

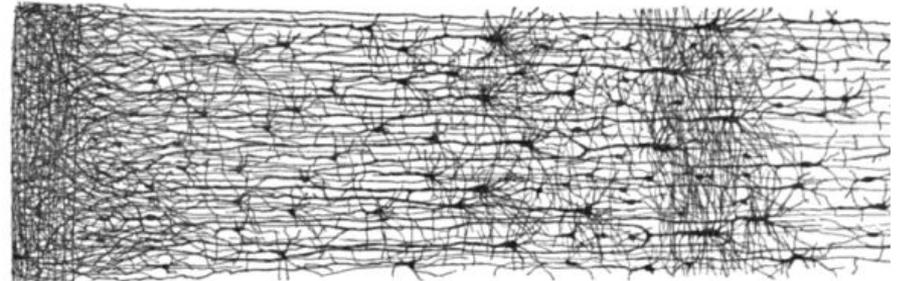
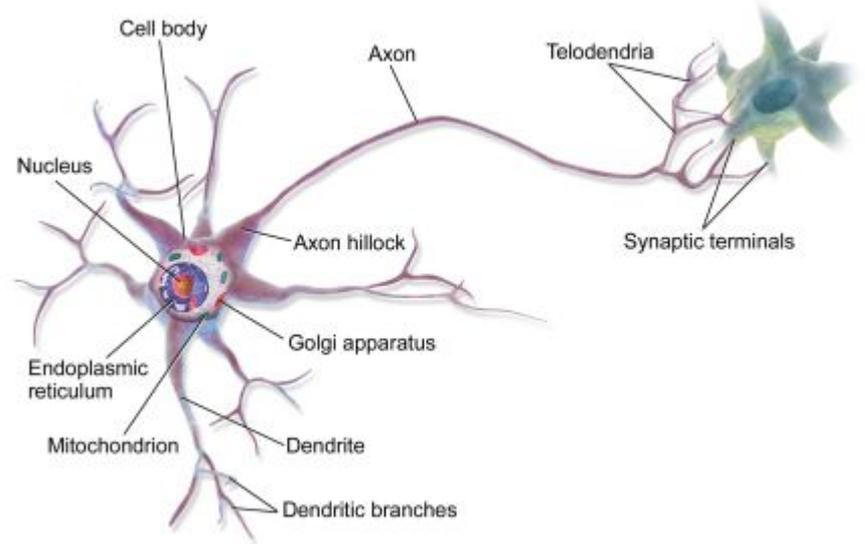
# Deep Learning

Fabián Villena

# Neurona Biológica

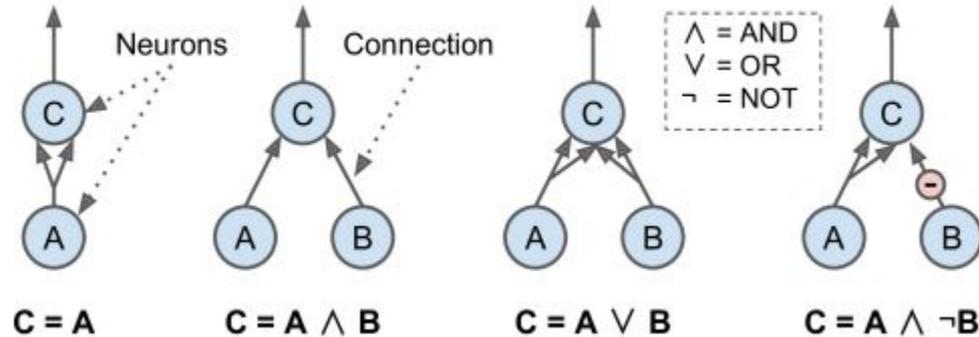
Una célula compuesta por dendritas, unas prolongaciones que reciben pulsos eléctricos que son procesados en el cuerpo y pueden ser transmitidos a través del axón, el cual puede conectarse a más neuronas.

Complejas computaciones pueden realizarse en una red de neuronas.



# Computaciones lógicas con neuronas

Una neurona artificial puede recibir una o más entradas binarias y dar una salida binaria. La neurona puede activar su salida cuando recibe un número determinado de señales de entrada. Con este modelo podemos construir una red capaz de computar cualquier proposición lógica.

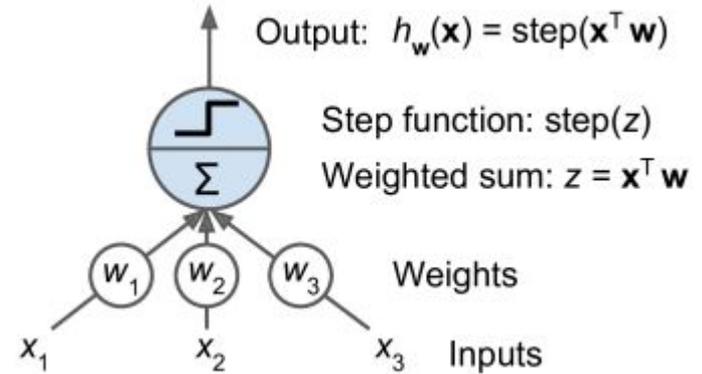


# El perceptrón

Es una de las redes neuronales artificiales más simples. Las entradas y las salidas son ahora números y cada conexión de entrada está asociada a un peso.

Esta unidad computa una suma ponderada de sus entradas y después aplica una función a esa suma y da salida al resultado.

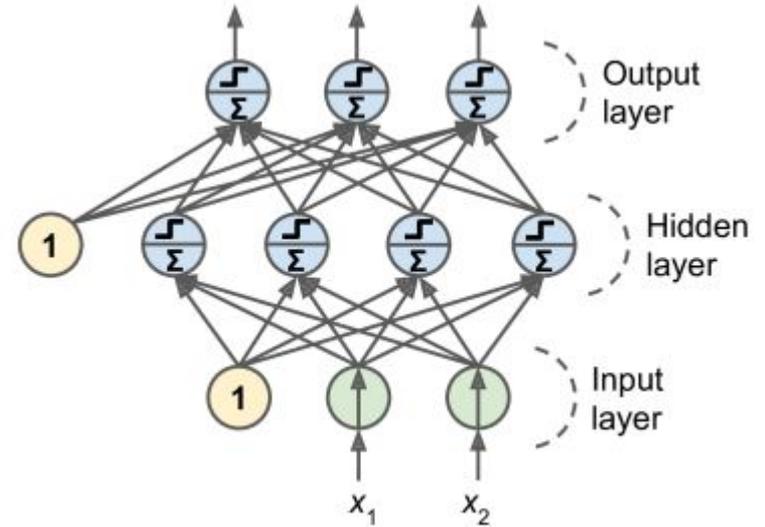
Con esto podemos generar un clasificador simple.



# Perceptrón multicapa

Esta red neuronal artificial elimina algunas limitaciones del perceptrón al apilar múltiples capas de perceptrones para poder resolver problemas más complejos.

Cuando una red neuronal artificial contiene una pila profunda de capas profundas es llamada una Deep Neural Network.



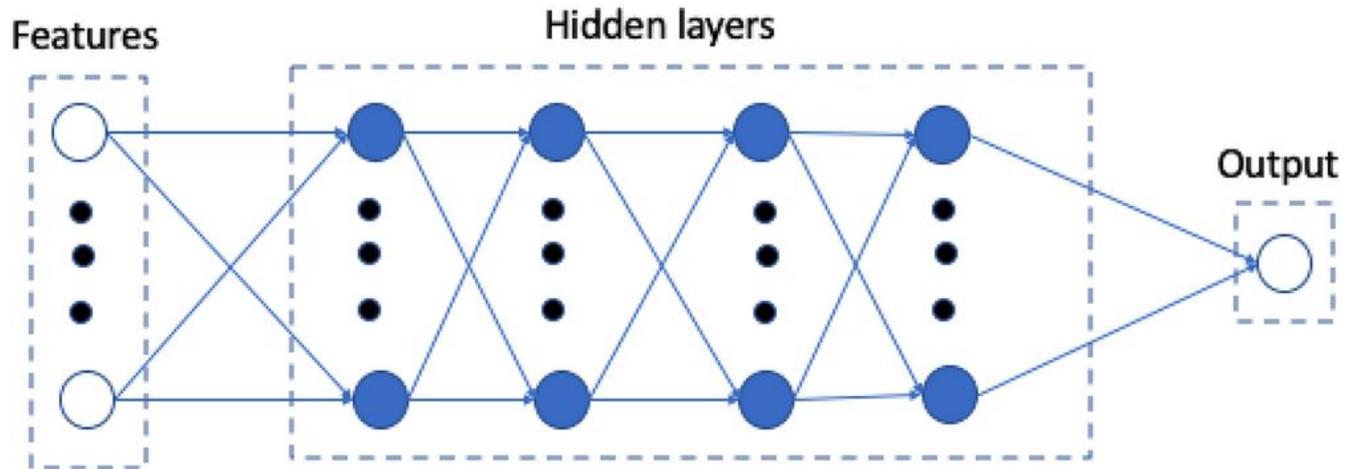
# Backpropagation

Es un método para ajustar una red neuronal. Esta técnica es una forma eficiente de ajustar los pesos de las conexiones.

1. Pasamos un grupo de ejemplos de entrenamiento por la red y calculamos las predicciones.
2. Se calcula el error respecto a las respuestas reales.
3. Se calcula cuánto cada conexión aportó a ese error.
4. Finalmente se ajustan los pesos de cada conexión en función del aporte al error de cada conexión.

# Regresión con MLP

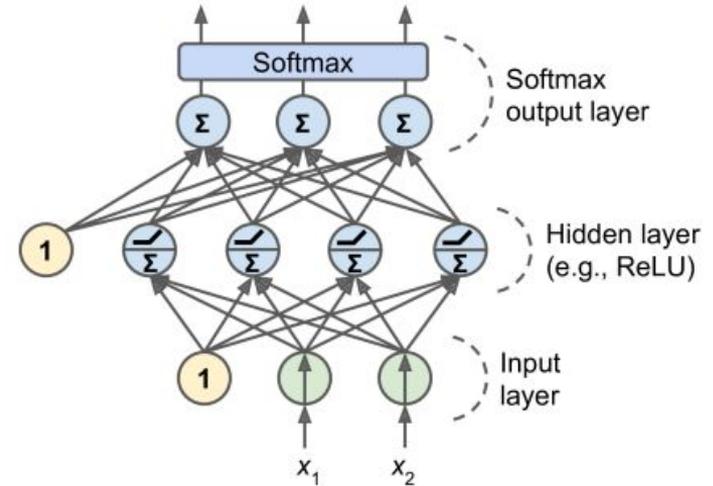
Si se necesita predecir un valor único, entonces se necesita sólo una unidad de salida en la red neuronal. Podemos no sólo predecir un único valor, sino que también podríamos predecir un vector de valores, simplemente al colocar tantas unidades como sea necesario en la capa de salida.



# Clasificación con MLP

Para una clasificación binaria, podemos colocar una unidad única en la capa de salida y aplicar una función de activación logística para obtener valores entre 0 y 1 para poder interpretar la salida como la probabilidad de pertenecer a la clase positiva.

Podemos también resolver problemas multiclase (múltiples unidades con activación softmax) y multietiqueta (múltiples unidades con activaciones logísticas).



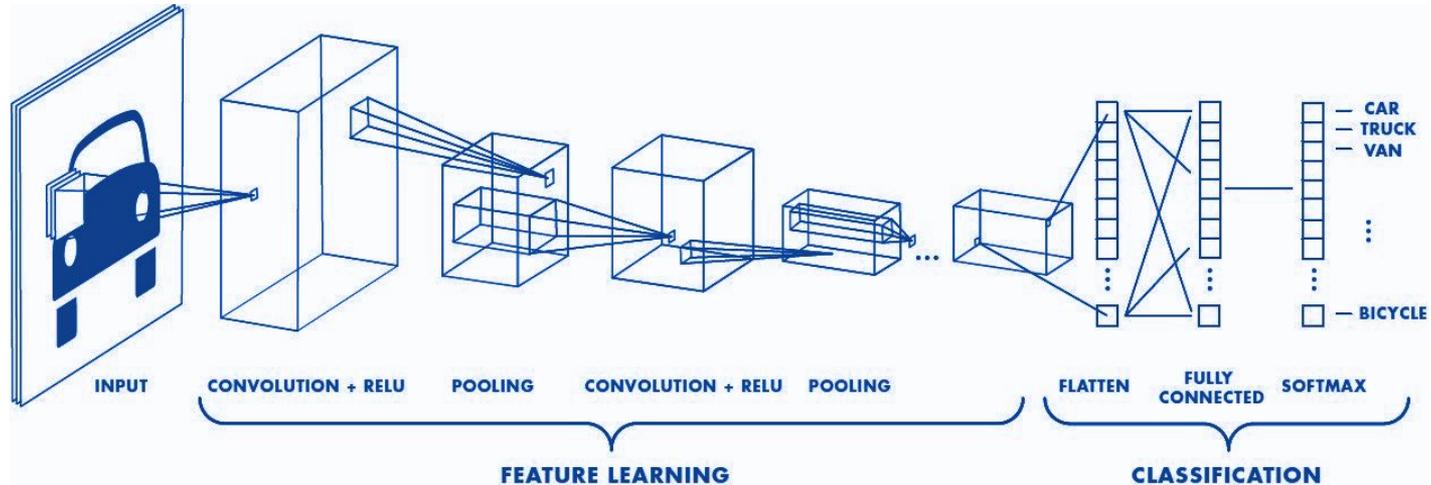
# Hiperparámetros

En un perceptrón multicapa tenemos múltiples hiperparámetros que podemos modular para poder cambiar la arquitectura de la red. Uno de los hiperparámetros más importantes son:

- Cantidad de capas ocultas
- Cantidad de unidades por capa oculta
- Learning rate: Cantidad relativa en la cual se cambiarán los pesos de la red.
- Batch size: Cantidad de elementos que se le pasan a la red en cada ciclo de backpropagation:

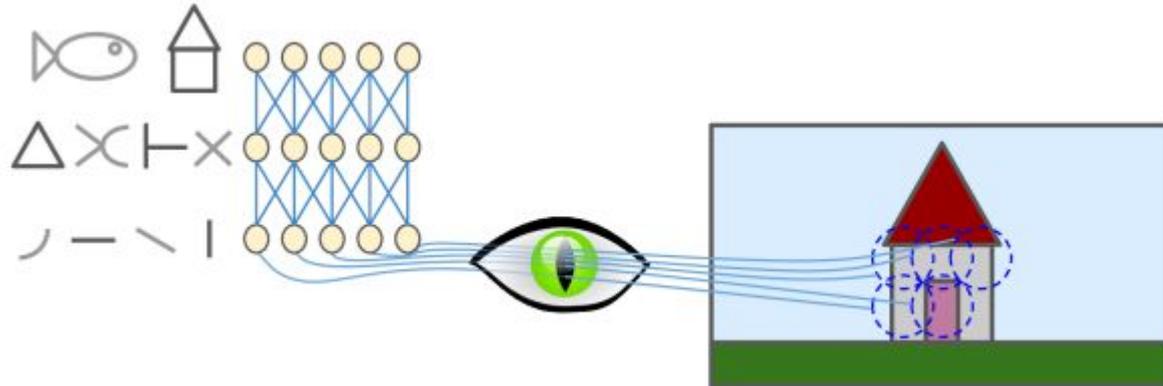
# Imágenes

Las imágenes son un tipo de dato no estructurado, el cual debemos ser capaces de representar de una manera numérica para poder ser analizado. A través de redes neuronales profundas somos capaces de representar una imagen y analizarla.



# La corteza visual

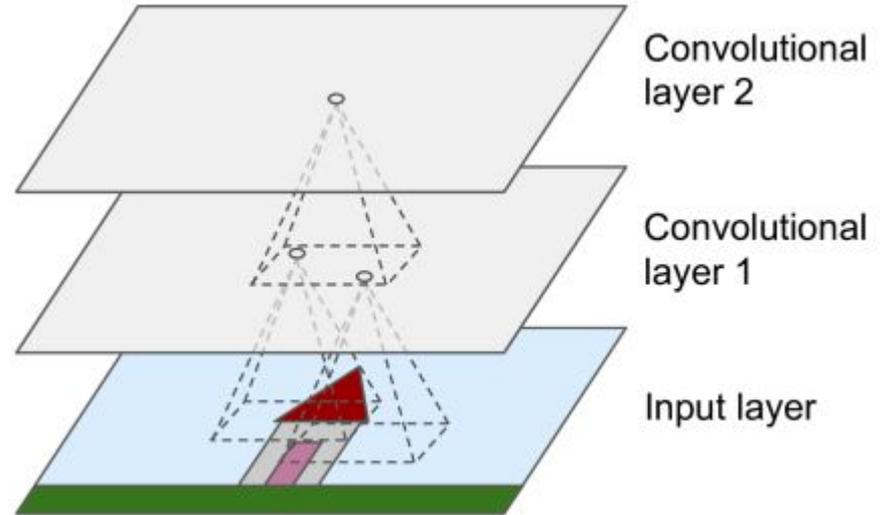
Muchas neuronas en la corteza visual tienen un campo receptivo pequeño, eso significa que sólo son capaces de reaccionar ante estímulos en un campo visual acotado. Otras neuronas tienen campos receptivos más grandes y ellas reaccionan a patrones más complejos que son combinaciones de patrones más simples.



# La convolución

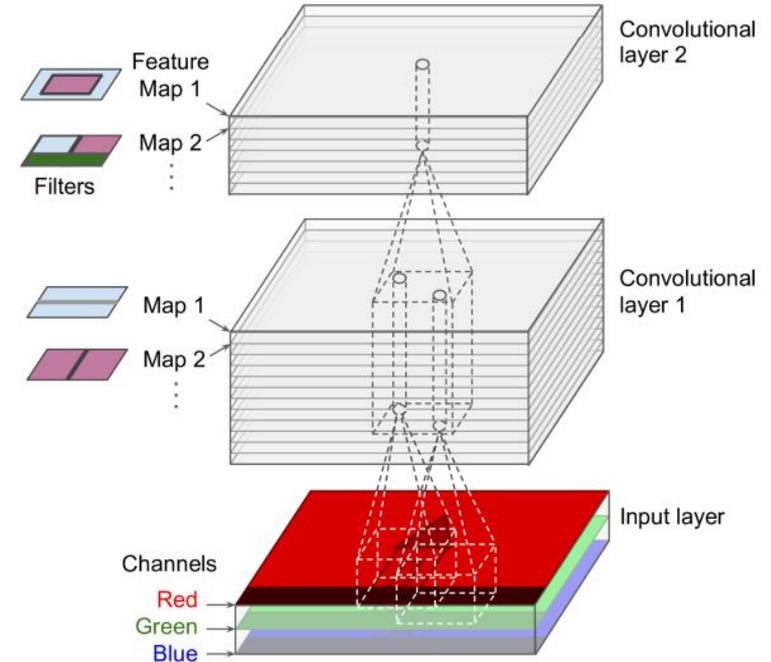
A través de esta técnica podemos ir aprendiendo a distinguir patrones simples y componerlos en patrones más complejos.

Esta estructura jerárquica de patrones es común en las imágenes del mundo real.



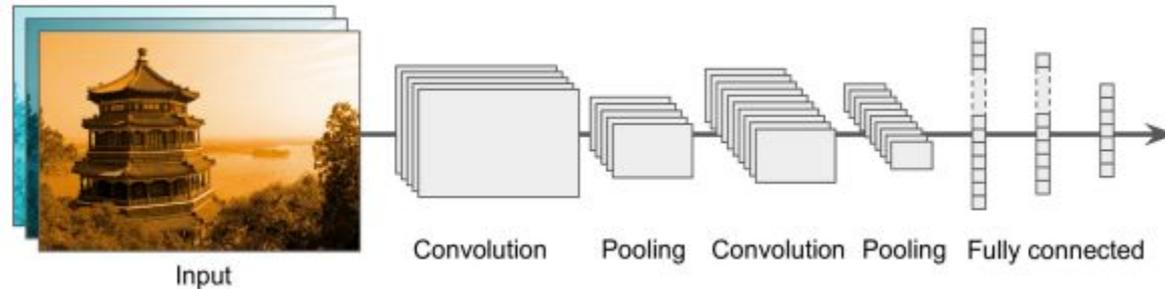
# Redes convolucionales

A través de distintas capas convolucionales podemos calcular distintas características de nuestra imagen, para poder realizar análisis sobre ella.



# Clasificación de imágenes

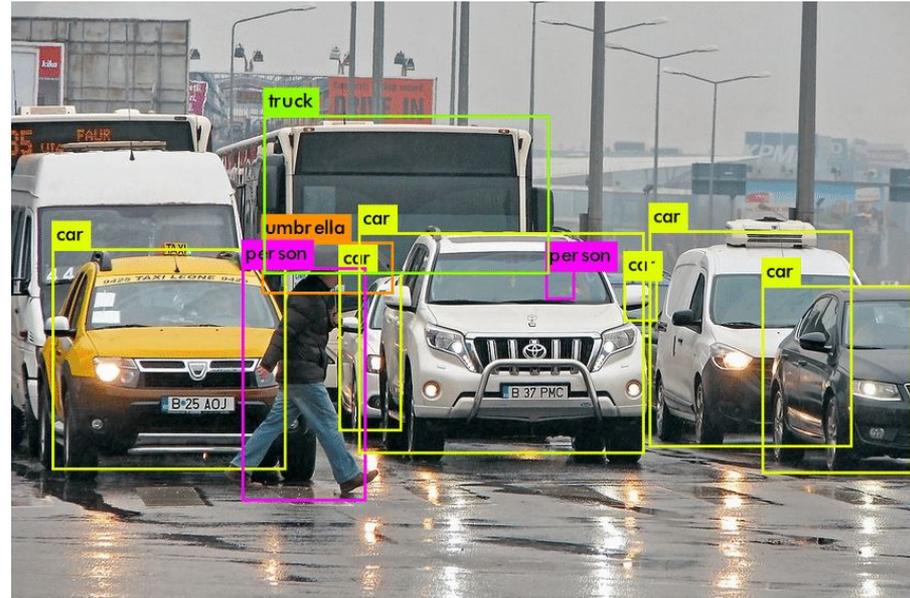
Después de las capas de convolución podemos adicionar una red totalmente conectada (perceptrón multicapa) y poder realizar una clasificación sobre las características aprendidas de la imagen.



# Detección de objetos

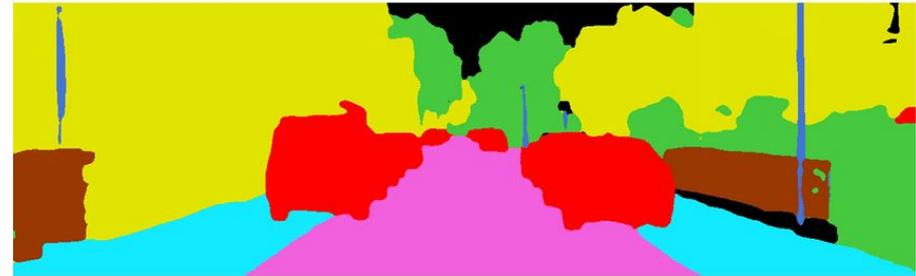
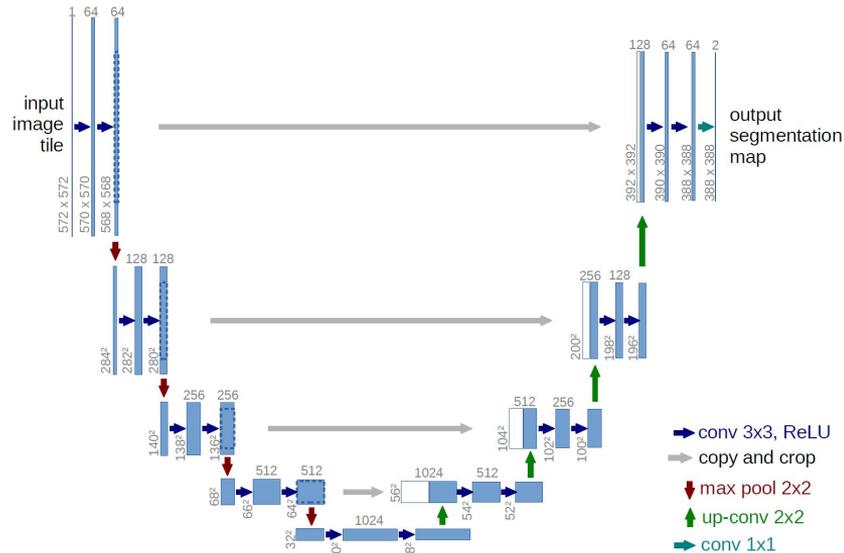
Existen múltiples arquitecturas para resolver la tarea de detección de objetos.

Una de las formas más simples es utilizar una red que clasifique el objeto que estamos buscando, aplicándola en una ventana de la imagen en donde queremos detectar el objeto.



# Segmentación semántica

En esta tarea buscamos clasificar cada uno de los pixeles dentro de una clase.



 Road	 Sidewalk	 Building	 Fence
 Pole	 Vegetation	 Vehicle	 Unlabel

# Procesamiento de Lenguaje Natural

El procesamiento de lenguaje natural es el área que **analiza las interacciones entre sistemas computacionales y los lenguajes humanos.**

- Reconocimiento de voz
- Entendimiento del lenguaje natural
- Generación de lenguaje natural

**Gift shop**

Items such as caps, t-shirts, sweatshirts and other miscellanea such as buttons and mouse pads have been designed. In addition, merchandise for almost all of the projects is available.



**Hi. I'm your automated online assistant. How may I help you?**

CD or DVD

There is a series of CDs/DVDs with selected Wikipedia content being produced by Wikipedians and [SOS Children](#).



**Downloading**

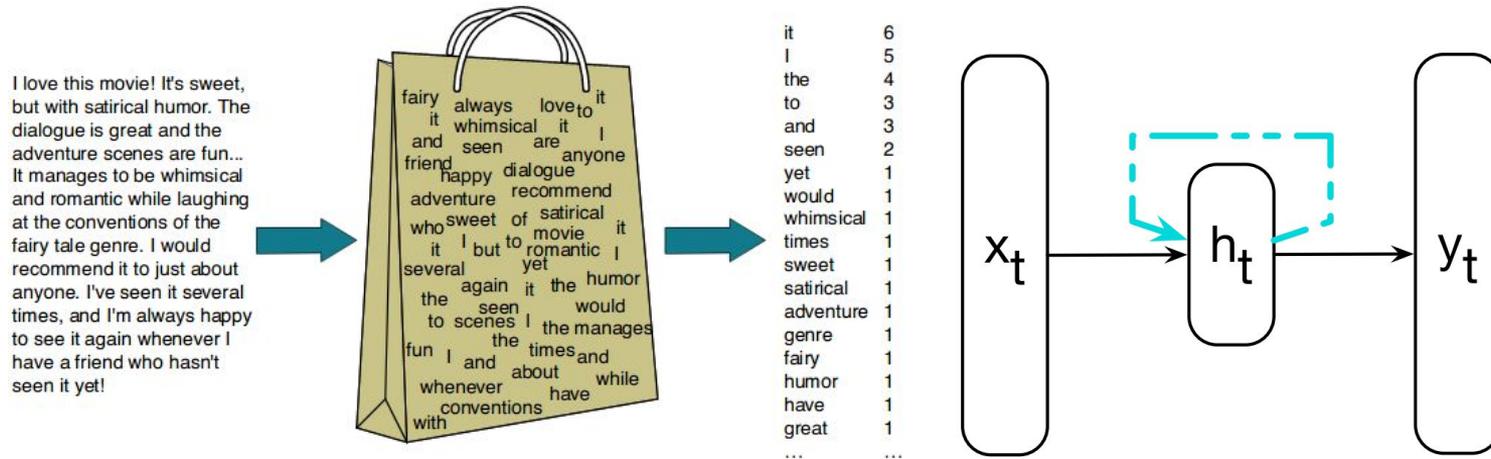
Downloading content from Wikipedia is free of charge. All text content is licensed under the [GNU Free Documentation License](#).



(GFDL). Images and other files are available under [different terms](#), as detailed on

# Representaciones de texto

Para poder representar un texto podemos utilizar **métodos simples de vectorización que no toman en cuenta el orden de las palabras** dentro del documento (bolsa de palabras o TF\*IDF) o podemos utilizar representaciones más complejas que pueden tomar en cuenta el orden de las palabras.

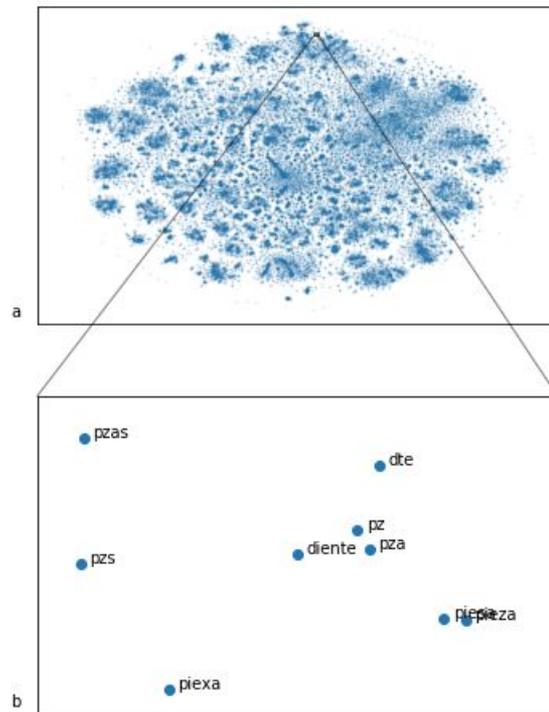


# Word embeddings

Las representaciones de texto modernas aprenden **representaciones unitarias de cada una de las palabras del conjunto de entrenamiento** para posteriormente poder representar una secuencia de texto.

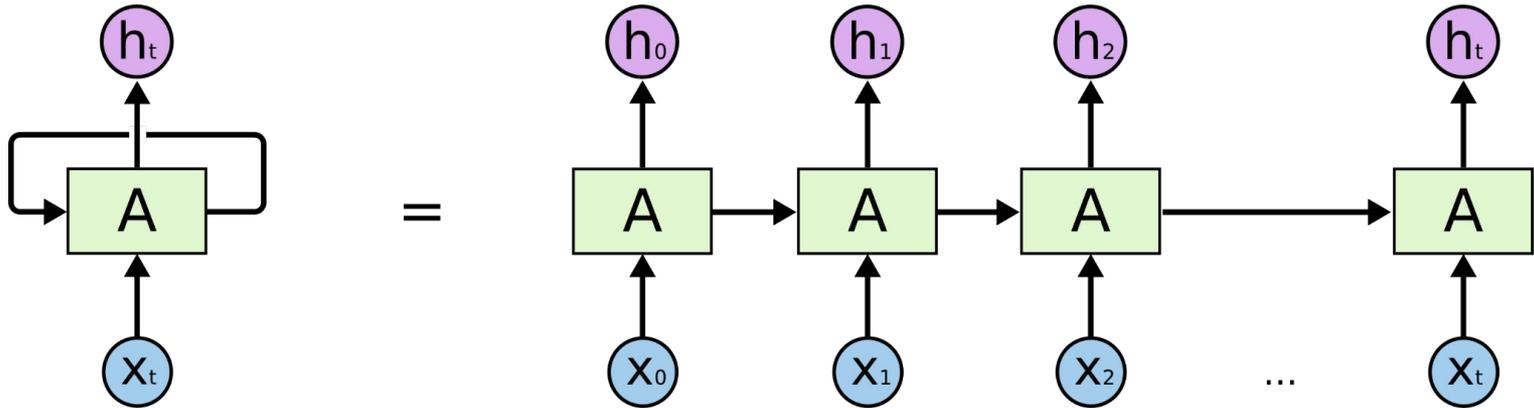
Estas representaciones independientes de palabras pueden ser mejoradas al generar representaciones que tomen en cuenta el contexto para determinar la representación de las palabras.

t-SNE Projection of Word Embeddings



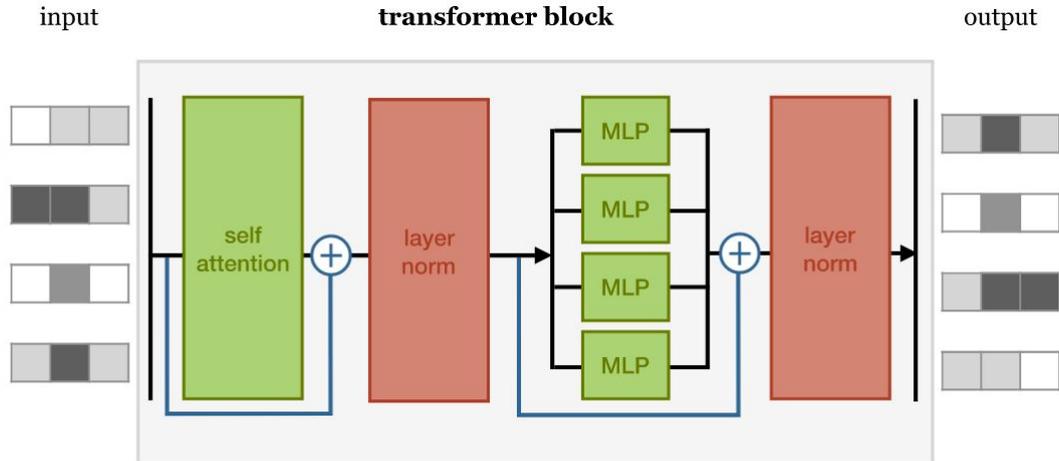
# Redes Neuronales Recurrentes

Una de las formas modernas de representación de texto que toma en cuenta el orden de las palabras es **la utilización de redes neuronales recurrentes para que desde los embeddings de las palabras, podemos obtener una representación de un documento completo**. El problema es que estas representaciones son seriales, por ende su cálculo no es eficiente y además se pierde la información distante.



# Transformers

El problema de la información distante y la naturaleza secuencial de las redes recurrentes llevaron al desarrollo de los Transformers; un acercamiento al **procesamiento de secuencias que elimina las conexiones recurrentes** y se asemeja más a las redes totalmente conectadas.



# Clasificación de texto

Podemos representar el texto utilizando una red recurrente o una red basada en transformers y agregar una red totalmente conectada al final para realizar la predicción de la clase.

Villena et al. *BMC Med Inform Decis Mak* (2021) 21:208  
<https://doi.org/10.1186/s12911-021-01565-z>

BMC Medical Informatics and  
Decision Making

RESEARCH ARTICLE

Open Access

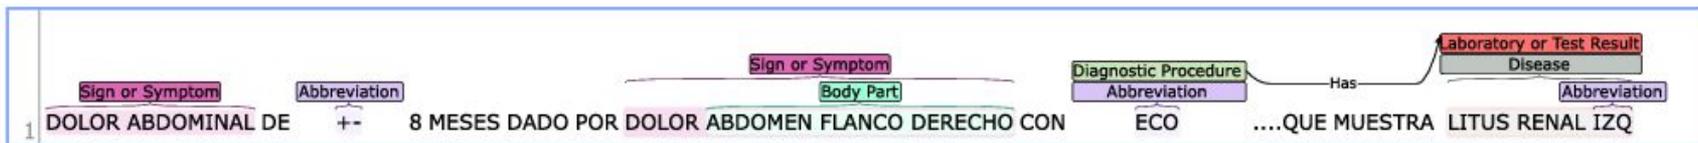
Supporting the classification of patients in public hospitals in Chile by designing, deploying and validating a system based on natural language processing



Fabián Villena<sup>1,2</sup>, Jorge Pérez<sup>3,4</sup>, René Lagos<sup>5</sup> and Jocelyn Dunstan<sup>1,2\*</sup> 

# Reconocimiento de entidades nombradas

Podemos representar cada una de las palabras del texto con alguna técnica de aprendizaje profundo y posteriormente vamos clasificando cada palabra en una de las categorías que estamos buscando



## Automatic Extraction of Nested Entities in Clinical Referrals in Spanish

PABLO BÁEZ, Center for Medical Informatics and Telemedicine, University of Chile, Chile

FELIPE BRAVO-MARQUEZ, Department of Computer Science, University of Chile and IMFD, Chile

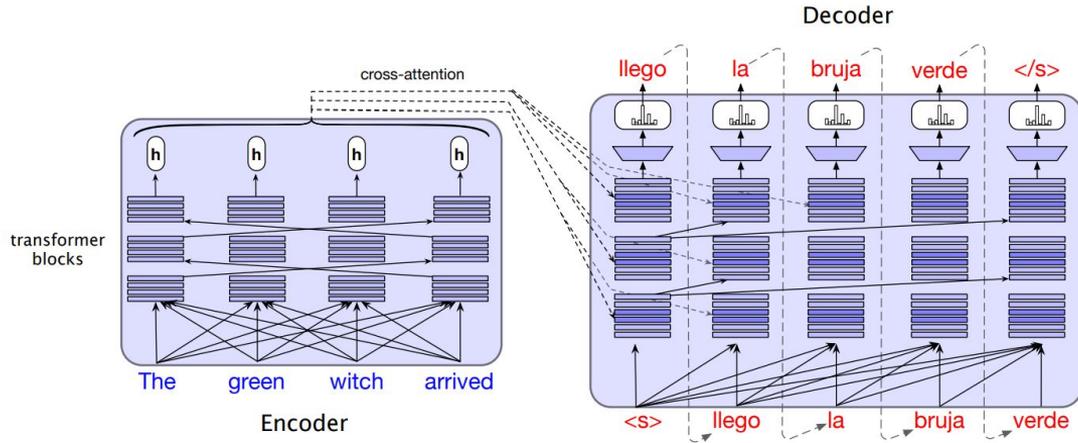
JOCELYN DUNSTAN, Initiative for Data & Artificial Intelligence and Center for Mathematical Modeling - CNRS IRL 2807, University of Chile, Chile

MATÍAS ROJAS, Department of Computer Science, University of Chile, Chile

FABIÁN VILLENA, Center for Mathematical Modeling - CNRS IRL 2807, University of Chile, Chile

# Traducción automática

Podemos representar la semántica de un texto a través de redes neuronales para poder decodificar esta representación en un idioma distinto al original.



# Modelos de lenguaje

Un modelo de lenguaje estima la probabilidad de una secuencia de palabras. Con estos modelos podemos ser capaces de generar texto.

## **Clinical Flair: A Pre-Trained Language Model for Spanish Clinical Natural Language Processing**

**Matías Rojas<sup>1,3</sup>, Jocelyn Dunstan<sup>2,3,4</sup>, and Fabián Villena<sup>1,3</sup>**

<sup>1</sup>Department of Computer Sciences, University of Chile.

<sup>2</sup>Initiative for Data & Artificial Intelligence, University of Chile.

<sup>3</sup>Center for Mathematical Modeling - CNRS IRL 2807, University of Chile.

<sup>4</sup>Millenium Institute for Intelligent Healthcare Engineering, ANID, Chile.

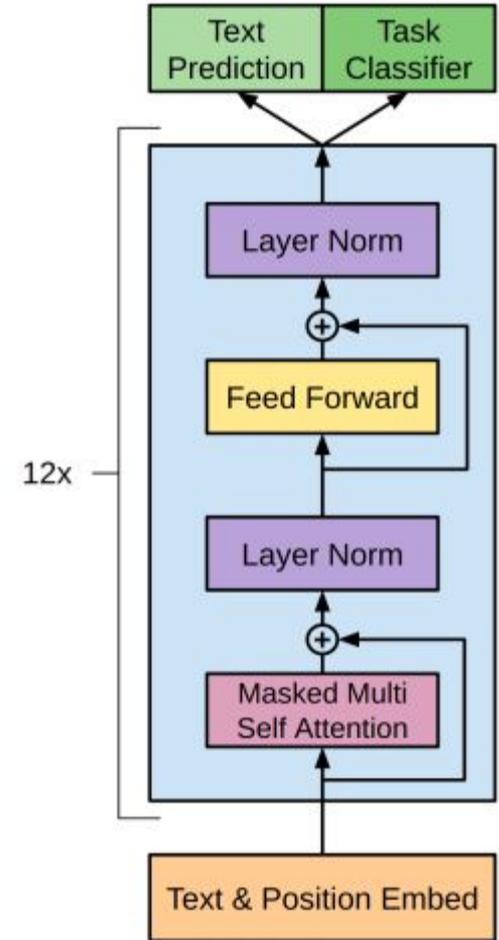
`matias.rojas.g@ug.uchile.cl`

`{jdunstan, fabian.villena}@uchile.cl`

# GPT

Generative Pre-trained Transformer es una arquitectura que **utiliza sólo un decoder para ajustar un modelo de lenguaje para la predicción de la siguiente palabra.**

Esta arquitectura sólo puede atender a las palabras previamente vistas para predecir la siguiente. Esto puede ser limitante para poder codificar oraciones, porque uno debe observar toda la oración para poder entender una palabra.



# BERT

Bidirectional Encoder Representations from Transformers utiliza la arquitectura de encoder.

Esta arquitectura permite **obtener información de la secuencia completa a través de cambiar la tarea de predicción de la siguiente palabra por la predicción de una palabra enmascarada** dentro de la oración.

