



VYSOKÉ UČENÍ FAKULTA
TECHNICKÉ STAVEBNÍ
V BRNĚ

NWB024

LOGISTIKA

03

OPTIMALIZAČNÍ METODY

Václav Venkrbec

03

Heuristické metody

Matematické metody

Rozdělení do dvou hlavních skupin:

1, Heuristické metody

klasické heuristické

meta-heuristické

hyper-heuristické

bio-inspirované

2, Matematické metody

lineární programování LP

nelineární programování NLP

smíšené celočíselné lineární programování MILP

smíšené celočíselné nelineární programování MINLP

Optimalizační metody - obecně

- skupina obecných modelů
- slouží k nalezení nejlepšího řešení problémů a modelovaných reálií
- přináší řešení: prvky konečné / ne-konečné množiny
- patří sem lineární, nelineární, dynamické a stochastické programování, vícekriteriální rozhodování, atd.

Optimalizační metody - obecně

- lze řešit širokou škálu různých technických problémů
- formulovány mohou být podobným způsobem

Optimalizační problém

účelová (kriteriální / optimalizační) funkce:

$$\mathbf{min} \mathbf{f}_{(x)}$$

(pro vektor rozhodovacích proměnných x)

kde X je množina přípustných řešení

za podmínek:

$$h_{(x)} = 0 \text{ (podmínka rovnosti)}$$

$$g_{(x)} \leq 0 \text{ (podmínka nerovnosti)}$$

Optimalizační problém

účelová (kriteriální / optimalizační) funkce:

$$\mathbf{min} \mathbf{f}_{(x)}$$

- definuje kritéria pro výběr optimálního řešení
(např. závislost zisku na množství výrobků)
- může být také maximalizována:

$$\mathbf{max} \mathbf{f}_{(x)} = - \mathbf{min} (- \mathbf{f}_{(x)})$$

Výběr metody optimalizace

Před výběrem metody řešení je nutno analyzovat problém z hlediska:

- vhodných funkcí
- omezení
- rozhodovacích proměnných

Metody mohou být:

- jedno-kriteriální
- více-kriteriální

Jedno-kriteriální metody

1, Heuristické metody

klasické heuristické

meta-heuristické

hyper-heuristické

bio-inspirované

2, Matematické metody

lineární programování LP

nelineární programování NLP

smíšené celočíselné lineární programování MILP

smíšené celočíselné nelineární programování MINLP

Heuristické metody optimalizace

Heuristika

- z řečtiny *heuriskó* – nalézt, objevit
- znamená zkusmé řešení problémů, pro něž neznáme algoritmus nebo přesnější metodu
- konvergují rozumně rychle
- často jen přibližné řešení
- založené na odhadu, intuici apod.

Heuristické metody optimalizace

Metody přímého vyhledávání

Heuristiky - většinou deterministické algoritmy

- Horolezecké algoritmy
- Simplexový algoritmus (Nelder-Mead)

Metaheuristiky - většinou stochastické algoritmy

Inspirované přírodou

Inspirované fyzikálními zákony

- Simulované žhání

Inspirované evolucí – **Evoluční algoritmy**

- Genetické algoritmy
- Evoluční strategie
- Evoluční programování

Heuristické metody optimalizace

Nejjednodušší heuristická metoda:

- pokus / omyl

Další členění heuristických metod:

- Klasické heuristické metody
- Meta-heuristické metody
- Hyper-heuristické
- Bio-inspirované

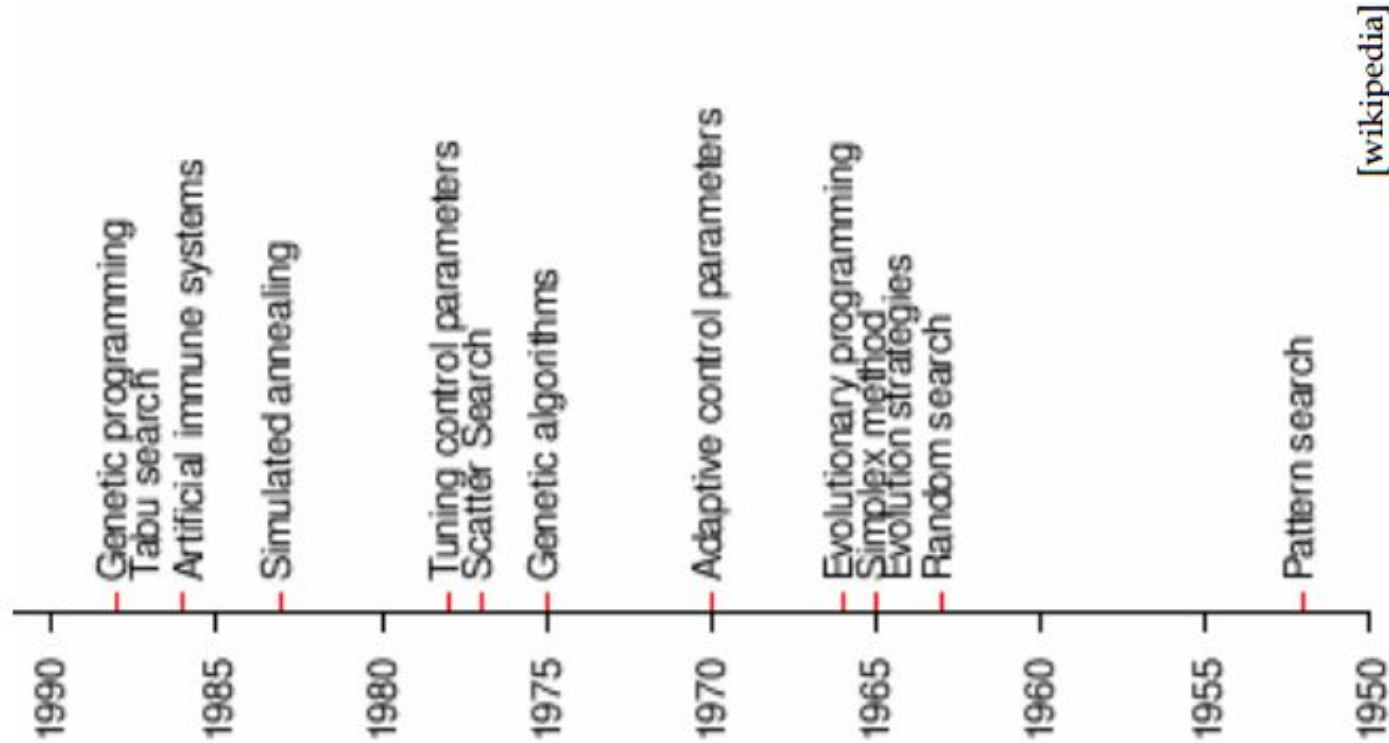
Klasické heuristické metody optimalizace

- Přímé hledání Direct search (DS)
- Evoluční strategie Evolution strategies (ES)
- **Genetické algoritmy** Genetic algorithms (GA)
- Zakázané prohledávání Tabu search (TS)
- Simulované žíhání Simulated annealing (SA)
- **Neuronové sítě** Neural networks (NN)
- Evoluční algoritmy
 - např. Diferenční evoluce Differential evolution (DE)
- Harmonické vyhledávání Harmony search (HS)

Meta-heuristické metody optimalizace

- rozšíření hlavních heuristických metod na meta- a hyper-heuristické stochastické techniky inklinují k bio-inspirovaným výpočetním metodám
- např. Algoritmy na bázi teorie hejna:
 - Opt. mravenčí kolonií Ant colony opt. (ACO)
 - Opt. hejnem částic Particle swarm opt. (PSO)
 - Opt. hejnem světlušek Firefly algorithm (FA)
 - Opt. včelím rojem Artificial bee colony (ABC)

Historie Meta-heuristických metod optimalizace




Bio-inspirované metody optimalizace

- Optimalizace chování bakteriální Bacterial foraging optimization (BFO)
- Kukaččí algoritmus Cuckoo search (CS)
- Netopýří algoritmus Bat algorithm (BA)
- Algoritmus principu opylování Flower pollination algorithm (FPA)
- Optimalizace umělou rostlinou Artificial plant optimization (APO)
- Algoritmus vlčího hledání Wolf search algorithm (WSA)

Bio-inspirované metody optimalizace

Autor většiny algoritmů:



Xin-She Yang

Oxford University UK

(od 2008 - dosud)

Genetické algoritmy

- snaží se aplikací principů evoluční biologie nalézt řešení složitých problémů, pro které neexistuje použitelný exaktní algoritmus
- postupná tvorba generací různých řešení daného problému

Genetické algoritmy

Jednoduchý GA lze zapsat, jako posloupnost kroků:

1. **Vytvoření počáteční populace** (většinou náhodné)
2. **Ohodnocení** populace (vyhodnocení FF)
3. **Selekce** - výběr rodičovských párů
4. **Křížení** - vytvoření potomků
5. **Mutace** - použita na nové jedince
6. **Ohodnocení** - spočtení FF pro nové jedince
7. **Vytvoření nové populace** - z potomků a části minulé generace
8. **Testování** koncové podmínky - pokud není splněna, pokračuje se krokem
9. **Výsledek** - určený nejlepším jedincem v populaci

Genetické algoritmy

Operátory genetických algoritmů

Selekce (Selection)

Cílem je vybrat vhodné rodičovské páry pro vytvoření nových potomků.

Křížení (Crossover)

Ze dvou rodičovských chromozomů (v klasickém pojetí) vytvoří jeden (či více) nový chromozom potomka

Mutace (Mutation)

Na výsledné potomstvo se aplikuje ještě další genetický operátor – mutace.

Náhodně mění hodnotu jednotlivých genů

Genetické algoritmy

Operátory genetických algoritmů

Strategie obměny populace (generational replacement strategy)

Poté co jsou pomocí selekce, křížení a mutace vygenerováni noví jedinci, je třeba obměnit stávající populaci za novou:

- Ryzí obměna
- Doplnění

Příklady GA:

<https://www.youtube.com/watch?v=iV-hah6xs2A>

<https://youtu.be/XcinBPhgT7M>

https://youtu.be/9MQNW35Or_E

Příklady optimalizačních metod v praxi

Optimalizace problému umístění objektů zařízení staveniště pomocí genetického algoritmu




Fig. 4. Illustrated example for space detection.

Zdroj:

H. M. Osman, M. E. Georgy, and M. E. Ibrahim, "A hybrid CAD-based construction site layout planning system using genetic algorithms", Automation in Construction, vol. 12, no. 6, pp. 749-764, 2003

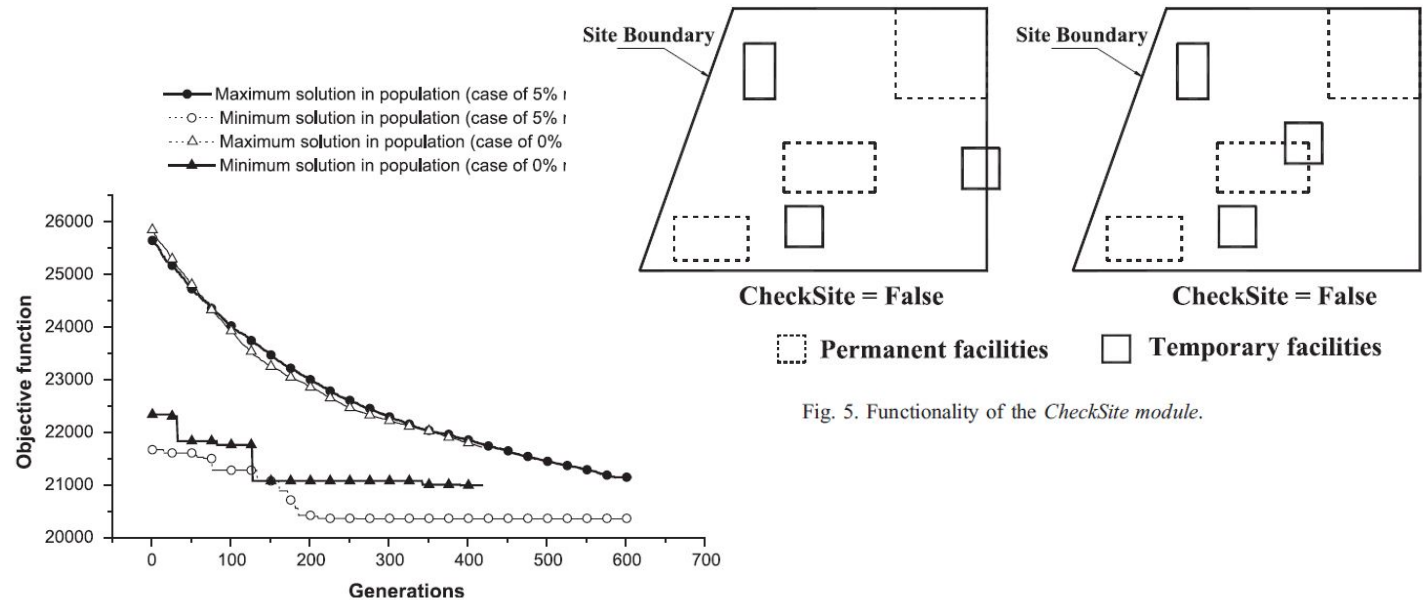


Fig. 10. Convergence of population parameters at different levels of mutation.

Fig. 5. Functionality of the *CheckSite* module.

Příklady optimalizačních metod v praxi

Optimalizace problému dopravních tras na staveništi a umístění zařízení staveniště pomocí GA



Figure 5. Comparison of layouts from linear distance and actual travel distance driven optimization

The objective function was mathematically defined as:

$$\text{Min} \sum_{p=1}^N \sum_{i=1}^{n-1} \sum_{j=i+1}^n d_{ijp} R_{ijp} f_{ijp} P_{ijp} \quad (3)$$

$$\text{s.t.} \quad \sum_{p=1}^N \sum_{i=1}^{n-1} \sum_{j=i+1}^n e_{ijp} P_{ijp} \leq S_{ijp} \quad (4)$$

$$e_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (5)$$




Figure 3. Linear and Actual Travel Paths

Zdroj:

J. C. P. Cheng and S. S. Kumar, "A BIM based construction site layout planning framework considering actual travel paths", in 31st International Symposium on Automation and Robotics in Construction and Mining, ISARC 2014 - Proceedings, 2014, pp. 450-457.

Příklady opti. metod v praxi

Optimální umístění sestavy jeřábů pomocí algoritmu světlušek (FA)

Distance: The distance between any two fireflies i and j at x_i and x_j is the Cartesian distance as follows:

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (4)$$

where $x_{i,k}$ is the k -th component of the i -th firefly.

Movement: The movement of a firefly, i is attracted to another more attractive (brighter) firefly j , is determined by

$$\bar{x}_i = x_i + \beta(r) \times (x_i - x_j) + \alpha \left(r - \frac{1}{2} \right) \quad (5)$$

where the second term is due to the attraction while the third term is randomization with α being the randomization parameter and r is a random number generator uniformly distributed in $[0, 1]$. In this paper,

Hence, the minimal average transportation time for all crane hooks is

$$\min f_2(x) = \min ATT(x, y) = \frac{1}{K} \min \sum_{i=1}^I \sum_{j=1}^J T_i^j \quad (2)$$




Figure 2 movement of hook during transportation




Figure 3 vertical transportation distance of hook

Zdroj:

Příklady opti. metod v praxi

Optimální umístění sestavy jeřábů pomocí algoritmu světlušek (FA)

Optimální řešení




Figure 4. The optimal tower crane layout scheme




Figure 6. Tower cranes installation heights in stage two

Zdroj:

J. Wang, J. Liu, W. Shou, X. Wang, and L. Hou, "Integrating building information modelling and firefly algorithm to optimize tower crane layout", in 31st International Symposium on Automation and Robotics in Construction and Mining, ISARC 2014 - Proceedings, 2014, pp. 321-328.

Příklady opti. metod v praxi


Optimální umístění sestavy jeřábů pomocí algoritmu světlušek (FA) a informačního modelu budovy (BIM)

$$\min TC = \min \sum_{k=1}^K \sum_{i=1}^I \sum_{j=1}^J T_{ij}^k \times Q_{ij}^k \times C^k \quad (1)$$


$$\sum_{k=1}^K \sum_{j=1}^J Q_{ij}^k \leq Q_{S_i} \quad (2)$$

$$\sum_{k=1}^K \sum_{i=1}^I Q_{ij}^k = Q_{D_j} \quad (3)$$

where K is the number of cranes; I is the number of supply points; J is the number of demand points; T_{ij}^k is the travel time from i -th supply point (S_i) to j -th demand point (D_j) by k -th crane; Q_{ij}^k is quantity of material flow from S_i to D_j by k -th crane; C^k is cost of material flow per unit quantity and unit time by k -th crane; Q_{S_i} is the total supply capacity of S_i ; and Q_{D_j} is the total demand quantity of D_j .



a: Results from mathematical model



b: Final results after modification


Fig. 10. a: Results from mathematical model. b: Final results after modification.

Zdroj:

J. Wang, X. Zhang, W. Shou, X. Wang, B. Xu, M. J. Kim, and P. Wu, "A BIM-based approach for automated tower crane layout planning", *Automation in Construction*, no. vol. 59, pp. 168-178, 2015.

Příklady opti. metod v praxi

Optimální umístění sestavy jeřábů pomocí algoritmu světlušek (FA) a informačního modelu budovy (BIM)



Zdroj:

Fig. 8. 3D visualisation for the final optimal tower crane layout.

J. Wang, X. Zhang, W. Shou, X. Wang, B. Xu, M. J. Kim, and P. Wu, "A BIM-based approach for automated tower crane layout planning", *Automation in Construction*, no. vol. 59, pp. 168-178, 2015.

Jedno-kriteriální metody

1, Heuristické metody

klasické heuristické

meta-heuristické

hyper-heuristické

bio-inspirované

2, Matematické metody

lineární programování LP

nelineární programování NLP

smíšené celočíselné lineární programování MILP

smíšené celočíselné nelineární programování MINLP



VYSOKÉ UČENÍ FAKULTA
TECHNICKÉ STAVEBNÍ
V BRNĚ

NWB024

LOGISTIKA

03

DĚKUJI ZA POZORNOST

Václav Venkrbec