


**ARTGORITMY / P**

# **EVOLUČNÍ ALGORITMY**



**Výstupy počítačového umění jsou typicky generovány jednoduchými algoritmy s numerickými parametry**

funkční hodnoty rovnic, koeficienty transformací...

**Další parametry lze zadávat interakčně**

výběr barev, textur, parametrů štětce...


**Pokud máme představu, jak má výstup vypadat, ale nevíme, jakými parametry k němu dospět**

(nebo má-li být výstup neobvyklý a překvapující),

**můžeme se s výhodou inspirovat**

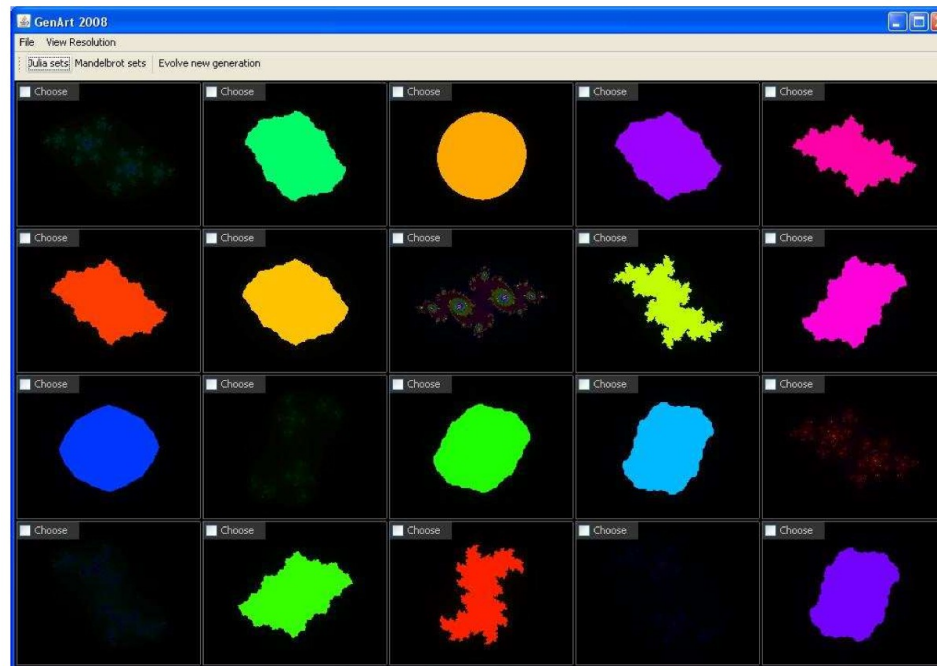
**biologickými procesy**

## Genetické algoritmy




Parametrický prostor obrazu je popsán chromozomem s genetickou informací  
= výčtem stavebních prvků obrazu

Počáteční stav populace může být generován náhodně nebo dle vhodných pravidel



➔ *Evofractal*

➔ *Evolvotron*



**Výběr perspektivních jedinců je obvykle interakční – podle vkusu uživatele**

ale může být i výstupem estetických algoritmů modelujících funkci „*fitness*“ chromozomu (v přírodě: přežití, šíření genů)

1-Point

Rodič 1  
1 0 1 1 1 0 1 0

Rodič 2  
1 1 1 0 1 0 0 1

Potomek 1  
1 0 1 0 1 0 0 1

Potomek 2  
1 1 1 1 1 0 1 0

2-Point

Rodič 1  
1 0 1 1 1 0 1 0

Rodič 2  
1 1 1 0 1 0 0 1

Potomek 1  
1 0 1 0 1 0 1 0

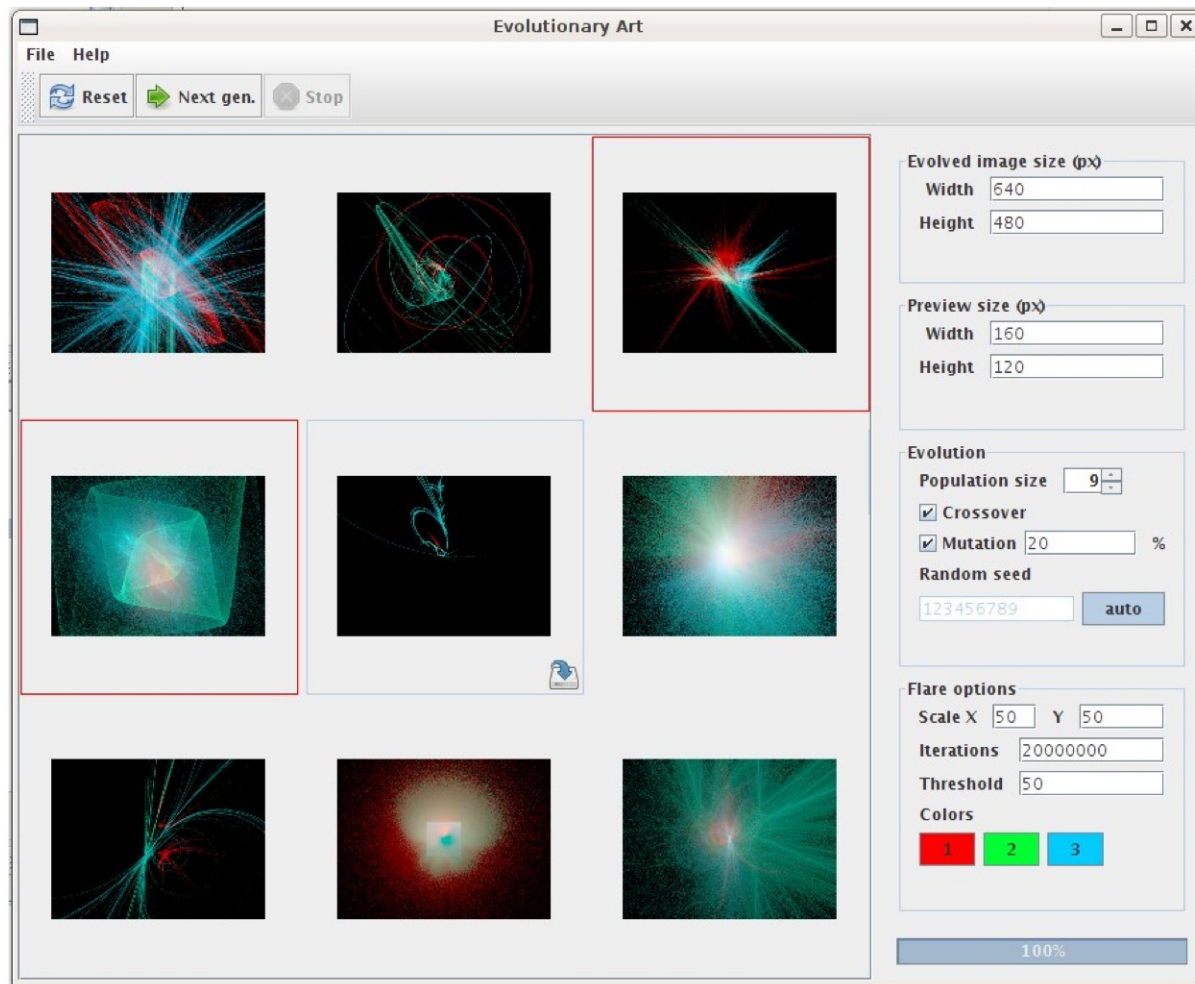
Potomek 2  
1 1 1 1 1 0 0 1

**Nové generace vznikají křížením**

= kombinováním částí chromozomů vybraných jedinců (náhodně, rovnoměrně, intervalově...)

**Proces výběru a křížení se opakuje**

dokud není funkce *fitness* maximalizována nebo nedosáhneme-li daného počtu generací



Ukázka výběru rodičovské generace fraktálů IFS  
v programu Jána Švece



**Diverzitu populace lze obnovit mutacemi**

= nezděděnými geny, které se mohou dále dědit

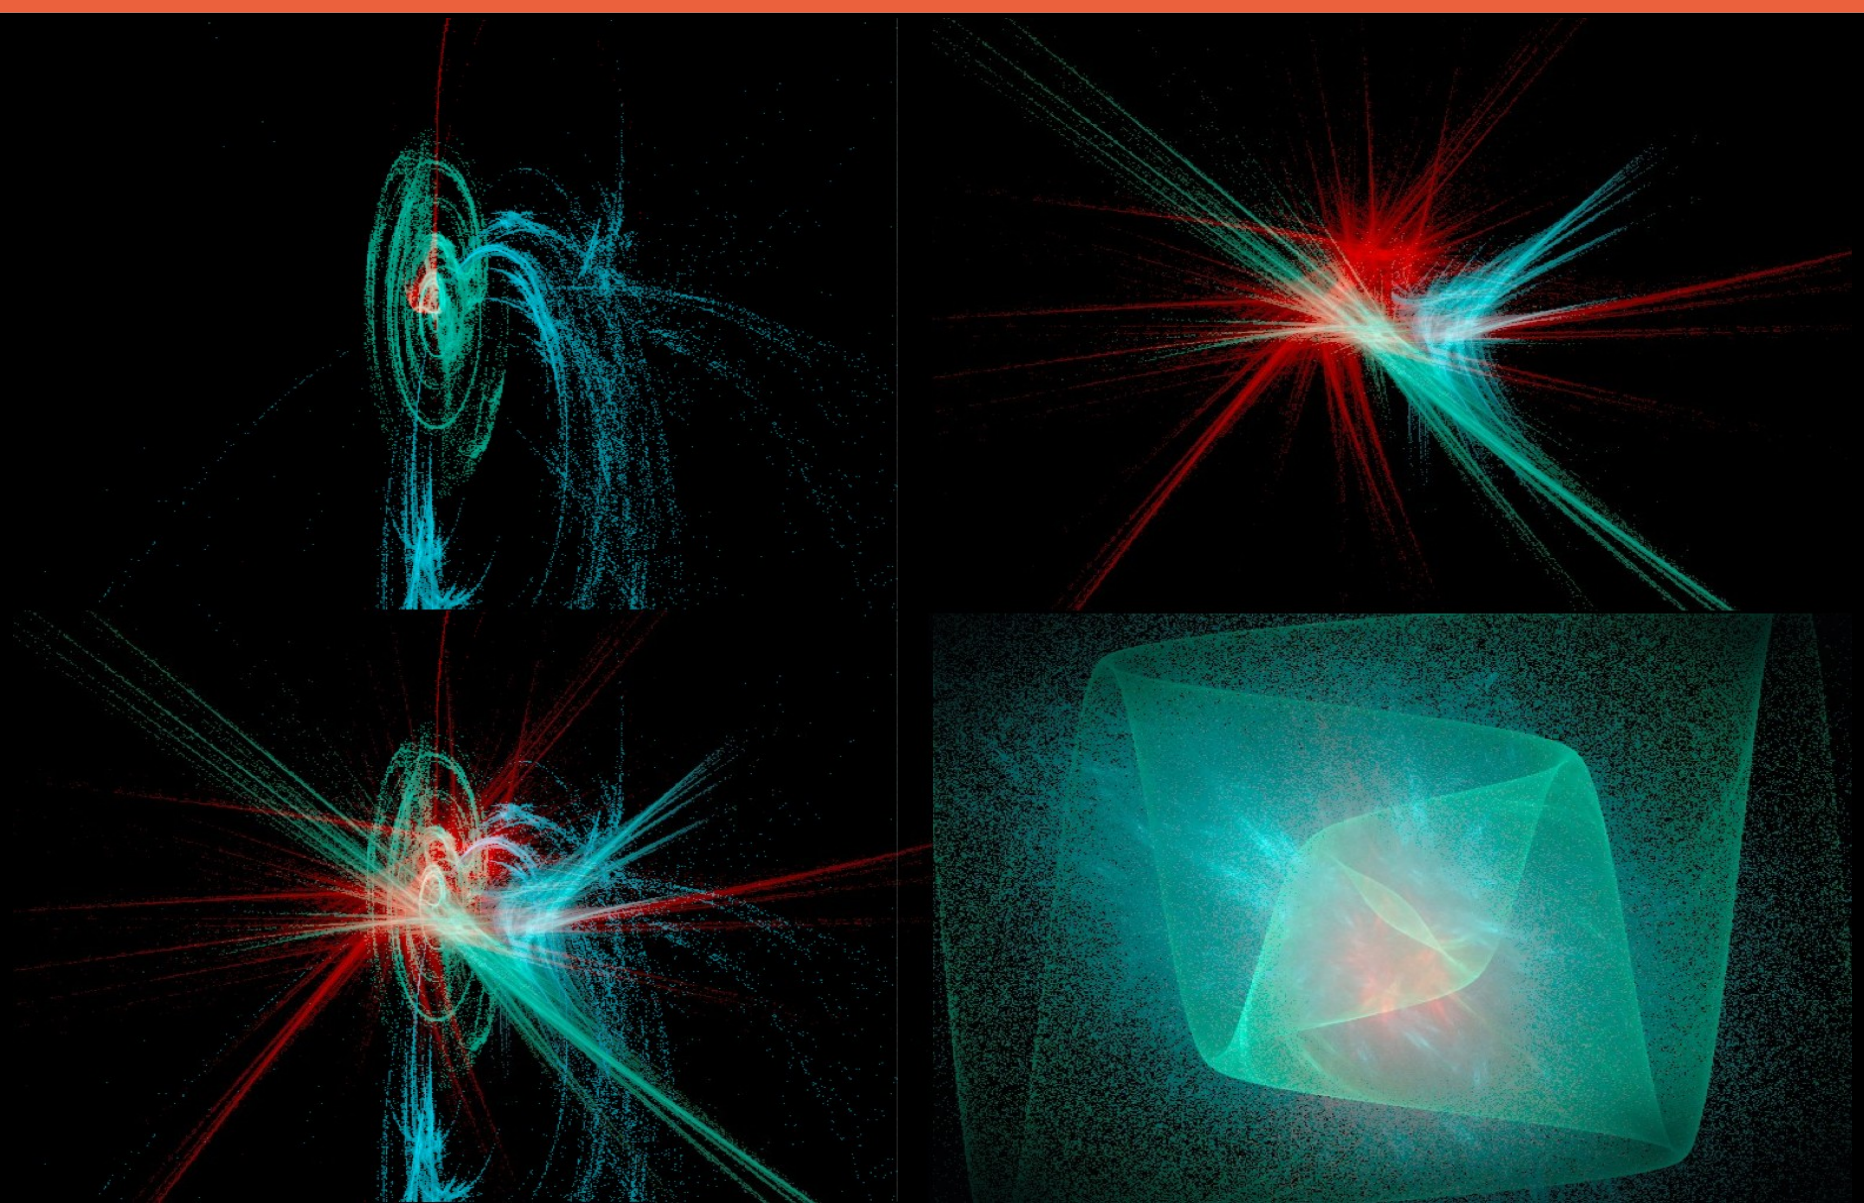
**Mutace spočívá v nahrazení genu v chromozomu jiným (náhodným) genem**

**Mutace je dobré mít pod kontrolou — mohou být přínosné i degenerativní**

Lze je provádět na vyžádání, ovládat řízenou pravděpodobností výskytu, omezit maximálním počtem v jedné generaci apod.




**Mutace jsou vhodné tehdy, když křížení již nepřináší nic esteticky nového**





**Rozdílné výsledky efektu křížení a mutace**









## Genetické variace Mandelbrotovy množiny

S. Rooke






M. Tkáčiková



**D. Buchta**





V. Rylko



**Algoritmus nemusí nutně produkovat generovanou estetiku**

**Genetické algoritmy lze využít např. pro výtvarné zpracování obrazu —**

**lze jimi automatizovat výtvarné techniky nebo nápodobu uměleckých stylů**

Funkce *'fitness'* typicky hodnotí vygenerovanou populaci z pohledu efektivity pokrytí vstupního obrazu a míry shody barevné / tvarové informace

➔ ***ImageEvolver***



(a) Generation 1



(b) Generation 150



(c) Generation 300



(d) Generation 600




(e) Generation 900




(f) Target

GA parameters: Base chromosome 600 circles (size 10-40), mask chromosome 250 circles (size 1-10), 128 fixed-colour palette, population size 160, crossover rate 100%, mutation rate 80%, tournament size 4, 2-point crossover.



V. Lazareva







**S. Bergen**

## Neuronové sítě

**Neurony v živých organismech =  
buňky přijímající signály a reagující na ně**  
(příjem pomocí dendritů, šíření pomocí axonů)



**Přijímaný signál je korigován vahami  
a šířen do buňky, kde vzniká potenciál  
Je-li dostatečně velký, buňka jej vyše dál**

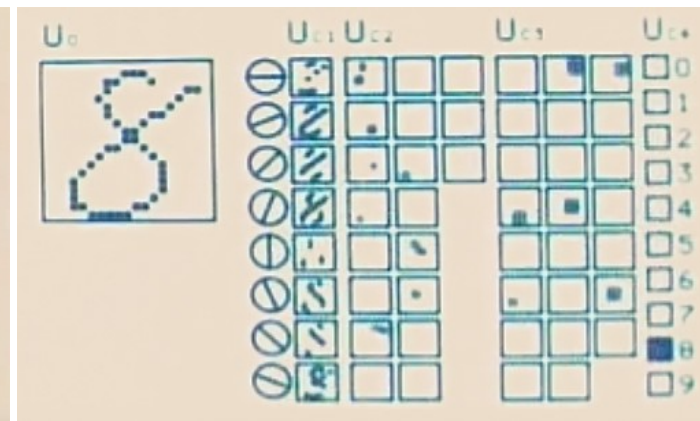
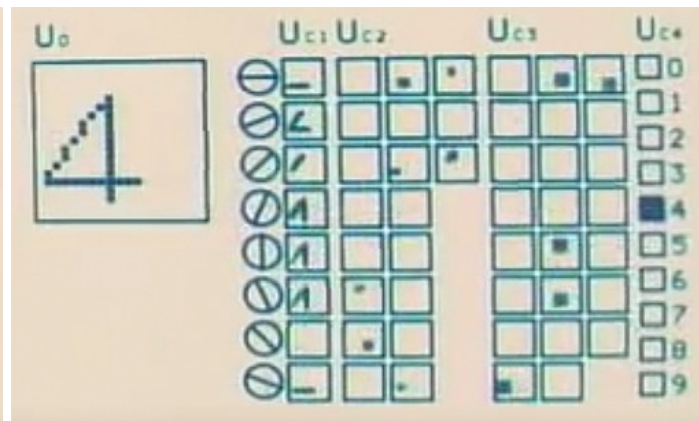
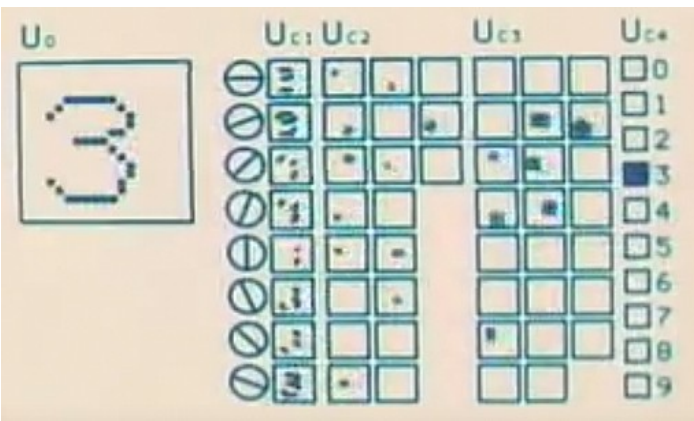

Aktivační funkce je typicky nelineární

**Umělé neuronové sítě  
seskupují neurony do vrstev**

**Každá vrstva je zodpovědná  
za konkrétní úkol**

Např. v počítačovém vidění:  
detekce kontrastu a hran,  
rozpoznání pozice a tvarů...

**Výsledek = klasifikace**  
např. rozpoznání číslice



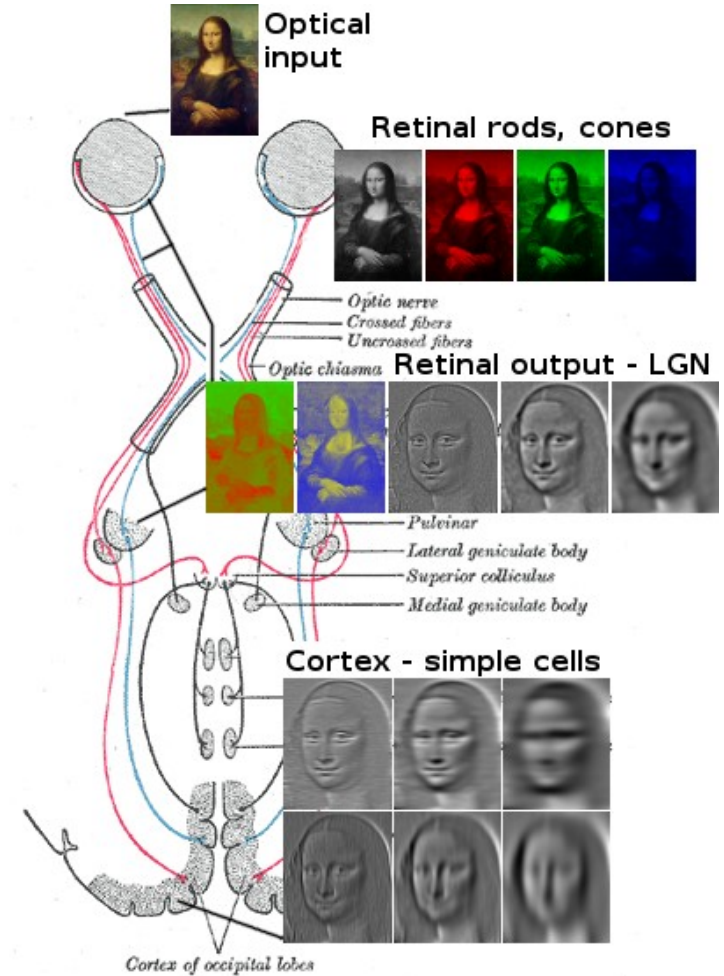
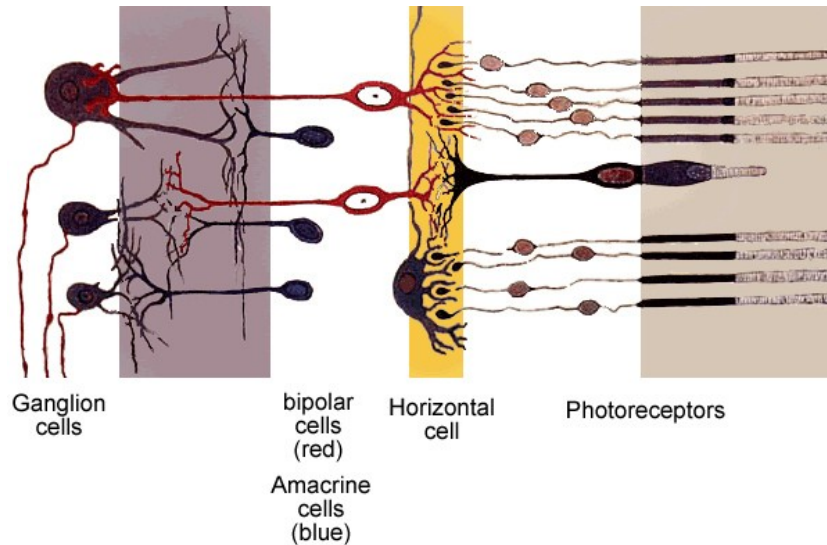


Princip učení – neurony si uchovávají  
informaci o propustnosti signálu  
v různém nastavení hodnot vah

**Váhy = znalost**

Příklad:

Rozpoznávání viděných objektů




**Algoritmů učení je celá řada —  
např. metoda ‚zpětného šíření‘ (*backpropagation*):**

- **Vybere se vzorek**
- **Neuronová síť provede klasifikaci**
- **Výsledek klasifikace se porovná  
s očekávaným výstupem a vypočtou se  
změny vah podle odchylky**
- **Váhy se od spodních vrstev nahoru  
aktualizují a vybere se další vzorek**
- **Učení končí, když klasifikace odpovídá  
očekávaným výstupům ( $\pm$  tolerance)**

## Typická aplikace počítačového vidění:

→ Popiš co vidíš na obrázku

když máš znalost, jak vypadá auto, kolo, pes





## Kreativní aplikace počítačového vidění:

→ Hledej kde vidíš na obrázku psa



Neobvyklé výstupy zejm. pokud na něm žádný pes není

## První pokusy: *DeepDream* (2015)


[ → ]

„Zpětné šíření“:  
neupravují se váhy,  
ale obrazová data


+ **zpětná vazba**

klasifikovaný obrázek  
je zpracován znovu


= cokoli v obrázku uvidíš,  
to neustále zvýrazňuj



Horizon



Towers & Pagodas



Trees



Buildings



Leaves



Birds & Insects





P. Havelka





M. Rokosová






J. Kolářová

## Zadání

**Experimentujte s estetikou genetických algoritmů a neuronových sítí**



## Výstup

**Výsledná grafika / série obrazů**

ilustrující vývoj původní formy k nejlepšímu výsledku

**nebo grafika vytvořená „archeologickými technikami“**

*DeepDream* apod., ne AI, Midjourney, ChatGPT apod.