

Kooperation in selbstorganisierten heterogenen Schwärmen¹

Ruby L. V. Moritz²

Abstract: In heterogenen Schwärmen haben Individuen verschiedene Qualifikationen oder Interessen, die deren Verhalten maßgeblich beeinflussen können. Sie treten nicht nur in der Natur, sondern auch zunehmend in technischen Anwendungen auf. Die hier zusammengefasste Dissertation erforscht das Problem der Teambildung mit einem Fokus auf multikriterieller Entscheidungsfindung. Anhand von Multi-Agent-Systemen wurden Strategien zur Bildung von Teams, die mehrere Ressourcen abbauen, analysiert. Informationsarme Entscheidungsmechanismen erwiesen sich als sehr effektiv. Darüberhinaus wurde ein Model mit Agenten, die Ressourcen multikriteriell ordnen, entwickelt. Es zeigte sich, dass die Art der Ordnungsrelation den Optimierungsprozess und die Lösungsqualität beeinflusst, sowohl in Multi-Agent-Systemen, als auch bei multikriteriellen Metaheuristiken. Eine hohe Diversität von Ordnungsrelationen im System stellte sich als sehr profitabel heraus.

1 Schwarmintelligenz und multikriterielle Entscheidungsfindung

In der Natur wird Komplexität typischerweise durch dezentrale, verteilte und heterogene Systeme organisiert. Über Millenia hinweg wurden sie durch evolutionäre Prozesse geformt und können heute diversen Selektionsdrücken widerstehen. Dank ihrer außergewöhnlichen Flexibilität und Anpassungsfähigkeit haben sie sich auf allen Kontinenten verbreitet. Besonders faszinierend sind die einfachen Mechanismen, die beispielsweise sozialen Insektenstaaten eine umfangreiche Nährstoffversorgung sichern, hygienische Standards erhalten und Schutz vor Räubern und Konkurrenten bieten. Diese Eigenschaften sind leider nicht typisch für humane Gesellschaften. Doch, wo das menschliche Gehirn komplex und vielschichtig ist, haben Insekten deutlich einfachere Nervensysteme. Wenn tatsächlich Schwärme aus einfachen Individuen besser geeignet sind zur Erfüllung einfacher - aber essentieller - Aufgaben als zentralisierte Systeme, dann kann das Entwickeln von Strategien auf Schwarmebene maßgeblich für unsere Zukunft sein.

Heterogene Schwärme Schwärme können aus identischen Individuen bestehen, doch meistens sind sie - ob natürlich oder künstlich - heterogen. Insbesondere wenn die Schwarmmitglieder zur Bewältigung verschiedener Aufgaben entwickelt wurden, zeichnen sie sich durch individuelle Fähigkeiten aus. Es ist nicht ausgeschlossen, dass sie auch Aufgaben, für die sie nicht designt wurden, bearbeiten können, wenngleich weniger effizient. In Not-situationen kann es jedoch zwingend erforderlich sein, dass bestimmte Aufgaben erfüllt werden und Effizienz eine untergeordnete Rolle spielt. Flexible Individuen sind hierbei besonders gut geeignet, wenn sie ihre Fähigkeiten mit entsprechenden Kosten anpassen können. Im Folgenden werden die Mitglieder eines Schwarms als *Agenten* bezeichnet.

¹ Englischer Titel der Dissertation: "Cooperation in Self-Organized Heterogeneous Swarms"

² Otto-von-Guericke-Universität Magdeburg, ruby.moritz@ovgu.de

Wenn nicht jeder Agent alle benötigten Fähigkeiten zum Erfüllen einer Aufgabe vorweist, ist es notwendig, dass mehrere Agenten miteinander kooperieren, um innerhalb eines Teams diese Fähigkeiten zu kombinieren. Weiterhin gibt es Aufgaben, die von sich aus eine Zusammenarbeit mehrerer Agenten erfordert, beispielsweise der Transport großer oder schwerer Objekte. Solche *Multi-Agent-Aufgaben* setzen voraus, dass Agenten sich in Teams zusammenfinden und kooperieren. Die Zuordnung von Aufgaben, die von einzelnen Agenten bearbeitet werden, ist umfangreich untersucht worden [GM04]. Das Problem der Zuordnung von Multi-Agent-Aufgaben hingegen, ist weniger gut studiert. Eine Formalisierung des Problems ist vorhanden [LZ03], doch nur wenige Lösungsstrategien wurden untersucht [SK98]. Die zusammengefasste Dissertation analysiert, sowohl theoretisch als auch durch Simulationen, Lösungsstrategien insbesondere für Systeme mit zur Laufzeit konfigurierbaren Agenten.

Multikriterielle Entscheidungsfindung Ein bedeutender Aspekt, der innerhalb dieser Arbeit untersucht wurde, ist die Fähigkeit von Teams multikriterielle Entscheidungen zu treffen. Die Schwierigkeit bei multikriteriellen Entscheidungsproblemen ist die gleichzeitige Optimierung mehrerer Qualitätskriterien, zum Beispiel Kosten, Zeitaufwand oder Sicherheit. Oft muss man bei einem Qualitätskriterium Abstriche machen, um ein anderes verbessern zu können. Die von Vilfredo Pareto eingeführte *Pareto-Dominanz* erlaubt es zwei Lösungen zu vergleichen, wenn eine in allen Qualitätskriterien mindestens genauso gut wie die andere ist und in mindestens einem Kriterium besser. Doch alle Paare von Lösungen a, b aus der Lösungsmenge X für die mindestens zwei Kriterien $i, j \in \{1, \dots, k\}$ existieren, in der jeweils eine Lösung besser ist als die andere, sodass $f_i(a) < f_j(b)$ und $f_j(b) < f_i(a)$ gilt, können mit der Pareto-Dominanz nicht geordnet werden. Hierbei sei k die Anzahl aller Kriterien und $f_i(a)$ die Funktion, die $a \in X$ bezüglich des Kriteriums i bewertet. In der Dissertation werden mehrere Ordnungsrelationen vorgeschlagen, die eine weitreichendere Vergleichbarkeit als die Pareto-Dominanz ermöglichen. Die Qualität dieser Ordnungsrelationen wird mithilfe von theoretischen Untersuchungen und multikriteriellen Metaheuristiken ergründet, bevor sie in Multi-Agent-Systemen zur Anwendung kommen.

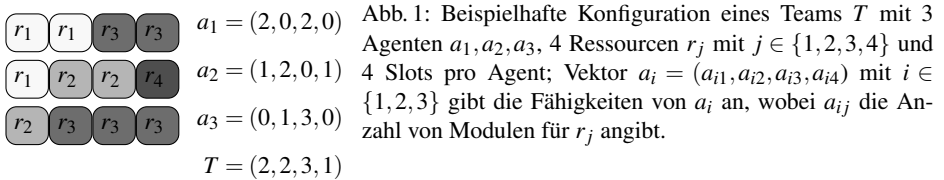
In Abschnitt 2 wird zunächst auf die Teambildung in Multi-Agent-Systemen eingegangen, Modelle beschrieben und entsprechende Ergebnisse erläutert. In Abschnitt 3 werden Eigenschaften von mehreren Ordnungsrelationen theoretisch und experimentell verglichen. Anschließend wird in Abschnitt 4 gezeigt, wie Multi-Agent-Systeme Ordnungsrelationen priorisieren. Den Abschluss bildet eine kurze Synthese der präsentierten Ergebnisse.

2 Effektive Teams in Multi-Agent-Systemen

Im Zentrum der Doktorarbeit stehen Schwärme von Agenten, deren Aufgabe es ist verschiedene Ressourcen zu sammeln. Dabei ist nicht jeder Agent gleichermaßen befähigt zum Sammeln der verschiedenen Typen von Ressourcen. Die Fähigkeiten eines Agenten werden über dessen Konfiguration festgelegt. Hierzu wird ein Steckplatz- bzw. *Slot-Modell* verwendet. Jedem Agent steht eine feste Anzahl von Slots zur Verfügung, die er

mit Ressourcen-spezifischen Modulen belegt kann. Je mehr Slots mit Modulen für eine spezifische Ressource belegt sind, desto effektiver kann der Agent diese sammeln.

Agenten können ihre Effektivität erhöhen, indem sie Teams bilden und von Synergieeffekten profitieren. Hierfür wird eine Teamkonfiguration berechnet, die dann die Teammitglieder als ihre eigene übernehmen. Die Konfiguration eines Teams bestimmt sich nicht über die absolute Anzahl von Modulen der Teammitglieder, sondern setzt sich aus den Fähigkeiten der besten Agenten je Ressource zusammen. So kann im optimalen Fall pro Ressource ein Agent alle seine Slots zum Abbau seiner zugeordneten Ressource belegen. Daraus folgt, dass das optimale Team genau einen Agenten je Ressource hat. Abbildung 1 verdeutlicht wie sich die Konfiguration eines Teams zusammensetzt.



Ein Agent in dessen Team sich für jeden Ressourcentyp mindestens ein anderer Agent befindet, der diese Ressource besser sammeln kann als er, gibt seinem Team keinen Mehrnutzen. Dann ist dieser Agent für das Team überflüssig. Seien nur Teams ohne überflüssige Agenten valide und die Qualität der Partition einer Menge A von Agenten in Teams definiert als die summierte Effektivität aller Agenten gemäß ihrer Teamkonfiguration. Besteht die Menge A aus zwei validen Teams, dann ist das Problem die Partition von A mit höchster Qualität zu finden NP-schwer. Der entsprechende Beweis erfolgte über eine Reduktion des 3-SAT Problems auf das *optimale Partitionsproblem* [Mo15b].

In Simulationen wurden verschiedene Bewegungsstrategien für Agenten analysiert. Diese müssen entscheiden, ob sie sich in Richtung von hilfreichen Agenten oder nahrhaftem Regionen bewegen. Hierbei zeigt sich unter anderem, dass kleine Teams profitieren, wenn sie sehr kritisch in der Auswahl neuer Mitglieder sind und nahrhafte Regionen bevorzugen. Für größere Teams hingegen ist der Austausch von Agenten mit anderen Teams rentabler [MM13].

Rekonfigurierbarkeit Das modulare Slot-Modell wurde gewählt, um rekonfigurierbare Hardware zu simulieren. Rekonfigurierbare Agenten haben die Möglichkeit sich an die Bedürfnisse des Teams anzupassen und ungenutzte Module auszutauschen. In dem untersuchten Model bewegen sich die Agenten in einer Arena und können andere Agenten, die sich in ihrem Laufweg befinden als Teammitglied rekrutieren. In der Arena gibt es mehrere Quellen, die radial eine spezifische Ressource verströmen. Je näher sich ein Agent oder Team in der Nähe der Quelle einer Ressource befindet, desto größer ist das Vorkommen dieser Ressource und damit auch der Erfolg beim Sammeln. Jeder Agent hat eine Energieversorgung, die alle 500 Zeitschritte für 50 Zeitschritte neu aufgeladen oder gewechselt werden muss. Zum Aufladen verlässt ein Agent sein Team, ist unbeweglich und kann keine Ressourcen sammeln.

Es zeigte sich, dass das Bewegungsverhalten der Agenten einen großen Einfluss auf die Effektivität des Systems und die Größen der gebildeten Teams hat [MM14]. Langsame Agenten, die sich häufiger um ihre eigene Achse drehen akkumulieren größere und effektivere Teams als Agenten, die sich sehr zielstrebig bewegen.

Eine adaptive Strategie zur Teambildung erlaubt Teams, so lange Agenten aufzunehmen, bis ein Agent im Team ein ungenutztes Modul aufweist. Erst wenn dieses Modul durch ein Nützliches ausgetauscht, darf das Team weitere Mitglieder rekrutieren. In Abbildung 2 ist zu sehen, dass die durchschnittliche Teamgröße tatsächlich von der Anzahl der verfügbaren Ressourcen abhängt [MM15a]. Dabei ist zu beachten, dass das System mit einzelnen Agenten initialisiert wird, d.h. alle Agenten sind initial in Teams der Größe 1. Diese adaptive Strategie erzielt für das System eine höhere Effektivität als ein System mit vergleichbaren Teamgrößen, in dem Agenten zufällig mit einer vorgeschriebenen Wahrscheinlichkeit entscheiden, ob sie einen Agenten rekrutieren.

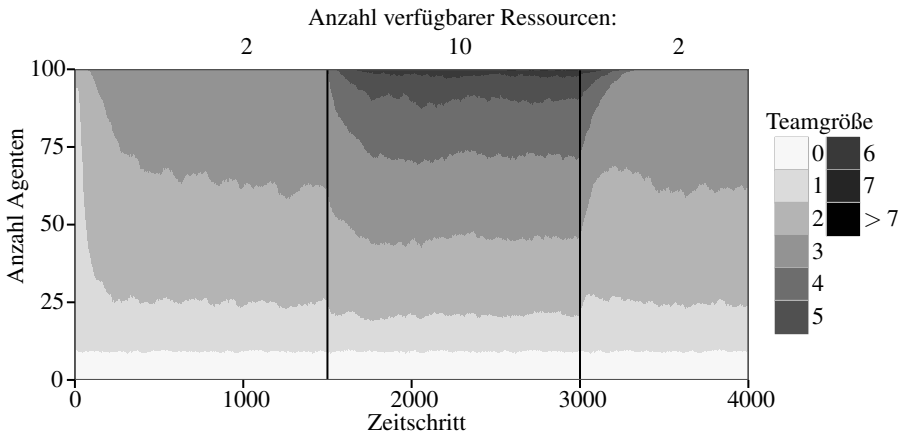


Abb. 2: Zeitreihe über 4000 Zeitschritte einer Simulation; durchschnittliche Anzahl von Agenten, die Mitglied in einem Team der angegebenen Größe sind; Agenten, die gerade Energie aufladen, sind in Teams der Größe 0; in den ersten 1500 und letzten 1000 Zeitschritten sind nur 2 Ressourcen verfügbar, dazwischen 10 (gekennzeichnet durch vertikale Linien).

Schlussfolgernd, können einfache Strategien die Adaptivität und Effektivität in dynamischen kooperativen Systemen steigern, indem Teams ihre Größe selbst regulieren. Ein weiterer Aspekt der Dissertation ist die Adaption von Verhaltensregeln in Schwärmen. Hierzu wurde untersucht, wie Agenten multikriterielle Entscheidungen fällen, wenn sie mehrere Ordnungsrelationen zur Auswahl haben. Dieser Untersuchung ging eine umfangreiche theoretische und experimentelle Analyse dieser Ordnungsrelationen voraus.

3 Multikriterielle Rangordnungen

Ein multikriterielles Optimierungsproblem ist anstelle von einer einzelnen Zielfunktion, über mehrere Zielfunktionen $\vec{f} = (f_1, \dots, f_k)$ definiert, die es ohne Beschränkung der Allgemeinheit zu minimieren gilt. Das gesuchte Optimum ist, wegen der Mehrdimensiona-

lität des Suchraumes, kein Punkt, sondern ein $(k - 1)$ -dimensionaler Raum und enthält typischerweise viele Lösungen. Er wird als *Pareto-Front* bezeichnet. Hierbei bezieht man sich generell auf die Pareto-Optimalität, gemäß der jede Lösung optimal ist, wenn die Verbesserung eines Kriteriums nur möglich ist, indem mindestens ein anderes Kriterium verschlechtert wird. Da es, insbesondere bei NP-schweren Problemen, oft keine akzeptable Möglichkeit gibt die Pareto-Front zu bestimmen, findet man sich in vielen Anwendungen damit ab, wenn nur eine Teilmenge der Pareto-optimalen Lösungen berechnet werden, bzw. Lösungen, die der Pareto-Front sehr nah sind. Um die Qualität einer Menge von Lösungen zu bestimmen wird das dominierte Hypervolumen zwischen einem oder mehreren Referenzpunkten und der gegebenen Lösungsmenge als Maßstab herangezogen. In Abbildung 3 wird dieses Konzept anhand eines Beispiels grafisch dargestellt.

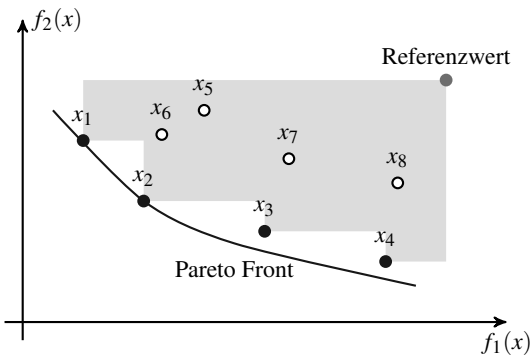


Abb. 3: Lösungen x_1, \dots, x_8 im zwei-dimensionalen Suchraum und die tatsächliche (meist unbekannte) Pareto-Front (dunkle Linie); Lösungen x_1 bis x_4 (dunkel) sind nicht-dominiert bezüglich der Pareto-Dominanz; die graue Fläche gibt das Hypervolumen der nicht-dominierten Front an bezüglich eines Referenzwertes (obere rechte Ecke) an.

Mit starker Ähnlichkeit zu den untersuchten Multi-Agent-Systemen, nutzen populationsbasierte Metaheuristiken Selektionsmechanismen um aus einer (relativ kleinen) Menge von Lösungen die 'Besten' auszuwählen. Dies ist zum Beispiel der Fall beim *populationsbasierten Ameisenalgorithmus* (P-ACO) [GM02]. Er nutzt wie der originale Ameisenalgorithmus [DCG99] eine Pheromonmatrix, die allerdings nur mit Pheromon aus der aktuellen Population P befüllt wird. Die Population enthält p Lösungen, deren Struktur genutzt wird, um l neue Lösungen zu generieren. Aus diesen $p + l$ Lösungen werden p Lösungen selektiert als Population für die nächste Iteration. Bei kleinen Populationen ist der Selektionsschritt besonders einflussreich für das Konvergenzverhalten des Algorithmus.

Das Prinzip der Pareto-Optimalität (\prec) ist nicht total, d.h. viele Lösungen sind unvergleichbar. Deshalb ist \prec oft unzureichend, um eine fundierte Auswahl an Lösungen zu treffen. Multikriterielle Ordnungsrelationen, die totale Halbordnungen induzieren, schaffen hier Abhilfe. Die Dissertation beschränkt sich dabei auf die theoretische Analyse und den experimentellen Vergleich von Ordnungsrelationen, die möglichst wenig Rechenaufwand erfordern. Diese werden im Folgenden beschrieben.

Rangordnungen Der *Winning Score* [MBC06], der gemäß [CK07] equivalent zum *Average Rank* [BW98] ist, wird vom durchschnittlichen Rang einer Lösung abgeleitet. Sei $r_i(a)$ der Rang von Lösung a bezüglich des Kriteriums i innerhalb einer Menge von Lösun-

gen A , dann wird der durchschnittliche Rang bestimmt durch $\text{rang}(a) = \sum_{i=1}^k r_i(a)$. Ähnlich zur *Global Detriment* Methode [GFTPCC09], wird die *gewichtete* Rangordnung $<_w$ über eine gewichtete Summe, allerdings in paarweisen Vergleichen, mit normalisierten Gewichten w_1, \dots, w_k bestimmt, sodass $a <_w b$ g.d.w. $\sum_{i=1}^k w_i f_i(a) \leq \sum_{i=1}^k w_i f_i(b)$ gilt.

In einem Turnier-ähnlichem Vergleich, bei dem alle Lösungen paarweise mit $<$ verglichen werden über alle Kriterien, können mithilfe verschiedener Punktesysteme mehrere Ordnungsrelationen definiert werden. Eine Lösung ‘gewinnt’ gegen eine andere Lösung, wenn sie in mehr Kriterien besser ist als die andere. Für die Ordnungsrelation *Win-Lose* $<_{WL}$ ist sowohl die Anzahl der ‘gewonnenen’ Vergleiche relevant, sowie die Anzahl der ‘verlorenen’ Vergleiche. So gilt $a <_{WL}^A b$, für $a, b \in A$, wenn bei paarweisen Vergleichen mit allen Lösungen aus A entweder a häufiger gewonnen hat als b , oder bei gleich vielen Gewinnen, zumindest seltener verloren hat. Die *Punkte* Ordnungsrelation hingegen, vergibt für jeden gewonnenen Vergleich w viele Punkte und für jedes Unentschieden genau einen Punkt. Die Summe über alle Punkte ergibt das Ordnungskriterium für diese Ordnungsrelationen.

Entsprechende Beweise bestätigten, dass diese vier Ordnungsrelationen totale Halbordnungen ist, d.h. sie sind reflexiv, transitiv und total. Darüber hinaus sind sie feiner als die Pareto-Dominanz [Mo13, Mo15a].

Weitere untersuchte Selektionsverfahren sind das *Standard*-Verfahren, dass zusammen mit dem multikriteriellen P-ACO vorgeschlagen wurde [GM03]. Hierbei wird für die Population eine Lösung und ihre $p - 1$ nächsten Nachbarn im Suchraum aus der nicht-dominierten Front gewählt. Das außerdem verwendete *Crowding*-Verfahren vergleicht jede neue Lösung a mit einer Untermenge $B \in P$ aus der Population [An07]. Habe $b \in B$, von allen Lösungen aus B die kleinste Differenz zu a im Lösungsraum, dann wird b durch a ersetzt, wenn $a \prec b$. Dieser Ansatz ist nicht zu verwechseln mit dem *crowding* Maß von [De00], das Ähnlichkeiten von Lösungen im Suchraum misst.

Konvergenzverhalten Die Ordnungsrelationen wurden von einem P-ACO und einem genetischen Algorithmus (GA) genutzt, um multikriterielle Instanzen des *Fließfertigungsplanungsproblems* (FSP) und des *Problems des Handlungsreisenden* (TSP) zu optimieren. Während beim FSP die Wahl der Kriterien (Fertigungszeit, totale Laufzeit, Wartezeiten der Maschinen und Aufträge) die Korrelation zwischen diesen festlegt, wurde eine spezielle Methode entwickelt, um für die TSP Instanzen Korrelationen nutzerdefiniert zu setzen. Mithilfe einer umfangreichen theoretischen Analyse wurde die erwartete Korrelation exakt bestimmt [Mo14]. In einer Untersuchung auf Robustheit der verschiedenen Ordnungsrelationen gegen positive und negative Korrelationen zwischen den Kriterien, waren Methoden, die auf dem Prinzip der Pareto-Dominanz basieren stabiler als randomisierte oder gewichtete Methoden.

Abbildung 4 zeigt, dass bei den zwei untersuchten Problemen die Ordnungsrelationen unterschiedlich gut abschneiden. Während das Standard- und Crowding-Verfahren nicht zur erwünschten Konvergenz der Algorithmen führen, erreichen die anderen vier Ordnungsrelationen schnell gute Lösungen und dominieren einen großen Anteil des Suchraumes. Die

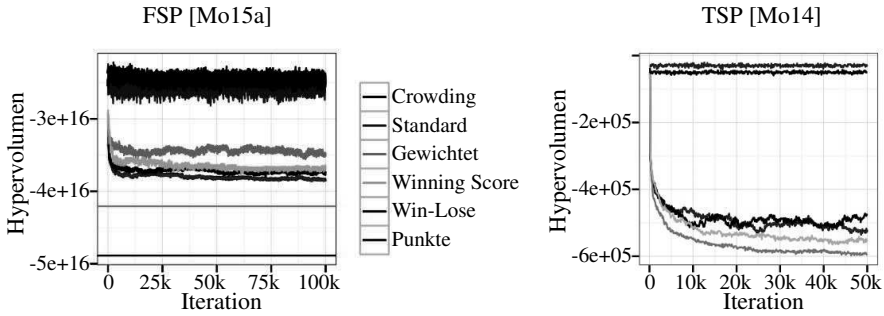


Abb. 4: Konvergenzverhalten des P-ACO mit den entsprechenden Ordnungsrelationen auf einer FSP Instanz (*car1*) und einer TSP Instanz abgeleitet von der *att48* Instanz mit positiver Korrelation; Hypervolumen der Lösungsmengen in Population und neu erzeugten Lösungen; gemessen alle 100 Iterationen; gemittelt über 10 Durchläufe; Der Referenzpunkt setzt sich zusammen aus allen gemessenen Maximalwerten für jedes Kriterium über alle Durchläufe. Für die kleinere FSP Instanz war es möglich die tatsächlich Pareto-Front zuberechnen und als Vergleich mit anzugeben: Die obere horizontale Linie ist das durchschnittliche Hypervolumen von 1000 Stichproben von 5 Lösungen aus der Pareto-Front (Populationsgröße), die untere horizontale Linie ist der entsprechende Wert für eine Stichprobe von 30 Lösungen (Populationsgröße zusammen mit neu erzeugten Lösungen).

Ergebnisse zeigen klar, dass es nicht ein einzelnes optimales Verfahren gibt, sondern in Abhängigkeit zum gewählten Problem, andere Verfahren zu priorisieren sind.

4 Multikriterielle Entscheidungsfindung in Teams

Motiviert durch die Forschungsergebnisse aus Abschnitt 3, wurden dMulti-Agent-Systeme mit mehreren Ordnungsrelationen versehen, sodass die Agenten lernen, welche Ordnungsrelation gemäß der aktuellen Situation am günstigsten ist. Lernen in Schwärmen, insbesondere soziales Lernen, rückt zunehmend in den Fokus der Forschungsgemeinschaft im Bereich der Schwarmintelligenz. Eine besondere Herausforderung liegt hierbei beim Lernen in dynamischen Umgebungen, in denen eine regelmäßige Neoadaption stattfinden muss und Konvergenz vermieden werden sollte. In diesem Rahmen wurde ein neues Konzept für evolutionäre Schwärme vorgestellt: *Haplo-Diploidie*. Dieses Konzept, inspiriert von haplo-diploiden Organismen, beinhaltet ein Vererbungsschema, dass die Diversität im Schwarm erhöht, da alle Agenten zwei Genome besitzen, dabei aber auch die Kommunikation reduziert im Vergleich zu diploiden Systemen basierend auf [GS87]. Zu Vergleichszwecken wurde auch ein haploides System entwickelt, in dem Agenten nur ein Genom zur Verfügung haben.

Die Agenten bewegen sich in einer Arena, in der Aufgaben gleichmäßig verteilt sind und unterschiedliche Anforderungen haben. Agenten, die Informationen zu mehreren Aufgaben speichern können, müssen im Team entscheiden, welche Aufgabe als Nächste bearbeitet wird. Dabei erwägen sie (1) Bewegungs- und Bearbeitungszeit, (2) den Bonus der durch Erfüllung der Aufgabe ausgezahlt wurde, (3) die Wahrscheinlichkeit eine ausreichende Teamgröße beim Erreichen der entsprechenden Aufgabe zu haben und (4) die

Aktualität der Informationen, die veraltet sein können. Jeder Agent hat eine ihm zugeordnete Ordnungsrelation. In einer gleichberechtigten Entscheidung wird die Aufgabe, deren durchschnittlicher Rang am höchsten ist, vom Team gewählt.

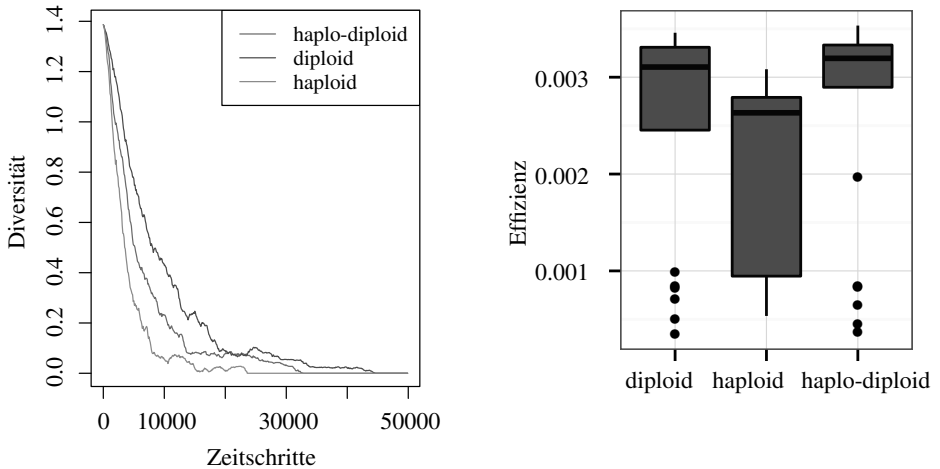


Abb. 5: Diversität der Ordnungsrelationen im System, gemessen mit dem Shannon-Weaver Index und durchschnittlich gesammelter Bonus (Effektivität) bei dynamischer Umgebung, die alle 100 Zeitschritte zwischen verschiedenen Szenarios wechselt.

Es zeigte sich, dass nicht einzelne Ordnungsrelationen, sondern Mischungen aus diesen, die Effektivität des Systems maximieren. Allerdings senken zufällige Effekte und genetischen Drift die Diversität in den Systemen so stark, dass alle Systeme homogenisiert werden [MM15b].

5 Synthese

Diversität in komplexen Systemen ist Herausforderung und Chance zugleich. Die Herausforderung besteht unter anderem in der effektiven Verteilung von Kompetenzen, etwa durch das Bilden von Teams. In umfassenden Untersuchungen von Multi-Agent-Systemen konnte gezeigt werden, dass autonome Teambildung in dynamischen Szenarios adaptiv reguliert werden muss, um die Effizienz des Systems zu maximieren. Bei Teams von rekonfigurierbaren Agenten ist die Größe des Teams maßgeblich für dessen Effizienz.

Doch Diversität birgt auch unverkennbare Vorteile. Hier wurde untersucht wie Diversität im multikriteriellen Entscheidungsfinden Systeme beeinflusst. Systeme, die ihre Diversität länger aufrecht erhalten können, erreichen höhere Effizienzen. Diese Forschungsergebnisse zeigen eindeutig, dass für die Zukunft diversitätserhaltende und -erzeugende Methoden von großem Interesse sein werden.

Literatur

- [An07] Angus, D.: Crowding Population-based Ant Colony Optimisation for the Multi-objective Travelling Salesman Problem. In: Computational Intelligence in Multi-criteria Decision Making, IEEE Symposium on. S. 333–340, April 2007.
- [BW98] Bentley, P.J.; Wakefield, J.P.: Finding Acceptable Solutions in the Pareto-Optimal Range using Multiobjective Genetic Algorithms. In (Chawdhry, P.K.; Roy, R.; Pant, R.K., Hrsg.): *Soft Computing in Engineering Design and Manufacturing*, S. 231–240. Springer, 1998.
- [CK07] Corne, David W.; Knowles, Joshua D.: Techniques for Highly Multiobjective Optimisation: Some Nondominated Points Are Better Than Others. In: Proceedings of the 9th Annual Conference on Genetic and Evolutionary Computation. GECCO '07, ACM, New York, NY, USA, S. 773–780, 2007.
- [DCG99] Dorigo, Marco; Caro, Gianni; Gambardella, Luca: Ant algorithms for discrete optimization. *Artificial life*, 5(2):137–172, 1999.
- [De00] Deb, K.; Agrawal, S.; Pratap, A.; Meyarivan, T.: A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. In: *Parallel Problem Solving from Nature PPSN*. LNCS 1917. Springer, S. 849–858, 2000.
- [GFTPCC09] Garza-Fabre, M.; Toscano Pulido, G.; Coello Coello, C. A.: Ranking Methods for Many-Objective Optimization. In: *Proc. Advances in Artificial Intelligence (MICAI)*. Jgg. 5845 in LNCS, S. 633–645, 2009.
- [GM02] Guntsch, M.; Middendorf, M.: A population based approach for ACO. In (Cagnoni, Stefano; Gottlieb, Jens; Hart, Emma; Middendorf, Martin; Raidl, Günther R., Hrsg.): *Applications of Evolutionary Computing*. LNCS 2279. Springer, S. 72–81, 2002.
- [GM03] Guntsch, M.; Middendorf, M.: Solving multi-objective permutation problems with population based ACO. In (Fonseca, Carlos M.; Fleming, Peter J.; Zitzler, Eckart; Thiele, Lothar; Deb, Kalyanmoy, Hrsg.): *Evolutionary Multi-Criterion Optimization*. LNCS 2636. Springer, S. 464–478, 2003.
- [GM04] Gerkey, Brian P.; Mataric, Maja J.: A Formal Analysis and Taxonomy of Task Allocation in Multi-Robot Systems. *The International Journal of Robotics Research*, 23:939 – 954, 2004.
- [GS87] Goldberg, David E; Smith, Robert E: Nonstationary Function Optimization Using Genetic Algorithms with Dominance and Diploidy. In: *ICGA*. S. 59–68, 1987.
- [LZ03] Lau, Hoong Chuin; Zhang, Lei: Task allocation via multi-agent coalition formation: Taxonomy, algorithms and complexity. In: *Tools with Artificial Intelligence*, 2003. Proceedings. 15th IEEE International Conference on. IEEE, S. 346–350, 2003.
- [MBC06] Maneeratana, Kuntinee; Boonlong, Kittipong; Chaiyaratana, Nachol: Compressed-objective Genetic Algorithm. In: *Proceedings of the 9th International Conference on Parallel Problem Solving from Nature*. PPSN'06, Springer-Verlag, Berlin, Heidelberg, S. 473–482, 2006.
- [MM13] Moritz, R.L.V.; Middendorf, M.: Self-organized cooperation between agents that have to solve resource collection tasks. In: *Swarm Intelligence (SIS)*, 2013 IEEE Symposium on. S. 206–212, April 2013.

- [MM14] Moritz, R.L.V.; Middendorf, M.: Self-adaptable Group Formation of Reconfigurable Agents in Dynamic Environments. In (Terrazas, German; Otero, Fernando E. B.; Masegosa, Antonio D., Hrsg.): Nature Inspired Cooperative Strategies for Optimization (NICSO 2013), Jgg. 512 in Studies in Computational Intelligence, S. 287–301. Springer International Publishing, 2014.
- [MM15a] Moritz, R.L.V.; Middendorf, M.: Decentralized and dynamic group formation of reconfigurable agents. *Memetic Computing*, 7(2):77–91, 2015.
- [MM15b] Moritz, R.L.V.; Middendorf, M.: Evolutionary Inheritance Mechanisms for Multi-criteria Decision Making in Multi-agent Systems. In: Proceedings of the 2015 on Genetic and Evolutionary Computation Conference. GECCO '15, ACM, New York, NY, USA, S. 65–72, 2015.
- [Mo13] Moritz, R.L.V.; Reich, E.; Schwarz, Ma.; Bernt, M.; Middendorf, M.: Refined Ranking Relations for Multi Objective Optimization And application to P-ACO. In: Proceedings of the 15th Annual Conference on Genetic and Evolutionary Computation. GECCO '13, ACM, New York, NY, USA, S. 65–72, 2013.
- [Mo14] Moritz, R.L.V.; Reich, E.; Bernt, M.; Middendorf, M.: The Influence of Correlated Objectives on Different Types of P-ACO Algorithms. In (Blum, Christian; Ochoa, Gabriela, Hrsg.): Evolutionary Computation in Combinatorial Optimisation, Jgg. 8600 in Lecture Notes in Computer Science, S. 230–241. Springer Berlin Heidelberg, 2014.
- [Mo15a] Moritz, R.L.V.; Reich, E.; Schwarz, M.; Bernt, M.; Middendorf, M.: Refined ranking relations for selection of solutions in multi objective metaheuristics. *European Journal of Operational Research*, 243(2):454 – 464, 2015.
- [Mo15b] Moritz, Ruby Louisa Viktoria: Cooperation in self-organized heterogeneous swarms. Dissertation, Universität Leipzig, 2015.
- [SK98] Shehory, Onn; Kraus, Sarit: Methods for Task Allocation via Agent Coalition Formation. *Artificial Intelligence*, 101(1-2):165–200, Mai 1998.



Ruby L. V. Moritz (*8. Juni 1987, Erlangen) studierte Bioinformatik an der Martin-Luther-Universität Halle-Wittenberg (Oktober 2006 - September 2011, *sehr gut*). Im Februar 2012 wechselte sie als wissenschaftliche Mitarbeiterin und Promotionsstudentin an die Universität Leipzig. In der Arbeitsgruppe von Martin Middendorf war sie neben ihrer Forschungstätigkeit auch bei der Betreuung studentischer Abschlussarbeiten involviert und sammelte Lehrerfahrungen. Während der dreijährigen Promotionsphase war sie zu Gast beim Algorithms & Computational Biology Laboratory der National Taiwan University in Taipeh, ROC, und als DAAD-Stipendiatin beim Advanced Concept Team der Europäischen Welt- raum Behörde (ESA) in Noordwijk, NL. Im Februar 2015 verteidigte sie erfolgreich ihre Promotion “Cooperation in Self-Organized Heterogeneous Swarms” mit *summa cum laude* und ist seit August 2015 in der Arbeitsgruppe von Sanaz Mostaghim an der Otto-von-Guericke-Universität Magdeburg als Postdoktorandin in Lehre und Forschung tätig.