

## RECONOCIMIENTO DE CÉLULAS EPIDÉRMICAS VEGETALES MEDIANTE UNA RED NEURONAL ARTIFICIAL

**Ledda I. Larcher, E. Alejandra Catán, Claudia A. Degano**

*INDEAS (Instituto para el Desarrollo Agropecuario del Semiárido), Facultad de Agronomía y  
Agroindustrias, Universidad Nacional de Santiago del Estero,  
Av. Belgrano Sur 1912; G4200ABT Santiago del Estero ([llarcher@unse.edu.ar](mailto:llarcher@unse.edu.ar))  
<http://faa.unse.edu.ar>*

**Palabras clave:** procesamiento de imágenes, visión artificial; red neuronal, microhistología

**Resumen:** Este artículo muestra la aplicación de redes neuronales artificiales en el campo de la microhistología.

El reconocimiento de células de epidermis es una tarea realizada normalmente por un técnico microscopista, quien en función de su entrenamiento y experiencia, reconoce las características propias de las células epidérmicas para poder identificar la especie ingerida.

Durante las primeras etapas de este proyecto de investigación, se desarrolló una herramienta de software consistente en bases de datos que permitían consultar fichas donde constaban las características de las células y posibilitaba la visualización de fotografías a diferentes aumentos que asistían al especialista en la identificación. Se mostraba también una lista de especies que presentaban características similares y con las que podía fácilmente ser confundida. Profundizaciones realizadas en el estudio y el uso de esta herramienta dieron como resultado un porcentaje de fallos, que si bien eran bajos, resultaban inaceptables en la práctica.

Se determinó que una mejor aproximación a la resolución de este problema era suministrada por el área de la Inteligencia Artificial, aplicada al reconocimiento óptico de las células.

Se presenta una herramienta de software, específicamente una red neuronal artificial del tipo backpropagation (RNAB), que asiste a este especialista en la realización de su tarea. La red neuronal backpropagation construida, toma como entrada imágenes digitales de trozos de epidermis y reconoce las células de diferentes especies vegetales presentes en la dieta de caprinos en la región denominada Chaco Semiárido del noroeste argentino.

En particular, la RNAB será de gran utilidad para el técnico quien verá incrementada su eficiencia y eficacia al contar con un modelo de razonamiento automático entrenado en la determinación de especies vegetales encontradas en la dieta de rumiantes que pastorean a monte en el chaco semiárido del NOA. Asimismo, permitirá a los investigadores la determinación de relaciones de estrategias alimentarias en herbívoros silvestres y domésticos en el semiárido, que puedan manifestar competencia por alimento.

## 1 INTRODUCCIÓN

El caprino es un animal que se alimenta de vegetales pertenecientes a diferentes grupos: herbáceas, arbóreas, cactáceas y arbustivas, tomando de ellos tanto follaje como frutos a fin de alcanzar su equilibrio nutricional. En las regiones semiáridas, las especies forrajeras leñosas son un importante complemento para su alimentación al prevalecer en las épocas en que el pasto ha desaparecido, por lo cual -especialmente cuando el pastoreo se realiza en áreas naturales- el hábito selectivo de este animal le permite mantener niveles regulares de nutrición. En Argentina, la actividad caprina ha sido desde siempre patrimonio de numerosos productores minifundistas, constituyéndose en una fuerte componente de las economías regionales. En general, se trata de un sistema de subsistencia debido a que los productores involucrados pertenecen al sector del minifundio con menores recursos. Se caracterizan por ser sistemas de tipo extensivo, basados en encierro nocturno, pastoreo a campo natural, sin límites determinados, sin agua asegurada y sin control sanitario ni de producción. (Salinas y Dellepiane, 1994).

Para hacer referencia al comportamiento de una especie animal frente a una oferta forrajera, se deben manejar los conceptos de palatabilidad, preferencia y selectividad, para lo que es necesario el conocimiento previo de la composición botánica de la dieta. (Pelliza de Sbriller, 1993)

De esta manera, el conocimiento de la dieta de herbívoros ayuda a comprender algunas de las relaciones ecológicas entre los productores primarios (comunidad vegetal) y los consumidores (herbívoros). Además, la composición botánica de la dieta y su variación en el tiempo juegan un papel importante desde la perspectiva de producción de ganado caprino, ya que conocer la dieta es fundamental para corregir las deficiencias nutricionales producidas por la alimentación con forraje nativo, permitiendo diseñar estrategias de manejo tanto del forraje como del estado nutricional del animal. (Mellado et al., 1991).

Habitualmente, es el técnico microscopista quien, a partir del análisis de fragmentos epidérmicos, reconoce características de las células contenidas e identifica las especies vegetales ingeridas. Para la determinación de la composición botánica de la dieta de herbívoros se han empleado distintas metodologías, tales como: densidad total, frecuencia relativa, rangos, parcela puntual y censos, entre otras, adaptándose cada una a una situación particular (Havstad y Donart, 1978; Holecheck y Gross, 1982; Norbury, 1998; Sparks y Malechek, 1968; Westoby et al., 1976; Barker, 1986). La microhistología es una de las técnicas más frecuentemente utilizadas; sin embargo, resulta una tarea complicada y su éxito depende en gran medida del entrenamiento y experiencia del técnico que realiza la tarea, puesto que implica el conocimiento de un amplio número de especies y de sus caracteres histológicos. Existe, por lo tanto, una necesidad tanto técnica como económica de aplicar nuevos métodos que permitan el reconocimiento de células botánicas de manera confiable y rápida.

Usar técnicas de programación convencional equivalía a equiparar la foto a reconocer con todas las fotos posibles de esa misma célula. Una tarea evidentemente imposible, a lo que debía sumarse la posibilidad de trabajar con fotos pocas nítidas. La programación convencional resulta, evidentemente, poco adecuada para este tipo de problemas, surgió así el concepto de reconocimiento de patrones (propio del área de la Inteligencia Artificial). El reconocimiento de objetos en una imagen está desarrollado ampliamente en la bibliografía (Castleman, 1996; González y Woods, 2002; Schalkoff, 1989; Jähne, 2005), pero los

programas de procesamiento digital de imágenes que generalmente acompañan a los equipos de adquisición no tienen la capacidad para hacer algún tipo de reconocimiento y tampoco admiten la posibilidad de agregar algoritmos para hacerlo. El reconocimiento de patrones involucra técnicas de medición de características morfológicas de los objetos contenidos en la imagen; el desarrollo de una red neuronal artificial permitirá reconocer el objeto a partir de las características medidas.

Este trabajo demuestra la aplicabilidad exitosa de las redes neuronales artificiales al campo de la microhistología presentándose una red neuronal del tipo backpropagation, inicialmente entrenada para reconocer imágenes de células epidérmicas de las especies vegetales más significativas de la dieta de caprinos que pastorean a monte en el Chaco semiárido del noroeste argentino.

## 2 MATERIALES Y MÉTODOS

Para poder clasificar las células presentes en una muestra es necesario distinguir las diferentes características (forma, tamaño) y la composición de las mismas. La pared celular rodea al citoplasma con lo cual cada una tiene tamaño y volumen propios. Al mismo tiempo, la observación de objetos tan pequeños sólo es posible mediante microscopios, y su conservación sólo es posible mediante la preparación de muestras, con lo que algunas de estas características no son 100% reales (pérdida de volumen por secado, cambios en la coloración por tinción, cambios en la forma original por triturado).

La adquisición de imágenes es el proceso de convertir una foto en su representación numérica (digital), apropiada para pasos posteriores de procesamiento de imágenes, y es realizado mediante un digitalizador.

Las técnicas de procesamiento de imágenes permiten extraer de una imagen un conjunto de características numéricas, expresadas como características codificadas del objeto seleccionado, que pueden ser usadas para diferenciar una clase de objetos de otra.

Sin embargo, el principal inconveniente es que la unidad de información en una imagen digitalizada es el píxel y cada píxel posee propiedades de posición y valores de color; sin embargo, por sí mismo, el conocer la posición y el valor de un píxel en particular, generalmente no conlleva ninguna información biológica relacionada con el reconocimiento de una célula. Para evitar este problema, se establece un conjunto de características.

Las redes neuronales artificiales clasifican una sección de tejido microhistológico luego de ser entrenadas con un conjunto específico de datos tomando en cuenta todas o algunas de las características extraídas. Cada salida de una red neuronal es la probabilidad de clasificar una entrada que pertenece a una clase específica. Asignamos la sección de entrada a la clase asociada dándole el valor más alto a la salida.

Siguiendo la metodología propuesta por [Marmo et al. \(2005\)](#), los pasos principales en este trabajo ([Figura 1](#)) son:

1. adquisición de la imagen;
2. aplicación de filtros a la imagen;
3. extracción de características;
4. normalización de características;
5. reducción de la dimensión de la entrada;
6. red neuronal.

Estos pasos fueron implementados en un lenguaje de programación. El software obtenido realiza la clasificación de una imagen digitalizadas en tiempo menor al necesario para un técnico microscopista, usando una computadora de escritorio basada en un procesador Pentium IV con 256 MB de memoria RAM.

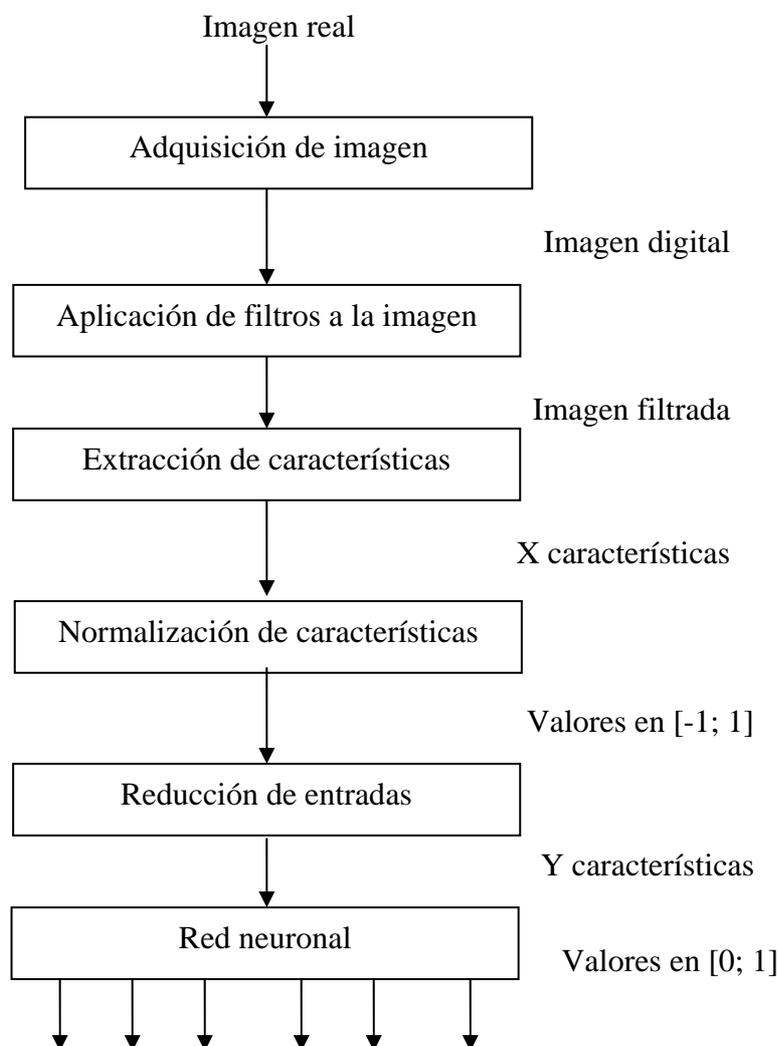


Figura 1. Secuencia de pasos implementada

## 2.1 Adquisición de imágenes

Se utilizaron las imágenes correspondientes a tejido de las especies vegetales que comúnmente forman parte de la dieta de pequeños rumiantes, contenidas en una base de datos desarrollada con anterioridad (Degano *et al.*, 1998). La colección de referencia fue realizada en el Laboratorio de Botánica de la Facultad de Agronomía y Agroindustrias de Santiago del Estero con muestras recolectadas en el campo experimental del INTA “La María” y siguiendo las técnicas de Peña Neira y una variante de la misma (Catán *et al.*;

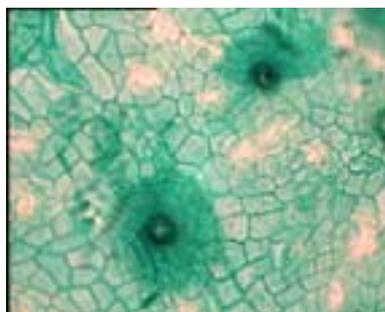
2003). Se consideraron las especies *Zizyphus mistol* (mistol), *Acacia* sp., *Prosopis alba* (quebracho blanco), *Justicia campestris* (alfalfita o alfilla), *Clematis montevidense*, *Celtis palida*, *Lippia turbinata* (poleo), *Lantana* sp., *Geoffroea decorticans* (chañar), *Eupatorium* sp., *Wissadula* sp., *Sphaeralcea* sp., *Tabebuia nodosa* (huiñaj), *Jodina rhombifolia* (sombra de toro, quebracho flojo), *Allenrolfea vaginata* (jume), *Lithraea ternifolia* (molle), *Castela coccinea* (mistol de zorro), *Schinopsis haenkeana* (orco quebracho) y *Celtis tala* (tala)

Como ya se enunció, la adquisición de imágenes describe el proceso de convertir una foto en su representación numérica, apropiada para pasos posteriores de procesamiento de imágenes. El proceso de adquisición es realizado mediante un microscopio binocular capaz de trabajar a 100 aumentos Arcano, con una cámara de video Samsung incorporada y el software para capturar fotos Pinnacle Studio Quick Start.

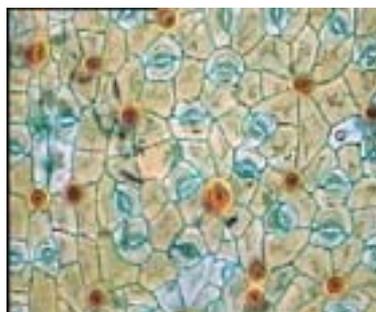
El parámetro de color de una imagen es una de las características directas usadas para la discriminación visual (Sève, 1996; Bajon *et al.*, 1988). Petersen y Krutz, (1992) resaltan la importancia del uso del color para mejorar precisión del reconocimiento. En el caso de las imágenes utilizadas, la información referente a color ha sido descartada debido al procesamiento previo que reciben las muestras (tinción), como se muestra en la Figura 2. Las imágenes en blanco y negro presentaban la dificultad de resultar confusas debido al gran número de elementos presentes en cada muestra, por otra parte, se consideró que la señal de color contenía información relacionada con el espesor de los objetos transparentes expuestos. Se decidió trabajar con niveles de gris para encontrar rápidamente el contorno de los diferentes elementos de la célula.

Con el término “imagen digital” nos referimos a una matriz bidimensional  $M$ ; cada  $M(i,j)$  es un píxel ubicado en la fila  $i$  y en la columna  $j$  que contiene el tono de color relacionado a la imagen real.

En este trabajo se usan imágenes de 256 tonos de grises (0 corresponde al negro y 255 a blanco) de tamaño 288 x 352 píxeles de 150dpi, tomadas a 40x.



*Tabebuia nodosa* (Huiñaj o palo de cruz). 40x



*Prosopis alba* (algarrobo blanco). 40x.

Figura 2. Diferentes efectos en las muestras debido a la tinción de tejido durante su preparación

## 2.2 Aplicación de filtros a las imágenes

Las imágenes se transforman a escala de grises mediante la conversión de los valores RGB a coordenadas NTCS y colocando en cero los componentes de tono y saturación y luego volviéndolos nuevamente al espacio de color RGB.

Se desarrolló una interface tipo browser, que permite seleccionar un directorio de trabajo, y seleccionar y abrir archivos. En la Figura 3 puede apreciarse su simplicidad de manejo:

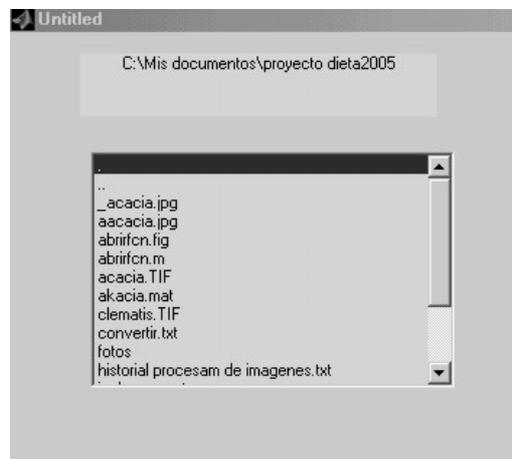


Figura 3. Interface para la selección de archivos de trabajo.

Si el archivo seleccionado no corresponde a un archivo de imágenes, se invoca a un visor de archivos standard.

Si se determina que se trata de una imagen, la próxima tarea consiste en la determinación del tipo de archivo y su conversión en caso de ser necesario. Se convierte el archivo en un arreglo bidimensional. La cabecera del archivo contiene los datos que permitirán determinar el tipo de imagen de que se trata.

El tamaño de imagen a utilizar se estandariza y, a continuación, el archivo de entrada se convierte a escala de grises de 8 bits usando diferentes funciones.

Se generaron opciones que permiten la corrección básica de la imagen, con posibilidad de usar máscara poligonal en caso que se desee trabajar usando regiones de interés:

- **Ecualización imagen:** mejora el contraste de la imagen transformando los valores de manera que, en el histograma de la imagen de salida, los valores de los píxeles de la imagen se distribuyan de manera uniforme a lo largo del rango potencialmente disponible.
- **Filtro adaptativo lowpass:** permite mejorar una imagen degradada por adición constante de ruido usando el método de Wiener, que usa los vecinos de tamaño  $m \times n$  para calcular la media local y el desvío standard alrededor de cada píxel (Lim, 1990)
- **Filtro por mediana:** Este filtro es similar a usar un proceso en el que cada píxel de salida tome como valor el “promedio” de los vecinos del píxel de entrada correspondiente. En este caso, sin embargo, el valor del píxel de salida se establece usando la mediana de los vecinos del píxel de entrada correspondiente. La mediana es mucho menos sensitiva a valores extremos que la media, por lo tanto, puede reducir estos valores extremos sin pérdida de nitidez en la imagen resultante.
- **Iluminación y oscurecimiento:** se reemplaza el mapcolor por otro más claro (oscuro) que tiene, esencialmente, los mismos colores.
- **Aumento y disminución de contraste:** se ajustan los valores de intensidad (o colormap) de una imagen; se toman una imagen de entrada y dos vectores: [bajo

alto] y [base tope]. La imagen de salida se genera mapeando el valor bajo de la imagen de entrada al valor base de la imagen resultado; el valor alto de la imagen origen al valor tope en la imagen resultante, y escalando linealmente los valores intermedios.

- **Detección de límites** por los métodos de Sobel, Prewitt, Roberts, cruce de ceros, Laplace y Canny, para resaltar los bordes de los elementos que componen la imagen.)

Con la versión resultante, finalmente se logran archivos aptos como entrada para la red. A continuación, la [Figura 4](#) muestra la interface construida:

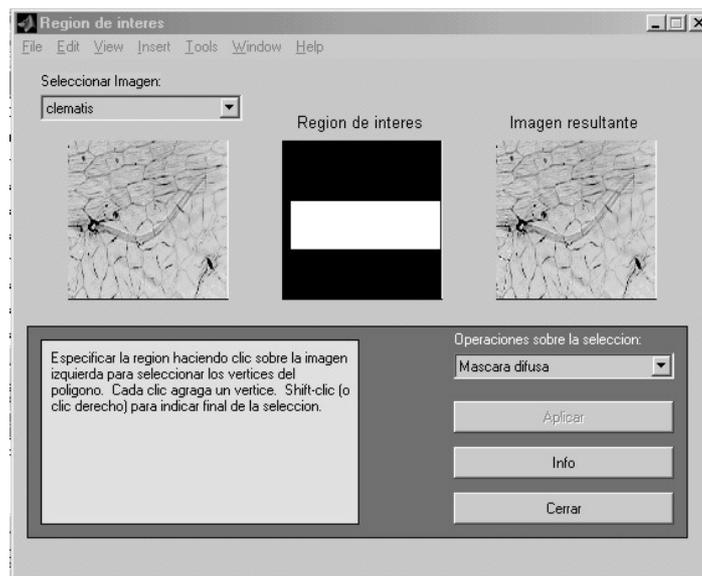


Figura 4. Interface para el módulo de selección de áreas de interés en el archivo de trabajo

### 2.3 Extracción de características

Esta fase se compone de una secuencia de operaciones sobre la matriz de imagen, con el objeto de medir las características de los objetos. Luego, estos valores son ingresados a la red neuronal. Entre las mediciones efectuadas:

- porcentaje de los tonos de gris más frecuentes;
- número de píxeles límite en las áreas grises
- número de píxeles límite entre las áreas grises y blancas
- número de áreas blancas
- número de píxeles de las áreas blancas

A partir de los resultados, se seleccionaron las características a tener en cuenta a efectos de la clasificación:

- Forma de la célula
- Presencia de pelos
- Forma de los pelos
- Forma de los estomas

## 2.4 Red neuronal

Las redes neuronales están compuestas por elementos simples o unidades de procesamiento que operan en paralelo. Estos elementos están inspirados por el sistema nervioso biológico (Hilera y Martínez, 1995). Como en la naturaleza, el funcionamiento de la red está determinado por las conexiones entre los elementos.

Se puede entrenar una red neuronal para que realice una tarea en especial mediante el ajuste de valores de las conexiones (pesos) entre los elementos. Generalmente las redes neuronales son ajustadas o entrenadas, de manera que una entrada específica lleve a una salida objetivo particular. Ver Figura 5. Aquí, se ajusta la red basándose en la comparación de la salida y el objetivo hasta que la salida de la red coincida con el objetivo. Se necesitan varios pares entrada/objetivo para entrenar una red.

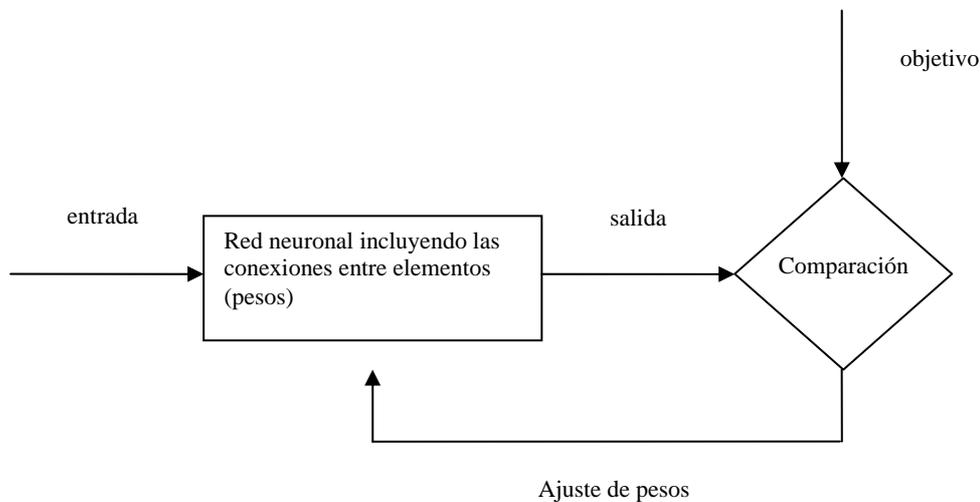


Figura 5. Operación de una red neuronal

Cada elemento de procesamiento tiene varias entradas pero una sola salida que puede aplicarse a muchas otras unidades de la red. Cada conexión tiene asociada una magnitud llamada peso o intensidad de conexión, que es comparable a la intensidad de las conexiones sinápticas de las neuronas. Las entradas que llegan a un elemento de procesamiento están desglosadas en varios tipos. Esto refleja el hecho de que cada conexión de entrada puede tener un efecto excitatorio o inhibitorio (pesos positivos o negativos). Cada unidad de procesamiento determina un valor de entrada neto basándose en todas las conexiones de entrada; lo típico es calcular el valor de entrada neto sumando los valores de entrada multiplicados por sus pesos correspondientes. Una vez calculada la entrada neta, se transforma en el valor de activación (o activación simplemente) para esa neurona. Una vez calculada la activación, puede determinarse el valor de salida, aplicando una función de salida. (Figura 6)

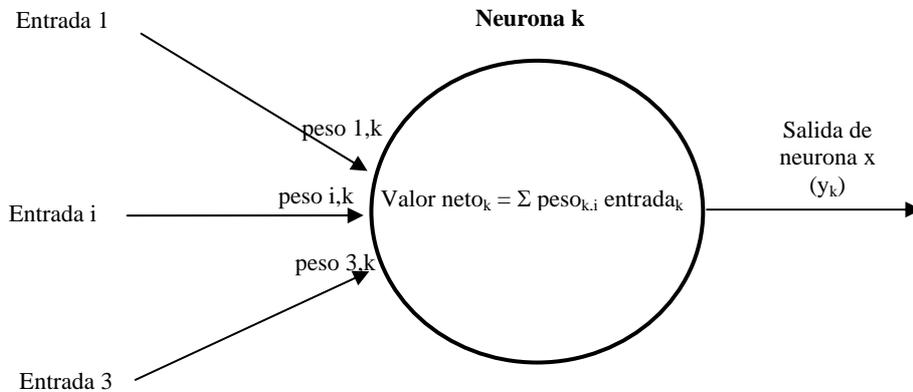


Figura 6. Diagrama de una neurona o elemento de procesamiento.

Debe tenerse en cuenta que una red neuronal es un **sistema dinámico**, es decir, un sistema que evoluciona a lo largo del tiempo. Para poder describir redes de este tipo, se escriben ecuaciones diferenciales que describan el ritmo de cambio temporal de las salidas de los distintos elementos de procesamiento. Dado que la ponderación de entradas y pesos depende de las salidas de muchas otras unidades, lo que se tiene realmente es un sistema de ecuaciones diferenciales acopladas.

Si se trabaja bajo el supuesto que el aprendizaje es un resultado de la modificación de la fuerza de las uniones sinápticas de las neuronas (es decir que los datos memorizados están más relacionados con los valores sinápticos de las conexiones entre neuronas, que con ellas mismas), se puede escribir un sistema de ecuaciones diferenciales para los pesos donde la derivación de los pesos respecto del tiempo resulte en una función que representaría la **ley de aprendizaje**. El proceso de aprendizaje consiste en hallar los pesos que codifican ese conocimiento que se desea que aprenda el sistema.

La arquitectura de una red describe la cantidad de capas que la componen, el patrón de conexiones entre las neuronas, el método o algoritmo de aprendizaje que utilizará para determinar los pesos de sus conexiones, y la función de activación que transformará el estado actual de cada neurona en una señal de salida (Rich y Knight, 1994). La elección de la mejor arquitectura depende del tipo de problema a ser representado por la red.

Para este problema se eligió una red del tipo backpropagation, de tres capas (de entrada – oculta – de salida). Fue decisiva para esta elección, su capacidad de aprender la asociación de patrones de entrada de la red (ejemplos) con las clases correspondientes propagando el error hacia atrás, es decir, su capacidad de auto-adaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones dados como ejemplo y sus salidas correspondientes. Esto posibilita que, después del entrenamiento, se reconozcan nuevos vectores de entrada con ruido o incompletos, dando una salida activa si la nueva entrada es parecida a las presentadas durante el aprendizaje. Esta importante característica, que se exige a los sistemas de aprendizaje (Hilera y Martínez, 1995), es la capacidad de generalización, entendida como la facilidad

de dar salidas satisfactorias a entradas que el sistema no ha visto nunca durante su fase de entrenamiento.

A la neurona ingresa un vector  $p$  de  $R$  elementos  $p_1, p_2, p_R$  que se multiplican por los pesos  $w_{1,1}; w_{1,2}; \dots; w_{1,R}$ .

Los valores incluyendo los pesos son suministrados a la suma, que es el producto de la matriz  $W$  (de una sola fila) y el vector  $p$  ( $Wp$ )

La neurona tiene un bias  $b$  que se adiciona a las entradas para formar  $n$ , el cual se usará como argumento de la función de activación  $f$ .

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b$$

La función de activación usada es denotada mediante  $f^N$  donde  $N$  indica la capa a la que corresponde. Sirve para calcular la salida de una capa a partir la entrada a la red. Es, en el caso de redes del tipo backpropagation, una función diferenciable (Freeman y Skapura, 1993). Pueden usarse diferentes funciones de activación para cada capa. Aquí se ha utilizado una función lineal en la primera capa y una función log-sigmoidea en la capa de salida. Esta función retorna el argumento como un valor restringido al intervalo (0;1)

La Figura 7 muestra la arquitectura de la red neuronal backpropagation implementada:

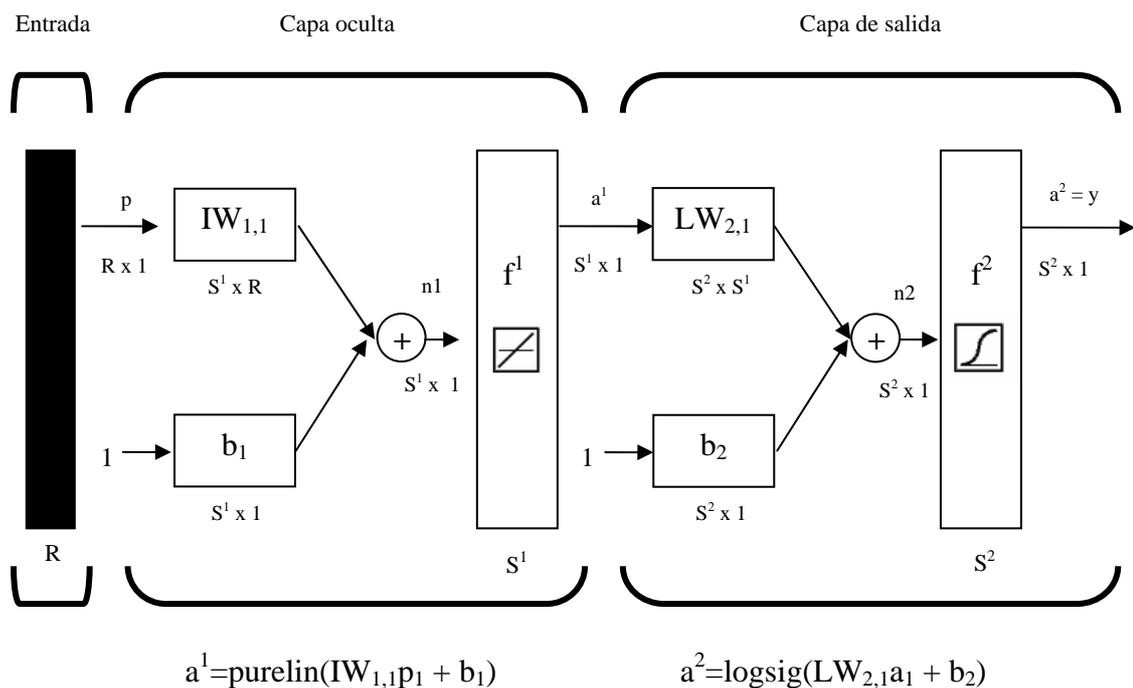


Figura 7. Arquitectura de la red neuronal implementada

Donde:

- $S^N$  indica la cantidad de neuronas de la capa  $N$ ,
- $f^N$  indica la función de activación usada para la capa  $N$ .

$$\blacksquare \text{ logsig}(n) = \frac{1}{1 + \exp(-n)}$$

- La salida de la capa 2 ( $a^2$ ) es la salida de interés, por tanto se iguala a  $y$ .

La capa de entrada contiene tantas neuronas como especies se desea reconocer ( $R$ ); la capa oculta tiene 10 neuronas y la capa de salida tiene la misma cantidad de neuronas que la cantidad de imágenes seleccionadas como representativas para cada especie, correspondientes a las salidas correctas.

Como ya se indicó anteriormente, cada imagen es representada mediante una matriz de  $288 \times 352$  elementos, cada una de estas matrices se convierte en un vector de entrada.

Los vectores objetivo se definen con  $R$  elementos, asignándose un 1 en la posición de la especie que representa y 0 en todas las demás posiciones.

Para operar correctamente, la red debe responder con un 1 en la posición de la especie que se le está presentando y 0 en todas las demás posiciones.

Además, la red debe ser capaz de manejar imágenes con ruido. En la práctica, la red no recibe como entrada un vector booleano perfecto, y debe cometer la menor cantidad de errores posibles al clasificar vectores con ruido de media 0 y desvío standard menor o igual a 0.2.

Se entrena a la red para obtener un 1 en la posición correcta del vector de salida y 0 en las demás posiciones. Sin embargo, las entradas con ruido podrían resultar en que la red no creara solamente 1s y 0s. Luego que la red es entrenada, se pasa la salida a una función de transferencia competitiva, para asegurarse que la salida correspondiente a la especie más parecida tome el valor 1 con 0 en las posiciones restantes. El resultado de este post-procesamiento es la salida efectivamente usada.

Para que la red pueda manejar vectores de entrada que tengan ruido, es mejor realizar el entrenamiento con vectores tanto ideales como con ruido. La red entonces, es entrenada primero con vectores ideales (imágenes limpias) hasta que la suma de los errores cuadrados sea pequeña. Luego, la red es entrenada usando conjuntos de vectores ideales y con ruido. Se usan vectores ideales para que la red mantenga la capacidad de reconocer vectores de entrada ideales.

Lamentablemente, luego que se haya realizado el entrenamiento descrito, la red puede haber aprendido a clasificar vectores “difíciles” y con ruido al costo de “olvidar” la clasificación de vectores sin ruido. Por esta razón, nuevamente se entrena a la red con sólo vectores ideales.

Todo el entrenamiento se realiza de manera no asistida, tiempos adaptativos (los valores de los pesos y bias se actualizan en la dirección del gradiente negativo de la función de performance) y momento, ya que éste último permite que la red responda no sólo al gradiente local sino también a tendencias recientes en la superficie de error; al actuar como un filtro, permite que la red ignore valores pequeños en la superficie de error. Sin usar momento la red podría quedar estancada en un mínimo local.

Las Figuras 8 y 9 muestran la cantidad de ciclos necesarios (epochs) hasta que la red reconoce las células correspondientes a cada especie. El entrenamiento se realiza hasta se alcance el número máximo de ciclos o la suma de los errores cuadrados sea menor a 0,1; la curva descendente indica que la red ha comenzado a aprender y puede darse por terminada la fase de entrenamiento.

```
[net,tr] = train(net,P,T);
TRAINIDX, Epoch 0/5000, SSE 168.447/0.1, Gradient 46.0382/1e-006
TRAINIDX, Epoch 20/5000, SSE 25.7528/0.1, Gradient 1.9299/1e-006
TRAINIDX, Epoch 40/5000, SSE 25.2952/0.1, Gradient 0.415125/1e-006
TRAINIDX, Epoch 60/5000, SSE 25.5128/0.1, Gradient 0.3371/1e-006
TRAINIDX, Epoch 80/5000, SSE 25.5261/0.1, Gradient 0.339056/1e-006
TRAINIDX, Epoch 100/5000, SSE 25.4204/0.1, Gradient 0.407/1e-006
TRAINIDX, Epoch 120/5000, SSE 24.8589/0.1, Gradient 0.594/1e-006
TRAINIDX, Epoch 140/5000, SSE 23.0034/0.1, Gradient 0.723414/1e-006
TRAINIDX, Epoch 160/5000, SSE 14.4322/0.1, Gradient 1.29897/1e-006
TRAINIDX, Epoch 180/5000, SSE 1.62053/0.1, Gradient 0.482638/1e-006
TRAINIDX, Epoch 199/5000, SSE 0.0903872/0.1, Gradient 0.0562929/1e-006
TRAINIDX, Performance goal met.
```

Figura 8. Ciclos realizados durante el entrenamiento

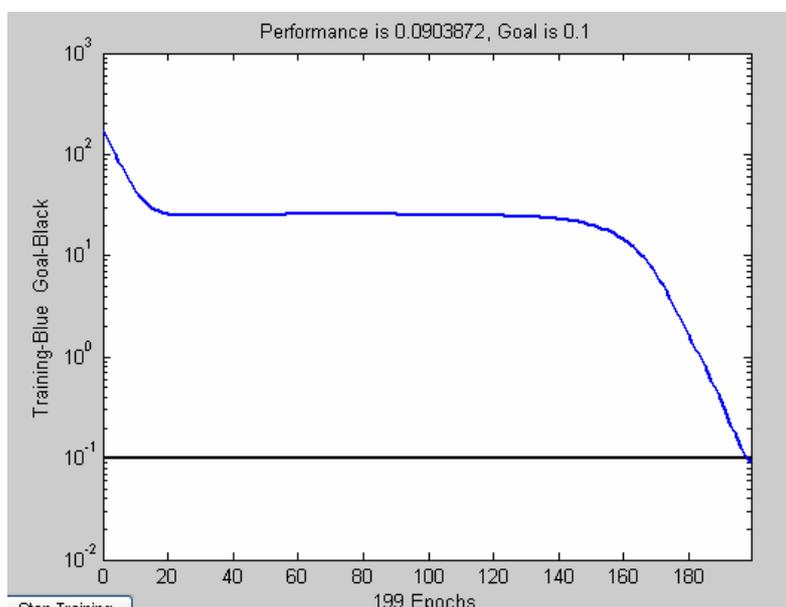


Figura 9. Convergencia del aprendizaje al valor establecido como objetivo.

Para obtener una red no sensible al ruido (imágenes defectuosas o poco claras), se entrena a la red usando copias de vectores ideales y copias de imágenes no ideales, que tienen ruido con mediana 0.1 y 0.2. Con esto se obliga a la red a identificar apropiadamente imágenes aún cuando contengan defectos sin olvidar los vectores ideales.

El número máximo de ciclos se reduce a 300 pero se incrementa el valor de error permitido a 0.6, reflejando que se espera mayor error al presentársele mayor cantidad de vectores.

### 3 PERFOMANCE DEL SISTEMA

La confiabilidad del sistema de reconocimiento de patrones con la red neuronal se midió probándola con 50 vectores de entrada con cantidades variable de ruido. En la [Figura 10](#) se observa el porcentaje de errores de la red versus ruido. Se agrega a los vectores de entrada

ruido con mediana 0 y desvío standard entre 0 y 0.5. A cada nivel de ruido, se realizan 50 presentaciones de diferentes versiones de cada tipo de célula conteniendo ruido y se calcula la salida de red. Luego se pasa la salida a través de una función competitiva de manera que sólo uno de los resultados presente un 1.

Se suman las cantidades de clasificaciones erróneas y se obtienen los porcentajes.

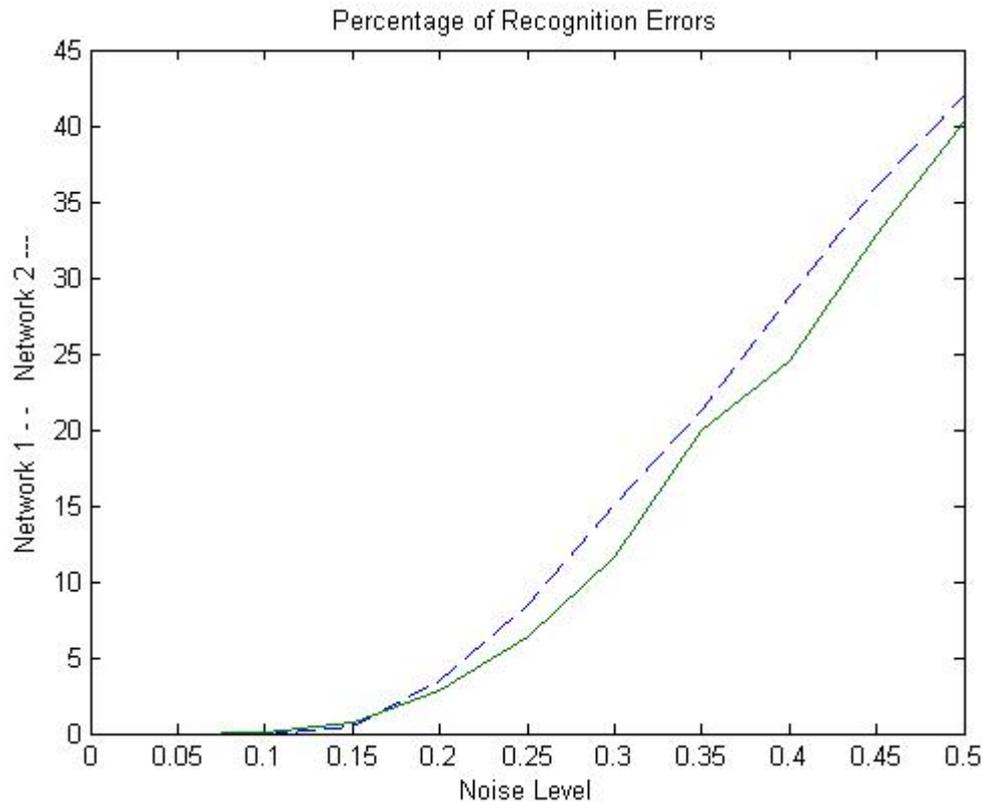


Figura 10. Comparación de entrenamientos con y sin ruido.

La línea plena del gráfico muestra la confiabilidad de la red entrenada con y sin ruido. Con línea discontinua se muestra la confiabilidad de la misma red cuando fue entrenada solamente con imágenes sin ruido. Puede observarse que el entrenamiento realizado con vectores con ruido reduce los errores en gran proporción al momento de clasificar imágenes defectuosas.

La red no comete errores con ruido de mediana 0.00 o 0.05. Al agregarse ruido de mediana 0.2 ambas redes comenzaron a producir clasificaciones incorrectas.

## REFERENCIAS

- J. Bajon, M. Cattoen y L. Liang. Identification of multicolored objects using a vision module. In: *Proc. 6th International Conference of Robot Vision and Sensory Control*, Paris, France, 10:21-30, 1988.
- R. Barker. A technique to simplify herbivore diet analysis. *Aust. Wildl.* 13:569-573, 1986.
- K. Castleman. *Digital image processing*. Prentice Hall, 1996.

- A. Catán; C. A. M. Degano y L. Larcher. Modificaciones a la técnica microhistológica de Peña Neira para especies forrajeras del Chaco Semiárido Argentino. *Quebracho*, 10: 71-75, 2003.
- R. González y R. E. Woods. *Digital image processing*. Prentice Hall, 2002.
- C. Degano, L. Larcher, R. Renolfi y R. Martiarena. A database to help in the determination of species that conform the diet of herbivorous, when microhistology is used. *Pakistan Journal of Botany*, 31(2): 295-300, 1998.
- J. A. Freeman y D. M. Skapura. *Redes neuronales. Algoritmos, aplicaciones y técnicas de programación*. Addison-Wesley Iberoamericana, 1993.
- K. Havstad, y G. Donart. The microhistological technique: testing two central assumptions in South-Central New Mexico, *Journal of Range Management*, 31(6): 469-470, 1978.
- J. Hilera y V. Martínez. *Redes neuronales artificiales. Fundamentos, modelos y aplicaciones*. Addison-Wesley Iberoamericana, 1995.
- J. Holecheck y B. Gross. Training needed for quantifying simulated diets from fragmented range plants, *Journal of Range Management*, 35(5): 644-647, 1982
- B. Jähne. *Digital image processing*. Springer, 2005.
- J. Lim. *Two-Dimensional Signal and Image Processing*. Prentice Hall, 536-540, 1990.
- R. Marmo, S. Amodio, R. Tagliaferri, V. Ferreri y G. Longo. Textural identification of carbonate rocks by image processing and neural network: Methodology proposal and examples. *Computers & Geosciences* 31: 649-659, 2005
- M. Mellado, M. Foote, A. Rodríguez y P. Zárate. Botanical composition and nutrient content of diet selected by goats grazing on desert grassland in northern Mexico. *Small Ruminant Research*, 6: 141-150, 1991.
- G. Norbury. Microscopic analysis of herbivore diets - a problem and a solution. *Aust. Wildl.*, 15: 51-57, 1998.
- A. Pelliza de Sbriller. Acerca de la microhistología. Comunicación Técnica N° 32, *Recursos Naturales, Dieta, INTA*, Argentina, 1993
- P. E. H. Petersen y G. W. Krutz. Automatic identification of weed seeds by color machine vision. *Seed Science and Technology*. 20: 193-208, 1992.
- E. Rich y K. Knight. *Inteligencia Artificial* (2da. Edición), McGraw Hill, 1994.
- A. Salinas y G. Dellepiane. Situación del Sector Caprino Nacional. *Ministerio de Economía y Obras y Servicios Públicos, Secretaría de Agricultura Ganadería y Pesca*, Argentina, 1994.
- R. J. Schalkoff. *Digital image processing and computer vision*. John Willey & Sons, 1989.
- R. Sève. *Physique de la Couleur*. Mason, Paris, pp 334, 1996.
- D. Sparks y J. Malechek. Estimating percentage dry weight in diets using microscopic technique. *Journal of Range Management*, 21(4): 264-265, 1968.
- M. Westoby; G. Rost y J. Weis. Problems with estimating herbivore diets by microscopically identifying plant fragments from stomachs, *J. Mammals* 57: 167-172, 1976.