales responden los elementos de una capa delgada del cuerpo que se modela. Estas fuerzas incluyen: gravedad, autogravedad, centrífuga, centrípeta, de marea, de presión de gas, de compresión y de viscosidad.

Se usa un método de integración conocido como Runge-Kutta para resolver simultáneamente el conjunto de ecuaciones y obtener la tasa de disipación de energía, el radio, la velocidad azimutal y la velocidad radial para cada uno de los elementos que conforman la capa seleccionada (Moreno y Koenigsberger, 1999).


### 2.3.2. Sistema observado

Para este trabajo se hizo uso de TIDES que es un modelo que esta basado en un conjunto de ecuaciones diferenciales que describen las fuerzas a las cuales responden los elementos de una capa delgada del cuerpo que se modela. El cuerpo que se usó para modelar fue la estrella Spica.

Spica (Alfa Virginis) es una estrella que pertenece a la constelación de Virginis con una magnitud aparente de aproximadamente de 1.04 (medida de la cantidad de luz (energía) que se recibe del objeto). Esto facilita la observación de la estrella con tiempos de exposición muy cortos. Se sabe desde la decada de los cincuentas que las lineas espectrales de esta estrella sufre variación en los perfiles.

Smith (1985) hizo un análisis detallado de esta variabilidad y concluyó que se pueden representar con armonicos esféricos. Esto sugirió que la estrella principal esta pulzando en lo que se llama modulos radianes y se encontró que había periodicidad consistentes.

Harrington (2009) analizó esta variabilidad utilizando espectros obtenidos en el telescopio CFHT Hawai y mostraron que en el mismo tipo de variabilidad se puede reproducir con el modelo de corrientes producidad por las fuerzas de marea.




*Figura 2.8: Perfil espectral obtenida por el telescopio CFHT*

En la figura 2.8 se muestra un ejemplo de estos espectros tomados por el CFHT. Como puede observarse el rango espectral va desde 4000 a

5000 angström y se puede observar un gran número de líneas de absorción.

Sin embargo es importante hacer notar que la mayoría de estas líneas tienen contribuciones de varias transiciones atómicas, es decir, si observamos una línea de absorción esta puede corresponder a transiciones anatómicas que se están dando en diversos átomos, es decir, hay un traslape de longitudes de onda.



*Figura 2.9: Perfil espectral obtenida por el telescopio CFHT*

Un análisis de variabilidad de los perfiles requiere contar con líneas en donde éste traslape sea mínimo, al mismo tiempo uno requiere que la línea tenga la suficiente intensidad para que la relación señal/ruido sea buena. De todas las líneas presentes en ese espectro solo hay tres que son óptimas para el análisis de la variabilidad espectral y estas corresponden a una transición de niveles de excitados del ion del silicio dos veces ionizados (Silicio III) estas líneas se muestran en la figura 2.9.



# Herramientas Computacionales

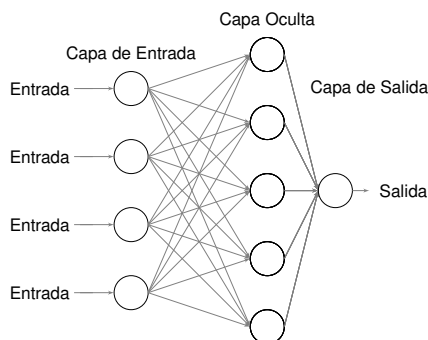
---

En este trabajo de tesis se hace uso de herramientas computacionales como lo son las redes neuronales artificial y también el uso de herramientas de análisis como la matriz de confusión y la correlación de datos.

## 3.1. Redes Neuronales

Una Red Neuronal Artificial es un modelo matemático aproximado inspirado en el comportamiento biológico de las neuronas y en la estructura del cerebro (McCulloch y Pitts, 1943).

Una red neuronal artificial consiste en un gran número de elementos simples de procesamiento llamados nodos o neuronas que están organizadas en capas. Cada neurona está conectada con otras neuronas mediante enlaces de comunicación, cada uno de los cuales tiene asociado un peso.



*Figura 3.1: Red Neuronal Artiificial*

### 3.1.1. Metodos de aprendizaje

El aprendizaje es el proceso en el cual una red neuronal artificial modifica sus pesos en respuesta a una entrada. Este proceso se divide principalmente en dos tipos: aprendizaje supervisado y aprendizaje no supervisado.

#### Aprendizaje supervisado

El aprendizaje supervisado se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por la respuesta conocida que debería generar la red a partir de una entrada determinada. La salida generada por la red es controlada y en caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada.

- **Aprendizaje por corrección de error.**  
Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos a la salida de la red, es decir, en función del error cometido en la salida.
- **Aprendizaje por refuerzo.**  
Se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir, de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada salida.  
El aprendizaje por refuerzo se reduce a indicar si la salida obtenida por la red es la deseada (éxito =+1 ó fracaso =-1) y en función de ello se ajustan los pesos.
- **Aprendizaje estocástico.**  
Consiste en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado. Si el comportamiento se acerca al deseado el cambio realizado se acepta, en caso contrario el cambio sería aceptado en función de una distribución de probabilidad.

#### Aprendizaje no supervisado

Las redes con aprendizaje no supervisado no requieren influencia externa para ajustar los pesos de las conexiones entre neuronas. La red no

recibe ninguna información si la salida generada en respuesta a una determinada entrada es o no correcta.

Estas redes deben encontrar las características, regularidades, correlaciones o categorías que se puedan establecer entre los datos que se presenten en su entrada.

- **Aprendizaje competitivo y comparativo.**  
Se orienta a la clusterización o clasificación de los datos de entrada. Como característica principal del aprendizaje competitivo se puede decir que, si un patrón nuevo se determina que pertenece a una clase reconocida previamente, entonces la inclusión de este nuevo patrón a esta clase representará la presentación de la misma. Si el patrón de entrada se determinó que no pertenece a ninguna de las clases reconocidas anteriormente, entonces la estructura y los pesos de la red neuronal serán ajustados para reconocer la nueva clase.

## 3.2. Mapas Auto-organizados

Los mapas auto-organizados son una red neuronal que se entrena usando aprendizaje no supervisado para producir una representación discreta del espacio de las muestras de entrada, llamado mapa. Los mapas auto-organizados son diferentes a otras redes neurales artificiales, en el sentido que estos usan una función de vecindad para preservar las propiedades topológicas del espacio de entrada.

El modelo fue descrito por primera vez como una red neuronal artificial por el profesor finlandés Kohonen (1990) basado en el método de Cuantificación vectorial.

### Cuantificación Vectorial

Es una técnica por la cual el espacio de entrada es dividido en un número determinado de regiones y para cada una de ellas es definido un vector que lo caracteriza. La entrada al sistema son vectores  $n$ -dimensionales y la salida es una representación discreta del espacio de entradas.

El método "*Vector Quantization*" (LVQ) fue originalmente desarrollado por Linde et al. (1980).

El algoritmo LVQ fue adaptado por Kohonen (1986) para reconocimiento de patrones. Se considera una red neuronal artificial clasificada como un clasificador supervisado.



LVQ combina el aprendizaje competitivo con la supervisión, esto requiere un conjunto de entrenamientos del comportamiento de la red. Si el patrón de entrada es clasificado correctamente, entonces se mueve el peso ganador hacia el vector de entrada de acuerdo al regla de Kohonen y si el patrón de entrada es clasificado incorrectamente entonces se mueve el peso ganador fuera del vector de entrada.

### 3.2.1. SOM

Un mapa auto-organizado  $N$  consiste en un conjunto de nodos o neuronas  $i$ ,  $i \in N$  en donde cada neurona tiene una posición  $p_i \in \mathbb{R}^q$  (en donde  $q$  es la dimensión del mapa) y donde a cada neurona posee un vector de pesos  $\mathbf{w}_i$ , también tenemos un conjunto de vectores de entrada  $\mathbf{v} \in \Omega$  con la misma dimensión  $n$  que los pesos (Figura 3.2).

El mapeo realizado de  $\Omega$  a  $N$  es tomado como el nodo más cercano al vector de entrada a este lo llamaremos como "nodo ganador" y es calculado como:

$$\Phi = \min \left( \sum_{j \in N} \sqrt{(\mathbf{w}_j - \mathbf{v})^2} \right) \quad (3.1)$$

El proceso de aprendizaje es un proceso iterativo desde  $t = 0$  hasta  $t = t_f \in \mathbb{N}$  donde los vectores  $\mathbf{v} \in \Omega$  son presentados al mapa para cada tiempo  $t$ . Se determina un nodo ganador  $s \in N$  dada por la ecuación (3.1), y los pesos de todos los nodos vecinos son actualizados con respecto a la entrada  $\mathbf{v}$  por la siguiente ecuación:

$$\Delta \mathbf{w}_i = \varepsilon(t) h_\sigma(t, i, s) (\mathbf{v} - \mathbf{w}_i) \quad (3.2)$$

con  $h_\sigma(t, i, j)$  siendo la función vecindad con la siguiente forma:

$$h_\sigma(t, i, j) = e^{-\frac{\|p_i - p_j\|^2}{2\sigma(t)^2}} \quad (3.3)$$

en donde  $\varepsilon(t)$  es el rango de aprendizaje y  $\sigma(t)$  es el radio de vecindad definidos como:

$$\sigma(t) = \sigma_i \left( \frac{\sigma_f}{\sigma_i} \right)^{\frac{t}{t_f}} \quad \varepsilon(t) = \varepsilon_i \left( \frac{\varepsilon_f}{\varepsilon_i} \right)^{\frac{t}{t_f}} \quad (3.4)$$

con  $\sigma_i$  y  $\sigma_f$  siendo respectivamente radio de vecindad inicial y final y  $\varepsilon_i$  y  $\varepsilon_f$  son respectivamente el rango de aprendizaje inicial y final.

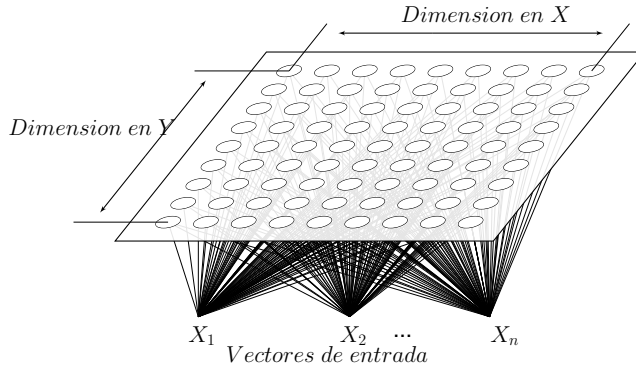


Figura 3.2: Estructura del mapa SOM

El algoritmo SOM tiene como característica principal el decremento del radio de vecindad en cada iteración de la fase de entrenamiento. Esta característica permite una mayor distribución de los datos, esto es porque para las primeras iteraciones el radio de vecindad cubre una mayor cantidad de nodos y para un tiempo  $t = t_f$  el radio de vecindad será el mínimo. Este radio de vecindad nos determina qué nodos son considerados para la actualización de sus pesos con respecto a una entrada.

### 3.2.2. DSOM

Los mapas auto-organizados dinámicos (Rougier y Boniface, 2011) son una variante al algoritmo propuesto por Kohonen, en donde la principal característica con respecto al SOM es que el proceso de aprendizaje no depende una variable de tiempo, esto nos permite obtener una línea de aprendizaje continua.

El DSOM es un mapa neuronal con una estructura compuesta por un conjunto de nodos o neuronas en donde a cada neurona  $i$  se le atribuye una posición  $p_i \in \mathbb{R}^q$  (en donde  $q$  es la dimensión del mapa) y donde a cada neurona posee un vector de pesos  $\mathbf{w}_i$ , también tenemos un conjunto de vectores de entrada  $\mathbf{v} \in \Omega$  con la misma dimensión  $n$  que los pesos (La estructura es semejante a la figura 3.2).

El proceso de aprendizaje es iterativo donde son presentados secuencialmente los vectores de entrada  $\mathbf{v} \in \Omega$  al mapa y se determina un nodo ganador acorde a la ecuación (3.1) con el cual todos los pesos de los nodos

dentro del mapa son actualizados con la siguiente ecuación:

$$\Delta \mathbf{w}_i = \varepsilon | \mathbf{v} - \mathbf{w}_i |_{\Omega} h_{\eta}(i, s, \mathbf{v})(\mathbf{v} - \mathbf{w}_i) \quad (3.5)$$

teniendo a  $\varepsilon$  como una constante de rango de aprendizaje y la función de vecindad  $h_{\eta}(i, s, v)$  de la forma:

$$h_{\eta} = e^{-(1/\eta^2)\|p_i - p_s\|^2 / \|\mathbf{v} - \mathbf{w}_s\|_{\Omega}^2} \quad (3.6)$$

y donde  $\eta$  es la elasticidad o plasticidad. A diferencia del algoritmo SOM en donde el radio de vecindad es reducido durante la fase de entrenamiento, el DSOM posee un radio de vecindad constante, esto quiere decir que su radio no es afectado durante el entrenamiento.

Sin embargo la característica que tiene el DSOM es la elasticidad. La elasticidad es un parametro que modula a la red la capacidad de adaptar los pesos de los nodos a los vectores de entrada.

En otras palabras la elasticidad determina que tanto puede adaptarse la red a los vectores de entrada.

### 3.2.3. SOM Circular

Un SOMC es un mapa neuronal que consiste en un conjunto de nodos en el cual a cada nodo  $i$  se le atribuye un vector característico de pesos  $\mathbf{W}_i$  una posición  $p_i$  en un espacio de datos.

Este espacio de datos cumple con la característica que tiene una estructura circular, es decir, el ultimo nodo esta relacionado con el primero como se muestra en la figura 3.3.

Tenemos un conjunto de datos de entrada  $X$  donde cada  $\mathbf{v} \in X$  tiene la misma dimensión que los vectores característicos.

El proceso de entrenamiento es iterativo en donde se le presenta de manera secuencial los vectores de entrada al mapa neuronal y donde se obtiene un nodo ganador  $k$  que es el nodo con la menor distancia Euclidiana con respecto al vector de entrada.

Una vez determinado el nodo ganador, los pesos de los nodos vecinos son actualizados de la siguiente manera:

$$\Delta \mathbf{w}_i = \varepsilon(t) h_{\sigma}(t, i, s)(\mathbf{v} - \mathbf{w}_i) \quad (3.7)$$

con  $h_{\sigma}(t, i, j)$  siendo la función vecindad con la siguiente forma:

$$h_{\sigma}(t, i, j) = e^{-\frac{\|p_i - p_j\|^2}{2\sigma(t)^2}} \quad (3.8)$$

en donde  $\varepsilon(t)$  es el rango de aprendizaje y  $\sigma(t)$  es el radio de vecindad definidos como:

$$\sigma(t) = \sigma_i \left( \frac{\sigma_f}{\sigma_i} \right)^{\frac{t}{t_f}} \quad \varepsilon(t) = \varepsilon_i \left( \frac{\varepsilon_f}{\varepsilon_i} \right)^{\frac{t}{t_f}} \quad (3.9)$$

con  $\sigma_i$  y  $\sigma_f$  siendo respectivamente radio de vecindad inicial y final y  $\varepsilon_i$  y  $\varepsilon_f$  son respectivamente el rango de aprendizaje inicial y final .

Entonces si este mapa neuronal posee los mismos criterios de aprendizaje que el mapa auto-organizado SOM (Kohonen, 1990). ¿Qué diferencias hay entre estos dos mapas?.

La diferencia es la estructura, debido a la posición que hay entre cada nodo permite realizar una diferencia en la actualización de pesos logrando un aprendizaje distinto. La idea del porque realiza esto, es principalmente asimilar la forma de una órbita.

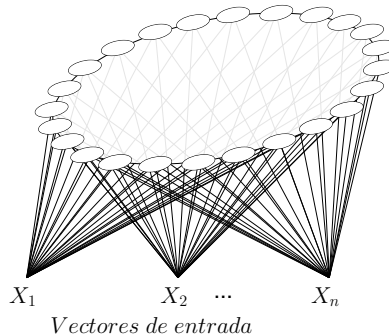


Figura 3.3: Estructura del mapa SOMC

### 3.2.4. Neural Gas

El algoritmo Neural Gas fue propuesto por Martinez et al. (1991), esta red neuronal consiste de  $k$  nodos, el cual se mueven independientemente sobre el espacio de datos durante la fase de entrenamiento.

El nombre de "Neural Gas" se le atribuye al hacer énfasis a la semejanza entre los movimientos de los nodos en el espacio de datos y el movimiento de las moléculas de gas en un contenedor cerrado.

El mapa consiste en  $k$  nodos en donde a cada nodo  $k_i$  tiene definido un vector de pesos  $w_i$ . Durante la ejecución del algoritmo se selecciona

de manera aleatoria un objeto  $\mathbf{x}_j$  el cual es un vector de entrada para la etapa de aprendizaje del algoritmo y se le es presentado al mapa, el cual ordenará los nodos por sus distancias respecto a  $\mathbf{x}_i$ , en el cual el nodo más cercano tendrá una mayor modificación de pesos y el más alejado tendrá una menor modificación de pesos. El algoritmo de aprendizaje es iterativo y puede presentarse de la siguiente manera.

Ajustes previos:

- Seleccionar el numero de nodos que será el número de clusters que se quiera tener.
- Inicializar los pesos de manera aleatoria para cada nodo dentro del mapa.
- Determinar los parametros de entrenamiento: maximo número de iteraciones  $t_f$ , el rango de aprendizaje inicial y final  $lr_i, lr_f$ , la constante de decaimiento inicial y final que determinarán el tamaño de la vecindad  $d_i, d_f$ .

Algoritmo:

1. Se presenta de manera aleatoria un vector de entrada  $\mathbf{X}$  al mapa.
2. Se determinan las distancias entre  $\mathbf{X}$  y los pesos  $\mathbf{w}_j$  para cada nodo del mapa.
3. Ordenar los nodos acorde a sus distancias respecto a  $\mathbf{X}$ , para encontrar al nodo ganador y a sus respectivos vecinos.
4. Para cada iteración  $t$  reajustar los pesos de ganador y sus respectivos vecinos acorde a la ecuación:

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + lr_t h_d(ind_i)(\mathbf{X} - \mathbf{w}_j(t)) \quad (3.10)$$

rango de aprendizaje:

$$lr(t) = lr_i \left( \frac{lr_f}{lr_i} \right)^{t/t_f}, lr \in [0, 1] \quad (3.11)$$

función de vecindad:

$$h_d(ind_i) = e^{-k_i/d} \quad (3.12)$$

constante de decaimiento

$$d(t) = d_i \left( \frac{d_f}{d_i} \right)^{t/t_f}, d \in [0, \infty] \quad (3.13)$$

### 3.3. Herramientas de análisis

#### 3.3.1. Matriz de Confusión

En el área de la Inteligencia Artificial una matriz de confusión es una herramienta que nos permite visualizar el desempeño de un algoritmo de clasificación.

Una matriz de confusión (Provost et al., 1998) contiene información acerca de las clasificaciones realizadas por el algoritmo y las clasificaciones que se tienen previstas. El rendimiento de tales sistemas se evalúa comúnmente usando los datos en la matriz.

En donde a cada columna de la matriz representa la clasificación que se espera obtener y en las filas de la matriz representan la clasificación realizada por el algoritmo.

En donde a cada fila se registra cuantos elementos fueron clasificados por el algoritmo en cada columna con respecto a la clasificación que se espera obtener. Estas filas son promediadas por el total de elementos de dicha fila.

#### 3.3.2. Correlación

La correlación estadística determina la relación o dependencia que existe entre dos variables que intervienen en una distribución bidimensional.

La correlación de dos variables  $X$  y  $Y$  es  $r_{XY}$  que esta descrita de la siguiente manera:

$$r_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)s_x s_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.14)$$

donde  $n$  es el total de elementos,  $\bar{x}$  y  $\bar{y}$  son las medias estadísticas y  $s_x$  y  $s_y$  son la desviación estandar (Nikoli y Singer, 2012).



# Experimentos y resultados

---

En este capítulo se describe el proceso que se realizó para cada uno de los mapas auto-organizados propuestos y los resultados obtenidos en cada uno de ellos.

Los perfiles de líneas espectrales que se usaron en este proyecto fueron el resultado obtenido por el modelo matemático computado TIDES.

El modelo matemático computado TIDES se ejecutó utilizando como parámetros de entrada los parámetros orbitales y las características de las dos estrellas que conforman el sistema Spica.

Se calcularon de esta manera cuatrocientos perfiles para todo el ciclo orbital, considerando que el período orbital son cuatro días.

La secuencia de perfiles corresponde a un perfil para cada centésimo de día.

## 4.1. Correlación de los datos


Tenemos cuatrocientos perfiles de líneas espectrales de los que se sabe poco, es por ello que recurrimos a realizar una matriz de correlación. Esto nos permitió observar el comportamiento y semejanza que existe entre los perfiles.

Para obtener la matriz de correlación se calculó la correlación de cada uno de los perfiles con los demás perfiles (Figura (3.14)).

El resultado se mostró con una matriz  $M$  con tamaño  $[400,400]$  donde a cada posición en la matriz  $(i, j)$  es la correlación que existe entre el perfil  $i$  con el perfil  $j$ .



### 4.1.1. Resultado matriz de correlación



*Figura 4.1: Matriz de correlación de los 400 perfiles de líneas espectrales*

En la figura 4.1 observamos una alta correlación de cada perfil espectral consigo mismo, esta correlación no posee mucha significancia. Sin embargo existen otras correlaciones que se pueden observar y éstas poseen una mayor relevancia.

Se puede observar una alta correlación entre los primeros cuarenta perfiles espectrales y los últimos cuarenta perfiles espectrales, esto se debe a que los perfiles espectrales comenzaron a ser capturados en el periastro durante un período orbital, es decir, las últimas capturas realizadas también terminaron en el periastro (Figura 4.2).

Existen también otras correlaciones importantes en la matriz, estas correlaciones son debido a una simetría en las fuerzas ejercidas en la estrella binaria entre un punto en la fase orbital y el otro a  $180^\circ$  de esa fase orbital (Figura 4.2).




Figura 4.2: Trayectoria de una estrella binaria

## 4.2. SOM

Para el mapa auto-organizado SOM se determinó los siguientes parámetros de entrada: La cantidad de nodos, el número de iteraciones, factor de aprendizaje inicial, factor de aprendizaje final, rango de aprendizaje inicial, rango de aprendizaje final y el tamaño del vector de entrada.

En este proyecto se usaron dos cantidades de nodos para el SOM uno de ellos con nueve nodos y el otro con dieciséis nodos.

### 4.2.1. Mapa SOM con nueve nodos

El mapa SOM de nueve nodos fue representado como un mapa neuronal de dimension 3x3.

Para el mapa SOM con nueve nodos se realizaron 800 iteraciones con un factor de aprendizaje inicial de 0.7, un factor de aprendizaje final de 1.2, rango de aprendizaje inicial de 2 y un rango de aprendizaje final de 0.5.

Los vectores de entrada tienen el mismo tamaño que los vectores característicos, este tamaño es de 58.

De los 400 perfiles de líneas espectrales obtenidos por TIDES se consideró un conjunto de patrones de entrenamiento de 300 perfiles de líneas espectrales. Estos perfiles fueron obtenidos como resultado de la selección aleatoria de 100 perfiles de líneas espectrales y los perfiles seleccionados de manera aleatoria fueron el conjunto de patrones de prueba.

En la fase de entrenamiento, el conjunto de patrones de entrenamiento fue

presentado al mapa para cada iteración del entrenamiento. En donde cada elemento del conjunto se calculó la distancia Euclidiana con respecto a los pesos de la red y se obtuvo un nodo ganador para después actualizar los pesos de los nodos dentro del radio de vecindad.

Una vez finalizada la fase de entrenamiento, los elementos del conjunto de patrones de prueba fueron presentados al mapa en donde fueron registradas las activaciones de todos los nodos, es decir, la distancia Euclidiana entre el elemento presentado y los pesos de la red. Este proceso se llevo a cabo veinte veces.

Se propuso una clasificación de los perfiles de líneas espectrales. Esto fue posible realizar debido a que se conoce la fase orbital a la que pertenece cada perfil de línea espectral y así sabemos en donde debe quedar cada perfil de línea espectral.

Esta clasificación nos permitió realizar una comparación con la clasificación realizada por el mapa auto-organizado.

La comparación se representó en una matriz de confusión en donde se registraron los perfiles espectrales que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como en la clasificación realizada por el mapa auto-organizado. Los resultados obtenidos en la matriz de confusión fueron presentados como el promedio de todas las procesos.

Los perfiles fueron agrupados con respecto al nodo al que fueron ubicado en la matriz de confusión y se calculó su media estadística de la activación generada en cada nodo. Los resultados fueron presentados en una matriz de activación.

### **Resultados del mapa SOM con nueve nodos**

El mapa de activación para el mapa SOM de nueve nodos (Figura 4.3) presentó una mayor activación en la diagonal. Esto es porque la mayoría de los perfiles espectrales clasificados en este nodo tienen una semejanza entre ellos.

Una activación también relevante es la que surge entre el nodo uno y el nodo ocho, esto puede ser explicado debido a la correlación de los datos calculados (Figura 4.1).

La matriz de confusión para el mapa SOM de nueve nodos (Cuadro 4.1) mostró que en promedio el 90,2% de los perfiles de líneas espectrales fueron ubicados de manera correcta con respecto a la clasificación propuesta.

Este resultado fue obtenido al promediar la diagonal de esta matriz. Ya que en esta diagonal se encuentran los perfiles que fueron ubicados en el mis-

mo nodo tanto en la clasificación propuesta como la clasificación realizada por el mapa auto-organizado.

Dado los resultados obtenidos en el mapa de activación y la matriz de confusión se concluyó que el mapa SOM de nueve nodos es capaz de clasificar los perfiles de líneas espectrales.




Figura 4.3: Mapa de activación SOM de nueve nodos

8	9,6%	0%	0%	0%	0%	0%	0%	7,1%	83,3%
7	0%	0%	0%	0%	0%	0%	5%	93%	2%
6	0%	1,6%	0%	0%	0%	3,3%	92,6%	2,5%	0%
5	0%	1,8%	0%	0%	2,7%	89,1%	6,4%	0%	0%
4	0%	0%	0%	4,7%	95,3%	0%	0%	0%	0%
3	0%	0%	7,1%	83,7%	8,2%	0%	1%	0%	0%
2	0%	3,1%	86,1%	6,9%	0%	0%	3,9%	0%	0%
1	0%	96,5%	2,3%	0%	0%	1,2%	0%	0%	0%
0	92,3%	4,3%	0%	0%	0%	0%	0%	0%	3,5%
	0	1	2	3	4	5	6	7	8

Cuadro 4.1: Matriz de confusión para mapa SOM de nueve nodos

### 4.2.2. Mapa SOM con dieciséis nodos

El mapa SOM de dieciséis nodos fue representado como un mapa neuronal de dimension 4x4.

Para el mapa SOM con dieciséis nodos se realizaron 800 iteraciones con un factor de aprendizaje inicial de 0.89, un factor de aprendizaje final de 1.4, rango de aprendizaje inicial de 3 y un rango de aprendizaje final de 0.5.

Los vectores de entrada tienen el mismo tamaño que los vectores característicos, este tamaño es de 58.

De los 400 perfiles de líneas espectrales obtenidos por TIDES se consideró un conjunto de patrones de entrenamiento de 300 perfiles de líneas espectrales. Estos perfiles fueron obtenidos como resultado de la selección aleatoria de 100 perfiles de líneas espectrales y los perfiles seleccionados de manera aleatoria fueron el conjunto de patrones de prueba.

En la fase de entrenamiento, el conjunto de patrones de entrenamiento fue presentado al mapa para cada iteración del entrenamiento. En donde cada elemento del conjunto se calculó la distancia Euclidiana con respecto a los pesos de la red y se obtuvo un nodo ganador para después actualizar los pesos de los nodos dentro del radio de vecindad.

Una vez finalizada la fase de entrenamiento, los elementos del conjunto de patrones de prueba fueron presentados al mapa en donde fueron registradas las activaciones de todos los nodos, es decir, la distancia Euclidiana entre el elemento presentado y los pesos de la red. Este proceso se llevo a cabo veinte veces.

Se propuso una clasificación de los perfiles de líneas espectrales. Esto fue posible realizar debido a que se conoce la fase orbital a la que pertenece cada perfil de línea espectral y así sabemos en donde debe quedar cada perfil de línea espectral.

La comparación se representó en una matriz de confusión en donde se registraron los perfiles espectrales que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como en la clasificación realizada por el mapa auto-organizado. Los resultados obtenidos en la matriz de confusión fueron presentados como el promedio de todas las procesos.

Los perfiles fueron agrupados con respecto al nodo al que fueron ubicado en la matriz de confusión y se calculó su media estadística de la activación generada en cada nodo. Los resultados fueron presentados en una matriz de activación.

### Resultados del mapa SOM con dieciséis nodos

Los resultados obtenidos para el mapa SOM con 16 nodos (Figura 4.4) también poseen una mayor activación en la diagonal, pero a diferencia del SOM con 9 nodos (Figura 4.3) las activaciones en los demás nodos con respecto a la diagonal son mucho menores.

Este también tiene una activación semejante entre el nodo uno y el nodo ocho.

La matriz de confusión para el mapa SOM de dieciséis nodos (Cuadro 4.2) mostró que en promedio el 87,0 % de los perfiles de líneas espectrales fueron ubicados de manera correcta con respecto a la clasificación propuesta.

Este resultado fue obtenido al promediar la diagonal de esta matriz. Ya que en esta diagonal se encuentran los perfiles que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como la clasificación realizada por el mapa auto-organizado.

También en el mapa SOM con dieciséis nodos se obtuvo una clasificación para los perfiles de líneas espectrales presentados.




Figura 4.4: Mapa de activación SOM de dieciséis nodos

15	4%	0%	0%	0%	0%	0%	0%	4%	2%	0%	0%	0%	0%	0%	0%	2%	88%
14	0%	0%	0%	0%	0%	0%	0%	0%	1,6%	0%	0%	0%	0%	0%	1,6%	93,6%	3,2%
13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	96,8%	3,2%	0%
12	0%	0%	0%	6%	4%	2%	0%	0%	0%	0%	0%	2%	82%	0%	4%	0%	0%
11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	6,9%	82,8%	10,3%	0%	0%	0%	0%
10	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	89,5%	10,5%	0%	0%	0%	0%	0%
9	0%	0%	0%	0%	0%	0%	0%	6,6%	0%	85,5%	0%	7,9%	0%	0%	0%	0%	0%
8	5,7%	0%	0%	0%	0%	1,9%	0%	3,8%	77,3%	7,5%	0%	0%	0%	0%	0%	0%	3,8%
7	0%	0%	0%	0%	0%	1,3%	3,8%	92,3%	2,6%	0%	0%	0%	0%	0%	0%	0%	0%
6	0%	0%	0%	0%	1,7%	8,5%	81,3%	6,8%	0%	1,7%	0%	0%	0%	0%	0%	0%	0%
5	0%	0%	0%	0%	5,2%	89,7%	3,4%	1,7%	0%	0%	0%	0%	0%	0%	0%	0%	0%
4	0%	0%	2,9%	0%	84,3%	7,1%	0%	0%	0%	0%	4,3%	1,4%	0%	0%	0%	0%	0%
3	0%	0%	2,9%	91,4%	4,3%	0%	0%	0%	1,4%	0%	0%	0%	0%	0%	0%	0%	0%
2	0%	3,5%	86%	8,7%	1,8%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
1	4,8%	90,4%	0%	0%	0%	0%	0%	0%	0%	0%	3,2%	1,6%	0%	0%	0%	0%	0%
0	81,8%	2,6%	1,3%	0%	0%	0%	0%	1,3%	3,9%	5,2%	0%	0%	0%	0%	0%	0%	3,9%
0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15		

Cuadro 4.2: Matriz de confusión para mapa SOM de dieciséis nodos

## 4.3. DSOM

Para el mapa auto-organizado DSOM se determinó los siguientes parámetros de entrada: La cantidad de nodos, elasticidad, rango de aprendizaje y el tamaño del vector de entrada.

En este proyecto se usaron dos cantidades de nodos para el DSOM uno de ellos con nueve nodos y el otro con dieciséis nodos.

### 4.3.1. Mapa DSOM con nueve nodos

El mapa DSOM de nueve nodos fue representado como un mapa neuronal de dimensión 3x3.

Para el mapa DSOM con nueve nodos se realizaron 800 iteraciones con un rango de aprendizaje de 1.5 y una elasticidad de 1.8.

Los vectores de entrada tienen el mismo tamaño que los vectores característicos, este tamaño es de 58.

De los 400 perfiles de líneas espectrales obtenidos por TIDES se consideró un conjunto de patrones de entrenamiento de 300 perfiles de líneas espectrales. Estos perfiles fueron obtenidos como resultado de la selección aleatoria de 100 perfiles de líneas espectrales y los perfiles seleccionados de manera aleatoria fueron el conjunto de patrones de prueba.

En la fase de entrenamiento, el conjunto de patrones de entrenamiento fue presentado al mapa para cada iteración del entrenamiento. En donde cada elemento del conjunto se calculó la distancia Euclidiana con respecto a los pesos de la red y se obtuvo un nodo ganador para después actualizar los pesos de los nodos dentro del radio de vecindad.

Una vez finalizada la fase de entrenamiento, los elementos del conjunto de

patrones de prueba fueron presentados al mapa en donde fueron registradas las activaciones de todos los nodos, es decir, la distancia Euclidiana entre el elemento presentado y los pesos de la red. Este proceso se llevo a cabo veinte veces.

Se propuso una clasificación de los perfiles de líneas espectrales. Esto fue posible realizar debido a que se conoce la fase orbital a la que pertenece cada perfil de línea espectral y así sabemos en donde debe quedar cada perfil de línea espectral.

La comparación se representó en una matriz de confusión en donde se registraron los perfiles espectrales que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como en la clasificación realizada por el mapa auto-organizado. Los resultados obtenidos en la matriz de confusión fueron presentados como el promedio de todas las procesos.

Los perfiles fueron agrupados con respecto al nodo al que fueron ubicado en la matriz de confusión y se calculó su media estadística de la activación generada en cada nodo. Los resultados fueron presentados en una matriz de activación.

### **Resultados del mapa DSOM con nueve nodos**

Los resultados obtenidos en el mapa DSOM con 9 nodos (Figura 4.5) mostrarán una mayor activación en la diagonal, como fue en el caso del mapa SOM. Sin embargo las activaciones que fueron generadas por los perfiles espectrales en el mapa DSOM presentan una activación mayor en los demás nodos; Esto no quiere decir que el DSOM no haya realizado una clasificación.

La matriz de confusión para el mapa DSOM de nueve nodos (Cuadro 4.3) mostró que en promedio el 82,6% de los perfiles de líneas espectrales fueron ubicados de manera correcta con respecto a la clasificación propuesta.

Este resultado fue obtenido al promediar la diagonal de esta matriz. Ya que en esta diagonal se encuentran los perfiles que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como la clasificación realizada por el mapa auto-organizado.

El DSOM fue capaz de clasificar los perfiles de líneas espectrales, esto es porque la mayoría de los perfiles clasificados presentaron una mayor activación en el nodo en el que fueron ubicados.






Figura 4.5: Mapa de activación DSOM de nueve nodos

8	12%	2,4%	0%	0%	0%	0%	1,6%	9,6%	74,4%
7	4,5%	0%	0%	0%	0%	0%	9%	79,3%	7,2%
6	0,8%	0%	0%	0%	0%	5,8%	85,2%	8,2%	0%
5	0%	0%	0%	0%	9%	78,8%	8%	3%	1,2%
4	0%	0%	0%	8,3%	77,5%	10%	4,2%	0%	0%
3	0%	2%	5%	90%	0%	3%	0%	0%	0%
2	0%	6,2%	80,8%	10%	3%	0%	0%	0%	0%
1	4,3%	92,4%	3,3%	0%	0%	0%	0%	0%	0%
0	85%	3,7%	0,9%	0%	0%	0%	0%	4,7%	5,7%
	0	1	2	3	4	5	6	7	8

Cuadro 4.3: Matriz de confusión para mapa DSOM de nueve nodos

### 4.3.2. Mapa DSOM con dieciséis nodos

El mapa DSOM de dieciséis nodos fue representado como un mapa neuronal de dimension 4x4.

Para el mapa DSOM con dieciséis nodos se realizaron 800 iteraciones con un rango de aprendizaje de 2.5 y una elasticidad de 2.

Los vectores de entrada tienen el mismo tamaño que los vectores característicos, este tamaño es de 58.

De los 400 perfiles de líneas espectrales obtenidos por TIDES se consideró un conjunto de patrones de entrenamiento de 300 perfiles de líneas espectrales. Estos perfiles fueron obtenidos como resultado de la selección aleatoria de 100 perfiles de líneas espectrales y los perfiles seleccionados de manera aleatoria fueron el conjunto de patrones de prueba.

En la fase de entrenamiento, el conjunto de patrones de entrenamiento fue presentado al mapa para cada iteración del entrenamiento. En donde cada elemento del conjunto se calculó la distancia Euclidiana con respecto a los pesos de la red y se obtuvo un nodo ganador para después actualizar los pesos de los nodos dentro del radio de vecindad.

Una vez finalizada la fase de entrenamiento, los elementos del conjunto de patrones de prueba fueron presentados al mapa en donde fueron registradas las activaciones de todos los nodos, es decir, la distancia Euclidiana entre el elemento presentado y los pesos de la red. Este proceso se llevó a cabo veinte veces.

Se propuso una clasificación de los perfiles de líneas espectrales. Esto fue posible realizar debido a que se conoce la fase orbital a la que pertenece cada perfil de línea espectral y así sabemos en donde debe quedar cada perfil de línea espectral.

La comparación se representó en una matriz de confusión en donde se registraron los perfiles espectrales que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como en la clasificación realizada por el mapa auto-organizado. Los resultados obtenidos en la matriz de confusión fueron presentados como el promedio de todas las procesos.

Los perfiles fueron agrupados con respecto al nodo al que fueron ubicado en la matriz de confusión y se calculó su media estadística de la activación generada en cada nodo. Los resultados fueron presentados en una matriz de activación.

### **Resultados del mapa DSOM con dieciséis nodos**

Los resultados del mapa DSOM para 16 nodos presentó una semejanza con el DSOM de 9 nodos, es decir, al igual que los anteriores resultados mostrados, este mapa también presentó una mayor activación en la diagonal.

La matriz de confusión para el mapa DSOM de dieciséis nodos (Cuadro 4.4) mostró que en promedio el 86,3 % de los perfiles de líneas espectrales fueron ubicados de manera correcta con respecto a la clasificación propuesta.

Este resultado fue obtenido al promediar la diagonal de esta matriz. Ya que

en esta diagonal se encuentran los perfiles que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como la clasificación realizada por el mapa auto-organizado.

Esto nos permite concluir que también el mapa DSOM con dieciséis nodos fue capaz de clasificar los perfiles de líneas espectrales.




Figura 4.6: Mapa de activación DSOM de dieciséis nodos

15	1.4%	0%	0%	0%	0%	0%	0%	0%	3%	1.4%	0%	0%	0%	0%	0%	2.9%	91.3%
14	1.4%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	4.7%	7.4%	0%	0%	86.5%	0%
13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	85.4%	14.6%	0%	0%
12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	14.8%	85.2%	0%	0%	0%	0%
11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	4.8%	82.3%	11.3%	1.6%	0%	0%	0%
10	0%	0%	0%	0%	0%	0%	0%	0%	6.8%	0%	82.2%	6.8%	4.2%	0%	0%	0%	0%
9	0%	0%	0%	0%	0%	0%	0%	3.5%	5.3%	84.2%	7%	0%	0%	0%	0%	0%	0%
8	0%	0%	0%	0%	0%	1.7%	0%	8.4%	84.8%	0%	5.1%	0%	0%	0%	0%	0%	0%
7	0%	0%	0%	0%	0%	1.7%	6.7%	79.7%	8.5%	3.4%	0%	0%	0%	0%	0%	0%	0%
6	0%	0%	0%	0%	7.9%	0%	82.6%	9.5%	0%	0%	0%	0%	0%	0%	0%	0%	0%
5	0%	0%	0%	0%	6.7%	91.1%	1.1%	0%	0%	0%	0%	11.1%	0%	0%	0%	0%	0%
4	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
3	0%	0%	5.3%	93%	1.7%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
2	0%	1.4%	87.8%	10.8%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
1	10.9%	75.1%	7.8%	0%	0%	0%	6.2%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
0	89.5%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1.8%	0%	8.7%
0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15		

Cuadro 4.4: Matriz de confusión para mapa DSOM de dieciséis nodos

## 4.4. SOMC

Para el mapa auto-organizado SOMC se determinó los siguientes parámetros de entrada: La cantidad de nodos, el número de iteraciones, factor de aprendizaje inicial, factor de aprendizaje final, rango de aprendizaje inicial, rango de aprendizaje final y el tamaño del vector de entrada. En este proyecto se usaron dos cantidades de nodos para el SOMC uno de ellos con nueve nodos y el otro con dieciséis nodos.

### 4.4.1. Mapa SOMC con nueve nodos

Para el mapa SOMC con nueve nodos se realizaron 800 iteraciones con un factor de aprendizaje inicial de 0.7, un factor de aprendizaje final de 1.2, rango de aprendizaje inicial de 4 y un rango de aprendizaje final de 0.5.

Los vectores de entrada tienen el mismo tamaño que los vectores característicos, este tamaño es de 58.

De los 400 perfiles de líneas espectrales obtenidos por TIDES se consideró un conjunto de patrones de entrenamiento de 300 perfiles de líneas espectrales. Estos perfiles fueron obtenidos como resultado de la selección aleatoria de 100 perfiles de líneas espectrales y los perfiles seleccionados de manera aleatoria fueron el conjunto de patrones de prueba.

En la fase de entrenamiento, el conjunto de patrones de entrenamiento fue presentado al mapa para cada iteración del entrenamiento. En donde cada elemento del conjunto se calculó la distancia Euclidiana con respecto a los pesos de la red y se obtuvo un nodo ganador para después actualizar los pesos de los nodos dentro del radio de vecindad.

Una vez finalizada la fase de entrenamiento, los elementos del conjunto de patrones de prueba fueron presentados al mapa en donde fueron registradas las activaciones de todos los nodos, es decir, la distancia Euclidiana entre el elemento presentado y los pesos de la red. Este proceso se llevó a cabo veinte veces.

Se propuso una clasificación de los perfiles de líneas espectrales. Esto fue posible realizar debido a que se conoce la fase orbital a la que pertenece cada perfil de línea espectral y así sabemos en donde debe quedar cada perfil de línea espectral.

La comparación se representó en una matriz de confusión en donde se registraron los perfiles espectrales que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como en la clasificación realizada por el mapa auto-organizado. Los resultados obtenidos en la matriz de confusión

fueron presentados como el promedio de todas las procesos. Los perfiles fueron agrupados con respecto al nodo al que fueron ubicado en la matriz de confusión y se calculó su media estadística de la activación generada en cada nodo. Los resultados fueron presentados en una matriz de activación.

### **Resultados del mapa SOMC con nueve nodos**

El mapa de activación del SOMC de nueve nodos (Figura 4.7) también presentó una mayor activación en la diagonal y se observó que la activación es reducida conforme se aleja de esta.

El mapa SOMC de nueve nodos realizó una clasificación con los perfiles de líneas espectrales. Debido a que las activaciones son las distancias euclidianas entre los perfiles de líneas espectrales y los nodos del mapa, es decir, que estos perfiles son correlacionados entre sí.

La matriz de confusión para el mapa SOMC de nueve nodos (Cuadro 4.5) mostró que en promedio el 89,9% de los perfiles de líneas espectrales fueron ubicados de manera correcta con respecto a la clasificación propuesta.

Este resultado fue obtenido al promediar la diagonal de esta matriz. Ya que en esta diagonal se encuentran los perfiles que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como la clasificación realizada por el mapa auto-organizado.




Figura 4.7: Mapa de activación SOMC de nueve nodos

8	3,1%	0%	0%	0%	0%	0%	0%	6,3%	90,6%
7	4,7%	0%	0%	0%	0%	0%	5,7%	89,6%	0%
6	0%	0%	0%	0%	0%	4,2%	88,5%	7,3%	0%
5	0%	0%	0%	2,3%	0%	93,9%	3,8%	0%	0%
4	0%	0%	5,5%	0%	87,9%	6,6%	0%	0%	0%
3	0%	0%	7,4%	89,4%	3,2%	0%	0%	0%	0%
2	0%	5%	88,3%	6,7%	0%	0%	0%	0%	0%
1	0,9%	92,3%	6,8%	0%	0%	0%	0%	0%	0%
0	88,4%	3,9%	0%	0%	0%	0%	0%	0%	7,7%
	0	1	2	3	4	5	6	7	8

Cuadro 4.5: Matriz de confusión para mapa SOMC de nueve nodos

#### 4.4.2. Mapa SOMC con dieciséis nodos

Para el mapa SOMC con dieciséis nodos se realizaron 800 iteraciones con un factor de aprendizaje inicial de 0.89, un factor de aprendizaje final de 1.4, rango de aprendizaje inicial de 7 y un rango de aprendizaje final de 0.5.

Los vectores de entrada tienen el mismo tamaño que los vectores característicos, este tamaño es de 58.

De los 400 perfiles de líneas espectrales obtenidos por TIDES se consideró un conjunto de patrones de entrenamiento de 300 perfiles de líneas espectrales. Estos perfiles fueron obtenidos como resultado de la selección aleatoria de 100 perfiles de líneas espectrales y los perfiles seleccionados de manera aleatoria fueron el conjunto de patrones de prueba.

En la fase de entrenamiento, el conjunto de patrones de entrenamiento fue presentado al mapa para cada iteración del entrenamiento. En donde cada elemento del conjunto se calculó la distancia Euclidiana con respecto a los pesos de la red y se obtuvo un nodo ganador para después actualizar los pesos de los nodos dentro del radio de vecindad.

Una vez finalizada la fase de entrenamiento, los elementos del conjunto de patrones de prueba fueron presentados al mapa en donde fueron registradas las activaciones de todos los nodos, es decir, la distancia Euclidiana entre el elemento presentado y los pesos de la red. Este proceso se llevó a cabo veinte veces.

Se propuso una clasificación de los perfiles de líneas espectrales. Esto fue posible realizar debido a que se conoce la fase orbital a la que pertenece cada perfil de línea espectral y así sabemos en donde debe quedar cada perfil de línea espectral.

La comparación se representó en una matriz de confusión en donde se registraron los perfiles espectrales que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como en la clasificación realizada por el mapa auto-organizado. Los resultados obtenidos en la matriz de confusión fueron presentados como el promedio de todas las procesos.

Los perfiles fueron agrupados con respecto al nodo al que fueron ubicado en la matriz de confusión y se calculó su media estadística de la activación generada en cada nodo. Los resultados fueron presentados en una matriz de activación.

### **Resultados del mapa SOMC con dieciséis nodos**

Observamos que el comportamiento que mostró el mapa SOMC con 16 nodos (Figura 4.8) es semejante a algunos comportamientos de la matriz de correlación de los 400 perfiles espectrales (Figura 4.1).

La matriz de confusión para el mapa SOMC de dieciséis nodos (Cuadro 4.6) mostró que en promedio el 87,6 % de los perfiles de líneas espectrales fueron ubicados de manera correcta con respecto a la clasificación propuesta.

Este resultado fue obtenido al promediar la diagonal de esta matriz. Ya que en esta diagonal se encuentran los perfiles que fueron ubicados en el mis-

mo nodo tanto en la clasificación propuesta como la clasificación realizada por el mapa auto-organizado.

El mapa de activación del SOMC de dieciséis nodos clasificó los perfiles de líneas espectrales esto se pudo concluir debido a que en la diagonal del mapa es donde se presentó la mayor actividad generada.




Figura 4.8: Mapa de activación SOMC de dieciséis nodos

15	1.4%	0%	0%	0%	0%	0%	0%	1.4%	2.8%	0%	0%	0%	0%	0%	0%	0%	4.2%	90.2%
14	0%	0%	0%	0%	0%	0%	5.4%	3.6%	0%	0%	0%	0%	0%	0%	0%	3.5%	82.1%	5.4%
13	0%	0%	0%	0%	0%	1.3%	2.6%	0%	0%	0%	0%	0%	0%	5.3%	82.9%	6.6%	1.3%	
12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%	
11	0%	0%	0%	6.6%	1.6%	0%	0%	0%	0%	0%	6.6%	80.3%	4.9%	0%	0%	0%	0%	
10	0%	0%	1.6%	4.9%	0%	0%	0%	0%	0%	8.2%	85.3%	0%	0%	0%	0%	0%	0%	
9	0%	3.4%	1.8%	0%	0%	0%	0%	0%	0%	91.4%	3.4%	0%	0%	0%	0%	0%	0%	
8	4.7%	0%	0%	0%	0%	0%	0%	0%	93.7%	1.6%	0%	0%	0%	0%	0%	0%	0%	
7	0%	0%	0%	0%	0%	0%	0%	91.2%	8.8%	0%	0%	0%	0%	0%	0%	0%	0%	
6	0%	0%	0%	0%	0%	5.4%	81.1%	13.5%	0%	0%	0%	0%	0%	0%	0%	0%	0%	
5	0%	0%	0%	0%	0%	96.7%	0%	0%	0%	0%	0%	0%	0%	0%	3.3%	0%	0%	
4	0%	0%	0%	5.6%	85.2%	1.9%	0%	0%	0%	0%	0%	0%	7.3%	0%	0%	0%	0%	
3	0%	4.3%	0%	88.4%	5.8%	0%	0%	0%	0%	1.5%	0%	0%	0%	0%	0%	0%	0%	
2	0%	7.2%	81.2%	2.9%	0%	0%	0%	0%	0%	5.8%	2.9%	0%	0%	0%	0%	0%	0%	
1	2.8%	84.5%	5.6%	0%	0%	0%	0%	0%	0%	4.3%	2.8%	0%	0%	0%	0%	0%	0%	
0	87.7%	5.3%	2%	0%	0%	0%	0%	0%	3.4%	1.8%	2%	0%	0%	0%	0%	0%	1.8%	
0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15			

Cuadro 4.6: Matriz de confusión para mapa SOMC de dieciséis nodos



## 4.5. NG

Para el mapa auto-organizado NG se determinó los siguientes parámetros de entrada: La cantidad de nodos, el número de iteraciones, factor de aprendizaje inicial, factor de aprendizaje final, rango de aprendizaje inicial, rango de aprendizaje final y el tamaño del vector de entrada.

En este proyecto se usaron dos cantidades de nodos para el NG uno de ellos con nueve nodos y el otro con dieciséis nodos.

### 4.5.1. Mapa NG con nueve nodos

Para el mapa NG con nueve nodos se realizaron 800 iteraciones con un factor de aprendizaje inicial de 0.7, un factor de aprendizaje final de 1.0, rango de aprendizaje inicial de 6 y un rango de aprendizaje final de 0.5.

Los vectores de entrada tienen el mismo tamaño que los vectores característicos, este tamaño es de 58.

De los 400 perfiles de líneas espectrales obtenidos por TIDES se consideró un conjunto de patrones de entrenamiento de 300 perfiles de líneas espectrales. Estos perfiles fueron obtenidos como resultado de la selección aleatoria de 100 perfiles de líneas espectrales y los perfiles seleccionados de manera aleatoria fueron el conjunto de patrones de prueba.

En la fase de entrenamiento, el conjunto de patrones de entrenamiento fue presentado al mapa para cada iteración del entrenamiento. En donde cada elemento del conjunto se calculó la distancia Euclidiana con respecto a los pesos de la red y se obtuvo un nodo ganador para después actualizar los pesos de los nodos dentro del radio de vecindad.

Una vez finalizada la fase de entrenamiento, los elementos del conjunto de patrones de prueba fueron presentados al mapa en donde fueron registradas las activaciones de todos los nodos, es decir, la distancia Euclidiana entre el elemento presentado y los pesos de la red. Este proceso se llevó a cabo veinte veces.

Se propuso una clasificación de los perfiles de líneas espectrales. Esto fue posible realizar debido a que se conoce la fase orbital a la que pertenece cada perfil de línea espectral y así sabemos en donde debe quedar cada perfil de línea espectral.

La comparación se representó en una matriz de confusión en donde se registraron los perfiles espectrales que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como en la clasificación realizada por el mapa auto-organizado. Los resultados obtenidos en la matriz de confusión fueron presentados como el promedio de todas las procesos.

Los perfiles fueron agrupados con respecto al nodo al que fueron ubicado en la matriz de confusión y se calculó su media estadística de la activación generada en cada nodo. Los resultados fueron presentados en una matriz de activación.

### **Resultados del mapa NG con nueve nodos**

En la clasificación realizada por el mapa auto-organizado NG también se observó que la mayor activación fue realizada en la diagonal.

Los resultados realizados por el mapa NG es una aproximación de la clasificación original realizada, esto es debido a la estructura que posee este mapa. El mapa esta compuesto por nodos que no tienen una posición definida principalmente porque la posición de los nodos cambia con respecto a la entrada que este se le presenta.

Es por ello que no es posible ordenarlos de manera secuencial pero se consideró solo a los nodos que fueron ubicados los perfiles y ver la activación que tienen, si la activación en la diagonal es mayor que los demás podremos saber que la mayoría de los perfiles encuentran en cada nodo clasificado están correlacionados.

La matriz de confusión para el mapa NG de nueve nodos (Cuadro 4.7) mostró que en promedio el 82,6% de los perfiles de líneas espectrales fueron ubicados de manera correcta con respecto a la clasificación propuesta.

Este resultado fue obtenido al promediar la diagonal de esta matriz. Ya que en esta diagonal se encuentran los perfiles que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como la clasificación realizada por el mapa auto-organizado.

Por los resultados obtenidos en la matriz de confusión y el mapa de activación sabemos que el NG también realizó una clasificación a los perfiles de líneas espectrales.




Figura 4.9: Mapa de activación NG de nueve nodos

8	7,2%	0,9%	0%	0%	0%	0%	0%	6,4%	85,5%
7	11,9%	2,8%	0%	0%	0%	0%	5,5%	78,9%	0,9%
6	0%	1,4%	0%	0%	0%	5,6%	87,4%	3,5%	2,1%
5	0%	0%	1,2%	3,5%	0%	88,2%	2,4%	3,5%	1,2%
4	0%	0%	6,5%	0%	77,2%	10,6%	5,7%	0%	0%
3	0%	0%	3,9%	89,8%	6,3%	0%	0%	0%	0%
2	2,6%	6,8%	81,2%	7,7%	0%	1,7%	0%	0%	0%
1	1,1%	76,1%	3,3%	0%	0%	0%	0%	5,4%	14,1%
0	79,8%	5,3%	0%	3,2%	0%	0%	0%	8,5%	3,2%
	0	1	2	3	4	5	6	7	8

Cuadro 4.7: Matriz de confusión para mapa NG de nueve nodos

### 4.5.2. Mapa NG con dieciséis nodos

Para el mapa NG con dieciséis nodos se realizaron 800 iteraciones con un factor de aprendizaje inicial de 0.5, un factor de aprendizaje final de 1.7, rango de aprendizaje inicial de 10 y un rango de aprendizaje final de 0.5. Los vectores de entrada tienen el mismo tamaño que los vectores característicos, este tamaño es de 58.

De los 400 perfiles de líneas espectrales obtenidos por TIDES se consideró un conjunto de patrones de entrenamiento de 300 perfiles de líneas espectrales. Estos perfiles fueron obtenidos como resultado de la selección aleatoria de 100 perfiles de líneas espectrales y los perfiles seleccionados de manera aleatoria fueron el conjunto de patrones de prueba.

En la fase de entrenamiento, el conjunto de patrones de entrenamiento fue presentado al mapa para cada iteración del entrenamiento. En donde cada elemento del conjunto se calculó la distancia Euclidiana con respecto a los pesos de la red y se obtuvo un nodo ganador para después actualizar los pesos de los nodos dentro del radio de vecindad.

Una vez finalizada la fase de entrenamiento, los elementos del conjunto de patrones de prueba fueron presentados al mapa en donde fueron registradas las activaciones de todos los nodos, es decir, la distancia Euclidiana entre el elemento presentado y los pesos de la red. Este proceso se llevó a cabo veinte veces.

Se propuso una clasificación de los perfiles de líneas espectrales. Esto fue posible realizar debido a que se conoce la fase orbital a la que pertenece cada perfil de línea espectral y así sabemos en donde debe quedar cada perfil de línea espectral.

La comparación se representó en una matriz de confusión en donde se registraron los perfiles espectrales que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como en la clasificación realizada por el mapa auto-organizado. Los resultados obtenidos en la matriz de confusión fueron presentados como el promedio de todas las procesos.

Los perfiles fueron agrupados con respecto al nodo al que fueron ubicado en la matriz de confusión y se calculó su media estadística de la activación generada en cada nodo. Los resultados fueron presentados en una matriz de activación.


### Resultados del mapa NG con dieciséis nodos

En el mapa de activación obtenido por el mapa auto-organizado NG con dieciséis nodos al igual que el de nueve nodos solo se consideró la

diagonal debido a la estructura del mapa NG. La matriz de confusión para el mapa NG de dieciséis nodos (Cuadro 4.8) mostró que en promedio el 86,5 % de los perfiles de líneas espectrales fueron ubicados de manera correcta con respecto a la clasificación propuesta.

Este resultado fue obtenido al promediar la diagonal de esta matriz. Ya que en esta diagonal se encuentran los perfiles que fueron ubicados en el mismo nodo tanto en la clasificación propuesta como la clasificación realizada por el mapa auto-organizado.

En este mapa también se observó que existe una mayor activación en la diagonal con respecto a los demás nodos y por los resultados obtenidos en la matriz de confusión que también el mapa NG con dieciséis nodos clasificó los perfiles de líneas espectrales.



*Figura 4.10: Mapa de activación NG de dieciséis nodos*

15	3%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	4.5%	92.5%
14	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	6.3%	92.1%	1.6%
13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	8.3%	81.7%	10%	0%	0%
12	0%	3%	1.5%	0%	0%	0%	0%	0%	1.5%	0%	11.9%	82.1%	0%	0%	0%	0%
11	0%	0%	3.2%	0%	0%	1.6%	0%	0%	0%	11.4%	77.4%	6.4%	0%	0%	0%	0%
10	0%	0%	0%	4.9%	0%	0%	0%	0%	1.6%	93.5%	0%	0%	0%	0%	0%	0%
9	0%	0%	0%	0%	0%	4.6%	6.2%	0%	0%	80%	6.1%	3.1%	0%	0%	0%	0%
8	0%	0%	2.1%	0%	0%	0%	0%	4.3%	91.5%	2.1%	0%	0%	0%	0%	0%	0%
7	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%
6	0%	0%	0%	0%	0%	4.9%	86.9%	0%	8.2%	0%	0%	0%	0%	0%	0%	0%
5	0%	0%	0%	0%	1.6%	79%	11.3%	0%	0%	0%	3.2%	4.9%	0%	0%	0%	0%
4	0%	0%	0%	10%	75%	6.3%	0%	0%	0%	0%	7.5%	1.2%	0%	0%	0%	0%
3	0%	0%	0%	93.6%	1.6%	0%	0%	0%	3.2%	1.6%	0%	0%	0%	0%	0%	0%
2	0%	2.9%	83.9%	0%	5.9%	0%	0%	0%	4.4%	0%	0%	0%	2.9%	0%	0%	0%
1	0%	85%	10%	1.7%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	3.3%
0	90.6%	3.8%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	5.6%
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15

Cuadro 4.8: Matriz de confusión para mapa NG de dieciséis nodos



## CAPÍTULO 5

# Conclusiones

---

En este trabajo de tesis se tiene como problema la clasificación de perfiles de líneas espectrales de una estrella binaria. Para llevar a cabo la clasificación se usó mapas auto-organizados que son un tipo de red neuronal artificial. Los mapas auto-organizados propuestos fueron el SOM, DSOM, SOMC y NG.

Los resultados obtenidos en esta tesis demostraron que los mapas auto-organizados pueden clasificar los perfiles de líneas espectrales. Además que los perfiles de líneas espectrales fueron clasificados de acuerdo a su fase orbital.

De los mapas auto-organizados propuestos se observó que el mapa SOM desempeñó un mejor trabajo. El mapa SOM obtuvo el mayor porcentaje de perfiles clasificados de acuerdo a la clasificación que se propuso.

Se observó que el mapa SOMC presentó en el mapa de activación una mayor similitud a la matriz de correlación.

Por los resultados obtenidos en el mapa NG podemos decir que es un mapa capaz de realizar una clasificación. Sin embargo es necesario buscar otra forma de poder observar los resultados del mapa NG, esto se debe a la estructura que este mapa posee.

Se concluyó que para este trabajo el DSOM fue el mapa auto-organizado con el menor desempeño de todos.





# Bibliografía

- Carroll, B. W. (2006). *An Introduction to Modern Astrophysics*. Addison-Wesley.
- Daszykowski, M., Walczak, B., y Massart, D. L. (2002). On the optimal partitioning of data with k-means, growing k-means, neural gas, and growing neural gas. *Journal of chemical information and computer sciences*, 42(6):1378–1389.
- Harrington, Koenigsberger, M. K. J. (2009). Line-profile variability from tidal flows in alpha virginis (spica). 704:813–830.
- Herschel, W. (1802). Observations on the two lately discovered celestial bodies. *Philosophical Transactions of the Royal Society of London*, pages 213–232.
- Kohonen, T. (1986). Representation of sensory information in self-organizing feature maps, and relation of these maps to distributed memory networks. In *Optical and hybrid computing*, pages 248–259. International Society for Optics and Photonics.
- Kohonen, T. (1990). The self-organizing map. *Proceedings of the IEEE*, 78(9):1464–1480.
- Labib, K. y Vemuri, R. (2002). Nsom: A real-time network-based intrusion detection system using self-organizing maps. *Networks and Security*, pages 1–6.
- Linde, Y., Buzo, A., y Gray, R. M. (1980). An algorithm for vector quantizer design. *Communications, IEEE Transactions on*, 28(1):84–95.
- Martinetz, T., Schulten, K., et al. (1991). *A "neural-gas" network learns topologies*. University of Illinois at Urbana-Champaign.
- McCulloch, W. S. y Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133.
- Moreira, J. y Costa, L. D. F. (1996). Neural-based color image segmentation and classification using self-organizing maps. *Anais do IX Sibgrapi*, 12(6):47–54.

- Moreno, E. y Koenigsberger, G. (1999). A model for tidal interactions in iota orionis. 35:157.
- Moreno, E., Koenigsberger, G., y Toledano, O. (2005). Line profile variability from tidal interactions in binary systems. 437:641–656.
- Nikoli, D., M. R. C. F. W. y Singer, W. (2012). *Scaled correlation analysis: a better way to compute a cross-correlogram*. European Journal of Neuroscience.
- Provost, F. J., Fawcett, T., y Kohavi, R. (1998). The case against accuracy estimation for comparing induction algorithms. In *ICML*, volume 98, pages 445–453.
- Rougier, N. y Boniface, Y. (2011). Dynamic self-organising map. *Neurocomputing*, 74(11):1840–1847.
- Smith, M. (1985). The nonradial oscillations of spica-part two-a quasi-toroidal mode. *The Astrophysical Journal*, 297:224.
- Weaver, W. B. (2000). Spectral classification of unresolved binary stars with artificial neural networks. *The Astrophysical Journal*, 541(1):298.
- Weaver, W. B. y Torres-Dodgen, A. V. (1995). Neural network classification of the near-infrared spectra of a-type stars. *The Astrophysical Journal*, 446:300.