



Praktikum – Beating the Worst Case

Jean-Pierre von der Heydt und Marcus Wilhelm | 22.11.2023



Fragen zum Übungsblatt 1

Gradverteilung

- Wie unterscheiden sich die Gradverteilungen?
 - Gib es hierfür ein Maß?
- [Wie] habt ihr die Verteilungen visualisiert?

Lokalität


- Wie kann man Lokalität messen?
- Welche Maße habt ihr verwendet?

Allgemein


- Mit welchen Maßen lassen sich die vier Netzwerkklassen unterscheiden?
- [Wo / Wie] habt ihr Recherchiert?
- Habt ihr eine Vermutung, wie die Graphen erzeugt wurden?



Netzwerke aus Datensatz




Homogene Gradverteilung




n: 4843
mean: 19.4
variance: 18.7
stdev: 4.33

Heterogene Gradverteilung




Heterogene Gradverteilung



n: 3472
mean: 20.0
variance: 891
stdev: 29.8




Heterogene Gradverteilung



n: 3472
mean: 20.0
variance: 891
stdev: 29.8




Heterogene Gradverteilung




n: 3472
mean: 20.0
variance: 891
stdev: 29.8



Heterogene Gradverteilung – Details




Heterogene Gradverteilung – Details



Heterogene Gradverteilung – Details

Gerade Linie im log-log plot


- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$



Heterogene Gradverteilung – Details

Gerade Linie im log-log plot


- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$



Heterogene Gradverteilung – Details

Gerade Linie im log-log plot

- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$




Heterogene Gradverteilung – Details

Gerade Linie im log-log plot

- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$

Definition: power-law distribution

- Zufallsvariable D mit Dichte $f_D(x) = cx^{-\tau}$
- τ heißt auch power-law exponent




Heterogene Gradverteilung – Details

Gerade Linie im log-log plot

- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$

Definition: power-law distribution

- Zufallsvariable D mit Dichte $f_D(x) = cx^{-\tau}$
- τ heißt auch power-law exponent
- üblicherweise: $\tau \in (2, 3)$



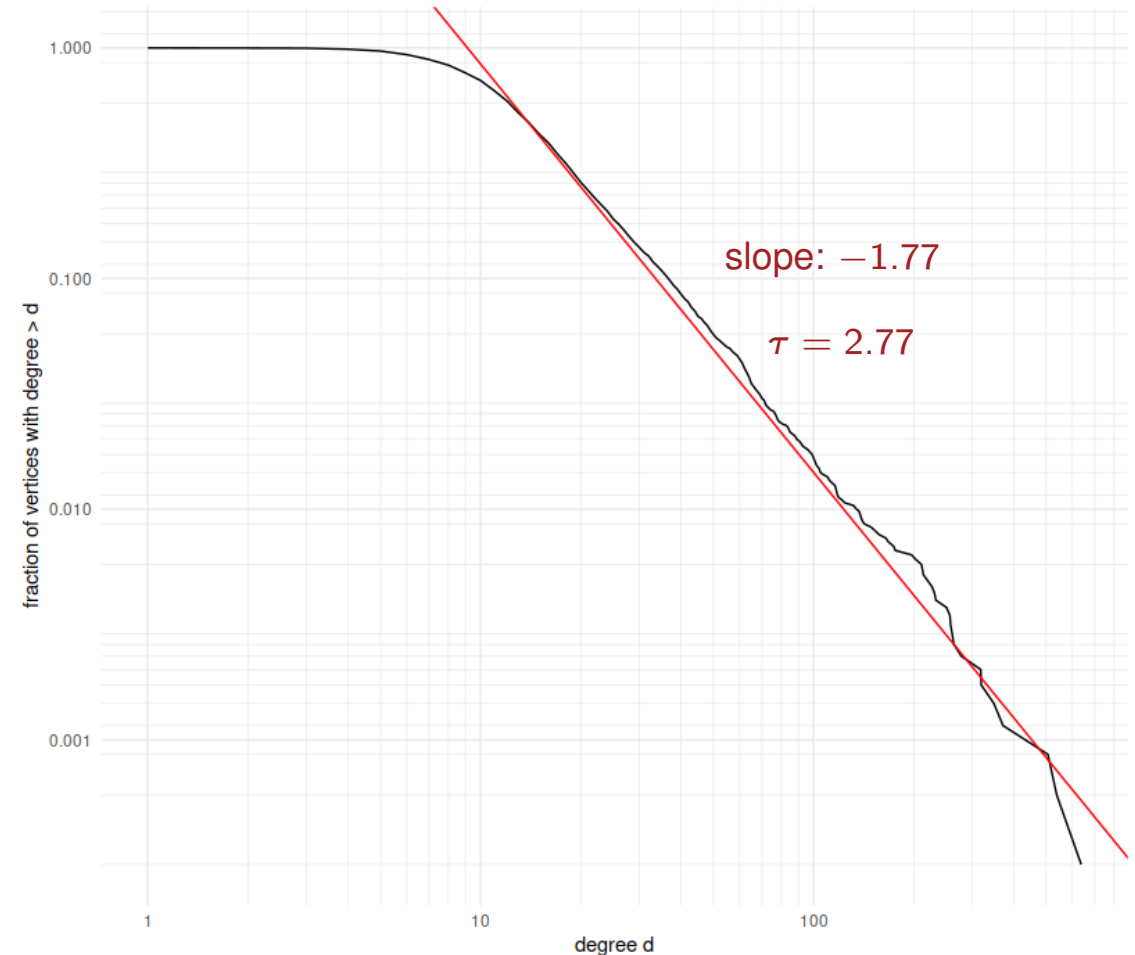
Heterogene Gradverteilung – Details

Gerade Linie im log-log plot

- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$

Definition: power-law distribution

- Zufallsvariable D mit Dichte $f_D(x) = cx^{-\tau}$
- τ heißt auch power-law exponent
- üblicherweise: $\tau \in (2, 3)$
 - $\tau > 2 \rightarrow$ constant average degree
 - $\tau \in (2, 3] \rightarrow$ variance increases with n
 - $\tau > 3 \rightarrow$ constant variance




Heterogene Gradverteilung – Details

Gerade Linie im log-log plot

- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$

Definition: power-law distribution

- Zufallsvariable D mit Dichte $f_D(x) = cx^{-\tau}$
- τ heißt auch power-law exponent
- üblicherweise: $\tau \in (2, 3)$
 - $\tau > 2 \rightarrow$ constant average degree
 - $\tau \in (2, 3] \rightarrow$ variance increases with n
 - $\tau > 3 \rightarrow$ constant variance



Heterogene Gradverteilung – Details

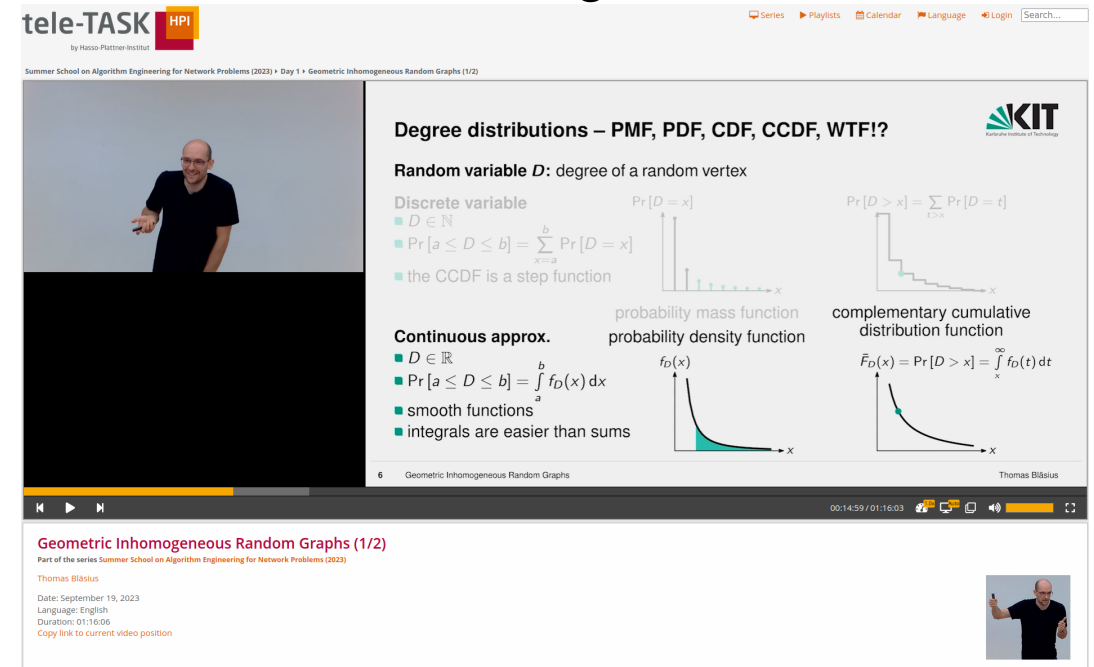
Gerade Linie im log-log plot

- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$

Definition: power-law distribution

- Zufallsvariable D mit Dichte $f_D(x) = cx^{-\tau}$
- τ heißt auch power-law exponent
- üblicherweise: $\tau \in (2, 3)$
 - $\tau > 2 \rightarrow$ constant average degree
 - $\tau \in (2, 3] \rightarrow$ variance increases with n
 - $\tau > 3 \rightarrow$ constant variance

weiterführend: Vortrag von Thomas



tele-TASK HPI

by Hosco Plattner-Institut

Summer School on Algorithm Engineering for Network Problems (2023) • Day 1 • Geometric Inhomogeneous Random Graphs (1/2)

Degree distributions – PMF, PDF, CDF, CCDF, WTF!?

Random variable D : degree of a random vertex

Discrete variable

- $D \in \mathbb{N}$
- $\Pr[a \leq D \leq b] = \sum_{x=a}^b \Pr[D = x]$
- the CCDF is a step function

Continuous approx.

- $D \in \mathbb{R}$
- $\Pr[a \leq D \leq b] = \int_a^b f_D(x) dx$
- smooth functions
- integrals are easier than sums

probability mass function

probability density function

complementary cumulative distribution function

$\Pr[D = x]$

$\Pr[D > x] = \sum_{t>x} \Pr[D = t]$

$f_D(x)$

$\bar{F}_D(x) = \Pr[D > x] = \int_x^\infty f_D(t) dt$

6 Geometric Inhomogeneous Random Graphs Thomas Blasius

00:14:59 / 01:16:03

Geometric Inhomogeneous Random Graphs (1/2)

Part of the series Summer School on Algorithm Engineering for Network Problems (2023)

Thomas Blasius

Date: September 19, 2023
 Language: English
 Duration: 01:16:06
 Copy link to current video position

Noch weiterführender:
Scale-free networks well done
 (Phys. Rev. Research 1, 033034)




Heterogene Gradverteilung – Details

Gerade Linie im log-log plot

- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$

Definition: power-law distribution

- Zufallsvariable D mit Dichte $f_D(x) = cx^{-\tau}$
- τ heißt auch power-law exponent
- üblicherweise: $\tau \in (2, 3)$
 - $\tau > 2 \rightarrow$ constant average degree
 - $\tau \in (2, 3] \rightarrow$ variance increases with n
 - $\tau > 3 \rightarrow$ constant variance




Heterogene Gradverteilung – Details

Gerade Linie im log-log plot

- gerade Linie: $y' = b - ax'$
- log-log plot: $\log y = b - a \log x$
- CCDF: $y = \bar{F}_D(x) = \Pr(D > x) = e^b x^{-a}$
- PDF: $f_D(x) = cx^{-\tau}$ mit $\tau = a + 1$

Definition: power-law distribution


- Zufallsvariable D mit Dichte $f_D(x) = cx^{-\tau}$
- τ heißt auch power-law exponent
- üblicherweise: $\tau \in (2, 3)$
 - $\tau > 2 \rightarrow$ constant average degree
 - $\tau \in (2, 3] \rightarrow$ variance increases with n
 - $\tau > 3 \rightarrow$ constant variance




einfacheres Maß für Heterogenität:
coefficient of variaton: $\frac{\text{std. dev.}}{\text{mean}}$




Lokalität Wiederholung



- Teil des US-Straßennetzes
- Knoten mit gemeinsamen Nachbarn sind oft selbst benachbart




- Spiele von College football teams
- Kanten entsprechen community structure




- Erdős–Rényi Graph
- Jede mögliche Kante existiert mit Wahrscheinlichkeit p (unabhängig)


Lokalität Wiederholung



- Teil des US-Straßennetzes
- Knoten mit gemeinsamen Nachbarn sind oft selbst benachbart




- Spiele von College football teams
- Kanten entsprechen community structure




- Erdős–Rényi Graph
- Jede mögliche Kante existiert mit Wahrscheinlichkeit p (unabhängig)


Lokalität Wiederholung



- Teil des US-Straßennetzes
- Knoten mit gemeinsamen Nachbarn sind oft selbst benachbart



- Spiele von College football teams
- Kanten entsprechen community structure




- Erdős–Rényi Graph
- Jede mögliche Kante existiert mit Wahrscheinlichkeit p (unabhängig)

- „Lokalität“, „Clustering“, „Geometrie“
- In vielen Echtwelt Netzwerken beobachtet (z.B. Straßen-, soziale Netzwerke)

- keine „Lokalität“
- high *“temperature”*


Local Clustering Coefficient

- Wie nah ist meiner Nachbarschaft an einer Clique dran?




Local Clustering Coefficient

- Wie nah ist meiner Nachbarschaft an einer Clique dran?
- Wie viele Kanten kann es in $N(v)$ geben?




Local Clustering Coefficient

- Wie nah ist meiner Nachbarschaft an einer Clique dran?
- Wie viele Kanten kann es in $N(v)$ geben?
 - $\binom{\deg(v)}{2}$




Local Clustering Coefficient

- Wie nah ist meiner Nachbarschaft an einer Clique dran?
- Wie viele Kanten kann es in $N(v)$ geben?
 - $\binom{\deg(v)}{2}$
- Wie viele Kanten sind tatsächlich in $N(v)$?




Local Clustering Coefficient

- Wie nah ist meiner Nachbarschaft an einer Clique dran?
- Wie viele Kanten kann es in $N(v)$ geben?
 - $\binom{\deg(v)}{2}$
- Wie viele Kanten sind tatsächlich in $N(v)$?
- Local Clustering von v : $\frac{\#edges\ in\ N(v)}{\binom{\deg(v)}{2}}$
- \Rightarrow Durchschnitt über alle Knoten bilden



Local Clustering Coefficient


- Wie nah ist meiner Nachbarschaft an einer Clique dran?
- Wie viele Kanten kann es in $N(v)$ geben?
 - $\binom{\deg(v)}{2}$
- Wie viele Kanten sind tatsächlich in $N(v)$?
- Local Clustering von v : $\frac{\#edges\ in\ N(v)}{\binom{\deg(v)}{2}}$
- \Rightarrow Durchschnitt über alle Knoten bilden



■ Was ist der erwartete Local Clustering Coefficient von Erdős–Rényi Graphen?

Local Clustering Coefficient

- Wie nah ist meiner Nachbarschaft an einer Clique dran?
- Wie viele Kanten kann es in $N(v)$ geben?
 - $\binom{\deg(v)}{2}$
- Wie viele Kanten sind tatsächlich in $N(v)$?
- Local Clustering von v : $\frac{\#edges\ in\ N(v)}{\binom{\deg(v)}{2}}$
- \Rightarrow Durchschnitt über alle Knoten bilden




■ Was ist der erwartete Local Clustering Coefficient von Erdős–Rényi Graphen?

■ Jede Kante kommt with Wahrscheinlichkeit p vor $\Rightarrow \frac{p \binom{\deg(v)}{2}}{\binom{\deg(v)}{2}} = p$




Global Clustering Coefficient

- Betrachte $\{u, v\}, \{v, w\} \in E$
- Ist dann auch $\{u, w\} \in E$?




Global Clustering Coefficient

- Betrachte $\{u, v\}, \{v, w\} \in E$
- Ist dann auch $\{u, w\} \in E$?
- Tripel: drei Knoten die mit mindestens 2 Kanten verbunden sind
 - offen: $\{u, w\} \notin E$
 - geschlossen: $\{u, w\} \in E$




Global Clustering Coefficient

- Betrachte $\{u, v\}, \{v, w\} \in E$
- Ist dann auch $\{u, w\} \in E$?
- Tripel: drei Knoten die mit mindestens 2 Kanten verbunden sind
 - offen: $\{u, w\} \notin E$
 - geschlossen: $\{u, w\} \in E$
- Global Clustering Coefficient: $\frac{\# \text{ geschlossene Tripel}}{\# \text{ Tripel gesamt}}$




Global Clustering Coefficient

- Betrachte $\{u, v\}, \{v, w\} \in E$
- Ist dann auch $\{u, w\} \in E$?
- Tripel: drei Knoten die mit mindestens 2 Kanten verbunden sind
 - offen: $\{u, w\} \notin E$
 - geschlossen: $\{u, w\} \in E$
- Global Clustering Coefficient: $\frac{\# \text{ geschlossene Tripel}}{\# \text{ Tripel gesamt}}$
- Nicht über alle Tripel aus Knoten iterieren
- Lieber über Kanten und Nachbarschaften



Global Clustering Coefficient


- Betrachte $\{u, v\}, \{v, w\} \in E$
- Ist dann auch $\{u, w\} \in E$?
- Tripel: drei Knoten die mit mindestens 2 Kanten verbunden sind
 - offen: $\{u, w\} \notin E$
 - geschlossen: $\{u, w\} \in E$
- Global Clustering Coefficient: $\frac{\# \text{ geschlossene Tripel}}{\# \text{ Tripel gesamt}}$
- Nicht über alle Tripel aus Knoten iterieren
- Lieber über Kanten und Nachbarschaften



- Was ist der erwartete Global Clustering Coefficient von Erdős–Rényi Graphen?

Global Clustering Coefficient


- Betrachte $\{u, v\}, \{v, w\} \in E$
- Ist dann auch $\{u, w\} \in E$?
- Tripel: drei Knoten die mit mindestens 2 Kanten verbunden sind
 - offen: $\{u, w\} \notin E$
 - geschlossen: $\{u, w\} \in E$
- Global Clustering Coefficient: $\frac{\# \text{ geschlossene Tripel}}{\# \text{ Tripel gesamt}}$
- Nicht über alle Tripel aus Knoten iterieren
- Lieber über Kanten und Nachbarschaften



- Was ist der erwartete Global Clustering Coefficient von Erdős–Rényi Graphen?
- Auch p aber nicht so leicht zu zeigen...


Probleme mit den Clustering Coefficients

- Was ist der Local / Global Clustering Coefficient von Grid Graphen?




Probleme mit den Clustering Coefficients

- Was ist der Local / Global Clustering Coefficient von Grid Graphen?
- Beide sind 0, weil der Graph bipartit ist
- Eigentlich hat der Graph viel *Lokalität*



Probleme mit den Clustering Coefficients

- Was ist der Local / Global Clustering Coefficient von Grid Graphen?
 - Beide sind 0, weil der Graph bipartit ist
 - Eigentlich hat der Graph viel *Lokalität*
- Was ist der Local / Global Clustering Coefficient von Wheel Graphen?




Probleme mit den Clustering Coefficients

■ Was ist der Local / Global Clustering Coefficient von Grid Graphen?

- Beide sind 0, weil der Graph bipartit ist
- Eigentlich hat der Graph viel *Lokalität*


■ Was ist der Local / Global Clustering Coefficient von Wheel Graphen?

- Local: geht gegen $2/3$ für $n \rightarrow \infty$
- Global: geht gegen 0 für $n \rightarrow \infty$




Detour Distance

- Wie groß ist der Umweg, wenn die Straße vor mir gesperrt wird?



Detour Distance


- Wie groß ist der Umweg, wenn die Straße vor mir gesperrt wird?



Detour Distance

- Wie groß ist der Umweg, wenn die Straße vor mir gesperrt wird?
- Betrachte Verhältnis zwischen Umweg und durchschnittlicher Distanz zwischen nicht Nachbarn
- Für Kante $e = \{u, v\} \in E$:


$$C(e) = 1 - \frac{d_{G \setminus e}(u, v) - 2}{\text{avg. Distance of non neighbors} - 2}$$



Detour Distance

- Wie groß ist der Umweg, wenn die Straße vor mir gesperrt wird?
- Betrachte Verhältnis zwischen Umweg und durchschnittlicher Distanz zwischen nicht Nachbarn
- Für Kante $e = \{u, v\} \in E$:

$$C(e) = 1 - \frac{d_{G \setminus e}(u, v) - 2}{\text{avg. Distance of non neighbors} - 2}$$
- $C(e) = 1 \Leftrightarrow u, v$ haben gemeinsamen Nachbarn
- Bilde Durchschnitt über alle Kanten




Detour Distance

- Wie groß ist der Umweg, wenn die Straße vor mir gesperrt wird?
- Betrachte Verhältnis zwischen Umweg und durchschnittlicher Distanz zwischen nicht Nachbarn
- Für Kante $e = \{u, v\} \in E$:

$$C(e) = 1 - \frac{d_{G \setminus e}(u, v) - 2}{\text{avg. Distance of non neighbors} - 2}$$

- $C(e) = 1 \Leftrightarrow u, v$ haben gemeinsamen Nachbarn
- Bilde Durchschnitt über alle Kanten
- Aufpassen, dass man nicht durch 0 teilt




Detour Distance

- Wie groß ist der Umweg, wenn die Straße vor mir gesperrt wird?
- Betrachte Verhältnis zwischen Umweg und durchschnittlicher Distanz zwischen nicht Nachbarn
- Für Kante $e = \{u, v\} \in E$:

$$C(e) = 1 - \frac{d_{G \setminus e}(u, v) - 2}{\text{avg. Distance of non neighbors} - 2}$$

- $C(e) = 1 \Leftrightarrow u, v$ haben gemeinsamen Nachbarn
- Bilde Durchschnitt über alle Kanten
- Aufpassen, dass man nicht durch 0 teilt
- Aufwändig zu berechnen \Rightarrow sampeln



Detour Distance

- Wie groß ist der Umweg, wenn die Straße vor mir gesperrt wird?
- Betrachte Verhältnis zwischen Umweg und durchschnittlicher Distanz zwischen nicht Nachbarn
- Für Kante $e = \{u, v\} \in E$:

$$C(e) = 1 - \frac{d_{G \setminus e}(u, v) - 2}{\text{avg. Distance of non neighbors} - 2}$$

- $C(e) = 1 \Leftrightarrow u, v$ haben gemeinsamen Nachbarn
- Bilde Durchschnitt über alle Kanten
- Aufpassen, dass man nicht durch 0 teilt
- Aufwändig zu berechnen \Rightarrow sampeln

- Was ist die Detour Distance Grid / Wheel Graphen?

