

Structure et dynamique des réseaux

Clémence Magnien, Lionel Tabourier, Fabien Tarissan

LIP6 – CNRS and Université Pierre et Marie Curie

`prenom.nom@lip6.fr`

16 septembre 2014

Fonctionnement du cours

Enseignants

Clémence Magnien `clemence.magnien@lip6.fr`

Lionel Tabourier `lionel.tabourier@lip6.fr`

Fabien Tarissan `fabien.tarissan@lip6.fr`

Page du cours

<http://www-rp.lip6.fr/~magnien/sdr.html>

Évaluation

- Contrôle continu : 40%
 - deux TP notés
- Examen : 60%

Outline

- 1 Introduction – Contexte
- 2 Graphes – Rappels
 - Définitions
 - Stockage en mémoire
- 3 Propriétés des graphes de terrain

Outline

- 1 Introduction – Contexte
- 2 Graphes – Rappels
 - Définitions
 - Stockage en mémoire
- 3 Propriétés des graphes de terrain

Réseaux / graphes

informatique : internet, web, pair-à-pair, usages, etc
mais aussi :

sciences sociales : collaboration, amitié, contacts sexuels,
échanges, économie, etc

biologie : cerveau, gènes, protéines, écosystèmes, etc


linguistique : synonymie, co-occurrence, etc

transport : routier, aérien, électrique, etc

etc, etc

réseaux de relations

contextes très différents




Réseaux / graphes

Contextes différents, mais

- Propriétés communes
→ Ressemblance
- **Problématiques** communes


Problématique – Mesure



Impossible de mesurer l'objet complet :

- Taille
- Contraintes techniques
- ...

Problématique – Métrologie



que peut on dire sur l'objet réel à partir de la mesure ?

Comparer aux instituts de sondage

- Vue représentative : complexe
- Ici, choix limité sur la procédure de mesure

impact sur les propriétés observées ?
impact des propriétés sur la vue ?
mesures ciblant certaines propriétés ?

Problématique – Analyse

décrire

extraire de l'information pertinente

statistiques

densité
degrés
densité locale
corrélations
...

structure

Problématique – Analyse


décrire

extraire de l'information pertinente

statistiques

densité
degrés
densité locale
corrélations
...

structure



Problématique – Modélisation

Modèle : générateur de graphes

génération de graphes *réalistes*
(i.e. ayant les propriétés observées)

motivations : approches formelles, simulation, explication

Problématique – Algorithmique

Taille


- problèmes classiques à **revisiter**
- restrictions en **espace**

Problématique – Algorithmique

Taille

- problèmes classiques à **revisiter**
- restrictions en **espace**

+ problèmes **spécifiques**



Dynamique

Apparition/disparition au fil du temps

- de nœuds
- de liens

Dans ce cours

- Panorama des questions du domaine
 - Modèles
 - Communautés
 - Métrologie
 - ...
- Trois cas d'intérêt particuliers
 - Internet
 - Réseaux de contacts
 - P2P

Outline

- 1 Introduction – Contexte
- 2 Graphes – Rappels
 - Définitions
 - Stockage en mémoire
- 3 Propriétés des graphes de terrain

Graphe


On modélise les réseaux par des *graphes*

Un graphe $G = (V, E)$ est un couple d'ensembles.

- V est l'ensemble des *sommets* (ou *nœuds*)
- $E \subseteq (V \times V)$ est l'ensemble des *arêtes* (ou *liens*).


Exemple

- $V = \{0, 1, 2, 3, 4, 5\}$
- $E = \{(0, 1), (0, 2), (3, 4), (4, 5), (5, 0), (1, 4)\}$



Exemple

- $V = \{0, 1, 2, 3, 4, 5\}$
- $E = \{(0, 1), (0, 2), (3, 4), (4, 5), (5, 0), (1, 4)\}$



Attention à ne pas confondre le **graphe** et le **dessin** !

Notations

On note :

- $n = |V|$ le nombre de sommets
- $m = |E|$ le nombre d'arêtes

u et v sont **voisins** s'il y a une arête entre eux.

Degré : $d^\circ(v)$: nombre de voisins de v

Degré moyen, densité

degré moyen du graphe, $d^\circ(G)$

moyenne des degrés de tous les sommets

Degré moyen, densité


densité du graphe, δ

= probabilité d'existence de tout lien

= à quel point tout le monde est lié

$$\delta = \frac{2m}{n(n-1)}$$

Degré moyen, densité



degrés : **2**, **2**, **3**, **1** ; degré moyen 2

$$n = 4, m = 4, \delta = \frac{8}{12} = 0.66..$$

Graphes orientés/non orientés

Graphe **non-orienté** : $(u, v) = (v, u)$

Graphe **orienté** : $(u, v) \neq (v, u)$

Degré entrant : $d^+(v)$

Degré sortant : $d^-(v)$

Sauf mention contraire : graphes **non-orientés**


Matrice d'adjacence

$$\begin{array}{c} 0 \\ 1 \\ \dots \\ n-1 \end{array} \begin{array}{c} 0 \quad 1 \quad \dots \quad n-1 \\ \left(\begin{array}{cccc} & & & \\ & & & \\ & & \dots & \\ & & & \end{array} \right) \end{array}$$

Case (i, j) :

- 1 s'il y a une arête entre i et j
- 0 sinon

Listes d'adjacence



Avantages, inconvénients

Existence d'une arête

Lister les voisins d'un sommet

Taille

En général, les graphes de terrain sont **peu denses**

$$\rightarrow \mathcal{O}(m) \ll \mathcal{O}(n^2)$$

Avantages, inconvénients

	Matrice	Listes
Existence d'une arête	$\mathcal{O}(1)$	$\mathcal{O}(d^\circ(v))$
Lister les voisins d'un sommet	$\mathcal{O}(n)$	$\mathcal{O}(d^\circ(v))$
Taille	$\mathcal{O}(n^2)$	$\mathcal{O}(m)$

En général, les graphes de terrain sont **peu denses**

$$\rightarrow \mathcal{O}(m) \ll \mathcal{O}(n^2)$$


Stockage compact

On stocke :

- le nombre de sommets
- leurs degrés dans un tableau
- les voisins dans un **tableau**

n

4	2	3	1	2	3
0	1	...	i	...	$n-1$



Stockage compact

On stocke :


- le nombre de sommets

n

- leurs degrés dans un tableau

4	2	3	1	2	3
0	1	...	i	...	$n-1$

- les voisins dans un **tableau**



Allocation contigue : un seul gros tableau pour tous les voisins

Outline

- 1 Introduction – Contexte
- 2 Graphes – Rappels
 - Définitions
 - Stockage en mémoire
- 3 Propriétés des graphes de terrain

Densité

En pratique, **densité faible** pour les graphes de terrain.

Faible ?

Degré moyen **très faible** par rapport à n

Connexité

Chemin de u à v : suite d'arêtes $(u, v_1), (v_1, v_2), \dots, (v_{k-1}, v)$

Longueur = k (nombre d'arêtes)

Composante connexe : ensemble **maximal** de sommets t. q. \exists
un chemin entre toutes les paires de sommets.


Graphe **connexe** : une seule composante connexe

Connexité

Pour les graphes de terrain


En général, composante **géante**

→ Contient la plupart des sommets



Distance

chemin de u à v = suite d'arêtes $u\dots v$




un chemin de longueur 3

Distance

chemin de u à v = suite d'arêtes $u\dots v$

distance $d(u, v)$ = longueur d'un plus court chemin




un plus court chemin ; longueur 2 \Rightarrow distance = 2

Distance

chemin de u à v = suite d'arêtes $u\dots v$

distance $d(u, v)$ = longueur d'un plus court chemin

diamètre Δ = plus grande distance



diamètre = 2

Distances et connexité

Distance moyenne : moyenne de la distance pour toutes les paires de sommets

Connexité ?

Distance définie pour deux sommets de la même composante connexe

En pratique

Distance moyenne, diamètre :

→ dans la plus grande composante connexe

Distances et connexité

Distance moyenne : moyenne de la distance pour toutes les paires de sommets

Connexité ?

Distance définie pour deux sommets de la même composante connexe

En pratique

Distance moyenne, diamètre :

→ dans la plus grande composante connexe

Distance

Pour les graphes de terrain

En général, distances courtes ($\sim \log(n)$)

Expérience de **Milgram**

“Six degrés de séparation”

Kevin Bacon game

Distribution des degrés (1/2)

Distribution des degrés :

4 nœuds, degrés : 2 3 3 1


Distribution des degrés (1/2)

Distribution des degrés :

4 nœuds, degrés : 2 3 3 1

Distribution : combien de nœuds ont degré k , en fonction de k .

$1 \rightarrow 1, 2 \rightarrow 1, 3 \rightarrow 2$



Loi de puissance (power-law)

Loi de puissance

- $N_k \sim k^{-\alpha}$
- droite en échelle log-log

Distribution **hétérogène** : **proche** d'une loi de puissance

Loi de puissance



- **droite** en échelle log-log
sur plusieurs ordres de
grandeur

≠


Hétérogène

- plusieurs ordres de
grandeur
- **proche** d'une droite en
échelle log-log


Exemple



Distributions hétérogènes : échelle log-log





échelle linéaire



échelle logarithmique

Distributions hétérogènes vs homogènes



Homogène

Notion de normalité (et d'**exceptions**)

Hétérogène

Tous les comportements existent

→ pas de notion de normalité

Distribution des degrés (2/2)

Pour les graphes de terrain

En général, distributions des degrés **hétérogènes**

Coefficient de clustering

coefficient de clustering $cc(v)$

= probabilité que deux voisins de v soient reliés




= # paires de voisins reliés / # paires de voisins
= densité locale

Coefficient de clustering

coefficient de clustering $cc(v)$

= probabilité que deux voisins de v soient reliés



coefficients de clustering : 1, 1, $\frac{1}{3}$, indéfini

Coefficient de clustering

Coefficient de clustering du **graphe** :
moyenne sur tous les sommets de **degré ≥ 2**

Pour les graphes de terrain


En général, clustering **fort**

Plusieurs ordres de grandeur au dessus de la **densité**

Définir les communautés

But

Rechercher une structure interne au graphe.



Définition

- intuitive: personnes partageant un intérêt commun, pages web au contenu similaire...
- structurelle: zone du graphe dense en liens

Propriétés communes – conclusion

La plupart des graphes de terrain ont des propriétés
communes :

densité	faible
connexité	comp. géante
distances	faibles
degrés	hétérogènes
clustering	fort
communautés	oui