

Modelowanie i analiza sieci złożonych

III. Cechy sieci rzeczywistych i wizualizacja grafów.

Grzegorz Siudem

Politechnika Warszawska



Politechnika
Warszawska

Unia Europejska
Europejski Fundusz Społeczny



Zadanie 10 pn.

„Przygotowanie i uruchomienie nowego kierunku studiów na studiach II stopnia
- Inżynieria i Analiza Danych (IAD)”

realizowane jest w ramach projektu
„NERW PW. Nauka – Edukacja – Rozwój – Współpraca”
współfinansowanego ze środków Unii Europejskiej
w ramach Europejskiego Funduszu Społecznego


Przed zajęciami

Przypomnij sobie – stopień wierzchołka

Stopień wierzchołka (sieci nieskierowane)

Liczba krawędzi podłączonych do wierzchołka

$$k = \{1, 2, 2, 3, 2\},$$



Powtórka z probabilistyki i statystyki:

Powtórka z probabilistyki i statystyki:

- Czy rozkład prawdopodobieństwa może nie mieć wartości oczekiwanej? Wariancji?

Powtórka z probabilistyki i statystyki:

- Czy rozkład prawdopodobieństwa może nie mieć wartości oczekiwanej? Wariancji?
- Jakie są przykłady takich rozkładów?

Powtórka z probabilistyki i statystyki:

- Czy rozkład prawdopodobieństwa może nie mieć wartości oczekiwanej? Wariancji?
- Jakie są przykłady takich rozkładów?
- Co wiadomo o nośniku rozkładu, który nie ma skończonych momentów?

Powtórka z probabilistyki i statystyki:

- Czy rozkład prawdopodobieństwa może nie mieć wartości oczekiwanej? Wariancji?
- Jakie są przykłady takich rozkładów?
- Co wiadomo o nośniku rozkładu, który nie ma skończonych momentów?
- Jaką interpretację ma średnia (dobry estymator wartości oczekiwanej) gdy ta wartość oczekiwana nie istnieje? Do jakiej wartości zbiega wraz ze zwiększaniem próbki?

Wykład

Jakie są rzeczywiste sieci złożone?

Co *nie* wyróżnia sieci rzeczywistych?

Jakie są rzeczywiste sieci złożone?

Co *nie* wyróżnia sieci rzeczywistych?

- Rozmiar (małe i duże).

Jakie są rzeczywiste sieci złożone?

Co *nie* wyróżnia sieci rzeczywistych?

- Rozmiar (małe i duże).
- Planarność (por. wizualizacja).

Jakie są rzeczywiste sieci złożone?

Co *nie* wyróżnia sieci rzeczywistych?

- Rozmiar (małe i duże).
- Planarność (por. wizualizacja).
- Stopień regularności (choć dominują mniej regularne).

Jakie są rzeczywiste sieci złożone?

Co *nie* wyróżnia sieci rzeczywistych?

- Rozmiar (małe i duże).
- Planarność (por. wizualizacja).
- Stopień regularności (choć dominują mniej regularne).
- Typ grafu.

Jakie są rzeczywiste sieci złożone?

Co *nie* wyróżnia sieci rzeczywistych?

- Rozmiar (małe i duże).
- Planarność (por. wizualizacja).
- Stopień regularności (choć dominują mniej regularne).
- Typ grafu.
- ...

Przykłady?

Jakie są sieci rzeczywiste?

Co wyróżnia sieci rzeczywiste?

Jakie są sieci rzeczywiste?

Co wyróżnia sieci rzeczywiste?

- Rozkłady stopni wierzchołków o grubych ogonach

Jakie są sieci rzeczywiste?

Co wyróżnia sieci rzeczywiste?

- Rozkłady stopni wierzchołków o grubych ogonach
- Zjawisko małych światów.

Jakie są sieci rzeczywiste?

Co wyróżnia sieci rzeczywiste?

- Rozkłady stopni wierzchołków o grubych ogonach
- Zjawisko małych światów.
- Korelacje pomiędzy wierzchołkami.

Jakie są sieci rzeczywiste?

Co wyróżnia sieci rzeczywiste?

- Rozkłady stopni wierzchołków o grubych ogonach
- Zjawisko małych światów.
- Korelacje pomiędzy wierzchołkami.
- Obecność hierarchii (często).

Jakie są sieci rzeczywiste?

Co wyróżnia sieci rzeczywiste?

- Rozkłady stopni wierzchołków o grubych ogonach
- Zjawisko małych światów.
- Korelacje pomiędzy wierzchołkami.
- Obecność hierarchii (często).
- Samopodobieństwo (czasami).

Jakie są sieci rzeczywiste?

Co wyróżnia sieci rzeczywiste?

- Rozkłady stopni wierzchołków o grubych ogonach
- Zjawisko małych światów.
- Korelacje pomiędzy wierzchołkami.
- Obecność hierarchii (często).
- Samopodobieństwo (czasami).

Uwaga!

Powyższe obserwacje są wynikami empirycznymi, a nie matematycznymi. Nie jest tak, **każda** sieć złożona posiada **każdą** z powyższych cech.

Co to są grube ogony?

Przypomnienie z probabilistyki

$$\mathbb{E}X^p = \int_{-\infty}^{\infty} x^p f(x) dx = \infty^*$$

analogicznie dla rozkładów dyskretnych

$$\mathbb{E}X^p = \sum_{k=0}^{\infty} k^p P(k) = \infty^*$$

Przypomnienie z probabilistyki

$$\mathbb{E}X^p = \int_{-\infty}^{\infty} x^p f(x) dx = \infty^*$$

analogicznie dla rozkładów dyskretnych

$$\mathbb{E}X^p = \sum_{k=0}^{\infty} k^p P(k) = \infty^*$$

Uwaga!

Warunkiem koniecznym rozbiegania całek jest nieograniczony nośnik gęstości (funkcji masy p-stwa).

Co to są grube ogony?

Przypomnienie z probabilistyki

$$\mathbb{E}X^p = \int_{-\infty}^{\infty} x^p f(x) dx = \infty^*$$

analogicznie dla rozkładów dyskretnych

$$\mathbb{E}X^p = \sum_{k=0}^{\infty} k^p P(k) = \infty^*$$

Uwaga!

Warunkiem koniecznym rozbiegania całek jest nieograniczony nośnik gęstości (funkcji masy p-stwa).

Co jednak z sieciami rzeczywistymi?

Skończone czy nieskończone?

Jak sobie poradzić z tym problemem?

Typowo uznajemy, że rozkład stopni wierzchołków ma gruby ogon, jeśli odpowiednie całki (sumy) rozbiegają w granicy $N \rightarrow \infty$.

Jak sobie poradzić z tym problemem?

Typowo uznajemy, że rozkład stopni wierzchołków ma gruby ogon, jeśli odpowiednie całki (sumy) rozbiegają w granicy $N \rightarrow \infty$.

Przecież to niezgodne z matematyką! :(

Jak sobie poradzić z tym problemem?

Typowo uznajemy, że rozkład stopni wierzchołków ma gruby ogon, jeśli odpowiednie całki (sumy) rozbiegają w granicy $N \rightarrow \infty$.

Przecież to niezgodne z matematyką! :(

Zła wiadomość:

Takim stopniem precyzji cechuje się prawie cała sieciologia.

Jak sobie poradzić z tym problemem?

Typowo uznajemy, że rozkład stopni wierzchołków ma gruby ogon, jeśli odpowiednie całki (sumy) rozbiegają w granicy $N \rightarrow \infty$.

Przecież to niezgodne z matematyką! :(

Zła wiadomość:

Takim stopniem precyzji cechuje się prawie cała sieciologia.

Dobra wiadomość:

Jest to bardzo skuteczne podejście.

Jak sobie poradzić z tym problemem?

Typowo uznajemy, że rozkład stopni wierzchołków ma gruby ogon, jeśli odpowiednie całki (sumy) rozbiegają w granicy $N \rightarrow \infty$.

Przecież to niezgodne z matematyką! :(

Zła wiadomość:


Takim stopniem precyzji cechuje się prawie cała sieciologia.

Dobra wiadomość:

Jest to bardzo skuteczne podejście.


Bardziej matematyczno-precyzyjni będziemy na Wykładzie 7.

Czym skutkują grube ogony?



Źródło: wikipednia

Czym skutkują grube ogony?




Źródło: wikipedia

Reguła Pareto (80/20)

Jaka część zasobów należy do jakiej części populacji?

Czym skutkują grube ogony?



Źródło: wikipednia

Reguła Pareto (80/20)





Jaka część zasobów należy do jakiej części populacji?

Czy to prawda dla dowolnych rozkładów?

Sprawdzimy podczas projektu!

Dlaczego sieci potęgowe są bezskalne?

Uzasadnienie empiryczne



Dlaczego sieci potęgowe są bezskalowe?

Uzasadnienie empiryczne

Zajmiemy się nim w trakcie części projekt!

Dlaczego sieci potęgowe są bezskalne?

Uzasadnienie matematyczne

Rozkładami o grubych ogonach nazywamy takie, dla których nie istnieje wartość oczekiwana lub któryś z wyższych momentów.

$$\mathbb{E}X^k = \int f(x)x^k dx = \infty^*$$

Dlaczego sieci potęgowe są bezskalne?

Uzasadnienie matematyczne

Rozkładami o grubych ogonach nazywamy takie, dla których nie istnieje wartość oczekiwana lub któryś z wyższych momentów.

$$\mathbb{E}X^k = \int f(x)x^k dx = \infty^*$$

Założmy, że nie istnieje drugi moment

$$\mathbb{E}X^2 = \infty,$$

a zatem

$$\mathbb{E}[X - \mathbb{E}X]^2 = \infty,$$

Dlaczego sieci potęgowe są bezskalne?

Uzasadnienie matematyczne

Rozkładami o grubych ogonach nazywamy takie, dla których nie istnieje wartość oczekiwana lub któryś z wyższych momentów.

$$\mathbb{E}X^k = \int f(x)x^k dx = \infty^*$$

Założmy, że nie istnieje drugi moment

$$\mathbb{E}X^2 = \infty,$$


a zatem

$$\mathbb{E}[X - \mathbb{E}X]^2 = \infty,$$

Zatem nie mamy skali!

A jak to interpretować w przypadku skończonym?

Sieci o rozkładach potęgowych



Albowiem wszelkiemu mającemu będzie dano, i obfitować będzie, a temu, który nie ma, i to, co się zda mieć, będzie wzięto od niego.

Mt 25:29.

Albowiem wszelkiemu mającemu będzie dano, i obfitować będzie, a temu, który nie ma, i to, co się zda mieć, będzie wzięto od niego.

Mt 25:29.

- Reguła św. Mateusza,

Albowiem wszelkiemu mającemu będzie dano, i obfitować będzie, a temu, który nie ma, i to, co się zda mieć, będzie wzięto od niego.

Mt 25:29.

- Reguła św. Mateusza,
- *rich get richer rule*,

Albowiem wszelkiemu mającemu będzie dano, i obfitować będzie, a temu, który nie ma, i to, co się zda mieć, będzie wzięto od niego.

Mt 25:29.

- Reguła św. Mateusza,
- *rich get richer rule*,
- magnetyzm sławy,

Albowiem wszelkiemu mającemu będzie dano, i obfitować będzie, a temu, który nie ma, i to, co się zda mieć, będzie wzięto od niego.

Mt 25:29.

- Reguła św. Mateusza,
- *rich get richer rule*,
- magnetyzm sławy,
- reguła preferencyjnego dołączania,

Albowiem wszelkiemu mającemu będzie dano, i obfitować będzie, a temu, który nie ma, i to, co się zda mieć, będzie wzięto od niego.

Mt 25:29.

- Reguła św. Mateusza,
- *rich get richer rule*,
- magnetyzm sławy,
- reguła preferencyjnego dołączania,
- zasada pieniądź robi pieniądź,

Albowiem wszelkiemu mającemu będzie dano, i obfitować będzie, a temu, który nie ma, i to, co się zda mieć, będzie wzięto od niego.

Mt 25:29.

- Reguła św. Mateusza,
- *rich get richer rule*,
- magnetyzm sławy,
- reguła preferencyjnego dołączania,
- zasada pieniądź robi pieniądź,
- ...

M. Perc, J. R. Soc. Interface, **11**, (2014).

Pytanie:

Należy rozstrzygnąć (udowodnić lub znaleźć kontrprzykład) czy rozkład stopni wierzchołków jednoznacznie charakteryzuje sieć/graf.

Czym mogą różnić się sieci o tym samym rozkładzie?

Asortatywność vs dysasortatywność

$$\mathcal{P}(k_i|k_j) = \frac{NP(k_i, k_j)}{k_j \mathcal{P}(k_j) / \langle k \rangle}$$

Asortatywność vs dysasortatywność

$$\mathcal{P}(k_i|k_j) = \frac{N\mathcal{P}(k_i, k_j)}{k_j\mathcal{P}(k_j)/\langle k \rangle}$$

- Sieć dysasortatywna to taka, gdzie prawdopodobieństwo połączenia węzłów o bardzo różnym stopniu jest duże.

Czym mogą różnić się sieci o tym samym rozkładzie?

Asortatywność vs dysasortatywność

$$\mathcal{P}(k_i|k_j) = \frac{N\mathcal{P}(k_i, k_j)}{k_j\mathcal{P}(k_j)/\langle k \rangle}$$

- Sieć dysasortatywna to taka, gdzie prawdopodobieństwo połączenia węzłów o bardzo różnym stopniu jest duże.
- Sieć asortatywna to taka, gdzie prawdopodobieństwo połączenia węzłów o zbliżonym stopniu jest duże

Pytanie

Jakie są przykłady rzeczywiste takich sieci?

Czym mogą różnić się sieci o tym samym rozkładzie?

Korelacje

$\mathcal{P}(k_i, k_j)$ - prawdopodobieństwo, że losowo wybrana krawędź łączy węzły o stopniach k_i i k_j

$$\mathcal{R}(k_i, k_j) = \frac{\mathcal{P}(k_i, k_j)}{\mathcal{P}_u(k_i, k_j)},$$

a \mathcal{P}_u odpowiada sieci nieskorelowanej o tym samym rozkładzie

Wyprowadzenie \mathcal{P}_u

Czym mogą różnić się sieci o tym samym rozkładzie?

Korelacje

$\mathcal{P}(k_i, k_j)$ - prawdopodobieństwo, że losowo wybrana krawędź łączy węzły o stopniach k_i i k_j

$$\mathcal{R}(k_i, k_j) = \frac{\mathcal{P}(k_i, k_j)}{\mathcal{P}_u(k_i, k_j)},$$

a \mathcal{P}_u odpowiada sieci nieskorelowanej o tym samym rozkładzie

Wyprowadzenie \mathcal{P}_u

- Losowe przetaczanie – ilustracja.

Czym mogą różnić się sieci o tym samym rozkładzie?

Korelacje

$\mathcal{P}(k_i, k_j)$ - prawdopodobieństwo, że losowo wybrana krawędź łączy węzły o stopniach k_i i k_j

$$\mathcal{R}(k_i, k_j) = \frac{\mathcal{P}(k_i, k_j)}{\mathcal{P}_u(k_i, k_j)},$$

a \mathcal{P}_u odpowiada sieci nieskorelowanej o tym samym rozkładzie

Wyprowadzenie \mathcal{P}_u

- Losowe przetaczanie – ilustracja.

- $\mathcal{P}_u(k_i, k_j) = \frac{k_i k_j \mathcal{P}(k_i) \mathcal{P}(k_j)}{\langle k \rangle^2}$

Przypomnijmy:

Ile uścisków dłoni dzieli dwóch dowolnych mieszkańców Ziemi?
(eksperyment Milgrama)

Przypomnijmy:

Ile uścisków dłoni dzieli dwóch dowolnych mieszkańców Ziemi?
(eksperyment Milgrama)

Jak zmierzyć małość świata?

$$\ell = \frac{1}{N(N-1)} \sum_{i \neq j} d(i, j)$$

Ile wynosi średnia droga w wybranych modelach sieci?

Przypomnijmy:

Ile uścisków dłoni dzieli dwóch dowolnych mieszkańców Ziemi?
(eksperyment Milgrama)

Jak zmierzyć małość świata?

$$\ell = \frac{1}{N(N-1)} \sum_{i \neq j} d(i, j)$$

Ile wynosi średnia droga w wybranych modelach sieci?

- dla grafów przypadkowych $\ell \sim \frac{\ln N}{\ln \langle k \rangle}$,

Przypomnijmy:

Ile uścisków dłoni dzieli dwóch dowolnych mieszkańców Ziemi?
(eksperyment Milgrama)

Jak zmierzyć małość świata?

$$\ell = \frac{1}{N(N-1)} \sum_{i \neq j} d(i, j)$$

Ile wynosi średnia droga w wybranych modelach sieci?

- dla grafów przypadkowych $\ell \sim \frac{\ln N}{\ln \langle k \rangle}$,
- dla siatki kwadratowej $\ell \sim \sqrt{N}$,

Przypomnijmy:

Ile uścisków dłoni dzieli dwóch dowolnych mieszkańców Ziemi?
(eksperyment Milgrama)

Jak zmierzyć małość świata?

$$\ell = \frac{1}{N(N-1)} \sum_{i \neq j} d(i, j)$$

Ile wynosi średnia droga w wybranych modelach sieci?

- dla grafów przypadkowych $\ell \sim \frac{\ln N}{\ln \langle k \rangle}$,
- dla siatki kwadratowej $\ell \sim \sqrt{N}$,
- dla sieci bezskalowych z $\alpha = 3$ $\ell \sim \frac{\ln N}{\ln \ln N}$,

Przypomnijmy:

Ile uścisków dłoni dzieli dwóch dowolnych mieszkańców Ziemi?
(eksperyment Milgrama)

Jak zmierzyć małość świata?

$$\ell = \frac{1}{N(N-1)} \sum_{i \neq j} d(i, j)$$

Ile wynosi średnia droga w wybranych modelach sieci?

- dla grafów przypadkowych $\ell \sim \frac{\ln N}{\ln \langle k \rangle}$,
- dla siatki kwadratowej $\ell \sim \sqrt{N}$,
- dla sieci bezskalowych z $\alpha = 3$ $\ell \sim \frac{\ln N}{\ln \ln N}$,
- dla sieci bezskalowych z $\alpha \in (2, 3)$ $\ell \sim \ln \ln N$.

- fraktalne sieci dystrybucyjne,

- fraktalne sieci dystrybucyjne,
- sieci hierarchiczne,

- fraktalne sieci dystrybucyjne,
- sieci hierarchiczne,
- sieci ze strukturą społeczną.

Pytanie:

Znajdź rzeczywisty przykład powyższych sieci.

Cechy dobrej wizualizacji:

Cechy dobrej wizualizacji:

- odpowiednia odległość pomiędzy wierzchołkami,

Cechy dobrej wizualizacji:

- odpowiednia odległość pomiędzy wierzchołkami,
- odpowiednie kąty pomiędzy krawędziami,

Cechy dobrej wizualizacji:

- odpowiednia odległość pomiędzy wierzchołkami,
- odpowiednie kąty pomiędzy krawędziami,
- minimalna liczba przecięć,

Cechy dobrej wizualizacji:

- odpowiednia odległość pomiędzy wierzchołkami,
- odpowiednie kąty pomiędzy krawędziami,
- minimalna liczba przecięć,
- symetrie!

Cechy dobrej wizualizacji:

- odpowiednia odległość pomiędzy wierzchołkami,
- odpowiednie kąty pomiędzy krawędziami,
- minimalna liczba przecięć,
- symetrie!
- jest *przyjemna dla oka*.

Uwaga

Optymalizacja powyższych cech (zwłaszcza ostatniej!) jest wymagająca algorytmicznie.

Cechy dobrej wizualizacji:

- odpowiednia odległość pomiędzy wierzchołkami,
- odpowiednie kąty pomiędzy krawędziami,
- minimalna liczba przecięć,
- symetrie!
- jest *przyjemna dla oka*.

Uwaga

Optymalizacja powyższych cech (zwłaszcza ostatniej!) jest wymagająca algorytmicznie.

Wniosek:

Wizualizacja to w dużej mierze sztuka... lub wykorzystanie gotowych narzędzi.

Dla fanów R-a

<http://kateto.net/network-visualization>

Podsumowanie

Na następne zajęcia:

Przeczytaj

- M.E.J. Newman, *Power laws, Pareto distributions and Zipf's law*, Contemporary Physics, **46**, 323-351 (2005).
i/lub item rozdziały 3.1-3.3 w A. Fronczak, P. Fronczak, *Świat sieci złożonych* PWN (2009).

Przeczytaj

Pobierz i przygotuj się do analizy wybranych danych o potęgowym rozkładzie.

Dziękuję za uwagę!



Fundusze Europejskie
Wiedza Edukacja Rozwój

**Politechnika
Warszawska**

Unia Europejska
Europejski Fundusz Społeczny



Zadanie 10 pn.

„Przygotowanie i uruchomienie nowego kierunku studiów na studiach II stopnia
- Inżynieria i Analiza Danych (IAD)”

realizowane jest w ramach projektu
„NERW PW. Nauka – Edukacja – Rozwój – Współpraca”
współfinansowanego ze środków Unii Europejskiej
w ramach Europejskiego Funduszu Społecznego