

2. INTRODUCCIÓN A LAS REDES NEURONALES

Las redes neuronales artificiales son modelos matemáticos simplificados del funcionamiento del sistema nervioso. Con ello, se busca un sistema que en situaciones reales, con sus imprecisiones e incertidumbres, sea capaz de resolver problemas de manera robusta y eficaz.

En el sistema nervioso la unidad de proceso es la neurona. Una neurona es una célula con unas características que la diferencia de los demás tipos de células existentes en los seres vivos. Está formada por un cuerpo donde se encuentra el núcleo, por un axón y por dendritas.

Las neuronas tienen la habilidad especial de comunicarse entre sí. En dicha comunicación, una neurona es estimulada por una o más señales en las dendritas y el cuerpo de la neurona genera una señal de salida que es enviada a otras neuronas a través del axón. La salida depende de cada una de las señales de entrada y de las características de las conexiones de entrada. Esta conexión entre neuronas se llama sinapsis. Algunas sinapsis tenderán a excitar la neurona cuando haya una señal presente y otras serán de carácter inhibitorio que reducirán la salida de la neurona.

Se estima que existen del orden de 10^{15} sinapsis en el cerebro humano con aproximadamente 1000 sinapsis a la entrada y salida de cada neurona. La relación real entre entradas y salidas puede ser extraordinariamente compleja, sin embargo, las redes neuronales artificiales pueden dar excelentes resultados para casos prácticos con modelos simples.

Las redes neuronales artificiales, al igual que el cerebro, aprenden de la experiencia y son capaces de generalizar los casos aprendidos anteriormente a casos nuevos. Las redes neuronales presentan numerosas ventajas de las que podemos destacar:

2. INTRODUCCIÓN A LAS REDES NEURONALES

- *Aprendizaje adaptativo:* esto es la capacidad de aprender a realizar una tarea tras un entrenamiento con un conjunto de ejemplos.
- *Autoorganización:* Las redes neuronales son capaces de organizarse a sí mismas y la información que reciben durante el proceso de entrenamiento.
- *No linealidad:* tanto una neurona como el conjunto de ellas son no lineales y en la mayoría de los casos los datos presentados a la red neuronal también serán de carácter no lineal.
- *Robustez:* una red neuronal es capaz de dar algunos resultados aún cuando una parte de dicha red ha sido destruido parcialmente. Las redes neuronales también pueden ser tolerante a fallos en los datos si estos presentan ruido, si están distorsionados o si están incompletas.
- *Operación en tiempo real:* los cálculos en las redes neuronales se pueden llevar a cabo en paralelo acelerando significativamente la velocidad del procesado de la información.

2.1. MODELO DE UNA NEURONA ARTIFICIAL

La neurona artificial o nodo es la unidad de proceso de una red neuronal y simula el funcionamiento de una neurona biológica. El modelo de la neurona artificial se muestra en la Figura 2.1.




Figura 2.1: Modelo de una neurona artificial.

La neurona tiene n entradas numeradas de 0 a $n-1$. La neurona multiplica las entradas por n pesos y los suma. Al resultado de este sumatorio se aplica la función de activación $f(v)$ para obtener la salida de la neurona. Esta función normalmente no está centrada en el origen sino que está desplazado y este desplazamiento es distinto para cada neurona. Para simplificar el modelo se considera una entrada adicional n denominada *bias* de valor la unidad.

Esto se puede expresar matemáticamente para una neurona j con la siguiente ecuación:

$$y_j = f(red) = \left(\sum_{i=0}^{n-1} x_i w_{ji} + w_n \right) \quad Ec.(2.1)$$

Donde x_i con $i = 0, 1, \dots, n-1$ son las entradas a la neurona j

y_j es la salida de la neurona

w_{ji} son los n pesos de la neurona j

$f(red)$ es la función de activación

Una neurona está caracterizada por los pesos y por la función de activación. El valor de los pesos se establece durante el entrenamiento de la red. La función de activación se define a priori y las funciones más comunes se mostrarán a continuación.

2.1.1. Tipos de funciones de activación

Las funciones de activación típicas de una neurona son las siguientes:

Función escalón:

Si el conjunto de los estados de activación es $E=\{0,1\}$, tenemos que:

$$f(z) = \begin{cases} 1 & z \geq 0 \\ 0 & z < 0 \end{cases} \quad \text{Ec.(2.2)}$$




Figura 2.2: Función escalón.

2. INTRODUCCIÓN A LAS REDES NEURONALES

Si el conjunto de los estados de activación es $E=\{-1,1\}$, tenemos que:

$$f(z) = \begin{cases} +1 & z \geq 0 \\ -1 & z < 0 \end{cases} \quad \text{Ec.(2.3)}$$




Figura 2.3: Función escalón centrado en cero.

Con $z = \sum_{i=0}^{n-1} x_i w_i$

Esta función sólo se aplica cuando las salidas de la red son binarias.

Función lineal y mixta:

En la función lineal la salida es igual a la entrada total de la neurona:

$$f(z) = z \quad \text{Ec.(2.4)}$$




Figura 2.4: Función lineal.

La función lineal es como si no se aplicara función de activación alguna y es utilizado en raras ocasiones.

La función mixta es una función lineal con límites inferior b y superior B :

$$f(z) = \begin{cases} b & z \leq -B \\ z & -b < z < B \\ B & z \geq B \end{cases} \quad \text{Ec.(2.5)}$$




Figura 2.5: Función mixta.

2. INTRODUCCIÓN A LAS REDES NEURONALES

Función sigmoïdal:

La función sigmoïdal es una función cuya derivada es continua y positiva, lo cual es una ventaja en algoritmos de aprendizaje que usan derivadas.

La función sigmoïdal más empleada es la función logística cuya derivada se halla de forma muy simple:

$$f(z) = \frac{1}{1 + e^{-z}} \quad \text{Ec.(2.6)}$$

$$f'(z) = f(z)(1 - f(z)) \quad \text{Ec.(2.7)}$$




Figura 2.6: Función sigmoïdal.

Otras funciones sigmoïdales como la tangente hiperbólica son usadas a veces:

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad \text{Ec.(2.8)}$$

2.2. ARQUITECTURAS DE UNA RED NEURONAL

La arquitectura de una red neuronal es la organización y disposición de las neuronas en la red. La distribución de las neuronas dentro de la red se realiza formando capas o niveles de un número establecido de neuronas en cada una de las capas. En una red neuronal se pueden distinguir hasta tres tipos de capas:

- *Capa de entrada:* esta capa es la que recibe la información de entrada a la red. Esta capa no realiza ningún tratamiento de la información.
- *Capas ocultas:* son capas localizadas entre la capa de entrada y la de salida. Las entradas de las neuronas de estas capas provienen de las salidas de otras y sus salidas pasarán a ser las entradas de otras neuronas. El número de capas ocultas puede ser desde varias capas a ninguno.
- *Capa de salida:* esta capa es la última cuyas salidas es el resultado final de toda la red.

La organización de las neuronas o conectividad es la forma que están comunicadas dichas neuronas, esto es, la manera en que la salida de una neurona pasa a ser entrada de otras neuronas o entrada de sí misma. Existen tres tipos de conexiones:

- *Conexiones hacia delante:* aquí las salidas de una capa pasarán a ser las entradas de la siguiente capa de nivel superior.
- *Conexiones laterales:* en este tipo de conexiones las salidas de una capa son entradas de neuronas de la misma capa.

- *Conexiones hacia atrás:* las salidas de un nivel son entradas de neuronas de un nivel previo.

En los siguientes apartados se describirán los distintos tipos de arquitecturas de redes neuronales.

2.2.1. Redes monocapa

Estas redes están formadas por una capa de entrada y una capa de salida. Se consideran monocapa debido a que la capa de entrada no realiza ningún tratamiento de la información, son los datos de entrada directamente, por lo que sólo una capa (la de salida) es la encargada de realizar los cálculos para obtener los resultados de la red neuronal.

En estas redes se pueden establecer conexiones entre neuronas de la única capa existente con conexiones laterales. Un ejemplo de este tipo de red es la red de Hopfield. También se puede permitir que las neuronas tengan conexiones a sí mismas llamados autorrecurrentes.

En la Figura 2.7 se muestra un ejemplo de una red monocapa con tres entradas y tres neuronas de salida y con conexiones hacia delante.




Figura 2.7: Ejemplo de red monocapa.

2.2.2. Redes multicapa

Estas redes están formadas por una capa de entrada, una de salida y una o varias capas ocultas. Según el tipo de conexiones que dispone la red neuronal podemos distinguir dos tipos de redes multicapa:

Redes con conexiones hacia adelante (feedforward):

En estas redes la información atraviesa la red desde la entrada hacia la salida sin ninguna conexión hacia atrás, esto es, las neuronas de una capa sólo están conectadas con otras de un nivel superior. Normalmente en estas redes no existen conexiones laterales.

Las redes monocapa más comunes son: el Perceptrón, Adaline, Madaline, el Backpropagation y los propuestos por Kohonen llamados LVQ y TPM.

En la siguiente figura se muestra como ejemplo una red multicapa feedforward de tres capas con tres neuronas de entrada, tres en la capa oculta y dos en la capa de salida:




Figura 2.8: Ejemplo de red multicapa feedforward.

Redes con conexiones hacia adelante y hacia atrás (feedforward/feedback):

A diferencia de las redes anteriores, estas redes neuronales sí permiten que la información vaya desde neuronas de una capa hacia neuronas de una capa anterior, por tanto existen conexiones tanto de tipo hacia adelante como hacia detrás. También existen en este grupo de redes las que presentan conexiones laterales.

Entre las redes *feedforward/feedback* se encuentran la máquina de Cauchy, la máquina de Boltzmann, BAM entre otras.

2.3. MÉTODOS DE APRENDIZAJE DE UNA RED NEURONAL

Para que una red neuronal pueda realizar una tarea determinada, primero hay que enseñar a la red cómo hacerlo mostrando a dicha red distintas muestras o patrones de entrenamiento. Durante el aprendizaje se van creando, destruyendo y modificando conexiones entre las neuronas. Una conexión es creada cuando su valor cambia de cero y es destruido cuando pasa a valer cero. Se considera que la red ha aprendido cuando los valores de los pesos permanecen estables.

La forma o el criterio por el que se cambian los valores de los pesos de las neuronas se llama regla de aprendizaje. Se consideran dos tipos de reglas de aprendizaje: aprendizaje supervisado y aprendizaje no supervisado.

2.3.1. Aprendizaje supervisado

En este tipo de aprendizaje es un supervisor o un maestro el que controla todo el proceso de aprendizaje. Generalmente este supervisor indica la respuesta que debería de

2. INTRODUCCIÓN A LAS REDES NEURONALES

dar la red neuronal ante una determinada entrada. Si la respuesta de la red no coincide con la deseada dentro de un margen de error se pasa a modificar los pesos de la red y así hasta que se alcanza el resultado deseado.

Existen tres tipos de aprendizajes supervisados: por corrección de error, por refuerzo y estocástico.

2.3.1.1. Aprendizaje por corrección de error

En el aprendizaje por error se modifican los pesos según el error cometido a la salida de la red que es la diferencia entre la salida deseada y el resultado dado por dicha red. Este proceso se repite de manera iterativa hasta que los resultados son satisfactorios.

Un ejemplo simple de regla de aprendizaje podría ser:

$$\Delta w_{ji} = \alpha y_i (d_j - y_j) \quad \text{Ec. (2.9)}$$

Siendo: Δw_{ji} la variación en el peso de la conexión entre la neurona i y j .

y_i la salida de la neurona i .

d_j la salida deseada en la neurona j .

y_j la salida de la neurona j .

α el factor de aprendizaje ($0 < \alpha < 1$) que regula la velocidad de aprendizaje.

De esta forma, los nuevos pesos serían:

$$w_{ji}^{\text{actual}} = w_{ji}^{\text{anterior}} + \Delta w_{ji}$$




Figura 2.9: Conexión entre la capa i y la capa j.

2.3.1.2. Aprendizaje por refuerzo

En esta forma de entrenamiento el supervisor indica a la red si la respuesta es la deseada o no a través de una señal de refuerzo en vez de indicar la respuesta deseada directamente. En función de esta señal se modifican los pesos según un mecanismo de probabilidades. Se puede decir que la red tenderá a reproducir los casos satisfactorios.

2.3.1.3. Aprendizaje estocástico

Los pesos de la red neuronal en este tipo de aprendizaje se modifican de manera aleatoria y se comparan los resultados obtenidos antes y después del cambio. Si la respuesta se acerca más a la respuesta deseada se acepta el cambio y en caso contrario se aceptaría en función de una determinada distribución de probabilidades.

2.3.2. Aprendizaje no supervisado

Al contrario que en el caso del aprendizaje supervisado, aquí no tenemos la presencia de un supervisor para indicar si la respuesta obtenida por la red es la deseada o no. Estas redes buscan similitudes en los patrones de entrada presentados para así dar una misma respuesta a casos similares. Esto es, clasifica los patrones de entrada en distintas categorías con características parecidos.

La forma en que la red crea las distintas categorías y la forma en que luego clasificará los patrones de entrada dependerá del tipo de algoritmo de aprendizaje empleado. Se suele considerar dos tipos de aprendizajes no supervisados: hebbiano y el competitivo.

2.3.2.1. Aprendizaje Hebbiano

La teoría hebbiana fue postulado por Donald O. Hebb en 1949 y es una teoría que describe cómo se podrían conectar las neuronas biológicas entre sí. Este postulado fue escrito como se indica a continuación:

Cuando un axón de una celda A está suficientemente cerca como para conseguir excitar una celda B y repetida o persistentemente toma parte en su activación, algún proceso de crecimiento o cambio metabólico tiene lugar en una o ambas celdas, de tal forma que la eficiencia de A, cuando la celda a activar es B, aumenta.

Esto se puede traducir para nuestra red neuronal como: el peso de la conexión entre dos neuronas es aumentada o reforzada si esas dos neuronas se activan simultáneamente, en caso contrario esa conexión es debilitada o eliminada.

2. INTRODUCCIÓN A LAS REDES NEURONALES

Por ejemplo, si las salidas de las neuronas son binarias pueden tomar los valores +1 y -1 el cambio que se produce en el peso de la conexión se puede expresar como:

$$\Delta w_{ij} = y_i y_j \quad \text{Ec.(2.10)}$$

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} \quad \text{Ec.(2.11)}$$




Figura 2.10: Conexión entre neurona *i* y neurona *j*.

2.3.2.2. Aprendizaje competitivo y cooperativo

En este aprendizaje las neuronas compiten entre sí para ser la única en una capa o de un grupo de neuronas en activarse. En estas redes pueden existir conexiones autorrecurrentes para que las neuronas se autoexciten y también conexiones laterales para inhibir las neuronas vecinas o, en caso que la red sea cooperativa, para excitarlas.

El resultado que se obtiene con este tipo de redes es la clasificación de los patrones de entrada. Las entradas que sean similares activarán la misma neurona de salida.

2.4. REPRESENTACIÓN DE LA INFORMACIÓN

Las redes neuronales se pueden clasificar (además de por su topología o método de aprendizaje) por la forma de representar la información tanto de entrada como de salida. De esta clasificación se obtiene las siguientes redes:

- *Redes continuas*: en estas redes tanto las entradas como las salidas son continuas y normalmente estarán normalizadas.
- *Redes discretas*: en este caso las entradas y salidas son de carácter discreto o binario.
- *Redes híbridas*: aquí la información de entrada puede tomar valores continuos mientras que las salidas tomará valores discretos.