

Redes Neuronales, Bioinspiración para el Desarrollo de la Ingeniería

Neural Networks, Bioinspiration for Engineering Development

José Noguera*

Nayades Portillo**

Luis Hernandez***

RESUMEN

El presente documento está orientado a la comprensión de las redes neuronales, basadas éstas en técnicas que imitan el funcionamiento biológico de una neurona con la finalidad de brindar una solución a problemáticas en el área de ingeniería.

La Biomimesis, como se le puede llamar también a las técnicas bio-inspiradas, usa el entendimiento o raciocinio científico de sistemas biológicos para explotar ideas de la naturaleza con la finalidad del desarrollo de tecnología. Se presenta al respecto un ejemplo de Biomimesis del funcionamiento operativo de la neurona para el desarrollo de un algoritmo a implementar en el control de una máquina selectora de frutas, de tal forma que, conociendo esta aplicación, el lector pueda extender las capacidades del uso de las redes neuronales para implementar niveles sofisticados de automatización.

Palabras Claves: Redes Neuronales; Biomimesis; Técnicas evolutivas; Algoritmo Evolutivo; Bioinspiración.

ABSTRACT

This paper is oriented to neural networks comprehension, which are based in techniques that take into account the biologic function of a neuron to bring a solution for engineering problems.

The Biomimicry, the way bio-inspired techniques may be named, uses the scientific understanding or rationale of biological systems to exploit nature's ideas so that technology be able to evolve. The operative way a neuron works is shown as an instance of Biomimicry, in order to develop an algorithm for controlling a fruit selector machine so, knowing this particular use, readers could extend the applicability of neural networks to implement more complex levels of automation.

Key Words: Neural Networks; Biomimicry; Evolutionary techniques; Evolutionary Algorithm; Bioinspiration.

* *Ingeniero Electrónico. Profesor Investigador Universidad Cooperativa de Colombia, Santa Marta. Correo electrónico: Jose.noguerap@campusucc.edu.co*

** *Ingeniero de Sistemas. Decana Ingeniería Universidad Cooperativa de Colombia, Santa Marta. Correo electrónico: nayades.portillo@ucc.edu.co. Grupo de Investigación: Sistemas Electrónicos y Energías Renovables, SEER. Facultad de Ingeniería, Universidad Cooperativa de Colombia, Sede Santa Marta.*

*** *Ingeniero de Sistemas. Director Centro de Investigaciones Universidad Cooperativa de Colombia, Santa Marta.*

Correo electrónico: luis.hernandez@ucc.edu.co

Fecha de recepción: 22 de Julio del 2014 • Fecha de aceptación: 01 de Septiembre del 2014

1. INTRODUCCIÓN

El área de las redes neuronales va de la mano con la inteligencia artificial, el control inteligente, la Biomimesis, entre otros temas y ello ofrece un campo de trabajo novedoso, donde las aplicaciones y mejoras a sistemas avanzan a pasos cada vez más rápidos.

El uso de técnicas evolutivas representa, en la actualidad, una forma de optimizar un proceso y dado que los sistemas biológicos presentan un punto óptimo de funcionamiento, surge entonces el concepto de bio-inspiración [1]. Las técnicas evolutivas se encuentran llenando muchas aplicaciones actualmente; así, se puede encontrar que en artículos como [2] se busca incentivar a jóvenes estudiantes de ingeniería a utilizar el concepto de bio-inspiración para lograr diseños óptimos, aplicables a proyectos de ingeniería. En este artículo, los autores presentan un repositorio de sistemas biológicos con información relevante para el diseño de sistemas bio-inspirados. En [3], los autores exponen los objetivos, retos e ideas de la ingeniería bio-inspirada con base en los sistemas biológicos que usan bio-sonar como lo son los murciélagos. Las aplicaciones en este campo son variadas; sonar, ultrasonido biomédico, pruebas no destructivas, sensores para sistemas autónomos y comunicaciones inalámbricas, entre otros. Los autores en [4] se basan en estudios estructurales y experimentales de más de 300 especies de insectos de diferentes linajes para desarrollar un material polímero bio-inspirado, con la habilidad de múltiple pegado y despegado. También es posible el diseño de un simulador dinámico para pequeños robots manipuladores, tomando como base el mecanismo de succión de los cefalópodos para su aplicación en el agarre de objetos, como muestran los autores en [5]. En el artículo [6], los autores proponen el diseño de un sistema de control de temperatura en múltiples zonas, lo cual es un problema de control distribuido, por lo que los autores hacen uso de la teoría del comportamiento ecológico (Foraging theory), la cual describe matemáticamente la búsqueda animal por nutrientes y la selección de cuales consumir.

Como se puede observar, los campos de aplicación de sistemas bio-inspirados pueden ser muy variados. La necesidad de encontrar una solución óptima a un problema lleva casi instantáneamente a pensar cómo la naturaleza ha solucionado problemas similares y tomar ejemplo de ello, por tanto el presente documento tiene como base principal este enfoque.

2. BIOINSPIRACIÓN

Existen muchos procesos biológicos que pueden ser representados como un proceso de optimización con un propósito básico, control automático, automatización y toma de decisiones. Por tanto, es preciso observar que, a través del tiempo, la vida ha evolucionado para funcionar de una manera eficiente y robusta, logrando prolongar su existencia en una variedad de formas. Algunos ejemplos de ello son: las moscas, que poseen un diseño único de alas con una distribución de masa que optimiza la eficiencia del musculo; las águilas, que pueden detallar objetos a gran distancia debido a la gran densidad de conos y bastones, en comparación con el ojo humano; los camaleones, los cuales imitan el color del entorno para camuflarse de los depredadores [2], entre muchos otros. Lo anterior permite entender que en la naturaleza hay una gran fuente de inspiración para la aplicación en problemas de ingeniería. Las técnicas evolutivas a emplear son variadas, dependiendo de factores como el propósito al cual está dirigida (control de posición,

encuentro de puntos óptimos, etc.) y el enfoque o inspiración natural tomada en cuenta (neuronas, bacterias, abejas, etc.).

Los métodos de la inspiración biológica pueden ser clasificados de acuerdo con las células, tejidos, órganos, organismos y jerarquía de poblaciones en la biología. Es posible extraer ideas de células u órganos (neuronas y funciones del ser humano), organismos (humanos que toman decisiones para solucionar un problema de control), o del comportamiento coordinado de un grupo de organismos (modelamiento de sistemas de control en vehículos autónomos con base en micro organismos que buscan nutrientes y evitan ambientes peligrosos). Además, existen adaptaciones evolutivas que suceden en sistemas biológicos y estas pueden ser útiles para mejorar el rendimiento de sistemas de control, a través de una interacción prolongada con su entorno [1]. Un ejemplo de bio-inspiración puede considerar entonces una neurona como se muestra en la Fig. 1 para producir un modelo sencillo, como se muestra en la Figura 2.

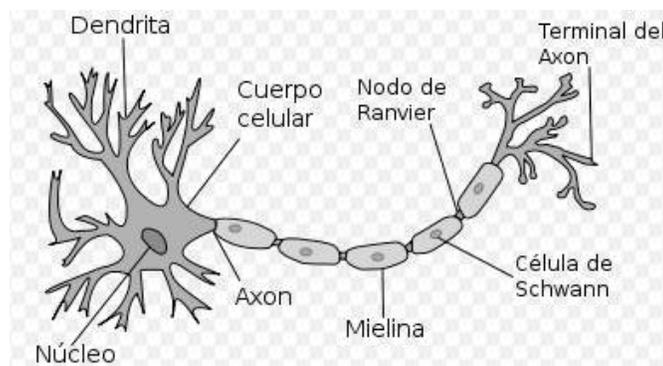


Figura 1. Neurona.

Fuente: Imagen tomada de [7].

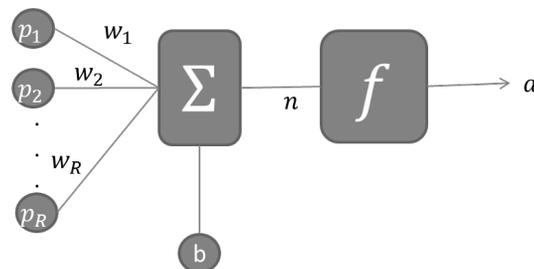


Figura 2. Modelo de una Neurona.

Fuente: Notación tomada de [8].

El modelo matemático sencillo de esta neurona [7], es el correspondiente a la ecuación (1):

$$a = f(WP + b) \quad (1)$$

Donde a corresponde a un vector fila con w_1, w_2, \dots, w_R y P corresponde a un vector columna con p_1, p_2, \dots, p_R para R entradas. Físicamente w corresponde a la fuerza que posee la sinapsis entre neuronas, es también el grado de importancia que posee una determinada señal de entrada a la neurona. El valor p corresponde a la señal que entra en las dendritas. El cuerpo de la neurona está representado por la sumatoria, la función de activación f y la salida a , que representa la

señal sobre el axón, el cual haría parte de la señal de entrada p , para otra neurona. Una cadena de neuronas de este estilo puede formar una red, que puede poseer un nivel de aprendizaje, variando los parámetros w y b para reconocer patrones, agrupar datos, etc. Básicamente, aquí se ve un modelo sencillo de una neurona. Con agrupaciones de neuronas y pequeñas variaciones sobre el modelo de red de neuronas, es posible desarrollar soluciones a diversas problemáticas.

Para tener una comprensión sobre los fundamentos que posee la Bio-mímesis, es preciso considerar entonces aspectos como los mencionados por los autores en [1] y organizarlos de la siguiente forma:

1. El Sistema Nervioso (redes neuronales, planificación, deducción)
2. Organismos (Sistemas difusos, basados en reglas)
3. Grupos de Organismos (comportamiento social, coordinación de actividades)
4. Evolución (efectos de los cambios genéticos)

1.1. Aprendizaje en una Neurona

El aprendizaje que se desarrolla en una neurona parte de la variación de los valores de los pesos y los bias, como se había mencionado anteriormente. Para tal caso es preciso tener claro cuales son los límites de decisión, tomando como base una neurona sencilla de dos entradas y función de transferencia limitador duro simétrico, como se muestra en la Figura 3. Existen diferentes tipos de funciones de activación como se evidencia en la literatura [8], pero para comprender el caso de aprendizaje es suficiente utilizar la función de limitador duro simétrico. Ésta función se define como:

$$\text{hardlims}(n) = a \quad \therefore \quad \begin{cases} a = -1 & \forall n < 0 \\ a = 1 & \forall n \geq 0 \end{cases} \quad (1)$$

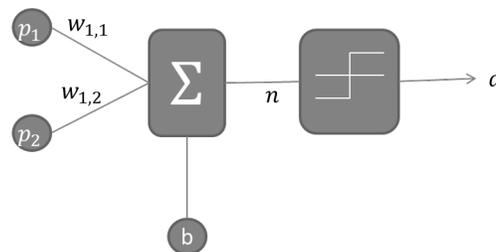


Figura 3. Neurona de dos entradas.

Fuente: Elaboración de los autores.

Se considera el caso de una red con dos entradas desconocidas p_1 y p_2 , con pesos y bias escogidos aleatoriamente $w_{1,1} = -1$, $w_{1,2} = 1$ y $b = -1$. Con estos datos es posible saber cual será la salida para cuales sean los valores de las entradas p_1 y p_2 . Siguiendo los pasos a continuación, se podrá ver, de forma gráfica, cómo se clasificará la salida de la neurona para los diversos valores de entrada p_1 y p_2 .

2.2. Pasos para determinar los límites de decisión

1. Se plantea la condición:

$$WP + b = 0 \quad (2)$$

2. Se remplazan los valores:

$$[-1 \ 1] \begin{bmatrix} p_1 \\ p_2 \end{bmatrix} - 1 = 0 \quad (3)$$

3. Se hace $p_2=0$:

$$[-1 \ 1] \begin{bmatrix} p_1 \\ 0 \end{bmatrix} - 1 = 0$$

4. Se ejecuta la operación:

$$-p_1 + 0 - 1 = 0$$

5. Se despeja p_1 :

$$p_1 = -1 \text{ (Este es el valor del punto en el eje } P_1 \text{)}$$

Se tiene entonces la primera coordenada (-1,0).

6. Ahora, retomando el paso 2, se hace $p_1 = 0$ en la ecuación (3);

$$[-1 \ 1] \begin{bmatrix} 0 \\ p_2 \end{bmatrix} - 1 = 0$$

7. Se ejecuta la operación:

$$0 + p_2 - 1 = 0$$

8. Se despeja p_2 :

$$p_2 = 1 \text{ (Este es el valor del punto en el eje } P_2 \text{)}$$

Se tiene entonces la segunda coordenada (0,1).

9. Los puntos para sacar la gráfica son (-1,0) y (0,1); con estas coordenadas se procede a unir los puntos con una recta que los atraviesa, como se observa en la Figura 4, que se conocerá como la **recta de los límites de decisión**. El vector del peso, (W), será siempre perpendicular a la recta encontrada, sin importar su magnitud, iniciando su recorrido desde la coordenada (0,0). En este caso la magnitud del vector peso está dada por la coordenada (-1,1). La recta de los límites de decisión divide en dos regiones el plano con ejes p_1 y p_2 , la región de

color azul corresponde a los valores de a para $n \geq 0$ y la región color verde corresponde a los valores de a para $n < 0$

2.3. Prueba sobre la recta:

Para probar los límites de decisión se procede a escoger dos puntos aleatorios sobre el plano, uno a un lado de la recta y otro al otro lado de la recta, como se observa en la Figura 5. Se escogen entonces los puntos aleatorios $(-0.5, 1)$ y $(-1, -1)$.

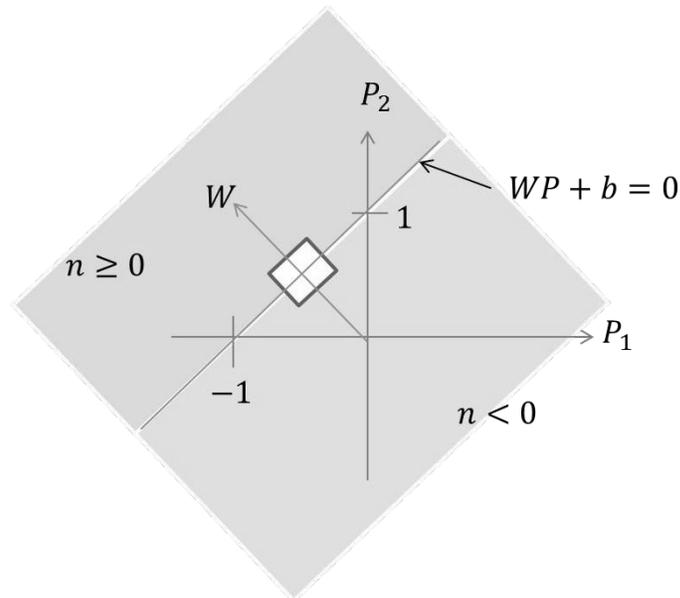


Figura 4. Límites de decisión.
Fuente: Elaboración de los autores.

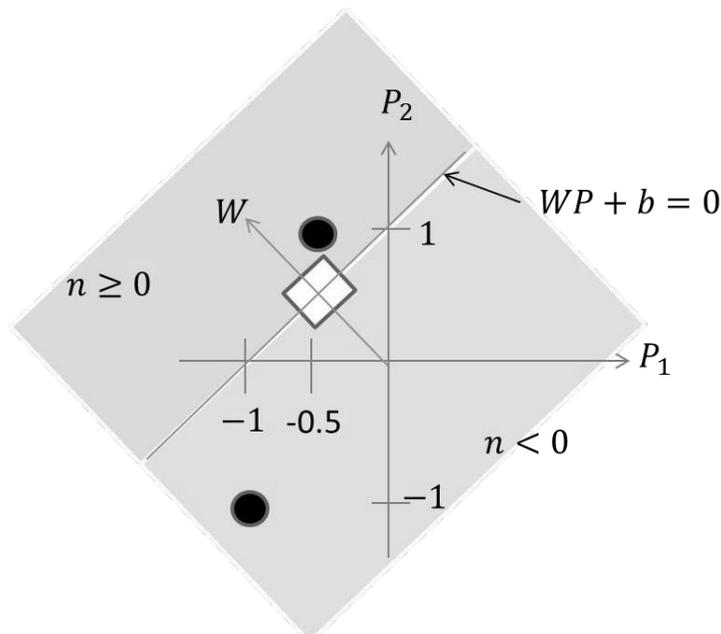


Figura 5. Dos puntos cualquiera a un lado y otro de la recta de decisión.
Fuente: Elaboración de los autores.

1. Se toma la ecuación de la neurona:

$$a = \text{hardlims}(wp + b)$$

2. Se remplazan los valores para (-0.5, 1):

$$a = \text{hardlims}\left(\begin{bmatrix} -1 & 1 \end{bmatrix} \begin{bmatrix} -0.5 \\ 1 \end{bmatrix} - 1\right)$$

$$a = \text{hardlims}(0.5 + 1 - 1)$$

$$a = \text{hardlims}(0.5)$$

$$a = 1$$

3. Se remplazan los valores para (-1, -1):

$$a = \text{hardlims}\left(\begin{bmatrix} -1 & 1 \end{bmatrix} \begin{bmatrix} -1 \\ -1 \end{bmatrix} - 1\right)$$

$$a = \text{hardlims}(1 - 1 - 1)$$

$$a = \text{hardlims}(-1)$$

$$a = -1$$

Se puede observar que los resultados son 1 y -1, respectivamente, para los puntos (-0.5, 1) y (-1, -1), por lo que una neurona sencilla puede entonces separar dos puntos haciendo uso de una recta. Todos los puntos que estén de un lado darán como resultado 1 y los que estén del otro lado de la recta, darán como resultado -1. Este tipo de neuronas funciona para problemas donde los puntos sean linealmente separables.

3. REGLAS DE APRENDIZAJE PARA UN SISTEMA DE CONTROL ON-OFF

Como se pudo observar, la recta de decisión define con valores de pesos y bias la clasificación de los valores de entrada. En los problemas de ingeniería, se tienen datos de entrada que deben ser tratados para obtener la solución a un problema. Para visualizar un aspecto práctico se podría imaginar una máquina clasificadora de bananas y manzanas, con características similares a la planteada por los autores en [9]. En la Fig. 6 se observa el sistema que compone la máquina clasificadora.

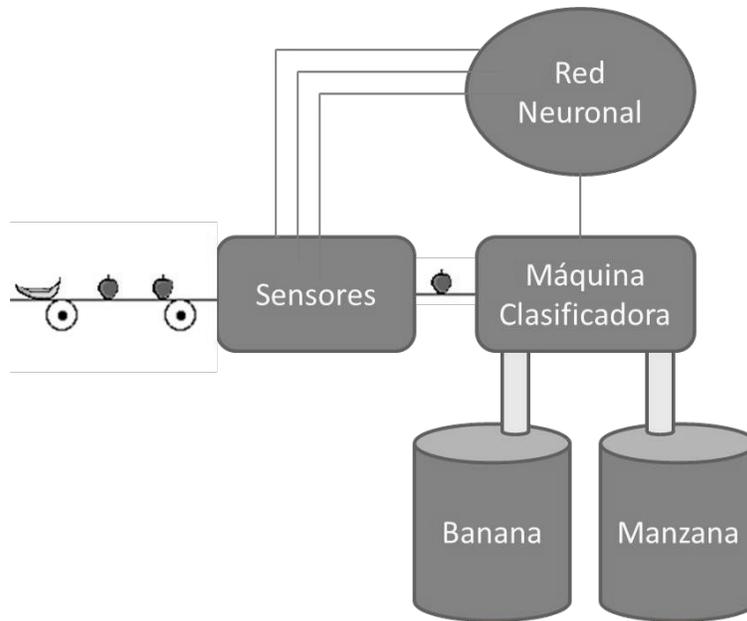


Figura 6. Máquina clasificadora de bananas y manzanas.

Fuente: Elaboración de los autores.

Se tiene entonces que, en este ejemplo, se propone un vector que tiene los siguientes datos de los sensores:

$$P = \begin{bmatrix} Forma \\ Textura \end{bmatrix}$$

El sensor identifica los objetos y envía los siguientes datos:

- Forma: 1 si es redondo y -1 si es elíptico
- Textura: 1 si es suave y -1 si es rugoso

Con base en los datos recibidos de los sensores, la red neuronal identifica el objeto para enviar la información al clasificador, el cual usa un mecanismo o actuador de dos estados, que envía la fruta a su determinado almacenamiento. El proceso que toma la neurona en este caso se puede comparar con un sistema de control de dos estados (ON-OFF) [8].

Se determina que las siguientes características que corresponden a rasgos comunes para las dos frutas son:

$$P_A = \begin{bmatrix} -1 \\ 1 \end{bmatrix}, \quad P_B = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

Por tanto, P_A corresponde a una banana y P_B corresponde a una manzana, lógicamente. Si se ubican estos dos valores sobre el plano se tiene:

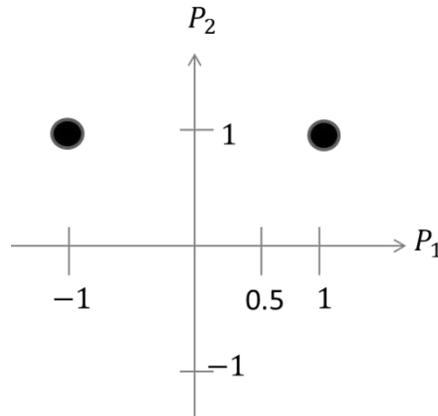


Figura 7. Ubicación de los puntos en el plano.

Fuente: Elaboración de los autores.

Ahora, la pregunta es: ¿cómo modificar los valores de pesos y bias en el modelo neuronal para que se realice correctamente la clasificación? La respuesta se encuentra primero organizando los datos en las entradas y salida objetivo, de la siguiente forma:

$$\left\{ P_A = \begin{bmatrix} -1 \\ 1 \end{bmatrix}, \quad t_1 = 1 \right\} \quad \left\{ P_B = \begin{bmatrix} 1 \\ 1 \end{bmatrix}, \quad t_2 = 0 \right\}$$

Cabe mencionar que la salida objetivo en este caso se ha determinado como para las entradas y para las entradas porque estas señales podrían ser los estados de entrada a la máquina selectora de frutas para operar el actuador.

La función de activación de la neurona que maneja dos estados, que se pueden interpretar como estados lógicos bajo y alto en sistemas digitales, es la función hardlim:

$$\text{hardlim}(n) = a \quad \therefore \begin{cases} a = 0 & \forall n < 0 \\ a = 1 & \forall n \geq 0 \end{cases}$$

Ahora para modificar el peso y bias se procede a establecer las siguientes reglas de aprendizaje:

$$e = t - a$$

$$W^{\text{nuevo}} = W^{\text{viejo}} + eP$$

$$b^{\text{nuevo}} = b^{\text{viejo}} + e$$

Donde,

e : corresponde al error entre la salida deseada “ t ” menos la salida actual “ a ” de la neurona.

W^{viejo} : corresponde al valor inicial de los pesos, que se va actualizando con cada iteración, hasta llegar al resultado adecuado, como se observará mas adelante.

P : corresponde a la entrada que se le presenta a la neurona.

b^{viejo} : corresponde al valor inicial del bias que se va actualizando con cada iteración hasta llegar al resultado adecuado.

3.1. Pasos para modificar pesos y bias en el modelo neuronal.

1. Se escoge un valor aleatorio inicial para los pesos, por ejemplo:

$$W = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

2. Se escoge un valor aleatorio inicial para el bias, por ejemplo:

$$b = 0$$

Con la elección de estos valores el plano queda de la siguiente forma:

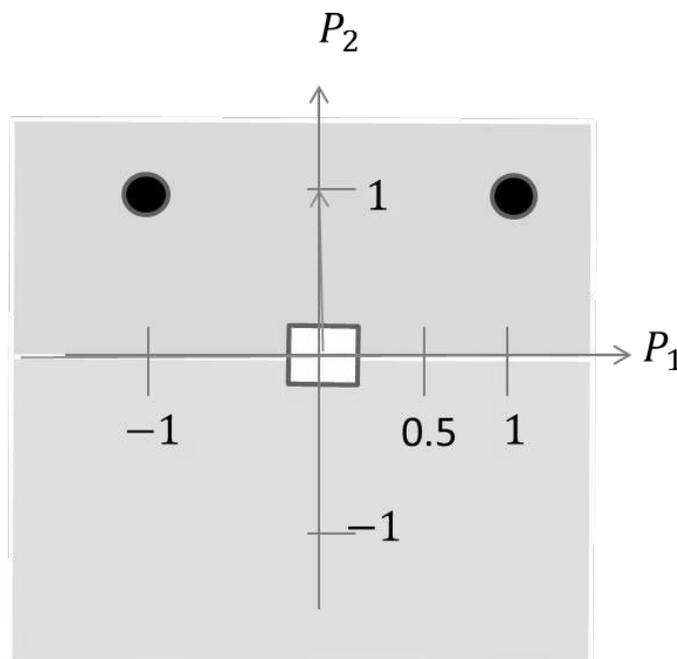


Figura 8. Posición inicial de la recta de decisión y pesos.

Fuente: Elaboración de los autores.

Claramente, se observa que no habrá una clasificación por parte de la neurona, porque ambos puntos (Banana y Manzana) se encuentran del mismo lado de la recta de decisión, donde la salida del modelo neuronal será la misma.

3. Se remplazan los valores para la entrada P_A (Banana):

$$a = \text{hardlim} \left([0 \quad 1] \begin{bmatrix} -1 \\ 1 \end{bmatrix} + 0 \right)$$

$$a = 1$$

4. Se verifica la ecuación de error:

$$e = t_1 - a$$

$$e = 1 - 1 = 0$$

Se puede observar que la condición se cumple para clasificar las Bananas.

5. Ahora se procede a remplazar los datos para clasificar la Manzana.

$$a = \text{hardlim} \left([0 \quad 1] \begin{bmatrix} 1 \\ 1 \end{bmatrix} + 0 \right)$$

$$a = 1$$

6. Se verifica la ecuación de error:

$$e = t_2 - a$$

$$e = 0 - 1 = -1$$

Lo anterior muestra que no se está clasificando la Manzana.

7. Se procede ahora a aplicar las reglas de aprendizaje:

$$W^{nuevo} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} + (-1) \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} -1 \\ 0 \end{bmatrix}$$

El bias no es necesario modificarlo porque este valor se define como en la ecuación de la línea recta, un intercepto sobre el eje y si se observa la Fig. 8 se puede dejar el bias igual a cero, lo que hará que el vector de pesos gire en el plano con origen fijo en la coordenada (0,0).

8. Se remplazan los nuevos valores en el modelo de la neurona:

$$a = \text{hardlim} \left([-1 \quad 0] \begin{bmatrix} 1 \\ 1 \end{bmatrix} - 0 \right)$$

$$a = \text{hardlim}(-1) = 0$$

Ahora que el valor “ a ”, de salida del modelo neuronal, corresponde con el valor deseado de “ t_2 ” se puede decir que ya se han encontrado los valores de pesos y bias. En este caso, la salida cero dice que la fruta de entrada corresponde a una Manzana.

Se puede verificar nuevamente que con el nuevo valor de pesos no se altera el resultado cuando se le presenta una Banana:

$$a = \text{hardlim} \left([-1 \ 0] \begin{bmatrix} -1 \\ 1 \end{bmatrix} - 0 \right)$$

$$a = \text{hardlim}(1) = 1$$

Ahora se puede observar en la Fig. 9, que el valor de pesos obtenido, clasifica correctamente los valores de entrada según la recta de decisión. Con este ejercicio se puede ver la aplicabilidad de las redes neuronales a los sistemas digitales para operar una máquina con un actuador de dos estados lógicos o un sistema de control ON-OFF.

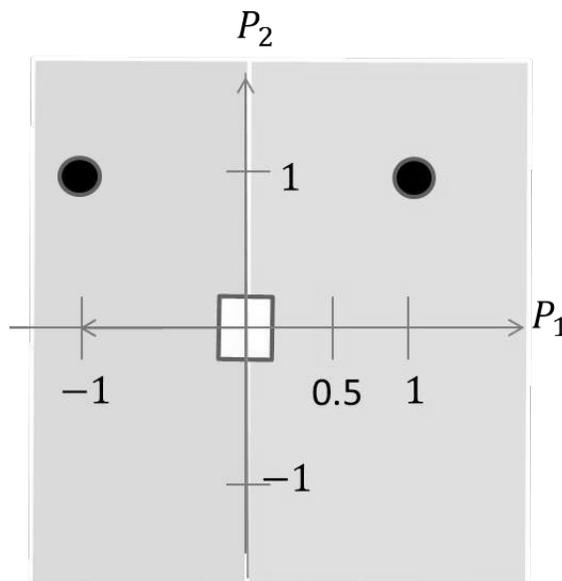


Figura 9. Posición final de la recta de decisión y pesos.

Fuente: Elaboración de los autores.

4. MÁQUINAS INTELIGENTES

En la sección anterior se observó una forma de aplicar aprendizaje supervisado a un modelo neuronal, para que una máquina pueda aprender a clasificar dos vectores de datos. La pregunta que se hacen todos es ¿Podrá una máquina llegar a ser inteligente? Para tal caso se podría cuestionar lo que es la inteligencia en sí misma.

Según el diccionario de la Real Academia Española, se entiende “inteligencia” como la capacidad de entender o comprender; la capacidad de resolver problemas, teniendo también presente la habilidad, destreza y experiencia, entre otros [10].

Howard Garner en [11], define la inteligencia como la habilidad para resolver problemas o crear productos que son valiosos dentro de uno o más entornos culturales. También especifica que ésta no se desarrolla de igual forma en todas las personas y propone unos criterios para desarrollar y observar la inteligencia, más no para medirla. Propone que existen varios tipos de inteligencia que son:

1. Lingüística: habilidad en la lectura, narración de historias, escritura, memorización de fechas. Este tipo de personas aprenden mejor leyendo, hablando, escribiendo, discutiendo y debatiendo.
2. Lógico-matemática: habilidad en razonamiento, lógica, solución de problemas
3. Musical: habilidad en reconocer sonidos, recordar melodías, ritmos, cantar. Este tipo de personas aprenden mejor cantando, escuchando melodías.
4. Espacial: habilidad con ubicaciones en mapas,
5. Cinético-corporal
6. Naturalista
7. Interpersonal
8. Intrapersonal

Conforme mencionan los autores en [12], existen diferentes definiciones agrupadas en varios aspectos:

Tabla 1. Clasificación de la Inteligencia en las máquinas.

Pensamiento Humano	Pensamiento Racional
Actuar Humano	Actuar Racional

Fuente: Elaboración de los autores.

Las definiciones que tienen como base las facultades de pensamiento, percepción, razón y todos los procesos, que conlleva el pensamiento se agrupan en la primera fila de la Tabla 1, dividiéndose en dos columnas; la primera que hace alusión a la forma de pensar, apegada a lo humano, interpretando que los datos de entrada y salida de una máquina y sus tiempos de respuesta sean similares a los de un humano. En este aspecto, la investigación se desarrolla en el campo de la ciencia cognitiva, donde los experimentos psicológicos y las técnicas de la inteligencia artificial elaboran teorías sobre las fases del razonamiento y procesos de funcionamiento de la mente humana.

La segunda columna de la primera fila de la Tabla 1 se basa en el concepto ideal de inteligencia, entendiéndose que si un sistema hace lo correcto en función de su conocimiento, entonces ese

sistema es racional. Tal concepto parte de las consideradas leyes del pensamiento que se basan en los silogismos y la lógica. La segunda fila de la Tabla 1 se enfoca en el actuar. La primera columna de la segunda fila tiene un enfoque humano, más específicamente considerando la prueba de Turing. La prueba propuesta por Alan Turing en 1950 consta de una serie de preguntas donde se evalúan varios aspectos de la máquina como: Procesamiento del lenguaje natural, Representación del conocimiento, Razonamiento Automático y Aprendizaje Automático. Adicionalmente, se desarrolló una prueba global de Turing, donde se evalúa la visión computacional y la robótica empleada por la máquina. Por último, en la tabla se muestra el actuar racional; que corresponde al enfoque del agente racional, donde un agente es algo que razona y actúa, de ahí que la palabra viene del latín *agere*, que quiere decir “hacer”. El agente, entonces, actúa para buscar el mejor resultado o en presencia de incertidumbre, hacer lo mejor posible.

Se puede entender que la conceptualización del término inteligencia conlleva al desarrollo de máquinas más sofisticadas puesto que el diseño detrás de la máquina muestra el nivel de comprensión que poseen los creadores de tal máquina. Mientras mas información arrojen las investigaciones en el campo de la biología y los procesos que se desarrollan en la naturaleza, muchas mejoras podrán ser integradas en el diseño y desarrollo de las máquinas.

5. CONCLUSIONES

La naturaleza hace una propuesta elegante para el desarrollo de soluciones prácticas, no solo en el campo de la ingeniería sino en todos aquellos aspectos que, tomando conciencia de sus procesos, pueden ser mejorados imitando un sistema biológico. En el documento se observan las capacidades que ofrece una sola neurona. Tomando en cuenta la información que se observa en el plano cartesiano, se pudo comprender que la solución es posible si los datos son linealmente separables. No obstante, si se tuviesen un conjunto de datos no separables, podría pensarse en la posibilidad de obtener un resultado agregando más dimensiones al plano, por lo que hasta tres dimensiones puede ser gráficamente entendible.

En el ejemplo práctico, es suficiente tener dos características para la solución del problema de clasificación. La solución se obtuvo utilizando únicamente las capacidades de una neurona. Con lo cual se puede aprender como funciona operativamente una neurona en una máquina.

Teniendo en cuenta los conceptos de inteligencia presentados, la misma se puede entender como el conjunto de capacidades que, en diferentes proporciones, posee una persona para desarrollar una determinada solución a los diferentes problemas que plantea el medio o entorno.

Como resultado, la comprensión del funcionamiento biológico y la naturaleza ofrecen una forma de ver la solución u optimización de los procesos y problemas del entorno pero con las capacidades que ofrece la biomímesis.

REFERENCIAS BIBLIOGRÁFICAS

- [1] K. M. Passino, *Biomimicry for Optimization, Control, and Automation*. Londres, Inglaterra: Springer-Verlag, 2005.
- [2] H. Bruck, A. Gershon, I. Golden, S. Gupta, L. Gyger, E. Magrab, y B. Spranklin. "Training mechanical engineering students to utilize biological inspiration during product development", *Bioinspiration and Biomimetics*, vol. 2, n°. 4, pp. S198-S209, 2007.
- [3] R. Muller y R. Kuc. "Biosonar-inspired technology: goals, challenges and insights". *Bioinspiration and Biomimetics*, vol. 2, No. 4, pp. S146-S161, 2007.
- [4] S. Gorb, M. Sinha, A. Peressadko, K. Daltorio y R. Quinn. "Insects did it first: a micropatterned adhesive tape for robotic applications", *Bioinspiration and Biomimetics*, vol. 2, n. 4, pp. S117-S125, 2007.
- [5] F. Grasso y P. Setlur. "Inspiration, simulation and design for smart robot manipulators from the sucker actuation mechanism of cephalopods", *Bioinspiration and Biomimetics*, vol. 2, no. 4, pp. S170-S181, 2007.
- [6] N. Quijano, K. Passino y B. Andrews. "Foraging Theory for Multizone Temperature Control", *IEEE Computational Intelligence Magazine*, vol. 1, n. 4, pp. 18-27, 2006.
- [7] Health, U. N. (11 de Noviembre de 2012). National Cancer Institute. Obtenido de Neurons & Glial Cells: <http://training.seer.cancer.gov/brain/tumors/anatomy/neurons.html>
- [8] K. Ogata, *Ingeniería de Control Moderna*. Madrid. España: Pearson Education, 2003.
- [9] M. Hagan, H. Demuth y M. Beale, *Neural Network Design*. Boston: PWS Publishing Company, 1996.
- [10] Real Academia Española. Diccionario de la Real Academia Española.
- [11] H. Gardner, *Frames of Mind. The Theory of Multiple Intelligences*. New York: BasicBooks, 1993.
- [12] S. Russell and P. Norvig, *Inteligencia Artificial. Un enfoque moderno*. Madrid: Pearson Education, 2004.