

## IV122 Zadání: Analýza dat

Jako vstupy pro obě úlohy použijte poskytnutá data i vlastní simulovaná data, tj. dílčí podúkol je napsat generátor simulovaných dat.

### A) Lineární regrese

Vstup: seznam bodů  $x_i, y_i$ .

Výstup: přímka  $ax + b$  minimalizující sumu čtverců chyb; znázorněno obrázkem (body i přímka).

Algoritmy: výpočet vzorcem, approximativní řešení (grid search nebo gradient descent).

U simulovaných dat prozkoumejte vztah mezi pravými hodnotami  $a, b$  (těmi, které byly použity pro generování) a vypočtenými hodnotami. Jak tento vztah závisí na množství dat a na velikosti šumu? Jak robustní je výpočet při přítomnosti odlehlých bodů (body s výrazně vyšší odchylkou než ostatní body)?

### B) Detekce shluků

Vstup: seznam bodů  $x_i, y_i$ ; žádaný počet shluků  $k$ .

Výstup: rozdelení na  $k$  shluků; znázorněno obrázkem (obarvení bodů podle shluků).

Algoritmus: k-means.

Prozkoumejte chování algoritmu (stabilita, závislost na iniciálních podmínkách, počet iterací potřebných pro konvergenci) pro různé typy vstupních dat, konkrétně například pro různé počty shluků a míra „překrývání“ shluků.