Codificadores Neuronales

Pedro Almagro Blanco

May 12, 2016

Red Neuronal Artificial Feedforward Multi-capa

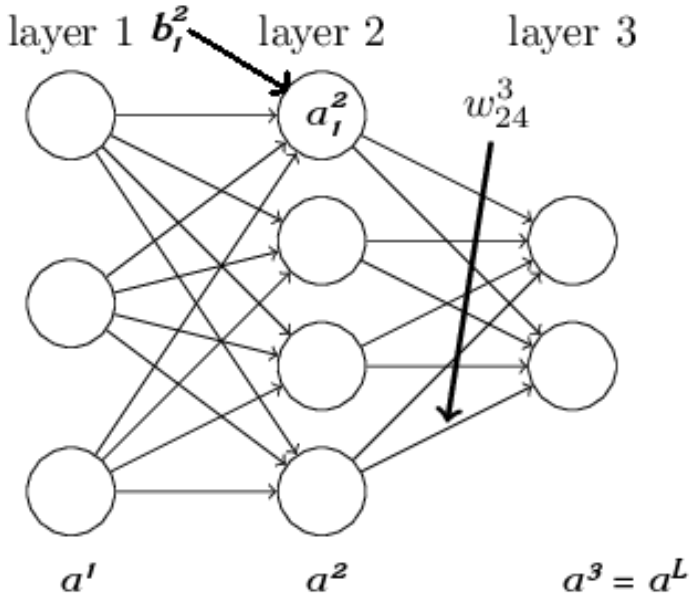

Hasta ahora hemos hecho uso de las redes neuronales feedforward como máquinas de cálculo, en esta ocasión presentamos un uso de las mismas que será (y ha sido) de fundamental importancia para los nuevos resultados que se han obtenido con ellas.

Codificador Neuronal

Objetivo: Aprender una codificación a partir de un conjunto de datos.

- Si estamos intentando aproximar una función por medio de una red que tiene una capa oculta, tras el ajuste de los parámetros podemos pensar que la capa oculta mantiene la información necesaria de los datos de entrada que son necesarios para el cálculo de la función.
- Desde el punto de vista de la función que calcula la red, podemos decir que la capa oculta codifica los datos de entrada.
- Los pesos (y bias) que se han usado definen la función de codificación entre ambos espacios.

Codificador Neuronal

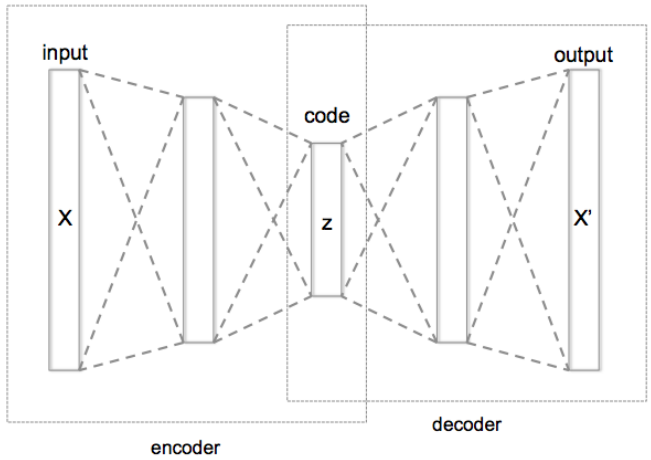

Si prescindimos de las capas posteriores, obtenemos una nueva red neuronal que produce como salida una representación del espacio de entrada en un espacio de dimensión concreta (el número de neuronas en la capa oculta que se ha considerado).

Codificador Neuronal

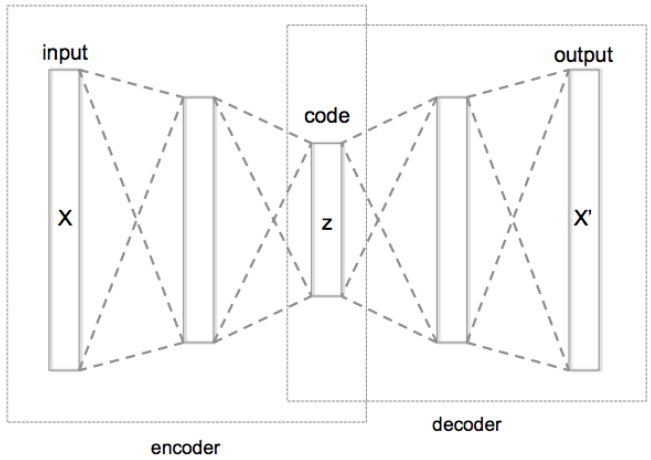

Esta representación se consigue como aplicación parcial de una función que se ha obtenido a partir de una red feedforward que aproxima una función prefijada y, consecuentemente, la codificación obtenida es relativa a esta función (y al proceso de aproximación).

Autocodificadores neuronales

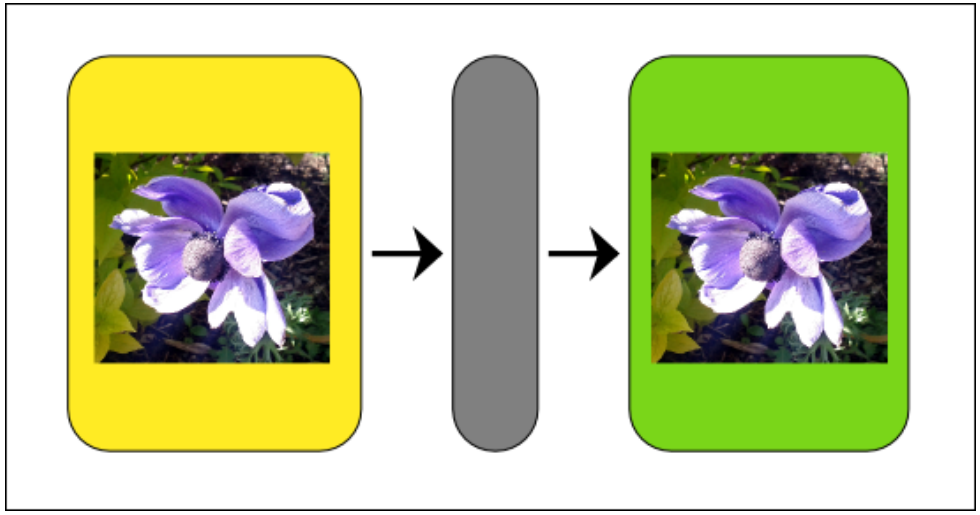

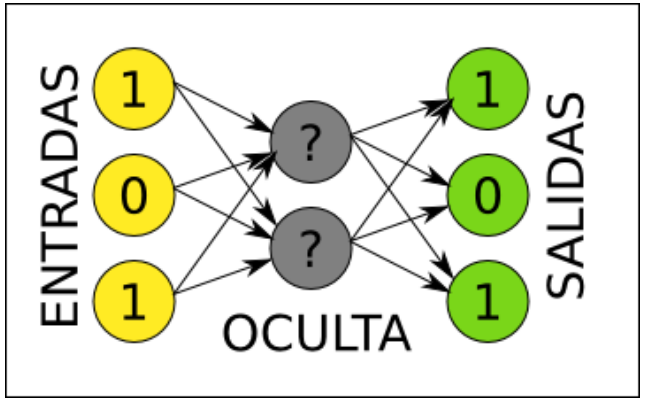

Autocodificadores neuronales

- Los autocodificadores son un caso concreto de codificador neuronal en el que se ha intentado aprender la función identidad ($|a^1| = |a^L|$).
- El conjunto de muestras de entrenamiento sería $\{(\vec{x}^1, \vec{x}^1), \ldots, (\vec{x}^N, \vec{x}^N)\}$.
- Cuando la red alcanza un estado aceptable, las activaciones en las unidades de las capas ocultas capturan información del dato original $\vec{x}$ presentado en la capa de entrada.
- Si el número de unidades en la capa oculta usada para la codificación difiere del número de unidades en la capa de entrada (y salida) estaremos además haciendo una cambio dimensional al realizar la codificación.
- Si los tamaños de las capas ocultas son los mismos que las capas de entrada y salida se deben imponer condiciones adicionales para no estar aprendiendo la función identidad de forma trivial (factor de dispersión, ruido en la entrada...).

Autocodificadores y Deep Learning

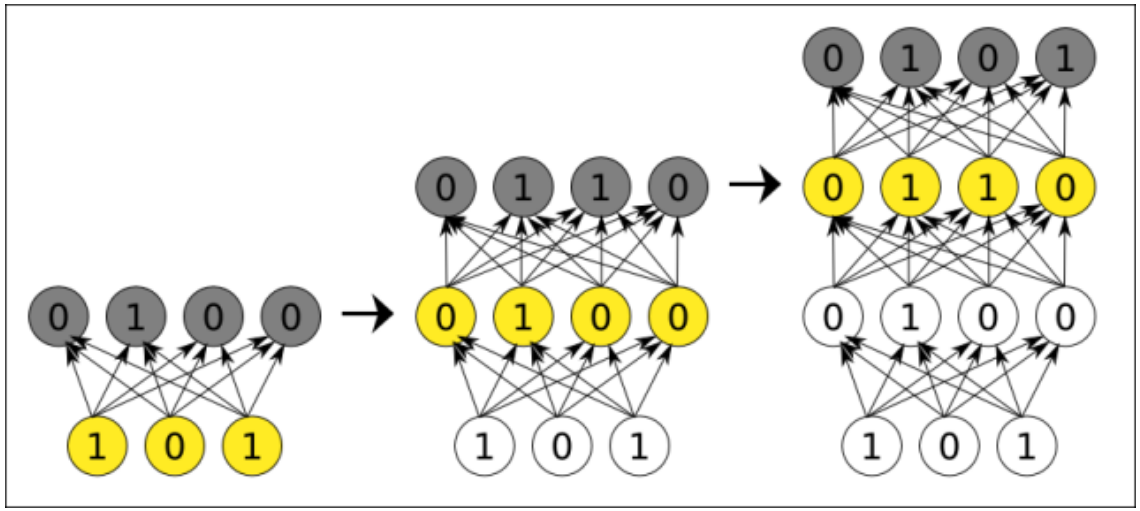

- Herramienta utilizada habitualmente para pre-entenar las capas en una Red Neuronal Profunda (Deep Learning).
- Una vez entrenado un auto-codificador, la segunda mitad de la red se puede descartar, nos interesa sólo la parte que codifica.
- Apilaremos la primera mitad de varios autocodificadores, de tal manera que la codificación obtenida en el autocodificador l será el vector utilizado para entrenar el autocodificador $l + 1$.

Autocodificadores y Deep Learning

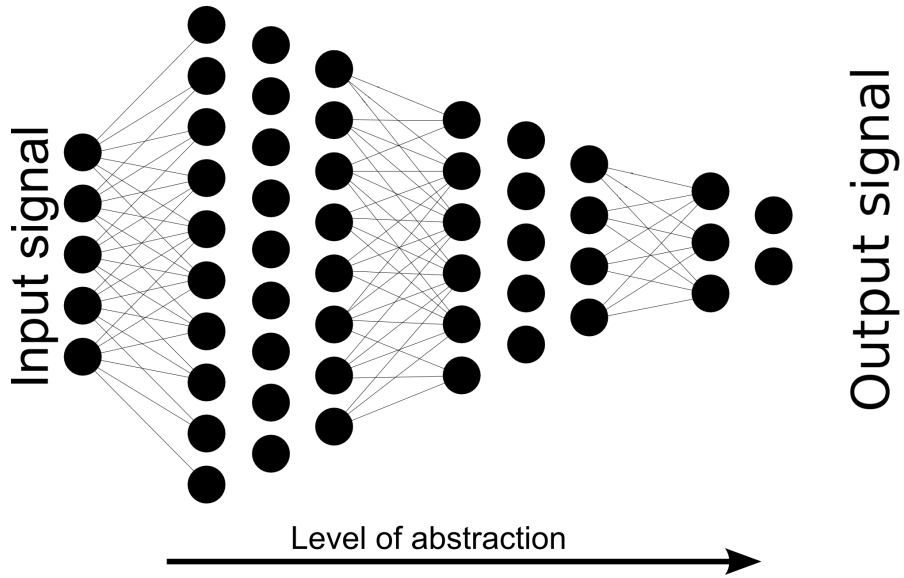

- Una vez que hemos apilado los diferentes codificadores, obtenemos una red profunda pre-entrenada a la que ahora podemos aplicar *backpropagation* sabiendo que se encuentra *cerca* de una configuración *óptima*.

Word2Vec

- Una de las aplicaciones de los codificadores neuronales que mejores resultados ha proporcionado es la realizada con palabras.
- Word2Vec es el nombre genérico de dos arquitecturas de codificadores neuronales: *Continuous bag-of-words* (CBOW) y *Skip-gram*.

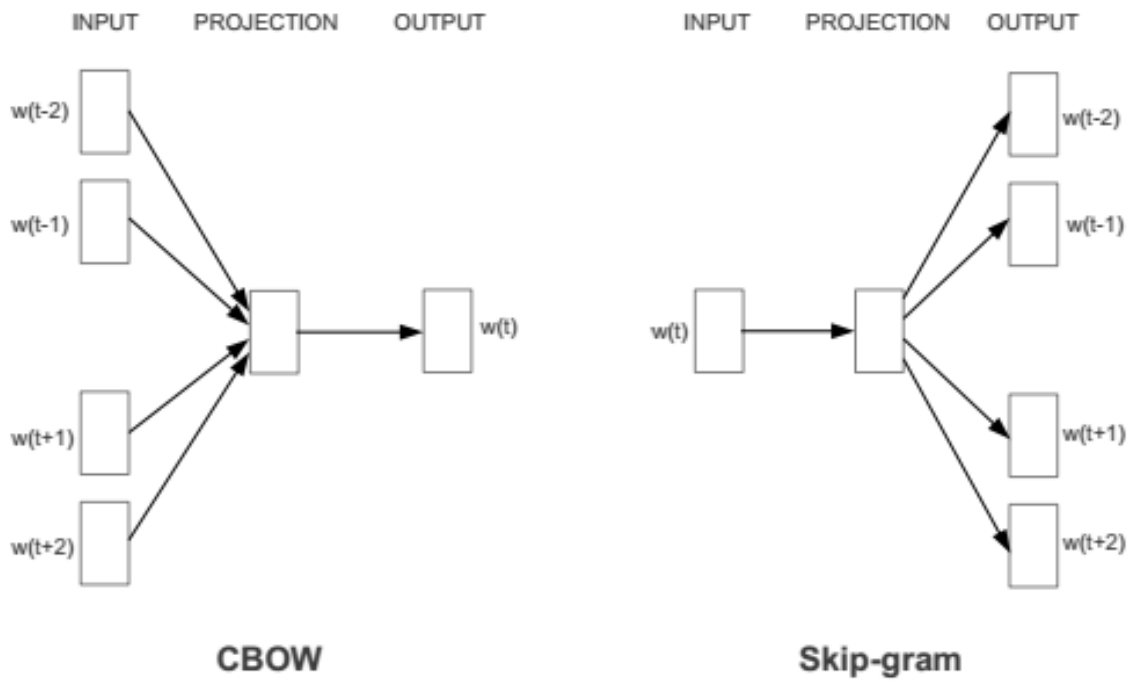

Word2Vec

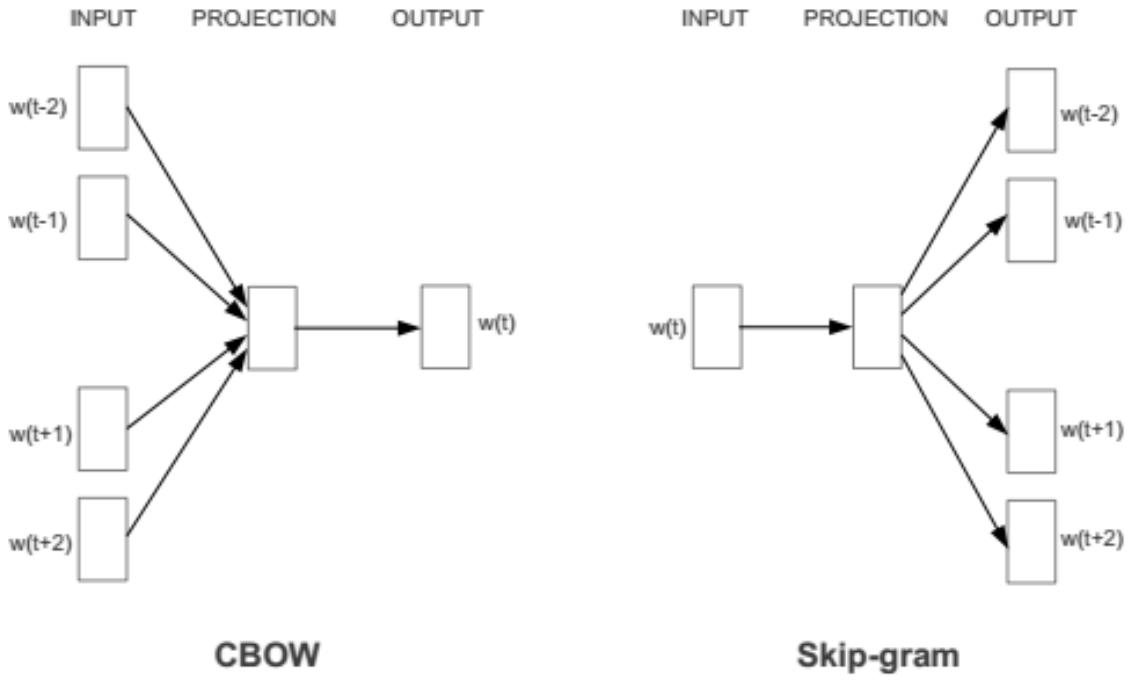

- Ambas arquitecturas consisten en redes neuronales artificiales feedforward con 3 capas, pero se diferencian en la función objetivo que intentan aproximar.

Word2Vec

- Fijaremos un vocabulario de trabajo V extraído a partir de los textos que sirven de corpus para el aprendizaje. En ocasiones se trabaja únicamente con los lemas de las palabras y/o se eliminan *stopwords*.
- Las capas de entrada y de salida tendrán tantas neuronas como palabras distintas haya en el vocabulario, de forma que si ordenamos el vocabulario, $V = \{w^1, \ldots, w^k\}$, entonces la neurona i-ésima de esas capas codificará a w^i.
- El tamaño del contexto, también llamado *ventana*, es variable y se decide en función de la codificación a realizar, por lo que se convierte en un parámetro libre de los modelos.
- La tarea de entrenamiento supervisado se realizará con el conjunto de muestras de la forma (w, C) en el caso de la arquitectura Skip-gram, y a través de un conjunto de muestras de la forma (C, w) en el caso de la arquitectura CBOW, donde w representa una de las palabras de V, y C representa uno de los posibles contextos asociados a dicha palabra.

Word2Vec

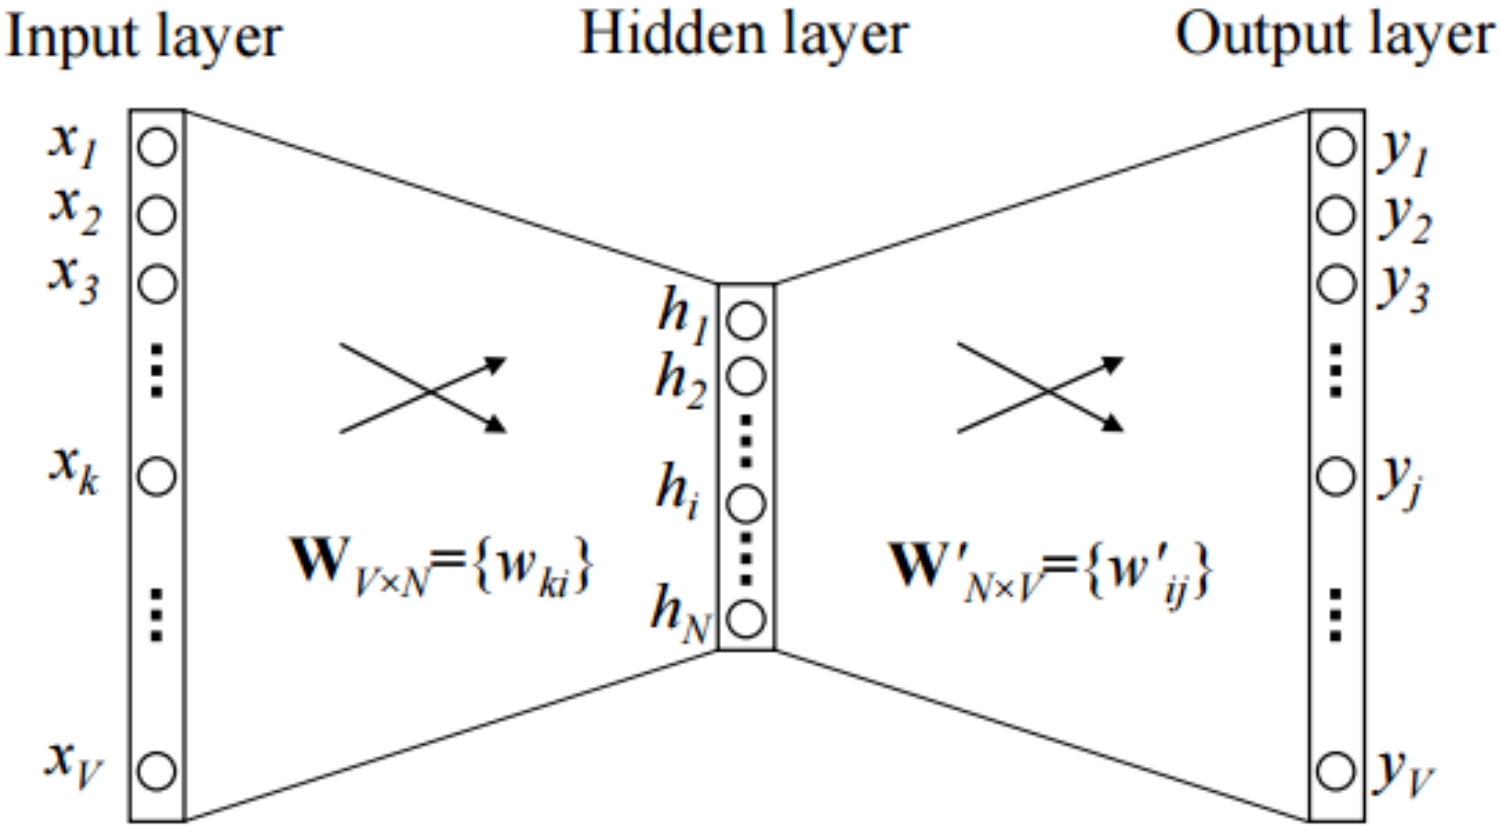
Input layer
Hidden layer
Output layer
x_1
x_2
x_3
x_k
x_V
h_1
h_2
h_i
h_N
y_1
y_2
y_3
y_j
y_V
$\mathbf{W}_{V\times N}=\{w_{ki}\}$
$\mathbf{W}'_{N\times V}=\{w'_{ij}\}$

Word2Vec

Tras conseguir la aproximación deseada:

- El vector de activaciones de la capa oculta $\vec{a}^2$ que se obtiene al usar como entrada de la red una palabra determinada del vocabulario ($\vec{a}^1 = w^i$) en el caso de la arquitectura Skip-gram representa la codificación de dicha palabra en el nuevo espacio vectorial.
- En el caso de la arquitectura CBOW, el vector de activaciones de la capa oculta $\vec{a}^2$ resultante al ingresar el vector promedio de los vectores contexto asociados a una palabra determinada w^i por las entradas de la red ($\vec{a}^1 = C^i$) representa la codificación de la palabra w^i asociada a dichos contextos en el nuevo espacio vectorial.

Word2Vec

El objetivo principal del citado trabajo de Mikolov et al. es reducir la complejidad en el modelo neuronal para permitir al sistema aprender a partir de un volúmen *enorme* de datos textuales. Hasta la llegada de word2vec, ninguna arquitectura de este tipo había sido capaz de entrenarse con más de algunos millones de palabras.

Por medio de la relación que se establece entre las palabras del vocabulario y sus contextos, el modelo captura diferentes tipos de similaridad y proporciona una inmersión en el espacio vectorial que refleja estas similaridades. Así, puede capturar por ejemplo:

$$w2v(\text{"}Hombre\text{"}) - w2v(\text{"}Mujer\text{"}) + w2v(\text{"}Rey\text{"}) \approx w2v(\text{"}Reina\text{"})$$

Word2Vec

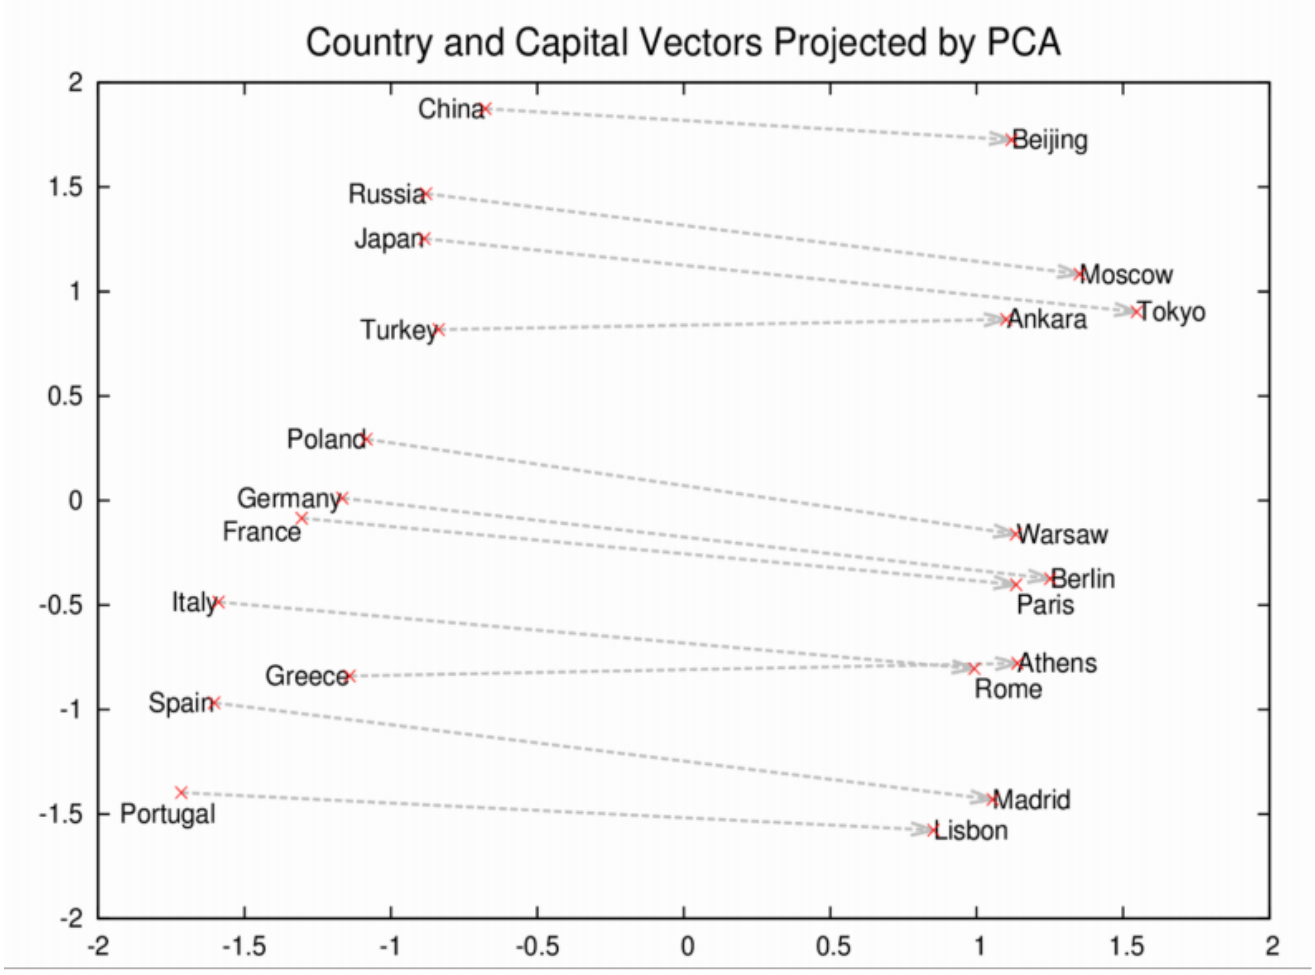
Country and Capital Vectors Projected by PCA
China
Beijing
Russia
Japan
Moscow
Tokyo
Turkey
Ankara
Poland
Germany
France
Warsaw
Berlin
Paris
Italy
Athens
Greece
Rome
Spain
Madrid
Portugal
Lisbon
2
1.5
1
0.5
0
-0.5
-1
-1.5
-2
-2
-1.5
-1
-0.5
0
0.5
1
1.5
2