

# Grammar-based genetic programming

Obhajoba diplomové práce

Adam Nohejl

Vedoucí práce: RNDr. František Mráz, CSc.  
Katedra software a výuky informatiky, MFF UK Praha

2011

1 Úvod do problematiky: genetické programování

2 Cíle práce

3 Výsledky práce


4 Reference

# Genetické programování (tradiční verze)

Genetické programování jako druh **evolučního algoritmu**:

**Reprezentace**: stromy programů v podmnožině LISPu.


**GP strom**:



**GP funkce**: \*, expt (binární)

**GP terminály**: 2, c, m

**Odpovídající derivační strom**:



**Odpovídající pravidla gramatiky**:

$E \rightarrow (* E E)$      $E \rightarrow (\text{expt } E E)$

$E \rightarrow 2$                      $E \rightarrow c$                      $E \rightarrow m$

**Reprezentovaný výraz**: (\* m (expt c 2))

**Operátory**: na stromech; respektují množiny funkcí a terminálů.

**Zbývá**: interpretovat výstup programů, přiřadit fitness.

# Genetické programování: problémy

- **Jazyk jedinců**

Je vše vhodné programovat v LISPU?

- **Typy**

Co když problém zahrnuje více datových typů?

- **obecněji: Uzávěr (*closure*)**

Může být každý GP terminál a výstup každé GP funkce libovolným argumentem libovolné GP funkce?

- **Dostatečnost (*sufficiency*)**

Umožňují zvolené GP funkce a GP terminály vyřešit problém?

- **obecněji: Deklarativní reprezentace znalostí**

Jak zachytit jemnější znalosti o problému a zefektivnit tak jeho řešení?



# Genetické programování založené na gramatice

Změny oproti tradičnímu GP:

- místo GP stromů: derivační stromy,
- místo množin funkcí a terminálů: pravidla formální gramatiky.

**Přínos:** lze popsat jazyk, typový systém i znalosti o problému.

**Trade-off:** vyjadřovací schopnost  $\times$  efektivita operátorů GP.

- **CFG-GP** (Whigham '95): bezkontextová gramatika (CFG), operace na derivačních stromech.
- **LOGENPRO** (Wong & Leung '95): logická gramatika, potenciálně Turingovsky úplná, operace na deriv. stromech.
- **Grammatical Evolution** (Ryan & O'Neill '98): CFG, ale stromy zakódované jako řetězce čísel výběrů v pořadí nejlevější derivace, operace na nich.

1 Úvod do problematiky: genetické programování

2 Cíle práce

3 Výsledky práce

4 Reference

V literatuře chybí srovnání mezi CFG-GP, GE, LOGENPRO. LOGENPRO a GE byly aplikovány především svými autory. Operátory GE na číselných řetězcích: efekt na stromy? Vyplatí se silný formalismus LOGENPRO?

## Cíle:

- Popsat, srovnat a (vyjma LOGENPRO) implementovat.
- Porovnat výsledky experimentů v různých aplikacích.

## Důraz kladen na

- kvalitní implementaci,
- reprodukovatelnost výsledků,
- ověření proklamovaných výhod metod,
- alespoň empirické zhodnocení efektů operátorů GE.

1 Úvod do problematiky: genetické programování

2 Cíle práce

3 Výsledky práce

4 Reference



Při pečlivém čtení publikovaných výsledků LOGENPRO se ukazuje, že logické predikáty i unifikace se užívají **triviálně** → zbývá: CFG. **Dva experimenty** podle Wanga & Leunga (2000) s jejich implementací LOGENPRO a mojí implementací CFG-GP a GE:

- Konečný **typový systém** lze snadno popsat CFG.
- **Generování náhodných konstant** pomocí logického predikátu lze nahradit sadou pravidel, navíc je v dané aplikaci zbytečné.
- Celkově: **slabší metody** CFG-GP a GE dávají **podobné výsledky** jako LOGENPRO.

# Operátory GE: většinou stejné nebo horší výsledky

Srovnával jsem statistiky výšky a košatosti stromů během generací evoluce u GE a CFG-GP.

- GE má tendenci produkovat nižší stromy, méně košaté, méně různorodých tvarů → **menší prohledávaný prostor**.
- Přitom jsou operátory poměrně **destruktivní**.

Ve speciálních případech může být chování GE výhodné.

Ve většině experimentů to však vedlo k až o řád horším výsledkům.


**Příklad špatného fungování:**

automaticky definované funkce

(„stavební bloky“): **podstromy**

**se řídí odlišnými částmi gramatiky.**

Obrázek: proměnná  $z$  v ADF; funkce  $f$   
a proměnné  $x, y$  v hlavním programu.



# GE není nutně časově efektivnější

Nejnáročnější je **operace křížení**, při které se vyměňují kompatibilní podstromy dvou stromů:

- **GE**: **jednoduchá** implementace, navíc asymptoticky:  $O(m + n)$ , kde  $m$ ,  $n$  jsou počty vrcholů stromů.
- **CFG-GP**: náročnější implementace, asymptoticky  $O(mn)$ , ale pokud se implementuje dobře, je **praktický rozdíl malý**, navíc podstatně náročnější je pak vyhodnocování jedinců.
- **LOGENPRO**: asymptoticky  $O(mn \log m)$  s **vysokou multiplikační konstantou** (unifikace) a za předpokladu vyvážených stromů (logaritmická hloubka).

LOGENPRO: velmi náročné pro „pravé“ logické gramatiky, zbytečná režie pro CFG. U GE ale může být **celkový běh algoritmu** delší než u CFG-GP (uvidíme později).

# Rozvrhování zkoušek: pěkné výsledky CFG-GP i GE

Bader-El-Den et al. (2009): článek o zajímavé aplikaci GP s gramatikou (varianta CFG-GP) skoro z reálného světa: **rozvrhování zkoušek**. Zavedený problém (Carter '96) s mnoha vyzkoušenými heuristikami. **Hyperheuristický** přístup. Mé výsledky pro 5 datových sad z 10, kde CFG-GP a GE dopadly zvláště dobře:

	car91	car92	tre92	uta92	yor83
Bader-El-Den	5.12	4.46	8.62	3.47	40.56
CFG-GP	5.11	4.44	8.78	3.49	40.73
GE	5.15	4.44	8.63	3.51	40.60
CFG-GP*	5.13	4.37	8.63	3.44	40.94
GE*	5.22	4.51	8.79	3.44	41.47
Nejlepší jiná	Fuzzy 5.20	Fuzzy 4.52	Fuzzy 8.67	TM 3.04	Fuzzy 40.66

\*: mnou zvolená gramatika. Nejlepší jiná: z konstruktivních heuristik, podle Bader-el-Den et al. (2009). **1.** a **2.** nejlepší výsledek. TM: Tabu-Multi-stage.

## Shrnutí výsledků

- **Efektivní implementace** GE a CFG-GP: o řád rychlejší než jiné. **Rozsáhlé srovnání** těchto metod a LOGENPRO.
- Ve vybraných úlohách (používaných i autory LOGENPRO) **se neprokázala výhodnost logických gramatik.**
- GE dosahovala **obvykle horších výsledků**: rozbor příčin.
- V **reálné aplikaci rozvrhování zkoušek**: podobné výsledky jako Bader-El-Den et al. (2009), s některými sadami dat i lepší (CFG-GP). Ukázal jsem, že lze zvolit **výhodnější gramatiku.**

Výsledky naznačují, že přínosnější než sofistikované metody GP založeného na gramatikách by mohly být metody generování (evoluce) gramatik vhodných pro úlohu.

1 Úvod do problematiky: genetické programování

2 Cíle práce

3 Výsledky práce

4 Reference

# Reference

- Mohamed Bahy **Bader-El-Den**, Riccardo Poli, and Shaheen Fatima. Evolving timetabling heuristics using a grammar-based genetic programming hyperheuristic framework. *Memetic Computing*, 1(3):205–219, 2009.
- Michael W. **Carter**, Gilbert Laporte, and Sau Yan Lee. Examination timetabling: Algorithmic strategies and applications. *J Oper Res Soc*, 47(3):373–383, 03 1996.
- Michael **O'Neill** and Conor **Ryan**. *Grammatical Evolution: Evolutionary Automatic Programming in an Arbitrary Language*. Springer, 2003.
- Peter **Whigham**. Inductive bias and genetic programming. In *First International Conference on Genetic Algorithms in Engineering Systems: Innovations and Applications, GALESIA*, pages 461–466, 1995.
- Man Leung **Wong** and Kwong Sak **Leung**. *Data Mining Using Grammar-Based Genetic Programming and Applications*. Kluwer Academic Publishers, Norwell, MA, USA, 2000.