

Aplicaciones de la Teoría de Redes al Procesamiento del Lenguaje Natural

Alvaro J. Riascos Villegas

Febrero, 2016

Contenido

1 Introducción: Teoría de Redes

2 Redes do Coocurrencia

3 Redes de Asociaciones

4 Aplicaciones


5 Construcción de Redes

6 Resumenes de Textos

7 Aplicación

Ejemplos de Redes: Matrimonios Familia Medici, Florencia 1400

- Padgett, J.F y C.K. Ansell (1993). Robust action and the rise of the Medici, 1400-1434.
- Red de matrimonios entre familias (cada enlace representa un matrimonio entre miembros de dos familias).



Ejemplos de Redes: Matrimonios Familia Medici, Florencia 1400

- Basados en la riqueza y poder político es difícil explicar como los Medici surgieron como una familia tan importante (la familia Strozzi tenía más riqueza y poder político, sin embargo fueron opacados por los Medici).
- La estructura de relaciones puede ser un determinante.
- Si comparamos con cuántas familias se encuentra una familia específica relacionada y comparamos entre ellas, los Medici sobresalen (3 a 2).
- Una relación de cercanía resulta más sugestiva.

Ejemplos de Redes: Matrimonios Familia Medici, Florencia 1400

- Sea $P(ij)$ el número de caminos más cortos que conectan una familia i con j . Sea $P_k(ij)$ el número de estos caminos que incluyen a la familia k .
- Por ejemplo si $i =$ Barbadori, $j =$ Guadagni, entonces $P(ij) = 2$. Si $k =$ Medici entonces $P_k(ij) = 2$ mientras que si $k =$ Strozzi o Albizzi $P_k(ij)$ es cero o uno respectivamente.

Ejemplos de Redes: Matrimonios Familia Medici, Florencia 1400

- Si calculamos una medida de importancia (betweenness Freeman) de cada familia k como:

$$\sum_{i,j: i \neq j, k \in \{i,j\}} \frac{\frac{P_k(ij)}{P(ij)}}{(n-1)(n-2)/2} \quad (1)$$

donde $\frac{P_k(ij)}{P(ij)} = 0$ si no hay caminos entre i y j . El coeficiente $(n-1)(n-2)/2$ es el número máximo de pares de familias que incluirían a la familia k .

- Esta medida de poder para los Medici es 0.522. Esto significa que los Medici están en más de la mitad de los caminos más cortos entre todos los caminos más cortos entre cada par de familias.
- Este mismo cálculo para los Strozzi es 0.103. El segundo más alto es los Guadagni que es 0.255.
- En este sentido los Medici estaban mejor posicionados que cualquier otra familia.
- Esta estructura es endógena? Es óptima?

Ejemplos de Redes: Amistades y romances en estudiantes secundaria

- Datos de 90,000 estudiantes de la encuesta Add Health entrevistados en los años 90.
- A los estudiantes se les preguntaba con quién habían tenido relaciones románticas en los últimos seis meses.




Figure 1.2: A Figure from Bearman, Moody and Stovel [47] based the Add Health Data Set. A Link Denotes a Romantic Relationship, and the Numbers by Some Components Indicate How Many Such Components Appear.

Ejemplos de Redes: Formación aleatoria de redes




Figure 1.7: Frequency Distribution of a Randomly Generated Network and the Poisson Approximation for a Probability of .08 on each Link

Contenido

1 Introducción: Teoría de Redes

2 Redes do Coocurrencia

3 Redes de Asociaciones

4 Aplicaciones

5 Construcción de Redes

6 Resumenes de Textos

7 Aplicación

Redes do Coocurrencia

- Son redes que se construyen usando como nodos palabras (o solamente las que pertenecen a algún tipo de palabra) y creando un enlace entre ellas cuando aparecen juntas en una ventana de N-palabras (puede ser en una frase o parágrafo).
- Pueden ser redes dirigidas o no y con pesos (usando la verosimilitud, etc).
- Ferrer-i-Cancho y Sole (2001) muestran que este tipo de redes tienen características de mundos pequeños. Diametro de aprox. 2,65 y coeficiente de clustering 0,5 y distr. libre de escala.
- Usan British National Corpus ($n = 470,000$, $m = 170mm$).

Redes do Coocurrencia

- Son redes que se construyen usando como nodos palabras (o solamente las que pertenecen a algún tipo de palabra) y creando un enlace entre ellas cuando aparecen juntas en una ventana de N-palabras (puede ser en una frase o parágrafo).
- Pueden ser redes dirigidas o no y con pesos (usando la verosimilitud, etc).
- Ferrer-i-Cancho y Sole (2001) muestran que este tipo de redes tienen características de mundos pequeños. Diametro de aprox. 2,65 y coeficiente de clustering 0,5 y distr. libre de escala.
- Usan British National Corpus ($n = 470,000$, $m = 170mm$).

Redes do Coocurrencia

- Son redes que se construyen usando como nodos palabras (o solamente las que pertenecen a algún tipo de palabra) y creando un enlace entre ellas cuando aparecen juntas en una ventana de N-palabras (puede ser en una frase o parágrafo).
- Pueden ser redes dirigidas o no y con pesos (usando la verosimilitud, etc).
- Ferrer-i-Cancho y Sole (2001) muestran que este tipo de redes tienen características de mundos pequeños. Diametro de aprox. 2,65 y coeficiente de clustering 0,5 y distr. libre de escala.
- Usan British National Corpus ($n = 470,000$, $m = 170mm$).

Redes do Coocurrencia

- La distribución del grado sigue una power law con parámetro $-1,5, -2,7$. Esta regularidad empírica sirve para validar una teoría: existe un kernel lexicon del inglés que comparten la mayoría de personas (50m palabras) y una lista de palabras menos usadas.

- Ferrer-i-Cancho y Sole (2001) muestran que este tipo de redes tienen características de mundos pequeños. Diametro de aprox. 2,65 y coeficiente de clustering 0,5 y distr. libre de escala.
- Usan British National Corpus ($n = 470,000$, $m = 170mm$).
- La distribución del grado sigue una power law con parámetro $-1,5$, $-2,7$. Esta regularidad empírica sirve para validar una teoría: existe un kernel lexicon del inglés que comparten la mayoría de personas (50m palabras) y una lista de palabras menos usadas.

Redes de Coocurrencia: Ejemplos

- Masucci y Rodgers (2006). Palabras adyacentes en la novela de Orwell 1984.
 - Encuentran evidencia fuerte de power laws.




Figure 4.2. The graph corresponding to the beginning of 1984.

Contenido

- 1 Introducción: Teoría de Redes
- 2 Redes do Coocurrencia
- 3 **Redes de Asociaciones**
- 4 Aplicaciones
- 5 Construcción de Redes
- 6 Resumenes de Textos
- 7 Aplicación

Ejemplos de Redes: Semánticas

- Steyvers y Tenenbaum (2005): Experimento con seis mil personas. Se les dan 500 palabras y ellos declaran si hay alguna asosicación entre pares.




Figure 4.5. Free-word-association network (Steyvers and Tenenbaum 2005b).

Table 4.2. *Properties of semantic networks.*


Property	Associative	Roget	WordNet
C	0.186	0.875	0.0265
C_r	4.35×10^{-3}	0.613	1×10^{-4}

The comparison is between the actual clustering coefficient and the clustering coefficient of a random graph of the same size.

Contenido


- 1 Introducción: Teoría de Redes
- 2 Redes do Coocurrencia
- 3 Redes de Asociaciones
- 4 Aplicaciones**
- 5 Construcción de Redes
- 6 Resumenes de Textos
- 7 Aplicación

Clasificación de textos: Grafo de Documentos



- An undirected bipartite graph is a triple $G = (D, W, E)$ where D, W are two sets of vertices and E is the set of edges. Take D as the set of documents, W as the set of words they contain and an edge exists if word w occurs in document d . Note that the edges are undirected.
- In this model, there are no edges between words or between documents.
- Dhillon (2001) utiliza un algoritmo de particion de redes bipartitas.
- Tiene la ventaja de que usa información sobre las palabras y documentos para hacer la clasificación

- Detección de plagio.
- The concrete task is to implement a graph edit distance algorithm, which calculates similarity between two graphs.
- The algorithm is based on calculating the number of edit operations needed to transform one graph into another (Riesen and Bunke, 2009).



*The ball was kicked out of the stadium
by the boy*

*The player kicked the object out of the
field*

Figure 1.1: Example of dependency graphs




Figure 2.1: An example of edit operations for two graphs

Contenido

- 1 Introducción: Teoría de Redes
- 2 Redes do Coocurrencia
- 3 Redes de Asociaciones
- 4 Aplicaciones
- 5 Construcción de Redes
- 6 Resumenes de Textos
- 7 Aplicación

Construcción de Redes

- Red de términos.
- Red de documentos.
- Red bipartita de términos y documentos.

Contenido

- 1 Introducción: Teoría de Redes
- 2 Redes do Coocurrencia
- 3 Redes de Asociaciones
- 4 Aplicaciones
- 5 Construcción de Redes
- 6 Resumenes de Textos
- 7 Aplicación

Resúmenes de Textos

- Grafos estocásticos.
- RT se basa en la relevancia de ciertas frases.
- LexRank se basa en la centralidad de las frases en un grafo de frases (i.e., PageRank).
- La técnica también puede ser utilizada para tareas como: clasificación de entidades nombradas, adjunción de proposiciones a frases y clasificación de textos.

- La sintetización de textos es típicamente orientada por el tópico de interés.
- El problema que aquí se resuelve es de síntesis de múltiples documentos de tópicos genérico (sin especificar).
- Existen dos grandes formas de hacer resumenes: extraer subconjuntos de frases de los documentos o abstracta, en la que se parafrasea las frases (típico de los resumenes humanos).
- Solamente la primera forma ha alcanzado resultados satisfactorios.

Medidas de la Importancia de Frases: Basadas en centroides

- En un grafo de múltiples documentos se identifican clusters.
- La centralidad de una frase se mide con base en la centralidad de las palabras que contiene.
- Para adeterminar la centralidad de las palabras se construye un pseudodocumento a partir de cada cluster (se llama centroide).
- El centroide del cluster se construye de palabras que tiene un valor mínimo de $tf \times idf$ donde tf es la frecuencia de los términos en el cluster de documentos y idf es la inversa de la frecuencia del término en un corpus de documentos más grande pero afín a los documentos en cuestión.
- Las frases que tengan más palabras del centroide se consideran son consideradas centrales (del cluster?).
- Esta técnica ha sido exitosa y es la base de sistemas de sintetización de multidocumentos: www.newsinessence.com

Medidas de la Importancia de Frases: Basadas en medidas de centralidad

- Todas las propuestas a continuación se basan en el concepto de prestigio en redes.
- La hipótesis es que las frases que son similares a muchas de las frases en el cluster son más relevantes.
- Para esto tenemos que definir similaridad entre frases y segundo la centralidad de una frase dada la similaridad a otras frases.

- Cada frase se representa como un vector N – *dimensional* donde N es el número de palabras posibles del lenguaje en consideración.
- Cada palabra en una frase se le asocia un número en el vector N – *dimensional*: Frecuencia del término en la frase \times idf.
- La similitud entre dos frases se define como (el coseno entre dos vectores: idf-modified-cosine):

$$s(x, y) = \frac{\sum_{w \in x, y} tf_{w,x} tf_{w,y} (idf_w)^2}{\sum_{xi \in x} (tf_{xi,x} idf_{xi})^2 \sum_{yi \in y} (tf_{yi,y} idf_{yi})^2} \quad (2)$$

- Un cluster de documentos se puede representar por una matriz de similitud (coseno) donde cada entrada es la similitud entre la pareja de frases.
- Esta matriz se puede utilizar para representar un grafo con pesos.
- Se puede escoger un umbral para disminuir el número de elementos positivos de la matriz y también olvidarnos de que es un grafo por pesos.

- Grado
- Prestigio (eigenvector centrality y LexRank)
- Considere la siguiente definición de centralidad de un nodo u :

$$p(u) = \sum_v \in adj[u] \frac{p(v)}{deg(v)} \quad (3)$$

Sea B la matriz que se obtiene de la matriz de adjacencia del grafo de similitud de frases normalizando cada entrada por la suma de la fila.

- B representa una matriz de transición de una cadena de Markov.

- B representa una matriz de transición de una cadena de Markov y obsérvese que $p^T B = p^T$. Es decir p corresponde a una distribución estacionaria de B : $\lim_{n \rightarrow \infty} 1^T r$.
- No importa la distribución del estado inicial, asintóticamente la distribución del estado es la distribución estacionaria.
- Para garantizar la existencia de esta distribución estacionaria es necesario que B sea irreducible (cada estado puede ser alcanzado con probabilidad positiva después de suficientes transiciones) y aperiodico (siempre existe la posibilidad de salir cambiar de estado).
- En estas condiciones el teorema de Perron - Frobenius garantiza la existencia de una única distribución estacionaria.

- Para lograr esto se hace la siguiente modificación de la centralidad de cada nodo (i.e., PageRank):

$$p(u) = \frac{d}{N} + (1 - d) \sum_v \in adj[u] \frac{p(v)}{deg(v)} \quad (4)$$

donde N es el total de nodos en un grafo y d es un factor de dumping (típicamente entre 0.1 y 0.2)

- La aplicación de esta forma de calcular la centralidad de cada nodo al grafo de similitud entre frases se denomina LexRank.
- Una versión alterntaiva se basa en la versión del grafo de similitud por pesos.

Contenido

- 1 Introducción: Teoría de Redes
- 2 Redes do Coocurrencia
- 3 Redes de Asociaciones
- 4 Aplicaciones
- 5 Construcción de Redes
- 6 Resumenes de Textos
- 7 Aplicación

Aplicación

- DUC 2003 y 2004 contiene 30 y 50 clusters de documentos de noticias (todos en inglés).
- Para evaluación se uso la métrica ROUGE basada en $n - \text{gram}$ coocurrencia: reporta puntajes para 1,2,3,4 - gramas de coincidencia entre los resumenes del modelo y el resumen.
- Implementaron la metodología en un software disponible en www.summarization.xom
- Se sabe que el puntaje de los 1-gramas tiende a coincidir con las evaluaciones de humanos.