

# idetec)

Libro de Actas

## Estudiantes de Grado y Posgrado



Secretaría de Ciencia,  
Tecnología y Posgrado



**UTN VILLA MARIA**

Compilación:

**Ing. Marcelo Cejas, Ing. Javier Gonella, Ing. Fabián Sensini**

Congreso de Investigaciones y Desarrollos en Tecnología y Ciencia, IDETEC 2020 : Libro de Actas - Estudiantes de Grado y Posgrado / Micaela Mariel Achetoni ... [et al.] ; compilado por Marcelo Oscar Cejas ; Javier Nicolás Gonella ; Fabián Marcelo Sensini. - 1a ed. - Ciudad Autónoma de Buenos Aires : edUTecNe, 2021.

268 p. ; 240 x 150 cm.

ISBN 978-987-4998-69-9

1. Ingeniería. 2. Tecnologías. 3. Medio Ambiente. I. Achetoni, Micaela Mariel. II. Cejas, Marcelo Oscar, comp. III. Gonella, Javier Nicolás, comp. IV. Sensini, Fabián Marcelo, comp.

CDD 607.3

Edición y Diseño:



**Universidad Tecnológica Nacional – República Argentina**

**Rector:** Ing. Héctor Eduardo Aiassa

**Vicerrector:** Ing. Haroldo Avetta

**Secretaria Académica:** Ing. Liliana Raquel Cuenca Pletsch



**Universidad Tecnológica Nacional – Facultad Regional Villa María**

**Decano:** Ing. Pablo Andrés Rosso

**Vicedecano:** Ing. Franco Salvático



**edUTecNe – Editorial de la Universidad Tecnológica Nacional**

**Coordinador General a cargo:** Fernando H. Cejas

**Director Colección Energías Renovables, Uso Racional de Energía, Ambiente:** Dr. Jaime Moragues.

Queda hecho el depósito que marca la Ley N° 11.723

© edUTecNe, 2021

Sarmiento 440, Piso 6 (C1041AAJ)

Buenos Aires, República Argentina

Publicado Argentina – Published in Argentina



Reservados todos los derechos. No se permite la reproducción total o parcial de esta obra, ni su incorporación a un sistema informático, ni su transmisión en cualquier forma o por cualquier medio (electrónico, mecánico, fotocopia, grabación u otros) sin autorización previa y por escrito de los titulares del copyright. La infracción de dichos derechos puede constituir un delito contra la propiedad intelectual.

# ANÁLISIS DE MÉTODOS DE INTELIGENCIA ARTIFICIAL PARA LA REDUCCIÓN DE INCERTIDUMBRE

Pamela A. Chirino<sup>1</sup>, Mariela F. Galdamez<sup>1</sup>, Paola G. Caymes-Scutari<sup>1,2</sup>, Germán Bianchini<sup>1</sup>

<sup>1</sup>Laboratorio de Investigación en Cómputo Paralelo/Distribuido Departamento de Ingeniería en Sistemas de Información Facultad Regional Mendoza/Universidad Tecnológica Nacional Rodríguez 273 (M5502AJE) Mendoza, +54 261 5244579

<sup>2</sup>Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)  
pamela.chirino@alumnos.frm.utn.edu.ar, mariela.galdamez@alumnos.frm.utn.edu.ar,  
pcaymesscutari@frm.utn.edu.ar, gbianchini@frm.utn.edu.ar

## Resumen:

En este trabajo se estudian diferentes métodos de inteligencia artificial y su posible paralelización, con el objetivo de aplicarlo en un modelo de predicción de incendios forestales desarrollado en el Laboratorio de Investigación en Computo Paralelo/Distribuido. La finalidad es reducir la incertidumbre presente en las variables de entrada con las que opera el modelo subyacente. Los métodos de inteligencia artificial en los que centraremos nuestro estudio son: redes neuronales y visión computacional. Se estudian teóricamente y las formas de desarrollarlos para luego estudiar las posibilidades de paralelización. Con las redes neuronales, centramos nuestro estudio en el perceptrón por ser una red neuronal simple y fácil de desarrollar en lenguaje C. En cuanto a la visión computacional, nos encontramos analizando la forma correcta de aplicarla en nuestro modelo, trabajando actualmente con redes convolucionales.

## 1. Introducción

La Inteligencia Artificial es la simulación de inteligencia humana por parte de las máquinas. Dicho de otro modo, es la disciplina que trata de crear sistemas capaces de aprender y razonar como un ser humano [3].

Normalmente, un sistema de inteligencia artificial es capaz de analizar datos en grandes cantidades, identificar patrones y tendencias y, por lo tanto, formular predicciones de forma automática, con rapidez y precisión.

Por las características anteriormente mencionadas, y con el fin de reducir la incertidumbre en el modelo de predicción de incendios llevado a cabo en el Laboratorio de Investigación en Computo Paralelo/Distribuido (falta de certeza en cuanto a los valores dinámicos de variables de entrada como dirección y velocidad del viento, tipo de vegetación afectada, humedad presente en la vegetación, etc.) [1] [2], se estudiarán a continuación dos métodos de inteligencia artificial: Redes neuronales y Visión Computacional.

## 2. Redes Neuronales

Las redes neuronales artificiales son un modelo computacional vagamente inspirado en el comportamiento observado en el cerebro humano. Consiste en un conjunto de unidades, llamadas neuronas artificiales, conectadas entre sí para transmitirse señales [4]. La información de entrada atraviesa la red neuronal (donde se somete a diversas operaciones) produciendo valores de salida como se muestra en la Figura 1. Cabe mencionar que la capa oculta puede estar constituida por varias capas de neuronas.

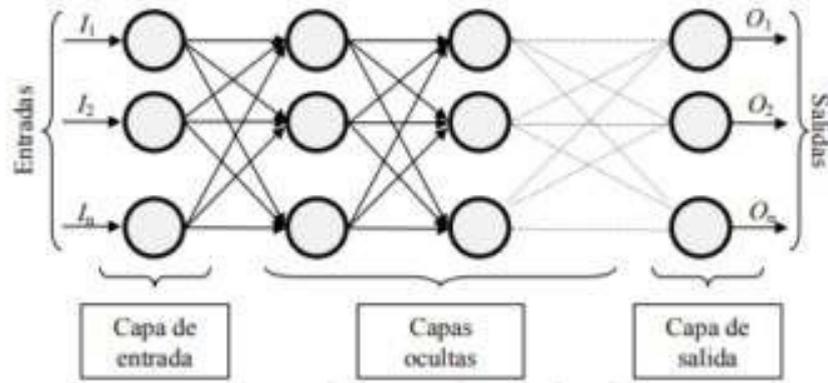


Fig.1: Esquema de una red neuronal.

Además de las capas ya mencionadas, una red neuronal cuenta con distintas funciones para poder llevar a cabo su funcionamiento.

## 2.1. Funciones de la red neuronal

Las redes neuronales cuentan con tres tipos de funciones: Función de entrada, Función de activación, y Función de Salida. Las mismas se detallan a continuación.

### 2.1.1. Función de entrada

La neurona trata a muchos valores de entrada como si fueran uno solo; esto recibe el nombre de entrada global. La forma de lograr la entrada global es a través de la función de entrada, la cual se calcula a partir del vector entrada [4].

Los valores de entrada se multiplican por los pesos anteriormente ingresados a la neurona. Estos pesos de los valores de entrada cambian los pesos de las neuronas haciendo que cambie también la influencia de las mismas, es decir, una neurona con mayor peso tendrá mayor relevancia en el problema que una con un peso inferior a ésta.

### 2.1.2. Función de activación

La función de activación tiene como objetivo acotar los valores de salida de una red neuronal para mantenerlos en ciertos rangos, es decir, calcula el estado de actividad de una neurona; transformando la entrada global en un valor (estado) de activación [3][4]. En su forma simplificada, esta función es binaria, esto es, se activa la neurona o no.

### 2.1.3. Función de salida

El último componente que una neurona necesita es la función de salida. El valor resultante de esta función es la salida de la neurona ( $out_i$ ); por ende, la función de salida determina qué valor se transfiere a las neuronas vinculadas. Si la función de activación está por debajo de un umbral determinado, ninguna salida se pasa a la neurona subsiguiente [4].

## 2.2. Aprendizaje de las redes neuronales

Una red neuronal debe aprender a calcular la salida correcta para cada arreglo o vector de entrada en el conjunto de ejemplos. En nuestro caso debe aprender a calcular, a partir de conjuntos de variables, cuál es la que se aproxima más a la predicción más exacta.

El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada [4] [5].

El método de aprendizaje que nos interesa para este artículo es el aprendizaje supervisado que se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo, que podría ser el programador (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor controla la salida de la red y en caso de que ésta no coincida con la deseada, se procederá a modificar los pesos [5].

La idea principal, es brindarle a la red neuronal diferentes combinaciones de valores de variables que presentan incertidumbre en el momento del desarrollo de un incendio y su correspondiente salida esperada o predicción correcta. A partir de esto, la red neuronal aprenderá a reconocer qué pesos tienen estas variables en el resultado de la predicción y cuáles influyen más en la exactitud de la predicción.

Para el estudio práctico de esta propuesta, estudiamos y ponemos en práctica este tipo de aprendizaje con la red neuronal Perceptrón.

### **2.3. Perceptrón**

El perceptrón es la red neuronal más básica que existe de aprendizaje supervisado. El funcionamiento del perceptrón es muy sencillo, simplemente lee los valores de entrada, suma todas las entradas de acuerdo a unos pesos y el resultado lo introduce en una función de activación que genera el resultado final [4].

Dado que al principio de esta investigación se contaba con poca experiencia en redes neuronales, se decidió comenzar a estudiar el perceptrón multicapa. También se tuvo en cuenta que en el LICPaD se trabajaba con lenguaje C/C++ y que una de las pocas redes neuronales que se pueden implementar en este lenguaje es el perceptrón, debido a que es más sencillo de implementar cuando no se cuenta con clases.

Luego de determinar que se utilizaría el perceptrón para experimentar, se estudió cómo funcionaba y las formas de pasaje de parámetros, o valores de entrada que podía tener el mismo. Dado que se pretende operarlo con un determinado número de variables para poder aplicarlo al problema de la predicción de incendios, decimos parametrizarlo y trabajar con el pasaje de entradas mediante archivos para mantener un buen orden y simpleza en el código.

## **3. Visión computacional**

La visión computacional trata de interpretar las imágenes recibidas por dispositivos y reconocer los objetos, ambiente y posición en el espacio [6]. El objetivo al momento de incluir este tema al estudio se basa en la necesidad de trabajar con información proveniente de imágenes de mapas satelitales. A través de la visión computacional proponemos un análisis más rápido y automático de estos mapas con el fin de ayudar a realizar una predicción más precisa.

A continuación, describiremos las redes convolucionales con las que trabajaremos la visión computacional.

### **3.2. Redes convolucionales**

Las redes neuronales convolucionales son muy similares a las redes neuronales ordinarias como el perceptrón multicapa que fue descrito anteriormente; se componen de neuronas que tienen pesos y capacidad de aprender [6].

Lo que diferencia a las redes neuronales convolucionales es que suponen explícitamente que las entradas son imágenes, lo que nos permite codificar ciertas propiedades en la arquitectura; permitiendo ganar en eficiencia y reducir la cantidad de parámetros en la red.

Las redes neuronales convolucionales trabajan modelando de forma consecutiva pequeñas piezas de información, y luego combinan esta información en las capas más profundas de la red.

### 3.2.1. Estructura de las Redes Neuronales Convolucionales

En general, las redes neuronales convolucionales suelen estar construidas con una estructura que contendrá tres tipos distintos de capas que se detallan a continuación y se pueden observar en la Figura 3.

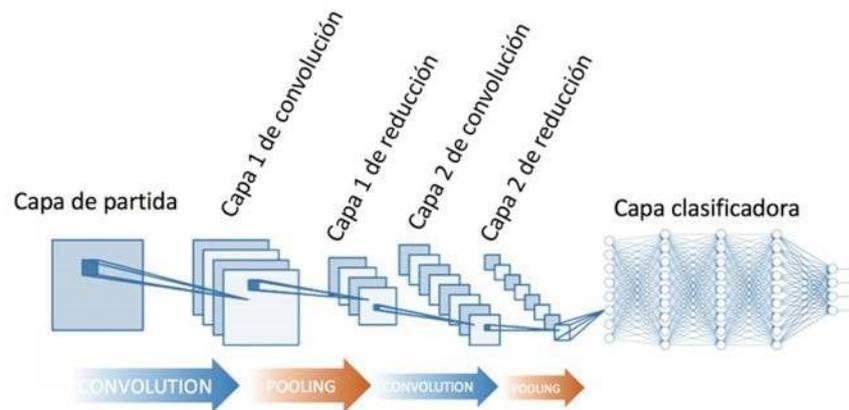


Fig.3: Esquema de la estructura de una red convolucional.

#### 3.2.1.1. Capa convolucional

Esta es la capa que le da nombre a la red, lo que distingue a las redes neuronales convolucionales de cualquier otra red neuronal. En la misma se utiliza una operación llamada convolución en alguna de sus capas [6].

La operación de convolución recibe como entrada o input la imagen y luego aplica sobre ella un filtro o kernel que nos devuelve un mapa de las características de la imagen original. De esta forma logramos reducir el tamaño de los parámetros.

#### 3.2.1.2. Capa de reducción o pooling

La utilidad principal de la capa de reducción o pooling radica en la reducción de las dimensiones espaciales (ancho x alto) del volumen de entrada para la siguiente capa convolucional [6].

#### 3.2.1.3. Capa clasificadora totalmente conectada

Al final de las capas convolucional y de pooling, las redes utilizan generalmente capas completamente conectadas en la que cada pixel se considera como una neurona separada al igual que en una red neuronal regular [6].

### 3.3. Forma de trabajo con Redes Convolucionales

Actualmente nos encontramos estudiando la librería OpenCV, que es una librería de inteligencia artificial con diversas herramientas de visión computacional. La misma nos permite manipular imágenes y videos. Además, se está estudiando si es posible aplicarla en lenguaje C para poder incluirla en el modelo existente.

## 4. Paralelismo en Redes Neuronales

El procesamiento paralelo es un método mediante el cual se dividen grandes problemas en componentes, tareas o cálculos que puedan resolverse en simultáneo. En particular, estamos analizando el modelo Master-Worker para incluir en nuestro estudio [7].

El modelo Master-Worker es un modelo aplicado a la descomposición de dominio, es decir, el dominio del problema se divide en subconjuntos de datos y los mismos son asignados a nodos diferentes [7], siguiendo un esquema como el que se muestra en la figura 4.

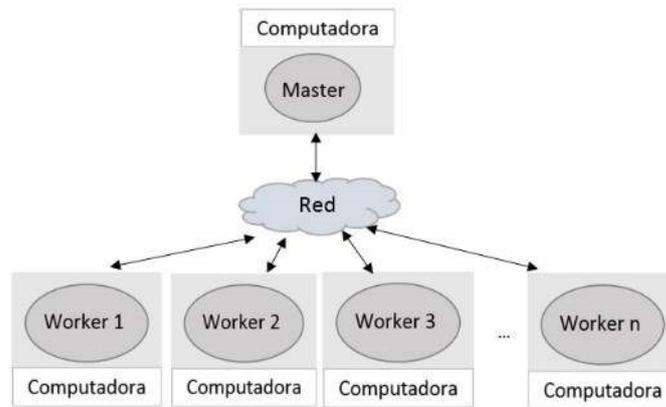


Fig.4: Esquema del modelo Master-Worker.

El proceso principal, denominado Master, es el proceso encargado de coordinar todo el tratamiento y procesamiento del problema, para lo que genera muchos subprocessos, que son ejecutados como procesos independientes denominados Workers, que en general se ejecutan en procesadores independientes de forma simultánea. El esquema de trabajo es el siguiente: el proceso Master inicia los procesos Worker, les asigna el trabajo a realizar, y estos devuelven los resultados normalmente en múltiples iteraciones.

Como la cantidad de datos a procesar es muy elevada, el Master sería el encargado de enviar el dominio de datos a los diferentes Workers que operarían la red neuronal. De esta manera se entrenaría a los diferentes Workers con los mismos dominios de datos para finalmente analizar el resultado obtenido del aprendizaje, y el correspondiente error que cada uno presente en la predicción. Una vez completado el entrenamiento, se analizarían diferentes combinaciones en este conjunto de variables que permitan obtener el resultado de predicción que esperamos de cada una.

## 5. Conclusiones

La inteligencia artificial avanza constantemente, mejorando y aplicándose a diferentes temáticas. Por lo tanto, consideramos importante estudiar la relevancia e impacto que puede tener en nuestro tema de estudio.

Este trabajo aborda los conceptos estudiados para entender el funcionamiento de una red neuronal y su posible paralelización. Actualmente nos encontramos estudiando su implementación, adaptación al modelo de predicción de incendios y su paralelización. Además, también estudiamos los conceptos y aspectos teóricos de la visión computacional, analizando la forma de aplicarla a nuestro modelo para que la misma brinde facilidad y eficiencia en el tratamiento de imágenes.

La idea principal es aplicar redes neuronales a las variables de entrada del modelo de incendios forestales en las que se presenta incertidumbre. Entrenaríamos a la red con información de incendios ya documentados para que aprenda del resultado al aplicar diferentes combinaciones de variables y ayude en la mejora de la predicción.

## 6. Referencias

- [1] Bianchini G., Caymes Scutari P., "Metodos basados en computación de alto rendimiento para predecir el comportamiento de incendios forestales" E-ICES7. ISBN 978-987-1323-27-2. Edit. CNEA. pp. 28-36, 2012.
- [2] Bianchini G., Caymes Scutari P., Méndez Garabetti M., "EvolutionaryStatistical System: a Parallel Method for Improving Forest Fire Spread Prediction". Journal of Computational Science (JOCS) Vol 6 pp. 58-66. ISSN: 1877-7503 doi: 10.1016/j.jocs.2014.12.001 Elsevier.
- [3] Ponce Cruz P., "Inteligencia Artificial Aplicada a la ingeniería", Alfaomega, 2001.
- [4] Ruiz Alberto C., "Redes Neuronales: Conceptos básicos y aplicaciones", UTN-Facultad Regional de Rosario, 2005.
- [5] Rivera E., "Entrenamiento de redes neuronales en algoritmos evolutivos", 2005.
- [6] Sucar Enrique, Giovani Gómez, "Vision Computacional", , 2008.
- [7] Wilkinson B., Allen M., "Parallel Programming". Pearson. 2005.