



Entrenamiento de Redes Neuronales Artificiales con Aprendizaje No Supervisado en el control de calidad del análisis

Training of Artificial Neural Networks with Unsupervised Learning in the quality control of the analysis

Treinamento de Redes Neurais Artificiais com Aprendizado Não Supervisionado no controle de qualidade da análise

Mario Gerardo Moreno-Pallares ^I
mario.moreno01@epn.edu.ec
<https://orcid.org/0000-0001-9083-8816>

Rodrigo Rigoberto Moreno-Pallares ^{II}
rodrigo.moreno@esPOCH.edu.ec
<https://orcid.org/0000-0003-1877-6942>

Edwin Fernando Mejia-Peñañafiel ^{III}
efmejia@esPOCH.edu.ec
<https://orcid.org/0000-0001-6888-4621>

Correspondencia: mario.moreno01@epn.edu.ec

Ciencias Técnicas y Aplicadas
Artículo de Revisión

* **Recibido:** 20 de marzo de 2022 * **Aceptado:** 18 de abril de 2022 * **Publicado:** 24 de mayo de 2022

- I. Magister en Computación Mención en Sistemas Inteligentes, Escuela Politécnica Nacional, Quito, Ecuador.
- II. Magister en Ingeniería Industrial y Productividad Msc, Escuela Politécnica Nacional, Quito, Ecuador.
- III. Magister en Informática Aplicada, Escuela Superior Politécnica de Chimborazo (ESPOCH), Riobamba, Ecuador.

Resumen

El aprendizaje automático tiene el propósito de entrenar a la computadora para realizar tareas rápidamente con grandes volúmenes de datos. En el presente trabajo se realiza la agrupación de un conjunto de datos de un vino el cual tiene tres características, una vez normalizado en formato .csv se realiza una comparación de un conjunto de datos utilizando redes neuronales artificiales, tales como: Red Neuronal de Auto- Mapa organizativo y una Red Neuronal Competitiva, combinando las propiedades de cada Red, se obtiene que para este caso particular es mejor que una Red Neuronal de Mapa Autoorganizador para la clasificación y que es la que menor porcentaje de error. Tenga en cuenta que se tomaron sus propiedades que han sido por defecto en el entorno MATLAB.

Palabras Clave: Redes Neuronales Artificiales; Red Mapa Autoorganizativo; Red Neuronal Competitiva; SOM; Aprendizaje no Supervisado.

Abstract

The machine learning has the purpose of training the computer to perform tasks quickly with large volumes of data. In the present work, the grouping of a data set of a wine which has three characteristics is performed, once normalized in a .csv format, a comparison of a data set is made using artificial neural networks, such as: Neural Network of Self-organizing Map and a Competitive Neural Network, combining the properties of each Network, it is obtained that for this particular case it is better than a Neuronal Network of Autoorganizing Map for the classification and that is the one that lower percentage of error. note that their properties were taken that have been by default in the MATLAB environment.

Keywords: Artificial Neural Networks; Self-organizing Map Network; Competitive Neural Network; SOM; Unsupervised Learning.

Resumo

O aprendizado de máquina tem o objetivo de treinar o computador para executar rapidamente tarefas com grandes volumes de dados. No presente trabalho é realizado o agrupamento de um conjunto de dados de um vinho, que possui três características, uma vez normalizado em formato .csv, é feita uma comparação de um conjunto de dados utilizando redes neurais artificiais, tais como: Rede Neural de Auto - Mapa Organizacional e uma Rede Neural Competitiva, combinando as propriedades de cada Rede, obtém-se que para este caso particular é melhor do que uma Rede

Neural de Mapa Auto-Organizável para classificação e que é a que apresenta o menor percentual de erro. Observe que suas propriedades foram retiradas do padrão no ambiente MATLAB.

Palavras-chave: Redes Neurais Artificiais; Rede de Mapas auto-organizada; Rede Neural Competitiva; SOM; Aprendizagem não supervisionada.

Introducción

El machine learning también conocido como aprendizaje de máquina tiene como propósito entrenar a la computadora para realizar ciertas tareas rápidamente, en grandes volúmenes y con el menor error posible. Esto se lo hace a través del aprendizaje de patrones con base en ejemplos. Las redes con aprendizaje no supervisado no requieren de la influencia externa para el ajuste de sus pesos de las conexiones entre sus neuronas, estas redes encuentran las características, correlaciones o categorías que pueden establecer los datos de entrada[1].

A través de la página <https://archive.ics.uci.edu/ml/datasets/wine> se obtuvo un conjunto de datos de los resultados de un análisis químico de vinos cultivados en una misma región en Italia, pero derivado de tres cultivares diferentes, el conjunto de datos especifica trece variables, la primera variable da a conocer a cuál de las tres de clases de vino pertenece la información[2].

En el presente trabajo se realizó el clustering del conjunto de datos en cuestión utilizando una Red Neuronal Competitiva y una Red Neuronal de Mapa Autoorganizativo (SON o SOFM) para la comparación de que red realizó de mejor manera la clasificación de los dato, tomando en cuenta el error que produjeron cada una de ellas, se modificaron las propiedades de cada una de las redes y se observó el error producido. Para realizar este trabajo se usó el entorno de MATLAB.

El presente trabajo la Sección II denominada Metodología y Materiales se encuentra el marco teórico y la metodología usada para resolver el problema planteado, la Sección III Resultados muestra los datos que se obtuvo al realizar el cambio de las propiedades en las redes, la Sección IV Discusión de los resultados obtenidos y Sección V Conclusiones muestra las conclusiones en base a los resultados obtenidos.

Metodología y materiales

Las Redes Neuronales Artificiales (ANN) con aprendizaje no supervisado también conocidas como autosupervisado no requieren de influencia externa para ajustar los pesos de las conexiones entre

sus neuronas. Le red no recibe ninguna información por parte del entorno que le indique si la respuesta generada es correcta o no a una determinada entrada[3], [4].

Estas redes encuentran las características, correlaciones o categorías que puedan establecer entre los datos de entrada. Hay varias posibilidades en la interpretación de la salida de estas redes, que dependen de su estructura y del algoritmo de aprendizaje que utilizan. Por lo general se consideran dos tipos de algoritmo de aprendizaje no supervisado, que dan lugar a los siguientes tipos de aprendizaje[3], [5]:

- Aprendizaje Hebbiano.
- Aprendizaje competitivo y comparativo.

El aprendizaje Hebbiano es la regla base para muchas otras, esta pretende medir la familiaridad de los datos de entrada. Se basa en una suposición simple: si dos neuronas N_i y N_j toman el mismo estado simultáneamente (activas o inactivas) el peso de la conexión entre ambas se incrementa. Las entradas y salidas de la neurona son: $\{-1,1\}$ o $\{0,1\}$. [3]

El aprendizaje competitivo se orienta a la clustrización o clasificación de los datos de entrada, como una característica importante es que si un patrón Nuevo se determina que pertenece a una clase reconocida con anterioridad, entonces la inclusión de este nuevo patrón a esta clase matizará la representación de la misma. Si el patrón de entrada se determinó que no pertenece a ninguna de las clases que se tiene, entonces los pesos de la red neuronal serán ajustados para reconocer la nueva clase. Antes de realizar el entrenamiento se escogen los pesos iniciales para las diversas conexiones entre las neuronas de la red neuronal. Esto es realizado por varios criterios, por ejemplo otorgar pesos aleatorios a cada conexión, encontrándose los mismos dentro de un cierto intervalo[3], [5].

Para detener el aprendizaje es necesario establecer una condición de detención. Normalmente el entrenamiento se detiene cuando el cálculo del error cuadrado sobre todos los ejemplos de entrenamiento ha alcanzado un mínimo o cuando para cada uno de los ejemplos dados, el error observado está por debajo de un umbral. Otra condición de detención del aprendizaje puede ser cuando un cierto número de ciclos de entrenamiento hayan sido completamente corridos[3].

Existen dos tipos de codificación de los datos de entrada, como lo son[3]:

- Variable o atributos numéricos (continuo).
- Variable o atributos simbólicos (discreto).

Un atributo numérico es aquel que puede tomar cualquier valor dentro de un interval $[a, b]$; donde a puede ser $-\infty$ y b puede ser ∞ .

La arquitectura de una red neuronal consiste en la organización de las neuronas de la misma, en la formación de las capas de neuronas que están más cerca o no de la entrada y salida de la red. Los parámetros fundamentales de la red son: el número de capas, neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas. Las redes monocapa establecen conexiones entre las neuronas que pertenecen a la única capa que constituye la red[3], [5].

Redes multicapa son aquellas que disponen de un conjunto de neuronas agrupadas en varias capas. Normalmente todas las neuronas de una capa reciben señales de entrada desde otra capa anterior y envían señales de salida a una capa posterior, a estas conexiones se las denomina conexiones hacia adelante o feedforward[3], [5]. Existen de igual manera redes que pueden conectar la salida de las neuronas de capas posteriores a la entrada de capas anteriores, a estas capas se las denomina conexiones hacia atrás o feedback[3], [5].

Las Redes Neuronales Competitivas pertenecen a una clase de redes recurrentes y se basa en algoritmos de aprendizaje no supervisado. En el aprendizaje competitivo las neuronas de salida de una red neuronal compiten entre sí para activarse, en el aprendizaje competitivo solo una neurona de salida está activa en cualquier momento. Por lo general existen tres elementos necesarios para construir una red con una regla de aprendizaje competitivo[5], [6]:

1. Un conjunto de neuronas que tiene la misma estructura y que están conectadas con pesos seleccionados inicialmente al azar.
2. Un valor límite se determina según la fuerza de cada neurona.
3. Un mecanismo que permite a las neuronas completar el derecho a responder a un subconjunto dado de entradas, de manera que solo una neurona salida este activa a la vez.

En la forma más sencilla de aprendizaje competitivo una Red Neuronal Artificial tiene un sola capa de neuronas de salida, cada una de las cuales están totalmente conectadas a los nodos de entrada. La competencia entre las neuronas de la capa de salida se implementa mediante la inhibición lateral, un conjunto de conexiones negativas entre neuronas. El más conocido entre este paradigma de las redes neuronales es el Mapa Autoorganizativo (SOM) de Kohonen[6].

La red de Kohonen consiste en una capa de entrada que distribuye las entradas a cada nodo en la segunda capa, llamada capa competitiva, cada nodo de esta capa actúa como un nodo de salida. Cada neurona en la capa competitiva está conectada a otras neuronas en su vecindad y la retroalimentación se restringe a las vecinas a través dichas conexiones laterales[3], [5], [6]. Las neuronas en la capa competitiva tienen conexiones excitadoras con vecinos inmediatos y

conexiones inhibitorias con neuronas más distantes. Todas las neuronas de la capa competitiva reciben una mezcla de señales excitadoras e inhibitorias de las neuronas de la capa de entrada y otras de neuronas de la capa competitiva[6].

A medida que se presenta un patrón de entrada, algunas de las neuronas están suficientemente activadas para producir salidas que se retroalimentan a otras neuronas en sus vecindarios[6]. El nodo con el vector de peso más cercano al vector del patrón de entrada produce la salida más grande. Durante el entrenamiento los pesos de entrada de la neurona ganadora y sus vecinos se ajustan para que se aparezcan mucho más al patrón de entrada[6].

Al finalizar el entrenamiento el nodo ganador termina con su vector de peso alineado con el patrón de entrada y produce la salida más fuerte cada vez que se presenta ese patrón particular. Los nodos en el vecindario del nodo ganador también tienen sus pesos modificados para establecer una representación promedio de esa clase de patrón. Como resultado los patrones invisibles que pertenecen a esa clase también se clasifican correctamente. Se dice que los barrios m , correspondientes a las m clases de patrones posibles forman un mapa topológico que representan los patrones[5], [6].

Metodología

El conjunto de datos a realizar el clustering correspondiente se la obtuvo de la página web: <https://archive.ics.uci.edu/ml/datasets/wine>, que son datos de los resultados de un análisis químico de vinos cultivados en una región en Italia derivado de tres cultivares diferentes. El análisis determinó las cantidades de trece componentes en cada uno de los tres vinos, los atributos son: alcohol, ácido málico, ceniza, alcalinidad de las cenizas, magnesio, fenoles totales, flavonoides, fenoles no flavonoides, proantoacianinas, intensidad de color, hue, OD280/OD315 de vinos diluidos y prolina; todos los atributos son continuos[2].

Para este trabajo se eliminó el primer atributo ya que este mostraba la clase del vino a la que pertenece, este atributo ayudó a encontrar el error del clustering que se realizó.

Los datos del conjunto de datos correspondiente fueron normalizados mediante el método MIN-MAX, su fórmula es la siguiente:

$$v = \frac{v' - \min_a}{\max_a - \min_a} (\text{nuevoMax}_a - \text{nuevoMin}_a) + \text{nuevoMin}_a$$

Donde:

$$\text{nuevoMax}_a = 1;$$

$$\text{nuevoMin}_a = 0;$$

min_a = menor cantidad del atributo correspondiente

max_a = mejor cantidad del atributo correspondiente

v' es cada uno de los valores del conjunto de datos

Mediante el entorno de MATLAB se procedió a la lectura del conjunto de datos una vez que se han normalizado, el conjunto de datos normalizado se le asignó la extensión .csv; para la lectura de este tipo de archive se utilizó la función *csvread* proporcionada por MATLAB y guardada a la vez en una variable P , luego a la variable P se le asigna P' (transpuesta).

Cabe recalcar que el procedimiento anteriormente descrito se aplica a los dos tipos de redes creadas, y el cambio de las propiedades se lo realiza de igual forma a los dos tipos de redes. Para la creación de una Red Neuronal de Mapa Autoorganizativo (SOM) se utilizó la función *newsom* proporcionada por MATLAB y como tamaño de red se le aplicó [3 1].

Para la creación de una Red Neuronal Competitiva se lo hizo con la función *nwec* proporcionada por MATLAB, con un número de neuronas de tres.

Para los dos tipos de redes del presente trabajo se tomó como numero de épocas el valor de 1000. Para el cálculo del error en cada una de las redes se aplicó un bucle *for* que cuente el número de coincidencias en cada uno de los datos del conjunto de datos y se verificó con el número de clases del conjunto de datos original así obteniendo el número de valores clasificados de forma correcta. Para la Red Neuronal de Mapa Autoorganizativo se realizó la combinación de la función de topología y la función de distancia, manteniendo las demás propiedades que están por defecto, de la siguiente manera:

- hextop – linkdist
- gridtop– linkdist
- randtop-linkdist
- hextop-dist
- hextop-mandist
- gridtop-dist

- gridtop-mandist
- randtop-dist
- randtop-mandist
- por defecto en MATLAB

Además al conjunto de datos se le retiró la última característica perteneciente a prolina y se realizó la ejecución con los datos que están por defecto, esto se lo hizo con el objetivo de ver el comportamiento del error.

Para la creación de la Red Neuronal competitiva se combinaron los datos de tasa de aprendizaje de Kohonen y la tasa de aprendizaje, de la siguiente forma:

- por defecto en MATLAB.
- 0.05-0.001
- 0.01-0.005
- 0.01-0.002
- 0.01-0.0005
- 0.005-0.0005
- 0.008-0.0008
- 0.009-0.0009
- 0.007-0.0007

Como en el caso anterior en esta red también se ejecutó la red con sus propiedades que vienen por defecto y retirando la última característica perteneciente a prolina, esto se lo hizo con la finalidad de ver el comportamiento del error

Resultados

En la creación de la Red Neuronal de Mapa Autoorganizativo (SOM) se realizaron 10 ejecuciones con diferentes valores en la función de topología de la red (TFCN) y en la función de distancia (DFCN), como se indica a continuación en la Tabla 1.

TABLA I
CANTIDADES RED NEURONAL AUTOORGANIZATIVA

| TFCN | DFCN | %Error |
|-----------------------|-----------------------|---------|
| hextop | linkdist | 16.8539 |
| gridtop | linkdist | 17.4157 |
| randtop | linkdist | 16.8539 |
| hextop | dist | 17.4157 |
| hextop | mandist | 17.4157 |
| gridtop | dist | 16.8539 |
| gridtop | mandist | 17.4157 |
| randtop | dist | 17.4187 |
| randtop | mandist | 17.4187 |
| defecto | defecto | 10.1124 |
| defecto(12 atributos) | defecto(12 atributos) | 7.8652 |

Tabla de valores de la Red Neuronal de Mapa Autoorganizativo.

En la creación de la Red Neuronal Competitiva se realizaron nueve ejecuciones con la combinación en las propiedades de la red como lo es en: Tasa de Aprendizaje de Kohonen (KLR) y Tasa de Aprendizaje de Consciencia (CLR), se obtuvieron los datos que se muestran en la Tabla 2.

TABLA II
CANTIDADES RED NEURONAL COMPETITIVA

| KLR | CLR | %Error |
|-----------------------|-----------------------|---------|
| defecto | defecto | 13.4831 |
| 0.05 | 0.001 | 15.7303 |
| 0.01 | 0.005 | 44.9438 |
| 0.01 | 0.002 | 30.3371 |
| 0.01 | 0.0005 | 12.3596 |
| 0.005 | 0.0005 | 12.3596 |
| 0.008 | 0.0008 | 15.7303 |
| 0.009 | 0.0009 | 11.2360 |
| 0.007 | 0.0007 | 20.2247 |
| defecto(12 atributos) | defecto(12 atributos) | 24.7191 |

Tabla de valores de la Red Neuronal Competitiva.

Discusión

En el presente trabajo en el que se realizó el clustering de un conjunto de datos de trece características con tres distintas clases de vino, mediante una Red Neuronal de Mapa Autoorganizativo y una Red Neuronal Competitiva.

Para este caso en particular se obtuvieron errores menores al 18% en la utilización de una Red Neuronal de Mapa Autoorganizativo con la variación de sus propiedades en la Función de Topología de la red y en la Función de Vecindad que tiene dicha red.

Mientras tanto en el uso de una Red Neuronal Competitiva se obtuvieron cantidades altas de error en algunos casos sobrepasan el 30%, para este caso que se ha presentado con la variación en la Tasa de Aprendizaje de Kohonen y en la Tasa de Aprendizaje de Consciencia.

Tomando en cuenta las ejecuciones últimas a cada red correspondiente en las que solo se tomaron doce atributos en la Red Neuronal de Mapa Autoorganizativo (SOM) se tiene un error menor al 10%, por otra parte en la Red Neuronal Competitiva su error no es significativo.

Conclusiones

Utilizar una Red Neuronal de Mapa Autoorganizativo con sus propiedades que tiene por defecto, para el conjunto de datos mencionado tiene un error de 10.1124% por lo que es una señal significativamente alta de una clasificación correcta realizada.

Para este caso es mucho mejor utilizar en el conjunto de datos solo doce características de las trece ya que así su error es del 7.8652%.

La Red Neuronal Competitiva en su menor porcentaje de error es de 11.2360% esto se presenta cuando la Tasa de Aprendizaje de Kohonen es 0.009 y la Tasa de Aprendizaje de Consciencia es 0.0009.

Referencias

- [1] “Machine Learning: Qué es y para qué sirve el Clustering - Kueski.com.” [Online]. Available: <https://kueski.com/blog/tecnologia/machine-learning-que-es-clustering/>. [Accessed: 14-Dec-2018].
- [2] “UCI Machine Learning Repository: Wine Data Set.” [Online]. Available: <https://archive.ics.uci.edu/ml/datasets/wine>. [Accessed: 14-Dec-2018].
- [3] C. Alberto Ruiz Marta Susana Basualdo Autor and D. Jorge Matich, “Cátedra: Informática Aplicada a la Ingeniería de Procesos-Orientación I Redes Neuronales: Conceptos Básicos y Aplicaciones.”
- [4] “6 COMPETITIVE NETWORKS AND COMPETITIVE LEARNING.”
- [5] L. B. Neto, “Aprendizado não supervisionado.”
- [6] T. Kohonen and T. Honkela, “Kohonen network,” *Scholarpedia*, vol. 2, no. 1, p. 1568, 2007.