

Predicción del éxito de proyectos TIC mediante redes neuronales artificiales

Predicting success of ict projects through artificial neural networks

Mary-Luz Mouronte-López
Universidad Francisco de Vitoria (España)

DOI: <http://dx.doi.org/10.6036/9724>

Hay distintas clases de Redes Neuronales Artificiales (RNA) [1]: Feed-Forward (FF), Radial Basis Function (RBF), Multi-Layer Perceptron (MLP), Convolutional, Recurrent Neural Network (RNN), Modular, Sequence-To-Sequence Models, las cuales tienen diferentes campos de aplicación [2]. En esta investigación, surgida del requerimiento de optimizar los resultados del negocio de una gran compañía del sector de Tecnologías de Información y Comunicación (TIC), se estiman las posibilidades de éxito de cualquier proyecto TIC mediante el uso de RNA. La solución implementada emplea para la predicción 16 variables, las cuales permiten la caracterización del proyecto y se refieren a complejidad, riesgo, tamaño y entorno. Las posibilidades de éxito son calculadas considerando ciertos criterios establecidos por la compañía. Según estos criterios, un proyecto exitoso es aquel que tiene una ocurrencia de 0 impactos no planificados, una desviación sobre el presupuesto estimado en el rango $[0, -4]\%$ del mismo, un desvío sobre la fecha final prevista en el intervalo $[0, +2]$ semanas y una evaluación por parte del cliente en el rango $[7, 10]$. Estas variables son evaluadas separadamente empleando 4 RNA. Para cada RNA, con una tasa de aprendizaje inferior a 0,1, se requiere lograr un tiempo de entrenamiento inferior a 1,50 horas y un MSE más pequeño de 0,00025.

La determinación de la estructura más adecuada para cada RNA se llevó a cabo estudiando distintas configuraciones caracterizadas por un número diferente de capas ocultas y nodos: 1 capa oculta con 11 nodos, 2 y 3 capas ocultas con 2, 5 y 11 nodos. La configuración que proporcionó resultados mejores fue la de 3 capas ocultas con 11 nodos. Se comparó la utilización de diferentes funciones de activación en las capas ocultas: Sigmoid, Rectified Linear Unit, Hyperbolic Tangent, y Arc-hyperbolic sine. Los mejores resultados se lograron con la función de activación

Rectified Linear Unit en dichas capas ocultas. Por tanto, cada una de las RNA utilizadas fue una High-Order Multi-Layer Perceptron (MLP) constituida por una capa de entrada con 16 nodos, 3 capas ocultas con 11 nodos, una capa de salida con un nodo, y una función de activación Rectified Linear Unit en las capas ocultas. La función de activación Sigmoid fue la utilizada en la capas de entrada y salida.

Durante la negociación en el proceso de ventas, la solución resulta de utilidad al equipo de las cuentas comerciales; cuyos miembros, si el proyecto no cumple en un primer momento los criterios de éxito, pueden modificar algunas de sus características (arquitectura, tecnología, alcance, duración, número de sedes con interfaces de cliente independientes, etc.), realizando nuevas estimaciones hasta conseguir su logro.

La metodología utilizada incluye:

Establecimiento de los datos de entrada que se necesitan: información histórica sobre proyectos ya terminados incluyendo área, complejidad, riesgos, tamaño, entorno, impactos no planificados, variación respecto al presupuesto inicialmente previsto, desviación respecto a la fecha final de disponibilidad y calificación conseguida en la encuesta de cliente.

Datos del proyecto a analizar: área, complejidad, riesgos, tamaño y entorno.

Determinación de los informes necesarios: impactos no planificados, desviación respecto al presupuesto previsto y a la fecha final de disponibilidad, calificación en la encuesta de cliente, comparación de escenarios.

Establecimiento de la red neuronal que se empleará. Considerando distintos números de capas y nodos, y una tasa de aprendizaje, se compara el MSE conseguido por la RNA tras aplicar en las capas ocultas sobre el conjunto de entrenamiento las funciones de activación indicadas. Finalmente se seleccionó la más adecuada.



Un prototipo de la solución fue desarrollado y desplegado. La solución consta de diversos componentes: un agente software que utiliza la RNA, una base de datos ORACLE [3] (12c Release 2) y una GUI Java. Se emplean los productos Python (versión 3.7.0) [4], Oracle Application Server 10g (version 10.1.3.3) y MQSeries Messaging (version 9.1) [5].

El prototipo fue instalado en una máquina con: 4 CPU, 500 GB hard disk, 4 GB memory. La solución fue empleada durante un año, probándose que la investigación logró los objetivos referentes a que con una tasa de aprendizaje inferior a 0,1, debería conseguirse un tiempo de entrenamiento menor a 1,50 horas y un MSE inferior 0,00025.

La solución fue valorada con una puntuación de 9,2 sobre 10 en una encuesta realizada a aquellas personas que guardan relación con la solución y que están implicadas en el proceso de ventas.

REFERENCES

- [1] Oludare IA, Aman JA, Esther O, Kemi VD, Nachaat AEM, Humaira A. "State-of-the-art in artificial neural network applications: A survey". Heliyon. Vol. 4-11, p. 217-225, 2018.
- [2] Jayne C, Iliadis L. Special issue: Engineering applications of neural networks. Neural Computing and Application, Vol. 29-7, p. 303-637, 2018.
- [3] ORACLE. <http://www.oracle.com/es/index.html>. [Accessed February 2020].
- [4] PYTHON. <https://www.python.org/> [Accessed February 2020].
- [5] IBM MQ. <http://www-03.ibm.com/software/products/en/ibm-mq>. [Accessed 24 February 2020].