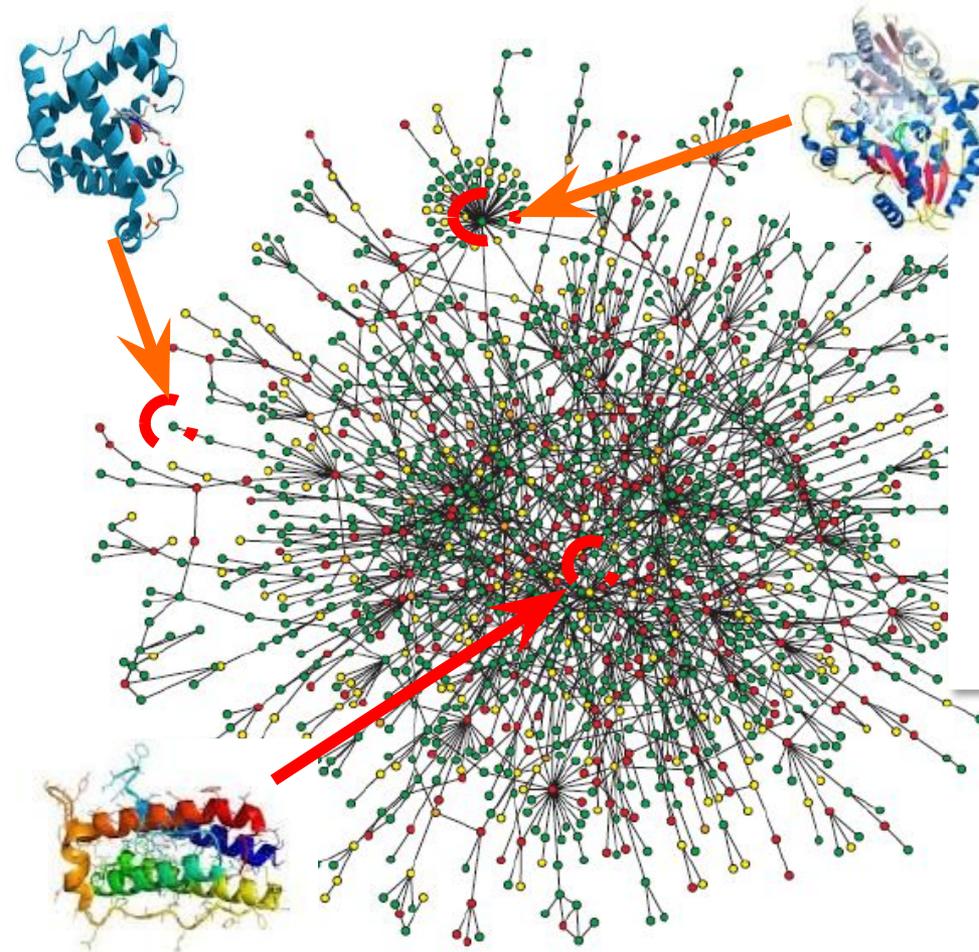


Centralidad

¿Qué tan *relevante* es un nodo de la red?

Topología y rol biológico



Redes Complejas

Degree
Eccentricity
Closeness
Betweenness
Bridging centrality
Eigenvalue centrality
Random walk centralities
....



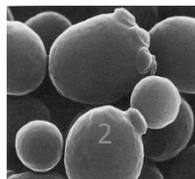
Biologia

Essentiality
Phenotypic variability
Biological function
Cancer related
Disease Related
...

Protein-protein interaction in yeast *S. cerevisiae*, (N=1870 and L=2240).

Jeong et al., Nature, 411, 41 (2001).

Redes Complejas - Chernomoretz



Propiedades topológicas: entorno local/global

Propiedades Locales

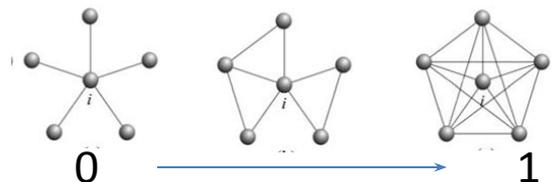
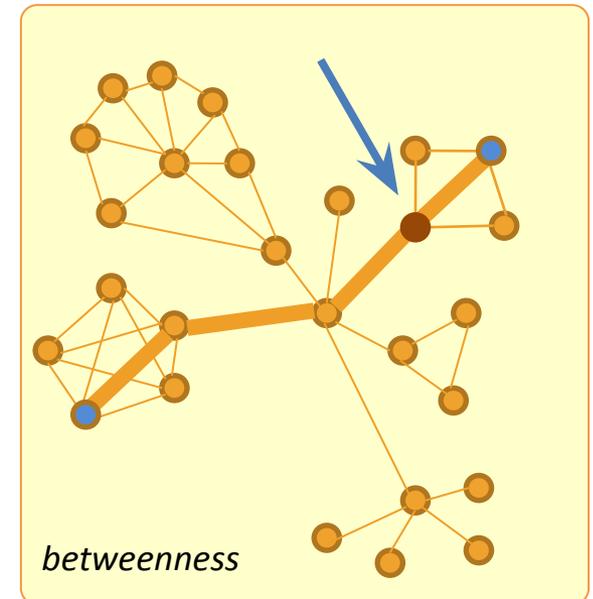
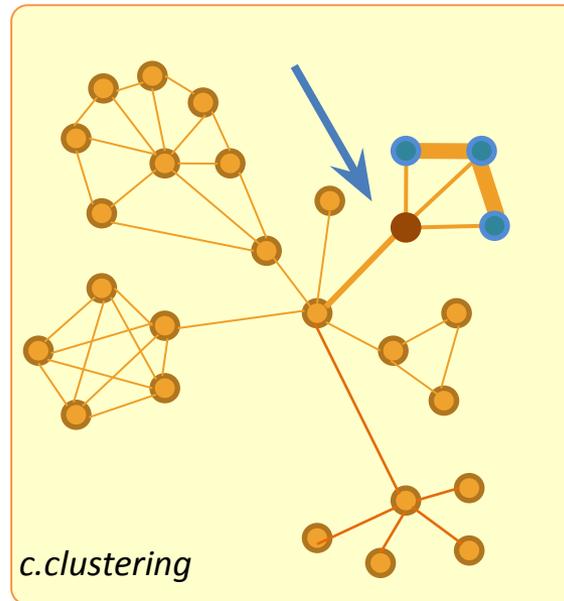
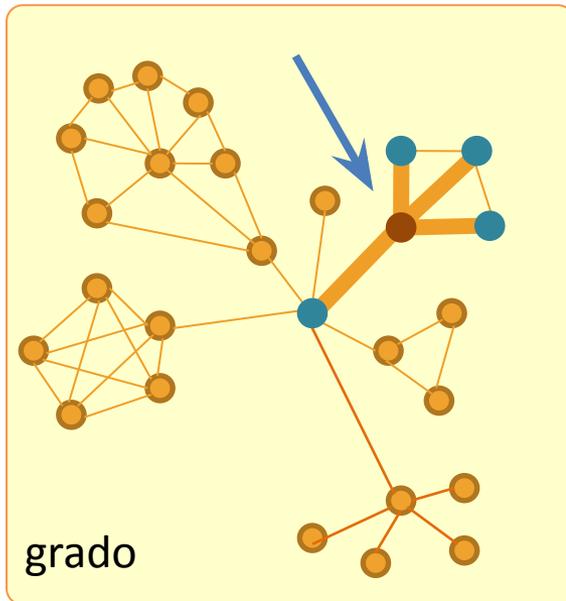
grado
coef. Clustering
centralidad 'random walk'

...

Propiedades Globales

betweenness
centralidad de autovalores adyacencia
cercania

...



$$be(v) = \sum_{s \neq t \neq v} \frac{\sigma_{s,t}^{shortest-path}(v)}{\sigma_{s,t}^{shortest-path}}$$

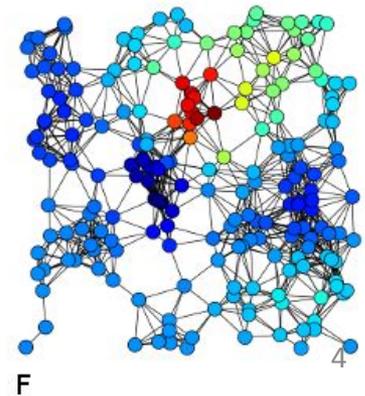
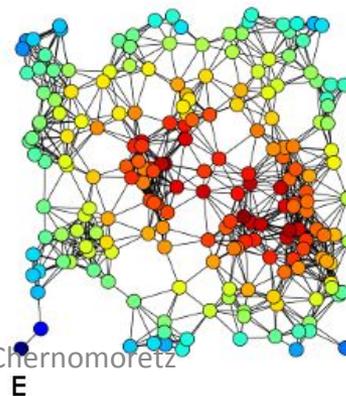
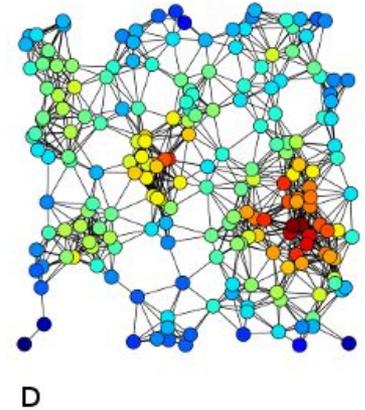
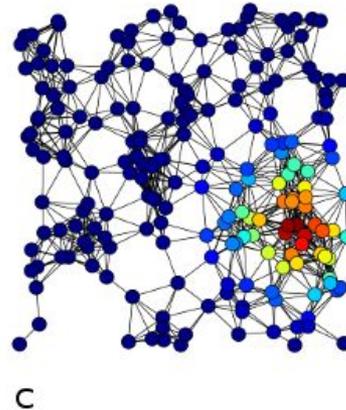
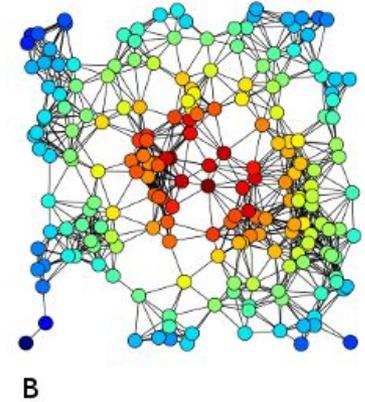
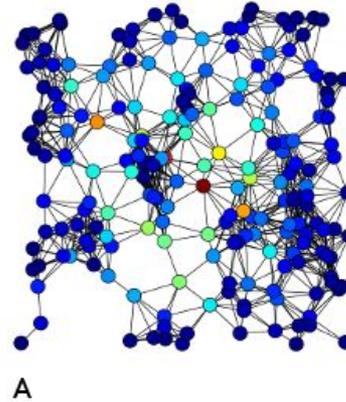
Centralidad

Dime qué modelas con tu red y te diré **qué es ser importante**

Dos dimensiones que pueden ser relevantes:

- . Noción de **flujo** sobre la red
- . Noción de **cohesividad** sobre la red

- intermediatez
- cercanía
- autovalor
- grado
- centralidad armónica
- centralidad de Katz



Centralidad y flujos

Dime qué modelas con tu red y te diré qué significa ser importante

- Flujo de ítems indivisibles que están en un único lugar a un dado tiempo. Su difusión es por transferencia. Puede haber casos en que:
 - Billetes, libros: se mueven por el grafo **sin restricciones** acerca de repetir enlaces o nodos ya visitados (i.e. *walks*)
 - Ropa usada, *re-gifting*: se mueven por el grafo **sin repetir enlaces** (i.e. *trails*)
 - correo, gps: se mueven por el grafo desde un nodo origen hacia uno destino minimizando distancia recorrida (i.e. geodésicas).
- Flujo de entidades que pueden estar en varios lugares a la vez. Difusión por replicación.
 - Chismes: Transmisión boca-a-boca, en general no repite enlaces, pero si vértices (i.e. *trails*)
 - Campaña mailing: Transmisión por emisora (*broadcasting*), suele ser simultánea.
 - Ideas, creencias, modas, actitudes: influencia que se transmite boca-a-boca por replicación. Puede repetir enlaces (i.e. *walks*)
 - Procesos infecciosos, con inmunidad. Procede por replicación, pero sin visitar vértices (i.e. *paths*).

Centralidad de grado

Utiliza directamente el **grado** de un nodo como medida de su importancia:

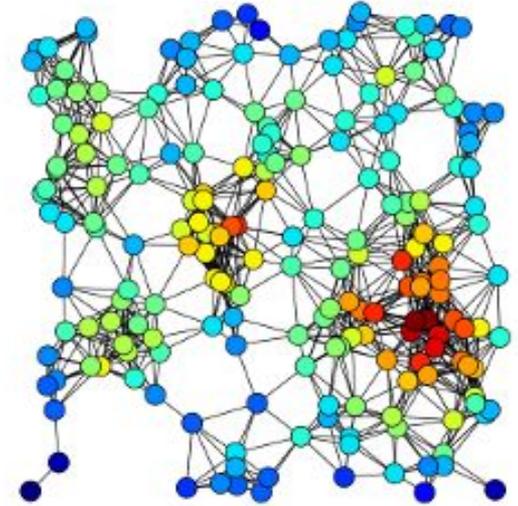
$$\text{Cent}(n_i) = k_i$$

En términos de flujo:

- + caracteriza efectos de influencia inmediata
- + razonable por ejemplo para aplicar en procesos de duplicación paralela (prob de recibir algo que está distribuido aleatoriamente por la red es proporcional al nro de contactos) o de caminatas al azar

Asume linealidad: un nodo con el **doble** de **vecinos** que otro tiene el **doble de importancia**

Sólo utiliza información **local**

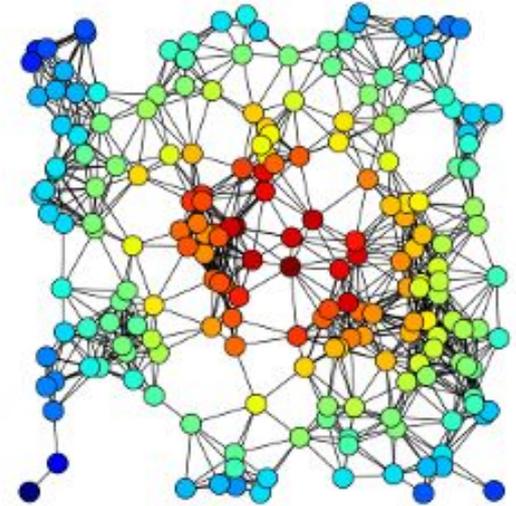


Centralidad de cercanía

- Asume que los nodos más importantes son aquellos que pueden alcanzar fácilmente a más vecinos (están **cerca** de todos)

$$Closeness\ Centrality(n_i) = \left[\frac{\sum_{j \neq i} d_{geod}(n_i, n_j)}{N - 1} \right]^{-1}$$

(sin vecinos) $0 \leq Closeness\ Centrality \leq 1$ (vecino de todos)



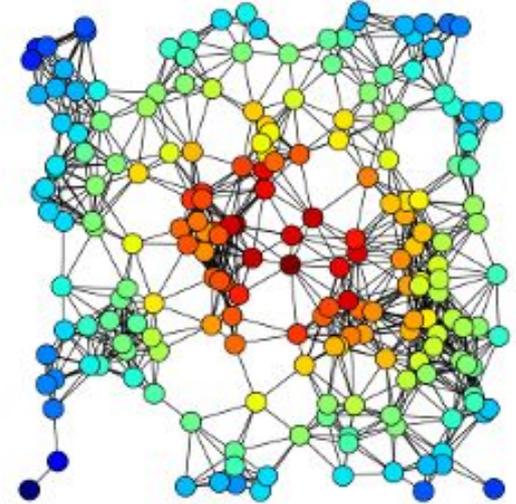
- nodos que en promedio reciben flujo transmitido por la red rápidamente:
 - red de flujo de información: ubicaciones ventajosas
 - red de contactos sexuales : ubicaciones riesgosas
 - en gral para flujos a lo largo de geodésicas o por duplicación en paralelo
 - no sería un buen índice para identificar, por ejemplo, quién recibirá info antes si el proceso de transmisión es tipo rumor (no va por caminos mas cortos)

Centralidad de cercanía

- Asume que los nodos más importantes son aquellos que pueden alcanzar fácilmente a más vecinos (están **cerca** de todos)

$$\text{Closeness Centrality}(n_i) = \left[\frac{\sum_{j \neq i} d_{\text{geod}}(n_i, n_j)}{N - 1} \right]^{-1}$$

(sin vecinos) $0 \leq \text{Closeness Centrality} \leq 1$ (vecino de todos)



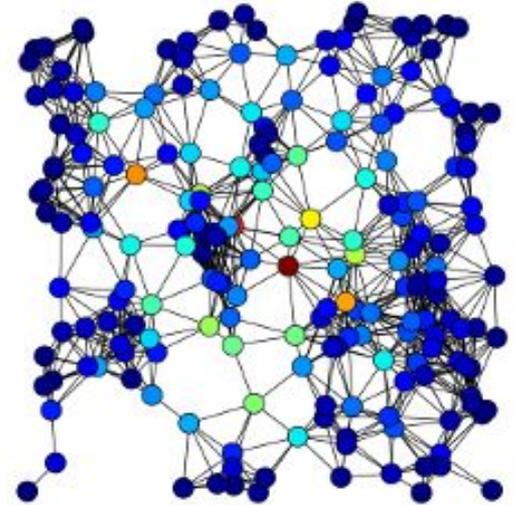
- En general tiene un rango dinámico chico (distancias geodésicas son chicas $1 < d_{\text{geod}} < o(\log N)$)
- No está bien definido para redes con más de una componente.
- Aún si calculáramos cada componente por separado no es trivial dar un ordenamiento global (centralidad en componentes más chicas tiende a ser mayor)

$$\text{Harmonic Closeness Centrality}(n_i) = \frac{1}{N - 1} \sum_{j \neq i} \frac{1}{d_{\text{geod}}(n_i, n_j)}$$

- Bien definido aún para redes con más de una componente.
- Se le da más peso a entorno local

Centralidad de **intermediatez** (*betweenness*)

Si hay un intercambio global de mensajes entre **todos los pares** de nodos de la red y si la información se intercambia por **geodésicas**: el nodo por el que pasarán más mensajes es aquél por el que pasan la mayor cantidad de geodésicas de la red.

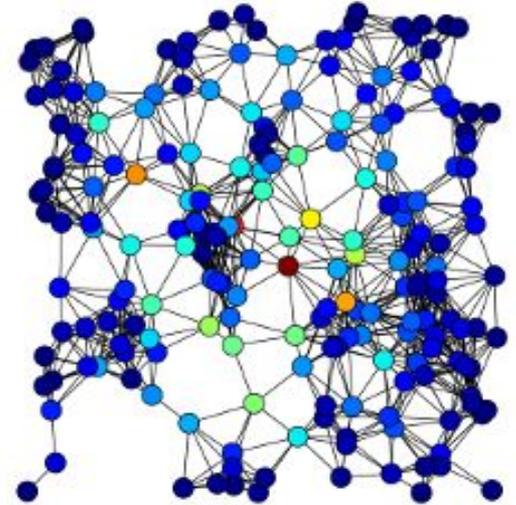


$$bet(n_i) = \sum_{r,s} \frac{x_{rs}^i}{x_{rs}}$$

← nro de geodésicas entre r y s que pasan por i
← nro de geodésicas entre r y s

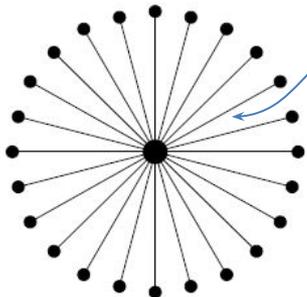
Centralidad de **intermediatez** (*betweenness*)

Si hay un intercambio global de mensajes entre **todos los pares** de nodos de la red y si la información se intercambia por **geodésicas**: el nodo por el que pasarán más mensajes es aquél por el que pasan la mayor cantidad de geodésicas de la red.



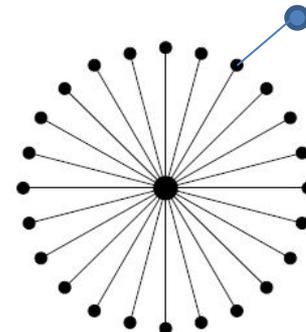
$$bet(n_i) = \sum_{r,s} \frac{x_{rs}^i}{x_{rs}}$$

← nro de geodésicas entre r y s que pasan por i
 ← nro de geodésicas entre r y s



$$bet_{max} = n^2 - (n - 1)$$

Participa en la geodesica de todos los pares menos en la de los $n-1$ perifericos consigo mismos

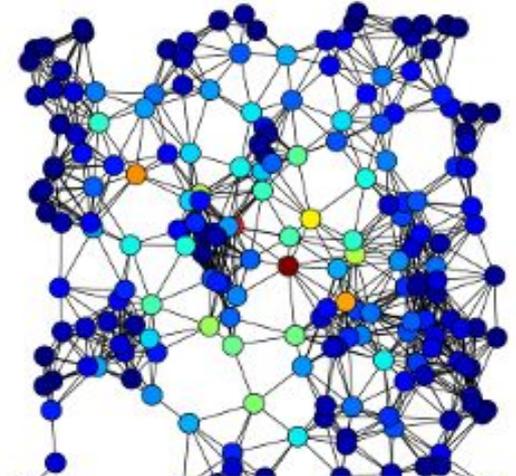


$$bet_{min} = 2n - 1$$

Participa en las geodesicas (ida y vuelta) del azul con el resto $2(n-1)$ mas la del azul consigo mismo.

Centralidad de **intermediatez** (*betweenness*)

Si hay un intercambio global de mensajes entre **todos los pares** de nodos de la red y si la información se intercambia por **geodésicas**: el nodo por el que pasarán más mensajes es aquél por el que pasan la mayor cantidad de geodésicas de la red.



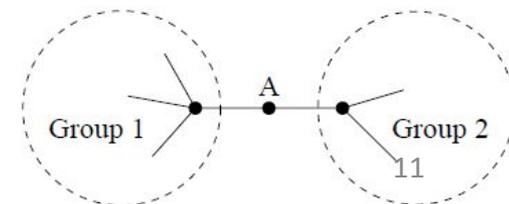
$$bet(n_i) = \sum_{r,s} \frac{x_{rs}^i}{x_{rs}}$$

← nro de geodésicas entre r y s que pasan por i
← nro de geodésicas entre r y s

$$\left. \begin{aligned} bet_{min} &= 2n - 1 \\ bet_{max} &= n^2 - (n - 1) \end{aligned} \right\} \frac{bet_{max}}{bet_{min}} \sim \frac{1}{2}n \quad (\text{amplio rango dinámico})$$

Es una medida global

Es una medida de intermediatez más que de conectividad



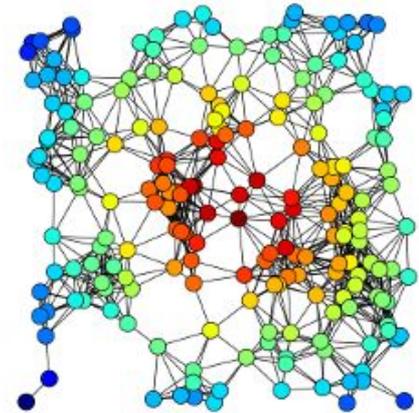
Centralidad de autovalor

Nodos importantes tienen vecinos importantes

- Importancia de nodo- i (x_i) depende de importancia de nodo- j vecino (x_j).
- La importancia se *transmite* por la red asumiendo linealidad

$$x_i \sim \sum_{j=1}^N a_{ij} x_j$$

$\mathbf{x} \in \mathbb{R}^N$ es un autovector de \mathbf{A} $\lambda \mathbf{x} = \mathbf{A} \mathbf{x}$



$$\mathbf{A} \mathbf{x} - \lambda \mathbf{x} = 0$$

$$(\mathbf{A} - \lambda \mathbf{I}) \mathbf{x} = 0$$

$$\det(\mathbf{A} - \lambda \mathbf{I}) = 0$$

$$\mathbf{A} = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^{-1}$$

\mathbf{U} matriz de autovectores
como columnas

$\mathbf{\Lambda}$ matriz autovalores en
diagonal

Pero... la matriz \mathbf{A} tiene N
autovalores/autovectores...
cual de todos ellos me da
el campo de centralidad
que busco?

$$\lambda_\alpha \mathbf{v}_\alpha = \mathbf{A} \mathbf{v}_\alpha$$

$$\alpha = 1, \dots, N$$

Ec autovalores de \mathbf{A}

Otra manera de encontrar **direcciones especiales**

$$\lambda_{\alpha} \mathbf{v}_{\alpha} = A \mathbf{v}_{\alpha}$$

$$\alpha = 1, \dots, N$$

Pensemos
iterativamente...

$$\mathbf{x}' = A \mathbf{x}$$

$$\mathbf{x}'' = A \mathbf{x}' = A A \mathbf{x}$$

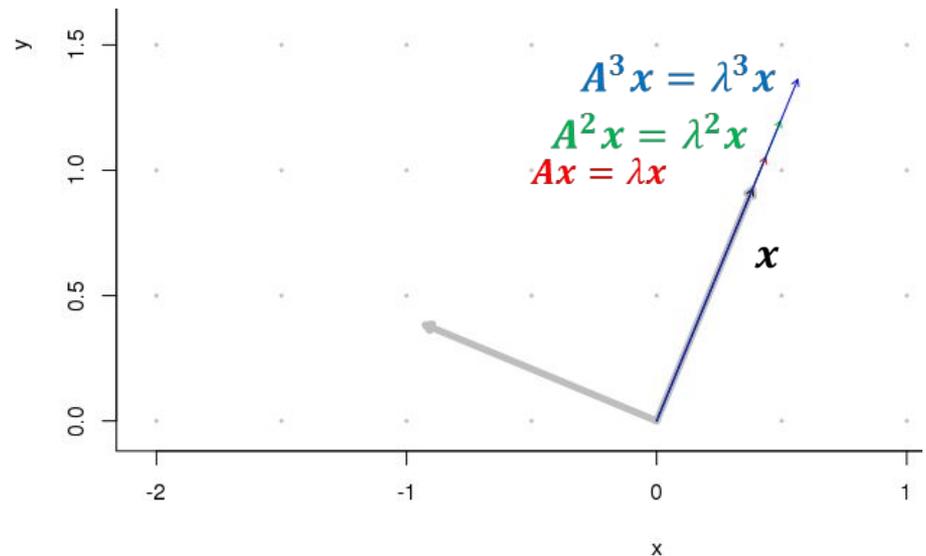
$$\mathbf{x}(s) = \overbrace{A A \dots A}^s \mathbf{x}(0)$$

$$\mathbf{x}(s) = A^s \mathbf{x}(0)$$

Si $\mathbf{x}(0) = \mathbf{v}_{\alpha}$

$$\mathbf{x}(s) = \lambda_{\alpha}^s \mathbf{v}_{\alpha}$$

si \mathbf{x} inicial fuera justo un **autovector**, por ejemplo \mathbf{v}_i , de la matriz de adyacencia A



Otra manera de encontrar **direcciones especiales**

$$\lambda_\alpha \mathbf{v}_\alpha = A \mathbf{v}_\alpha$$

$$\alpha = 1, \dots, N$$

Sea \mathbf{x} un vector cualquiera:

$$\mathbf{x}(s) = A^s \mathbf{x}(0)$$

$$\mathbf{x}(0) = c_1 \mathbf{v}_1 + c_2 \mathbf{v}_2 + \dots = \sum_i c_i \mathbf{v}_i$$

$$\begin{aligned} A^s \mathbf{x}(0) &= \sum_i c_i A^s \mathbf{v}_i = \sum_i c_i \lambda_i^s \mathbf{v}_i \\ &= \lambda_*^s \sum_i c_i \left(\frac{\lambda_i}{\lambda_*} \right)^s \mathbf{v}_i \end{aligned}$$

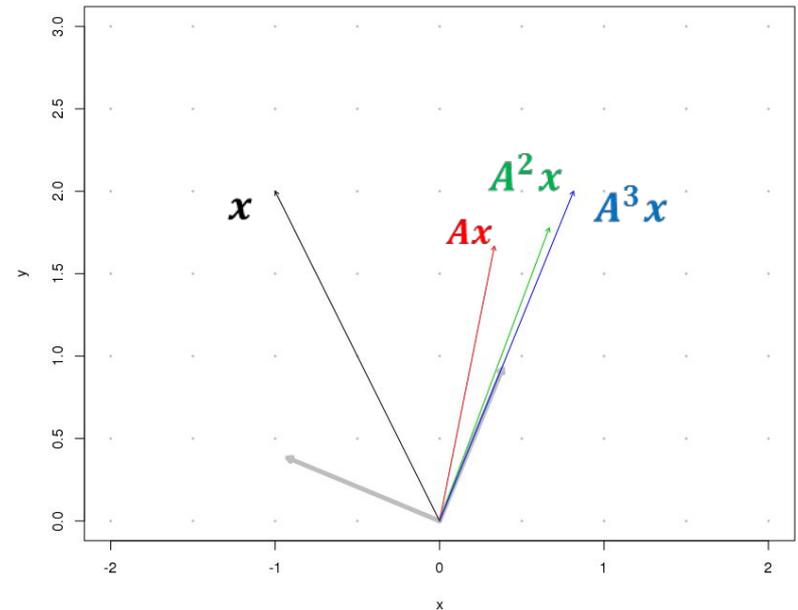
Autovalor dominante

$$\mathbf{x}(s) = \lambda_*^s \sum_i c_i \overbrace{\left(\frac{\lambda_i}{\lambda_*} \right)^s}^{<1} \mathbf{v}_i$$

$$\mathbf{x}(s) \sim \lambda_*^s c_i \mathbf{v}_*$$

$$s \rightarrow \infty$$

En el caso general $\mathbf{x}(0)$ no coincide con una dirección privilegiada asociada con A



Todo campo inicial $\mathbf{x}(0)$ converge a \mathbf{v}_* asintóticamente...este es el que estamos buscando !

Centralidad de autovalor

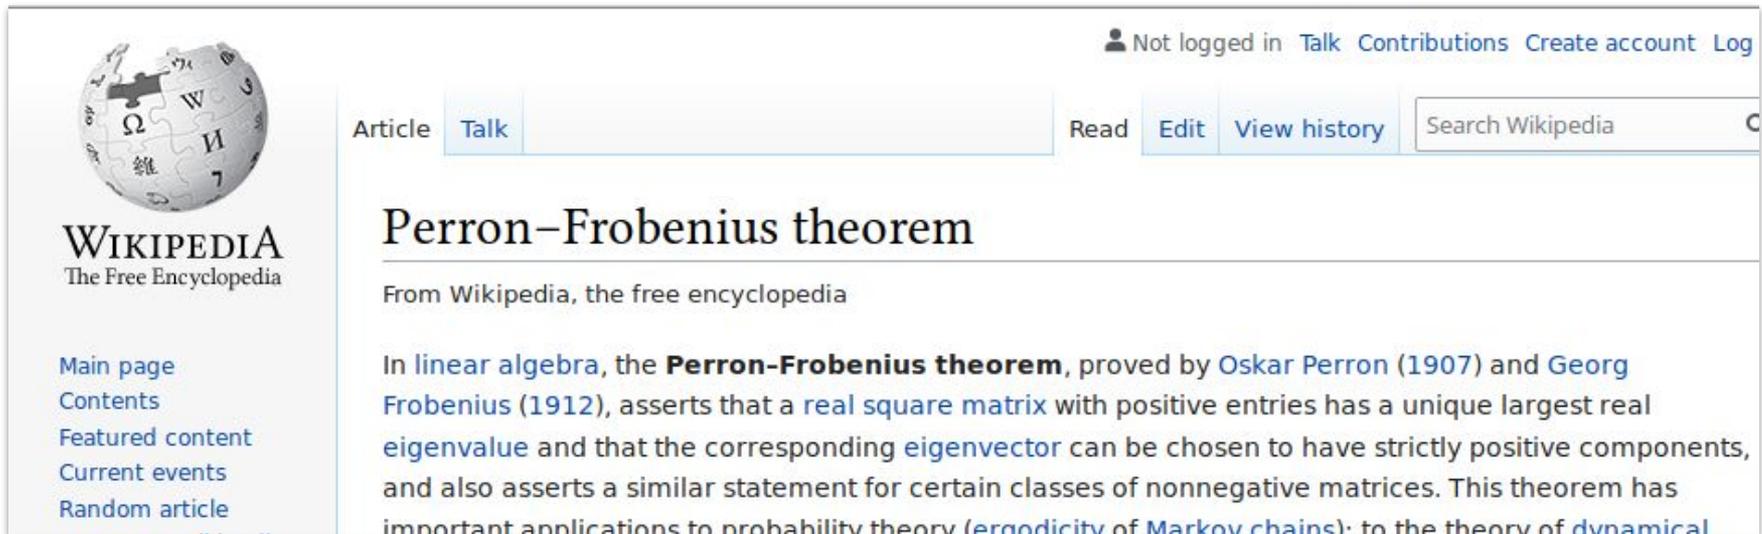
$$A\mathbf{x}^* = \lambda_* \mathbf{x}^*$$

\mathbf{x} se conoce como **centralidad de Bonacich**

$$x_i^* = \frac{1}{\lambda_*} \sum_j A_{ij} x_j^*$$

La centralidad de un nodo depende de la de sus vecinos.

Es \mathbf{x}^* una buena centralidad? Quien me asegura que sus componentes sean todas positivas, por ejemplo? o que el subespacio asociado al mayor autovalor no este degenerado?



The screenshot shows the Wikipedia page for the Perron-Frobenius theorem. At the top right, it indicates the user is "Not logged in" and provides links for "Talk", "Contributions", "Create account", and "Log". Below this, there are navigation tabs for "Article" and "Talk", and a search bar. The main heading is "Perron-Frobenius theorem". Below the heading, it says "From Wikipedia, the free encyclopedia". The text of the article begins: "In linear algebra, the **Perron-Frobenius theorem**, proved by Oskar Perron (1907) and Georg Frobenius (1912), asserts that a real square matrix with positive entries has a unique largest real eigenvalue and that the corresponding eigenvector can be chosen to have strictly positive components, and also asserts a similar statement for certain classes of nonnegative matrices. This theorem has important applications to probability theory (ergodicity of Markov chains); to the theory of dynamical

Centralidad de autovalor

$$\mathbf{Ax}^* = \lambda_* \mathbf{x}^*$$

\mathbf{x} se conoce como **centralidad de Bonacich**

$$x_i^* = \frac{1}{\lambda_*} \sum_j A_{ij} x_j^*$$

La centralidad de un nodo depende de la de sus vecinos.

Es \mathbf{x}^* una buena centralidad? Quien me asegura que sus componentes sean todas positivas, por ejemplo? o que el subespacio asociado al mayor autovalor no este degenerado?

Teorema de Perron-Frobenius

Sea \mathbf{A} una matriz de $N \times N$ con elementos no negativos. Entonces:

- \mathbf{A} tiene **un unico** autovalor real dominante: $\lambda_1 > |\lambda_i|$ para $i = 2, \dots, N$
- λ_1 corresponde a un autovalor para el que se puede elegir un autovector cuyas **componentes son no-negativas**
- Además vale que λ_1 está acotado por la mínima y máxima suma por columna de \mathbf{A}

$$\min_j \left(\sum_{i=1}^N a_{ij} \right) \leq \lambda_1 \leq \max_j \left(\sum_{i=1}^N a_{ij} \right)$$

Centralidad de autovalor

$$\mathbf{A}\mathbf{x}^* = \lambda_* \mathbf{x}^*$$

\mathbf{x} se conoce como **centralidad de Bonacich**

$$x_i^* = \frac{1}{\lambda_*} \sum_j A_{ij} x_j^*$$

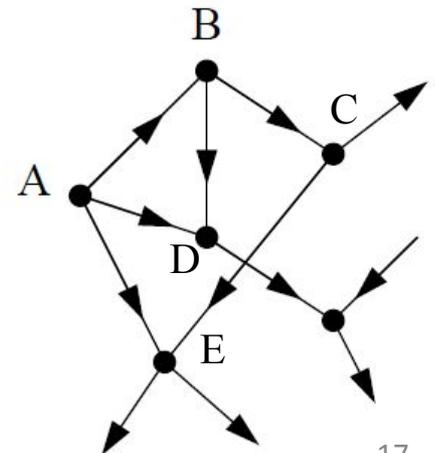
La centralidad de un nodo depende de la de sus vecinos.

Para redes dirigidas (\mathbf{A} matriz no simétrica) se usa la misma definición de centralidad. Esto equivale a considerar el autovector-por-derecha de mayor autovalor.

Sin embargo puede haber problemas:

- x_A no tiene vecinos, entonces $x_A=0$
- pero también $x_B=0$, $x_C=0$, $x_D=0$, $x_E=0$

Sólo nodos de una **componente fuertemente conexa** de dos o más vértices (o la **out-component** de dicha componente) pueden tener centralidad de Bonacich no nula. **Potencial problema (!)**



Centralidad de Katz

$$x_i = \alpha \sum_j A_{ij} x_j + \beta$$

Matricialmente

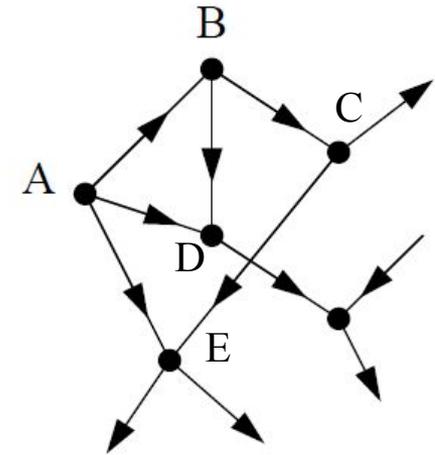
centralidad de base.
Gran diferencia para nodos
con $k_{in}=0$

$$\mathbf{x} = \alpha \mathbf{A} \mathbf{x} + \beta \mathbf{1}$$

$$\mathbf{x} - \alpha \mathbf{A} \mathbf{x} = \beta \mathbf{1}$$

$$(\mathbf{I} - \alpha \mathbf{A}) \mathbf{x} = \beta \mathbf{1}$$

$$\mathbf{x} = (\mathbf{I} - \alpha \mathbf{A})^{-1} \beta \mathbf{1}$$



Usualmente se toma $\beta=1$ y se debe especificar α , que controla la importancia relativa del primer término respecto del segundo

Centralidad de Katz

$$x_i = \alpha \sum_j A_{ij} x_j + 1$$

$$\mathbf{x} = (\mathbf{I} - \alpha \mathbf{A})^{-1} \mathbf{1}$$

Se debe especificar α , como lo elijo?

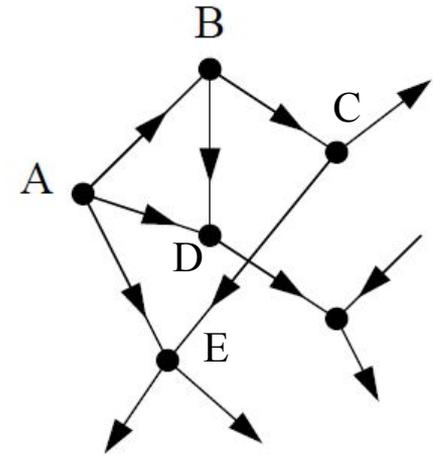
- $\alpha = 0$ resulta en distribución uniforme de centralidad
- $\alpha > 0$ le doy más peso al primer término
- **PERO OJO:** para algún $\alpha > 0$ la matriz $\mathbf{I} - \alpha \mathbf{A}$ puede no ser invertible. Esto sucede cuando $\det(\mathbf{I} - \alpha \mathbf{A}) = 0$, o lo que es lo mismo, cuando:

$$\det(\mathbf{A} - \alpha^{-1} \mathbf{I}) = 0 \xrightarrow{\alpha^{-1} = \lambda} \det(\mathbf{A} - \lambda \mathbf{I}) = 0$$

La condición para identificar α problemáticos esta **asociada** a la ecuación de autovalores para \mathbf{A} (!)

Para α creciente el *primer* problema lo encuentro cuando $\alpha^{-1} = \lambda_*$

Por lo tanto, se suele elegir α en el rango $0 < \alpha < 1/\lambda_*$



Centralidad de Katz

Estimación de centralidad

Algebraica:

$$\mathbf{x} = (\mathbf{I} - \alpha\mathbf{A})^{-1}\beta\mathbf{1}$$

Iterando:

$$x_i^{(t+1)} = \alpha \sum_j A_{ij} x_j^{(t)} + \beta$$

Costo
computacional

$o(n^3)$

$o(M.r)$

M: #enlaces, i.e. items no nulos de \mathbf{A}
r: #iteraciones

Centralidad de Katz generalizada

Asignamos una relevancia-a-priori, que puede ser diferente para cada nodo, utilizando **información externa a la red**

$$\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_N)$$

$$x_i^{(t+1)} = \alpha \sum_j A_{ij} x_j^{(t)} + \beta_i \quad \mathbf{x} = (\mathbf{I} - \alpha \mathbf{A})^{-1} \boldsymbol{\beta}$$

Centralidad PageRank

Katz generalizado:

$$x_i^{(t+1)} = \alpha \sum_j A_{ij} x_j^{(t)} + \beta_i$$

Un posible problema: nodos con **alta centralidad** distribuyen ese valor (**alto**) a todos sus contactos k_{out} . Quizas no sea eso lo que uno quiere.

↓ 'diluye' la contribución del nodo-j

$$x_i^{(t+1)} = \alpha \sum_j \frac{1}{k_j^{out}} A_{ij} x_j^{(t)} + \beta_i$$

Centralidad PageRank sin bias

$$x_i^{(t+1)} = \cancel{\alpha} \sum_j \frac{1}{k_j^{out}} A_{ij} x_j^{(t)} + \cancel{\beta_i}$$

$$\mathbf{x} = \mathbf{AD}^{-1}\mathbf{x}$$

$$[\mathbf{D}^{-1}]_{ii} = 1/k_i^{out}$$

- Estoy buscando el autovector de \mathbf{AD}^{-1} asociado a $\lambda=1$
- Para redes no-dirigidas es fácil ver que $x_j = k_j$ es la solución autoconsistente buscada.
- O sea PageRank sin bias equivale a centralidad de grado.

$$k_i = \sum_j \frac{1}{k_j} A_{ij} k_j = \sum_j A_{ij} \quad \checkmark$$

Nota:

- para redes no dirigidas se puede demostrar (practica) que el autovalor dominante de \mathbf{AD}^{-1} es 1, con autovector (k_1, k_2, \dots, k_n)
- para redes dirigidas no. pero resulta $o(1)$

Centralidad PageRank

$$x_i^{(t+1)} = \alpha \sum_j \frac{1}{k_j^{out}} A_{ij} x_j^{(t)} + \beta_i$$

$$\mathbf{x} = \alpha \mathbf{A} \mathbf{D}^{-1} \mathbf{x} + \boldsymbol{\beta} \quad [\mathbf{D}^{-1}]_{ii} = 1/k_i^{out}$$

$$(\mathbf{I} - \alpha \mathbf{A} \mathbf{D}^{-1}) \mathbf{x} = \boldsymbol{\beta}$$

$$\mathbf{x} = (\mathbf{I} - \alpha \mathbf{A} \mathbf{D}^{-1})^{-1} \boldsymbol{\beta}$$

deja de ser
invertible cuando

$$\det(\mathbf{I} - \alpha \mathbf{A} \mathbf{D}^{-1}) = 0$$

$$\det\left(\frac{1}{\alpha} \mathbf{I} - \mathbf{A} \mathbf{D}^{-1}\right) = 0$$

$$\det(\lambda \mathbf{I} - \mathbf{A} \mathbf{D}^{-1}) = 0$$

$$\lambda = 1/\alpha$$

$$\mathbf{x} = (\mathbf{I} - \alpha \mathbf{A} \mathbf{D}^{-1})^{-1} \boldsymbol{\beta}$$

$$= (\mathbf{D} \mathbf{D}^{-1} - \alpha \mathbf{A} \mathbf{D}^{-1})^{-1} \boldsymbol{\beta}$$

$$= [(\mathbf{D} - \alpha \mathbf{A}) \mathbf{D}^{-1}]^{-1} \boldsymbol{\beta}$$

$$\mathbf{x} = \mathbf{D} (\mathbf{D} - \alpha \mathbf{A})^{-1} \boldsymbol{\beta}$$

razonando como antes $\alpha < 1/\lambda_{dominante}$ de $\mathbf{A} \mathbf{D}^{-1}$.
 Pero vimos que $\lambda_{dominante} = 1$
 $0 < \alpha < 1$...se suele usar $\alpha = 0.85$

Centralidades de recurrencia (resumen)

$$x_i^{(t+1)} = \sum_j A_{ij} x_j^{(t)}$$

$$\mathbf{x} = \lambda_*^{-1} \mathbf{A} \mathbf{x}$$

**Eigenvector (Bonacich)
centrality**

$$x_i^{(t+1)} = \alpha \sum_j A_{ij} x_j^{(t)} + \beta_i$$

$$\mathbf{x} = (\mathbf{I} - \alpha \mathbf{A})^{-1} \boldsymbol{\beta}$$

Katz centrality

$$x_i^{(t+1)} = \sum_j \frac{1}{k_j^{out}} A_{ij} x_j^{(t)}$$

$$\mathbf{x} = \mathbf{A} \mathbf{D}^{-1} \mathbf{x}$$

Degree centrality

$$x_i^{(t+1)} = \alpha \sum_j \frac{1}{k_j^{out}} A_{ij} x_j^{(t)} + \beta_i$$

$$\mathbf{x} = (\mathbf{I} - \alpha \mathbf{A} \mathbf{D}^{-1})^{-1} \boldsymbol{\beta}$$

$$\mathbf{x} = \mathbf{D} (\mathbf{D} - \alpha \mathbf{A})^{-1} \boldsymbol{\beta}$$

PageRank centrality

Conectores (*hubs*) y Autoridades

- Hasta ahora, en **redes dirigidas**, los algoritmos que vimos asignaban más nivel de **centralidad** a aquellos nodos que **recibían** muchas conexiones
- Puede ser de interés, sin embargo, identificar nodos que actúen como buenos *reviews*. Implica idea de centralidad asociada con k_{out} hacia nodos relevantes (e.g. página con links hacia otras páginas relevantes)

Idea [Kleinberg, Authoritative Sources in a Hyperlinked Environment, 1999 10122 citas]:

Generalizar la centralidad de Bonacich y permitir que cada nodo tenga dos atributos

1. **Autoridad**: que tanto conocimiento, información, etc, tiene un nodo respecto a un tema
2. **Conectividad (*hubiness*)**: que tanto un nodo es capaz de encontrar información sobre un tema

En este esquema:

- Los nodos son caracterizados simultáneamente como **conectores y autoridades**
- Los mejores conectores apuntan a las mejores autoridades
- Algoritmo HITS (*Hyperlink-induced topic search*)

Conectores (*hubs*) y Autoridades

Para un nodo, dos centralidades: x_i (autoridad), y_i (conector)

$$x_i = \alpha \sum_j A_{ij} y_j$$

$$y_i = \beta \sum_j A_{ji} x_j$$

$$\mathbf{x} = \alpha \mathbf{A} \mathbf{y}$$

$$\mathbf{y} = \beta \mathbf{A}^T \mathbf{x}$$

pero entonces

$$\mathbf{x} = (\alpha\beta) \mathbf{A} \mathbf{A}^T \mathbf{x} \quad \mathbf{y} = (\alpha\beta) \mathbf{A}^T \mathbf{A} \mathbf{y}$$

$$\mathbf{A} \mathbf{A}^T \mathbf{x} = \lambda \mathbf{x} \quad \mathbf{A}^T \mathbf{A} \mathbf{y} = \lambda \mathbf{y} \quad \text{con } \lambda = \alpha\beta$$

fijarse además que:

- $\mathbf{A} \mathbf{A}^T$ es la matriz de co-citas, por lo que la **centralidad de autoridad** puede verse como **centralidad de autovector de la red de co-citas**
- $\mathbf{A}^T \mathbf{A}$ es la matriz bibliográfica, por lo que la **centralidad de conectividad** puede verse como **centralidad de autovector de la red bibliográfica**

Conectores (*hubs*) y Autoridades

Para un nodo, dos centralidades: x_i (autoridad), y_i (conector)

$$x_i = \alpha \sum_j A_{ij} y_j \qquad y_i = \beta \sum_j A_{ji} x_j$$

$$\mathbf{x} = \alpha \mathbf{A} \mathbf{y} \qquad \mathbf{y} = \beta \mathbf{A}^T \mathbf{x}$$

pero entonces

$$\mathbf{x} = (\alpha\beta) \mathbf{A} \mathbf{A}^T \mathbf{x} \qquad \mathbf{y} = (\alpha\beta) \mathbf{A}^T \mathbf{A} \mathbf{y}$$

$$\mathbf{A} \mathbf{A}^T \mathbf{x} = \lambda \mathbf{x} \qquad \mathbf{A}^T \mathbf{A} \mathbf{y} = \lambda \mathbf{y} \qquad \text{con } \lambda = \alpha\beta$$

fijarse además que:

$$\mathbf{A}^T (\mathbf{A} \mathbf{A}^T \mathbf{x}) = \lambda \mathbf{A}^T \mathbf{x}$$

$$\mathbf{A}^T \mathbf{A} (\mathbf{A}^T \mathbf{x}) = \lambda (\mathbf{A}^T \mathbf{x})$$

por lo que $\mathbf{y} = (\mathbf{A}^T \mathbf{x})$ o sea, basta con resolver la ecuación de autovalores de $\mathbf{A}^T \mathbf{A}$

Conectores (*hubs*) y Autoridades

Para un nodo, dos centralidades: x_i (autoridad), y_i (conector)

$$x_i = \alpha \sum_j A_{ij} y_j$$

$$y_i = \beta \sum_j A_{ji} x_j$$

$$\mathbf{x} = \alpha \mathbf{A} \mathbf{y}$$

$$\mathbf{y} = \beta \mathbf{A}^T \mathbf{x}$$

pero entonces

$$\mathbf{x} = (\alpha\beta) \mathbf{A} \mathbf{A}^T \mathbf{x} \quad \mathbf{y} = (\alpha\beta) \mathbf{A}^T \mathbf{A} \mathbf{y}$$

$$\mathbf{A} \mathbf{A}^T \mathbf{x} = \lambda \mathbf{x} \quad \mathbf{A}^T \mathbf{A} \mathbf{y} = \lambda \mathbf{y} \quad \text{con } \lambda = \alpha\beta$$

- $\mathbf{A} \mathbf{A}^T$ es una matriz simétrica, semi-definida positiva, por lo que sus autovalores son mayores que cero.
- De hecho, sus autovalores son los valores-singulares de \mathbf{A} elevados al cuadrado
- Perron-Frobenius: el autovector del autovalor dominante tiene componentes no-negativas

Conectores (*hubs*) y Autoridades

Para un nodo, dos centralidades: x_i (autoridad), y_i (conector)

$$x_i = \alpha \sum_j A_{ij} y_j$$

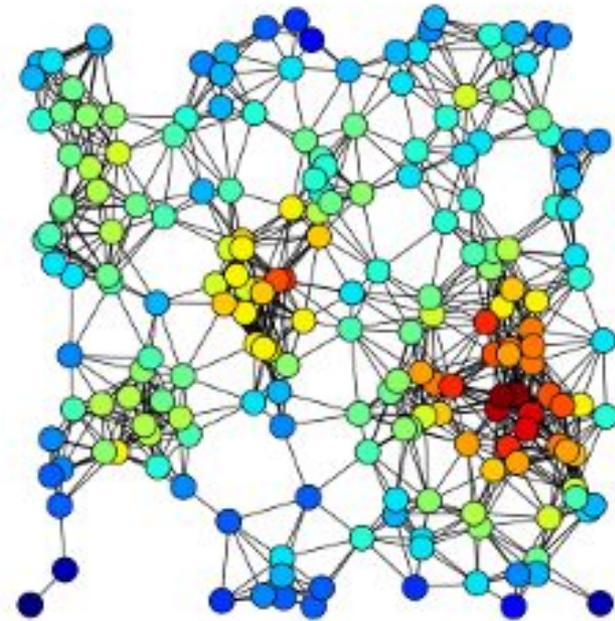
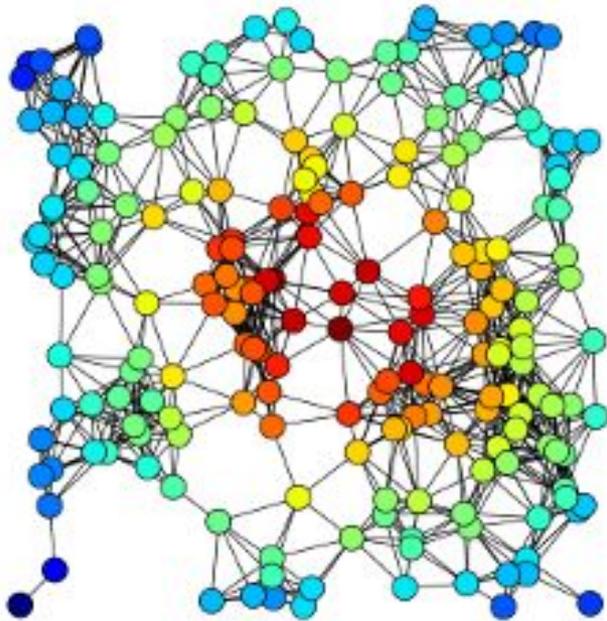
$$y_i = \beta \sum_j A_{ji} x_j$$

$$\mathbf{x} = \alpha \mathbf{A} \mathbf{y}$$

$$\mathbf{y} = \beta \mathbf{A}^T \mathbf{x}$$

Esta generalización admite modificaciones como las que vimos: un término aditivo, dividir por el grado, etc...

Que significa ser **importante**?



Noción de **flujo** sobre la red

Noción de **cohesividad** sobre la red

Dime qué modelas con tu red y te diré qué es ser importante

	Transferencia	Duplicación	
		serial	paralela
<i>Walks</i>	billete		creencias
<i>Trail</i>	ropa vieja	rumor	campana email
<i>Path</i>	viajante comercio	infección viral	
Geodésica	correo		-

Centralidad de autovalor

Nodos importantes tienen **vecinos** importantes

- x_i (importancia de nodo-i) depende de x_j (importancia de nodo-j vecino). La importancia se *transmite* por la red.
- la manera más simple es asumir linealidad

$$x_i' = \sum_{j=1}^N a_{ij} x_j \quad \mathbf{x}' = \mathbf{A} \mathbf{x}$$

- el nivel de importancia se establece recursivamente en la red

$$\mathbf{x}'' = \mathbf{A} \mathbf{x}' = \mathbf{A} \mathbf{A} \mathbf{x}$$

⋮

Después de s iteraciones:

$$\mathbf{x}(s) = \overbrace{\mathbf{A} \mathbf{A} \dots \mathbf{A}}^s \mathbf{x}(0)$$

$$\mathbf{x}(s) = \mathbf{A}^s \mathbf{x}(0)$$

Centralidad de autovalor

Nodos importantes tienen vecinos importantes

- x_i (importancia de nodo-i) depende de x_j (importancia de nodo-j vecino). La importancia se *transmite* por la red.
- la manera más simple es asumir linealidad

$$x_i' = \sum_{j=1}^N a_{ij} x_j \quad \mathbf{x}' = \mathbf{A} \mathbf{x}$$

- el nivel de importancia se establece recursivamente en la red

$$\mathbf{x}'' = \mathbf{A} \mathbf{x}' = \mathbf{A} \mathbf{A} \mathbf{x}$$

⋮

Después de s iteraciones:

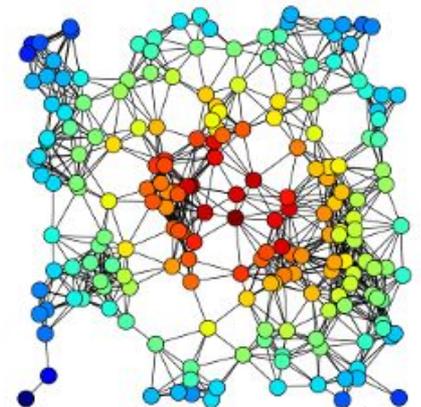
$$\mathbf{x}(s) = \overbrace{\mathbf{A} \mathbf{A} \dots \mathbf{A}}^s \mathbf{x}(0)$$

$$\mathbf{x}(s) = \mathbf{A}^s \mathbf{x}(0)$$

\mathbf{x} solución autoconsistente

$$\lambda \mathbf{x} = \mathbf{A}^s \mathbf{x}$$

$s \gg 1$



\mathbf{x} es un autovector de \mathbf{A}^s

Centralidad de autovalor

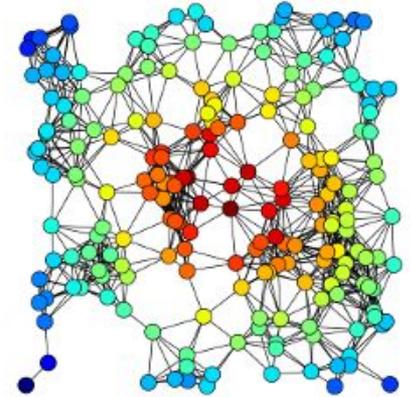
Busco x solución autoconsistente

$$x(s) = A^s x(0)$$

$$\lambda x = A^s x \quad x \in \mathbb{R}^N \text{ es un autovector de } A^s \text{ de autovalor } \lambda$$

Para ganar (recordar) intuición geométrica... caso
2D

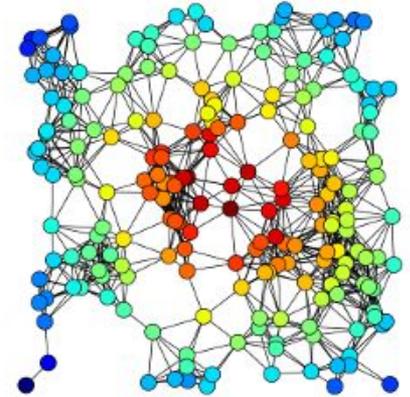
mathlets.org/mathlets/matrix-vector



Centralidad de autovalor

Busco x solución autoconsistente

$$\mathbf{x}(s) = \mathbf{A}^s \mathbf{x}(0)$$



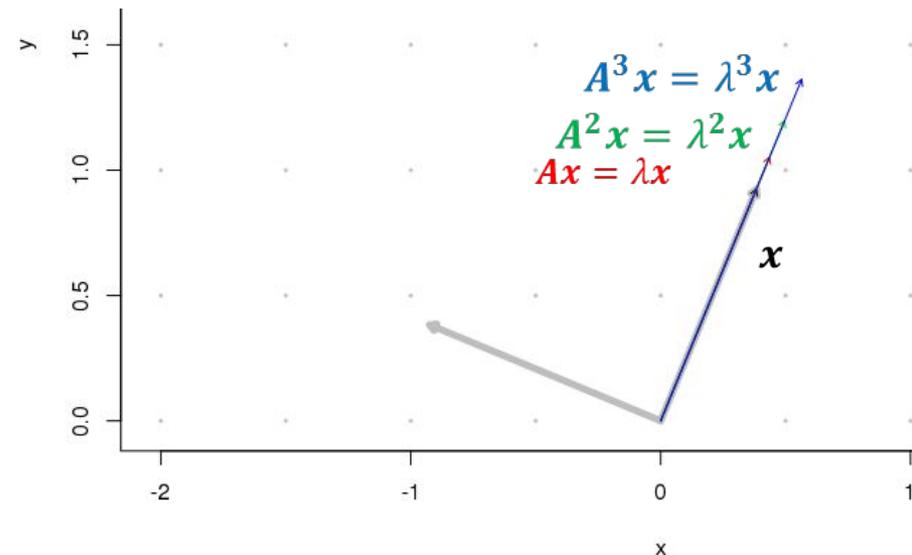
Si inicialmente arranco de un autovector: $\mathbf{x}(0) = \mathbf{v}_k$

$$\mathbf{x}(s) = \overbrace{\mathbf{A}\mathbf{A} \dots \mathbf{A}}^{s-1} \mathbf{A} \mathbf{v}_k = \lambda_k \overbrace{\mathbf{A}\mathbf{A} \dots \mathbf{A}}^{s-1} \mathbf{v}_k$$

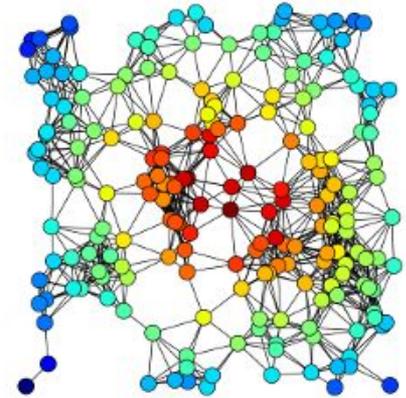
$$\mathbf{x}(s) = \lambda_k^s \mathbf{v}_k$$

Por lo que la **importancia relativa** de cada nodo se podría inferir de las componentes de \mathbf{v}_k

si \mathbf{x} inicial fuera justo un **autovector**, por ejemplo \mathbf{v}_k , de la matriz de adyacencia \mathbf{A}



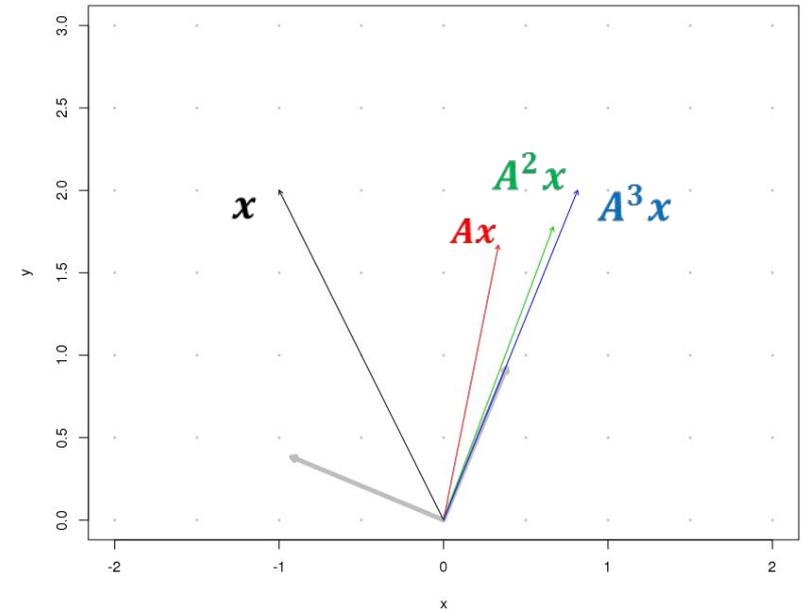
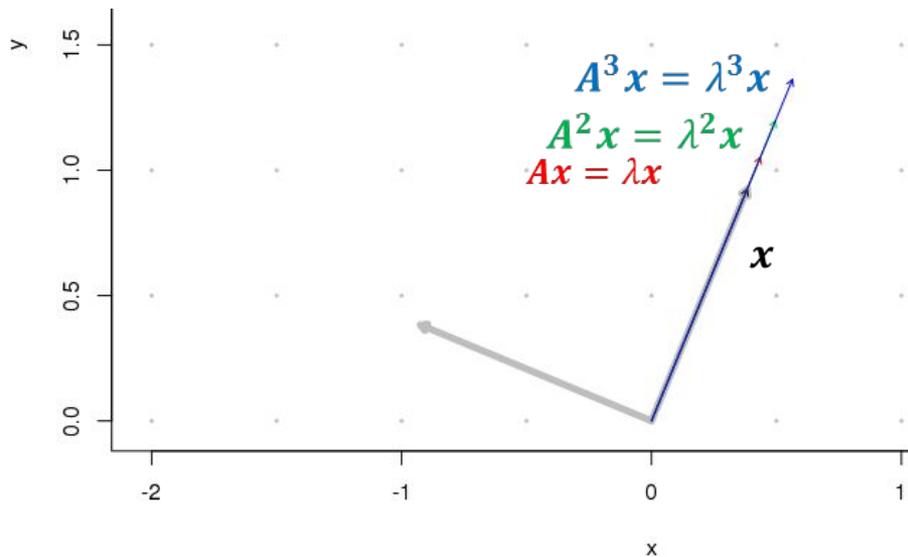
Centralidad de autovalor



$$\mathbf{x}(s) = \mathbf{A}^s \mathbf{x}(0)$$

si \mathbf{x} inicial fuera justo un **autovector**, por ejemplo \mathbf{v}_k , de la matriz de adyacencia \mathbf{A}

En el caso general $\mathbf{x}(0)$ no coincide con una dirección privilegiada asociada con \mathbf{A}



Centralidad de autovalor

Para ver como una **matriz** transforma vectores es útil pensar en término de sus **autovectores** \mathbf{v}_i (se transforman muy fácil: $\mathbf{A} \mathbf{v}_i = \lambda_i \mathbf{v}_i$). El vector $\mathbf{x}(0)$ puede ser escrito como combinación lineal de los $\{\mathbf{v}_i\}$

$$\mathbf{x}(0) = c_1 \mathbf{v}_1 + c_2 \mathbf{v}_2 + \dots = \sum_i c_i \mathbf{v}_i$$

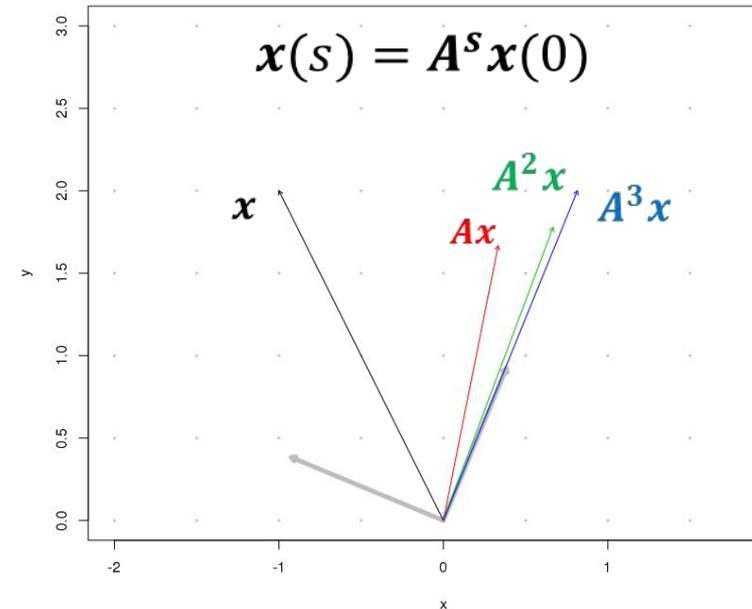
$$\mathbf{A}^s \mathbf{x}(0) = \sum_i c_i \mathbf{A}^s \mathbf{v}_i = \sum_i c_i \lambda_i^s \mathbf{v}_i = \lambda_*^s \sum_i c_i \left(\frac{\lambda_i}{\lambda_*} \right)^s \mathbf{v}_i$$

↑ mayor autovalor

$$\mathbf{x}(s) = \lambda_*^s \sum_i c_i \overbrace{\left(\frac{\lambda_i}{\lambda_*} \right)^s}^{<1} \mathbf{v}_i$$

$$\mathbf{x}(s) \sim \lambda_*^s c_i \mathbf{v}_*$$

$s \rightarrow \infty$



encontrar \mathbf{x} autoconsistente se reduce a encontrar el autovector de \mathbf{A} asociado al mayor autovalor

$$\mathbf{A} \mathbf{x} = \lambda_* \mathbf{x}$$

Retomando...

- Centralidad de autovalor

Nodos importantes tienen **vecinos** importantes

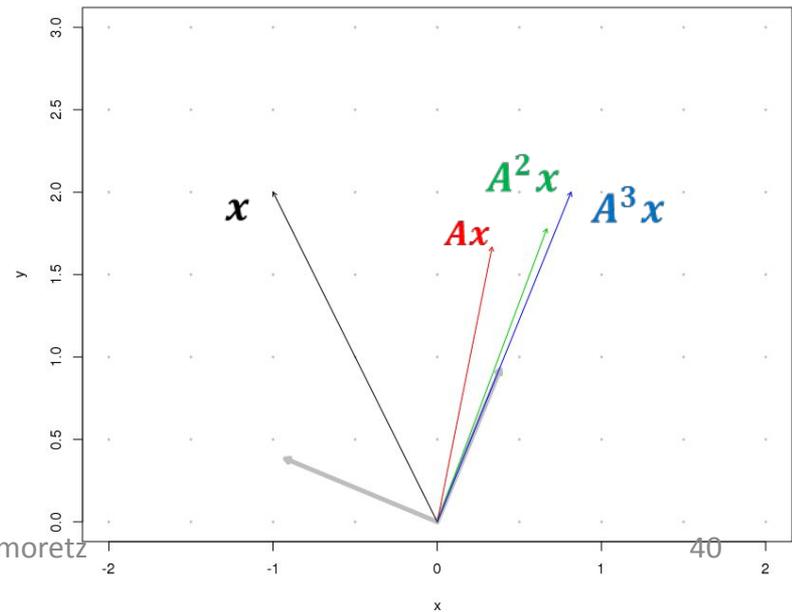
- x_i (importancia de nodo-i) depende de x_j (importancia de nodo-j vecino).
- La importancia se *transmite* por la red.
- la manera más simple es asumir linealidad

$$x_i' = \sum_{j=1}^N a_{ij} x_j \quad \mathbf{x}' = \mathbf{A} \mathbf{x}$$

$$\mathbf{A} \mathbf{x}^* = \lambda_* \mathbf{x}^*$$

Autovector del autovalor dominante de \mathbf{A}

\mathbf{x}^* se conoce como **centralidad de Bonacich**



Retomando...

- Centralidad de autovalor (Bonacich)

$$\mathbf{Ax}^* = \lambda_* \mathbf{x}^*$$

- Centralidad de Katz generalizada

$$x_i^{(t+1)} = \alpha \sum_j A_{ij} x_j^{(t)} + \beta_i \quad \mathbf{x} = (\mathbf{I} - \alpha \mathbf{A})^{-1} \boldsymbol{\beta}$$

$$0 < \beta_i < 1$$

$$0 < \alpha < 1/\lambda_*$$

Centralidad PageRank

$$x_i^{(t+1)} = \alpha \sum_j \frac{1}{k_j^{out}} A_{ij} x_j^{(t)} + \beta_i$$

$$\mathbf{x} = \alpha \mathbf{A} \mathbf{D}^{-1} \mathbf{x} + \boldsymbol{\beta}$$

$$[\mathbf{D}^{-1}]_{ii} = 1/k_i^{out}$$

$$(\mathbf{I} - \alpha \mathbf{A} \mathbf{D}^{-1}) \mathbf{x} = \boldsymbol{\beta}$$

$$\mathbf{x} = (\mathbf{I} - \alpha \mathbf{A} \mathbf{D}^{-1})^{-1} \boldsymbol{\beta}$$

$$= (\mathbf{D} \mathbf{D}^{-1} - \alpha \mathbf{A} \mathbf{D}^{-1})^{-1} \boldsymbol{\beta}$$

$$= [(\mathbf{D} - \alpha \mathbf{A}) \mathbf{D}^{-1}]^{-1} \boldsymbol{\beta}$$

$$\mathbf{x} = \mathbf{D} (\mathbf{D} - \alpha \mathbf{A})^{-1} \boldsymbol{\beta}$$

razonando como antes $\alpha < 1/\lambda_{\text{dominante}} \text{ de } \mathbf{A} \mathbf{D}^{-1}$.
igual....se suele usar $\alpha=0.85$

Centralidades de recurrencia (resumen)

$$x_i^{(t+1)} = \alpha \sum_j \frac{1}{k_j^{out}} A_{ij} x_j^{(t)} + \beta_i$$

$$\mathbf{x} = \mathbf{D}(\mathbf{D} - \alpha\mathbf{A})^{-1}\boldsymbol{\beta}$$

PageRank centrality

$$x_i^{(t+1)} = \sum_j \frac{1}{k_j^{out}} A_{ij} x_j^{(t)}$$

$$\mathbf{x} = \mathbf{A}\mathbf{D}^{-1}\mathbf{x}$$

Degree centrality

$$x_i^{(t+1)} = \alpha \sum_j A_{ij} x_j^{(t)} + \beta_i$$

$$\mathbf{x} = (\mathbf{I} - \alpha\mathbf{A})^{-1}\boldsymbol{\beta}$$

Katz centrality

$$x_i^{(t+1)} = \sum_j A_{ij} x_j^{(t)}$$

$$\mathbf{x} = \lambda_*^{-1}\mathbf{A}\mathbf{x}$$

**Eigenvector (Bonacich)
centrality**