

PERCEPTRÓN AUTO-SUPERVISADO UNA RED NEURONAL ARTIFICIAL CAPAZ DE REPLICACIÓN MEMÉTICA

SELF-SUPERVISED PERCEPTRON AN ARTIFICIAL NEURAL NETWORK CAPABLE OF MEMETIC REPLICATION

Dante Giovanni Sterpin Buitrago

Corporación Unificada Nacional de Educación Superior, CUN, Bogotá (Colombia)

Resumen

La cognición humana ha sido simulada con inteligencia artificial debido a su gran utilidad para resolver problemas; sin embargo, los procesos cognitivos también le causan ciertas dificultades al individuo y la sociedad. Los resultados del modelo propuesto en este artículo hacen parte de una investigación dirigida a estudiar dichas dificultades, mediante agentes sociales artificiales con desarrollo moral en entornos competitivos donde el egoísmo y el altruismo sean decisivos. Al respecto, la memética brinda terminología evolutiva para explicar el desarrollo cultural de creencias, artefactos y comportamientos, en una comunidad de egoístas y altruistas capaces de asimilar, innovar e intercomunicar ideas, para obtener beneficios individuales y comunitarios mediante competencias dialécticas o conductuales. Como dicho desarrollo podría simularse al modelar el proceso replicativo de ciertos elementos cerebrales, llamados neuro-memes, este artículo presenta un agente capaz de replicar la conducta de otro agente, empleando una red neuronal artificial con aprendizaje supervisado y no-supervisado.

Palabras clave: red neuronal artificial, perceptrón multicapa, mapa auto-organizado de kohonen, aprendizaje por imitación, auto-supervisión moral, neuro-meme, replicación neuro-memética

Abstract

Human cognition has been simulated with artificial intelligence because it's very useful to solve problems; however, the cognitive processes also cause some difficulties to individual and society. The results of the proposed model in this paper are part of an investigation aimed to study such difficulties, using artificial social agents with moral development at competitive environments where

selfishness and altruism are decisive. In this regard, memetics provides evolutionary terminology to explain the cultural development of beliefs, artifacts and behaviors, in an egotists and altruists community capable to assimilate, to innovate and to exchange ideas, to get individual and group benefits through dialectical or behavioral competitions. As that development could be simulated to model the replicative process of certain cerebral elements, called neuro-memes, this paper presents an agent able to replicate the behavior of other agent, using an artificial neural network with unsupervised and supervised learning.

Keywords: artificial neural network, multilayer perceptron, kohonen's self-organizing map, learning by imitation, moral self-supervision, neuro-meme, neuro-memetic replication

Introducción

El aprendizaje por imitación es una capacidad cognitiva tan evolucionada en los primates que a ello podría deberse la herencia y evolución cultural humana (Dawkins, 2002). De esta manera, es considerable la posibilidad de simular dicha capacidad mediante herramientas de inteligencia artificial, pues apunta al desarrollo de sistemas capaces de asimilar, mejorar y hasta inventar, formas de solucionar problemas autónomamente.

Dicha capacidad cognitiva se atribuye a las llamadas “neuronas-espejo”, las cuales conforman un circuito neuronal encontrado en el cerebro de los homínidos. Dichas neuronas se activan cuando el individuo ejecuta una acción y cuando éste “observa” a otro realizando la misma acción, por lo cual se considera que dichas neuronas tienen la función de relacionar la acción observada con el patrón motriz necesario para imitarla (Borenstein y Ruppín, 2004).

En el área de la robótica se ha simulado este tipo de aprendizaje mediante diversos modelos, algunos de los cuales incluyen redes neuronales artificiales. Particularmente en este artículo se propone un modelo híbrido entre dos redes neuronales artificiales – conocidas como Perceptrón multicapa y mapa auto-organizado, para ofrecer un agente-aprendiz dotado con la capacidad de replicar la conducta de un instructor estructuralmente semejante. Dicho modelo resaltaría sobre otros al demostrar que funciona como un *replicador neuronal*, con lo cual sería potencialmente útil para simular la evolución cognitiva individual y socio-cultural.

Replicación neuro-memética

El modelo evolutivo por excelencia corresponde al propuesto por Charles Darwin para los seres

vivos y en dicho contexto, Richard Dawkins, (2002) identificó a los genes como replicadores sobre los cuales actúa el mecanismo de selección natural. Adicionalmente, Dawkins (2002) acuñó el término *meme* para denominar un replicador hipotético sobre el cual actúa cierta selección en la evolución cultural, pues el modelo darwiniano puede generalizarse al detallar los mecanismos replicativos en cualquier proceso evolutivo.

En dicho argumento la replicación no es la simple repetición de algo. Por ejemplo, el acto de fotocopiar un texto escrito permite repetir cierta información pero, además de provocar daños tipográficos en las copias, no conlleva directamente a corregir sus posibles errores ortográficos, gramaticales o ideológicos, por lo tanto en dicho acto no hay replicación encaminada a mejorar. Por el contrario, en la replicación genética resulta provechoso tanto el copiado perfecto como el defectuoso, pues con el primero surgen linajes genéticos capaces de sobrevivir en el ADN de las especies existentes y, mediante el segundo podrían surgir cambios genéticos capaces de ganarse el beneficio de la supervivencia (Dawkins, 2002).

Robert Aunger mencionó las características básicas que permiten identificar claramente el replicador implicado en cualquier proceso evolutivo (Aunger, 2004), así:

- Causalidad: un replicador debe participar en el hecho de copiarse a sí mismo sin la obligación de controlar completamente el proceso de replicación.
- Similitud: un replicador y su respectiva copia deben ser tan semejantes como para garantizar que la copia pueda iniciar un proceso de replicación subsiguiente, donde se presente el mismo tipo de semejanza. Sin embargo, la copia no tiene la

obligación de ser completamente idéntica al replicador original, pues de las eventuales mutaciones depende la respectiva evolución.

- Transferencia de información: la información constituyente o subyacente al replicador debe ser suficiente para iniciar el proceso de replicación sin ayuda externa. Además, el replicador debe heredarle dicha información a la copia mediante el proceso de replicación.
- Duplicación: del proceso de replicación debe resultar, al menos, un replicador más.

Los replicadores deben estar sustentados en algún tipo de material, ya sea natural o artificial. Los genes y los priones son ejemplos de replicadores naturales mientras los virus informáticos son ejemplos de replicadores artificiales. Como los memes son los replicadores implicados en la explicación evolutiva de la cultura, éstos deben ser asumidos como objetos compuestos por un material específico, en lugar de considerarse como simples abstracciones presentes en las recetas de cocina, las creencias religiosas, los modales urbanos y los artefactos tecnológicos, cuestión que al haber sido deliberadamente asumida por los meméticos clásicos ha dejado a un lado la posibilidad de ubicar claramente a los memes (Aunger, 2004).

De esta forma la evolución cultural podría basarse en la replicación de *neuro-memes*, es decir, material cerebral capaz de replicarse tanto en el propio cerebro como en los ajenos. En el modelo de replicación neuro-memética de Aunger (2004) se considera la existencia hipotética de ciertos *nodos neuronales* que, para replicar su tendencia a descargar eléctricamente, deben estimular otros nodos neuronales subsiguientes y provocar en alguno de estos últimos la misma tendencia, con lo cual cumplen las cuatro características replicativas. Dicha hipótesis permite dilucidar el cerebro individual como un gran proceso de evolución cognitiva en el cual pueden detallarse ciertos modelos artificiales (Fernando y Szathmáry, 2009).

Al disponer de un algoritmo basado en la evolución de neuro-memes existiría la posibilidad de lograr sistemas sociales artificiales, en los cuales podrían emerger y evolucionar algunas de las ventajas y problemáticas subyacentes a la cultura humana. En la actualidad existen ciertos algoritmos meméticos (Moscato y Cotta, 2010) y ciertos híbridos entre

algoritmos evolutivos y redes neuronales con los cuales se ha visto emerger la capacidad de aprendizaje por imitación en una población de agentes neuronales (Borenstein y Ruppín, 2004) y hasta se ha visto la emergencia de cooperación altruista entre *robots* como estrategia para lograr beneficio social por encima del beneficio individual (Floreano *et al.*, 2008), lo cual se considera de orden moral y ha fundamentado el desarrollo de las sociedades humanas.

En Curran y O’Riordan (2004) puede detallarse la combinación del aprendizaje poblacional de un algoritmo genético, el aprendizaje neuronal en cada individuo de la respectiva población y cierto aprendizaje cultural, donde los mejores individuos en cada generación funcionan como tutores, al comunicar sus propias “verbalizaciones” sobre el medio ambiente a pupilos con la capacidad de imitarlas. Mediante la relación entre tutores y pupilos dicha población desarrolla autónomamente cierto léxico y acelera su propia evolución, lo cual simula el papel del lenguaje y la educación en la cultura humana. A pesar de la extensa literatura sobre redes neuronales evolutivas, aún no existe un modelo computacional capaz de simular la evolución cognitiva de un cerebro individual, sin embargo, ése es el propósito de la hipótesis del replicador neuronal (Fernando *et al.*, 2010). En general, los sistemas bioinspirados simulan ciertas características propias de los seres vivos y las sociedades naturales, pero ¿podrían utilizarse para simular la emergencia y evolución artificial de cuestiones tales como el arte, la escritura, el intercambio mercantil, la escisión social o la estratagema bélica, por ejemplo?

Para simular y estudiar las ventajas y problemáticas de un sistema socio-cultural remotamente cercano al humano, se proyectó una investigación donde resaltó la necesidad de diseñar un sistema basado en replicación neuro-memética, sin embargo, ante la complejidad implicada se consideró necesario disponer primero de un replicador neuro-memético apropiado. Por tal razón los resultados presentes en este artículo tan sólo atienden al siguiente problema: ¿Cómo utilizar redes neuronales artificiales para lograr un sistema capaz de aprender por imitación como una forma hipotética de replicación neuro-memética?

Metodología

Tras considerar el funcionamiento convencional tanto del Perceptrón Multicapa (MLP) como del Mapa Auto-Organizado (SOM), se diseñó una forma de utilizar el conocimiento asimilado por el SOM para entrenar el MLP y así, se armó un modelo híbrido al cual se denominó Perceptrón Auto-Supervisado (SSP). Para demostrar su capacidad de replicación neuro-memética se utilizó un *robot*-instructor cuya conducta fue observada, asimilada y reproducida por un *robot*-aprendiz controlado totalmente mediante dicho modelo híbrido, del cual se describen a continuación sus procedimientos matemáticos y algorítmicos.

Redes neuronales artificiales

Las redes neuronales artificiales son sistemas conexionistas por excelencia y, son capaces de simular ciertas capacidades cerebrales al interconectar neuronas artificiales. Estas últimas son sistemas de procesamiento numérico que simulan la propagación del impulso electro-químico, al interpretar las neuronas naturales como compuertas para dicha señal en el cerebro. De esta forma, una neurona artificial es capaz de propiciar y hasta inhibir impulsos electro-numéricos, según su nivel de estimulación y su forma particular de activación.

La estimulación de una neurona artificial considera un conjunto de n entradas con un peso de conexión sináptica asociado a cada una. Según la diferencia existente entre la cantidad de estimulación y cierto umbral de activación, se calcula una regla de propagación para obtener un valor denominado potencial posináptico. Con dicho valor se calcula una función de activación para determinar la reacción neuronal frente a la respectiva estimulación. Como funciones de activación suelen utilizarse el escalón, la rampa, la sigmoidea o la gaussiana. Los valores de las sinapsis representan la forma como la neurona *sabe* reaccionar a la estimulación, y por esto, al cambiar dichos valores cambia el comportamiento neuronal.

Perceptrón multicapa (MLP)

Una de las interconexiones neuronales artificiales más utilizada consiste en organizar neuronas artificiales en capas: una perceptora, una o varias intermedias,

y una eefectora, de tal manera que las neuronas de la primera capa reciben información específicamente sensorial y las de la última capa entregan información específicamente motriz, mientras las intermedias ayudan a complejizar la plasticidad senso-motriz del sistema basado en MLP.

Las sinapsis se organizan matricialmente según el número de capas intermedias más uno, es decir, si hay una única capa intermedia hay dos matrices sinápticas $[W_{ij}]$: una con las sinapsis entre neuronas eefectoras e intermedias, y la otra, con las sinapsis entre neuronas intermedias y sensoriales. El procesamiento neuronal toma los valores sensoriales y calcula la activación neuronal de las neuronas intermedias, luego utiliza estos valores como entradas para calcular las activaciones neuronales en la siguiente capa y así sucesivamente hasta llegar a la capa eefectora, con lo cual se obtiene la salida total del MLP.

Habitación conductual: el aprendizaje en el MLP

Como los valores sinápticos son inicializados aleatoriamente, el MLP “nace” sin *saber* cómo funcionar correctamente y, por tal razón, debe entrenarse. Típicamente se utiliza el método del descenso por el gradiente (LMS) para lograr el mínimo valor posible de error cuadrático medio. Con dicho algoritmo de aprendizaje se modifican reiterativamente los valores sinápticos, hasta cuando el sistema basado en MLP evidencia cierta conducta deseable.

Este método de aprendizaje es de tipo supervisado pues no depende de la experiencia directa entre agente y ambiente sino de la existencia de un patrón conductual predefinido, el cual debe manifestarse como conducta evidente. Sin embargo, es posible observar la conducta transitoria durante el entrenamiento y así detallar la evolución del sistema desde la torpeza inicial hasta la destreza deseada. Para un MLP con n entradas $[x_j]$ y m salidas $[y_i]$ el programador debe definir un conjunto de p patrones, donde cada patrón $[p_\mu]$ especifica las m salidas deseadas $[t_i]$ para alguna posible combinación numérica de entrada. Con la diferencia entre las salidas deseadas y las obtenidas puede calcularse el error cuadrático medio $[E_\mu]$ del sistema y, para minimizarlo, en cada nueva iteración del sistema se ajusta cada una de las conexiones sinápticas $[w_{ij}]$ según la variación sináptica $[\Delta w_{ij}]$ calculada mediante la siguiente expresión:

Ecuación 1. Algoritmo de aprendizaje para el MLP

$$\Delta w_{ij} = -\varepsilon \sum_{\mu=1}^p \frac{\partial E_{\mu}}{\partial w_{ij}} \quad ; \quad \text{donde } E_{\mu} = \frac{1}{2} \sum_{i=1}^m (t_i^{\mu} - y_i^{\mu})^2$$

El valor $[\varepsilon]$ se utiliza como tasa de convergencia o velocidad de aprendizaje. Las funciones de activación utilizadas para calcular las m $[y_i]$ deben ser totalmente derivables. Y además, suelen considerarse dos medidas de error: uno de entrenamiento y otro de generalización. El primero suele utilizar el 80% del conjunto de patrones y evalúa la obtención de las respectivas salidas deseadas, mientras el segundo utiliza el porcentaje restante para evaluar la operatividad del MLP en situaciones que no se le enseñan directamente. Durante el entrenamiento se registra el mínimo valor de cada error y, la variación de los pesos sinápticos se anula en caso de verse aumentada cualquiera de estas medidas por encima de dichos mínimos.

Mapa auto-organizado de Kohonen (SOM)

Este modelo neuronal está inspirado en la corteza somato-sensorial y tiene la capacidad de identificar patrones de semejanza presentes en sus percepciones, lo cual implica un proceso de aprendizaje mediante variaciones sinápticas sin necesidad de patrones predefinidos por el programador. El SOM está conformado por una capa de neuronas sensoriales interconectadas sinápticamente con un conjunto de neuronas cognitivas distribuidas en 2D o 3D.

En un SOM con s entradas $[x_k]$ se define un vector sináptico $[W_{\mu k}]$ de s conexiones para cada neurona cognitiva $[z_{\mu}]$. Dichas conexiones sinápticas inician con valores aleatorios y mediante su entrenamiento se logra reducir la multidimensionalidad de ciertas situaciones, clasificándolas y reconociéndolas por semejanza aproximada. Esto simula la capacidad cognitiva de un niño cuando observa cierto animal por primera vez y piensa en un “guau-guau”, porque identifica las características generales que frecuentemente ha observado en los perros.

Asimilación cognitiva: el aprendizaje en el SOM

El SOM sólo asimila patrones experimentados mediante su propio sistema de percepción y a este proceso

se le conoce como aprendizaje no-supervisado. En este proceso de aprendizaje las variaciones sinápticas conllevan a situar cada vector sináptico en una posición intermedia entre los vectores sensoriales con ciertas semejanzas. Para esto se calcula la distancia entre cada vector sináptico $[W_{\mu k}]$ y el vector sensorial $[X_k]$, tal como se muestra en la ecuación 2. Una vez se calcule dicha medida para todas las neuronas del SOM, la ecuación 3 muestra cómo utilizar el valor de la mínima y la máxima distancia, en cada nueva percepción, para calcular una distribución normalizada de activaciones neuronales.

Ecuación 2. Distancia euclídea entre sinapsis y sensaciones

$$d_{\mu} = \sqrt{\sum_{k=1}^s (w_{\mu k} - x_k)^2}$$

Ecuación 3. Función de activación neuronal distribuida

$$z_{\mu} = 1 - \left(\frac{d_{\mu} - \min}{\max - \min} \right)$$

En cada nueva percepción se activan ciertos sectores neuronales según los diversos grados de cercanía entre cada vector sináptico y el vector sensorial, sin embargo, la neurona más activa es aquella con el mínimo valor de distancia y por lo tanto, es la que mejor reconoce lo percibido. Esta activación neuronal permite focalizar las variaciones sinápticas de la asimilación cognitiva, tanto en la neurona más exaltada como en sus “vecinas”. En este método de aprendizaje las variaciones sinápticas $[\Delta w_{\mu k}]$ se calculan mediante la siguiente expresión:

Ecuación 4. Algoritmo de aprendizaje para el SOM.

$$\Delta w_{\mu k} = A(it) * V(r, R) * (x_k - w_{\mu k})$$

Dicho cálculo depende de un nivel de aprendizaje $[A(it)]$, una función de vecindad $[V(r,R)]$ y la respectiva diferencia entre el valor de entrada y el de la sinapsis. La ecuación 5 muestra cómo decrementar linealmente el nivel $[A(it)]$ en el transcurso de $[it_f]$ iteraciones, desde un valor inicial $[A_i]$ hasta uno final $[A_f]$. En la ecuación 6 se muestra el cálculo de la distancia $[r]$ entre cualquier neurona cognitiva y la más exaltada, ubicadas respectivamente en las coordenadas (f,c) y (F,C) de un SOM 2D. La ecuación 7 muestra cómo decrementar linealmente el radio de perturbación $[R(it)]$ en el transcurso de $[it_f]$ iteraciones, desde un valor inicial $[R_i]$ hasta uno final $[R_f]$. En la ecuación 8 se detalla la función $[V(r,R)]$ y en la ecuación 9 se detalla la actualización sináptica en cada nueva iteración. Debido al decremento lineal de $[A(it)]$ y $[R(it)]$ se dice que el SOM está inicialmente “abierto” a la asimilación cognitiva, pero a medida que avanza el aprendizaje se “endurece” la flexibilidad sináptica hasta “cerrarse”, tras suceder $[it_f]$ iteraciones.

Ecuación 5. Nivel de aprendizaje con decremento lineal

$$A(it) = \begin{cases} A_f & ; \text{ para } it \geq it_f \\ A_i + \left[\frac{(A_f - A_i) * it}{it_f} \right] & ; \text{ para } it < it_f \end{cases}$$

Ecuación 6. Distancia con respecto a la neurona ganadora

$$r = \sqrt{(f - F)^2 + (c - C)^2}$$

Ecuación 7. Radio de perturbación con decremento lineal

$$R(it) = \begin{cases} R_f & ; \text{ para } it \geq it_f \\ R_i + \left[\frac{(R_f - R_i) * it}{it_f} \right] & ; \text{ para } it < it_f \end{cases}$$

Ecuación 8. Función de vecindad tipo gaussiana

$$V(r, R) = \begin{cases} 1 - \left[2 * \left(\frac{r}{R} \right)^2 \right] & ; \text{ para } 0 \leq r \leq R/2 \\ 2 * \left(\frac{R - r}{R} \right)^2 & ; \text{ para } R/2 < r \leq R \\ 0,0 & ; \text{ para } r > R \end{cases}$$

Ecuación 9. Actualización sináptica en el SOM

$$w_{\mu k}(it + 1) = w_{\mu k}(it) + \Delta w_{\mu k}(it)$$

Finalmente, debe comentarse que las neuronas cognitivas compiten entre sí por semejarse a la respectiva percepción en cada nueva iteración.

Imitación conductual: el aprendizaje en el SSP

El SSP como modelo híbrido ente SOM y MLP utiliza los dos tipos de aprendizaje mencionados anteriormente con el fin de imitar una conducta ajena, para lo cual el SOM asimila el respectivo patrón conductual y el MLP lo habitúa como conducta propia. Tanto el SOM como el MLP pueden entrenarse en paralelo, calculando una iteración del MLP tras cada iteración del SOM, o puede entrenarse primero el SOM y tras su “cierre” el MLP.

Al SOM debe definírsele un vector sensorial $[X_k]$ de $n+m$ valores, según las n entradas y las m salidas del respectivo MLP. El algoritmo de aprendizaje en el SOM sigue operando tal como se describió en la sección (Asimilación cognitiva: el aprendizaje en el SOM), pero considerando en la ecuación 2 que $s=n+m$ sensaciones. De esta manera el SOM puede observar y asimilar posibles combinaciones senso-motrices para el MLP a su cargo, con lo cual pretende obtenerse finalmente un posible patrón $[p_\mu]$ por cada vector sináptico $[W_{\mu k}]$, y utilizarlos en conjunto para entrenar el MLP.

Para cada posible patrón $[p_\mu]$ se calcula un valor de probabilidad mediante una función de salida $[P_\mu]$ en las neuronas cognitivas del SOM. Dicha probabilidad se calcula según lo frecuente que haya sido perturbada cada neurona cognitiva y, sirve para definir la influencia de su respectivo vector sináptico $[W_{\mu k}]$ como patrón de entrenamiento en el MLP. La ecuación 10 permite detallar que $[P_\mu]$ considera un índice de suavidad $[\lambda(it)]$, el cual decrementa linealmente en el transcurso de $[it_f]$ iteraciones, desde un valor inicial $[\lambda_i]$ hasta uno final $[\lambda_f]$, tal como indica la ecuación 11. Debido a dicho decremento la función $[P_\mu]$ es inicialmente una equiprobabilidad del 50% y, tras funcionar con las diversas formas de una sigmoideal centrada en $[f_c]$, al cabo de $[it_f]$ iteraciones se convierte en una función escalonada de inclusión/exclusión binaria.

Ecuación 10. Probabilidad de influencia entre SOM y MLP

$$P_{\mu} = \left\{ \begin{array}{l} 0,5 \\ \left(\begin{array}{l} 0,0 \\ \frac{1}{2} * \left(\frac{f_{\mu} - f_c + \lambda f_c}{\lambda f_c} \right)^2 \\ 1 - \left[\frac{1}{2} * \left(\frac{f_c + \lambda f_c - f_{\mu}}{\lambda f_c} \right)^2 \right] \\ 1,0 \end{array} \right. \left. \begin{array}{l} ; \text{ para } f_{\mu} < (f_c - \lambda f_c) \\ ; \text{ para } f_{\mu} < f_c \\ ; \text{ para } f_{\mu} \geq f_c \\ ; \text{ para } f_{\mu} \geq (f_c + \lambda f_c) \end{array} \right\} \left. \begin{array}{l} ; \text{ para } f_c = 0 \\ ; \text{ para } f_c \neq 0 \end{array} \right\}$$

Ecuación 11. Índice de suavidad con decremento lineal.

$$\lambda(it) = \left\{ \begin{array}{l} \lambda_f \\ \lambda_i + \left[\frac{(\lambda_f - \lambda_i) * it}{it_f} \right] \end{array} \right\} \left. \begin{array}{l} ; \text{ para } it \geq it_f \\ ; \text{ para } it < it_f \end{array} \right\}$$

En cada neurona cognitiva del SOM se incrementa una frecuencia de perturbación $[f_{\mu}]$ cada vez que la respectiva neurona resulta como la más exaltada. En cada iteración del SOM debe calcularse la frecuencia promedio de perturbaciones, y debe limitarse el incremento de cada frecuencia $[f_{\mu}]$ al doble de dicho promedio. Durante el entrenamiento del SOM, las neuronas cuya frecuencia $[f_{\mu}]$ sea menor que cierta frecuencia crítica $[f_c]$ tienen menor probabilidad $[P_{\mu}]$, y quedan en desventaja competitiva con respecto a las demás. Tras el “cierre” del SOM, aquellas neuronas cuya frecuencia $[f_{\mu}]$ sea mayor o igual a $[f_c]$ son las únicas cuyo vector $[W_{\mu k}]$ influirá en el entrenamiento del MLP. Por esto $[P_{\mu}]$ funciona como un filtro cuyo propósito es discriminar probabilísticamente los patrones del SOM que definen la conducta del MLP.

Como el conjunto de patrones adquirido por el SOM debe utilizarse para calcular los valores de error

mencionados en la sección 2.2.1, deben discriminarse los patrones de entrenamiento y los de generalización. Los primeros se determinan utilizando un porcentaje alto de la frecuencia promedio como frecuencia crítica en $[P_{\mu}]$ y, los segundos se determinan utilizando un porcentaje más bajo de la frecuencia promedio. Para lograr dicha discriminación se toma el valor $[P_{\mu}]$ resultante en cada posible patrón $[p_{\mu}]$, y se ejecuta una decisión probabilística utilizando un conjunto de números aleatorios $[N_{\mu}]$ entre $[0;1]$, garantizando un número diferente para cada patrón y cambiándolos en cada iteración del MLP. La ecuación 12 detalla la forma de calcular el error cuadrático medio, utilizando cierto factor $[e_{\mu}]$ en el de entrenamiento y cierto factor $[g_{\mu}]$ en el de generalización. La ecuación 13 muestra un ejemplo de cómo definir dichos factores al discriminar los patrones de entrenamiento mediante el 90% de la frecuencia promedio y, los de generalización mediante el 60% de la frecuencia promedio.

Ecuación 12. Error cuadrático medio de entrenamiento y de generalización

$$E_e = \frac{1}{2} \sum_{\mu=1}^p \sum_{i=1}^m (t_i^{\mu} - y_i^{\mu})^2 * e_{\mu} \quad E_g = \frac{1}{2} \sum_{\mu=1}^p \sum_{i=1}^m (t_i^{\mu} - y_i^{\mu})^2 * g_{\mu}$$

Ecuación 13. Discriminación de los patrones de entrenamiento y generalización

$$\left\{ \begin{array}{l} e_{\mu} = 1; g_{\mu} = 0 \\ e_{\mu} = 0; g_{\mu} = 1 \\ e_{\mu} = 0; g_{\mu} = 0 \end{array} \right. \left. \begin{array}{l} ; \text{ para } N_{\mu} \leq P_{\mu}(f_c = 0,9 * \bar{f}) \\ ; \text{ para } P_{\mu}(f_c = 0,9 * \bar{f}) < N_{\mu} \leq P_{\mu}(f_c = 0,6 * \bar{f}) \\ ; \text{ para } N_{\mu} > P_{\mu}(f_c = 0,6 * \bar{f}) \end{array} \right\}$$

En el algoritmo de aprendizaje del MLP pueden introducirse dos factores, el de entrenamiento y uno de situación, los cuales permiten ejercer la influencia del SOM sobre el MLP. El factor de entrenamiento $[e_\mu]$ es obligatorio y sirve para permitir o anular la variación sináptica, en cada iteración del MLP. Por su parte, el factor de situación $[s_\mu]$ es opcional y sirve para graduar la variación sináptica del MLP, según

sea su respectiva percepción en cada iteración, con lo cual su conducta es corregida únicamente por los patrones gradualmente exaltados en el SOM, dada la situación sensorial del MLP. El factor $[s_\mu]$ semeja la activación neuronal descrita en la sección 2.3.1, pero en este caso sólo se consideran los n valores percibidos tanto por el SOM como por el MLP, según se muestra en la siguiente expresión:

Ecuación 14. Activación situacional de los patrones

$$s_\mu = 1 - \left(\frac{d_\mu - \min}{\max - \min} \right) ; \text{ donde } d_\mu = \sqrt{\sum_{k=1}^n (w_{\mu k} - x_k)^2}$$

Para entrenar el MLP del SSP, la ecuación 15 muestra cómo calcular las variaciones sinápticas $[\Delta w_{ij}]$ empleando los factores $[e_\mu]$ y $[s_\mu]$ en el

algoritmo LMS, mientras la ecuación 16 muestra cómo actualizar los valores sinápticos en cada nueva iteración.

Ecuación 15. Algoritmo de aprendizaje para el MLP del SSP.

$$\Delta w_{ij} = -\varepsilon \sum_{\mu=1}^p \frac{\partial E_\mu}{\partial w_{ij}} * e_\mu * s_\mu ; \text{ donde } E_\mu = \frac{1}{2} \sum_{i=1}^m (t_i^\mu - y_i^\mu)^2$$

Ecuación 16. Actualización sináptica en el MLP

$$w_{ij}(it + 1) = w_{ij}(it) + \Delta w_{ij}(it)$$

Para fijar el aprendizaje del MLP deben conservarse las frecuencias $[f_\mu]$ al “cerrarse” el SOM.


efector utiliza valores entre $[-10;+10]$ para representar el sentido y la velocidad de cada motor.

Resultados

Para observar cuantitativa y cualitativamente la capacidad aprehensiva del SSP, se le utilizó como sistema de control para un robot virtual cuyo sistema perceptivo simula dos sensores ultrasónicos fronto-laterales y, cuyo sistema efector simula la tracción diferencial central propia de una plataforma circular con dos motores y dos pivotes. La información numérica de cada sensor está entre $[-10;+10]$ y representa la distancia relativa con respecto a los obstáculos en un laberinto virtual, mientras la información del sistema

En la figura 1 se muestra la arquitectura del MLP cuyas neuronas sensoriales {A,B} reciben la información perceptiva del *robot*, mientras las neuronas efectoras {C,D} entregan la información motriz, según el contenido de las matrices sinápticas $[W_{ij}]$ en cada iteración del sistema. Para permitir el entrenamiento del MLP mediante el algoritmo LMS se utilizaron sigmoidales bipolares entre $[-10;+10]$ como funciones de activación en las neuronas intermedias y en las efectoras. La figura 3a muestra los patrones utilizados para que dicho robot desarrollara el hábito de evadir los obstáculos en el laberinto virtual.


Figura 1. Perceptrón multicapa con 2 neuronas sensoriales, 5 intermedias y 2 ectoras



En la figura 2 se muestra la arquitectura del SOM cuyas neuronas sensoriales {A,B,C,D} reciben la información sensorial y motriz del MLP entrenado anteriormente. Con este SOM y otro MLP como el de la figura 1 se conformó un SSP para controlar un segundo robot virtual. Con el fin de entrenar dicho sistema, se le hizo “observar” y asimilar la conducta

del primer robot mientras éste se movía libremente en el laberinto virtual. Tras el “cierre” cognitivo del SOM se utilizaron los patrones *asimilados* para entrenar el respectivo MLP, con lo cual el segundo *robot* habitó una conducta semejante a la del primero. En la figura 3b pueden observarse dichos patrones, sin embargo, su organización es diferente según la forma del laberinto.

Figura 2. Mapa auto-organizado con 4 neuronas sensoriales y [8x8] cognitivas





En las figuras 3a y 3b cada punto está compuesto por coordenadas (t_c, t_d) , lo cual corresponde a la combinación de salidas deseadas en cada posible patrón $[p_\mu]$. En juntas gráficas, los patrones de entrenamiento se indican con puntos de color fucsia y los de generalización

se indican con puntos de color violeta, mientras que los patrones excluidos por la función $[P_\mu]$ se indican con puntos grises en la figura 3b. Este resultado se obtuvo utilizando las siguientes constantes: $[A_i=1]$, $[A_f=0,1]$, $[R_i=2]$, $[R_f=1]$, $[\lambda_i=10]$, $[\lambda_f=0]$, $[it_f=10000]$ y,

considerando la frecuencia promedio de perturbaciones en el SOM, se utilizó el 100% de dicho valor como

frecuencia crítica $[f_c]$ para determinar el factor $[e_\mu]$, y el 70% para determinar el factor $[g_\mu]$.

Figura 3. a) Patrón conductual del robot-instructor, b) Patrón conductual del robot-imitador



Discusión

Debe aclararse que el *robot-imitador* no “observa” al *robot-instructor* como sucede entre dos primates, pues el SSP del imitador está directamente vinculado al MLP del instructor, es decir, las neuronas sensoriales {A,B,C,D} del SOM –en el SSP del imitador, reciben exactamente la información presente tanto en las neuronas sensoriales {A,B} como en las efectoras {C,D} del MLP correspondiente al instructor. En comparación, los agentes de Curran y O’Riordan, (2004) utilizan cierta comunicación verbal donde el agente-tutor no le “habla” al agente-pupilo como sucede entre dos personas, pues ciertas neuronas intermedias en la red neuronal del tutor están directamente vinculadas a neuronas análogas en la red neuronal del pupilo. Al respecto debe considerarse que el SSP no pretende simular por sí solo la gran complejidad perceptiva y cognitiva del cerebro, sino la función de un neuro-meme en la evolución cultural, por tanto la interconexión directa entre neuro-memes simples es válida, pues su existencia debió comenzar a pequeña escala y en cerebros individuales (Aunger, 2004).

Sobre cierta imperfección en el SSP

La diferencia entre las figuras 3a y 3b se debe a que el *robot-imitador* tan sólo “observó” la conducta manifiesta del *robot-instructor*, pues como este último

nunca operó por sí solo en las inmediaciones de los obstáculos, el imitador tan sólo asimiló los patrones correspondientes a dicha caracterización, sin embargo, el imitador logró reaccionar de forma semejante al instructor en las inmediaciones de los obstáculos. Al respecto debe considerarse que el *robot-imitador* es incapaz de “preguntarle” al instructor sobre ¿cómo actuar? en las situaciones poco evidentes y además, si la frecuencia experimental de ciertas situaciones es baja, entonces los respectivos patrones asimilados por el SOM probablemente no influyan en el entrenamiento del MLP, debido al efecto excluyente de la función $[P_\mu]$. Esto último resulta tan ventajoso como la mutación en la evolución genética, pues la variabilidad memética influye en la evolución cultural (Aunger, 2004) y, pudo observarse experimentalmente que los patrones asimilados por el SSP varían según la forma como el instructor le “expone” su conducta.

Sobre cierta moralidad en el SSP

En esta sección tan sólo se considerará el concepto freudiano del “super-yo” para detallar cierta capacidad moral implícita en el mecanismo de aprendizaje detallado en la sección (Imitación conductual: el aprendizaje en el SSP). Como el “super-yo” se encarga de asimilar las normas auto-supervisoras que el “yo” utiliza para aprender a controlar los apetitos instintivos del “ello” y, como el patrón de entrenamiento es para un

MLP como el “super-yo” es para el “yo” (Lahoz-Beltrá, 2004), entonces puede afirmarse que el SSP funciona como dicho sistema de auto-supervisión moral, pues el SOM del SSP asimila un conjunto de normas capaz de auto-corregir el comportamiento de su respectivo MLP y así, considerando al MLP como una especie de “yo” artificial, el SOM cumple el papel de “super-yo”. Este razonamiento permite ver las figuras 3a y 3b como patrones morales artificiales, y además permite afirmar que el conocimiento desarrollado por un SSP es jerárquico, pues el saber-hacer habitado por el MLP está subordinado al deber-hacer asimilado por el SOM.

Tanto las normas adquiridas por el SOM como la conducta desarrollada por el MLP se ubican específicamente en un contexto senso-motriz y, por ende, la moral desarrollada por un SSP es muy lejana de la moralidad en contextos socio-culturales. Sin embargo, la moral desarrollada por cada ser humano implica haber heredado genéticamente una gran capacidad cerebral y además, haber experimentado complejas situaciones individuales y sociales para asimilar un gran complejo de normas morales. Considerando a los memes como replicadores partícipes en dicho desarrollo individual y social, el lograr identificar al SSP como replicador neuro-memético abre la posibilidad de implementar un modelo computacional capaz de simular dicho desarrollo, como una especie de evolución cultural artificial. Al respecto no puede predecirse si emerjan agentes individualistas con libre albedrío, liderazgo político o doble moral, y tampoco puede predecirse la emergencia de agentes gregarios con cierta agresividad territorial, tendencias subversivas o fanatismo ideológico, por ejemplo. La evolución cultural artificial propuesta por Curran y O’Riordan, (2004) no se basa en el concepto de neuro-meme ni aborda implicaciones

morales entre los individuos de la población, sin embargo, permite confirmar que el lenguaje es un gran componente en dicha evolución, y sugiere considerarlo seriamente en la arquitectura del SSP mediante la inserción de capas neuro-lingüísticas.

Conclusión

Como el propósito de este artículo es identificar al SSP como un tipo de replicador neuronal, basta continuar el experimento de la sección Resultados y observar que un tercer *robot* dotado con SSP aprende a evadir obstáculos imitando al segundo *robot*, y así sucesivamente. Con esto puede afirmarse que dicho modelo evidencia las características replicativas de un neuro-meme, pues cuando un SSP con algún tipo de comportamiento estimula a otro, durante cierta cantidad de tiempo, le transfiere información senso-motriz, le induce un patrón de activación neuro-motriz similar y, al final resulta generando otro replicador con las mismas características.

El aporte específico de este trabajo es un modelo hipotético de replicación neuro-memética, el cual utiliza dos redes neuronales artificiales bastante conocidas, es capaz de imitar patrones conductuales mediante un proceso auto-supervisor con cierto carácter moral y, eventualmente es capaz de modificar dichos patrones mediante la relación instructor-aprendiz. Sin embargo, esta evidencia no permite asumir que el SSP pueda replicar comportamientos entre sistemas con la necesidad de comunicarse sin conexión neuronal directa, o entre sistemas estructuralmente diferentes. El trabajo subsiguiente podría encaminarse hacia el desarrollo de un algoritmo evolutivo basado en la replicación del SSP –incluyendo elementos lingüísticos– con el fin de lograr la emergencia de cierta complejidad a partir de su simplicidad.

Referencias

- Aunger, R. (2004). El meme eléctrico. Barcelona, Paidós.
- Borenstein, E. y Ruppin E. (2004). Envolving imitating agents and the emergence of a neural mirror system. *Artificial Life IX*, Cambridge, MIT Press, pp. 146-151.
- Curran, D. y O’Riordan, C. (2004). A comparison of population learning and cultural learning in artificial life societies. *Artificial Life IX*, MIT Press, Cambridge, pp. 152-157.
- Dawkins, R. (2002). El gene egoísta. 11ª Edición, Salvat, Barcelona.
- Fernando, C.; Goldstein, R. y Szathmáry, E. (2010). The neuronal replicator hypothesis. *Neural Computation*. MIT Press Journals, Vol. 22, N°. 11, pp. 2809–2857.

- Fernando, C. y Szathmáry, E. (2009). Chemical, neuronal and linguistic replicators. Towards an Extended Evolutionary Synthesis, MIT Press, Cambridge, pp. 209-249.
- Floreano, D., Mitri, S., Perez-Urbe, A., and Keller, L. (2008). Evolution of altruistic robots. Computational Intelligence: Research Frontiers Springer Verlag, pp. 232-248.
- Lahoz-Beltrá, R. (2004). Bioinformática, simulación, vida artificial e inteligencia artificial. Ediciones Díaz de Santos, Madrid.
- Moscato, P. y Cotta, C. (2010). A modern introduction to memetic algorithms. Handbook of Metaheuristics, 2ª Edición, Springer Verlag, pp. 141-183.

Sobre el autor

Dante Giovanni Sterpin Buitrago

Ingeniero electrónico. Especialista en Docencia Universitaria. Docente investigador de tiempo completo de la Corporación Unificada Nacional de Educación Superior, CUN, Bogotá (Colombia).

Ingeniero Electrónico de la Universidad Santo Tomás. Especialista en Docencia Universitaria de la Universidad Militar Nueva Granada.
dantesterpin@yahoo.com, dante_sterpin@cun.edu.co

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.