

# Anwendung maschinell gelernter räumlicher Bewegungsmuster in immersiven Umgebungen durch ein GPU-basiertes Partikelsystem

## Hintergrund

Immersive virtuelle Realitäten (IVR) erlauben die aus geovisuelle Sicht technisch und konzeptionell herausfordernde Darstellung raumbezogener Phänomene im Maßstab 1:1. Ein Beispiel für ein räumlich sowie zeitlich komplexes Phänomen sind die kollektiven Verhaltensweisen und Bewegungsmuster von Tieren, etwa zur dynamischen Repräsentation terrestrischer oder mariner Ökosysteme.

Um sowohl den technischen als auch konzeptionellen Anforderungen von GeolVRs gerecht zu werden, ist die Anwendung von Modellen kollektiven Verhaltens in *Game Engines* wie bspw. der *Unreal Engine* erforderlich. Der Anspruch dieser Arbeit ist ebendiese Anwendung unter Berücksichtigung immersiver Aspekte<sup>1</sup> (Bildwiederholrate, Bildqualität) sowie des bestmöglichen Einsatzes gegebener Hard- und Software.

## Zielsetzung

Entgegen bisheriger Modellierungsansätze mittels eines vorab definierten Regelsatzes, ist die Umsetzung und Anwendung eines deklarativen Modells Ziel dieser Arbeit. Am Beispiel virtueller Fische (Beute und Jäger) wird durch ein deklaratives Verfahren die selbstständige Entwicklung kollektiver Verhaltensweisen und räumlicher Bewegungsmuster in einem dreidimensionalen Ökosystem analysiert.

Um einen Vergleich der entwickelten kollektiven Dynamiken und der Performanz des deklarativen Modells zu realisieren, wird zusätzlich ein regelbasierter Ansatz umgesetzt. Des Weiteren gilt es zu prüfen, wie eine Implementierung und performante Anwendung der Modelle innerhalb der *Unreal Engine* möglich ist.

## Regelbasierter Ansatz

Der Regelsatz soll einerseits die Herausbildung komplexer räumlicher Bewegungsmuster ermöglichen, andererseits den Anforderungen des virtuellen Ökosystems gerecht werden.

### Beute-Agent:

- Kohäsion<sup>2</sup>
- Ausrichtung<sup>2</sup>
- Separation<sup>2</sup>
- Nahrungsbeschaffung
- Hindernisvermeidung<sup>2</sup>
- Heimkehr<sup>3</sup>
- Flucht<sup>4</sup>
- Perturbation<sup>5</sup>

### Jäger-Agent:

- Jagd (Kohäsion<sup>2</sup>)
- Separation<sup>2</sup>
- Hindernisvermeidung<sup>2</sup>
- Heimkehr<sup>3</sup>
- Perturbation<sup>5</sup>



Abb. 1: Stark polarisierter Schwarm (regelbasiert)

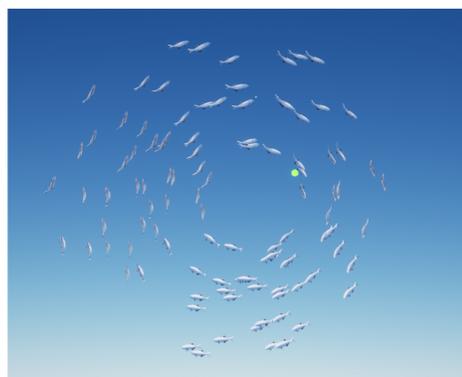


Abb. 2: „Hollow-core mill“ in der Nähe einer Nahrungsquelle (regelbasiert)



Abb. 3: Fluchtverhalten in der Gegenwart eines Jägers (regelbasiert)

## Deklarativer Ansatz

Die Entwicklung kollektiver Verhaltensweisen erfolgt über **Multi-Agenten Reinforcement Learning (MARL)** in der *Unity Engine*. Das Verhalten der Agenten wird durch ein neuronales Netzwerk (*multilayer perceptron*) definiert und mithilfe der *Proximal Policy Optimization*<sup>6</sup> (PPO) trainiert. Die Optimierung des Verhaltens findet dabei über eine **distanzbasierte Belohnungsfunktion** statt.

In Abhängigkeit der Entfernung der Agenten zu den Komponenten des Ökosystems (Hindernissen, Artgenossen, Jäger/Beute, Nahrung) erhalten diese zu jedem Simulationsschritt eine Belohnung. Folglich wird **kollektives Verhalten nicht explizit** von den Agenten gefordert.



Abb. 4: Diffuser Schwarm (deklarativ)



Abb. 5: „Tornado“ (deklarativ)



Abb. 6: Fluchtverhalten in der Gegenwart eines Jägers (deklarativ)

## Implementierung im Partikelsystem der Unreal Engine

Um eine performante Anwendung beider Modelle zu ermöglichen, findet die Simulation in einem **GPU-basierten Partikelsystem** der *Unreal Engine* statt. **Spatial Hashing** wird zur räumlichen Partitionierung des Simulationsraumes genutzt, um die Abfrage der nächsten Nachbarn optimieren zu können. Beide Modelle werden über **High Level Shading Language (HLSL)** im Partikelsystem implementiert.

## Ergebnisse

Die visuelle Inspektion beider Modelle konnte die **Herausbildung kollektiver Verhaltensweisen und Bewegungsmuster verifizieren** (vgl. Abb.1-6). Um diese kollektiven Dynamiken quantifizieren zu können, wurde anhand der Positionsdaten der Agenten eine **Clusterbildung (HDB-SCAN<sup>7</sup>)** durchgeführt und verschiedene Kennzahlen berechnet. Die **gebildeten Cluster** sowie **Extension<sup>8</sup>** und **Polarisation<sup>8</sup>** weisen auf die Gemeinsamkeiten und Unterschiede beider Modelle hin (vgl. Abb.7-9). Sowohl eine **räumliche Aggregation** als auch eine **gemeinsame Ausrichtung** der Agenten konnten hierdurch bestätigt werden. Das deklarative Modell zeichnet sich im Vergleich zum regelbasierten Vorgehen durch räumlich diffuse Strukturen aus (vgl. Abb. 8).

Für die **Auswertung der Performanz** wurde die durchschnittliche **GPU-Berechnungsdauer** für einen Simulationsschritt in Abhängigkeit der Anzahl an simulierten Partikeln erhoben (vgl. Abb. 10). Bis zu einer Partikelanzahl von etwa 15.000 sind die Unterschiede zwischen beiden Ansätzen marginal, wobei ab 40.000 Partikeln eine Divergenz einsetzt. Das **regelbasierte Modell** schneidet dann **etwa 15 bis 20 ms schlechter** ab. Die Auswertung der durchschnittlichen Anzahl an Bildern pro Sekunde (BpS) belegt, dass **beide Modelle mit 5000 Partikeln und etwa 70 BpS** simuliert werden können (vgl. Abb. 11).

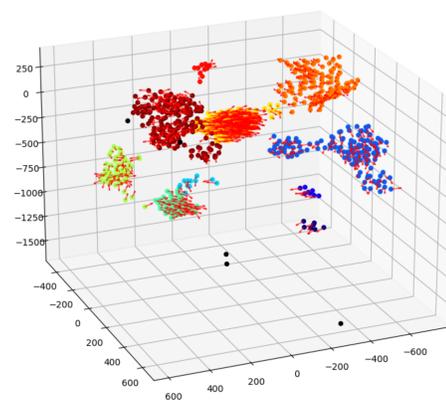


Abb. 7: Cluster des regelbasierten Modells (Schwarz: nicht klassifiziert)

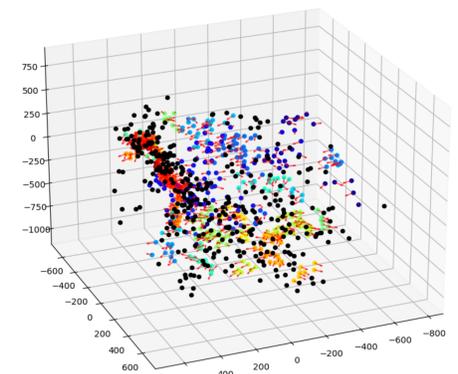


Abb. 8: Cluster des deklarativen Modells (Schwarz: nicht klassifiziert)

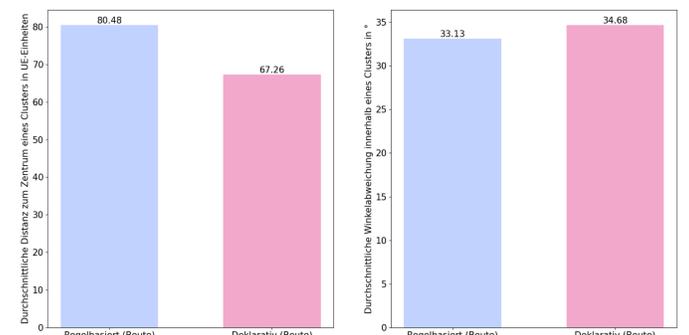


Abb. 9: Vergleich der Extension und Polarisation beider Modelle

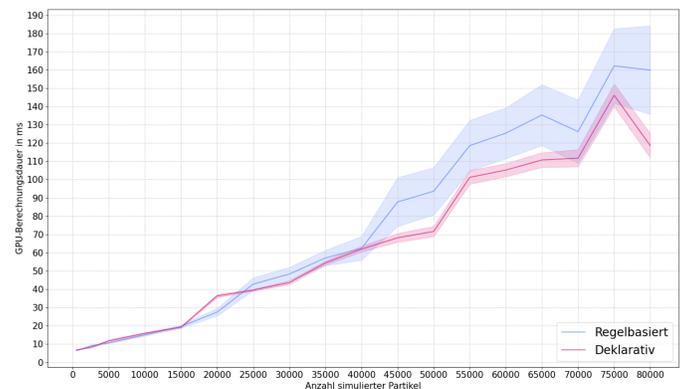


Abb. 10: Durchschnittliche GPU-Berechnungsdauer (in ms) pro Simulationsschritt in Abhängigkeit der Anzahl an simulierten Partikeln

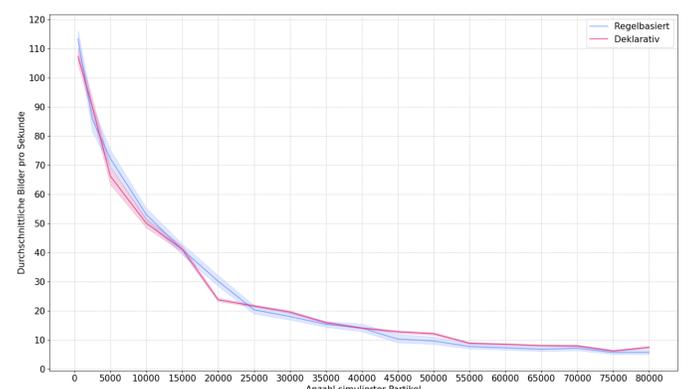


Abb. 11: Durchschnittliche Bilder pro Sekunde in Abhängigkeit der Anzahl an simulierten Partikeln

## Fazit

Die Ergebnisse zeigen, dass sich **kollektive Verhaltensweisen über ein deklaratives Verfahren** in einem virtuellen, dreidimensionalen Ökosystem entwickeln lassen und es zur **Herausbildung räumlicher Bewegungsmuster** kommt. Die Überführung des deklarativen Modells in das Partikelsystem der *Unreal Engine* mittels Blockmatrix-Multiplikation und Umwandlung in HLSL-Code war ebenfalls erfolgreich. Entgegen der Erwartung ist die Implementierung des deklarativen Ansatzes **performanter** als die des regelbasierten Vorgehens. Nichtsdestotrotz können **beide Implementierungen mehrere Tausend Agenten in Echtzeit simulieren**. Eine Schwäche des entwickelten deklarativen Modells ist die **Instabilität** in Bezug auf die **Konfiguration des Ökosystems und der Agenten**. Es ergibt sich hierdurch weiteres Forschungspotenzial, sowohl für die Weiterentwicklung eines deklarativen Modells, als auch für die Optimierung beider Ansätze hinsichtlich der Performanz.

## Literatur

- <sup>1</sup>CUMMINGS, JAMES. J. & JEREMY N. BAIENSON (2016): How Immersive Is Enough? A Meta-Analysis of the Effect of Immersive Technology on User Presence. In: *Media Psychology*, Vol. 19 (29), S. 272 – 309.
- <sup>2</sup>REYNOLDS, CRAIG W. (1987): Flocks, Herds, and Schools: A Distributed Behavioral Model. In: *ACM SIGGRAPH Computer Graphics*, Vol. 21 (4), S. 25 – 34.
- <sup>3</sup>SPECTOR, LEE & JON KLEIN (2002): Evolutionary Dynamics Discovered via Visualization in the BREVES Simulation Environment.
- <sup>4</sup>REYNOLDS, CRAIG W. (2002): Steering Behaviors For Autonomous Characters.
- <sup>5</sup>VICSEK, TAMÁS & ANNA ZAFEIRIS (2012): Collective Motion. In: *Physics Reports*, Vol. 517 (3-4), S. 71 – 140.
- <sup>6</sup>SCHULMAN, JOHN; WOLSKI, FILIP; DHARIWAL, PRAFULLA; RADFORD, ALEC & OLEG KLIMOV (2017): Proximal Policy Optimization Algorithms.
- <sup>7</sup>CAMPELLO, RICARDO J. G. B.; MOULAVI, DAVOUD & JOERG SANDER (2013): Density-Based Clustering Based on Hierarchical Density Estimates. In: *Advances in Knowledge Discovery and Data Mining*, Vol. 7819, S. 160 – 172.
- <sup>8</sup>HUTH, ANDREAS & CHRISTIAN WISSEL (1992): The Simulation of the Movement of Fish Schools. In: *Journal of Theoretical Biology*, Vol. 156 (3), S. 365 – 385.