




Trendy vývoje endoskopických zobrazovacích systémů v lékařství

Adaptivní akvizice k-prostoru na MR pomocí reinforcement learningu

MUDr. Bc. Matěj Šňupárek

Motivace a cíle

- MR vyšetření je časově náročné (pohybové artefakty, diskomfort pacienta, ekonomická nákladnost).
- Existující metody urychlení (PI, CS), ale mají své limity.
- Absence inteligentního systému, který se naučí optimálně **sbírat** data, ne jen pasivně rekonstruovat.
- Cíle: 1.) Vytvoření systému pro **aktivní akvizici** MR dat
- 2.) Využití **hlubokého posíleného učení (Deep RL)** pro adaptivní výběr sloupců v K-prostoru

Koncept adaptivní (aktivní) akvizice k-prostoru

Tradiční přístup (Statický):

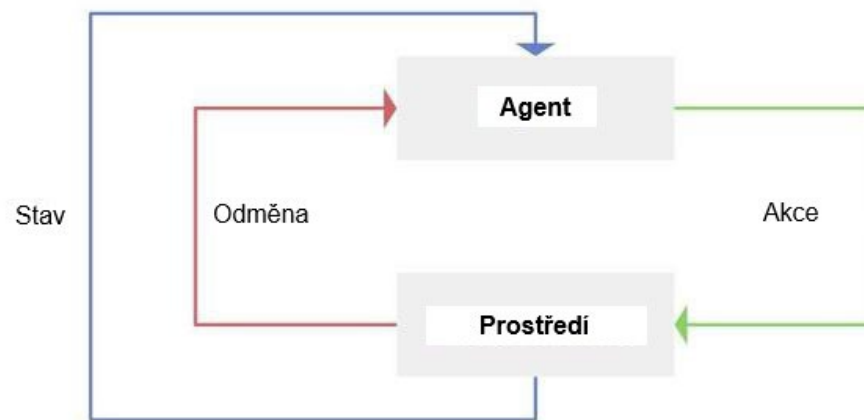
- Sběr dat probíhá podle předem pevně daného schématu (např. řádek po řádku nebo fixní podvzorkovací maska).
- Systém je "slepý" – neví, jak vypadá obraz, dokud není měření hotové.
- Může sbírat redundantní data (např. pozadí mimo objekt)

Aktivní akvizice (Dynamický):


- Vzorkovací trajektorie není fixní, ale mění se v reálném čase během skenování.
- Systém vyhodnotí data získaná v krocích $t_0, \dots, t_n$ a rozhodne, které měření v kroku t_{n+1} přinese největší nárůst kvality obrazu.
- **Cíl:** Získat diagnosticky podstatnou informaci s minimálním počtem měření (maximální akcelerace při zachování diagnostické hodnotitelnosti)

Reinforcement learning (RL)

- Výpočetní přístup zaměřený na učení agenta skrze přímou interakci s prostředím (pokus-omyl), nikoliv skrze statická trénovací data.
- **Cíl:** Nalezení optimální strategie (policy), která maximalizuje kumulativní odměnu v čase.
- Klíčové komponenty RL:
 1. **Agent:** Rozhodovací entita (učí se, jakou akci zvolit).
 2. **Prostředí (Environment):** Reaguje na akce agenta a generuje nový stav.
 3. **Akce:** Zásah agenta do prostředí.
 4. **Stav:** Reprezentace aktuální situace, kterou agent vidí.
 5. **Odměna:** Číselná zpětná vazba hodnotící úspěšnost akce.
- **Využití:** doporučovací systémy, robotika a automatizace, jazykové modely, ...




<https://analyticsindiamag.com/ai-features/reinforcement-learning-robotics-real-world/>



<https://newsroom.tiktok.com/how-tiktok-recommends-videos-for-you?lang=en>


Algoritmus PPO (Proximal Policy Optimization)

- Moderní metoda z rodiny Policy Gradient algoritmů.
- Zvolena pro svou vysokou stabilitu a efektivitu učení v porovnání se staršími metodami (např. DQN nebo TRPO).
- **Architektura Actor-Critic** (Model využívá dvě propojené neuronové sítě):
 1. **Actor (Politik):** Přímou navrhuje akce (výběr konkrétního sloupce k-prostoru).
 2. **Critic (Kritik):** Odhaduje hodnotovou funkci (očekávaný budoucí zisk/odměnu), čímž pomáhá redukovat rozptyl při učení Actora.
- **Klíčovou inovací PPO je "Clipped Objective Function",.**
- Zabraňuje příliš radikálním změnám v strategii agenta během jednoho kroku učení, což je klíčové pro prevenci nestability a "zhroucení" modelu.



<https://joel-baptista.github.io/phd-weekly-report/posts/ac/>

Adaptivní akvizice k-prostoru pomocí RL



RL Formulace:

- **Prostředí:** MR akvizice jednoho řezu (epizoda).
 - **Agent:** Neuronová síť rozhodující, co změřit.
 - **Akce:** Výběr konkrétního sloupce K-prostoru (fázové kódování).
 - **Stav:** Aktuální rekonstrukce + Maska vzorkování + Zbývajících rozpočet měření.
 - **Odměna:** zvýšení SSIM oproti předchozímu stavu.
- Rekonstrukční síť tvoří modifikovaný 2D U-Net s hloubkou 4 úrovní (Encoder-Decoder struktura), Konfigurace: 50 epoch, Batch size = 16, Optimalizátor: Adam, Ztrátová funkce: Kombinovaná perceptuální a strukturální ztráta, Learning rate: 1×10^{-3}


Vizualizace jedné epizody

- faktor urychlení 5R, koronární proton density řezy kolene s potlačením tuku

GT




Zero-filled



Recon



mask | step 0 | left 48
MSE ZF 0.0137 MSE R 0.0121 meas 16



Metriky hodnocení

- Porovnání rekonstruovaného obrazu (z podvzorkovaných dat) s referenčním "Ground Truth" (plně vzorkovaným) obrazem

1. SSIM (Strukturální podobnost / Structural Similarity Index):

• **Princip:** Perceptuální metrika, která se snaží napodobit lidské vnímání vizuální kvality. Nehodnotí jen absolutní chybu, ale změny v jasu, kontrastu a lokální struktuře.



• **Využití v práci:** Slouží jako signál odměny (reward) pro RL agenta, protože nejlépe koreluje s diagnostickou použitelností

2. PSNR (Vrcholný poměr signál-šum / Peak Signal-to-Noise Ratio):

• **Princip:** Tradiční metrika založená na střední kvadratické chybě (MSE).

• **Využití v práci:** Standard pro porovnání výsledků s existující literaturou a jinými studiemi.

Výsledky





Referenční sken



Faktor urychlení 4R



Faktor urychlení 6R



Faktor rychlení 8R

Diskuze

Interpretace technických výsledků:

- **Akcelerace R=4:** Model dosahuje vysoké věrnosti (medián SSIM 0,81). Adaptivní agent úspěšně identifikoval klíčové frekvence pro zachování struktury tkání.
- **Akcelerace R=8:** Pozorován nárůst variability a ztráta jemných detailů (medián SSIM 0,69). Zde se projevuje fyzikální limit podvzorkování, kde rekonstrukční síť musí více „odhadovat“ chybějící data.

Limity metrik (SSIM/PSNR):

- Matematické metriky nemusí plně korelovat s diagnostickou užitečností (např. vyhlazení šumu může zvýšit PSNR, ale odstranit drobnou lézi).

Plánované klinické hodnocení:

- Pro ověření reálné použitelnosti v praxi je připravena subjektivní evaluace lékařem – radiologem.
- **Metodika:** Slepé hodnocení sady náhodně vybraných skenů s různými akceleračními faktory.
- **Hodnocená kritéria:**
 - Celková kvalita obrazu (Likertova škála 1–5).
 - Hodnotitelnost anatomických struktur (menisky, vazy).
 - Přítomnost a rušivost artefaktů.
 - Diagnostická hodnotitelnost.

Děkuji za pozornost

MUDr. Bc. **Matěj Šňupárek**

matej.snuparek.st@vsb.cz