


Node embeddings

Hamilton et al. 2017. Representation Learning on Graphs: Methods and Applications. IEEE Data Engineering Bulletin on Graph Systems.

Jure Leskovec Lectures

Caracterizando nodos



Supongamos que tenemos una red... $G(V,E)$. Podemos conceptualizar a cada nodo como un punto en un espacio de baja dimensionalidad?

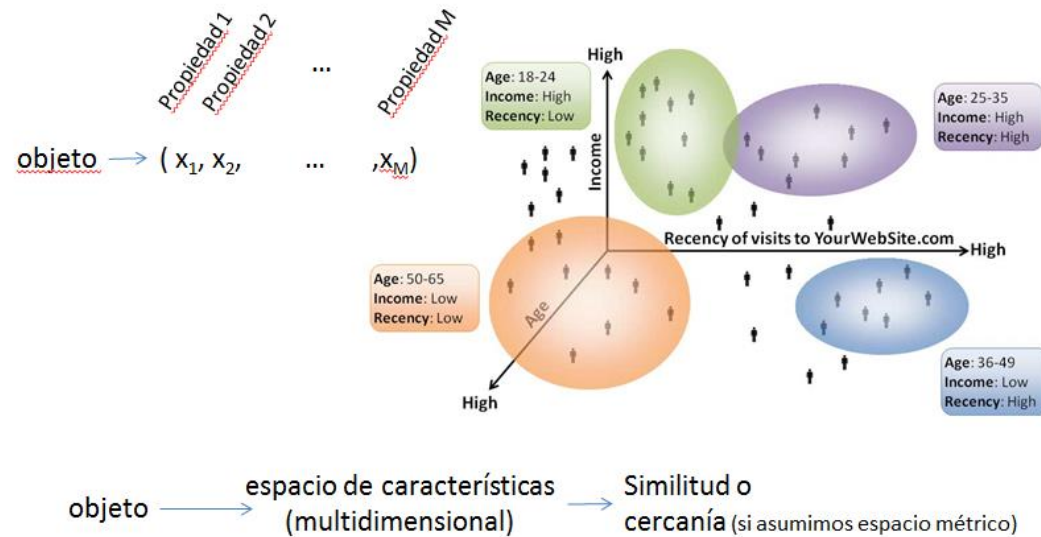
Por qué querriamos hacer esto? Muchas técnicas de aprendizaje automático podrían aplicarse: Clasificación, Priorización, Predicción de nuevos enlaces, etc...

Lo bueno es que si encontramos una manera piola de hacer el embedding, nos podríamos evitar hacer *ingeniería de features* para definir el espacio de Z 's donde trabajar

Recordando...

Similaridad en espacio métrico

Similitud a partir de **vectores de características**


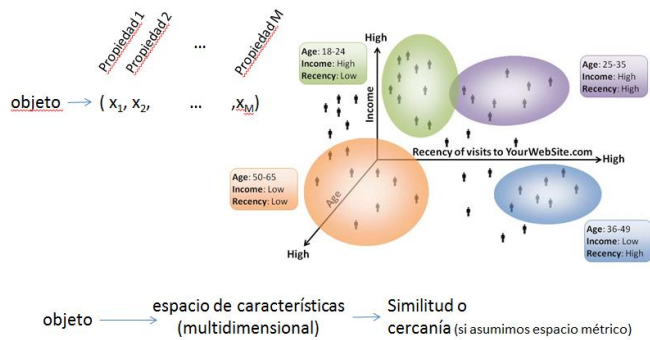


Lo bueno es que si encontramos una manera piola de hacer el embedding, nos podríamos evitar hacer *ingeniería de features* para definir el espacio de **Z**'s donde trabajar

Caracterizando nodos

Similaridad en espacio métrico


Similitud a partir de **vectores de características**



Idea: utilizar la información embebida en $G(V,E)$ para encontrar un buen embeddig.

Lo que vamos a ver es una instancia de **Representation Learning on Networks**


Cómo hacemos la magia?



Idea: Tratamos de acomodar los puntos en el espacio d-dimensional de manera que **nodos similares** en el grafo se correspondan con **puntos cercanos** en el embedding

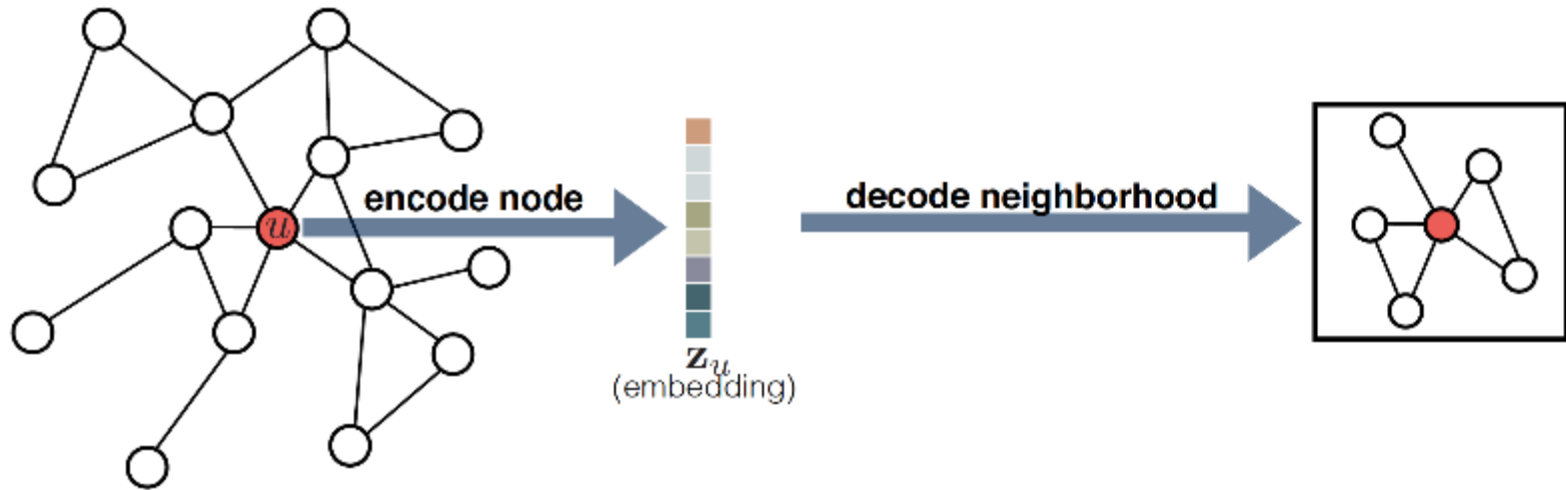
Vamos a llamar *encoder* a la función de mapeo: $Enc: V \rightarrow \mathbb{R}^d$

En nuestro caso $Enc(v) = Z[v]$.

 fila de la matriz $Z \in \mathbb{R}^{|V| \times d}$ que define el embedding

Abordaje Encoder-Decoder

Para encontrar un buen *encoder*...



El *encoder* mapea nodos al espacio d -dimensional

$$Enc(v) = Z[v].$$


$$Z \in \mathbb{R}^{|V| \times d}$$

El *decoder* reconstruye la vecindad de un nodo a partir de su vector representacion

$$Dec: \mathbb{R}^d \times \mathbb{R}^d \rightarrow \mathbb{R}^+$$

Para cada par de ptos $z(u_1), z(u_2)$ estima una relación o similaridad entre los nodos correspondientes u_1 y u_2

Abordaje Encoder-Decoder




Para un buen *encoder*...

$$\text{DEC}(\text{ENC}(u), \text{ENC}(v)) = \text{DEC}(z_u, z_v) \approx S(u, v)$$

Medida de similitud entre
puntos del embedding

Medida de similitud entre
nodos del grafo

Minimizando perdidas



Para un buen *encoder*...


$$\text{DEC}(\text{ENC}(u), \text{ENC}(v)) = \text{DEC}(z_u, z_v) \approx S(u, v)$$

Vamos a plantear el problema de encontrar un buen embedding como un problema de minimización de una función de pérdida

$$\mathcal{L} = \sum_{(u,v) \in \mathcal{D}} \ell(\text{DEC}(z_u, z_v), \mathbf{S}[u, v])$$

$\ell: \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$ mide discrepancia entre similaridades


Minimizando perdidas



$$\mathcal{L} = \sum_{(u,v) \in \mathcal{D}} \ell(\text{DEC}(\mathbf{z}_u, \mathbf{z}_v), \mathbf{S}[u, v])$$

Por ejemplo: $\|\mathbf{z}_u^T \cdot \mathbf{z}_v - A_{uv}\|^2$


Minimizando perdidas



$$\mathcal{L} = \sum_{(u,v) \in \mathcal{D}} \ell(\text{DEC}(\mathbf{z}_u, \mathbf{z}_v), \mathbf{S}[u, v])$$

Method	Decoder	Similarity measure	Loss function
Lap. Eigenmaps	$\ \mathbf{z}_u - \mathbf{z}_v\ _2^2$	general	$\text{DEC}(\mathbf{z}_u, \mathbf{z}_v) \cdot \mathbf{S}[u, v]$
Graph Fact.	$\mathbf{z}_u^\top \mathbf{z}_v$	$\mathbf{A}[u, v]$	$\ \text{DEC}(\mathbf{z}_u, \mathbf{z}_v) - \mathbf{S}[u, v]\ _2^2$
GraRep	$\mathbf{z}_u^\top \mathbf{z}_v$	$\mathbf{A}[u, v], \dots, \mathbf{A}^k[u, v]$	$\ \text{DEC}(\mathbf{z}_u, \mathbf{z}_v) - \mathbf{S}[u, v]\ _2^2$
HOPE	$\mathbf{z}_u^\top \mathbf{z}_v$	general	$\ \text{DEC}(\mathbf{z}_u, \mathbf{z}_v) - \mathbf{S}[u, v]\ _2^2$
DeepWalk	$\frac{e^{\mathbf{z}_u^\top \mathbf{z}_v}}{\sum_{k \in \mathcal{V}} e^{\mathbf{z}_u^\top \mathbf{z}_k}}$	$p_{\mathcal{G}}(v u)$	$-\mathbf{S}[u, v] \log(\text{DEC}(\mathbf{z}_u, \mathbf{z}_v))$
node2vec	$\frac{e^{\mathbf{z}_u^\top \mathbf{z}_v}}{\sum_{k \in \mathcal{V}} e^{\mathbf{z}_u^\top \mathbf{z}_k}}$	$p_{\mathcal{G}}(v u)$ (biased)	$-\mathbf{S}[u, v] \log(\text{DEC}(\mathbf{z}_u, \mathbf{z}_v))$


Minimizando perdidas



$$\mathcal{L} = \sum_{(u,v) \in \mathcal{D}} \ell(\text{DEC}(\mathbf{z}_u, \mathbf{z}_v), \mathbf{S}[u, v])$$

Method	Decoder	Similarity measure
Lap. Eigenmaps	$\ \mathbf{z}_u - \mathbf{z}_v\ _2^2$	general
Graph Fact.	$\mathbf{z}_u^\top \mathbf{z}_v$	$\mathbf{A}[u, v]$
GraRep	$\mathbf{z}_u^\top \mathbf{z}_v$	$\mathbf{A}[u, v], \dots, \mathbf{A}^k[u, v]$
HOPE	$\mathbf{z}_u^\top \mathbf{z}_v$	general
DeepWalk	$\frac{e^{\mathbf{z}_u^\top \mathbf{z}_v}}{\sum_{k \in \mathcal{V}} e^{\mathbf{z}_u^\top \mathbf{z}_k}}$	$p_{\mathcal{G}}(v u)$
node2vec	$\frac{e^{\mathbf{z}_u^\top \mathbf{z}_v}}{\sum_{k \in \mathcal{V}} e^{\mathbf{z}_u^\top \mathbf{z}_k}}$	$p_{\mathcal{G}}(v u)$ (biased)

Diferentes medidas $S[u, v]$ van a producir embeddings que reflejen diferentes propiedades del grafo... Ptos cercanos asociados a: nodos conectados? primeros vecinos comunes? roles estructurales similares? ...?




Similaridad de Adyacencia

$$\mathcal{L} = \sum_{(u,v) \in V \times V} \|z_u^T \cdot z_v - A_{u,v}\|^2$$

Idea: la similitud tipo producto interno debe aproximar la relación de existencia de enlace

Para encontrar $Z \in \mathbb{R}^{|V| \times d}$ se utiliza Stochastic Gradient Descent




Similaridad multi-salto

$$\mathcal{L}^{(k)} = \sum_{(u,v) \in V \times V} \left\| z_u^{(k)T} \cdot z_v^{(k)} - [A^k]_{u,v} \right\|^2$$

Idea: la similaridad tipo producto interno debe predecir k-hop vecinos

Se encuentran mappings para diferentes k y luego se concatenan

$$z_u = z_u^{k=1} \oplus z_u^{k=2} \oplus \dots \oplus z_u^{k=K}$$



Similaridad Random-Walk

$$z_u^T \cdot z_v \sim P_R(v|u)$$


probabilidad de que u y v co-ocurrán en una caminata aleatoria de tipo R sobre el grafo

Idea:

1. Estimar prob de encontrar a v en una random-walk que empieza en u siguiendo una estrategia R
2. Optimizar el embedding para que refleje la estadística relevada en la caminata

Perozzi et al. 2014. DeepWalk: Online Learning of Social Representations. KDD.

Grover et al. 2016. node2vec: Scalable Feature Learning for Networks. KDD.



Similaridad Random-Walk

Se parametriza a $P_R(v|z_u)$ como

$$\mathcal{L} = \sum_{u \in V} \sum_{v \in N_R(u)} -\log P_R(v|z_u)$$

$$P_R(v|z_u) = \frac{e^{(z_u^T \cdot z_v)}}{\sum_{n \in V} e^{(z_u^T \cdot z_n)}}$$

Idea:

1. Para cada nodo u corro random-walks cortas
2. En cada caso almaceno el *multiset* $N_R(u)$ de nodos visitados siguiendo la estrategia R
3. Optimizar embeddings de manera de minimizar \mathcal{L} (o sea maximizar la probabilidad de encontrar cerca de z_u los $ENC(N_R(u))$)

Perozzi et al. 2014. DeepWalk: Online Learning of Social Representations. KDD.

Grover et al. 2016. node2vec: Scalable Feature Learning for Networks. KDD.

Problema técnico

$$\mathcal{L} = \sum_{u \in V} \sum_{v \in N_R(u)} -\log \frac{e^{(z_u^T \cdot z_v)}}{\sum_{n \in V} e^{(z_u^T \cdot z_n)}}$$

Suma anidada sobre nodos $O(N^2)$!


Solución: **Negative sampling**

$$\log \left(\frac{\exp(\mathbf{z}_u^T \mathbf{z}_v)}{\sum_{n \in V} \exp(\mathbf{z}_u^T \mathbf{z}_n)} \right) \approx \log(\sigma(\mathbf{z}_u^T \mathbf{z}_v)) - \sum_{i=1}^k \log(\sigma(\mathbf{z}_u^T \mathbf{z}_{n_i}))$$

$n_i \sim$ sampling de vertices no incluidos en $N_R(u)$


Función sigmoidea

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$



- Comparo similaridad (z_u, z_v) con una estimación (k muestras) de similaridad de z_u respecto vectores asociados a nodos **fuera de la caminata** (de ahí el nombre).
- k altos dan estimaciones mas robustas.
- En la práctica se usa muestreo uniforme (!)

Entonces...



$$\mathcal{L} = - \sum_{u \in V} \sum_{v \in N_R(u)} \log(\sigma(\mathbf{z}_u^\top \mathbf{z}_v)) - \sum_{i=1}^k \log(\sigma(\mathbf{z}_u^\top \mathbf{z}_{n_i}))$$

Idea:

1. Para cada nodo u corro random-walks cortas
2. En cada caso almaceno el *multiset* $N_R(u)$ de nodos visitados siguiendo la estrategia R
3. Optimizar embeddings de manera de minimizar \mathcal{L} (o sea maximizar la probabilidad de encontrar cerca de z_u los $\text{ENC}(N_R(u))$)


Posibles estrategias:

- Uniform random walk
- Biased random-walk

Perozzi et al. 2014. DeepWalk: Online Learning of Social Representations. KDD.

Grover et al. 2016. node2vec: Scalable Feature Learning for Networks. KDD.

Entonces...



$$\mathcal{L} = - \sum_{u \in V} \sum_{v \in N_R(u)} \log(\sigma(\mathbf{z}_u^\top \mathbf{z}_v)) - \sum_{i=1}^k \log(\sigma(\mathbf{z}_u^\top \mathbf{z}_{n_i}))$$


Method	Decoder	Similarity measure
Lap. Eigenmaps	$\ \mathbf{z}_u - \mathbf{z}_v\ _2^2$	general
Graph Fact.	$\mathbf{z}_u^\top \mathbf{z}_v$	$\mathbf{A}[u, v]$
GraRep	$\mathbf{z}_u^\top \mathbf{z}_v$	$\mathbf{A}[u, v], \dots, \mathbf{A}^k[u, v]$
HOPE	$\mathbf{z}_u^\top \mathbf{z}_v$	general
DeepWalk	$\frac{e^{\mathbf{z}_u^\top \mathbf{z}_v}}{\sum_{k \in V} e^{\mathbf{z}_u^\top \mathbf{z}_k}}$	$p_G(v u)$
node2vec	$\frac{e^{\mathbf{z}_u^\top \mathbf{z}_v}}{\sum_{k \in V} e^{\mathbf{z}_u^\top \mathbf{z}_k}}$	$p_G(v u)$ (biased)

Perozzi et al. 2014. DeepWalk: Online Learning of Social Representations. KDD.

Grover et al. 2016. node2vec: Scalable Feature Learning for Networks. KDD.

node2vec: biased random walk

Por que?




Caminatas aleatorias de diferente tipo resuenan con diferentes regularidades de la red

$$N_{BFS}(u) = \{s_1, s_2, s_3\}$$

$$N_{DFS}(u) = \{s_4, s_5, s_6\}$$

Como?



Se implementa como una caminata aleatoria de **2do orden** (i.e. la prob de transición depende de donde estoy ahora y donde estubo en el paso anterior)

prob no normalizada $\pi_{vx} = \alpha_{pq}(t, x) \cdot w_{vx}$

$$\alpha_{pq}(t, x) = \begin{cases} \frac{1}{p} & \text{if } d_{tx} = 0 \\ 1 & \text{if } d_{tx} = 1 \\ \frac{1}{q} & \text{if } d_{tx} = 2 \end{cases}$$

p: controla la prob de revisita
q: controla tendencia a DFS



Por ejemplo:

Si $p > \max(q, 1)$ baja prob de visitar un nodo de los ultimos dos pasos
Si $q > 1$ tendencia al BFS

node2vec en acción


Red de co-aparición de Les Misérables

Comunidades detectadas en embedding 16-dim:



$p=1$ $q=0.5$


Las comunidades detectadas en el embedding reflejan similitud relacionada con homofilia.



$p=1$ $q=2$

Las comunidades detectadas en el embedding reflejan similitud de tipo estructural.

O sea



- Estuvimos analizando como embeber vertices de una red en un espacio d-dimensional de manera de reflejar similitudes estructurales de la red
- Existen diferentes maneras de hacerlo

$$\mathcal{L} = \sum_{(u,v) \in \mathcal{D}} \ell(\text{DEC}(\mathbf{z}_u, \mathbf{z}_v), \mathbf{S}[u, v])$$

Method	Decoder	Similarity measure
Lap. Eigenmaps	$\ \mathbf{z}_u - \mathbf{z}_v\ _2^2$	general
Graph Fact.	$\mathbf{z}_u^\top \mathbf{z}_v$	$\mathbf{A}[u, v]$
GraRep	$\mathbf{z}_u^\top \mathbf{z}_v$	$\mathbf{A}[u, v], \dots, \mathbf{A}^k[u, v]$
HOPE	$\mathbf{z}_u^\top \mathbf{z}_v$	general
DeepWalk	$\frac{e^{\mathbf{z}_u^\top \mathbf{z}_v}}{\sum_{k \in \mathcal{V}} e^{\mathbf{z}_u^\top \mathbf{z}_k}}$	$p_{\mathcal{G}}(v u)$
node2vec	$\frac{e^{\mathbf{z}_u^\top \mathbf{z}_v}}{\sum_{k \in \mathcal{V}} e^{\mathbf{z}_u^\top \mathbf{z}_k}}$	$p_{\mathcal{G}}(v u)$ (biased)

Hasta aca