

Simulácia šermu v 3D za pomoci UI diplomová práca


Autor: Bc. Jaroslav Blanář

Školiteľ: doc. Ing. Igor Farkaš, PhD.


Ciel'

- Navrhnuť a implementovať adaptívneho agenta s využitím umelej inteligencie pre simuláciu šermovania.
- Úlohou agenta je naučiť sa obranné manévry a úspešne tak odrážať protivníckove výpady.
- Implementovať simulátor šermovania v už existujúcom virtuálnom prostredí alebo navrhnuť a implementovať vlastné virtuálne prostredie pre simulátor v zjednodušenej podobe.

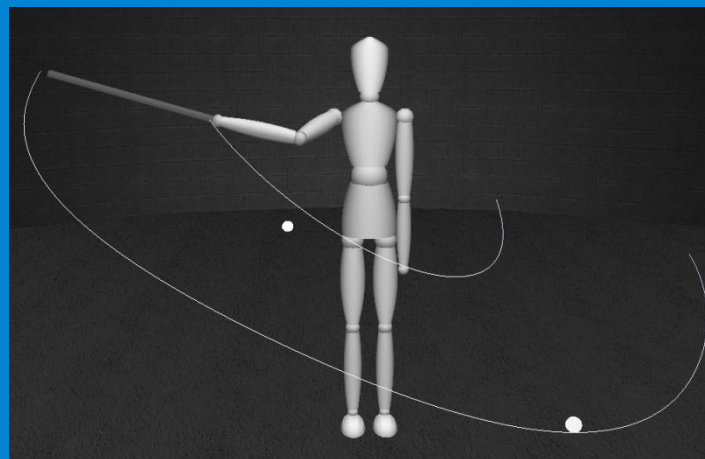
Modul šermovania




Typy výpadov



Výpad zľava

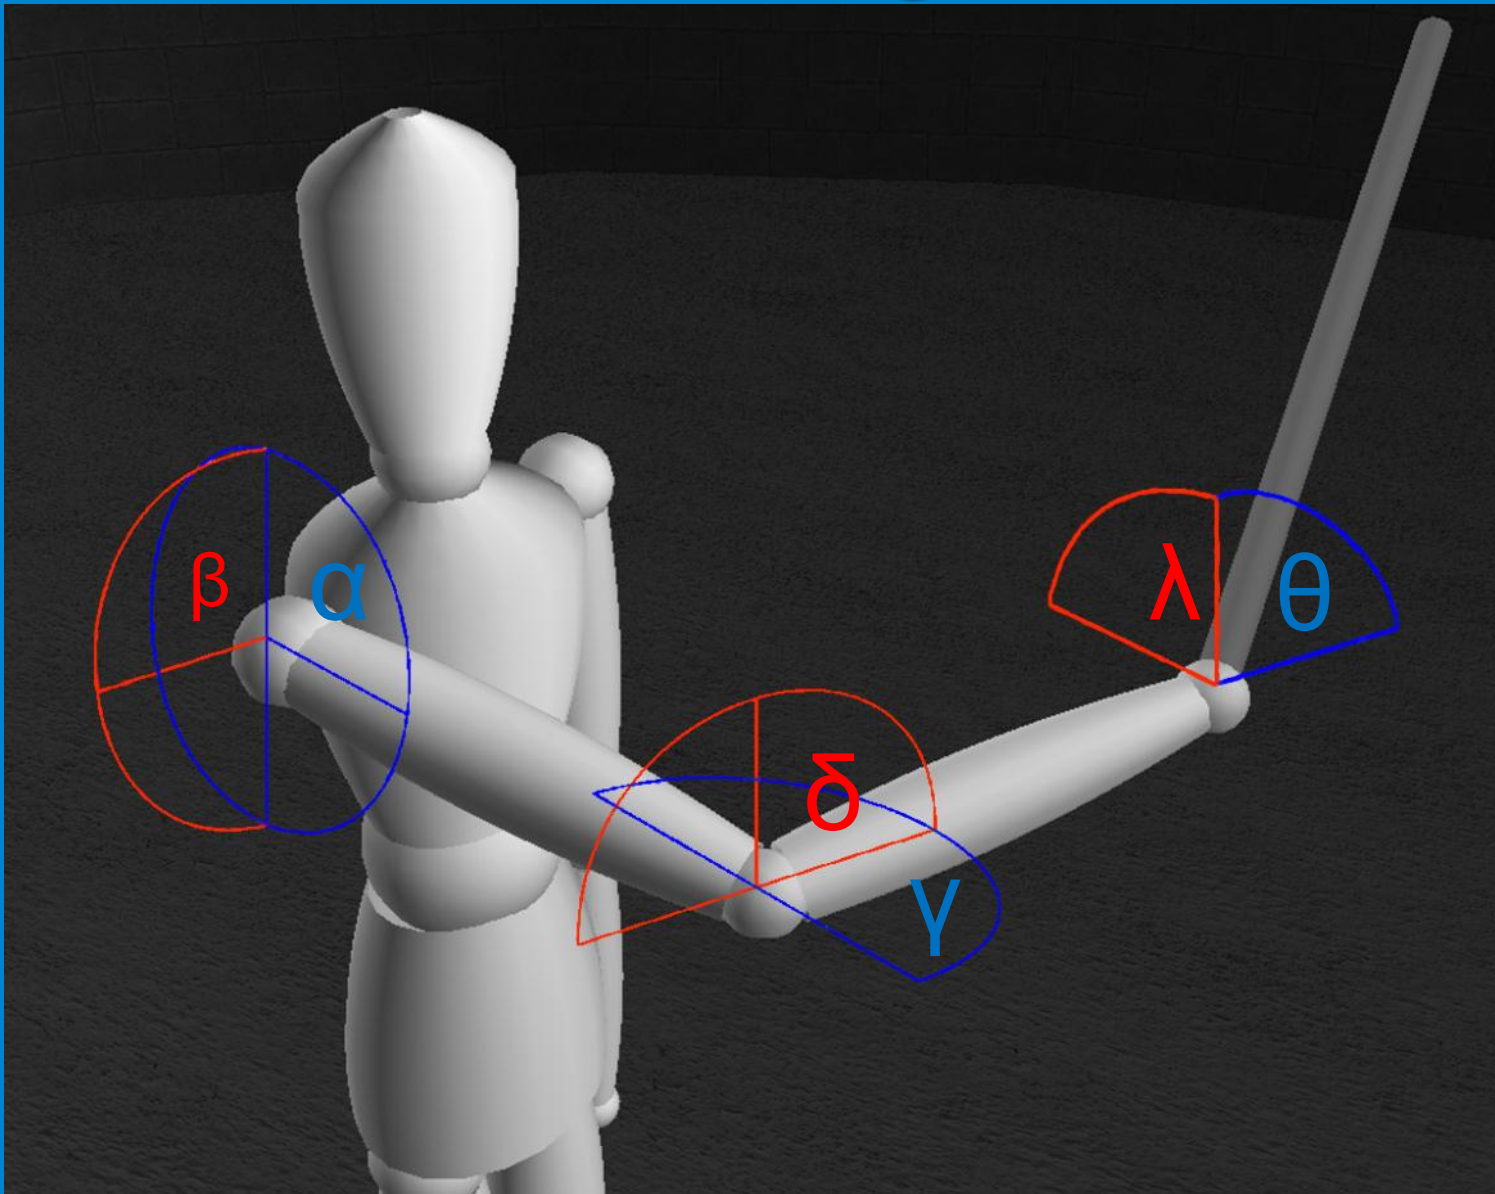


Výpad sprava



Výpad
zo stredu

Rameno agenta



Rameno agenta je ovládané pomocou 6 stupňov voľnosti.

Popis problému

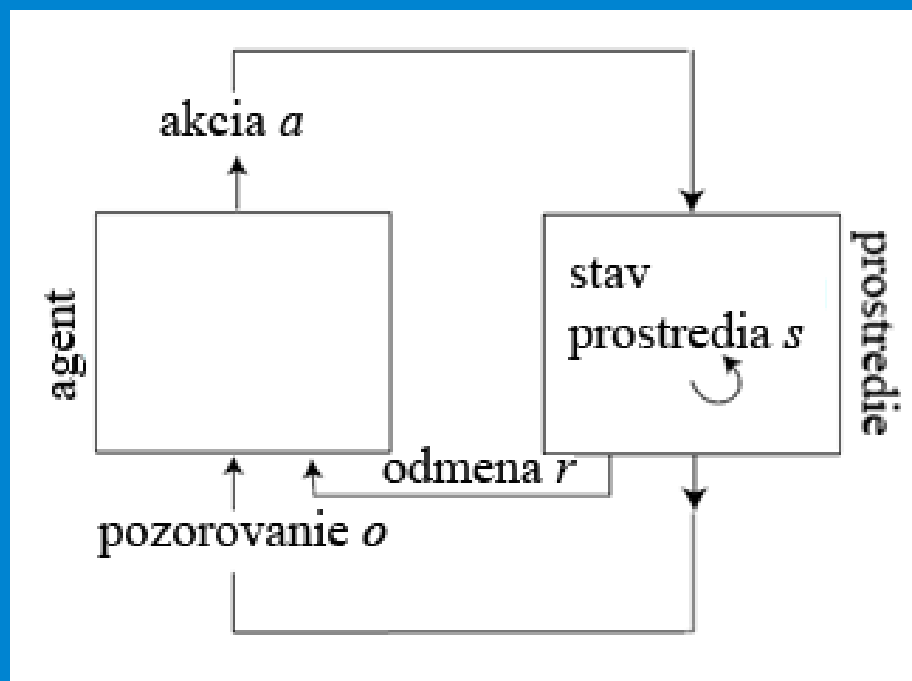
- Agentov aj trénerov meč je umiestnený v počiatočnej pozícii.
- Agent sa snaží voliť také akcie, ktorých aplikovaním sa jeho meč priblíži k trénerovmu meču.
- Cieľ je zablokovať trénerov meč, ktorý sa pohybuje smerom k agentovi.

Metódy UI

- Učenie s posilňovaním - Reinforcement learning
- Continuous Actor Critic Learning Automaton (CACLA)
- Neurónové siete

Učenie s posilňovaním

- s – konečná množina stavov
- a – konečná množina akcií
- r – funkcia, ktorá ohodnocuje správanie agenta
- o – informácie o aktuálnom stave pre agenta



CACLA

- **Aktér**
 - svojimi akciami priamo zasahuje do prostredia.
 - v stave s_t musí zvoliť najvhodnejšiu akciu a_t ,
 - počas tréovania sa snaží naučiť čo najlepšiu stratégiu.
 - reprezentovaný funkciou $AC(\text{stav})$, ktorá vráti najvhodnejšiu akciu na základe aktuálnej stratégie.
- **Kritik**
 - nezasahuje svojou činnosťou do prostredia.
 - počas tréovania sa snaží čo najlepšie ohodnocovať kvalitu stavov.
 - reprezentovaný funkciou $V(\text{stav})$, ktorá ohodnotí daný stav.

Učiacie pravidlo

- Použili sme doprednú neurónové siete, ktorých váhy sú parametre.
- Nech vektor θ^V je parametrom funkcie V , potom učiace pravidlo pre kritika je v tvare :

$$\theta_{i,t+1}^V = \theta_{i,t}^V + \alpha \delta_t \frac{\partial V_t(s_t)}{\partial \theta_{i,t}^V}$$

- Nech vektor θ^A je parametrom funkcie A , potom učiace pravidlo pre aktéra je v tvare :

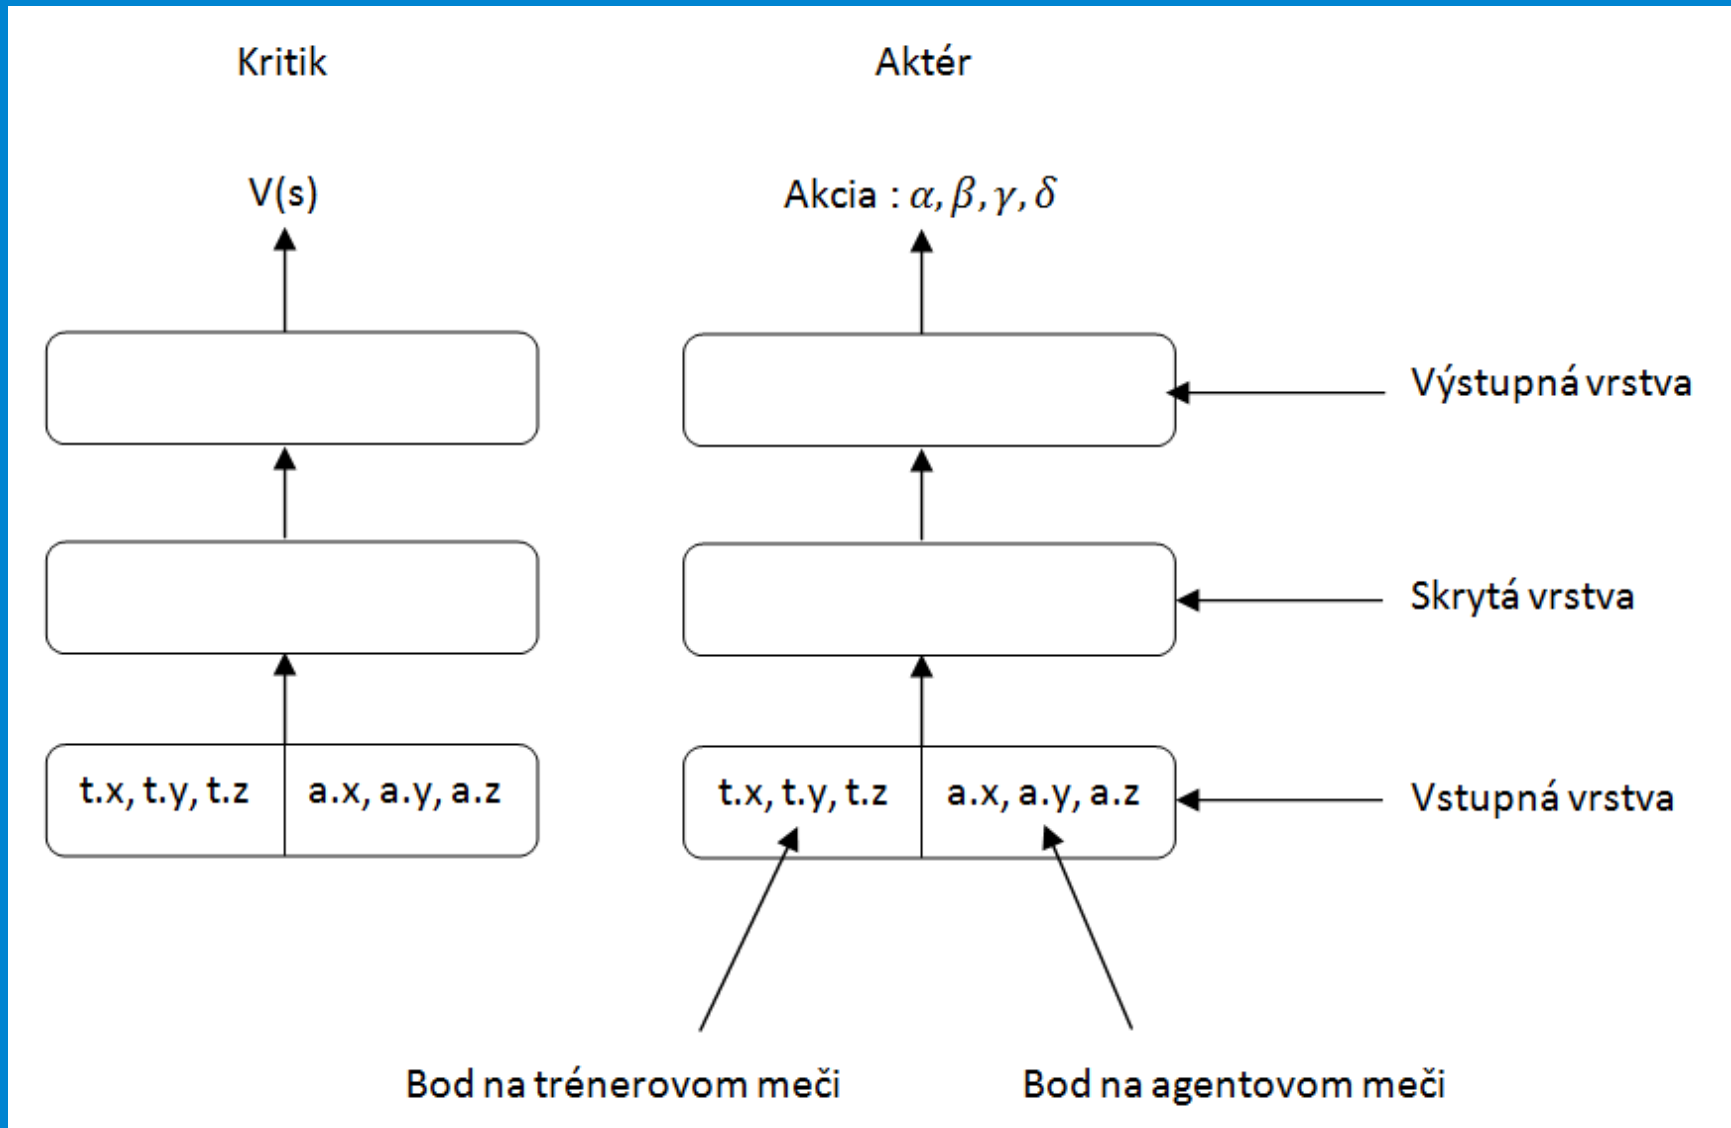
$$\text{if } \delta_t > 0 : \quad \theta_{i,t+1}^A = \theta_{i,t}^A + \alpha (a_t - A_t(s_t)) \frac{\partial A_t(s_t)}{\partial \theta_{i,t}^A}$$

kde α je rýchlosť učenia a t je parameter času.

Algorithmus CACLA

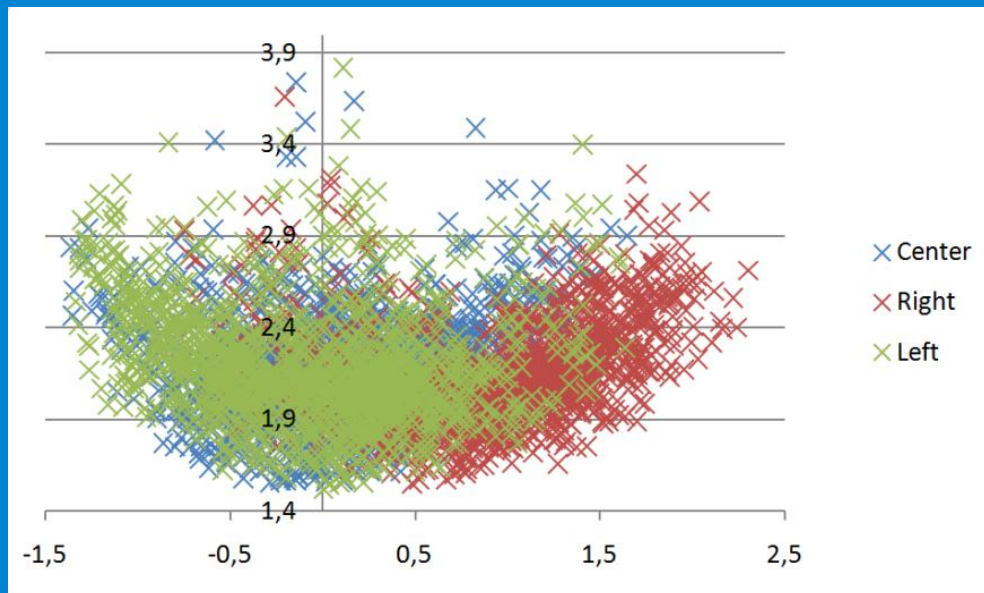
```
procedure Train(actualState) {  
    actionActor = Actor.A(actualState);  
    actionGaussian = GetRandomAction(actionActor);  
    newStateActor = ApplyAction(actionGaussian);  
    rewardGaussian = Reward(actionGaussian);  
    delta = rewardGaussian + discountFactor * Critic.V(newStateActor) - Critic.V(actualState);  
    if (delta > 0){  
        Actor.Update(actionGaussian, actualState);  
    }  
    delta = delta + Critic.V(actualState);  
    Critic.Update(delta, actualState);  
}
```

Návrh NS



Problém s CACLA


- Algoritmus CACLA prepustí pri podmienke $\delta > 0$ hodnoty s rozptylom v celom pásme, v dôsledku čoho sa agent nedokázal naučiť rozlišovať jednotlivé výpady a správne na ne reagovať.



Modifikácia CACLA alg.

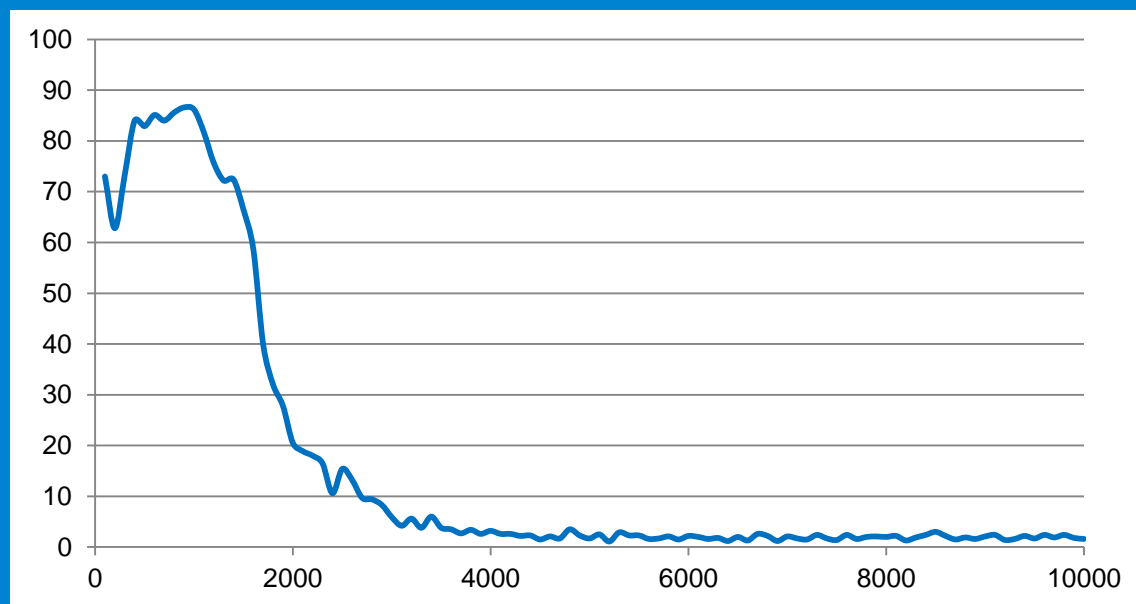
- Zmodifikoval som učiacu podmienku aktéra, ktorá viedla k zlepšeniu a schopnosti rozlíšiť jednotlivé výpady trénera.

```
valueActorAction = Critic.V(newStateActor);  
valueGaussianAction = Critic.V(newStateGaussian);  
if (valueGaussianAction > valueActorAction){  
    Actor.Update(actionGaussian, actualState);  
}
```



Výsledky

- CACLA – sa dokázala naučiť efektívne len jeden druh výpadov.
- Modifikácia CACLA algoritmus – sa dokázala naučiť efektívne obraňovať proti viacerým druhom útokov, preukázala schopnosť rozpoznávať jednotlivé výpady. Dĺžka trénovania ~ 3000 tisíc epoch.



*Priebeh chyby
MCACLA počas 10
tisíc epoch.*

Implementácia

- Visual C++
- OpenGL
- Beziérové krivky
- Windows

Ďakujem za pozornosť