

# Complejidad en redes neuronales - retropropagación

## Complexity in backpropagation neural networks

---

Vargas Sánchez Germán Gonzalo

### Resumen

**E**ste artículo muestra una forma para aplicar el concepto de complejidad a redes neuronales artificiales, particularmente a las que utilizan el método backpropagation. Apoyados en el principio hologramático del pensamiento complejo se encontró un método para preparar los datos de entrada a la red neuronal de acuerdo con los valores esperados de las salidas, separando los datos en dos conjunto los cuales tienen como patrones de entrenamiento el promedio de cada conjunto de datos.

**Palabras Clave:** redes neuronales artificiales, retropropagación, complejidad.

### Abstract

**T**his article shows a way to apply the concept of complexity to artificial neural networks, particularly those that use the backpropagation method. Supported by the hologrammatic principle of complex thinking, a method was found for preparing input data to the neural network according to the expected values of the outputs, separating the data into two sets which have the training average as a set. of data

**Keywords:** artificial neural networks, backpropagation, complexity.

---

Recibido / Received: Febrero 21 del 2017 Aprobado / Aproved: Marzo 21 del 2017

Tipo de artículo / Type of paper: Investigación Científica y Tecnológica Terminada.

Afiliación Institucional de los autores / Institutional Affiliation of authors: Multiversidad Mundo Real Edgar Morin Mexico

Autor para comunicaciones / Author communications: germanvargas@unbosque.edu.co

*El autor declara que no tiene conflicto de interés.*

## Introducción

Se pretende mostrar que los modelos predictivos arrojados por las redes neuronales artificiales presentan algunas falencias y se propone buscar una forma para lograr mejorar la predicción utilizando conceptos de complejidad en los datos de entrenamiento de las redes neuronales. [1] [2]

Hoy en día existen varias formas y métodos que permiten preparar los datos de entrenamiento de las RNA (Redes Neuronales Artificiales), sin embargo no existe un método que sea estandarizado y la predicción arrojada por las RNA muestran falencias al no lograr predecir datos que ocurrieron. [3] [4] [5] [6] [7]

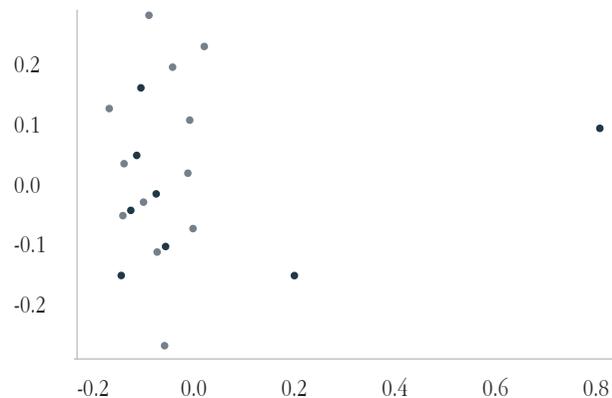
Desde el paradigma de la complejidad, se hace un análisis del comportamiento de las redes neuronales artificiales, aplicando el método *backpropagation*, que incluye una descripción del método y una investigación de su comportamiento al iterar una red neuronal con datos que posean elementos de complejidad. [8] [9] [10] [11]

Las redes neuronales artificiales deben ser abordadas por la investigación desde el paradigma de la complejidad y no desde el paradigma simplificante, pues actualmente se descartan y desechan datos, lo cual no debería ocurrir si los datos poseen elementos de complejidad. Se realizará un análisis en diferentes escenarios mediante la experimentación con el uso de datos de entrenamiento azarosos versus datos que poseen elementos de complejidad. Para Saber cómo están distribuidos los datos que se ingresan a una red neuronal, se utilizó la técnica de PCA (Análisis de Componentes Principales).

Suponga que se ha realizado un análisis de una situación la cual posee  $n$  dimensiones. Además se ha clasificado su salida en dos clases, los datos con salida color rojo y los datos con salida color azul. Para poder conocer como están distribuidos los datos de  $n$  dimensiones, se recurrió a la técnica mencionada y se obtienen datos, puede ser en dos dimensiones, como los mostrados en la Figura 1. que dan una idea de la distribución de los datos.

El problema del método *backpropagation* por el cual la predicción no es acertada en algunos casos, se debe a que los datos de entrenamiento de la RNA son al azar. Suponga que se ha escogido como dato de entrenamiento para los azules, el dato que se encuentra muy alejado del resto de los datos. (Observe la Figura 1). Esto no da garantía de una buena predicción.

Figura 1. Distribución de los datos. Técnica utilizada PCA



Para el desarrollo de esta investigación se buscó y encontró un método que garantiza que los datos de entrenamiento de la red sean complejos. Esto se logró aplicando un algoritmo aritmético entre los datos a modelar. Posteriormente se utilizó el resultado obtenido, como datos que hacen parte de la capa de entrada y que sirven de datos de entrenamiento para la red.

## Metodología

1. Se revisó el funcionamiento del algoritmo *backpropagation*.
2. Se comprendió la forma como se ejecuta el algoritmo
3. Se realizaron tres (3) experimentos en las mismas condiciones, es decir, con la misma cantidad de neuronas en la capa de entrada y con la misma tasa de aprendizaje.
4. Para cada uno de los experimentos se realizó lo siguiente:
  - Se estandarizaron los datos de entrada y se ejecutó la red neuronal.
  - Se estandarizaron los datos por grupos y se ejecutó la red neuronal.
5. Se ejecutó cada experimento utilizando el método tradicional y el método complejo producto de esta investigación.
6. Se compararon los datos de los experimentos contrastando para cada caso el método tradicional vs el método complejo.

## Desarrollo

### La hipótesis

Al aplicar elementos de complejidad en los datos de entrada de una red neuronal que utiliza el método *backpropagation*, el modelo predictivo arrojado por la red, mejora.

### El problema

¿De qué forma es posible aplicar el concepto complejidad a las redes neuronales artificiales para lograr analizar el comportamiento de los modelos predictivos producidos por el método *backpropagation*?

### Método tradicional

En este método los valores de entrenamiento de la red neuronal utilizando el algoritmo *backpropagation* son seleccionados al azar, de esta forma es posible que el modelo de predicción construido por la red, deseche datos reales y no haya una predicción total de los datos. [12] [13] [14] [15] [16].

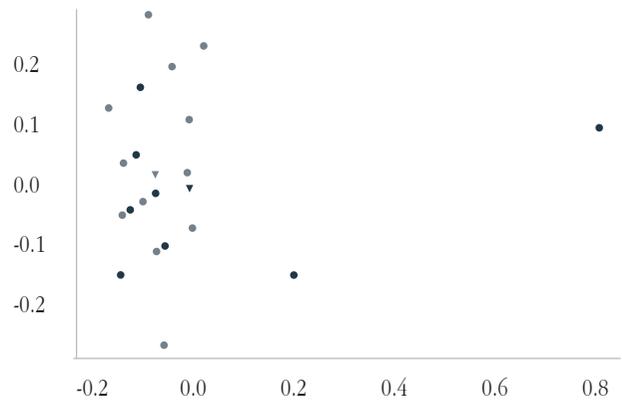
### Método con elementos de complejidad

La forma o método que se propone para establecer y garantizar que los datos de entrada de la red neuronal no son al azar, sino complejos, consiste en relacionar los datos por grupos, de acuerdo con los valores de salida. La relación se hace a través de los valores promedio de cada grupo. Estos serán los nuevos valores de entrenamiento para la red neuronal. Debe tenerse en cuenta el tamaño de la muestra, incluyendo los valores de entrenamiento, los cuales son aproximadamente el 10% de la totalidad de los datos, que es lo sugerido por el método *backpropagation*. [15] [16] [17]

Se utiliza la técnica de PCA para mostrar la distribución de los datos una vez aplicada la forma antes mencionada. Observe que los triángulos de cada color son los nuevos datos de entrenamiento para la RNA.

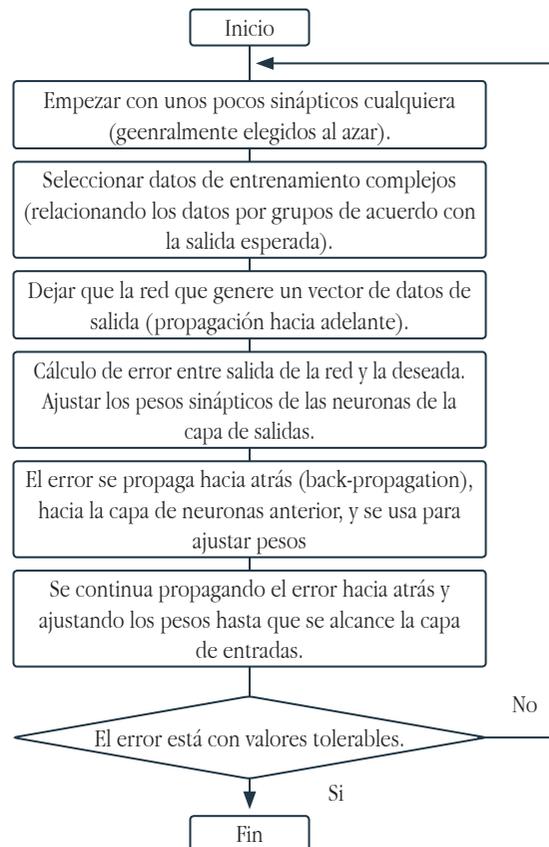
Observe que estos nuevos datos de entrenamiento tienen relación con los datos del grupo al cual pertenecen; los datos representados con el triángulo azul, son los representantes de los datos con color azul, lo mismo ocurre en el caso de los datos con color rojo.

**Figura 2.** Distribución de los datos, incluyendo los nuevos datos de entrenamiento para la RNA.



Con esto quedan preparados o listos los datos de entrenamiento para la RNA, garantizando que los datos de entrada a la red no son al azar sino complejos. En la Figura 3, puede observarse el flujo del proceso para el método descrito anteriormente.

**Figura 3.** Diagrama de Flujo. Método con elementos de complejidad



La función de transferencia utilizada para la investigación fue la Sigmoide, descrita como:  $z_i = \frac{1}{1 + e^{-n_i}}$ , donde  $n_i = W_{12}Z_2 + W_{13}Z_3 + W_{14}(+1)$

## Resultados

- Se encontró una forma para que el método *back-propagation* mejore la predicción, utilizando el concepto de complejidad entre los datos. El concepto de complejidad entre los datos se obtiene cuando por cada salida se calcula el valor promedio de los datos de entrada, creando una relación para cada conjunto de datos. Estos valores promedios serán los nuevos valores de entrenamiento de la red.
- Se muestran tres experimentos donde se comparan los métodos tradicional vs complejo, producto de la investigación realizada.

Los experimentos realizados fueron:

- Experimento financiero
- Experimento colegios
- Experimento diabetes

### El experimento financiero

- Consiste en construir un modelo de predicción para saber si una empresa quebrará o no. Las dimensiones o variables que se utilizaron fueron:

X1: (flujo de caja)/(deuda total)

X2:(ingreso neto)/(total de activos)

X3:(activos corrientes)/(pasivos corrientes)

X4:(activos corrientes)/(ventas netas)

Grupo 1: Empresas en bancarrota

Grupo 2: Empresas sanas financieramente

Los datos fueron tomados del ejemplo realizado por la Universidad de Buenos Aires, en Argentina (Johnson & Wichern, 1988, pág. 263).

### Experimento colegios

Se realizó un análisis en 20 colegios de Bogotá, con el objetivo de detectar la pérdida académica del año escolar,

para lo cual se tomaron como datos de entrada a la red las siguientes variables:

X1: Cantidad de profesores / la cantidad de alumnos,

X2: Número de materias perdidas / Número de materias totales.

X3: Número de fallas / Número de días.

X4: Número de estudiantes que almuerzan / Número total de estudiantes.

X5: Número de estudiantes que están remitidos a psicología / Número total de estudiantes

El dato de salida hace referencia para cada colegio, si más del 10% de los estudiantes de cada colegio pierde el año; siendo el valor cero (0) si perdió el año y el valor uno (1) si no lo pierde.

### Experimento diabetes

Hace referencia a datos de 768 pacientes de indígenas Pima cuyo objetivo es construir un modelo de predicción para saber si las pacientes presentan signos de diabetes o no. Los datos se encuentran distribuidos en dos grupos. El grupo cero (0) corresponde con las pacientes que no presentan signos de diabetes y el grupo uno (1) con las pacientes que sí presentan signos de diabetes.

Las variables utilizadas fueron:

Preg: Número de veces que ha estado embarazada

Plas: Concentración de glucosa de plasma unas

Pres: Presión arterial diastólica (mm Hg)

Skin: Grosor del pliegue cutáneo (mm)

Insu: Nivel de insulina (mu U / ml)

Indice de masa corporal (peso en kg / (altura en metros) <sup>2</sup>)

Pedi: Función de la diabetes pedigri

Age: Edad en años

La fuente de los datos es: Instituto Nacional de Diabetes y Enfermedades Digestivas y Enfermedades del Riñón. El donante de la base de dato es: Vicente Sigillito (vgs@aplcn.apl.jhu.edu).

- Al ejecutar la red neuronal utilizando el método *backpropagation* con elementos de complejidad en los datos de entrada para cada uno de los experimentos mencionados, la predicción arrojada por la red mejora, respecto a si los datos de entrada se seleccionan al azar. Los resultados se pueden observar en la Tabla 1.

**Tabla 1.** Resumen de resultados de los experimentos, Tradicional vs. Complejo.

| Experimento | Predicción con datos de entrada azarosas | Predicción con datos con complejidad |
|-------------|--|--------------------------------------|
| Financiero  | 97,6%                                    | 100%                                 |
| Colegios    | 94,4%                                    | 100%                                 |
| Diabetes    | 76%                                      | 99,3%                                |

## Conclusiones

Una de las formas para incluir elementos de complejidad en los datos de entrada de una red neuronal, es calcular los valores promedio de los datos de entrada por grupos, de acuerdo con el valor de la salida deseado e incluirlos como patrones de entrenamiento de la red.

Otra forma en la cual se pueden aplicar elementos de complejidad a las redes neuronales es a través del método de “Normalización de los datos”, puesto que relaciona cada uno de los datos de la red con el promedio del total de los datos, así como de la desviación estándar.

Al realizar una variación al método de “Normalización de los datos”, realizando la normalización por grupos de acuerdo con la salida esperada, la predicción arrojada por la red mejora considerablemente y el modelo predictivo converge más rápidamente hacia la salida deseada.

Con respecto a la hipótesis de esta investigación, se afirma que al utilizar elementos de complejidad en los valores de entrenamiento de una red neuronal los valores de los pesos utilizados para el cálculo de las salidas, convergen más rápidamente hacia el valor deseado.

Los datos de entrenamiento de una red neuronal deben ser pre-procesados y poseer elementos de complejidad

para obtener mejor rendimiento y predicción en la red que si se escogen al azar. Es posible obtener una muy buena predicción de los datos, en redes neuronales si se utilizan elementos de complejidad en los datos de entrenamiento.

## Referencias

- [1] Luna, P. T., Eleuterio, R. A., Rosas, R. M. V., & Méndez, B. G. R. (2010). Optimización del entrenamiento para Redes Neuronales Artificiales. *CIENCIA ergo-sum*, 17(3), 313-317.
- [2] Marco Antonio Valencia Reyes<sup>1</sup> Cornelio Yáñez Márquez<sup>2</sup>, & Fernández<sup>3</sup>, L. P. S. (2006). Algoritmo Backpropagation para Redes Neuronales: conceptos y aplicaciones. Thesis.
- [3] Izaurieta, F., & Saavedra, C. (1999). Redes Neuronales Artificiales. *Charlas de Física*, 1–15. doi:10.1016/S0210-5691(05)74198-X
- [4] Martinj Del Brio, B., & Serrano Cinca, C. (1995). Fundamentos De Las Redes Neuronales Artificiales: Hardware Y Software. Scire. Representación Y Organización Del Conocimiento, 1, 103–125. Retrieved from <http://ibersid.eu/ojs/index.php/scire/article/view/1036/1018>
- [5] Montaña, J. J. (2002). Redes Neuronales Artificiales aplicadas al Análisis de Datos. *Network*, 275.
- [6] Palmer Pol, a, & Montaña Moreno, J. J. (1999). ¿Qué son las redes neuronales artificiales? Aplicaciones realizadas en el ámbito de las adiciones. *Adiciones*, 11, 243–256. Retrieved from <http://disi.unal.edu.co/~lctorres/RedNeu/LiRna001.pdf>
- [7] Phansalkar, V. V., & Sastry, P. S. (1994). Analysis of the backpropagation algorithm with momentum. *IEEE Transactions on Neural Networks*, 5, 505–506. doi:10.1109/72.286925
- [8] Flores Burgess, A., Prieto Riascos, L., & Llaverro Bernal, F. (2011). Redes neuronales como sistemas complejos adaptativos.
- [9] Maldonado, C. E., & Cruz, N. A. G. (2011). El mundo de las ciencias de la complejidad: una investigación

sobre qué son, su desarrollo y sus posibilidades. Editorial Universidad del Rosario, Universidad Colegio Mayor de Nuestra Señora del Rosario, Facultad de Administración.

- [10] Toribio, P., & Alejo, R. (2009). Complejidad de los datos en las Redes Neuronales Artificiales: Estado de la cuestión. In 7 Congreso Internacional de Cómputo en Optimización y Software, CICOS.
- [11] Zhang, H., Xu, D., & Zhang, Y. (2014). Boundedness and convergence of split-complex backpropagation algorithm with momentum and penalty. *Neural Processing Letters*, 39, 297–307. doi:10.1007/s11063-013-9305-x
- [12] Che, Z.-G., Chiang, T.-A., & Che, Z.-H. (2011). Feed-forward neural networks training: A comparison between genetic algorithm and backpropagation learning algorithm. *International Journal of Innovative Computing, Information and Control*, 7, 5839–5850.
- [13] Fahlman, S. E., & Fahlman, S. E. (1988). An empirical study of learning speed in backpropagation networks. *Neural Networks*, 6, 1–19. Retrieved from <http://scholar.google.com/scholar?cluster=3383018529262918047&hl=en>
- [14] Kolen, J. F., & Pollack, J. B. (1990). Backpropagation is Sensitive to Initial Conditions. *Complex Systems*, 4, 269–280.
- [15] Rehman, M. Z., & Nawi, N. M. (2011). Improving the Accuracy of Gradient Descent Backpropagation Algorithm (GDAM) on Classification Problems. *International Journal on New Computer Architectures and Their Applications (IJNCAA) The Society of Digital Information and Wireless Communications*, 1, 861–870.
- [16] Van Ooyen, a., & Nienhuis, B. (1992). Improving the convergence of the backpropagation algorithm. *Neural Networks*, 5, 465–471. doi:10.1016/0893-6080(92)90008-7

---

## El Autor



### German Gonzalo Vargas Sánchez

Ingeniero de Sistemas Universidad Distrital Francisco José de Caldas. Especialista en Ingeniería de software. Especialista en Informática y Ciencias de la Computación. Magister en software Libre, Universidad Autónoma de Bucaramanga Colombia. Doctor en Pensamiento Complejo en la Multiversida Mundo Real Edgar Morín México.