

# Рачунарска интелигенција

Генетско програмирање

Александар Картељ

[kartelj@matf.bg.ac.rs](mailto:kartelj@matf.bg.ac.rs)

Ови слајдови представљају прилагођење слајдова:

A.E. Eiben, J.E. Smith, Introduction to Evolutionary computing: Genetic programming

# Генетско програмирање

- Развијено у Америци 90-тих година, J. Koza
- Обично се примењује у:
  - машинском учењу (предикција, класификација...)
- Конкурентан неуронским мрежама и сличним методама
  - Али захтева огромне популације (хиљаде јединки)
  - Релативно спор
- Специјлане карактеристике:
  - Нелинеарни хромозоми: стабла, графови
  - Мутација могућа, али није неопходна

# GP техничке карактеристике

Репрезентација	Стабло
Укрштање	Размена подстабала
Мутација	Случајна промена у дрвету
Селекција родитеља	Фитнес сразмерна
Селекција преживелих	Генерацијска замена

# Уводни пример: одређивање кредитне способности

- Банка хоће да направи разлику између добрих и лоших кандидата за давање позајмица
- Потребно је узети у обзир историјске податке

ID	Број дјече	Плата	Брачни статус	OK?
ID-1	2	45000	Married	0
ID-2	0	30000	Single	1
ID-3	1	40000	Divorced	1
...				

# Уводни пример: одређивање кредитне способности (2)

- Могући модел:

IF (број деце = 2) AND (плата > 80000) THEN добар ELSE лош

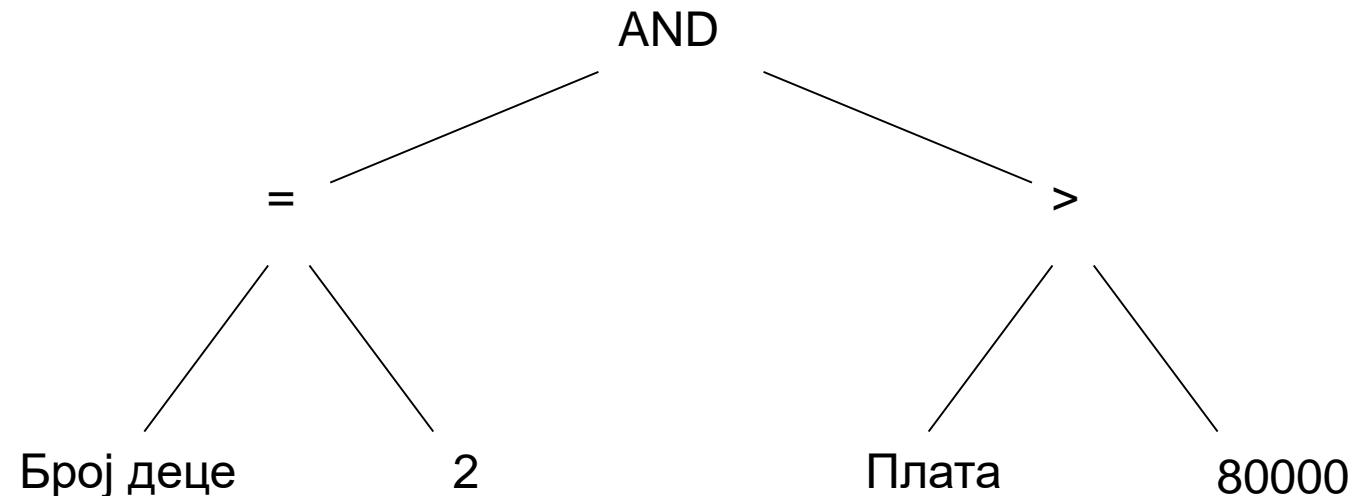
- Општи приступ:

IF формула THEN добар ELSE лош

- Непозната је формула по којој се одређује?
- Простор претраге (фенотип) је скуп свих формула
- Фитнес формуле: проценат добро класификованих примера
- Природна репрезентација формуле (генотип) је стабло

# Уводни пример: одређивање кредитне способности (3)

IF (број деце = 2) AND (плата > 80000) THEN добар ELSE лош  
се може представити следећим стаблом:

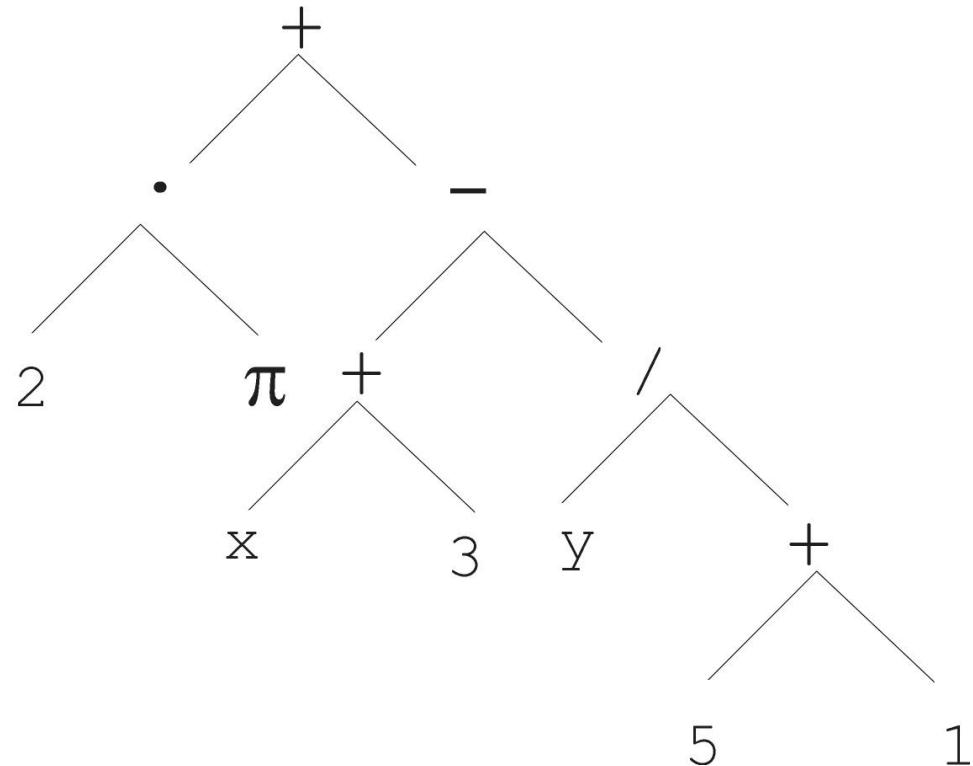


# Репрезентација стабла

- Стабла имају способност представљања великог броја формула
- Аритметичка формула
$$2 \cdot \pi + \left( (x + 3) - \frac{y}{5 + 1} \right)$$
- Логичка формула
$$(x \wedge \text{true}) \rightarrow ((x \vee y) \vee (z \leftrightarrow (x \wedge y)))$$
- Програм

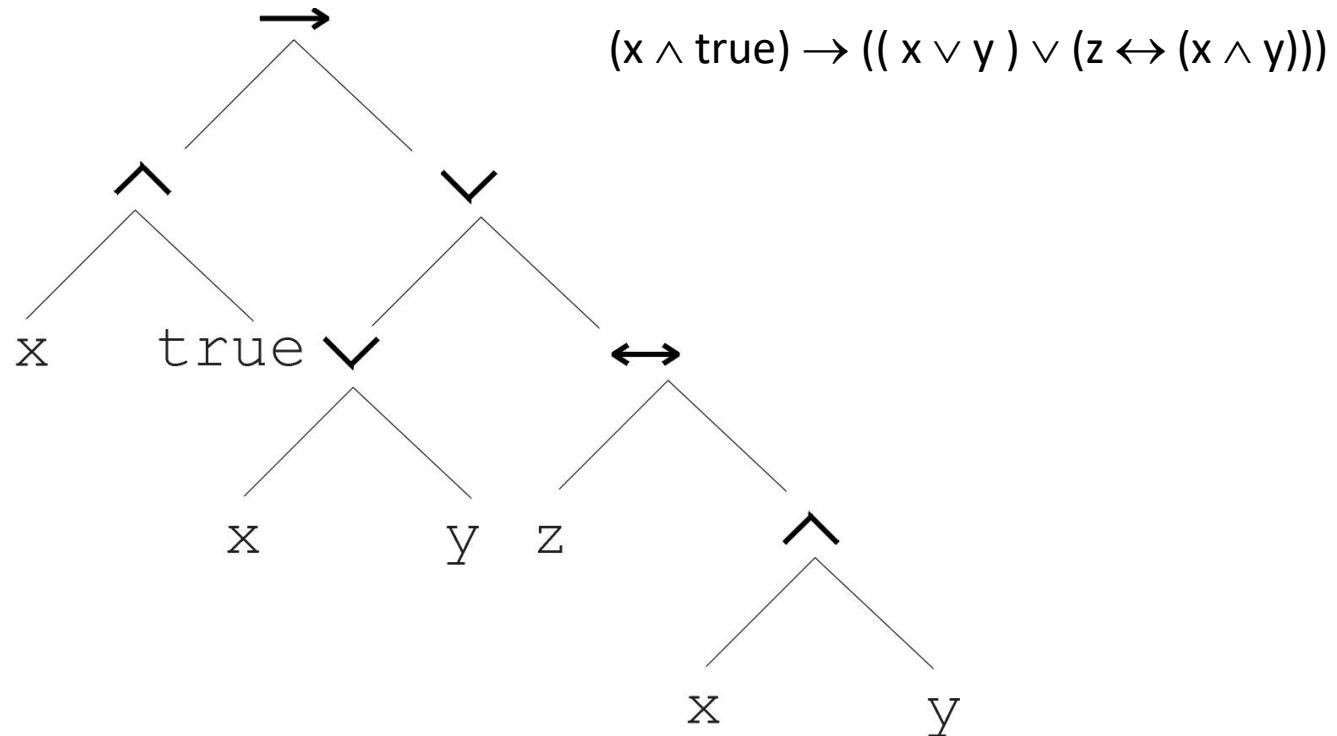
```
i =1;  
while (i < 20)  
{  
    i = i +1  
}
```

# Репрезентација стабла (2)

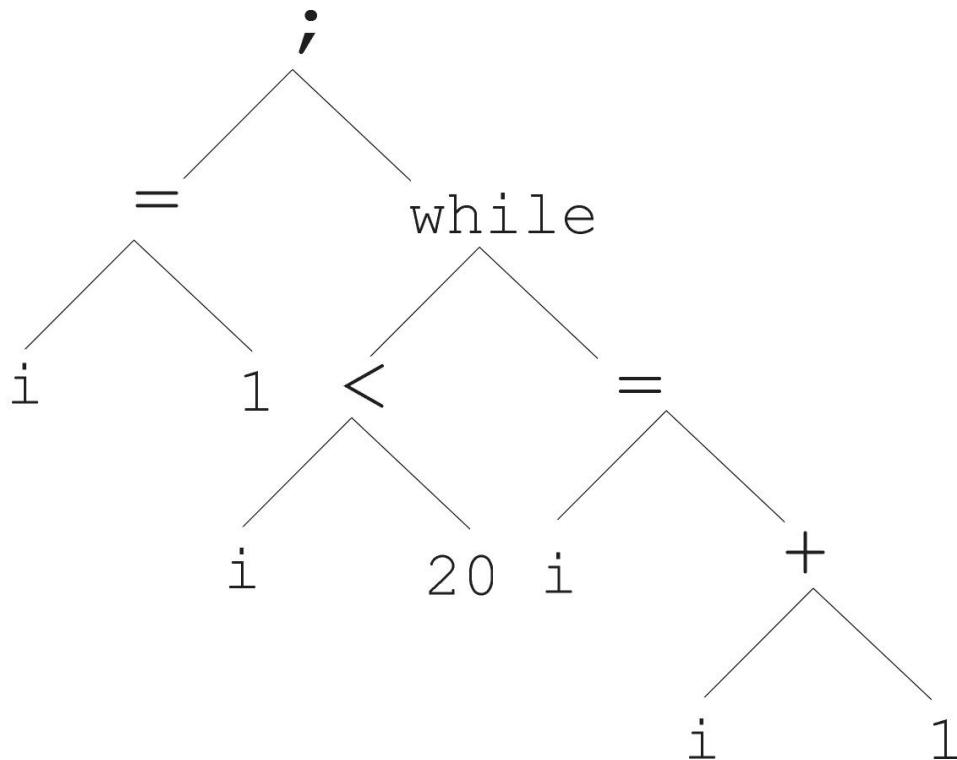


$$2 \cdot \pi + \left( (x + 3) - \frac{y}{5 + 1} \right)$$

# Репрезентација стабла (3)



# Репрезентација стабла (4)



```
i =1;  
while (i < 20)  
{  
    i = i +1  
}
```

# Репрезентација стабла (5)

- У генетским алгоритмима (GA), еволутивним стратегијама (ES), еволутивном програмирању (EP), хромозоми су линеарне структуре
  - Низови битова
  - Низови целих бројева
  - Низови реалних бројева
  - Пермутације
  - ...
- Стабло-хромозоми су нелинеарне структуре
- Код GA, ES, EP, величина хромозома је фиксна
- Стаблау GP могу да имају произвољну дубину и ширину

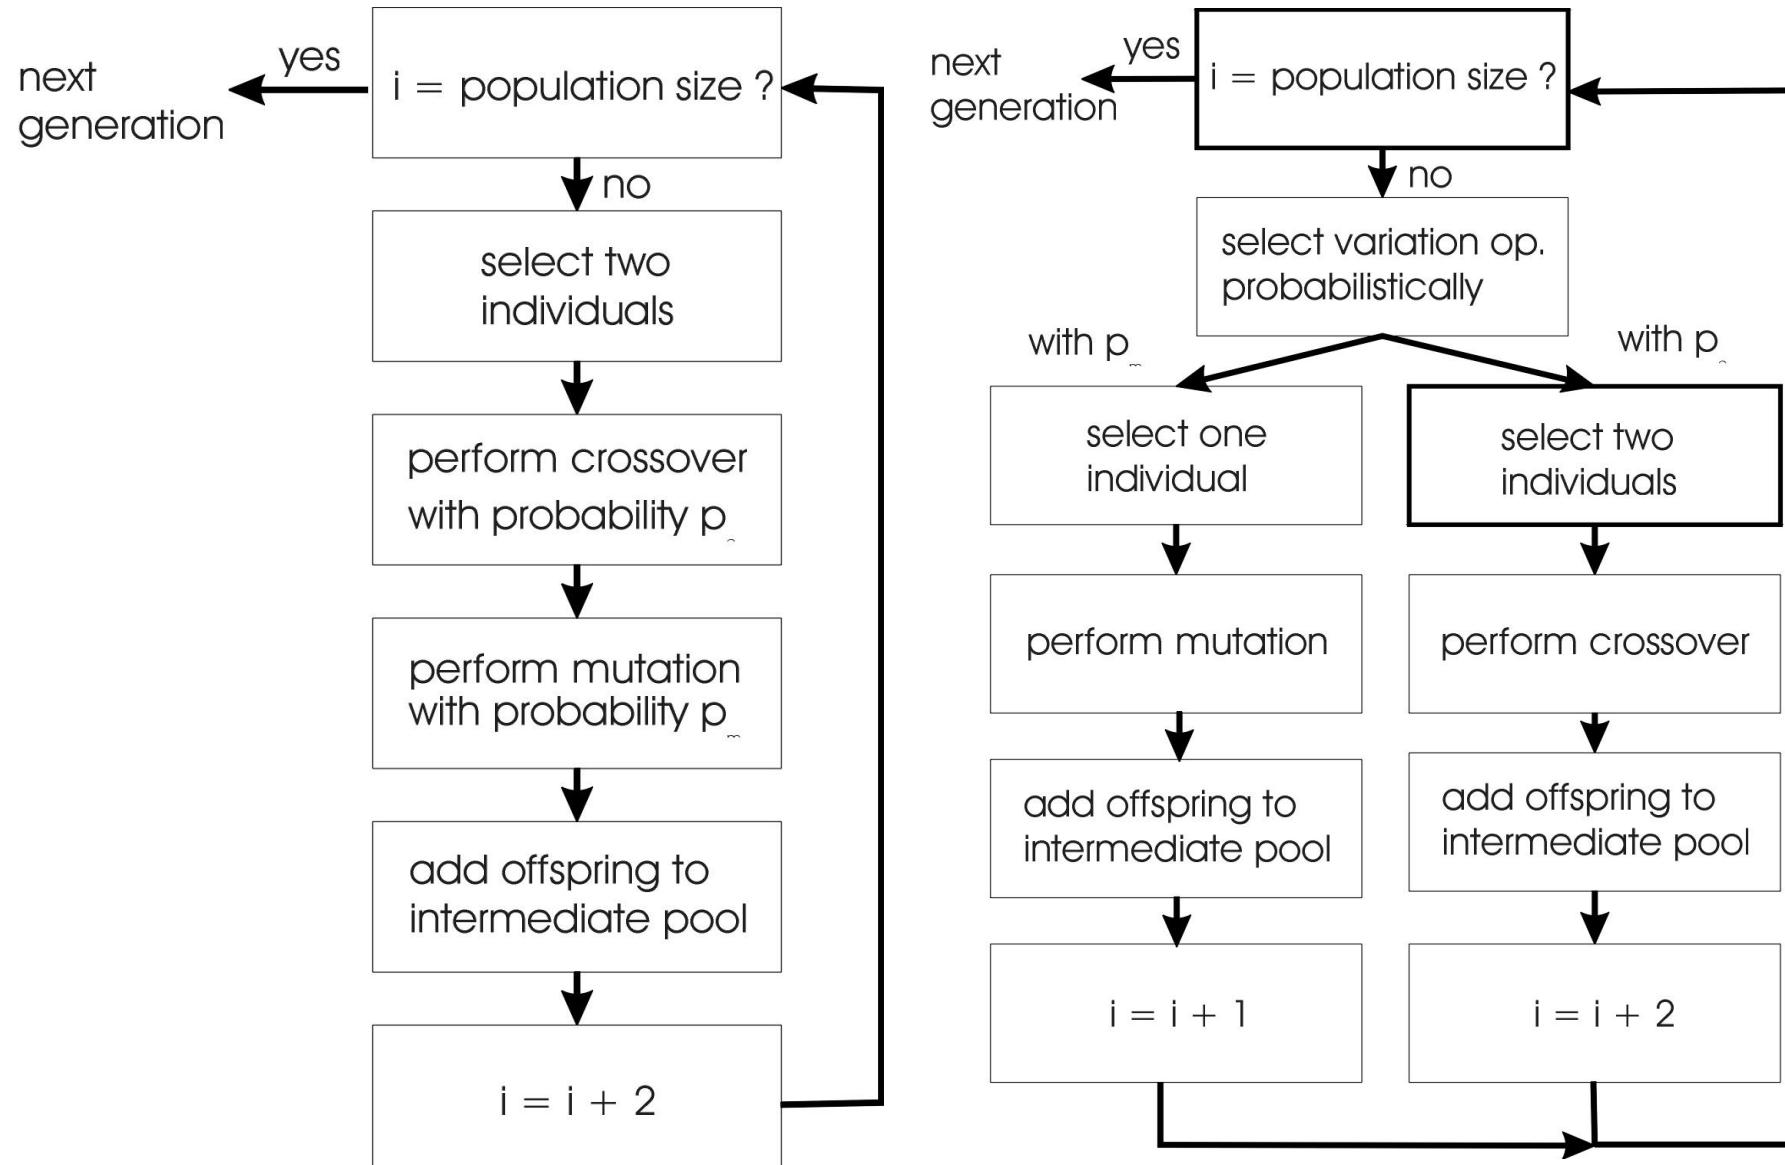
# Репрезентација стабла (6)

- Симболички изрази могу бити дефинисани помоћу
  - Скупа термова  $T$
  - Скупа функција  $F$  (са придрженим арностима)
- Потом се може користити следећа рекурзивна дефиниција:
  1. Сваки  $t \in T$  је коректан израз
  2.  $f(e_1, \dots, e_n)$  је коректан израз ако  $f \in F$ ,  $\text{arity}(f)=n$  и  $e_1, \dots, e_n$  су коректни изрази
  3. Не постоје друге коректне форме израза
- У општем случају, изрази у GP нису типизирани  
(сваки  $f \in F$  може узети било који  $g \in F$  као аргумент)

# Генерисање потомака

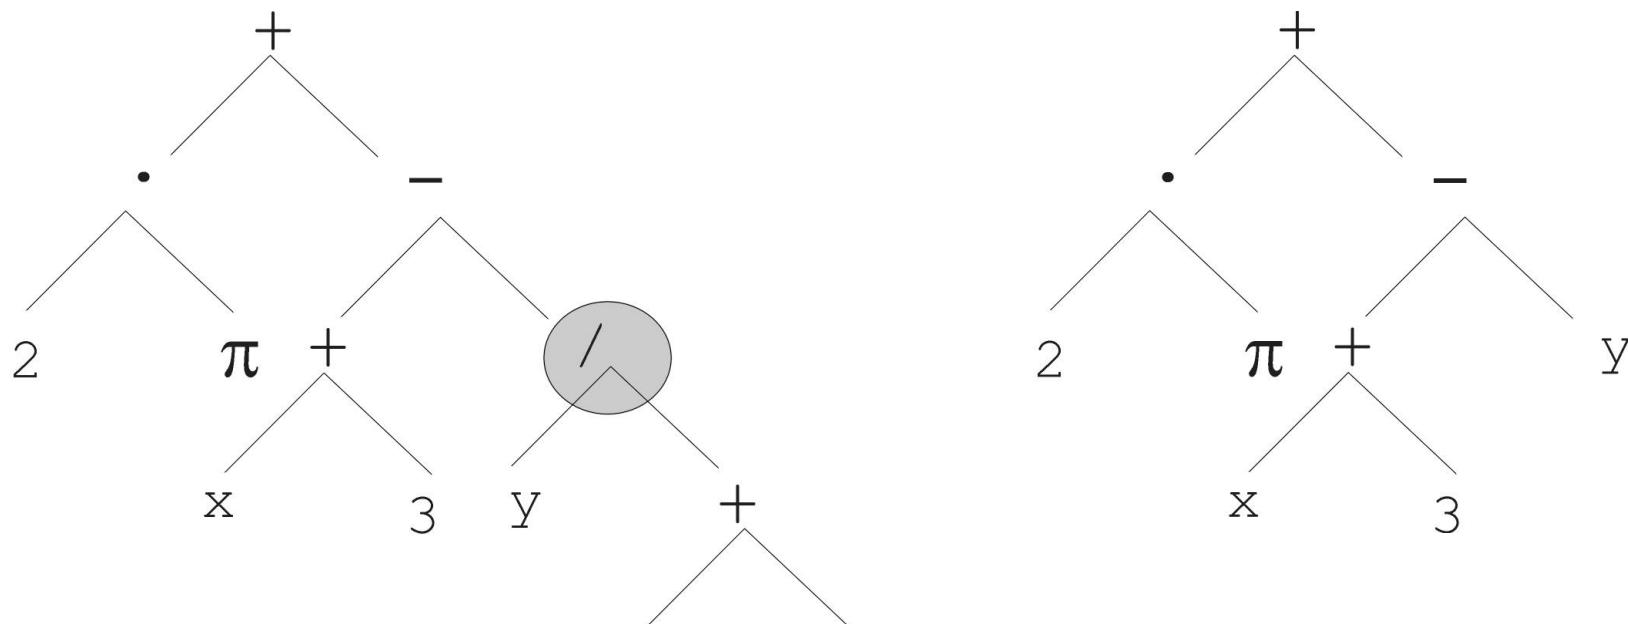
Поређење:

- GA користи укрштање **И** мутацију секвенцијално (случајно)
- GP користи укрштање **ИЛИ** мутацију (случајно)



# Мутација

- Најчешћи оператор мутације:  
замени случајно одабрано подстабло  
новим случајно генерисаним стаблом

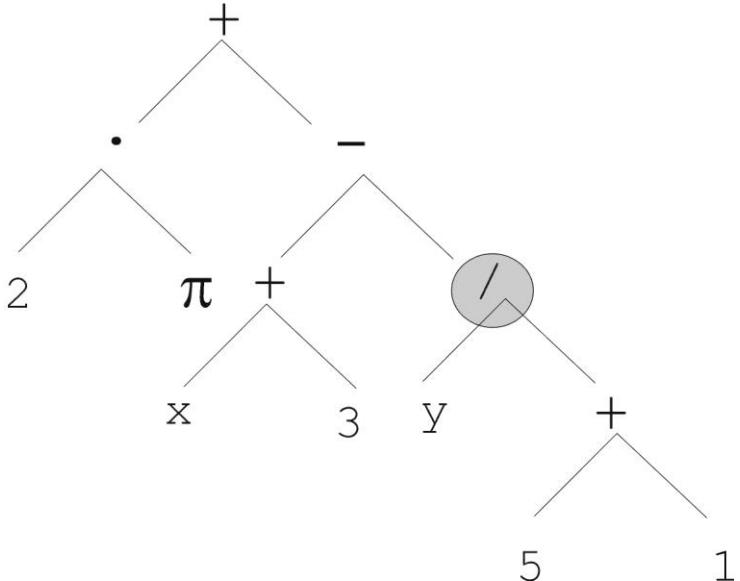


# Мутација (2)

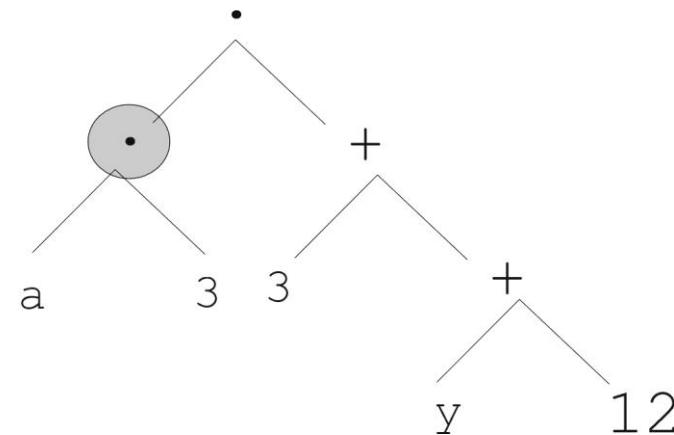
- Мутација има два параметра:
  - Вероватноћа  $p_m$  одабира мутације (у супротном укрштање)
  - Вероватноћа одабира унутрашње тачке (корена подstabла)
- Савет је да  $p_m$  буде 0 (Koza'92),  
или јако блиско 0, нпр. 0.05 (Banzhaf et al. '98)
- Величина детета може да буде већа од величине родитеља

# Укрштање

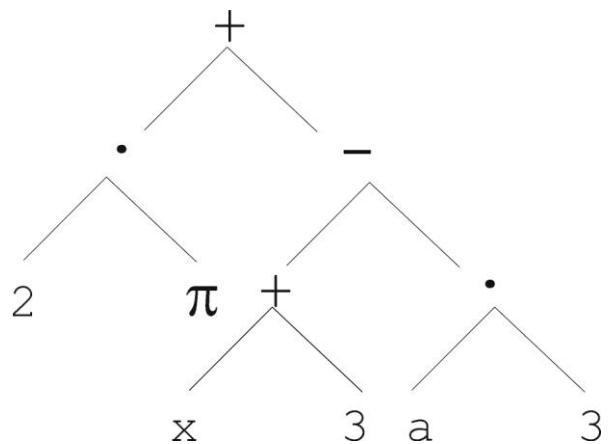
- Најчешћи оператор укрштања:  
замена два случајно одабрана подstabla између родитеља
- Укрштање има два параметра:
  - Вероватноћа  $r_c$  за одабир укрштања (или мутације у супротном)
  - Вероватноћа одабира унутрашње тачке (корена подstabla) као позиције за укрштање код сваког од родитеља
- Величина детета може да буде већа од величине родитеља



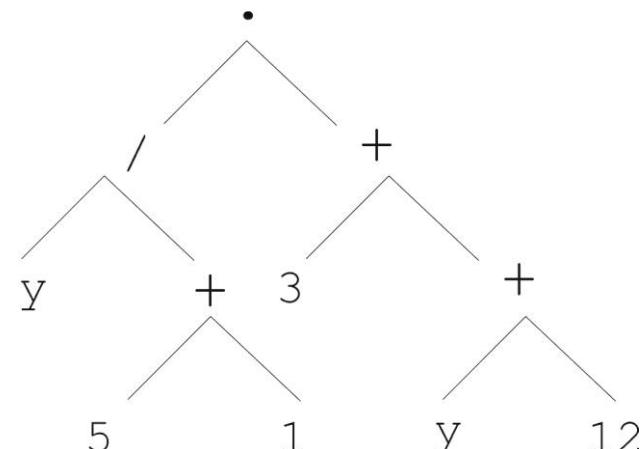
Родитель 1



Родитель 2



Дете 1



Дете 2

# Селекција

- Селекција родитеља је обично фитнес-сразмерна
- Селекција у веома великим популацијама
  - Рангирај популацију према фитнесу и подели их у две групе:
  - група 1: најбољих  $x\%$  популације
  - група 2 осталих  $(100-x)\%$
  - 80% операција селекције изврши над групом 1, преосталих 20% над групом 2
  - За популације величине = 1000, 2000, 4000, 8000  $x = 32\%, 16\%, 8\%, 4\%$
  - Ови проценти су одређени емпиријски
- Селекција преживелих:
  - Стандардни приступ: генерацијски
  - Модел са стабилним стањем и елитизмом постаје популаран у последње време

# Иницијализација популације

- Поставља се максимална дубина стабла  $D_{max}$
- Балансирани приступ (тежи се ка балансираном стаблу дубине  $D_{max}$ ):
  - Чвоорви на дубини  $d < D_{max}$  се случајно бирају из скупа функција  $F$
  - Чворови на дубини  $d = D_{max}$  се случајно бирају из скупа термова  $T$
- Ограничени приступ (тежи се ка стаблу ограничене дубине  $\leq D_{max}$ ):
  - Чворови на дубини  $d < D_{max}$  се случајно бирају из скупа  $F \cup T$
  - Чворови на дубини  $d = D_{max}$  се случајно бирају из скупа  $T$
- Стандардна GP иницијализација:  
комбиновани приступ који користи и балансирани и ограничени приступ  
(сваки по пола популације)

# Приступ заснован на повећавању

- Bloat = „тенденција ка удебљавању”, стабла унутар популације током времена расту
- Дебата у научним истраживањима
  - Сетимо се „окамове бритве“
- Потребне су контрамере, e.g.
  - Спречавање употребе оператора који доводе до „превелике“ деце
  - Пенализација „превеликих“ јединки

# Пример примене: символичка регресија

- За дате тачке у  $\mathbb{R}^2$ ,  $(x_1, y_1), \dots, (x_n, y_n)$
- Пронађи функцију  $f(x)$  такву да  $\forall i = 1, \dots, n : f(x_i) = y_i$
- Могуће GP решење:
  - Дати функцијски симболи  $F = \{+, -, /, \sin, \cos\}$ , и термови  $T = \mathbb{R} \cup \{x\}$
  - Фитнес представља грешку  $err(f) = \sum_{i=1} (f(x_i) - y_i)^2$
  - Стандардни оператори
  - Величина популације= 1000, употреба приступа пола-пола

# Дискусија

Да ли се GP:

Може користити за еволуцију рачунарских програма?

Шта је са другим репрезентацијама поред стабла?