



El índice global de innovación en Colombia: un análisis y selección de los factores influyentes mediante el uso de redes neuronales artificiales

*The global innovation index in Colombia: An analysis and selection of influencing
factors through the use of artificial neural networks*

Julián Alberto Uribe Gómez*

Instituto Tecnológico Metropolitano, Colombia

Recibido el 6 de marzo de 2020; aceptado el 25 de enero de 2021

Disponible en Internet el: 1 de febrero de 2021

Resumen

Esta investigación propone un modelo de selección y clasificación para entender cuáles son los factores que impactan en los procesos de innovación para el caso de Colombia. Se analizan los referentes conceptuales sobre el índice global de innovación y la técnica de optimización de redes neuronales artificiales, se presenta el marco de trabajo para el análisis y desarrollo por medio de las redes. Finalmente, se muestran los resultados obtenidos, donde se encuentra que 5 de las 133 variables más importantes para diagnosticar el índice global de innovación son: intensidad en la competencia local, inversión extranjera, crédito, educación terciaria, capital humano e investigación, otras variables descartadas por el modelo como de menor importancia son: PIB por unidad de energía utilizada o cantidad de acciones totales tranzadas. Se espera que los hallazgos sirvan para mejorar el proceso de toma de decisiones en la priorización de marcos de trabajo para los sistemas de innovación regional y nacional.

Código JEL: C53, C61, C63, O32

Palabras clave: Innovación; Indicadores; Redes neuronales artificiales; Modelos

*Autor para correspondencia

Correo electrónico: julianuribe@itm.edu.co (J.A. Uribe Gómez).

La revisión por pares es responsabilidad de la Universidad Nacional Autónoma de México.

<http://dx.doi.org/10.22201/fca.24488410e.2021.2871>

0186- 1042/© 2019 Universidad Nacional Autónoma de México, Facultad de Contaduría y Administración. Este es un artículo Open Access bajo la licencia CC BY-NC-SA (<https://creativecommons.org/licenses/by-nc-sa/4.0/>)

Abstract

This research proposes a selection and classification model to understand what are the factors that impact innovation processes in the case of Colombia. The conceptual referents on the global innovation index and the technique of artificial neural network optimization are analyzed, the framework for the analysis and development through the networks is presented. Finally, the results obtained are shown, where it is found that 5 of the 133 most important variables to diagnose global innovation index are: intensity in local competition, foreign investment, credit, tertiary education, human capital and research, other variables discarded by the model for its minor importance are: GDP per unit of energy used or amount of total shares traded. The findings are expected to improve the decision-making process in prioritizing frameworks for regional and national innovation systems.

JEL Code: C53, C61, C63, O32

Keywords: Innovation; Indicators; Artificial neural networks; Modelling

Introducción

Concepto de innovación

El concepto puede ser encontrado en el análisis de innovación en economía definido por Joseph Schumpeter (1934), quien acuñó el concepto de “destrucción creativa”. De acuerdo con Schumpeter este proceso juega un papel importante en la evolución histórica del capitalismo (Muller, Heraud and Zenker, 2017), donde se pueden encontrar varios tipos de innovación: de producto, de producción y transporte, de materiales y fuentes y de mercado. La innovación ha sido entendida como el factor principal que conduce al crecimiento económico y competitivo, siendo esta una idea de profunda reflexión en círculos sociales, tecnológicos y de negocios (Jankowska, Matysek-Jedrych and Mroczek-dabrowska, 2017). La innovación ha tenido una creciente importancia como indicador de prosperidad en el mundo, esto se debe a una mejor capacidad creativa, la cual no está limitada a economías avanzadas ni a sectores de alta tecnología, sino abierta como fenómeno global (Dutta, 2017). Esto ha generado que se produzcan las grandes revoluciones industriales, y por lo tanto, sociedades más modernas, tecnificadas y avanzadas (Rao, 2010). En la literatura especializada se han encontrado dos factores que favorecen el crecimiento económico de un país, primero, un talento humano con alta formación en conocimiento, y segundo, avances en tecnologías de comunicación e información (TICs). Por otro lado, el máximo potencial de la innovación de una economía está

influenciada por variables macro económicas y micro económicas, como lo son: El porcentaje del Producto Interno Bruto, Gasto porcentual en Innovación y Desarrollo, Brecha tecnológica, entre otros (Erciş and Ünalán, 2016). Sin embargo, esta visión reduccionista de factores debe ser reformulada, principalmente porque se han documentado ampliamente que la innovación no es de carácter determinístico ni lineal, es multiagente, orgánico y holístico (Díaz, 2019).

Métricas y sistemas de innovación

Uno de los indicadores a nivel mundial más representativo para medir la innovación entre países es el Índice Global de Innovación (De ahora en adelante, IGI). El objetivo de este índice es establecer criterios de valoración entre países de mayor a menor puntuación con base en diferentes factores o variables de innovación, el cual es presentado anualmente (Pençe, Kalkan and Çeşmeli, 2019) y establece la necesidad de entender y administrar los procesos de innovación por país (Franco and Oliveira, 2017). Lo que busca este índice es capturar la multivariabilidad en la innovación y crear un ambiente en el cual estos factores puedan ser evaluados continuamente, así mismo, establece las métricas y las aproximaciones que capturen la riqueza de la innovación y vayan más allá del enfoque tradicionalista como el número de artículos científicos, patentes, entre otros (Cornell University, INSEAD and WIPO, 2020). El IGI año tras año considera nuevos factores a evaluar, algunos son constantes en el tiempo y otros son cambiantes. La tabla 1 presenta la cantidad de factores evaluados para los años 2013-2019 y su respectiva calificación en el IGI para Colombia.

Tabla 1
Cantidad de aspectos evaluados y calificación por año en el IGI (Global Innovation Index, 2020)

Año	Cantidad de aspectos evaluados en el IGI	Calificación Índice Global de Innovación
2013	122	60
2014	109	68
2015	107	67
2016	110	63
2017	109	65
2018	108	63
2019	108	67

Fuente: Elaboración propia.

Los sistemas de innovación y su concepto fueron tratados por Freeman (1987), Lundvall (1982) y Nelson (1983) (Rinkinen, Oikarinen and Melkas, 2016), este concepto ha ganado una alta popularidad debido en gran parte a una mayor competencia internacional en una economía que se globaliza rápidamente, esto ha estimulado las capacidades de innovación y la competitividad entre regiones (Doloreux and Parto, 2005) y pueden ser definidos desde una gran variedad de enfoques: pueden ser nacionales, regionales, sectoriales o tecnológicos, y aunque no existe una definición universalmente aceptada para este concepto, existe un cierto grado de convergencia entre las propuesta que incluyen las redes localizadas de actores, la generación, transferencia, modificación, creación, difusión y uso del conocimiento y la innovación (Valdéz and León, 2015; Carlsson *et al.*, 2002) dentro de una estructura de producción de una región.

Los sistemas de innovación están basados en una gran cantidad de campos de investigación que incluyen economía evolutiva, economía institucional, teoría de clusters, nueva economía regional, economía del aprendizaje en sistemas y economía de la innovación y teoría de redes (Stuck, Broekel and Revilla, 2016), adicional, los sistemas de innovación se entienden como un arreglo de componentes en constante relación y cambio, y puede ser considerados un sistema complejo, ya que se encuentra compuesto por otros subsistemas de diferente naturaleza y fuertemente articulados (Muller, Heraud and Zenker, 2017).

El marco de trabajo de los sistemas de innovación consiste en enfatizar sobre cuales son las ventajas competitivas de cada nación o región para generar la innovación, todo esto bajo la relación de algunos componentes clave, organizados en subsistemas de exploración y explotación, los cuales están conformados por: empresas, instituciones universitarias, mediadores y las políticas de innovación (Doloreux, 2002). Cada uno de estos actores pertenecientes al sistema puede ser descrito como (Zollo, De Crescenzo and Ponsiglione, 2011):

- Explotadores o empresas: permiten transformar el conocimiento en valor en el mercado.
- Exploradores o instituciones universitarias: productores de conocimiento, exploran las fronteras del conocimiento produciendo nuevas ideas, nuevos métodos y nuevas técnicas disponibles para las empresas.
- Catalizadores o mediadores: facilitadores en el complejo proceso de transferencia, adaptación y utilización del conocimiento como incubadoras tecnológicas o mediadores de innovación.
- Gobierno o políticas de innovación: se encarga de guiar, organizar y coordinar las redes de actores, proveyendo competencias científicas y tecnológicas. Encargada de proveer lo necesario para generar innovación.

El IGI evalúa las fortalezas y debilidades de los sistemas nacionales de innovación, mediante dos subíndices: insumos y resultados, de aquí se desprende la relación de eficiencia, que expresa que tan eficiente es un país en términos de innovación. El subíndice de insumos está compuesto por instituciones, capital humano e investigación, infraestructura, sofisticación de mercados y sofisticación de negocios. Similar a esto, el subíndice de resultados lo componen conocimiento y tecnología y creatividad (Departamento Nacional de Planeación, 2018).

De acuerdo a las calificaciones obtenidas en el IGI, Colombia como país ha sido clasificado en un clúster de innovación media (Jankowska, Matysek-Jedrych and Mroczek-dabrowska, 2017) esto quiere decir, que aún existen debilidades entre la interdependencia de los actores del sistema de innovación, lo que significa que faltan estrategias coordinadas y acciones para soportar los procesos de innovación. Bajo esta perspectiva, Colombia se ha caracterizado también por un proceso de industrialización tardío y aún en construcción.

A partir de esto, se encuentra la necesidad de analizar las variables del IGI con el fin de encontrar cuáles de ellas son mayormente importantes y relevantes en el impacto de dicho índice. En general, el número de datos obtenidos y la cantidad de aspectos a evaluar, constituye una base de información importante que debe ser analizada a través de metodologías provenientes de la inteligencia artificial y el aprendizaje profundo, lo cual ayudará a analizar los datos y establecer modelos, que bajo otras metodologías sería complejo (Pençe, Kalkan and Çeşmeli, 2019).

Inteligencia artificial

Las metodologías actuales provenientes de la inteligencia artificial utilizadas en el análisis de información, sumado a la importancia de los datos en la creciente economía de la cuarta revolución industrial ha sido resumida bajo la siguiente declaración: “el Big Data es el nuevo petróleo” según el director ejecutivo de IBM. Recientes estudios han demostrado el impacto y el poder de los datos en la vida moderna (Iqbal et al., 2018). A partir de esto se han generado muchas herramientas basadas en minería de datos, las cuales, han servido para analizar todo tipo de bases de datos. Estas herramientas han sido denominadas como técnicas supervisadas y no supervisadas, las cuales han servido para realizar dos tipos de análisis: predictivo y descriptivo, donde uno de los focos del análisis descriptivo es la selección o extracción de factores de interés dentro de un dataset, este es un problema general en aprendizaje de máquina, el cual permite identificar un grupo de variables que tienen más influencia (Visalakshi and Radha, 2015) sobre algún evento dependiente, así mismo, es útil para reducir el ruido o variables redundantes, las cuales podrían degradar el desempeño del sistema (Devi

and Sabrigiriraj, 2018), en este caso particular son los factores que influyen en mayor medida sobre el IGI para Colombia.

Existen diversas técnicas para realizar un análisis descriptivo para la selección de los factores entre los que se encuentran los métodos probabilísticos, los evolutivos y las redes neuronales artificiales (De ahora en adelante RNA), estudiadas por McCulloch y Pitts en 1943, para plantear modelos computacionales con habilidades de aprendizaje a través de retroalimentaciones neurales (Baum, 1988). Actualmente, resulta imprescindible asociar este tipo de redes con el aprendizaje, el cual resulta fundamental para entrenar la inteligencia de la máquina, aunque el proceso de aprendizaje en el contexto de las RNA puede ser visto como un problema de actualización y carga de datos. La preferencia de las RNA sobre otro tipo de técnicas radica en que ellas constituyen una de las herramientas más poderosas y eficientes para la clasificación y reconocimiento de patrones, planeamiento, predicción (Hanafizadeh, Ravasan and Khaki, 2010), control y optimización debido a sus propiedades de aprendizaje adaptativo no lineal y no paramétrico (Blanco et al., 2013), por otro lado, constituyen un paradigma computacional que provee una gran variedad de modelos matemáticos no lineales, utilizado para estudiar un rango considerable de problemas estadísticos (Blanco et al., 2013), finalmente, las RNA no están alejadas de los métodos estadísticos y probabilísticos más tradicionales, de hecho, pueden ser consideradas como una técnica de regresión, la cual está representada por una alta no linealidad entre las variables dependientes e independientes (Geem and Roper, 2009).

La justificación para la preferencia de uso como técnica de análisis de las RNA, radica en sus principios fundamentados en el concepto neurofisiología del cerebro humano (Xiang and Deng, 2010) y su célula, la neurona, los cuales tienen varias características deseadas por cualquier sistema computacional, esta razón ha incrementado la investigación y el campo de aplicación sobre el funcionamiento de las RNA. Dichas redes aprenden de su entorno haciendo uso de la información disponible, por lo tanto, ellas no son programadas, sino entrenadas, como resultado, ellas pueden entregar buenos resultados en el corto plazo (Kigami, 2001), principalmente, los atributos encontrados en este tipo de técnicas son las siguientes: aprendizaje desde la experiencia, generalización desde ejemplos, desarrollo de soluciones más rápidas, eficiencia computacional y no linealidad.

Las RNA contienen varios algoritmos algunos de ellos son: perceptrón, propagación hacia atrás y hacia adelante, madaline, redes de base radial, entre otras. El perceptrón multicapa es la RNA más comúnmente utilizada (Blanco et al., 2013, Hamadache et al., 2017) en una gran variedad de disciplinas, para aspectos como clasificación y predicción de variables. El perceptrón multicapa pertenece al conjunto de técnicas supervisadas, esto quiere decir que

es necesario proveer al modelo con múltiples variables de entrada y una o varias salidas deseadas (Serrano-Cinca, 1996).

Por todo lo anteriormente mencionado, en esta investigación se propone aplicar una RNA, ya que como metodología novedosa permitirá a los tomadores de decisiones de políticas de innovación, realizar una selección de factores críticos que influyen en el IGI para Colombia, como estrategia para competir y compararse con otros países.

Método

Revisión de literatura

Para el desarrollo de esta investigación, el conjunto de datos utilizado se recolectó de la página de datos abiertos Global Innovation Index (2020) y la revisión de literatura cuenta con tres elementos principales: la innovación, el índice global de innovación y las redes neuronales artificiales, la búsqueda sobre estos elementos se realizó en las bases de datos indexadas SCOPUS, Science Direct, JSTOR y el uso de la plataforma ResearchGate como repositorio adicional de información, a través de las siguientes ecuaciones de búsqueda: (TITLE-ABS-KEY (“feature selection”) AND TITLE-ABS-KEY (“machine learning”)), (TITLE-ABS-KEY (“feature selection”) AND TITLE-ABS-KEY (“neural networks”)), (TITLE-ABS-KEY (“feature selection”) AND TITLE-ABS-KEY (“neural networks”)) AND (LIMIT-TO (ACCESSTYPE(OA))) AND (LIMIT-TO (PUBYEAR , 2020) OR LIMIT-TO (PUBYEAR , 2019)) y (TITLE-ABS-KEY (“feature selection”) AND TITLE-ABS-KEY (“machine learning”) AND TITLE-ABS-KEY (“Artificial Neural Networks”)) AND DOCTYPE (ar) AND ACCESSTYPE (OA) AND PUBYEAR > 2009, con sus respectivos documentos recuperados: 11100, 7264, 538 y 166. Finalmente, la revisión bibliográfica recuperó 40 documentos pertinentes para la investigación, donde el 97.5% son en idioma inglés y el 53% están publicadas en el rango de 2015-2020.

En trabajos relacionados con la temática de este artículo, autores como Dalmau et al. (2010) han utilizado el método de extracción de variables implementando RNA, en procesos complejos y no balanceados de digestión anaeróbica. Adicionalmente, Khumprom, Grewell and Yodo (2020) han utilizado el aprendizaje profundo y RNA como método de selección de variables en modelos de turbinas de gas para reducir el número de variables en la complejidad del modelo, se han encontrado que utilizar dichos métodos tiene mayores ventajas sobre los métodos tradicionales como los físicos o los estadísticos tradicionales, ya que su desempeño es superior cuando existen modelos complejos con alta no linealidad (Khumprom, Grewell and Yodo, 2020). En el campo de procesamiento del lenguaje natural sobre todo en el reconocimiento de emociones, las RNA son fundamentales, ya que el lenguaje y las emociones

son, computacionalmente, un tópico complejo de abordar, es así como Farooq et al. (2020) hacen uso de las RNA para clasificar y extraer variables para entender las emociones como una señal del habla, en este caso se encuentran diferentes clasificadores como las máquinas de soporte vectorial, los bosques aleatorios, los vecinos más cercanos, el perceptrón multicapa e incluso Bayes ingenuo para resolver el problema de la dimensionalidad de un dataset (Devi and Sabrigiriraj, 2018; Visalakshi and Radha, 2015).

Otra de las aplicaciones encontradas dentro de la revisión de literatura incluye el uso de las RNA en el sector económico y financiero, es así como los autores Liu and Schumann (2005) utilizan dicho método para selección de variables en procesos de crédito que en algunos casos, como se expresa, son dominados arbitrariamente. Huotari, Savolainen and Collan (2020) utilizaron aprendizaje profundo haciendo uso de redes convolucionales en la selección de acciones para S&P 500, en este caso se deseaba optimizar los portafolios de inversión. Finalmente, la RNA se han utilizado de manera prolífica y constante en procesos de salud, en especial para clasificar y seleccionar, en este caso Mourad et al. (2020) utilizan la selección de factores en la identificación de las variables más importantes para estudiar la causa de muerte del cáncer de tiroides, en este estudio se tienen en cuenta 7 variables, donde luego de aplicar el algoritmo de selección encuentran las tres variables más importantes. Como se puede observar, existe gran interés en la aplicación de estos métodos de optimización, inteligencia artificial y aprendizaje profundo, en un gran número de áreas del conocimiento como medicina, finanzas, economía, bioinformática y en otras por mencionar con marketing o innovación y sus sistemas relacionados.

Metodología

La metodología de trabajo abordada para esta investigación consistió en tomar como referencia el IGI, ya que este índice tiene como objetivo principal medir la innovación de manera robusta, contemplando multitud de variables. Este método permitirá mostrar las variables más y las menos importantes para fomentar estrategias en políticas de innovación, todo esto mediante el método de IA RNA perceptrón multicapa con algoritmo de retropropagación, la cual es necesario aclarar, no se considera una técnica estadística propiamente dicha, por lo tanto, las potencialidades del método es que la red se entrena con los datos de las variables independientes de entrada que se dispongan, estos son los aspectos del IGI. Esto significa que el método es tan exacto como los datos que se han utilizado para poder entrenar al sistema y el conocimiento y dominio del problema.

En esta parte de la sección se describe el algoritmo metodológico propuesto haciendo uso de una RNA para seleccionar factores, la cual se presenta en la figura 1, en esta se selecciona la variable objetivo o capa de salida, la cual es el IGI, luego se obtienen los datasets requeridos desde 2013 hasta 2019 del sitio web Global Innovation Index y se pre procesan los datos para poder ser cargados al modelo, los problemas de inconsistencia o incompletitud son comunes, por lo tanto, los datos faltantes se obtienen, en algunos casos, utilizando el valor promedio (Bansal et al., 2018), posterior a esto, se construye la arquitectura de la red neuronal, donde se detallan su capa de entrada y sus capas ocultas, finalmente, se entrena la RNA donde se validan las predicciones del modelo y se seleccionan los factores que impactan positivamente en el desempeño de la red.

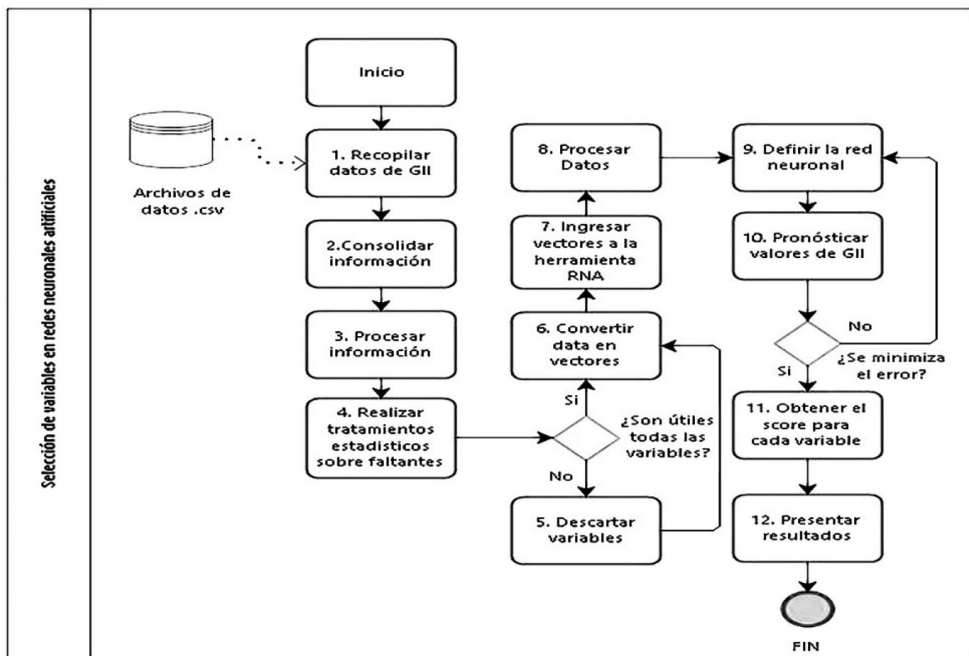


Figura 1. Metodología de investigación.

Fuente: Elaboración propia

A continuación, se presenta la ficha técnica de la investigación descrita en la tabla 2.

Tabla 2

Ficha técnica de investigación

Universo	Indicadores Índice Global de Innovación
Ámbito geográfico	Nacional (Colombia)
Origen de los datos	Global Innovation Index (Global Innovation Index, 2020)
Número total de indicadores a evaluar	134 indicadores para Colombia
Diseño muestral	134 indicadores con 7 años de datos para cada uno
Estructura del dataset de análisis	938 datos totales
Periodo de recogida de la información	2013-2019
Tipo de muestreo	Completo No probabilístico
Técnicas de análisis	Análisis descriptivo y Redes Neuronales Artificiales
Software utilizado	NETLOGO versión 6.0.4 e IBM SPSS versión 19

Fuente: Elaboración propia.

Construcción de la red neuronal para la selección de factores

Las RNA son técnicas para analítica de datos cualitativos y cuantitativos que han sido inspiradas en la manera como el cerebro procesa información (Hajek and Henriques, 2017), su elemento y su unidad básica es la neurona o nodo, la cual es la unidad más simple de procesamiento, estas están organizadas por tres tipos de capas: entrada, ocultas y salida (Geem and Roper, 2009). Cada nodo está vinculado a n-unidades de entrada a través de n-conexiones dirigidas, y está caracterizado por un valor límite, una función de activación univariable y un vector de pesos (Leshno and Spector, 1996). Los modelos de redes neuronales aceptan gran cantidad de entradas, sumándolas de manera ponderada. Usualmente, se aplican funciones no lineales para generar los resultados (Kuzey, Uyar and Delen, 2014) y transmitirla a otra neurona, dichos resultados se establecen como futuras entradas de la red. Las posibilidades del uso de redes neuronales radica en la necesidad de trabajar procesos de decisión cuando se encuentran gran cantidad de datos y patrones ocultos, escenarios donde el desarrollo de modelos matemáticos y estadísticos tradicionales se torna difícil y complejo (Hanafizadeh, Ravasan and Khaki, 2010). Así, una de las principales ventajas de las RNA consiste en sus capacidades de generalización, también en que no se basa en modelos preliminares o preestablecidos, estos modelos se han tornado robustos y confiables aunque hayan valores atípicos o falten datos (Di Tollo *et al.*, 2012).

Así como las neuronas biológicas, uno de los principales atractivos de las redes neuronales es su posibilidad de aprender y ajustarse a las condiciones de las capas de entrada y salida. Cada capa tiene una cantidad de neuronas asociadas y el número de capas o nodos ocultos determina la complejidad del modelo final (Blanco *et al.*, 2013). Por lo tanto, mientras más capas posea una red neuronal, será más profunda y creará mejores características para seleccionar y clasificar.

Dentro de los modelos de RNA, el perceptrón multicapa con el algoritmo de retropropagación del error es el modelo más popular para predicción y la selección de factores. En la figura 2 se puede ver la estructura general de este tipo de red neuronal.

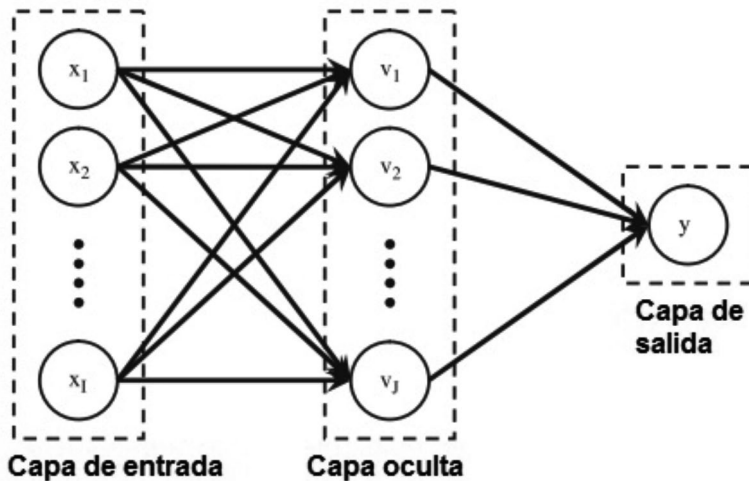


Figura 2. Concepto red neuronal artificial.
Fuente: Adaptado de (Geem and Roper, 2009)

Primero se tiene una capa de entrada con un número determinado de unidades, células o nodos, luego se tienen múltiples capas con unidades intermedias y finalmente una capa de salida. Cada una de las unidades o nodos está conectada con una unidad de la etapa anterior y la siguiente, y un peso sináptico asociado con el nodo de salida (Baum, 1988). La salida de la red neuronal que se encuentra en la capa final, está asociada a la ecuación 1, se debe considerar que cada neurona de la capa oculta y la capa de entrada aportan pesos ponderados y valores que se ajustan en el proceso de aprendizaje de la red (West, 2000), así mismo, existen diversas funciones de activación utilizadas por la RNA como por ejemplo la tangente hiperbólica y la función sigmoidea (Kigami, 2001), la cual se presenta en la ecuación 2.

$$Y_k = f_h \sum_{i=1}^n w_{ij} x_i + w_{jb} \quad (1)$$

Donde:

Y_k : son las neuronas de la capa de salida.

f_h : Es la función de activación de la red.

w_{ij} : son los pesos sinápticos del proceso de aprendizaje y adaptación.

$$Y_j = \frac{1}{1 + e^{-\sum w_{ij} X_i}} \quad (2)$$

Donde:

α : Es el parámetro de pendiente de la curva

v : Es la suma ponderada de la neurona

La RNA actúa a través de algoritmos de aprendizaje, los cuales, ajustan su arquitectura y parámetros de manera que permite minimizar una función de error que indica el grado de ajuste de los datos (Kengpol and Wangananon, 2006), o visto de otro modo, la tasa de aprendizaje de la red medida a través de la varianza (Xiang and Deng, 2010) para medir el desempeño del modelo (Hamadache et al., 2017). Por lo tanto, uno de los objetivos de la RNA es minimizar la función de error (denominada Loss Function) entre la salida deseada y la salida del modelo neuronal a partir de un conjunto de observaciones ya clasificadas (Kengpol and Wangananon, 2006). La función de error está definida como la raíz del error cuadrático medio (RMSE), y a través de esta función se estima el resultado del proceso. El valor se puede calcular como se indica en la ecuación 3.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y - y_i)^2}{n}} \quad (3)$$

El modelo de RNA de innovación puede ser desarrollado usando varios indicadores de innovación, los cuales son las variables independientes, para predecir el indicador de innovación (Nair, Kumar and Ahmed, 2014), por lo tanto, para la construcción del tipo de RNA perceptrón multicapa con algoritmo de retropropagación, se van a seleccionar 133 variables o factores independientes presentes en el Índice Global de Innovación, estructurados en 7 grandes grupos para reducir la complejidad visual de la red propuesta: Instituciones, Capital humano e investigación, Infraestructura, Sofisticación de mercado, Sofisticación de negocio, Conocimiento y tecnología y Creatividad. En la tabla 3 se pueden ver los parámetros y la información de inicio para la red construida.

Tabla 3
Construcción de la red neuronal

Información sobre la red neuronal		
Capa de entrada	VARIABLES INDEPENDIENTES FACTORES	133
Capas ocultas	Número de capas ocultas	2
	Número de unidades de la capa oculta	100
	Función de activación de la red	Tangente hiperbólica
Capa de salida	VARIABLES DEPENDIENTES	1
	Número de unidades	1
	Función de activación	Tangente hiperbólica
	Función de error	Suma de errores cuadráticos
Muestra	Entrenamiento	80%
	Prueba	20%

Fuente: Elaboración propia.

La figura 3 presenta la construcción de la RNA perceptrón multicapa, con sus tres capas de neuronas, en la capa de entrada se tienen las 133 variables independientes, sin embargo, por complejidad y extensión en la red presentada se utilizaron sus agrupaciones, la capa oculta, la cual, mediante la función de activación ajusta los pesos en las neuronas. La primera capa de las neuronas de la red se propaga a través de las capas superiores hasta generar una salida, que se compara con el resultado obtenido de las neuronas de salida con el resultado que se desea obtener, es decir con los resultados del Índice Global de Innovación, y mediante la función RMSE, esto se transmite hacia atrás para que cada neurona reciba el error aproximado de participación.

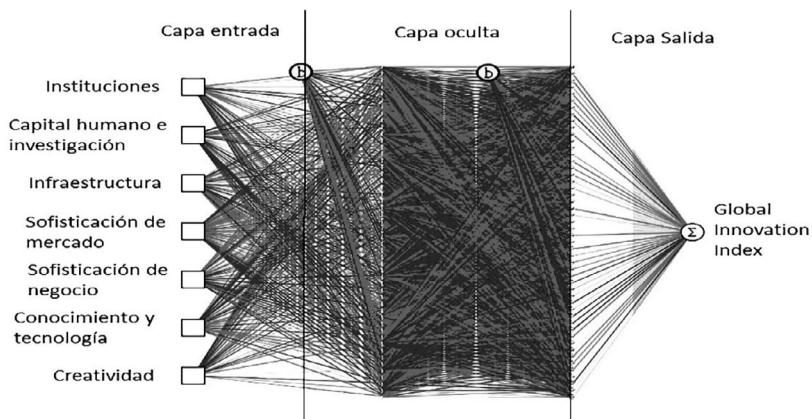


Figura 3. RNA Perceptrón multicapa
Fuente: Elaboración Propia

Resultados

La estructura de conformación de la red, comprende 133 variables, con 2 capas ocultas. El número de nodos ocultos fue de 100 en cada capa y se consideró 1 nodo en la capa de salida, el cual representa al IGI. El dataset se dividió en 2 grupos: 1 de ellos compuesto por el 80% para datos de entrenamiento y 20% para datos de prueba sobre la red. Se utilizó la función de tangente hiperbólica como función de transferencia de la capa oculta y la capa de salida.

Como se puede ver en la tabla 4, se obtuvo los resultados para el modelo RNA, donde el desempeño de la red en su fase de entrenamiento y prueba muestra un error cuadrático medio (RMSE) pequeños, de 0.061 y 0.000, respectivamente, esto indica que los datos obtenidos por la red en su predicción se acercaron significativamente a los datos reales provistos para la red. Adicional a esto se compararon otras arquitecturas, donde los errores cuadráticos en entrenamiento para las otras RNA fueron: 0.372, 0.087 y 0.098, respectivamente. En la etapa de prueba los errores cuadráticos fueron 0.005, 0.104 y 0.558. Se encuentra así que los resultados de la red seleccionada son mejores.

Por otro lado, en la figura 4 se puede observar la relación entre el valor pronosticado y el valor real del IGI, en esta se puede notar que se obtuvo un muy buen resultado notablemente alto en el coeficiente de determinación y por lo tanto de correlación, esto garantiza una vez más excelentes predicciones sobre este índice y la selección correcta de variables. Comparando los resultados con las redes similares se encuentra que los coeficientes de determinación son menores, indicando poco ajuste en los datos, los resultados fueron: 0.879, 0.897 y 0.558, demostrando que la RNA seleccionada tiene mejor ajuste en los datos pronosticados.

Tabla 4

Resultados del modelo de RNA

Resumen del modelo		
Entrenamiento	Suma de errores cuadráticos	0.061
	Error relativo	0.038
	Regla de parada utilizada	1 pasos consecutivos sin disminución del error
	Tiempo de entrenamiento	00:00:00.106
Prueba	Suma de errores cuadráticos	0.000
	Error relativo	No se puede calcular. Es posible que la variable dependiente sea constante en la muestra de prueba.

Fuente: Elaboración propia.




Figura 4. Ajuste y predicción del modelo.

Fuente: Elaboración propia

Para seleccionar los factores más importantes y de mayor influencia sobre el IGI, se utilizó la importancia de las variables independientes a través de su porcentaje ponderado de importancia y su porcentaje de importancia normalizada, ambas medidas indican cuanto cambia el valor de la variable dependiente por el modelo de la RNA para diferentes valores de la variable independiente. El indicador de importancia consiste en ponderar porcentualmente cada una de las variables analizadas y ordenarlas de mayor a menor, la importancia normalizada es el resultado de los valores divididos por los valores de importancia mayores expresados porcentualmente, así, el modelo creado de RNA, responde a la clasificación de factores e importancia de las variables sobre la influencia de la salida en el modelo. En la tabla 5 se presentan las quince variables más importantes obtenidas en el ejercicio, las cuales aportan aproximadamente el 40% de la contribución en el Índice Global de Innovación. Parece que las variables: intensidad de la competencia local, inversión, créditos, educación terciaria, capital humano e investigación, trabajadores de conocimiento y absorción de conocimiento, entre otros, tienen el mayor efecto sobre cómo clasifica la RNA al IGI.

Tabla 5
Importancia de las variables independientes en el modelo RNA

Importancia de las variables independientes			
Código variable	Explicación	Importancia	Importancia normalizada
V54	Intensity of local competition (Intensidad en la competencia local)	3.94%	100%
V86	Foreign direct investment net outflows (Flujos de inversión directa extranjera)	3.56%	90.4%
V46	Investment (Inversión)	3.11%	78.8%
V42	Credit (Crédito)	3.07%	77.8%
V43	Ease of getting credit (Facilidad en la obtención de créditos)	3.04%	77%
V20	Tertiary education (Educación terciaria)	2.93%	74.4%
V14	Human capital and research (Capital humano e investigación)	2.69%	68.1%
V37	Ecological sustainability (Sostenibilidad ecológica)	2.62%	66.4%
V56	Knowledge workers (Trabajadores de conocimiento)	2.60%	66%
V35	Logistics performance (Desempeño logístico)	2.36%	59.9%
V68	Knowledge absorption (absorción del conocimiento)	2.33%	59%
V32	Online e-participation (Participación electrónica en línea)	1.97%	50%
V51	Trade and competition (Intercambio y competencia)	1.86%	47.1%
V66	Joint venture/strategic alliance deals (Alianzas estratégicas)	1.81%	45.9%
V48	Market capitalization (capitalización del mercado)	1.62%	41%

Fuente: Elaboración propia.

Finalmente, se presenta en la figura 5 la importancia normalizada para todo el conjunto de las 133 variables independientes utilizadas en el modelo RNA. El gráfico de importancia normalizada es un gráfico de barras de la tabla 5, clasificado en valor de importancia descendente. En esta se pueden visualizar variables que aportan poco al IGI, en este caso con un aporte de 0.01% se encuentra el producto interno bruto por unidad de energía y con el 0.02% el total de acciones tranzadas.

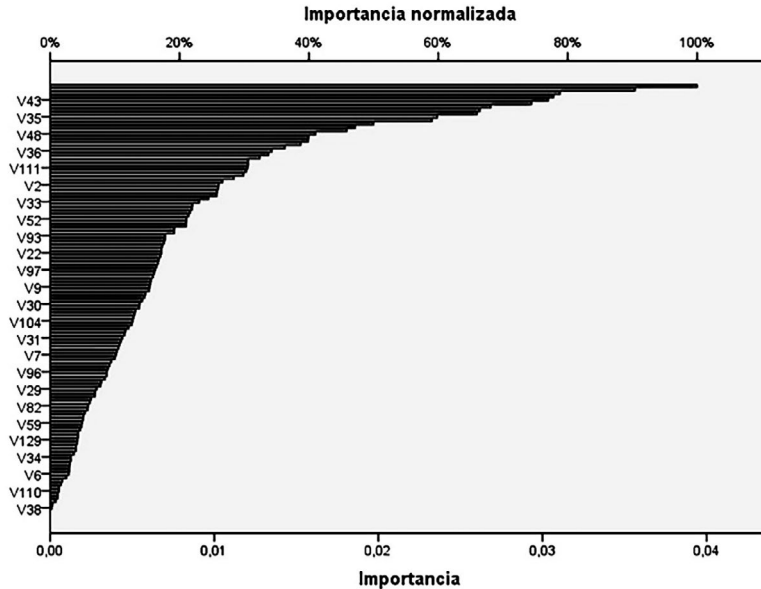


Figura 5. Importancia de los factores del IGI.
Fuente: Elaboración propia

Conclusiones

En este artículo, se desarrolló un modelo de RNA con algoritmo de retro propagación, demostrándose que este tipo de métodos computacionales, son capaces de desempeñar tareas de alta complejidad y con gran cantidad de variables con precisión estadística.

El modelo de RNA propuesto resulta pertinente para seleccionar los factores que determinan y más influyen sobre el Índice Global de Innovación en Colombia. A través del estudio se logró mostrar que los grupos con los factores más importantes para el indicador son los relacionados con: capital humano e investigación, infraestructura, sofisticación del mercado, sofisticación del negocio y solo un factor en conocimiento y tecnología.

Sobre la herramienta utilizada es importante aclarar que, dentro del método de aplicación de las redes neuronales, existe una desventaja y es el hecho que no hay un procedimiento único conocido que garantice que las soluciones globales encontradas, logren para el problema, encontrar una configuración de pesos sinápticos que minimice el criterio de error, por lo tanto, uno de los múltiples mínimos locales posibles es obtenido a través de una de las muchas reglas propuestas en la literatura. Por otro lado, como bien se ha explicado las redes

neuronales artificiales son una simplificación del proceso biológico y el modelo creado no captura la dinámica ni las propiedades espacio temporales, las cuales son importantes en el proceso biológico. No obstante, como ya se ha mencionado las redes neuronales artificiales pueden aproximar con exactitud diversos tipos de relaciones complejas, pero con sus claras limitantes.

Se debe tener en cuenta que la configuración de las RNA depende de los diferentes algoritmos de aprendizaje, por ejemplo, se pueden alcanzar buenas generalidades y errores mínimos con redes pequeñas, aunque al incrementar el número de capas y nodos se pueden obtener resultados similares con tasas de errores más pequeños. En general, se aconsejan largas capas iniciales con muchos nodos y capas ocultas pequeñas, aunque todo dependerá del contexto planteado, en este caso se contaba con una gran capa de nodos de 133 factores y dos capas ocultas más pequeñas, lo cual permitía mayor distribución del error y mejor aprendizaje.

Como trabajo futuro de investigación para este tópico, se podría proponer comparativos el desempeño de las RNA con otro tipo de aproximaciones metaheurísticas como algoritmos genéticos, lógica difusa, entre otros o con métodos tradicionales en ciencias como estadística y modelos de regresión lineal, especialmente para examinar si la eficacia de los métodos.

Referencias

- Bansal, D. et al. (2018) 'Comparative Analysis of Various Machine Learning Algorithms for Detecting Dementia', *Procedia Computer Science*. Elsevier B.V., 132, pp. 1497–1502. [https://doi: 10.1016/j.procs.2018.05.102](https://doi.org/10.1016/j.procs.2018.05.102).
- Baum, E. B. (1988) 'On the capabilities of multilayer perceptrons', *Journal of Complexity*, 4(3), pp. 193–215. [https://doi: 10.1016/0885-064X\(88\)90020-9](https://doi.org/10.1016/0885-064X(88)90020-9).
- Blanco, A. et al. (2013) 'Credit scoring models for the microfinance industry using neural networks: Evidence from Peru', *Expert Systems with Applications*. Elsevier Ltd, 40(1), pp. 356–364. [https://doi: 10.1016/j.eswa.2012.07.051](https://doi.org/10.1016/j.eswa.2012.07.051).
- Carlsson, B. et al. (2002) 'Innovation systems : analytical and methodological issues', *Research Policy*, 31, pp. 233–245.
- Cornell University, INSEAD and WIPO (2020) *The Global Innovation Index 2012 Stronger Innovation Linkages for Global Growth*. Available at: https://www.codespring.ro/wp-content/uploads/2012/11/GII-2012_Cover.pdf (Consultado: 18 February 2020).
- Dalmau, J. et al. (2010) 'Selecting the Most Relevant Variables for Anaerobic Digestion Imbalances: Two Case Studies', *Water Environment Research*, 82(6), pp. 492–498. [https://doi: 10.2175/106143009x12529484815359](https://doi.org/10.2175/106143009x12529484815359).
- Departamento Nacional de Planeación (2018) *Índice Global de Innovación 2018 informe para Colombia*. Available at: [https://colaboracion.dnp.gov.co/CDT/Prensa/Índice Global de Innovación%2C 2018. Informe para Colombia .pdf](https://colaboracion.dnp.gov.co/CDT/Prensa/Índice%20Global%20de%20Innovación%202018.pdf) (Consultado: 20 February 2020).
- Devi, S. G. and Sabrigiriraj, M. (2018) 'Feature Selection, Online Feature Selection Techniques for Big Data Classification: - A Review', *Proceedings of the 2018 International Conference on Current Trends towards Converging Technologies, ICCTCT 2018*. IEEE, pp. 1–9. [https://doi: 10.1109/ICCTCT.2018.8550928](https://doi.org/10.1109/ICCTCT.2018.8550928).

- Diaz, I. (2019) 'La innovación en Cuba: un análisis de sus factores clave', *Innovar*, 29(71), pp. 43–54. [https://doi: 10.15446/innovar.v29n71.76394](https://doi.org/10.15446/innovar.v29n71.76394).
- Doloreux, D. (2002) 'What we should know about regional systems of innovation', *Technology in Society*, 24(3), pp. 243–263. [https://doi: 10.1016/S0160-791X\(02\)00007-6](https://doi.org/10.1016/S0160-791X(02)00007-6).
- Doloreux, D. and Parto, S. (2005) 'Regional innovation systems: Current discourse and unresolved issues', *Technology in Society*, 27(2), pp. 133–153. [https://doi: 10.1016/j.techsoc.2005.01.002](https://doi.org/10.1016/j.techsoc.2005.01.002).
- Dutta, S. (2017) 'The Global Innovation Index 2017. Innovation feeding the world', (July), pp. 2–30.
- Erciş, A. and Ünalın, M. (2016) 'Innovation: A Comparative Case Study of Turkey and South Korea', *Procedia - Social and Behavioral Sciences*. The Author(s), 235(October), pp. 701–708. [https://doi: 10.1016/j.sbspro.2016.11.071](https://doi.org/10.1016/j.sbspro.2016.11.071).
- Farooq, M. et al. (2020) 'Impact of feature selection algorithm on speech emotion recognition using deep convolutional neural network', *Sensors (Switzerland)*, 20(21), pp. 1–18. [https://doi: 10.3390/s20216008](https://doi.org/10.3390/s20216008).
- Franco, C. and Oliveira, R. H. de (2017) 'Inputs and outputs of innovation: analysis of the BRICS', *RAI Revista de Administração e Inovação*. Departamento de Administração, Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo - FEA/USP, 14(1), pp. 79–89. [https://doi: 10.1016/j.rai.2016.10.001](https://doi.org/10.1016/j.rai.2016.10.001).
- Geem, Z. W. and Roper, W. E. (2009) 'Energy demand estimation of South Korea using artificial neural network', *Energy Policy*. Elsevier, 37(10), pp. 4049–4054. [https://doi: 10.1016/j.enpol.2009.04.049](https://doi.org/10.1016/j.enpol.2009.04.049).
- Global Innovation Index (2020) *Global Innovation Index, Report*. Available at: <https://www.globalinnovationindex.org/Home>.
- Hajek, P. and Henriques, R. (2017) 'Modelling innovation performance of European regions using multi-output neural networks', *PloS one*, (October), p. 22. Available at: <https://doi.org/10.1371/journal.pone.0185755>.
- Hamadache, M. et al. (2017) 'Application of multilayer perceptron for prediction of the rat acute toxicity of insecticides', *Energy Procedia*. Elsevier B.V., 139, pp. 37–42. [https://doi: 10.1016/j.egypro.2017.11.169](https://doi.org/10.1016/j.egypro.2017.11.169).
- Hanafizadeh, P., Ravasan, A. Z. and Khaki, H. R. (2010) 'An expert system for perfume selection using artificial neural network', *Expert Systems with Applications*. Elsevier Ltd, 37(12), pp. 8879–8887. [https://doi: 10.1016/j.eswa.2010.06.008](https://doi.org/10.1016/j.eswa.2010.06.008).
- Huotari, T., Savolainen, J. and Collan, M. (2020) 'Deep Reinforcement Learning Agent for S&P 500 Stock Selection', *Axioms*, 9(130), pp. 1–15.
- Iqbal, R. et al. (2018) 'Big data analytics: Computational intelligence techniques and application areas', *Technological Forecasting and Social Change*. Elsevier, (December 2017), pp. 0–1. [https://doi: 10.1016/j.techfore.2018.03.024](https://doi.org/10.1016/j.techfore.2018.03.024).
- Jankowska, B., Matysek-Jedrych, A. and Mroczek-dabrowska, K. (2017) 'Efficiency of National Innovation Systems – Poland and Bulgaria in The Context of the Global Innovation Index', *Comparative Economic Research*, 20(3), p. 18.
- Kengpol, A. and Wangananon, W. (2006) 'The expert system for assessing customer satisfaction on fragrance notes: Using artificial neural networks', *Computers and Industrial Engineering*, 51(4), pp. 567–584. [https://doi: 10.1016/j.cie.2006.04.006](https://doi.org/10.1016/j.cie.2006.04.006).
- Khumprom, P., Grewell, D. and Yodo, N. (2020) 'for Data-Driven Prognostic Model of Aircraft Engines'.
- Kigami, J. (2001) 'Mathematical Background', in, pp. 196–211. [doi: 10.1017/CBO9780511470943.008](https://doi.org/10.1017/CBO9780511470943.008).
- Kuzey, C., Uyar, A. and Delen, D. (2014) 'The impact of multinationality on firm value: A comparative analysis of machine learning techniques', *Decision Support Systems*. Elsevier B.V., 59(1), pp. 127–142. [https://doi: 10.1016/j.dss.2013.11.001](https://doi.org/10.1016/j.dss.2013.11.001).

- Leshno, M. and Spector, Y. (1996) 'Neural network prediction analysis: The bankruptcy case', *Neuro-computing*, 10(2), pp. 125–147. [https://doi: 10.1016/0925-2312\(94\)00060-3](https://doi.org/10.1016/0925-2312(94)00060-3).
- Liu, Y. and Schumann, M. (2005) 'Data mining feature selection for credit scoring models', *Journal of the Operational Research Society*, 56(9), pp. 1099–1108. [https://doi: 10.1057/palgrave.jors.2601976](https://doi.org/10.1057/palgrave.jors.2601976).
- Mourad, M. et al. (2020) 'Machine Learning and Feature Selection Applied to SEER Data to Reliably Assess Thyroid Cancer Prognosis', *Scientific Reports*, 10(1), pp. 1–11. [https://doi: 10.1038/s41598-020-62023-w](https://doi.org/10.1038/s41598-020-62023-w).
- Muller, E., Heraud, J. and Zenker, A. (2017) 'Are Innovation Systems Complex Systems?', Springer. [https://doi: 10.1007/978-3-319-45901-1](https://doi.org/10.1007/978-3-319-45901-1).
- Nair, H., Kumar, A. and Ahmed, O. (2014) 'Neural network modelling, simulation and prediction of innovation growth in United Arab Emirates (UAE)', *Procedia Computer Science*, 36(C), pp. 269–275. [https://doi: 10.1016/j.procs.2014.09.092](https://doi.org/10.1016/j.procs.2014.09.092).
- Pence, I., Kalkan, A. and Çeşmeli, M. Ş. (2019) 'Estimation of the Country Ranking Scores on the Global Innovation Index 2016 Using the Artificial Neural Network Method', *International Journal of Innovation and Technology Management*, 16(4). [https://doi: 10.1142/S0219877019400078](https://doi.org/10.1142/S0219877019400078).
- Rao, B. C. (2010) 'How to Measure Innovation', *Challenge*, 53(1), pp. 109–125. [https://doi: 10.2753/0577-5132530105](https://doi.org/10.2753/0577-5132530105).
- Rinkinen, S., Oikarinen, T. and Melkas, H. (2016) 'Social enterprises in regional innovation systems: a review of Finnish regional strategies', *European Planning Studies*, 24(4), pp. 723–741. [https://doi: 10.1080/09654313.2015.1108394](https://doi.org/10.1080/09654313.2015.1108394).
- Schumpeter, J. (1934) *The Theory of Economic Development, Management*. Harvard University Press ((trans R. Opie)). [https://doi: 10.1007/0-306-48082-4_3](https://doi.org/10.1007/0-306-48082-4_3).
- Serrano-Cinca, C. (1996) 'Self organizing neural networks for financial diagnosis', *Decision Support Systems*, 17(3), pp. 227–238. [https://doi: 10.1016/0167-9236\(95\)00033-X](https://doi.org/10.1016/0167-9236(95)00033-X).
- Stuck, J., Broekel, T. and Revilla, J. (2016) 'Network Structures in Regional Innovation Systems', *European Planning Studies*, 24(3), pp. 423–442.
- Di Tollo, G. et al. (2012) 'Neural Networks to model the innovativeness perception of co-creative firms', *Expert Systems with Applications*. Elsevier Ltd, 39(16), pp. 12719–12726. [https://doi: 10.1016/j.eswa.2012.05.022](https://doi.org/10.1016/j.eswa.2012.05.022).
- Valdéz, C. and León, J. I. (2015) 'Hacia una taxonomía de los sistemas regionales de innovación en México', *Economía, Sociedad y Territorio*, XV(48), pp. 517–553.
- Visalakshi, S. and Radha, V. (2015) 'A literature review of feature selection techniques and applications: Review of feature selection in data mining', 2014 IEEE International Conference on Computational Intelligence and Computing Research, IEEE ICCIC 2014. IEEE, (1997). [https://doi: 10.1109/ICCIC.2014.7238499](https://doi.org/10.1109/ICCIC.2014.7238499).
- West, D. (2000) 'Neural network credit scoring models', *Computers and Operations Research*, 27(11–12), pp. 1131–1152. [https://doi: 10.1016/S0305-0548\(99\)00149-5](https://doi.org/10.1016/S0305-0548(99)00149-5).
- Xiang, X. and Deng, Y. (2010) 'Second order spiking perceptron and its applications', *Applied Mathematical Modelling*. Elsevier Inc., 34(10), pp. 2966–2980. [https://doi: 10.1016/j.apm.2010.01.006](https://doi.org/10.1016/j.apm.2010.01.006).
- Zollo, G., De Crescenzo, E. and Ponsiglione, C. (2011) 'A gap analysis of regional innovation systems (RIS) with medium-low innovative capabilities: the case of Campania region (Italy)', in *ESU European University Network on Entrepreneurship Conference 2011*. Seville, pp. 1–19.