


Metoda Monte Carlo

czyli od próbkowania do wyników

Metody Probabilistyczne Informatyki 2023/24

Uniwersytet Jagielloński, TCS

Jędrzej Hodor, Piotr Micek



$\pi = 3,141592653589\dots$

$$\pi = 3,141592653589\dots$$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

$$\pi = 3,141592653589\dots$$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.


Spróbujmy zatem przybliżyć!

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2




$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2




$X, Y \sim \text{Uni}[-1, 1]$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2




$X, Y \sim \text{Uni}[-1, 1]$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$


$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$


$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$


$$E(Z) = \frac{\pi}{4}$$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)


$$Z_1, Z_2, \dots, Z_m$$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$


$$W = \sum_{i=1}^m Z_i$$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$


$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$$\pi = 3,141592653589\dots$$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$


$$W' = \frac{4}{m}W \text{ to naturalne oszacowanie na } \pi$$

$$\pi = 3,141592653589\dots$$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$W' = \frac{4}{m}W$ to naturalne oszacowanie na π


Z Chernoffa mamy: $P(|W' - \pi| \geq \varepsilon\pi) \leq 2e^{-m\pi\varepsilon^2/12}$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$W' = \frac{4}{m}W$ to naturalne oszacowanie na π

Z Chernoffa mamy: $P(|W' - \pi| \geq \varepsilon\pi) \leq 2e^{-m\pi\varepsilon^2/12}$


Definicja:

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$W' = \frac{4}{m}W$ to naturalne oszacowanie na π

Z Chernoffa mamy: $P(|W' - \pi| \geq \varepsilon\pi) \leq 2e^{-m\pi\varepsilon^2/12}$

Definicja:

Zmienna losowa X (randomizowany algorytm)


daje (ε, δ) -aproxymacje wartości V jeśli:

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$W' = \frac{4}{m}W$ to naturalne oszacowanie na π

Z Chernoffa mamy: $P(|W' - \pi| \geq \varepsilon\pi) \leq 2e^{-m\pi\varepsilon^2/12}$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:


$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$W' = \frac{4}{m}W$ to naturalne oszacowanie na π

Z Chernoffa mamy: $P(|W' - \pi| \geq \varepsilon\pi) \leq 2e^{-m\pi\varepsilon^2/12}$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Czyli, żeby otrzymać (ε, δ) aproxymacje wartości π dla pewnych ε, δ musimy zapewnić, że


$$2e^{-m\pi\varepsilon^2/12} \leq \delta$$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$W' = \frac{4}{m}W$ to naturalne oszacowanie na π

Z Chernoffa mamy: $P(|W' - \pi| \geq \varepsilon\pi) \leq 2e^{-m\pi\varepsilon^2/12}$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Czyli, żeby otrzymać (ε, δ) aproxymacje wartości π dla pewnych ε, δ musimy zapewnić, że

$$2e^{-m\pi\varepsilon^2/12} \leq \delta$$


Innymi słowy trzeba wykonać dużo powtórzeń

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$W' = \frac{4}{m}W$ to naturalne oszacowanie na π

Z Chernoffa mamy: $P(|W' - \pi| \geq \varepsilon\pi) \leq 2e^{-m\pi\varepsilon^2/12}$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Czyli, żeby otrzymać (ε, δ) aproxymacje wartości π dla pewnych ε, δ musimy zapewnić, że

$$2e^{-m\pi\varepsilon^2/12} \leq \delta$$

Innymi słowy trzeba wykonać dużo powtórzeń

Dokładniej, potrzebujemy


$$m \geq \frac{12\ln(2/\delta)}{\pi\varepsilon^2}$$

$\pi = 3,141592653589\dots$

Liczba niewymierna \rightarrow nie da się dokładnie obliczyć.

Spróbujmy zatem przybliżyć!

Losujemy punkt w kwadracie 2×2



$$X, Y \sim \text{Uni}[-1, 1]$$

$$Z = [\sqrt{X^2 + Y^2} \leq 1]$$

$$P(Z = 1) = \frac{\text{pole koła}}{\text{pole kwadratu}} = \frac{\pi}{4}$$

$$E(Z) = \frac{\pi}{4}$$

Powtórzmy eksperyment wiele razy (m razy)

$$Z_1, Z_2, \dots, Z_m$$

$$W = \sum_{i=1}^m Z_i$$

$$E(W) = \sum_{i=1}^m E(Z_i) = \frac{m\pi}{4}$$

$W' = \frac{4}{m}W$ to naturalne oszacowanie na π

Z Chernoffa mamy: $P(|W' - \pi| \geq \varepsilon\pi) \leq 2e^{-m\pi\varepsilon^2/12}$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Czyli, żeby otrzymać (ε, δ) aproxymacje wartości π dla pewnych ε, δ musimy zapewnić, że

$$2e^{-m\pi\varepsilon^2/12} \leq \delta$$

Innymi słowy trzeba wykonać dużo powtórzeń

Dokładniej, potrzebujemy

$$m \geq \frac{12\ln(2/\delta)}{\pi\varepsilon^2}$$

Aby otrzymać k miejsc po przecinku π z pewnością 95% trzeba powtórzyć eksperyment mniej więcej $15 \cdot 10^{2k}$ razy.

Twierdzenie 11.1 (Chernoff):

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ϵ, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \epsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ϵ, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \epsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

a *fully polynomial randomized approximation scheme* (FPRAS)

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS) jeśli dla wejścia x i parametrów ε, δ

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aprosymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aprosymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aprosymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aprosymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aprosymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ε, δ

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ε, δ

1. projektujemy zmienną losową X , że $E(X) = R(x)$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ε, δ

1. projektujemy zmienną losową X , że $E(X) = R(x)$
2. powtarzamy wiele razy: X_1, \dots, X_m

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ε, δ

1. projektujemy zmienną losową X , że $E(X) = R(x)$
2. powtarzamy wiele razy: X_1, \dots, X_m
3. tak wiele, aby Tw. dało (ε, δ) -aproxymacje

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3\ln(2/\delta)/\mu\varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon\mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ε, δ

1. projektujemy zmienną losową X , że $E(X) = R(x)$
2. powtarzamy wiele razy: X_1, \dots, X_m
3. tak wiele, aby Tw. dało (ε, δ) -aproxymacje
czyli $m \geq 3\ln(2/\delta)/R(x)\varepsilon^2$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ε, δ

1. projektujemy zmienną losową X , że $E(X) = R(x)$
2. powtarzamy wiele razy: X_1, \dots, X_m
3. tak wiele, aby Tw. dało (ε, δ) -aproxymacje
czyli $m \geq 3 \ln(2/\delta) / R(x) \varepsilon^2$
na pewno wielomianowe od $1/\varepsilon$ i $\ln(1/\delta)$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3\ln(2/\delta)/\mu\epsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ϵ, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \epsilon\mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ϵ, δ

umiemy generować (ϵ, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\epsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\epsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\epsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ϵ, δ

1. projektujemy zmienną losową X , że $E(X) = R(x)$
2. powtarzamy wiele razy: X_1, \dots, X_m
3. tak wiele, aby Tw. dało (ϵ, δ) -aproxymacje
czyli $m \geq 3\ln(2/\delta)/R(x)\epsilon^2$
na pewno wielomianowe od $1/\epsilon$ i $\ln(1/\delta)$
4. czy $1/R(x)$ jest wielomianowe od $|x|$?

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ϵ, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \epsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3\ln(2/\delta)/\mu\epsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ϵ, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \epsilon\mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ϵ, δ

umiemy generować (ϵ, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\epsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\epsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\epsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ϵ, δ

1. projektujemy zmienną losową X , że $E(X) = R(x)$
2. powtarzamy wiele razy: X_1, \dots, X_m
3. tak wiele, aby Tw. dało (ϵ, δ) -aproxymacje
czyli $m \geq 3\ln(2/\delta)/R(x)\epsilon^2$
na pewno wielomianowe od $1/\epsilon$ i $\ln(1/\delta)$
4. czy $1/R(x)$ jest wielomianowe od $|x|$?
5. zwracamy aproxymacje: $\frac{1}{m} \sum_{i=1}^m X_i \sim R(x)$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ϵ, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \epsilon V) \geq 1 - \delta$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

to $\frac{1}{m} \sum_{i=1}^m X_i$ daje (ε, δ) -aproxymacje dla μ .

Innymi słowy $P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta$.

Trudne problemy obliczeniowe

Definicja:

Mając dany problem obliczeniowy $x \rightarrow R(x)$, mówimy, że mamy a *fully polynomial randomized approximation scheme* (FPRAS)

jeśli dla wejścia x i parametrów ε, δ

umiemy generować (ε, δ) -aproxymacje $R(x)$

w czasie wielomianowym od $|x|, 1/\varepsilon, \ln(1/\delta)$.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $R(x)$

Uwaga: równoważnie wystarczy $(\varepsilon, 1/4)$ -aproxymacja

Metoda Monte Carlo

problem $x \rightarrow R(x)$

chemy FPRAS

dane: x, ε, δ

przykłady...

1. projektujemy zmienną losową X , że $E(X) = R(x)$
2. powtarzamy wiele razy: X_1, \dots, X_m
3. tak wiele, aby Tw. dało (ε, δ) -aproxymacje
czyli $m \geq 3 \ln(2/\delta) / R(x) \varepsilon^2$
na pewno wielomianowe od $1/\varepsilon$ i $\ln(1/\delta)$
4. czy $1/R(x)$ jest wielomianowe od $|x|$?
5. zwracamy aproxymacje: $\frac{1}{m} \sum_{i=1}^m X_i \sim R(x)$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underline{(x_1 \wedge \bar{x}_2 \wedge x_3)} \vee (\bar{x}_1 \wedge \underline{x_3}) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underline{(x_1 \wedge \bar{x}_2 \wedge x_3)} \vee (\bar{x}_1 \wedge \underline{x_3}) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underbrace{(x_1 \wedge \bar{x}_2 \wedge x_3)}_{\text{klauzula}} \vee \underbrace{(\bar{x}_1 \wedge x_3)}_{\text{literal}} \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge \underline{x_3}) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie:

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underline{(x_1 \wedge \bar{x}_2 \wedge x_3)} \vee (\bar{x}_1 \wedge \underline{x_3}) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

dlatego szukamy aproksymacji.

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underbrace{(x_1 \wedge \bar{x}_2 \wedge x_3)}_{\text{klauzula}} \vee \underbrace{(\bar{x}_1 \wedge x_3)}_{\text{literal}} \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje P=NP)

dlatego szukamy aproksymacji.

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underline{(x_1 \wedge \bar{x}_2 \wedge x_3)} \vee (\bar{x}_1 \wedge \underline{x_3}) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underline{(x_1 \wedge \bar{x}_2 \wedge x_3)} \vee (\bar{x}_1 \wedge \underline{x_3}) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underline{(x_1 \wedge \bar{x}_2 \wedge x_3)} \vee (\bar{x}_1 \wedge \underline{x_3}) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underline{(x_1 \wedge \bar{x}_2 \wedge x_3)} \vee (\bar{x}_1 \wedge \underline{x_3}) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underbrace{(x_1 \wedge \bar{x}_2 \wedge x_3)}_{\text{klauzula}} \vee \underbrace{(\bar{x}_1 \wedge x_3)}_{\text{literal}} \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underbrace{(x_1 \wedge \bar{x}_2 \wedge x_3)}_{\text{klauzula}} \vee \underbrace{(\bar{x}_1 \wedge x_3)}_{\text{literal}} \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underbrace{(x_1 \wedge \bar{x}_2 \wedge x_3)}_{\text{klauzula}} \vee \underbrace{(\bar{x}_1 \wedge x_3)}_{\text{literal}} \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$\underbrace{(x_1 \wedge \bar{x}_2 \wedge x_3)}_{\text{klauzula}} \vee \underbrace{(\bar{x}_1 \wedge x_3)}_{\text{literal}} \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

X = [wartościowanie spełnia F]

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

X = [wartościowanie spełnia F]

$$E(X) = P(X = 1) = \frac{C(F)}{2^n} = R(F)$$

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

X = [wartościowanie spełnia F]

$$E(X) = P(X = 1) = \frac{C(F)}{2^n} = R(F)$$

2. powtarzamy wiele razy: X_1, \dots, X_m

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

X = [wartościowanie spełnia F]

$$E(X) = P(X = 1) = \frac{C(F)}{2^n} = R(F)$$

2. powtarzamy wiele razy: X_1, \dots, X_m

3. tak wiele, aby Tw. dało (ε, δ) -aproksymację

czyli $m \geq 3 \ln(2/\delta) / R(F) \varepsilon^2$

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

X = [wartościowanie spełnia F]

$$E(X) = P(X = 1) = \frac{C(F)}{2^n} = R(F)$$

2. powtarzamy wiele razy: X_1, \dots, X_m

3. tak wiele, aby Tw. dało (ε, δ) -aproksymacje

czyli $m \geq 3 \ln(2/\delta) / R(F) \varepsilon^2$

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n$?

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

X = [wartościowanie spełnia F]

$$E(X) = P(X = 1) = \frac{C(F)}{2^n} = R(F)$$

2. powtarzamy wiele razy: X_1, \dots, X_m

3. tak wiele, aby Tw. dało (ε, δ) -aproksymacje

czyli $m \geq 3 \ln(2/\delta) / R(F) \varepsilon^2$

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n$?

$$1/R(F) = 2^n / C(F)$$

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

X = [wartościowanie spełnia F]

$$E(X) = P(X = 1) = \frac{C(F)}{2^n} = R(F)$$

2. powtarzamy wiele razy: X_1, \dots, X_m

3. tak wiele, aby Tw. dało (ε, δ) -aproksymacje

czyli $m \geq 3 \ln(2/\delta) / R(F) \varepsilon^2$

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n$?

$$1/R(F) = 2^n / C(F)$$

Jeśli $C(F) = 2^n / \text{poly}(n)$ to jest **dobrze**.

The DNF Counting Problem

Zliczanie wartościowań spełniających formuły boolowskie

DNF = disjunctive normal form

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (\bar{x}_1 \wedge x_3) \vee (\bar{x}_1 \wedge \bar{x}_2 \wedge x_4 \wedge x_5)$$

klauzula

literal

Bardzo łatwo sprawdzić, czy spełnialna:

Czy istnieje klauzula bez $\dots x \wedge \bar{x} \dots$?

Pytanie: Ile jest wartościowań spełniających?

Jest to problem **trudny**

(istnienie wielomianowego algorytmu implikuje $P=NP$)

(prosta redukcja z SAT)

dlatego szukamy aproksymacji.

Podejście naiwne:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$C(F)$ = liczba spełniających wartościowań

$$R(F) = \frac{C(F)}{2^n}$$

1. losujemy wartościowanie n zmiennych jednostajnie

X = [wartościowanie spełnia F]

$$E(X) = P(X = 1) = \frac{C(F)}{2^n} = R(F)$$

2. powtarzamy wiele razy: X_1, \dots, X_m

3. tak wiele, aby Tw. dało (ε, δ) -aproksymacje

czyli $m \geq 3 \ln(2/\delta) / R(F) \varepsilon^2$

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n$?

$$1/R(F) = 2^n / C(F)$$

Jeśli $C(F) = 2^n / \text{poly}(n)$ to jest **dobrze**.

Jeśli $C(F)$ jest mniejsze

(np. $C(F) \sim \text{poly}(n)$) to mamy **problem**.

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

Podójście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

$$X = [a \in RC_i]$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

$X = [a \in RC_i]$ – łatwo sprawdzić

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

$X = [a \in RC_i]$ – łatwo sprawdzić

Jednostajnie??

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

$X = [a \in RC_i]$ – łatwo sprawdzić

Jednostajnie??

Niech $(a, i) \in S$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

$X = [a \in RC_i]$ – łatwo sprawdzić

Jednostajnie??

Niech $(a, i) \in S$

$P(\text{wybrano } (a, i))$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

$X = [a \in RC_i]$ – łatwo sprawdzić

Jednostajnie??

Niech $(a, i) \in S$

$P(\text{wybrano } (a, i))$

$$= P(\text{wybrano } i)P(\text{wybrano } a \mid \text{wybrano } i)$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

$$X = [a \in RC_i] - \text{łatwo sprawdzić}$$

Jednostajnie??

Niech $(a, i) \in S$

$P(\text{wybrano } (a, i))$

$$= P(\text{wybrano } i)P(\text{wybrano } a \mid \text{wybrano } i)$$

$$= \frac{|SC_i|}{|S|} \frac{1}{|SC_i|} = \frac{1}{|S|}$$

Podejście lepsze:

dane: F -formuła DNF, ε, δ

n = liczba zmiennych w F

$$F = C_1 \vee C_2 \vee \dots \vee C_t$$

F prawdziwe $\Leftrightarrow \exists_i C_i$ prawdziwe

Zakładamy, że w klauzulach nie ma $\dots x \wedge \bar{x} \dots$

C_i ma ℓ_i literalów (czyli ℓ_i zmiennych)

dokładnie $2^{n-\ell_i}$ wartościowań spełnia C_i

SC_i = wartościowania spełniające C_i

$$S = \{(i, a) \mid i \in [t], a \in SC_i\}$$

$$|S| = \sum_{i=1}^t |SC_i| = \sum_{i=1}^t 2^{n-\ell_i}$$

$$C(F) = \text{liczba sp. wart.} = |\bigcup_{i=1}^t SC_i|$$

$$!!C(F) \leq |S|!!$$

$$RC_i = SC_i \setminus \bigcup_{j=1}^{i-1} SC_j$$

$$R = \{(i, a) \mid i \in [t], a \in RC_i\}$$

$$C(F) = |R|$$

$$R(F) = \frac{C(F)}{|S|} = \frac{|R|}{|S|}$$

1. losujemy jednostajnie element (a, i) z S

$$X = [(a, i) \in R]$$

JAK?

$$E(X) = P(X = 1) = \frac{|R|}{|S|} = R(F)$$

2. ... 3. ...

4. czy $1/R(F)$ jest wielomianowe od $|F| \sim n, t$?

$$1/R(F) = |S|/|R| \leq t$$

Z prawdopodobieństwem $\frac{|SC_i|}{|S|}$ wybierz $i \in [t]$

dla wylosowanego i

wybierz jednostajnie wartościowanie a z SC_i

$$X = [a \in RC_i] \text{ – łatwo sprawdzić}$$

Jednostajnie??

Niech $(a, i) \in S$

$P(\text{wybrano } (a, i))$

$$= P(\text{wybrano } i)P(\text{wybrano } a \mid \text{wybrano } i)$$

$$= \frac{|SC_i|}{|S|} \frac{1}{|SC_i|} = \frac{1}{|S|}$$

Dostaliśmy FPRAS dla DNF Counting!

Moc próbkowania

Definicja:

Moc próbkowania

Definicja:

daje ε -jednostajną próbkę Ω jeśli

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:

U jednostajny

$$\|\mathbb{P}_X - U\|_{TV} \leq \varepsilon$$

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|\mathbb{P}_X - U\|_{TV} \leq \varepsilon$

Definicja:

a *fully polynomial almost uniform sampler* (FPAUS)

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:

U jednostajny

$$\|\mathbb{P}_X - U\|_{TV} \leq \varepsilon$$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:

U jednostajny

$$\|\mathbb{P}_X - U\|_{TV} \leq \varepsilon$$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|\mathbb{P}_X - U\|_{TV} \leq \varepsilon$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|\mathbb{P}_X - U\|_{TV} \leq \varepsilon$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

w czasie wielomianowym od $|x|, \ln(1/\varepsilon)$.

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|\mathbb{P}_X - U\|_{TV} \leq \varepsilon$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

w czasie wielomianowym od $|x|, \ln(1/\varepsilon)$.

$x \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(x)$

Moc próbkowania

Sampling \rightarrow Counting

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|P_X - U\|_{TV} \leq \varepsilon$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

w czasie wielomianowym od $|x|, \ln(1/\varepsilon)$.

$x \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(x)$

Moc próbkowania

Sampling \rightarrow Counting

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|P_X - U\|_{TV} \leq \varepsilon$

Wejście: graf G

Pytanie: Ile jest zbiorów niezależnych w G ?

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

w czasie wielomianowym od $|x|, \ln(1/\varepsilon)$.

$x \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(x)$

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|P_X - U\|_{TV} \leq \varepsilon$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

w czasie wielomianowym od $|x|, \ln(1/\varepsilon)$.

$x \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(x)$

Sampling \rightarrow Counting

Wejście: graf G

Pytanie: Ile jest zbiorów niezależnych w G ?

$\Omega(G)$ = zbiory niezależnych w G

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|P_X - U\|_{TV} \leq \varepsilon$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

w czasie wielomianowym od $|x|, \ln(1/\varepsilon)$.

$x \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(x)$

Sampling \rightarrow Counting

Wejście: graf G

Pytanie: Ile jest zbiorów niezależnych w G ?

$\Omega(G)$ = zbiory niezależnych w G

Najpierw założymy, że mamy FPAUS.

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|P_X - U\|_{TV} \leq \varepsilon$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

w czasie wielomianowym od $|x|, \ln(1/\varepsilon)$.

$x \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(x)$

Sampling \rightarrow Counting

Wejście: graf G

Pytanie: Ile jest zbiorów niezależnych w G ?

$\Omega(G)$ = zbiory niezależnych w G

Najpierw założymy, że mamy FPAUS.

Pokażemy jak zrobić FPRAS.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(x)|$

FPAUS (approx. sampling) \rightarrow FPRAS (approx. counting)

Moc próbkowania

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

inaczej:
 U jednostajny
 $\|P_X - U\|_{TV} \leq \varepsilon$

Definicja:

Mając dany problem obliczeniowy $x \rightarrow \Omega(x)$,

gdzie $\Omega(x)$ to (duży) zbiór rozwiązań mówimy, że mamy

a *fully polynomial almost uniform sampler* (FPAUS)

jeśli dla wejścia x i parametru ε

umiemy generować ε -jednostajną próbkę $\Omega(x)$

w czasie wielomianowym od $|x|, \ln(1/\varepsilon)$.

$x \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(x)$

Sampling \rightarrow Counting

Wejście: graf G

Pytanie: Ile jest zbiorów niezależnych w G ?

$\Omega(G)$ = zbiory niezależnych w G

Najpierw założymy, że mamy FPAUS.

Pokażemy jak zrobić FPRAS.

Na końcu wykładu pokażemy jak zrobić FPAUS
w pewnym szczególnym przypadku.

$x \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(x)|$

FPAUS (approx. sampling) \rightarrow FPRAS (approx. counting)

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

Cel: Taka zmienna W , że

$$\mathbb{P} \left(\left| \frac{W}{|\Omega(G)|} - 1 \right| \leq \varepsilon \right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$\mathbb{P}(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G
 e_1, \dots, e_k – krawędzie G

Cel: Taka zmienna W , że

$$\mathbb{P} \left(\left| \frac{W}{|\Omega(G)|} - 1 \right| \leq \varepsilon \right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$\mathbb{P}(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

Cel: Taka zmienna W , że

$$\mathbb{P} \left(\left| \frac{W}{|\Omega(G)|} - 1 \right| \leq \varepsilon \right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$\mathbb{P}(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

Cel: Taka zmienna W , że

$$\mathbb{P} \left(\left| \frac{W}{|\Omega(G)|} - 1 \right| \leq \varepsilon \right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$\mathbb{P}(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

Cel: Taka zmienna W , że

$$\mathbb{P} \left(\left| \frac{W}{|\Omega(G)|} - 1 \right| \leq \varepsilon \right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$\mathbb{P}(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm) daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproxymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproxymacją r_i

to W spełnia **Cel**.

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproxymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia **Cel**.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproksymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k – krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 – same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia **Cel**.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

$$P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \frac{\delta}{k}$$

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

daje (ε, δ) -aproksymacje wartości V jeśli:

$$P(|X - V| \leq \varepsilon V) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k - krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 - same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia **Cel**.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

$$P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \frac{\delta}{k}$$

$$P\left(\bigcup_{i=1}^k \{|s_i - r_i| > \frac{\varepsilon}{2k} r_i\}\right) \leq \sum_{i=1}^k P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \sum_{i=1}^k \frac{\delta}{k} = \delta$$

Cel: Taka zmienna W , że

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) \geq 1 - \delta$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k - krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 - same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia Cel.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

$$P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \frac{\delta}{k}$$

$$P\left(\bigcup_{i=1}^k \{|s_i - r_i| > \frac{\varepsilon}{2k} r_i\}\right) \leq \sum_{i=1}^k P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \sum_{i=1}^k \frac{\delta}{k} = \delta$$

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) =$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k - krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 - same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia Cel.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

$$P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \frac{\delta}{k}$$

$$P\left(\bigcup_{i=1}^k \{|s_i - r_i| > \frac{\varepsilon}{2k} r_i\}\right) \leq \sum_{i=1}^k P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \sum_{i=1}^k \frac{\delta}{k} = \delta$$

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{W}{|\Omega(G)|} \leq 1 + \varepsilon\right) =$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k - krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 - same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia Cel.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

$$P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \frac{\delta}{k}$$

$$P\left(\bigcup_{i=1}^k \{|s_i - r_i| > \frac{\varepsilon}{2k} r_i\}\right) \leq \sum_{i=1}^k P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \sum_{i=1}^k \frac{\delta}{k} = \delta$$

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{W}{|\Omega(G)|} \leq 1 + \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1}{r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1} \leq 1 + \varepsilon\right) \geq$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k - krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 - same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia Cel.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

$$P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \frac{\delta}{k}$$

$$P\left(\bigcup_{i=1}^k \{|s_i - r_i| > \frac{\varepsilon}{2k} r_i\}\right) \leq \sum_{i=1}^k P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \sum_{i=1}^k \frac{\delta}{k} = \delta$$

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{W}{|\Omega(G)|} \leq 1 + \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1}{r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1} \leq 1 + \varepsilon\right) \geq$$

$$P\left(\bigcap_{i=1}^k \left\{1 - \frac{\varepsilon}{2k} \leq \frac{s_i}{r_i} \leq 1 + \frac{\varepsilon}{2k}\right\}\right) =$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k - krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 - same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia Cel.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

$$P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \frac{\delta}{k}$$

$$P\left(\bigcup_{i=1}^k \{|s_i - r_i| > \frac{\varepsilon}{2k} r_i\}\right) \leq \sum_{i=1}^k P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \sum_{i=1}^k \frac{\delta}{k} = \delta$$

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{W}{|\Omega(G)|} \leq 1 + \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1}{r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1} \leq 1 + \varepsilon\right) \geq$$

$$P\left(\bigcap_{i=1}^k \left\{1 - \frac{\varepsilon}{2k} \leq \frac{s_i}{r_i} \leq 1 + \frac{\varepsilon}{2k}\right\}\right) =$$

$$P\left(\bigcap_{i=1}^k \{|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i\}\right) \geq 1 - \delta \quad \square$$

Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $|\Omega(H)|$

Chcemy: $G \xrightarrow{\text{poly}} (\varepsilon, \delta)$ -aproksymacja $|\Omega(G)|$

Wejście: graf G , parametry ε, δ

n = liczba wierzchołków G

e_1, \dots, e_k - krawędzie G

$G_i = (V, \{e_1, \dots, e_i\})$

G_0 - same wierzchołki ($|\Omega(G_0)| = 2^n$)

$G_k = G$

$$|\Omega(G)| = \frac{|\Omega(G_k)|}{|\Omega(G_{k-1})|} \cdot \frac{|\Omega(G_{k-1})|}{|\Omega(G_{k-2})|} \cdot \dots \cdot \frac{|\Omega(G_2)|}{|\Omega(G_1)|} \cdot \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \cdot |\Omega(G_0)|$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

potrzebujemy dobre przybliżenia r_i

jak dobre?

powiedzmy, że s_i przybliża r_i

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

Lemat:

jeśli mamy s_i , które jest $(\varepsilon/2k, \delta/k)$ -aproksymacją r_i

to W spełnia **Cel**.

Dowód: Z definicji dla każdego $i \in [k]$

$$P(|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i) \geq 1 - \frac{\delta}{k}$$

$$P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \frac{\delta}{k}$$

$$P\left(\bigcup_{i=1}^k \{|s_i - r_i| > \frac{\varepsilon}{2k} r_i\}\right) \leq \sum_{i=1}^k P(|s_i - r_i| > \frac{\varepsilon}{2k} r_i) < \sum_{i=1}^k \frac{\delta}{k} = \delta$$

$$P\left(\left|\frac{W}{|\Omega(G)|} - 1\right| \leq \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{W}{|\Omega(G)|} \leq 1 + \varepsilon\right) =$$

$$P\left(1 - \varepsilon \leq \frac{s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1}{r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1} \leq 1 + \varepsilon\right) \geq$$

$$P\left(\bigcap_{i=1}^k \left\{1 - \frac{\varepsilon}{2k} \leq \frac{s_i}{r_i} \leq 1 + \frac{\varepsilon}{2k}\right\}\right) =$$

$$P\left(\bigcap_{i=1}^k \{|s_i - r_i| \leq \frac{\varepsilon}{2k} r_i\}\right) \geq 1 - \delta \quad \square$$

Czyli wystarczy umieć aproksymować $\frac{|\Omega(H)|}{|\Omega(H')|}$

gdzie $H = H' + e$ dla pewnej krawędzi e .

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P}\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P}\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P} \left(\left| \frac{Y}{R} - 1 \right| \leq \varepsilon' \right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P} \left(\left| \frac{Y}{R} - 1 \right| \leq \varepsilon' \right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)]$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P} \left(\left| \frac{Y}{R} - 1 \right| \leq \varepsilon' \right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)]$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P} \left(\left| \frac{Y}{R} - 1 \right| \leq \varepsilon' \right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad \mathbb{E}(Y) = \frac{1}{m} \sum_{i=1}^m \mathbb{E}(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = \mathbb{E}([I \in \Omega(H)]) = \mathbb{P}(I \in \Omega(H)) =: \mu$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2}$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami
w obu końcach, ale zawsze możemy usunąć jeden element)

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami
w obu końcach, ale zawsze możemy usunąć jeden element)

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|P(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P}(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad \mathbb{E}(Y) = \frac{1}{m} \sum_{i=1}^m \mathbb{E}(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = \mathbb{E}([I \in \Omega(H)]) = \mathbb{P}(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |\mathbb{P}(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P}(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad \mathbb{E}(Y) = \frac{1}{m} \sum_{i=1}^m \mathbb{E}(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = \mathbb{E}([I \in \Omega(H)]) = \mathbb{P}(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |\mathbb{P}(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P}(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad \mathbb{E}(Y) = \frac{1}{m} \sum_{i=1}^m \mathbb{E}(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = \mathbb{E}([I \in \Omega(H)]) = \mathbb{P}(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2} \quad (\text{dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element})$$

$$|\mu - R| = |\mathbb{P}(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Definicja:

Zmienna losowa X (randomizowany algorytm)

na skończonej przestrzeni Ω

daje ε -jednostajną próbkę Ω jeśli

dla każdego $S \subset \Omega$

$$|\mathbb{P}(X \in S) - \frac{|S|}{|\Omega|}| \leq \varepsilon$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P}(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad \mathbb{E}(Y) = \frac{1}{m} \sum_{i=1}^m \mathbb{E}(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = \mathbb{E}([I \in \Omega(H)]) = \mathbb{P}(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |\mathbb{P}(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $\mathbb{E}(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

$$\text{to } \mathbb{P}(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta.$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3 \ln(2/\delta') / \mu(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3 \ln(2/\delta) / \mu \varepsilon^2$,

$$\text{to } P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon \mu) \leq \delta.$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$\mathbb{P}(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad \mathbb{E}(Y) = \frac{1}{m} \sum_{i=1}^m \mathbb{E}(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = \mathbb{E}([I \in \Omega(H)]) = \mathbb{P}(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami
w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |\mathbb{P}(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $\mathbb{E}(X_i) = \mu$.

Jeśli $m \geq 3\ln(2/\delta)/\mu\varepsilon^2$,

$$\text{to } \mathbb{P}(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon\mu) \leq \delta.$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami
w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3\ln(2/\delta)/\mu\varepsilon^2$,

$$\text{to } P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon\mu) \leq \delta.$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami
w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Twierdzenie 11.1 (Chernoff):

Niech X_1, \dots, X_m indykatory iid mające $E(X_i) = \mu$.

Jeśli $m \geq 3\ln(2/\delta)/\mu\varepsilon^2$,

$$\text{to } P(|\frac{1}{m} \sum_{i=1}^m X_i - \mu| \geq \varepsilon\mu) \leq \delta.$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P((1 - \frac{\varepsilon'}{6})(1 - \frac{2\varepsilon'}{3}) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq (1 + \frac{\varepsilon'}{6})(1 + \frac{2\varepsilon'}{3})) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2} \quad (\text{dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element})$$

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P((1 - \frac{\varepsilon'}{6})(1 - \frac{2\varepsilon'}{3}) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq (1 + \frac{\varepsilon'}{6})(1 + \frac{2\varepsilon'}{3})) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

$$P(1 - \varepsilon' \leq \frac{Y}{R} \leq 1 + \varepsilon') \geq 1 - \delta'$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami
w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3 \ln(2/\delta') / \mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9 \ln(2/\delta') / (\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6} \mu) \leq \delta'$$

$$P(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P((1 - \frac{\varepsilon'}{6})(1 - \frac{2\varepsilon'}{3}) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq (1 + \frac{\varepsilon'}{6})(1 + \frac{2\varepsilon'}{3})) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

$$P(1 - \varepsilon' \leq \frac{Y}{R} \leq 1 + \varepsilon') \geq 1 - \delta'$$

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

nie jest to dokładnie schemat z początku (przybliżenie!)

$R \geq \frac{1}{2}$ (dodając krawędź zabijamy zbiory z elementami
w obu końcach, ale zawsze możemy usunąć jeden element)

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P((1 - \frac{\varepsilon'}{6})(1 - \frac{2\varepsilon'}{3}) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq (1 + \frac{\varepsilon'}{6})(1 + \frac{2\varepsilon'}{3})) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

$$P(1 - \varepsilon' \leq \frac{Y}{R} \leq 1 + \varepsilon') \geq 1 - \delta'$$

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

m jest wielomianowe od wejścia!

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2} \quad (\text{dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element})$$

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P((1 - \frac{\varepsilon'}{6})(1 - \frac{2\varepsilon'}{3}) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq (1 + \frac{\varepsilon'}{6})(1 + \frac{2\varepsilon'}{3})) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$P(1 - \varepsilon' \leq \frac{Y}{R} \leq 1 + \varepsilon') \geq 1 - \delta'$$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

m jest wielomianowe od wejścia!

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2} \quad (\text{dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element})$$

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Podsumowanie: Próbkowanie \rightarrow Zliczanie

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P((1 - \frac{\varepsilon'}{6})(1 - \frac{2\varepsilon'}{3}) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq (1 + \frac{\varepsilon'}{6})(1 + \frac{2\varepsilon'}{3})) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$P(1 - \varepsilon' \leq \frac{Y}{R} \leq 1 + \varepsilon') \geq 1 - \delta'$$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

m jest wielomianowe od wejścia!

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2} \quad (\text{dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element})$$

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Podsumowanie: Próbkowanie \rightarrow Zliczanie

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P\left(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}\right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P\left(\left(1 - \frac{\varepsilon'}{6}\right)\left(1 - \frac{2\varepsilon'}{3}\right) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq \left(1 + \frac{\varepsilon'}{6}\right)\left(1 + \frac{2\varepsilon'}{3}\right)\right) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$P\left(1 - \varepsilon' \leq \frac{Y}{R} \leq 1 + \varepsilon'\right) \geq 1 - \delta'$$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$P\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

m jest wielomianowe od wejścia!

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2} \quad (\text{dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element})$$

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Podsumowanie: Próbkowanie \rightarrow Zliczanie

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P((1 - \frac{\varepsilon'}{6})(1 - \frac{2\varepsilon'}{3}) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq (1 + \frac{\varepsilon'}{6})(1 + \frac{2\varepsilon'}{3})) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$P(1 - \varepsilon' \leq \frac{Y}{R} \leq 1 + \varepsilon') \geq 1 - \delta'$$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

$$P(|\frac{Y}{R} - 1| \leq \varepsilon') \geq 1 - \delta'$$

m jest wielomianowe od wejścia!

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2} \quad (\text{dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element})$$

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Podsumowanie: Próbkowanie \rightarrow Zliczanie

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

jeśli s_i , jest $(\varepsilon/2k, \delta/k)$ -aproxymacją r_i to W dobre

Zakładamy: $H \xrightarrow{\text{poly}} \varepsilon$ -jednostajna próbka $\Omega(H)$

z Tw jeśli $m \geq 3\ln(2/\delta')/\mu(\varepsilon'/6)^2$,
albo słabiej $m \geq 9\ln(2/\delta')/(\varepsilon'/6)^2$,

Wejście: grafy H, H' , gdzie $H = H' + e$ i parametry $\varepsilon' = \varepsilon/2k, \delta' = \delta/k$

$$R = \frac{|\Omega(H)|}{|\Omega(H')|}$$

Cel2: Taka zmienna Y , że

$$P\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

$$P(|Y - \mu| \geq \frac{\varepsilon'}{6}\mu) \leq \delta'$$

$$P\left(1 - \frac{\varepsilon'}{6} \leq \frac{Y}{\mu} \leq 1 + \frac{\varepsilon'}{6}\right) \geq 1 - \delta'$$

wiele razy (X_1, \dots, X_m) powtarzamy:

$$P\left(\left(1 - \frac{\varepsilon'}{6}\right)\left(1 - \frac{2\varepsilon'}{3}\right) \leq \frac{Y}{\mu} \cdot \frac{\mu}{R} \leq \left(1 + \frac{\varepsilon'}{6}\right)\left(1 + \frac{2\varepsilon'}{3}\right)\right) \geq 1 - \delta'$$

bierzemy $\varepsilon'/3$ -jednostajnie zbiór $I \in \Omega(H')$

$$P\left(1 - \varepsilon' \leq \frac{Y}{R} \leq 1 + \varepsilon'\right) \geq 1 - \delta'$$

$$X_i = [I \in \Omega(H)] \quad E(Y) = \frac{1}{m} \sum_{i=1}^m E(X_i) =$$

$$Y = \frac{1}{m} \sum_{i=1}^m X_i \quad = E([I \in \Omega(H)]) = P(I \in \Omega(H)) =: \mu$$

$$P\left(\left|\frac{Y}{R} - 1\right| \leq \varepsilon'\right) \geq 1 - \delta'$$

m jest wielomianowe od wejścia!

nie jest to dokładnie schemat z początku (przybliżenie!)

$$R \geq \frac{1}{2} \quad (\text{dodając krawędź zabijamy zbiory z elementami w obu końcach, ale zawsze możemy usunąć jeden element})$$

$$|\mu - R| = |P(I \in \Omega(H)) - \frac{|\Omega(H)|}{|\Omega(H')|}| \leq \frac{\varepsilon'}{3} \quad \mu \geq \frac{1}{3}$$

$$1 - \frac{\varepsilon'}{3R} \leq \frac{\mu}{R} \leq 1 + \frac{\varepsilon'}{3R}$$

$$1 - \frac{2\varepsilon'}{3} \leq \frac{\mu}{R} \leq 1 + \frac{2\varepsilon'}{3}$$

Podsumowanie: Próbkowanie \rightarrow Zliczanie

$$|\Omega(G)| = r_k \cdot r_{k-1} \cdot \dots \cdot r_2 \cdot r_1 \cdot 2^n$$

$$W = s_k \cdot s_{k-1} \cdot \dots \cdot s_2 \cdot s_1 \cdot 2^n$$

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$$

jeśli s_i , jest $(\varepsilon/2k, \delta/k)$ -aproxymacją r_i to W dobre

s_i otrzymujemy za pomocą założonego FPAUS

jak wyżej

Skąd brać próbki?

Skąd brać próbki?

Łańcuchy Markova?

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :
 - v jednostajnie wybrany wierzchołek z G

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :
 - v jednostajnie wybrany wierzchołek z G
 - jeśli $v \in X_i$ to $X_{i+1} = X_i \setminus \{v\}$

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :
 - v jednostajnie wybrany wierzchołek z G
 - jeśli $v \in X_i$ to $X_{i+1} = X_i \setminus \{v\}$
 - jeśli $v \notin X_i$ to

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :

v jednostajnie wybrany wierzchołek z G

jeśli $v \in X_i$ to $X_{i+1} = X_i \setminus \{v\}$

jeśli $v \notin X_i$ to

jeśli $X_i \cup \{v\}$ to zbiór niezależny to $X_{i+1} = X_i \cup \{v\}$

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :

v jednostajnie wybrany wierzchołek z G

jeśli $v \in X_i$ to $X_{i+1} = X_i \setminus \{v\}$

jeśli $v \notin X_i$ to

jeśli $X_i \cup \{v\}$ to zbiór niezależny to $X_{i+1} = X_i \cup \{v\}$

jeśli $X_i \cup \{v\}$ to nie jest zbiór niezależny to $X_{i+1} = X_i$

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :

v jednostajnie wybrany wierzchołek z G

jeśli $v \in X_i$ to $X_{i+1} = X_i \setminus \{v\}$

jeśli $v \notin X_i$ to

jeśli $X_i \cup \{v\}$ to zbiór niezależny to $X_{i+1} = X_i \cup \{v\}$

jeśli $X_i \cup \{v\}$ to nie jest zbiór niezależny to $X_{i+1} = X_i$

Rozkład stacjonarny istnieje i jest jednostajny!

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :

v jednostajnie wybrany wierzchołek z G

jeśli $v \in X_i$ to $X_{i+1} = X_i \setminus \{v\}$

jeśli $v \notin X_i$ to

jeśli $X_i \cup \{v\}$ to zbiór niezależny to $X_{i+1} = X_i \cup \{v\}$

jeśli $X_i \cup \{v\}$ to nie jest zbiór niezależny to $X_{i+1} = X_i$

Rozkład stacjonarny istnieje i jest jednostajny!

A jakie trzeba wziąć m w 3?

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0
2. Aby obliczyć X_{i+1} :

v jednostajnie wybrany wierzchołek z G

jeśli $v \in X_i$ to $X_{i+1} = X_i \setminus \{v\}$

jeśli $v \notin X_i$ to

jeśli $X_i \cup \{v\}$ to zbiór niezależny to $X_{i+1} = X_i \cup \{v\}$

jeśli $X_i \cup \{v\}$ to nie jest zbiór niezależny to $X_{i+1} = X_i$

Rozkład stacjonarny istnieje i jest jednostajny!

A jakie trzeba wziąć m w 3?

Okazuje się to zaskakująco trudne pytanie.

Skąd brać próbki?

Łańcuchy Markova?

1. Mamy dany (skomplikowany) rozkład π
2. Wymyślamy łańcuch Markova, gdzie π to rozkład stacjonarny
3. Znajdujemy takie m , że po m krokach łańcucha jesteśmy wystarczająco blisko π
4. $\dots X_m \dots X_{2m} \dots X_{3m} \dots X_{4m} \dots$ to nasza próbka

Jednostajne próbkowanie zbiorów niezależnych w G ?

1. Wybieramy dowolny zbiór początkowy X_0

MInd 1

2. Aby obliczyć X_{i+1} :

v jednostajnie wybrany wierzchołek z G

jeśli $v \in X_i$ to $X_{i+1} = X_i \setminus \{v\}$

jeśli $v \notin X_i$ to

jeśli $X_i \cup \{v\}$ to zbiór niezależny to $X_{i+1} = X_i \cup \{v\}$

jeśli $X_i \cup \{v\}$ to nie jest zbiór niezależny to $X_{i+1} = X_i$

Rozkład stacjonarny istnieje i jest jednostajny!

A jakie trzeba wziąć m w 3?

Okazuje się to zaskakująco trudne pytanie.

Dlatego rozważymy inny łańcuch i dodamy założenia...

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow$$

$$p = 2 \longrightarrow$$

$$p = 3 \longrightarrow$$

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow$$

$$p = 3 \longrightarrow$$

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow$$

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$

dla e, p wylosowanych jednostajnie.

$$I\Delta J = (I\setminus J) \cup (J\setminus I)$$

Path coupling

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$

dla e, p wylosowanych jednostajnie.

Path coupling

$$I\Delta J = (I\setminus J) \cup (J\setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Chcemy użyć sprzężenia łańcuchów

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Path coupling

$$I\Delta J = (I\setminus J) \cup (J\setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

Path coupling

$$I\Delta J = (I\setminus J) \cup (J\setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t))$$

Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$\mathbb{E}(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t))$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Path coupling

$$I\Delta J = (I\setminus J) \cup (J\setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$

Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t

Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Path coupling

$$I\Delta J = (I\setminus J) \cup (J\setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką"

Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym
Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny


Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką"



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny


Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką"
 $X_t \setminus Y_t = \{x_1, \dots, x_r\}$
 $Y_t \setminus X_t = \{y_1, \dots, y_s\}$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$


Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$


Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy


Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$


$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$


$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$

$$Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$


Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

- $Z_0 = X_t$
- $Z_1 = X_t \setminus \{x_1\}$
- $Z_2 = X_t \setminus \{x_1, x_2\}$
- ...
- $Z_r = X_t \cap Y_t$
- $Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$
- $Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$


Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

- $Z_0 = X_t$
- $Z_1 = X_t \setminus \{x_1\}$
- $Z_2 = X_t \setminus \{x_1, x_2\}$
- \dots
- $Z_r = X_t \cap Y_t$
- $Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$
- $Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$
- \dots
- $Z_{r+s} = Z_{d_t} = Y_t$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t \qquad Y_t \setminus X_t = \{y_1, \dots, y_s\}$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$


$$Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$$

$$Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$$

...

$$Z_{r+s} = Z_{d_t} = Y_t$$

$$\text{Mamy } |Z_{i-1} \Delta Z_i| = 1$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} \mid d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$

$$Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$$

$$Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$$


...

$$Z_{r+s} = Z_{d_t} = Y_t$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$

Mamy $|Z_{i-1} \Delta Z_i| = 1$

Więc $E(|K(Z_{i-1}) \Delta K(Z_i)|) \leq 1$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym
 Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$
 nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$
 dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$

$$Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$$

$$Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$$

...


$$Z_{r+s} = Z_{d_t} = Y_t$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$

Mamy $|Z_{i-1} \Delta Z_i| = 1$

Więc $E(|K(Z_{i-1}) \Delta K(Z_i)|) \leq 1$

$$d_{t+1} = |X_{t+1} \Delta Y_{t+1}|$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markova na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$

$$Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$$

$$Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$$

...


$$Z_{r+s} = Z_{d_t} = Y_t$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$

Mamy $|Z_{i-1} \Delta Z_i| = 1$

Więc $E(|K(Z_{i-1}) \Delta K(Z_i)|) \leq 1$

$$\begin{aligned} d_{t+1} &= |X_{t+1} \Delta Y_{t+1}| \\ &= |K(X_t) \Delta K(Y_t)| \end{aligned}$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$p = 1 \longrightarrow I' = I \setminus \{u, v\}$

$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$

$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzężenia łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$

$$Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$$

$$Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$$

...


$$Z_{r+s} = Z_{d_t} = Y_t$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$

Mamy $|Z_{i-1} \Delta Z_i| = 1$

Więc $E(|K(Z_{i-1}) \Delta K(Z_i)|) \leq 1$

$$\begin{aligned} d_{t+1} &= |X_{t+1} \Delta Y_{t+1}| \\ &= |K(X_t) \Delta K(Y_t)| \\ &= |K(Z_0) \Delta K(Z_{d_t})| \end{aligned}$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$

$$Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$$

$$Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$$

...


$$Z_{r+s} = Z_{d_t} = Y_t$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$

Mamy $|Z_{i-1} \Delta Z_i| = 1$

Więc $E(|K(Z_{i-1}) \Delta K(Z_i)|) \leq 1$

$$\begin{aligned} d_{t+1} &= |X_{t+1} \Delta Y_{t+1}| \\ &= |K(X_t) \Delta K(Y_t)| \\ &= |K(Z_0) \Delta K(Z_{d_t})| \\ &\leq \sum_{i=1}^{d_t} |K(Z_{i-1}) \Delta K(Z_i)| \end{aligned}$$



Path coupling

$$I \Delta J = (I \setminus J) \cup (J \setminus I)$$

Wejście: graf G z $\Delta(G) \leq 4$

Cel: FPAUS dla $\Omega(G)$

Plan: Łańcuch Markowa na $\Omega(G)$ z π jednostajnym

Pokażemy, że zbiega szybko do π .

Mając dany zbiór $I \in \Omega(G)$ definiujemy *krok* z I .

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Mając $I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$ nie powinno być trudno porównać $K_e^p(I)$ z $K_e^p(J)$ dla e, p wylosowanych jednostajnie.

faktycznie, analizując przypadki pokażemy, że

$$E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Chcemy użyć sprzęgania łańcuchów

Niech (X_t, Y_t) łańcuchem takim, że losujemy e_t, p_t jednostajnie

$$(X_{t+1}, Y_{t+1}) = (K_{e_t}^{p_t}(X_t), K_{e_t}^{p_t}(Y_t)) \quad d_t = |X_t \Delta Y_t|$$

Łańcuch $(X_t)_t$ ma rozkład stacjonarny jednostajny

Wystarczy pokazać, że $E(d_{t+1} | d_t) \leq d_t$

Rozważmy przypadki jakie jest d_t niech $K = K_{e_t}^{p_t}$

Jeśli $d_t = 0$ to $X_t = Y_t$, więc $X_{t+1} = Y_{t+1}$

Jeśli $d_t = 1$ to $|X_t \Delta Y_t| = 1$, a ten przypadek już zrobiliśmy

Jeśli $d_t > 1$ to łączymy X_t z Y_t "ścieżką" $X_t \setminus Y_t = \{x_1, \dots, x_r\}$

$$Z_0 = X_t$$

$$Z_1 = X_t \setminus \{x_1\}$$

$$Z_2 = X_t \setminus \{x_1, x_2\}$$

...

$$Z_r = X_t \cap Y_t$$

$$Z_{r+1} = (X_t \cap Y_t) \cup \{y_1\}$$

$$Z_{r+2} = (X_t \cap Y_t) \cup \{y_1, y_2\}$$

...

$$Z_{r+s} = Z_{d_t} = Y_t$$

$$Y_t \setminus X_t = \{y_1, \dots, y_s\}$$

Mamy $|Z_{i-1} \Delta Z_i| = 1$


Więc $E(|K(Z_{i-1}) \Delta K(Z_i)|) \leq 1$

$$d_{t+1} = |X_{t+1} \Delta Y_{t+1}|$$

$$= |K(X_t) \Delta K(Y_t)|$$

$$= |K(Z_0) \Delta K(Z_{d_t})|$$

$$\leq \sum_{i=1}^{d_t} |K(Z_{i-1}) \Delta K(Z_i)|$$



X_t

Y_t

$$E(d_{t+1} | d_t) \leq \sum_{i=1}^{d_t} E(|K(Z_{i-1}) \Delta K(Z_i)|) \leq d_t$$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^{p_t}$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^{p_t}$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Założmy więc, że $u \in N(x)$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

$$\text{I. } |N(u) \cap I| \geq 2$$

$$\text{II. } |N(u) \cap I| = 1$$

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

$$\text{III. } |N(u) \cap I| = 0$$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Założmy więc, że $u \in N(x)$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$


$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$


$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

I. $|N(u) \cap I| \geq 2$



II. $|N(u) \cap I| = 1$



Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,


$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

III. $|N(u) \cap I| = 0$



Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Założmy więc, że $u \in N(x)$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^{p_t}$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$


Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$


Załóżmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$




w każdym przypadku $D \leq 1$

II. $|N(u) \cap I| = 1$



III. $|N(u) \cap I| = 0$



Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$


Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$


Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$




w każdym przypadku $D \leq 1$

II. $|N(u) \cap I| = 1$



jeśli $v \in \{v_2, v_3\}$ to $D = 1$

III. $|N(u) \cap I| = 0$



Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

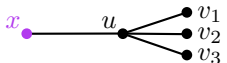
Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$

II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to

jeśli $v = v_1$ to

III. $|N(u) \cap I| = 0$ 

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

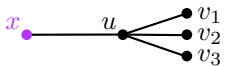
Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$

II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

jeśli $v = v_1$ to

III. $|N(u) \cap I| = 0$ 

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Załóżmy więc, że $u \in N(x)$

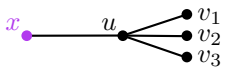
I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$

II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to

III. $|N(u) \cap I| = 0$ 

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$


Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$


Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$



w każdym przypadku $D \leq 1$

II. $|N(u) \cap I| = 1$




jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

$p = 3 \rightarrow D = 1$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

III. $|N(u) \cap I| = 0$



Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$

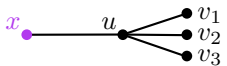
II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

III. $|N(u) \cap I| = 0$ 

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Załóżmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$


II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

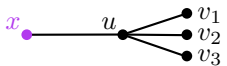
jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

(bo $K(I) = I \cup \{u\} \setminus \{v_1\}$ i $K(J) = J$) 

III. $|N(u) \cap I| = 0$ 

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Załóżmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$


II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

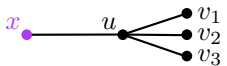
$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

(bo $K(I) = I \cup \{u\} \setminus \{v_1\}$ i $K(J) = J$) 

$$E(D \mid e \in \{ux, uv_1\}) = \frac{1}{2} \left(\frac{2}{3} \cdot 0 + \frac{1}{3} \cdot 1 \right) + \frac{1}{2} \left(\frac{2}{3} \cdot 1 + \frac{1}{3} \cdot 3 \right) = 1$$

III. $|N(u) \cap I| = 0$ 

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$


II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

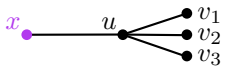
$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

(bo $K(I) = I \cup \{u\} \setminus \{v_1\}$ i $K(J) = J$) 

$$E(D \mid e \in \{ux, uv_1\}) = \frac{1}{2}(\frac{2}{3} \cdot 0 + \frac{1}{3} \cdot 1) + \frac{1}{2}(\frac{2}{3} \cdot 1 + \frac{1}{3} \cdot 3) = 1$$

III. $|N(u) \cap I| = 0$ 

jeśli $v = x$ to $D = 0$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Załóżmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$


II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

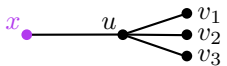
$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

(bo $K(I) = I \cup \{u\} \setminus \{v_1\}$ i $K(J) = J$) 

$$E(D \mid e \in \{ux, uv_1\}) = \frac{1}{2} \left(\frac{2}{3} \cdot 0 + \frac{1}{3} \cdot 1 \right) + \frac{1}{2} \left(\frac{2}{3} \cdot 1 + \frac{1}{3} \cdot 3 \right) = 1$$

III. $|N(u) \cap I| = 0$ 

jeśli $v = x$ to $D = 0$

jeśli $v = v_i$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$


II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

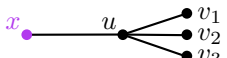
$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

(bo $K(I) = I \cup \{u\} \setminus \{v_1\}$ i $K(J) = J$) 

$$E(D \mid e \in \{ux, uv_1\}) = \frac{1}{2}(\frac{2}{3} \cdot 0 + \frac{1}{3} \cdot 1) + \frac{1}{2}(\frac{2}{3} \cdot 1 + \frac{1}{3} \cdot 3) = 1$$

III. $|N(u) \cap I| = 0$ 

jeśli $v = x$ to $D = 0$

jeśli $v = v_i$ $p \in \{1, 2\} \rightarrow D = 1$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$


II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

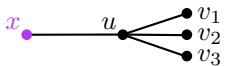
$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

(bo $K(I) = I \cup \{u\} \setminus \{v_1\}$ i $K(J) = J$) 

$$E(D \mid e \in \{ux, uv_1\}) = \frac{1}{2}(\frac{2}{3} \cdot 0 + \frac{1}{3} \cdot 1) + \frac{1}{2}(\frac{2}{3} \cdot 1 + \frac{1}{3} \cdot 3) = 1$$

III. $|N(u) \cap I| = 0$ 

jeśli $v = x$ to $D = 0$

jeśli $v = v_i$ $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 2$$

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Założmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$


II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

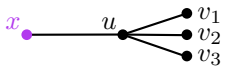
$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

(bo $K(I) = I \cup \{u\} \setminus \{v_1\}$ i $K(J) = J$) 


$$E(D \mid e \in \{ux, uv_1\}) = \frac{1}{2}(\frac{2}{3} \cdot 0 + \frac{1}{3} \cdot 1) + \frac{1}{2}(\frac{2}{3} \cdot 1 + \frac{1}{3} \cdot 3) = 1$$

III. $|N(u) \cap I| = 0$ 

jeśli $v = x$ to $D = 0$

jeśli $v = v_i$ $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 2$$

(bo $K(I) = I \cup \{u\}$ i $K(J) = J$) 

Wejście: graf G z $\Delta(G) \leq 4$

Dla krawędzi $e = uv$ w G i $p \in \{1, 2, 3\}$

$$p = 1 \longrightarrow I' = I \setminus \{u, v\}$$

$$p = 2 \longrightarrow I' = (I \setminus \{u\}) \cup \{v\}$$

$$p = 3 \longrightarrow I' = (I \setminus \{v\}) \cup \{u\}$$

Jeśli $I' \in \Omega(G)$ to $K_e^p(I) = I'$, wpp $K_e^p(I) = I$.

Lemat:

$I, J \in \Omega(G)$ takie, że $J = I \cup \{x\}$

e, p losowane jednostajnie,

$$\text{wtedy } E(|K_e^p(I) \Delta K_e^p(J)|) \leq 1$$

$$K = K_{e_t}^p$$

$$D = |K(I) \Delta K(J)|$$

chcemy $E(D) \leq 1$

Dowód:

Niech $e = uv$

Jeśli $u, v \notin N(x)$ to $D = 1$

Załóżmy więc, że $u \in N(x)$

I. $|N(u) \cap I| \geq 2$  w każdym przypadku $D \leq 1$


II. $|N(u) \cap I| = 1$  jeśli $v \in \{v_2, v_3\}$ to $D = 1$

jeśli $v = x$ to $p \in \{1, 2\} \rightarrow D = 0$

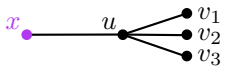
$$p = 3 \rightarrow D = 1$$

jeśli $v = v_1$ to $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 3$$

(bo $K(I) = I \cup \{u\} \setminus \{v_1\}$ i $K(J) = J$) 

$$E(D \mid e \in \{ux, uv_1\}) = \frac{1}{2}(\frac{2}{3} \cdot 0 + \frac{1}{3} \cdot 1) + \frac{1}{2}(\frac{2}{3} \cdot 1 + \frac{1}{3} \cdot 3) = 1$$

III. $|N(u) \cap I| = 0$ 

jeśli $v = x$ to $D = 0$

jeśli $v = v_i$ $p \in \{1, 2\} \rightarrow D = 1$

$$p = 3 \rightarrow D = 2$$

(bo $K(I) = I \cup \{u\}$ i $K(J) = J$) 

$$E(D \mid e \in \{ux, uv_i\}) \leq \frac{1}{\Delta} \cdot 0 + \frac{\Delta-1}{\Delta}(\frac{2}{3} \cdot 1 + \frac{1}{3} \cdot 2) = \frac{\Delta-1}{\Delta} \cdot \frac{4}{3} \leq 1$$

Dziękuję za uwagę!