

Oblast informatiky je velmi široká a každý, kdo se naučí programovat, si klade otázku, na co mu to potom bude dobré. Můžeme to přirovnat k používání orientálního koření v kuchyni. Záleží zejména na tom, kolik, v jakém okamžiku a na co ho nasypete. Pokud cítíte, že má smysl kombinovat informatiku s jinými vědami, nenechte se odradit počáteční náročností teoretické přípravy, která vám nakonec umožní radost z tvorby unikátního software...

Analýza fraktálních množin

Podařilo se nám vyvinout nové nevyčýlené odhady Renyiovy dimenze D_α , které jsou vhodným nástrojem analýzy fraktálních množin. Definovali jsme modifikovanou Reniovu entropii vztahem

$$H^*(\alpha, \epsilon) = \ln M + \frac{\ln E G^{\alpha-1}(\mathbf{x}, \epsilon)}{1 - \alpha} = C_\alpha - D_\alpha \ln \epsilon,$$

který je založen na stupni degenerace daného bodu

$$G(\mathbf{x}, \epsilon) = \sum_{k=1}^M \mathbf{I}(\|\mathbf{x} - \mathbf{x}_k\|_2 \leq \epsilon),$$

rychlém vyhledávání ve vyváženém k -D stromu, vzorkování metodou Monte Carlo a lineární regresi.

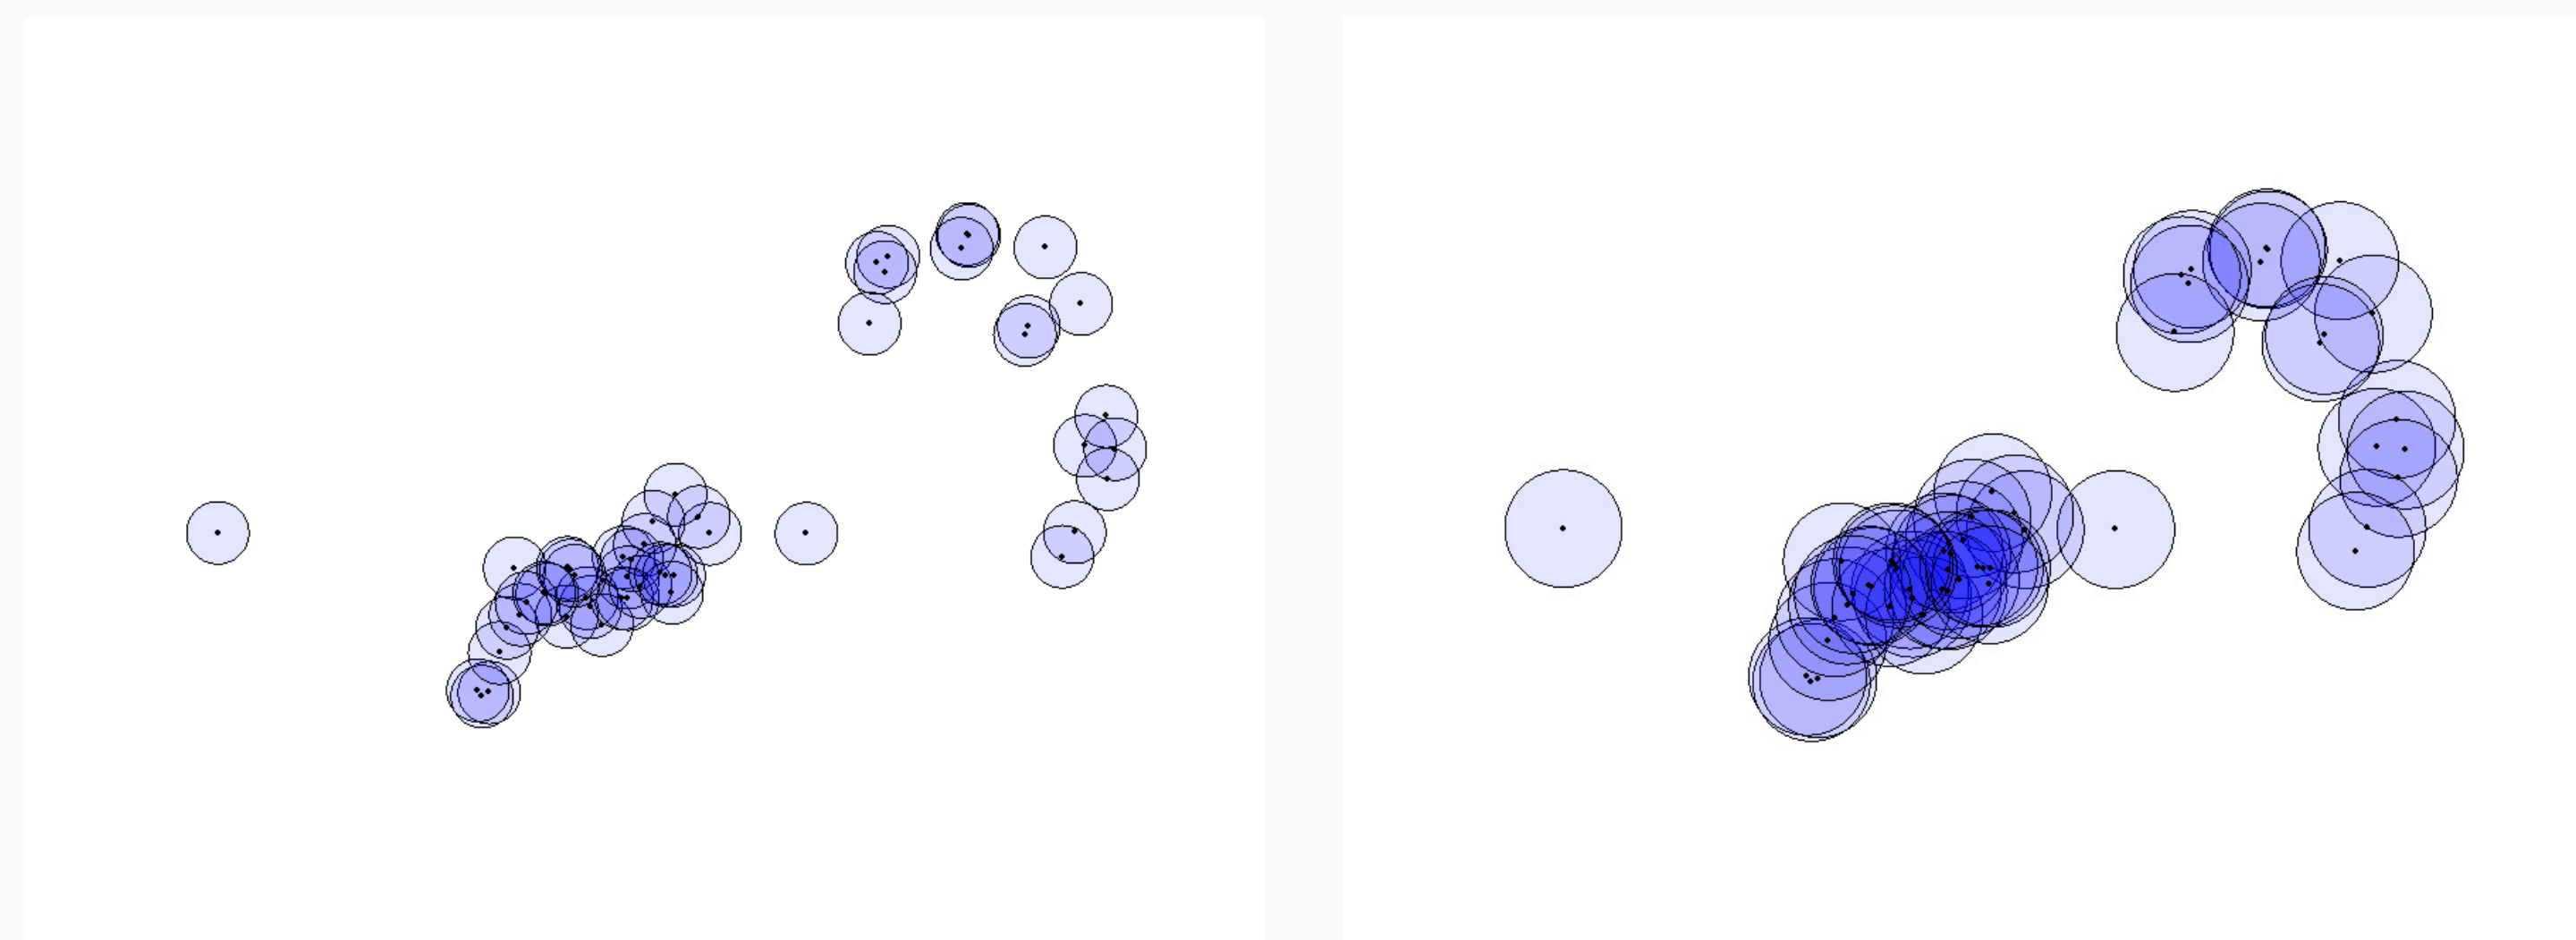


Figure: Stupeň degenerace bodu jako nástroj pro odhad Renyiovy dimenze pro ϵ_1 a $\epsilon_2 = 2\epsilon_1$.

Rovněž se zabýváme konstrukcí modelů fraktálů pomocí pravidelných mřížek, neorientovaných grafů a diskrétních bodových množin. Jde o to, jak uvedené modely efektivně implementovat v celočíselné aritmetice, jak realizovat difuzi pomocí náhodných skoků do sousedních bodů mřížky a jak analyzovat výsledky simulací. Přitom se využívá pojem důvěrně známý všem tulákům – pravděpodobnost návratu domů po k dnech, která je dána vztahem

$$p_k = \text{prob}(\mathbf{x}_k = \mathbf{x}_0 | \mathbf{x}_0) = Ak^{-d_s/2},$$

kde spektrální dimenze d_s nese cenné informace o rozmístění restaurací a dalších významných bodů v okolí bydliště.

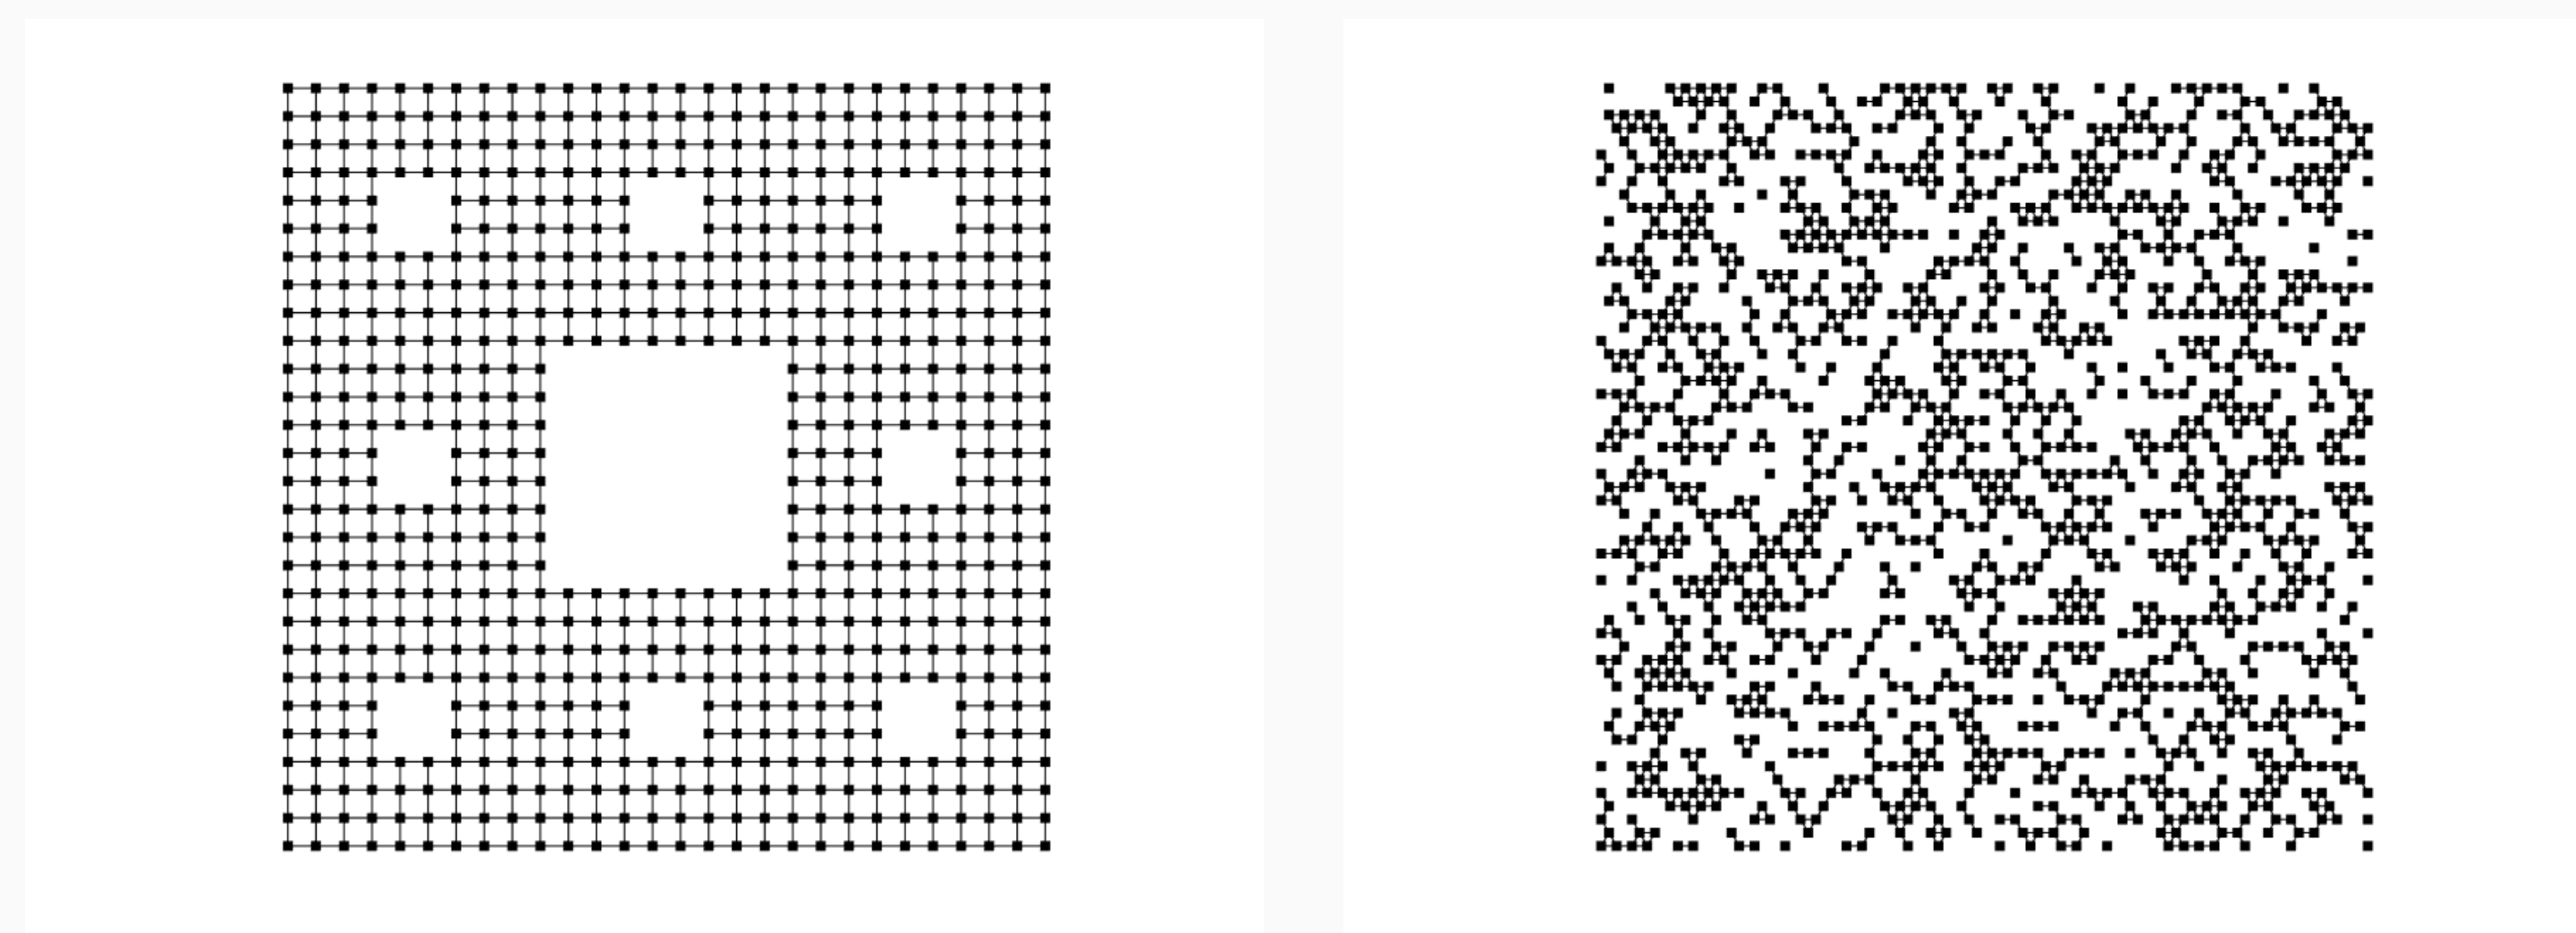


Figure: Aproximace fraktálních množin: Sierpinského koberec a prosakování.

Strojové učení v Hilbertově prostoru

V oblasti strojového učení dáváme přednost translačně a rotačně invariantním jádrům, která umožňují nelineární transformaci Φ z prostoru \mathbb{R}^n na povrch jednotkové hyperkoule $\mathcal{S} \subset \mathcal{H}$, kde \mathcal{H} je Hilbertův prostor nekonečné dimenze. Příslušná jádrová funkce je dána skalárním součinem

$$\mathbf{K}(\mathbf{a}, \mathbf{b}) = \Phi(\mathbf{a}) \cdot \Phi(\mathbf{b}).$$

Tradiční jádrová funkce RBF má tvar

$$\mathbf{K}(\mathbf{a}, \mathbf{b}) = \exp\left(-\frac{\|\mathbf{a} - \mathbf{b}\|_2^2}{2\sigma^2}\right)$$

a vyskytuje se v mnoha aplikacích, ale je jenom jednou z mnoha. Otevírají se tak nové možnosti strojového učení v Hilbertově prostoru \mathcal{H} , kdy si snad vychutnáme

lineární separabilitu, stochastické učení, lineární a kvadratické programování nebo optimalizační heuristiky. Naším dlouhodobým cílem je konstrukce nových typů klasifikátorů, které kombinují přesnost klasifikace se schopností zobecňovat zákonitosti v datech.

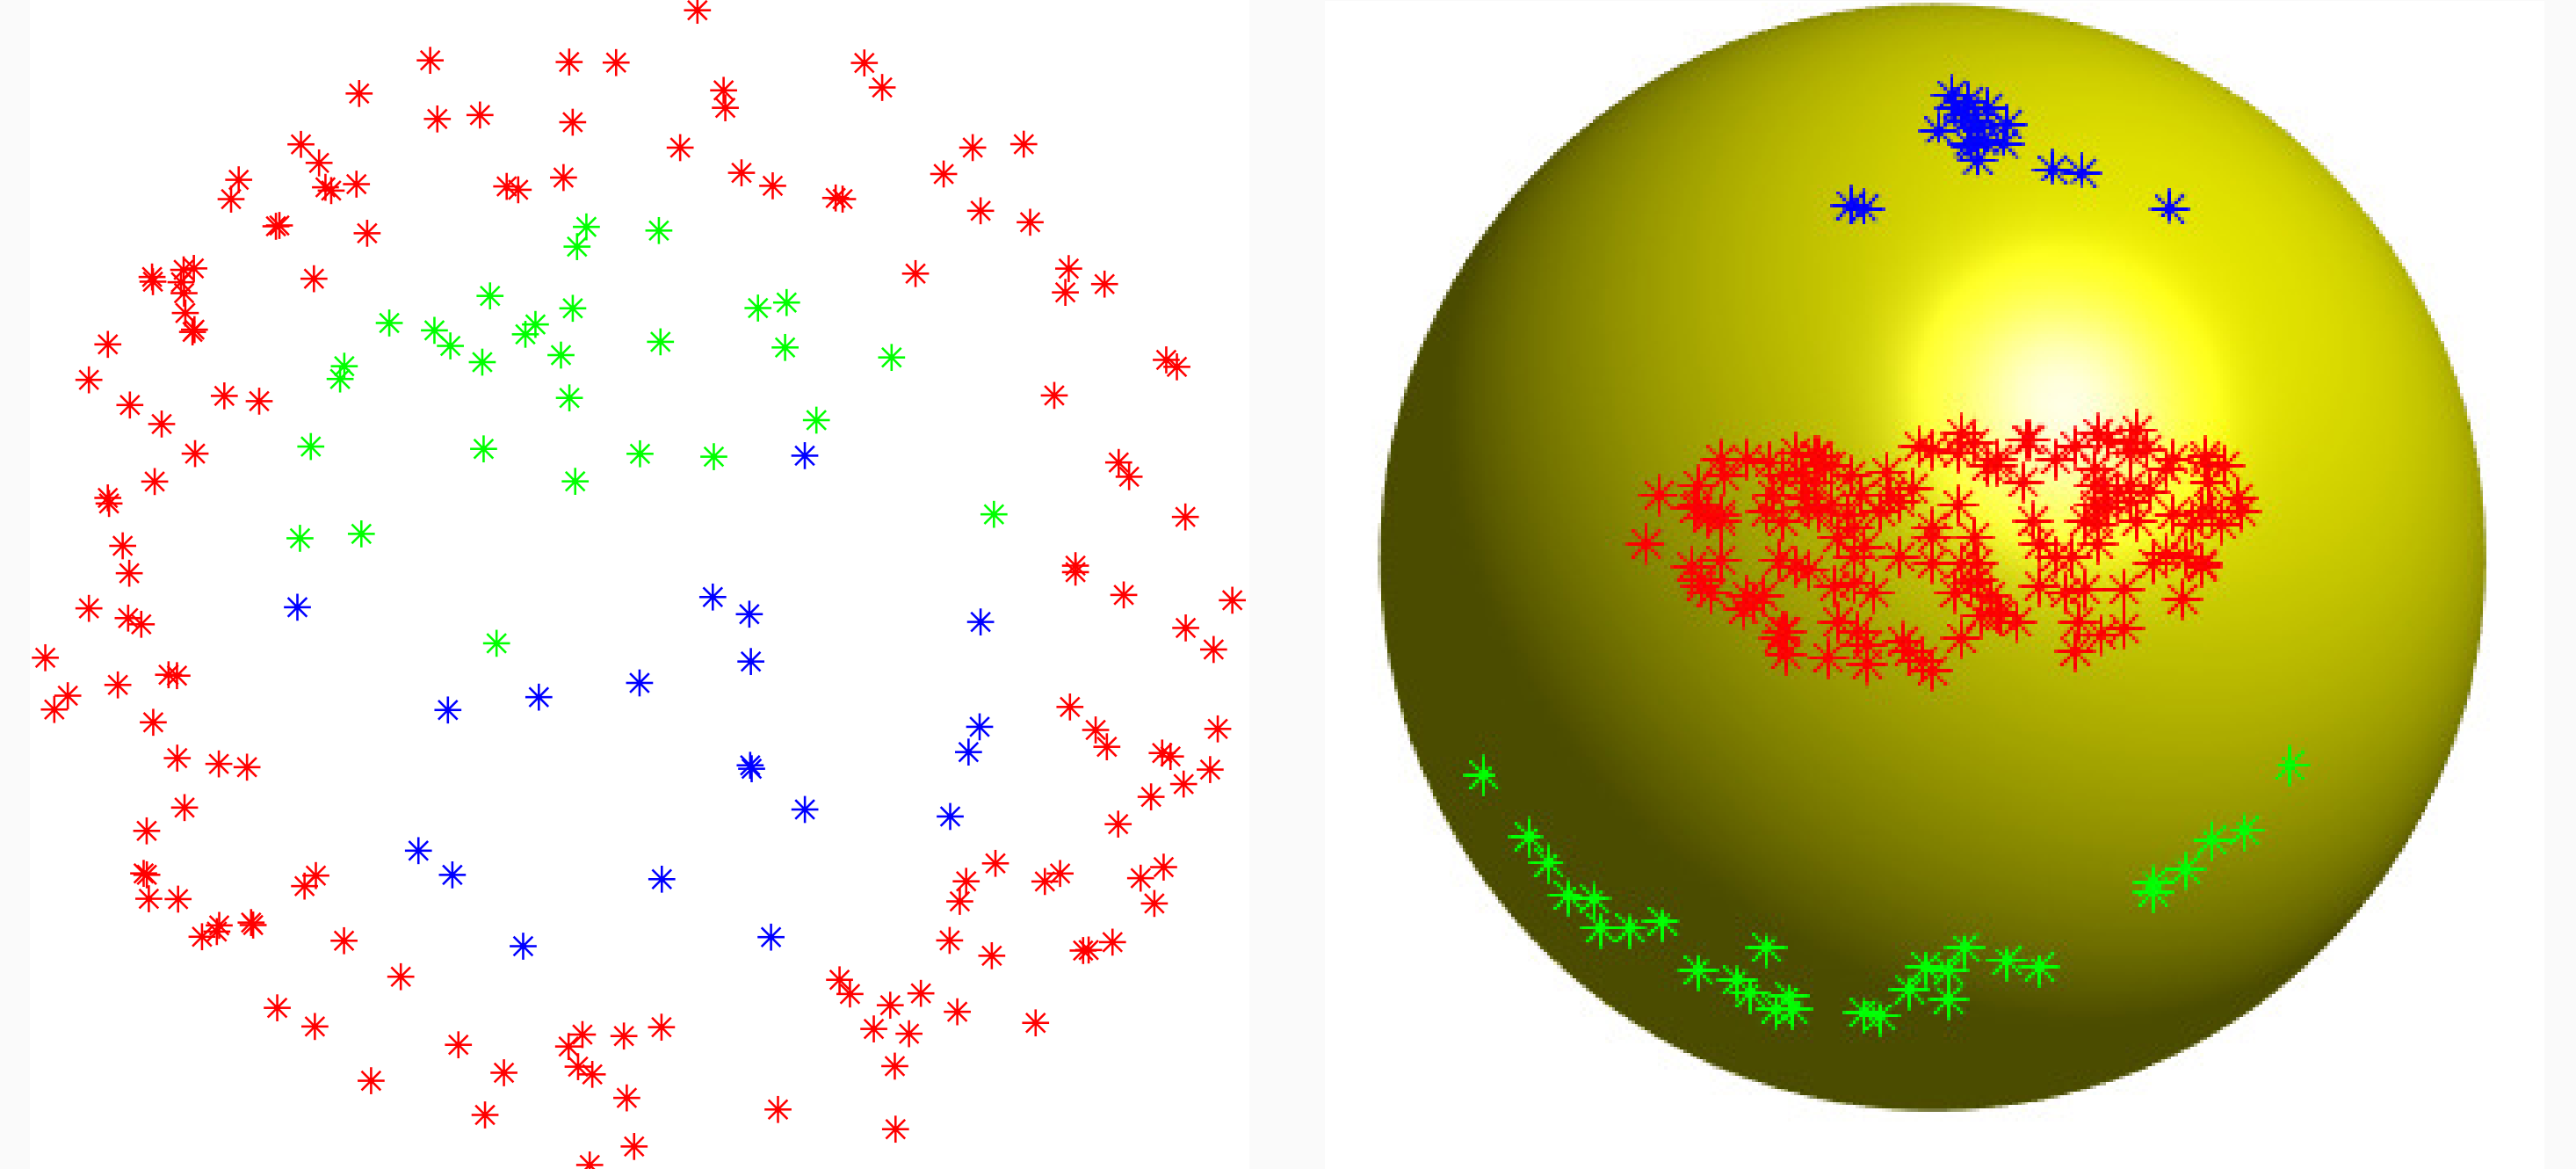


Figure: Množina vzorů ze tří tříd v \mathbb{R}^2 a její lineárně separabilní projekce do \mathcal{H} .

Modelování anomální difuze

Pokud si chcete vychutnat matematickou analýzu, numerickou matematiku, matematickou statistiku a programovací techniky, můžete u nás zkusit modelovat anomální difuzi popsanou zlomkovou parciální diferenciální rovnicí

$$\frac{\partial c(\mathbf{x}, t)}{\partial t} = D_\alpha \nabla^{(\alpha)} c(\mathbf{x}, t).$$

Jak anomální difuze, tak zlomkový Laplacián $\nabla^{(\alpha)}$ nejsou pouze hračkami pro teoretiky bez dalšího uplatnění. Anomální chování souvisí s turbulentním prouděním jako negaussovský rozptyl světla v atmosféře, který ovlivňuje astronomická pozorování, transport hmoty v chemických reaktorech nebo invazivní chování jedinců nejen v biologii.




Figure: Singularita a mřížka pro aproximaci $\nabla^{(\alpha)}$ v tetragonální a hexagonální topologii.

Vybrané publikace našich doktorandů

- ▶ Dlask, M., & Kukal, J. (2017). Application of rotational spectrum for correlation dimension estimation. *Chaos, Solitons & Fractals*, 99, 256-262.
- ▶ Dlask, M., & Kukal, J. (2018). Translation and rotation invariant method of Renyi dimension estimation. *Chaos, Solitons & Fractals*, 114, 536-541.
- ▶ Gaspar, F., & Kukal, J. (2022). Stochastic modelling of fractal diffusion and dimension estimation. *Physica A: Statistical Mechanics and its Applications*, 127624.
- ▶ Kukal, J., & Mojzes, M. (2018). Quantile and mean value measures of search process complexity. *Journal of Combinatorial Optimization*, 35(4), 1261-1285.
- ▶ Hrebik, R., Kukal, J., Jablonsky, J. (2019). Optimal unions of hidden classes. *Central European Journal of Operations Research*, 27(1), 161-177.
- ▶ Horaisová, K., & Kukal, J. (2016). Leaf classification from binary image via artificial intelligence. *Biosystems Engineering*, 142, 83-100.
- ▶ Horaisova, K., Dudasova, J., Kukal, J., Rusina, R., Matej, R., Buncova, M. (2018). Discrimination between AD and ALS via affine invariant spherical harmonics analysis of SPECT images. *Neural Network World*, 28(1), 17-39.