

# Lossless seeds for approximate string matching

Přibližné vyhledávání pomocí bezeztrátového filtrování

**Karel Břinda**

karel.brinda@jfifi.cvut.cz

**T**heoretical **I**nformatics **G**roup  
Fakulta jaderná a fyzikálně inženýrská  
České vysoké učení technické v Praze

Prezentace diplomové práce  
Praha, 6. června 2013

**VEDOUCÍ PRÁCE**  
**Ing. Karel Klouda, Ph.D.**  
FIT ČVUT v Praze

**KONZULTANT**  
**prof. Gregory Kucherov, Ph.D.**  
Université Paris-Est Marne-la-Vallée

# Cíle práce

- i)** Seznamte se s obecnou teorií související s přibližným vyhledáváním.
- ii)** Nastudujte existující výsledky o bezeztrátových seedech včetně nejnovějších příspěvků.
- iii)** Nastudujte kombinatorické metody používané pro konstrukci seedů.
- iv)** Udělejte systematický souhrn existujících výsledků.
- v)** Implementujte některé z algoritmů.
- vi)** Pokud to bude možné, zlepšete existující algoritmy používané pro konstrukci seedů.

# Úvod do problému

## DNA – NEXT GENERATION SEQUENCING

- Nové metody pro zpracování a analýzu DNA, produkují ohromné množství dat



# Úvod do problému

## DNA – NEXT GENERATION SEQUENCING

- Nové metody pro zpracování a analýzu DNA, produkuje ohromné množství dat
- Nutnost rychlého přibližného vyhledávání



# Úvod do problému

## DNA – NEXT GENERATION SEQUENCING

- Nové metody pro zpracování a analýzu DNA, produkují ohromné množství dat
- Nutnost rychlého přibližného vyhledávání
  - Dán krátký řetězec  $T$  a dlouhý referenční genom  $G$ , hledáme výskyty podřetězců  $G$ , které jsou podobné  $T$ .



# Úvod do problému

## DNA – NEXT GENERATION SEQUENCING

- Nové metody pro zpracování a analýzu DNA, produkují ohromné množství dat
- Nutnost rychlého přibližného vyhledávání
  - Dán krátký řetězec  $T$  a dlouhý referenční genom  $G$ , hledáme výskyty podřetězců  $G$ , které jsou podobné  $T$ .
  - K měření podobnosti používána Hammingova vzdálenost.



# Úvod do problému

- Klasické algoritmy – pomalé  $\implies$  zrychlení pomocí filtrace

vylepšené vyhledávání { **1. filtrační fáze**  
**2. ověřovací fáze**

# Úvod do problému

- Klasické algoritmy – pomalé  $\implies$  zrychlení pomocí filtrace

vylepšené vyhledávání { **1. filtrační fáze**  
**2. ověřovací fáze**

- Myšlenka bezztrátových seedů:

*„Podobné řetězce musí sdílet některé vzory.“* – tzv. **seedy**



# Úvod do problému

- Klasické algoritmy – pomalé  $\implies$  zrychlení pomocí filtrace

vylepšené vyhledávání { **1. filtrační fáze**  
**2. ověřovací fáze**

- Myšlenka bezztrátových seedů:

*„Podobné řetězce musí sdílet některé vzory.“* – tzv. **seedy**

- Příklad: ###-#-#

# ... pozice korespondence

- ... „žolíková pozice“

# Úvod do problému

- Klasické algoritmy – pomalé  $\implies$  zrychlení pomocí filtrace

vylepšené vyhledávání { **1. filtrační fáze**  
**2. ověřovací fáze**

- Myšlenka bezetrátových seedů:

*„Podobné řetězce musí sdílet některé vzory.“* – tzv. **seedy**

- Příklad: ###-#-#
  - # ... pozice korespondence
  - ... „žolíková pozice“
- Na myšlence seedů postavena většina programů pro podobnostní hledání v genomech
  - BLAST, FASTA, PatternHunter, BLASTZ, PatternHunter 2, YASS, ...

# Seedy

## Definice

**seed**  $Q$  libovolný řetězec nad abecedou  $\mathcal{A} = \{\#, -\}$

**váha seedu**  $Q$   $w(Q) = |Q|_{\#}$ , chceme maximalizovat

**$(m, k)$ -problém**  $m$  – délka porovn. řetězců,  $k$  – počet chyb

**$Q$  řeší  $(m, k)$ -problém**  $\forall$  polohu  $k$  chyb  $\exists$  umístění seedu  $Q$ :

$\# \implies$  „nechyba“ (korespondence znaků)

# Seedy

## Definice

- seed**  $Q$  libovolný řetězec nad abecedou  $\mathcal{A} = \{\#, -\}$
- váha seedu**  $Q$   $w(Q) = |Q|_{\#}$ , chceme maximalizovat
- $(m, k)$ -problém**  $m$  – délka porovn. řetězců,  $k$  – počet chyb
- $Q$  řeší  $(m, k)$ -problém**  $\forall$  polohu  $k$  chyb  $\exists$  umístění seedu  $Q$ :  
 $\# \implies$  „nechyba“ (korespondence znaků)

## Příklad

$Q = \###--\#-###$  řeší  $(16, 2)$ -problém. Ukázka pro konkrétní situaci:

<i>c</i>	<i>t</i>	<b>t</b>	<i>a</i>	<i>g</i>	<b>g</b>	<i>c</i>	<i>t</i>	<b>c</b>	<i>c</i>	<b>g</b>	<i>g</i>	<i>g</i>	<i>a</i>	<i>t</i>	<i>a</i>
<i>c</i>	<i>t</i>	<b>t</b>	<i>a</i>	<i>g</i>	<b>a</b>	<i>c</i>	<i>t</i>	<b>t</b>	<i>c</i>	<b>g</b>	<i>g</i>	<i>g</i>	<i>a</i>	<i>t</i>	<i>a</i>
		<b>#</b>	<b>#</b>	<b>#</b>	<b>-</b>	<b>-</b>	<b>#</b>	<b>-</b>	<b>#</b>	<b>#</b>	<b>#</b>				

# Seedy

## Definice

- seed**  $Q$  libovolný řetězec nad abecedou  $\mathcal{A} = \{\#, -\}$
- váha seedu**  $Q$   $w(Q) = |Q|_{\#}$ , chceme maximalizovat
- $(m, k)$ -problém**  $m$  – délka porovn. řetězců,  $k$  – počet chyb
- $Q$  řeší  $(m, k)$ -problém**  $\forall$  polohu  $k$  chyb  $\exists$  umístění seedu  $Q$ :  
 $\# \implies$  „nechyba“ (korespondence znaků)

## Příklad

$Q = \###--\#-###$  řeší  $(16, 2)$ -problém. Ukázka pro konkrétní situaci:

<i>c</i>	<i>t</i>	<b>t</b>	<i>a</i>	<i>g</i>	<b>g</b>	<i>c</i>	<i>t</i>	<b>c</b>	<i>c</i>	<b>g</b>	<i>g</i>	<i>g</i>	<i>a</i>	<i>t</i>	<i>a</i>
<i>c</i>	<i>t</i>	<b>t</b>	<i>a</i>	<i>g</i>	<b>a</b>	<i>c</i>	<i>t</i>	<b>t</b>	<i>c</i>	<b>g</b>	<i>g</i>	<i>g</i>	<i>a</i>	<i>t</i>	<i>a</i>
		<b>#</b>	<b>#</b>	<b>#</b>	<b>-</b>	<b>-</b>	<b>#</b>	<b>-</b>	<b>#</b>	<b>#</b>	<b>#</b>				

Problematice seedů se věnuje 112 článků.

# Výsledky práce

i) Shrnutí dosud publikované výsledky.

# Výsledky práce

- i) Shrnutí dosud publikované výsledky.
- ii)  $(m, 1)$ -problém:
  - Podrobně analyzován.
  - Navržen rychlý algoritmus pro hledání optimálních seedů.

# Výsledky práce

- i)** Shrnutí dosud publikované výsledky.
- ii)**  $(m, 1)$ -problém:
  - Podrobně analyzován.
  - Navržen rychlý algoritmus pro hledání optimálních seedů.
- iii)**  $(m, 2)$ -problém
  - Dokázáno nové kritérium pro řešitelnost.
  - Navržen algoritmus, který vrací pro nízká  $m$  dobré seedy.
  - Vyslovena hypotéza o struktuře optimálních seedů.



# Výsledky práce

- i)** Shrnutí dosud publikované výsledky.
- ii)**  $(m, 1)$ -problém:
  - Podrobně analyzován.
  - Navržen rychlý algoritmus pro hledání optimálních seedů.
- iii)**  $(m, 2)$ -problém
  - Dokázáno nové kritérium pro řešitelnost.
  - Navržen algoritmus, který vrací pro nízká  $m$  dobré seedy.
  - Vyslovena hypotéza o struktuře optimálních seedů.
- iv)** Vytvořeno několik programů.

# $(m, 1)$ -problém

## Věta

Nechť je dán  $(m, 1)$ -problém a seed  $Q$  délky  $s$ . Označme  $\ell = m - s$ . Pak

$Q$  řeší  $(m, 1)$ -problém  $\Leftrightarrow Q$  neobsahuje  $\#^{\ell+1}$ .

# $(m, 1)$ -problém

## Věta

Nechť je dán  $(m, 1)$ -problém a seed  $Q$  délky  $s$ . Označme  $\ell = m - s$ . Pak

$$Q \text{ řeší } (m, 1)\text{-problém} \quad \Leftrightarrow \quad Q \text{ neobsahuje } \#^{\ell+1}.$$

## Hledání optimálního seedu:

- 1 Pro každou délku  $s \in \{2, 3, \dots, m - 1\}$  sestrojíme hladovým algoritmem kandidáta  $Q^{(s)}$ , tedy:

$$Q^{(s)} = \text{prefix } (\#^{\ell}-)^{\omega} \text{ délky } s.$$

- 2 Z kandidátů vyberem toho s nejvyšší vahou.

# $(m, 2)$ -problém: laserová metoda

Snaha o podobné kritérium  $\implies$  laserová metoda

# $(m, 2)$ -problém: laserová metoda

Snaha o podobné kritérium  $\implies$  laserová metoda

**Příklad (Incidenční matice seedu  $Q = \#--\#---\#$  v  $(10, 2)$ -problému)**

$$M_Q = \left( \begin{array}{cc|cccccccc|cc} 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ \hline 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \hline 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \end{array} \right) .$$

## $(m, 2)$ -problém: laserová metoda

Snaha o podobné kritérium  $\implies$  laserová metoda

**Příklad (Incidenční matice seedu  $Q = \#--\#---\#$  v  $(10, 2)$ -problému)**

$$M_Q = \left( \begin{array}{cc|cccccccc|cc} 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ \hline 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \hline 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \end{array} \right) .$$

### Věta

*Seed  $Q$  řeší  $(m, 2)$ -problém  $\Leftrightarrow$  pokud incidenční matice  $M_Q$  neobsahuje „diagonální řetězec nul“ délky  $\ell + 1$ .*

# $(m, 2)$ -problém: laserová metoda

**Příklad  $((14, 2)$ -problém,  $s = 8$ ,  $\ell = 6$ )**

$Q = \#\#\#-\#--\#$

#	0	0	0	0	0	0	0							
#	0	0	0	0	0	0	0	0						
#	0	0	0	0	0	0	0	0	0					
-	1	1	1	1	1	1	0	0	0	1				
#	0	0	0	0	0	0	0	0	0	0	0			
-	1	1	1	1	1	1	0	0	0	1	0	1		
-	1	1	1	1	1	1	0	0	0	1	0	1	1	
#	0	0	0	0	0	0	0	0	0	0	0	0	0	
							0	0	0	1	0	1	1	0
							0	0	0	1	0	1	1	0
							0	0	0	1	0	1	1	0
							0	0	0	1	0	1	1	0
							0	0	0	1	0	1	1	0
							0	0	0	1	0	1	1	0





## $(m, 2)$ -problém: hladový algoritmus

- 1 Pro fixované  $m$  a všechna  $s \in \{2, 3, \dots, m - 1\}$ : hladově přidáváme lasery do  $-s$ .
- 2 Z kandidátů vybereme seed s nejvyšší vahou.

## $(m, 2)$ -problém: hladový algoritmus

- 1 Pro fixované  $m$  a všechna  $s \in \{2, 3, \dots, m-1\}$ : hladově přidáváme lasery do  $-s$ .
- 2 Z kandidátů vybereme seed s nejvyšší vahou.

Získané seedy jsou tvaru

$$Q^{(s)} = \text{prefix } (\#^a - \#^{c-d})^\omega \text{ délky } s,$$

kde  $a = \lfloor \frac{\ell}{2} \rfloor$ ,  $c = \lfloor \frac{\ell-1}{4} \rfloor$ ,  $d = \lfloor \frac{\ell}{4} \rfloor + 1$

## $(m, 2)$ -problém: hladový algoritmus

- 1 Pro fixované  $m$  a všechna  $s \in \{2, 3, \dots, m-1\}$ : hladově přidáváme lasery do  $-^s$ .
- 2 Z kandidátů vybereme seed s nejvyšší vahou.

Získané seedy jsou tvaru

$$Q^{(s)} = \text{prefix } (\#^a - \#^c - ^d)^\omega \text{ délky } s,$$

kde  $a = \lfloor \frac{\ell}{2} \rfloor$ ,  $c = \lfloor \frac{\ell-1}{4} \rfloor$ ,  $d = \lfloor \frac{\ell}{4} \rfloor + 1$

### Srovnání s ostatními metodami: $w$ v závislosti na $m$ a metodě

$m$	16	32	48	64	80	96	200	300	400	500
asympt. optim. metoda	1	3	10	12	21	30	88	150	210	284
perf. pravítka	7	14	23	31	41	50	109	166	224	283
las. metoda + hlad. alg.	7	16	26	35	46	57	128	197	266	337

## $(m, 2)$ -problém: hladový algoritmus

### Věta (Kucherov, Noé, Roytberg, 2005)

*Nechť je  $k$  fixované a  $w(m)$  označuje maximální váhu seedu řešícího  $(m, k)$ -problém. Pak*

$$m - w(m) \in \Theta\left(m^{\frac{k}{k+1}}\right)$$

## $(m, 2)$ -problém: hladový algoritmus

### Věta (Kucherov, Noé, Roytberg, 2005)

*Nechť je  $k$  fixované a  $w(m)$  označuje maximální váhu seedu řešícího  $(m, k)$ -problém. Pak*

$$m - w(m) \in \Theta\left(m^{\frac{k}{k+1}}\right)$$

- Pro každé  $k$  tedy musí platit:

$$\lim_{m \rightarrow +\infty} \frac{w(m)}{m} = 1.$$

## $(m, 2)$ -problém: hladový algoritmus

### Věta (Kucherov, Noé, Roytberg, 2005)

Nechť je  $k$  fixované a  $w(m)$  označuje maximální váhu seedu řešícího  $(m, k)$ -problém. Pak

$$m - w(m) \in \Theta\left(m^{\frac{k}{k+1}}\right)$$

- Pro každé  $k$  tedy musí platit:

$$\lim_{m \rightarrow +\infty} \frac{w(m)}{m} = 1.$$

- Pro hladový algoritmus však dostaneme odhad:

$$\frac{w(m, s)}{m} \leq \frac{3}{16} \left(4 - \frac{1}{m}\right).$$

## $(m, 2)$ -problém: hladový algoritmus

### Věta (Kucherov, Noé, Roytberg, 2005)

Nechť je  $k$  fixované a  $w(m)$  označuje maximální váhu seedu řešícího  $(m, k)$ -problém. Pak

$$m - w(m) \in \Theta\left(m^{\frac{k}{k+1}}\right)$$

- Pro každé  $k$  tedy musí platit:

$$\lim_{m \rightarrow +\infty} \frac{w(m)}{m} = 1.$$

- Pro hladový algoritmus však dostaneme odhad:

$$\frac{w(m, s)}{m} \leq \frac{3}{16} \left(4 - \frac{1}{m}\right).$$

**$\implies$  Hladový algoritmus tedy obecně neposkytuje optimální ani asymptoticky optimální seedy.**

# $(m, 2)$ -problém: cyklická pravítka

## Definice

$P \in \{\#, -\}^p$  nazveme (úplné) **cyklické pravítko**, pokud pro každé přirozené  $d$  existuje přirozené  $i$  tak, že

$$(P^\omega)_i = (P^\omega)_{i+d} = -$$




# $(m, 2)$ -problém: cyklická pravítka

## Definice

$P \in \{\#, -\}^p$  nazveme (úplné) **cyklické pravítko**, pokud pro každé přirozené  $d$  existuje přirozené  $i$  tak, že

$$(P^\omega)_i = (P^\omega)_{i+d} = -$$




# $(m, 2)$ -problém: cyklická pravítka

## Definice

$P \in \{\#, -\}^p$  nazveme (úplné) **cyklické pravítko**, pokud pro každé přirozené  $d$  existuje přirozené  $i$  tak, že

$$(P^\omega)_i = (P^\omega)_{i+d} = -$$



## Věta

Uvažujme konkrétní  $(m, 2)$ -problém a délku seedů  $s$ . Označme  $\ell := m - s$ . Pak pro každé cyklické pravítko  $P$  délky  $p \leq \ell + 1$  platí:

*prefix  $P^\omega$  délky  $s$*

*řeší náš  $(m, 2)$ -problém.*

# Hlavní hypotéza

## Hypotéza

Nechť seed  $Q$  řeší  $(m, 2)$ -problém, označme  $\ell = m - s$ . Pak existuje cyklické pravítko  $P$  délky  $p \leq \ell + 1$  takové, že

- $(m, 2)$ -problém řeší také seed

$$\tilde{Q} = \text{prefix } P^\omega \text{ délky } s,$$

- $w(Q) \leq w(\tilde{Q})$ , tedy seed  $\tilde{Q}$  je alespoň stejně tak dobrý jako  $Q$ .

# Hlavní hypotéza

## Hypotéza

Nechť seed  $Q$  řeší  $(m, 2)$ -problém, označme  $\ell = m - s$ . Pak existuje cyklické pravítko  $P$  délky  $p \leq \ell + 1$  takové, že

- $(m, 2)$ -problém řeší také seed

$$\tilde{Q} = \text{prefix } P^\omega \text{ délky } s,$$

- $w(Q) \leq w(\tilde{Q})$ , tedy seed  $\tilde{Q}$  je alespoň stejně tak dobrý jako  $Q$ .

**Hlavní přínos:** Dokázalo by se, že v optimálních seedech je struktura, a při hledání těchto seedů by se významně snížila složitost algoritmů.

# Hlavní hypotéza

## Hypotéza

Nechť seed  $Q$  řeší  $(m, 2)$ -problém, označme  $\ell = m - s$ . Pak existuje cyklické pravítko  $P$  délky  $p \leq \ell + 1$  takové, že

- $(m, 2)$ -problém řeší také seed

$$\tilde{Q} = \text{prefix } P^\omega \text{ délky } s,$$

- $w(Q) \leq w(\tilde{Q})$ , tedy seed  $\tilde{Q}$  je alespoň stejně tak dobrý jako  $Q$ .

**Hlavní přínos:** Dokázalo by se, že v optimálních seedech je struktura, a při hledání těchto seedů by se významně snížila složitost algoritmů.

## Příklad $((100, 2)$ -problém, $s = 61$ )

```

49 #####-#####-----#####-##
50 #####-#####-####-----#####-#
51 #####-#####-#####-----#####-#
52 #####-####-####-#####-----#####-#
53 #####-#####-###-###-#####-#--#####-#####

```

# Hlavní hypotéza

## Hypotéza

Nechť seed  $Q$  řeší  $(m, 2)$ -problém, označme  $\ell = m - s$ . Pak existuje cyklické pravítko  $P$  délky  $p \leq \ell + 1$  takové, že

- $(m, 2)$ -problém řeší také seed

$$\tilde{Q} = \text{prefix } P^\omega \text{ délky } s,$$

- $w(Q) \leq w(\tilde{Q})$ , tedy seed  $\tilde{Q}$  je alespoň stejně tak dobrý jako  $Q$ .

**Hlavní přínos:** Dokázalo by se, že v optimálních seedech je struktura, a při hledání těchto seedů by se významně snížila složitost algoritmů.

## Příklad $((100, 2)$ -problém, $s = 61$ )

```

49 #####-#####-#####-#####-##
50 #####-#####-#####-#####-##
51 #####-#####-#####-#####-##
52 #####-#####-#####-#####-##
53 #####-#####-#####-#####-##

```

# Přiložené programy

## 1. GUI pro laserovou metodu (HTML+JS)

### Laser method for the (m,2)-problem

Seed=

m=  l=3, s=6 [Increment\\_m](#) [Decrement\\_m](#) [Clear](#)

### Incidence matrix

	1	1	0	1	1	1	0	0	1	1	1
	1	1	1	0	1	1	1	0	0	1	1
	1	1	1	0	1	1	1	0	0	1	1
#	0	0	0	0	0	0	0	0	0	0	0
#	1	1	1	0	1	1	1	0	0	1	1
#	1	1	1	0	1	1	1	0	0	1	1
#	1	1	1	0	1	1	1	0	0	1	1
#	0	0	0	0	0	0	0	0	0	0	0
#	0	0	0	0	0	0	0	0	0	0	0
	1	1	1	0	1	1	1	0	0	1	1
	1	1	1	0	1	1	1	0	0	1	1
	1	1	1	0	1	1	1	0	0	1	1

## 2. Framework pro seedy, branch&bound (C++)

## 3. Několik skriptů pro hledání opt. seedů, hladový algoritmus, atd. (Python)

# Závěr

## Shrnutí:

- i)  $(m, 1)$ -problém je nyní plně vyřešen.
- ii)  $(m, 2)$ -problém stále plně vyřešen není. V rámci této práce bylo:
  - vysloveno nové kritérium pro řešitelnost,
  - vyšetřen hladový algoritmus,
  - vylepšeny algoritmy pro hledání seedů,
  - vyslovena hypotéza o struktuře optimálních seedů.
- iii)  $(m, k)$ -problém, kde  $k > 2$ .
  - Část výsledků z  $(m, 2)$ -problému je nejspíše možné zobecnit.



# Závěr

## Co dál:

- i) Dokázat/vyvrátit hypotézu o tom, že nejlepší seedy lze získat pomocí cyklických pravítek.
- ii) Důkladně popsat vlastnosti cyklických pravítek.
  - 1 Zjistit, zda byly již v ekvivalentní formulaci studované v některé oblasti (algebra, teorie kódování, apod.).
  - 2 Zjistit, zda je úloha hledání optimálních cyklických pravítek NP-úplná.
  - 3 Popsat rychlé algoritmy pro jejich konstrukci a pro konstrukci jejich aproximací.

**Děkuji za pozornost.**