



Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

Seminarausarbeitung Master 2. Semester

Torben Woggan

Mustererkennung in Bewegungsdaten

Inhaltsverzeichnis

1	Einleitung	3
1.1	Muster in Bewegungsdaten	3
1.2	Einsatz von Mustererkennung	4
2	Grundlagen	4
2.1	Aufbau der Bewegungsdaten.....	4
2.2	Entdeckung neuer Muster	5
3	Einsatzzweck in „WALK“	5
3.1	Ziele von „WALK“	5
3.2	Einsatz von Mustererkennung für „WALK“	5
3.3	Vorgehen im Projekt	6
4	Vergleichbare Projekte	7
4.1	Social Forces Model	8
4.2	Klassifizierung von Bewegungsmustern.....	10
4.3	Relative Motion („REMO“)	12
5	Abgrenzung und Ausblick	14
6	Literaturverzeichnis	15
7	Abbildungsverzeichnis	17

1 Einleitung

Diese Ausarbeitung befasst sich mit der Erkennung von Mustern in spatio-temporalen Bewegungsdaten. Im Rahmen des Projekts und Seminars im zweiten Mastersemester wird zunächst über die Grundlagen der Mustererkennung aufgeklärt, bevor über die Anwendung der Mustererkennung für die im Projekt „WALK“ entwickelte Evakuierungssimulation berichtet wird. Wichtige Arbeiten aus diesem Bereich werden vorgestellt und mit dem Ziel im Projekt verglichen. Zuletzt wird ein Ausblick auf das weitere Vorgehen gegeben.

Im ersten Kapitel wird zunächst darüber aufgeklärt, was genau ein Muster in Bewegungsdaten ist. Hierzu wird eine Definition von Mustern in Bewegungsdaten aufgestellt und es werden die Ursachen der Entstehung dieser Muster aufgezeigt. Danach werden beispielhaft verschiedene Einsatzbereiche von Mustererkennung beschrieben.

Das zweite Kapitel vermittelt die Grundlagen von Mustern in Bewegungsdaten. Hierzu wird zunächst beschrieben, in welcher Form die Bewegungsdaten vorliegen. Der zweite Teil behandelt das Vorgehen zur Entdeckung neuer Muster in Bewegungsdaten.

Das dritte Kapitel beschreibt, wie mit Hilfe von Mustererkennung in Bewegungsdaten die Validität der im Projekt „WALK“ entwickelten Evakuierungssimulation verbessert werden kann. Als erstes erfolgt eine kurze Einführung in das Projekt „WALK“, danach folgt eine Beschreibung der Einsatzmöglichkeiten der Mustererkennung in „WALK“. Der letzte Teil zeigt das bisherige Vorgehen im Projekt zur Identifizierung nützlicher Muster in Bewegungsdaten für die Validierung.

Im vierten Kapitel werden für unsere Forschung relevante andere Arbeiten vorgestellt und verglichen. Zunächst wird das Social Forces Model erläutert. Dieses kann viele in der Realität vorhandene emergente Muster korrekt darstellen und ist eine unserer Quellen für Bewegungsdaten. Danach werden die verschiedenen Klassen und Arten von Mustern in Bewegungsdaten vorgestellt. Dies stellt eine wichtige Grundlage zur Beschreibung der Muster dar. Zuletzt wird Relative Motion („REMO“) vorgestellt. Hierbei handelt es sich um ein Projekt, welches ein Konzept zur Erkennung von Mustern in Bewegungsdaten erarbeitet hat.

Im letzten Kapitel finden ein Vergleich und eine Abgrenzung der vorgestellten Arbeiten zu den Zielen im Projekt statt. Außerdem wird ein Ausblick auf das weitere Vorgehen gegeben.

1.1 Muster in Bewegungsdaten

Die Definition von Mustern in Bewegungsdaten ist sehr allgemein gehalten und umfasst dadurch verschiedene Typen von Mustern. Ein Muster in Bewegungsdaten kann jede erkennbare räumliche oder zeitliche Regelmäßigkeit oder jedes interessante Verhältnis in den Daten sein (Dodge et al. 2008).

Die Muster entstehen durch bewusste und unterbewusste Interaktionen von Objekten oder Subjekten mit der Umwelt. Die sogenannte Emergenz beschreibt dabei das Bilden von neuem Verhalten durch nicht-lineare Interaktionen zwischen diesen Objekten oder Subjekten. Ähnlich ist die Selbst-Organisation, bei der sich durch nicht-lineare Interaktionen zwischen Objekten oder Subjekten

eine Organisation, z.B. die Formierung von geordneten Mustern, ergibt (Helbing und Johansson 2009).

Wurde ein Muster ausreichend beschrieben, so lassen sich Bewegungsdaten nach diesem Muster durchsuchen (Laube und Imfeld 2002). Welche Art von Muster jedoch von Interesse ist, ist vom jeweiligen Anwendungsbereich abhängig. Aus diesem Grund gibt es auch keine Übereinkunft über relevante Arten von Mustern (Dodge et al. 2008).

1.2 Einsatz von Mustererkennung

Mustererkennung hat viele verschiedene Anwendungsbereiche. Im Folgenden werden Beispiele für drei verschiedene Bereiche gegeben.

Ein Anwendungsbereich ist die Analyse des Bewegungsverhaltens von Tieren. Bei dieser Analyse kann z.B. von Interesse sein, ob die Wildtiere alle zum gleichen Wasserloch laufen. Es kann auch versucht werden, dass Alpha-Tier anhand der Bewegungsdaten zu identifizieren. Ein weiterer Punkt wäre der Nachweis von Schwarmintelligenz (Gudmundsson et al. 2004).

Auch für die Analyse von Sport kann die Mustererkennung eingesetzt werden. Mit ihrer Hilfe können bestimmte Taktiken, z.B. beim Fußball, erkannt werden. Auch die Auswertung kann mit Hilfe von Mustererkennung erfolgen, so lässt sich unter anderem bestimmen, welche Mannschaft die erfolgreicherer Verteidigungslinien hatte (Gudmundsson et al. 2004).

Ein weiterer Anwendungsbereich wäre auch der Sicherheitsbereich. Mit Hilfe der Mustererkennung können Bereiche automatisch überwacht werden, so dass beim Auftritt von etwas Unerwartetem z.B. ein Alarm ausgelöst wird (Gudmundsson und van Kreveld 2006).

2 Grundlagen

Dieses Kapitel beschreibt in welcher Form die Bewegungsdaten vorliegen müssen und wie diese gewonnen werden können. Außerdem wird gezeigt, wie neue Muster in den Daten entdeckt werden können.

2.1 Aufbau der Bewegungsdaten

Bei den betrachteten Bewegungsdaten handelt es sich um spatio-temporale Daten. Sie umfassen verschiedene Objekte oder Subjekte. Für jedes dieser Objekte oder Subjekte werden von den Daten Trajektorien beschrieben. Diese „raumbezogenen Lebenslinien“ sind Folgen aus mindestens jeweils einer einzigartigen ID, einer Position und einem Zeitpunkt (Laube et al. 2005). Die Zeitpunkte zu denen die Position der einzelnen Objekte oder Subjekte beschrieben wird, sollten möglichst gleich sein, damit zu jedem Zeitpunkt alle Positionen bekannt sind. Die Dimensionen der Objekte oder Subjekte werden in den Daten ignoriert. Es werden nur sogenannte Moving Point Objects (MPOs) betrachtet (Dodge et al. 2008).

Aus diesen Daten können wiederum neue Werte abgeleitet werden. Dies umfasst unter anderem die Geschwindigkeit der MPOs, die Beschleunigung der MPOs, die Ausrichtung der MPOs und die Dichte der MPOs in einem bestimmten Bereich (Laube et al. 2005).

Die Bewegungsdaten können von verschiedener Herkunft sein. Verbreitet sind vor allem GPS-Daten und Daten aus Videoaufnahmen. Es besteht auch die Möglichkeit, Bewegungsdaten in einer Simulation zu gewinnen, wie z.B. einer Evakuierungssimulation (Weiskopf et al. 2010).

2.2 Entdeckung neuer Muster

Neue Muster können auf verschiedene Weisen entdeckt werden. Eine Möglichkeit besteht darin, Data-Mining-Algorithmen zur Extrahierung von Mustern aus den Daten zu benutzen. Mit Hilfe von Data-Mining lassen sich so Beziehungen zwischen den Bewegungsdaten verschiedener MPOs erkennen oder Folgen eines bestimmten Verhaltens erkennen (Dodge et al. 2008). Auch das Clustering ähnlicher Trajektorien zu Gruppen ist hiervon ein Bestandteil (Weiskopf et al. 2010).

Eine weitere wichtige Möglichkeit zur Entdeckung neuer Muster stellt die Visualisierung der Daten (Visual Analytics) dar. Das Ziel hierbei ist es, die Komplexität der Daten zu verringern. Die Visualisierung vereinfacht für Menschen das Erkennen von Zusammenhängen stark. Diese können nun anhand der Visualisierung Muster in den Daten erkennen (Weiskopf et al. 2010).

Die gefundenen Muster müssen eindeutig beschrieben werden. Auch muss geklärt werden, ob das beschriebene Muster die gewünschte Situation ausreichend beschreibt. Hierzu müssen Hypothesen und Theorien aufgestellt und getestet werden (Laube 2001).

3 Einsatzzweck in „WALK“

Dieses Kapitel beschreibt welche Rolle die Mustererkennung in Bewegungsdaten für die im Projekt „WALK“ entwickelte Evakuierungssimulation spielt. Zuerst wird ein kurzer Überblick über diese Simulation gegeben. Danach wird erläutert, wie die Mustererkennung zur Validität der Simulation beitragen kann. Als letztes wird über das bisherige Vorgehen zur Erreichung dieser Ziele berichtet.

3.1 Ziele von „WALK“

Ein wichtiger Bestandteil des auf Bevölkerungsschutz spezialisierten Projekts „WALK“ an der HAW Hamburg ist die Entwicklung einer agentenbasierten Evakuierungssimulation. Mit dieser lassen sich Evakuierungen simulieren und somit unter anderem Gefahrstelle, Gefahrensituationen und Evakuierungszeiten bestimmen. Im Gegensatz zu makroskopischen Evakuierungssimulationen basiert „WALK“ nicht auf einem Flussmodell. Stattdessen handelt es sich um eine mikroskopische Simulation, bei der jedes bewegliche Objekt bzw. Subjekt durch einen Agenten dargestellt wird. Diese Agenten besitzen verschiedene Eigenschaften. Jeder Agent trifft selbstständig Entscheidungen. Diese werden auch durch Emotionen beeinflusst. Hierdurch soll ein realistischeres Verhalten erreicht werden. Damit jedoch brauchbare Erkenntnisse aus den Simulationsläufen gezogen werden können, muss die Simulation möglichst genau mit der Realität übereinstimmen, sie muss also valide sein.

3.2 Einsatz von Mustererkennung für „WALK“

In Woggan 2011 wurde ein Konzept zur Validierung von mikroskopischen Gruppensimulationen entwickelt. Dieses bestand unter anderem aus einer automatischen Validierung. Bei dieser wurde die Anzahl der Agenten in einem bestimmten Teil der Simulation mit der Anzahl an Personen in dem korrespondierenden Bereich der Vergleichsdaten zu gleichen Zeitpunkten verglichen. Lagen die Abweichungen unter einem bestimmten Schwellwert, so wurden die Szenen als gleich angesehen. Allerdings handelt es sich bei dieser Validierung nur um eine makroskopische Validierung. Das

eigentliche Verhalten der Agenten wird nicht überprüft. Hierfür musste eine zusätzliche Validierung durch Menschen stattfinden.

Um eine genauere Validierung zu ermöglichen, soll dieses Konzept nun um Methoden, die die Mustererkennung nutzen, erweitert werden. Durch Mustererkennung kann automatisch überprüft werden, ob in der Simulation und den Vergleichsdaten das gleiche Verhalten der Agenten bzw. Personen vorhanden ist. Tritt in den Vergleichsdaten ein bestimmtes relevantes Muster auf, so sollte dies auch in der Simulation auftreten. Beispiele für solche Muster wären unter anderem Muster, die das Bilden von Spuren oder Stau beschreiben. Auch Muster die Führerschaft oder Gruppen beschreiben, können von Interesse sein.

Eine weitere Möglichkeit ist, zu überprüfen, ob aus dem Auftreten von bestimmten Mustern die gleichen Resultate in der Simulation und den Vergleichsdaten folgen. Würde in den Vergleichsdaten die Verringerung der Geschwindigkeit in einem Bereich auf einen folgenden Stau hinweisen, so muss dies auch für die Simulation gelten.

Durch diese neuen Möglichkeiten der Validierung ist es nun möglich, auch ohne menschliche Hilfe eine Validierung durchzuführen, die auch das Verhalten der Agenten miteinbezieht. Die Ergebnisse sind weniger von der subjektiven Meinung von Menschen abhängig und so besser nachvollziehbar. Durch die Automatisierbarkeit lassen sich auch eine große Zeitersparnis und eine genauere Validierung erwirken, da die Validierung z.B. nach jeder Änderung an der Simulation neu durchgeführt werden könnte.

3.3 Vorgehen im Projekt

Die bisherigen Bewegungsdaten wurden mit der auf dem Social Forces Model basierenden Gruppensimulation „PedSim“ (Gloor 2012) erstellt. In „PedSim“ wurden für die Validierung und Mustererkennung interessante Szenarien erstellt. Unter anderem wurde ein Szenario erstellt, bei dem eine große Menge an Personen einen Raum durch eine Engstelle verlässt (Abbildung 1). Hierbei bildet sich ein Stau vor der Engstelle. Die Szenarien wurden simuliert und die Bewegungsdaten aufgezeichnet. Um nun aus diesen Daten Hypothesen zu neuen Mustern zu gewinnen, wurden sie zur Verringerung der Komplexität visualisiert. Hierfür wurde eine Vielzahl an verschiedenen Visualisierungen erstellt, die die Daten in zwei- und dreidimensionalen Diagrammen darstellen.

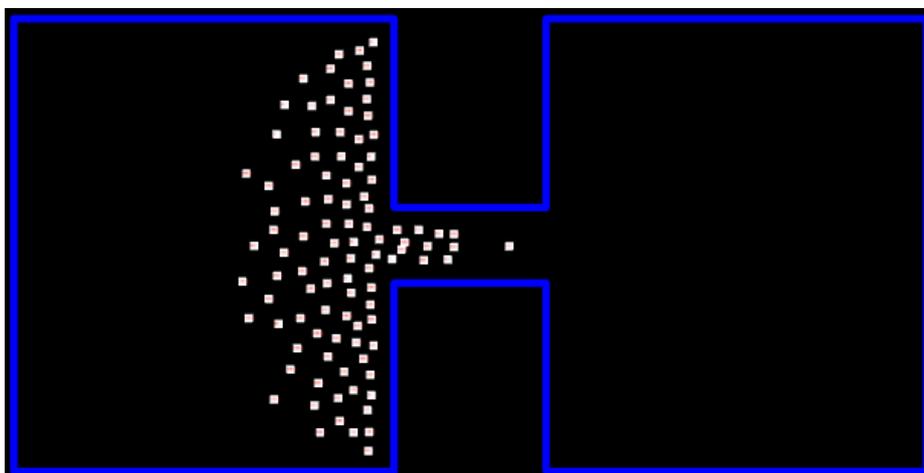


Abbildung 1 - Beispiel-Szenario zur Staubildung an Engstellen in PedSim

Eine der Visualisierungen stellt die Trajektorien der Agenten im Szenario dar (Abbildung 2). Die Höhe und Farbe der Trajektorien stellt hierbei die Zeit dar. Je höher die Trajektorie, desto mehr Zeit ist vergangen. Besitzt die Trajektorie also eine große Steigung, bedeutet dies, dass der Agent sich nur langsam fortbewegt hat. Im Beispiel-Szenario ist durch diese Darstellung sehr gut sichtbar, dass die Agenten ihre Geschwindigkeit vor der Engstelle verringern müssen. Auch die typische „Halbkreisbildung“ vor Engstellen ist gut erkennbar.

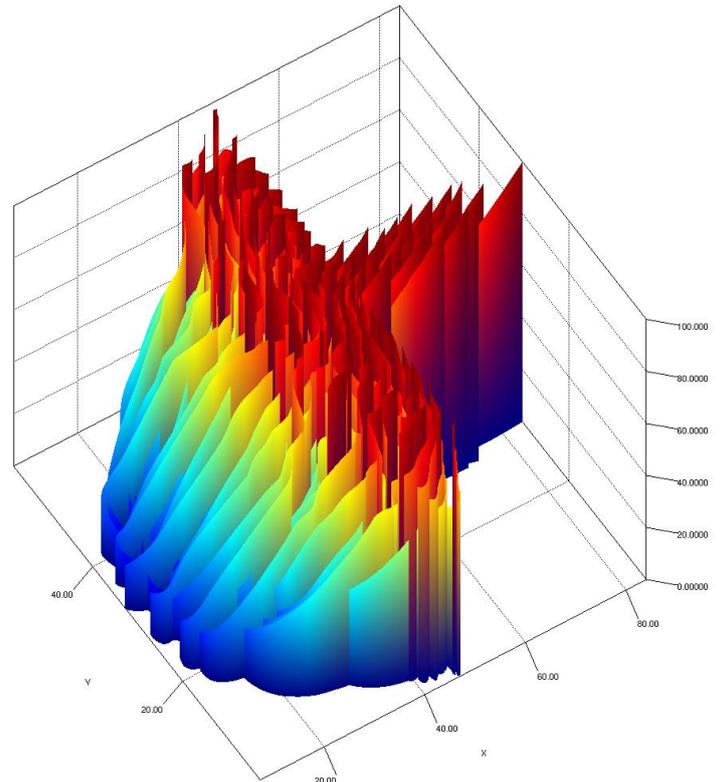


Abbildung 2 - Grafische Darstellung der Trajektorien der Agenten im Beispiel-Szenario

Außerdem wurde eine große Menge von Werten aus den Simulationsläufen bestimmt, die für die Entdeckung von Mustern und Vergleiche mit anderen Simulationen oder Realdaten verwendet werden können. Hierzu gehören unter anderem die Dichte um die Personen, die Flussrate in einem bestimmten Bereich, die Distanz zur nächsten Person und einfache Werte wie die Position, die Geschwindigkeit und den Richtungswinkel des Agenten. Diese Werte werden auch jeweils über alle Personen gemittelt berechnet, so dass sich z.B. eine allgemeine Verlangsamung der Flussgeschwindigkeit oder eine Zunahme der Dichte um die Personen beim Auftreten eines Staus beobachten lässt.

4 Vergleichbare Projekte

Dieses Kapitel beschreibt Projekte und Veröffentlichungen, die für unsere Forschung von Interesse sind. Begonnen wird mit dem Social Forces Model (Helbing und Johansson 2009). Hierbei handelt es sich um ein Modell zur Simulation von Menschenströmen. Da wir für die Generierung von Bewegungsdaten zurzeit eine Simulation einsetzen, die auf diesem Modell basiert („PedSim“), ist es wichtig über die Besonderheiten Bescheid zu wissen. Als nächstes folgt ein Projekt, dessen Ziel es ist, einen Rahmen zur Beschreibung von Bewegungsdaten zu bilden (Dodge et al. 2008).

Bewegungsmuster werden definiert und in verschiedene Klassen eingeteilt. Dies stellt eine wichtige Grundlage für unsere Arbeit dar. Als letztes wird Relative Motion („REMO“) vorgestellt (Laube und Imfeld 2002, Laube et al. 2005). Bei diesem Projekt gibt es die größten Übereinstimmungen mit unserer Arbeit, da ein Konzept zur automatischen Erkennung von Bewegungsmustern entwickelt und beschrieben wird.

4.1 Social Forces Model

Das Modell der „sozialen Kräfte“ von Helbing und Johansson (2009) ist ein Simulationsmodell für Fußgänger. Alle Fußgänger werden einzeln simuliert, sie besitzen jedoch keine individuellen Eigenschaften oder Intelligenz. Die Bewegungen der Fußgänger sind nur von Kräften abhängig. Diese können entweder anziehend oder abstoßend wirken. Anziehende Kräfte können z.B. von einem Zielort ausgehen. Abstoßende Kräfte wiederum sind unter anderem Wände, andere Agenten und Hindernisse. Durch dieses Konzept können sich die simulierten Fußgänger zu ihrem Ziel fortbewegen, ohne dass es zu Kollisionen oder Durchdringen von Hindernissen kommt.

Durch dieses einfache Konzept werden bereits viele in der Realität beobachtete emergente, also aus dem Zusammenspiel zwischen den Personen entstehende, Bewegungsmuster erzeugt. Dies zeigt, dass für diese Bewegungsmuster keine Kommunikation nötig ist und sie unterbewusst ablaufen. Beispiele hierfür sind z.B. bei der Betrachtung von in entgegengesetzter Richtung laufenden Fußgängerströmen zu finden.

Treffen Gruppen von Fußgängern aufeinander, die sich in verschiedene Richtungen fortbewegen wollen, so ist eine Bildung von Spuren erkennbar (Abbildung 3). Die Fußgänger folgen unterbewusst anderen Fußgängern, die sich in die gleiche Richtung fortbewegen, um ihre eigene Geschwindigkeit zu erhöhen und den Widerstand zu verringern. Da alle Fußgänger so handeln ergeben sich Spuren oder Schlangen von Personen, die sich fortbewegen. Dies ist sowohl in der Realität als auch im Social Forces Model zu beobachten.

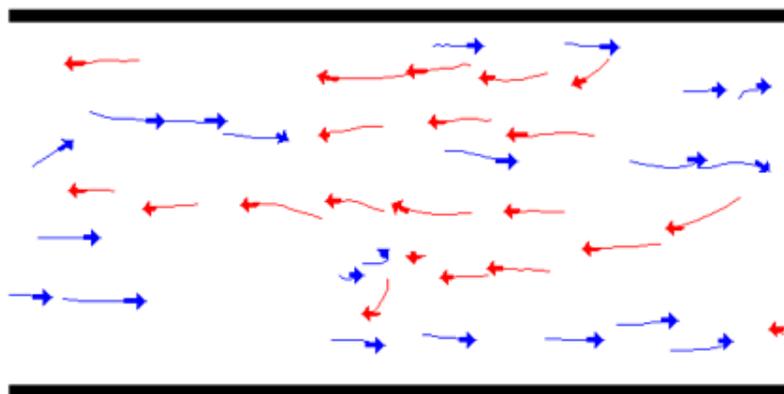


Abbildung 3 - Spurbildung bei zwei entgegengesetzten Fußgängerströmen (Helbing und Johansson 2009)

Ein ähnliches Muster ergibt sich bei engeren Passagen (Abbildung 4). Auch hier kommt es zu Spurbildung, jedoch entstehen oft nur zwei entgegengesetzte Spuren. Abhängig von der Kultur laufen die Personen links oder rechts. Auch dies kann unterbewusst ablaufen, ist aber antrainiert.



Abbildung 4 - Rechtslaufen bei zwei entgegengesetzten Fußgängerströmen (Helbing und Johansson 2009)

Ein letztes Beispiel für ein emergentes Muster sind die Personenflüsse an einer Engstelle (Abbildung 5). Wollen von beiden Seiten der Engstelle Personen auf die andere Seite gelangen, so ist zu beobachten, dass sich die beiden Flussrichtungen abwechseln. Schafft es eine Person, die Engstelle zu durchqueren, so folgen ihr andere Personen, die sich in die gleiche Richtung fortbewegen wollen. Dieser Fluss besteht so lange, bis der Druck aus der Gegenrichtung so groß wird, dass der Fluss zusammenbricht. Nun ist ein Fluss in die Gegenrichtung zu beobachten. Auch dieses Muster ist sowohl in der Realität als auch im Modell erkennbar.

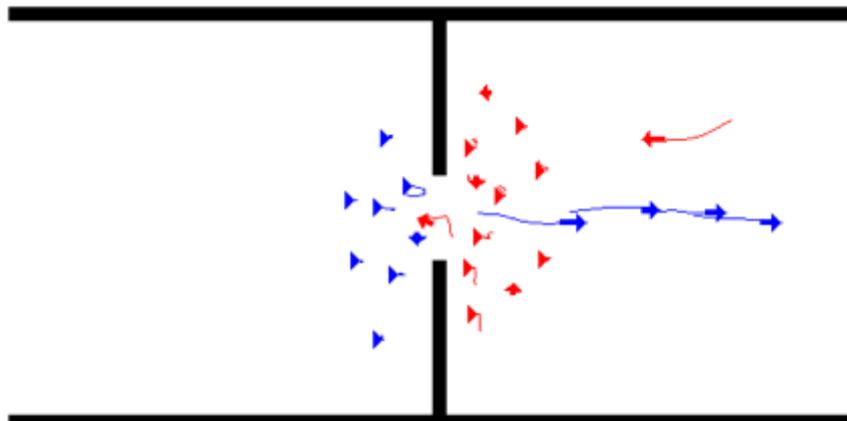


Abbildung 5 - Wechselnde Flüsse an Engstellen (Helbing und Johansson 2009)

Da unsere Bewegungsdaten unter anderem aus in „PedSim“, also einer auf dem Social Forces Model basierenden Gruppensimulation, selbstgenerierten Daten bestehen, ist es von großer Relevanz, dass die gewonnenen Daten auch echtes Verhalten zeigen. Wie gezeigt, weist das Social Forces Model viele der relevanten emergenten Muster auf und kann somit auch zur Generierung von Bewegungsdaten zu diesen und weiteren emergenten Mustern benutzt werden.

4.2 Klassifizierung von Bewegungsmustern

Da es noch keine Übereinkunft über relevante Bewegungsmuster und die Modellierung von Mustern in der Forschung gab, haben sich Dodge et al. (2008) daran versucht, dies zu beheben. Das Ziel ihrer Arbeit ist es, ein Konzept als Basis für die Entwicklung von Mustererkennungs- und Informationsvisualisierungs-Algorithmen zu entwerfen. Dieses soll dafür sorgen, dass die Algorithmen drei Eigenschaften erfüllen: Sie sollen effizient, effektiv und generisch sein. Effizient bedeutet, dass sie auch mit riesigen Datenmengen benutzbar sein sollen. Effektiv bedeutet, dass sie ein verlässliches Erkennen der Muster ermöglichen. Generisch wiederum bedeutet, dass sie für verschiedene Arten von Bewegungsdaten verwendbar sind.

Auf dem Weg zu diesem Ziel befinden sich einige Zwischenziele, die zuerst erreicht werden müssen. Zuerst wurde ein konzeptueller Rahmen zur Beschreibung von Bewegungsdaten erstellt. Danach fand eine Aufteilung von Bewegungsmustern in Klassen statt. Als nächstes wurden dann die Muster der verschiedenen Klassen definiert.

Die Beschreibung der Bewegungsdaten findet über Dimensionen und Parameter statt (Abbildung 6). Parameter können primitiv sein oder aber die erste oder zweite Ableitung eines primitiven Parameters sein. In den Dimensionen wird zwischen räumlich (spatial), temporal und spatio-temporal entschieden. Die primitiven Parameter sind Position (x,y) für räumliche Daten, Zeitpunkt oder Intervall (t) für temporale Daten und Position zu einem Zeitpunkt (x,y,t) für spatio-temporale Daten. Aus Positionen (x,y) lassen sich wiederum unter anderem Distanzen berechnen. Aus Zeitpunkten lassen sich z.B. Dauern bestimmen. Aus Positionen zu einem Zeitpunkt (x,y,t) lassen sich Geschwindigkeiten und gerichtete Geschwindigkeiten bestimmen. Diese Werte lassen sich jeweils weiter ableiten um noch mehr Informationen zu gewinnen.

Parameters Dimension	Primitive	Primary derivatives	Secondary derivatives
Spatial	Position (x,y)	Distance $f(posn)$	Spatial distribution $f(distance)$
		Direction $f(posn)$	Change of direction $f(direction)$
		Spatial extent $f(posn)$	Sinuosity $f(distance)$
Temporal	Instance (t)	Duration $f(t)$	Temporal distribution
	Interval (t)	Travel time $f(t)$	Change of duration $f(duration)$
Spatio-temporal (x, y, t)	—	Speed $f(x,y,t)$	Acceleration $f(speed)$
		Velocity $f(x,y,t)$	Approaching rate

Abbildung 6 - Tabelle zur Beschreibung der Bewegungsdaten (Dodge et al. 2008)

Bei den Bewegungsmustern wird zwischen generischen Mustern und Verhaltensmustern unterschieden (Abbildung 7). Die generischen Muster werden weiter in primitive Muster und zusammengesetzte Muster unterteilt. Primitive Muster können räumlich (spatial), temporal oder spatio-temporal sein. Zusammengesetzte Muster sind dagegen immer spatio-temporal.

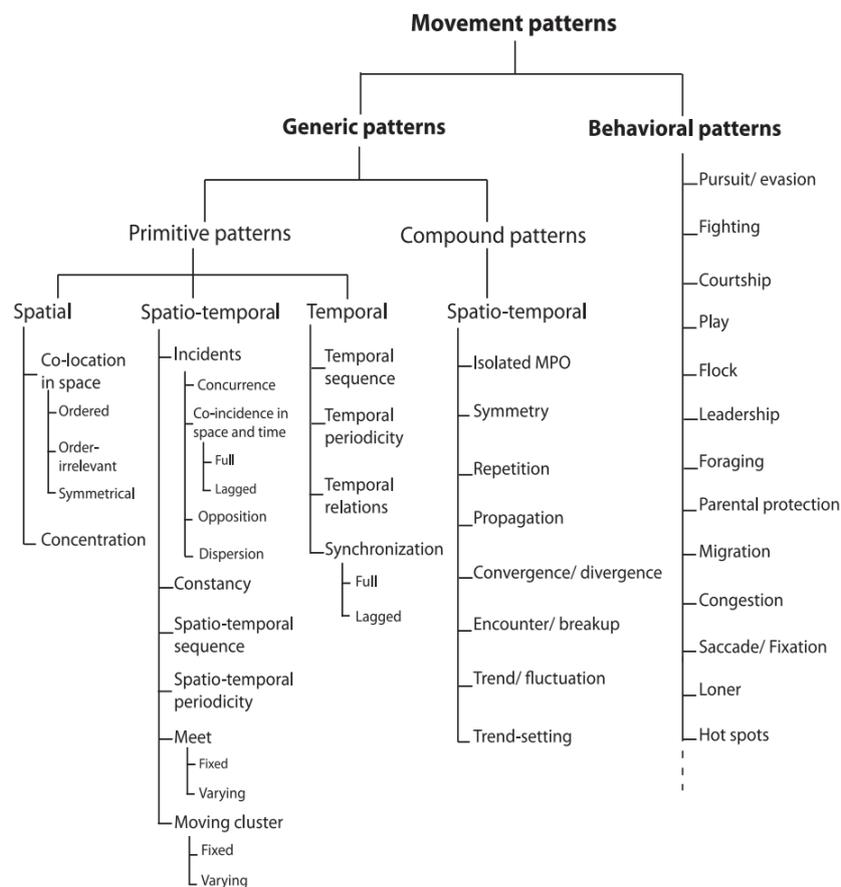


Abbildung 7 - Klassen der Bewegungsmuster (Dodge et al. 2008)

Generische Muster sind einfache Bewegungsmuster wie konstantes Fortbewegen in eine Richtung oder das Treffen von Objekten. Die hier enthaltenen Muster enthalten keinen höheren Sinn, es wird nicht hinterfragt, welche Aussage das Auftreten dieses Musters besitzt.

Im Gegensatz hierzu beschreiben Verhaltensmuster ein komplexeres Verhalten, das aus mehreren generischen Mustern, die hier als Bausteine dienen, zusammengesetzt ist. Diese Muster geben Erklärungen für das Bewegungsverhalten. Beispiele hierfür sind Führerschaft oder der elterliche Schutz ihrer Kinder.

Primitive und zusammengesetzte Muster gehören beide zu den generischen Mustern. Bei primitiven Mustern verändert sich während der Betrachtung nur ein Parameter. Bei einem Treffen (Position,t) werden für alle Objekte zu den gleichen Zeitpunkten die Positionen betrachtet. Der jeweilige Zeitpunkt (t) ist für alle Objekte also jeweils gleich.

Zusammengesetzte Muster sind aus primitiven Mustern zusammengesetzt und besitzen mehrere sich ändernde Bewegungsparameter. Sie beschreiben komplexe Beziehungen zwischen den Objekten. Ein gutes Beispiel hierfür ist das Trend-Setting: Ein Objekt macht etwas vor, bewegt sich z.B. zu einer bestimmten Position, und nach einiger Zeit machen andere Objekte das gleiche. Diese Zeit muss aber nicht für alle Objekte gleich sein, wir betrachten also nicht immer die gleichen Zeitpunkte (t), sondern möglicherweise für jedes Objekt einen anderen Zeitpunkt. Die Werte werden also nicht zur gleichen Zeit betrachtet, sondern diese Betrachtung ist zeitversetzt.

Die beschriebene Klassifizierung stellt eine wichtige Grundlage für unsere Arbeit dar. Sie erlaubt uns eine genaue Beschreibung und Definition von neu entdeckten Bewegungsmustern. Außerdem gibt die große Menge an beschriebenen Mustern einen guten Überblick über bekannte Muster und Möglichkeiten diese zu definieren. Diese Muster können auch als Anregung oder Baustein für neue Muster genutzt werden.

4.3 Relative Motion („REMO“)

Das Projekt „REMO“ von Laube und Imfeld (2002) und Laube et al. (2005) besitzt das Ziel, benutzerdefinierte Bewegungsmuster in Gruppen von Moving Point Objects (MPOs) finden und visualisieren zu können. Hierzu wurde zuerst ein Analysekonzept für Bewegungsdaten erstellt. Weitere Zwischenziele sind das Festlegen von Basisarten von Bewegungsmustern und die Entwicklung von Algorithmen zur Erkennung von Mustern in Bewegungsdaten.

Ein wichtiger Baustein von „REMO“ ist die sogenannte Analysematrix (Abbildung 8). Diese kann zur Darstellung von Richtungswinkeln, Geschwindigkeiten oder Änderungen der Geschwindigkeiten zu verschiedenen Zeitpunkten genutzt werden. Diese Daten können aus den Trajektorien der MPOs extrahiert werden. Die Darstellung der Werte erfolgt in diskreten Klassen. Richtungswinkel werden unter anderem in acht Klassen eingeteilt, die jeweils einen Bereich von 45° abdecken. Diese Klassen wurden nach den Himmelsrichtungen benannt: Nord, Nord-Ost, Ost, Süd-Ost, Süd, Süd-West und Nord-West. Neben einer Zeitachse besitzt die Analysematrix eine Objektachse. Im Gegensatz zur Zeitachse besitzt die Objektachse jedoch keine explizite Ordnung.

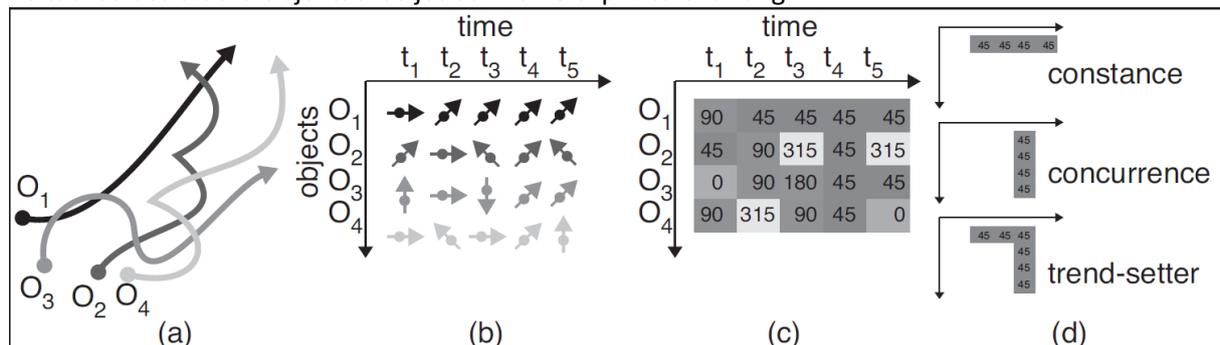


Abbildung 8 - Erstellung der REMO-Analysematrix (Laube et al. 2005)

Da die Analysematrix die Komplexität der Bewegungsdaten stark verringert, kann die Auswertung durch Menschen durchgeführt werden, jedoch ist auch eine Auswertung durch Algorithmen möglich.

Das Projekt definiert außerdem Basisarten von Bewegungsmustern (Abbildung 9). Unterschieden wird zuerst zwischen einfachen und komplexen Mustern. Zu den einfachen Mustern gehören Muster über die Zeit und Muster zwischen Objekten. Muster über die Zeit und zwischen Objekten sind komplexe Muster.

Simple patterns		Complex patterns
Patterns over time ↔	Patterns across objects ↓	Patterns over time and across objects ↕
SEQUENCE <i>t:1</i>	INCIDENT <i>1:n</i>	INTERACTION <i>t:n</i>
 <i>constance</i> <i>turn</i>	 <i>concurrency</i> <i>bimodality</i> <i>dispersion</i>	 <i>trend-setter</i> <i>independent</i>

Abbildung 9 - Basisarten von Bewegungsmustern mit Beispielen (Laube und Imfeld 2002)

Muster über die Zeit betrachten nur ein Objekt und den Verlauf seiner Parameter über die Zeit. Ein einfaches Beispiel hierfür ist das Muster „Konstanz“. Bezogen auf die Richtungswinkel besagt es, dass ein Objekt über einen bestimmten Zeitraum die gleiche Richtungswinkelklasse besitzt, sich also in die gleiche Richtung fortbewegt.

Muster zwischen Objekten betrachten nur einen Zeitpunkt und die jeweiligen Parameter der verschiedenen Objekte zu diesem Zeitpunkt. Ein einfaches Beispiel hierfür wäre die „Gleichzeitigkeit“. Bezogen auf die Richtungswinkel bedeutet dies, dass verschiedene Objekte zum gleichen Zeitpunkt die gleiche Richtungswinkelklasse besitzen, sich also zu diesem Zeitpunkt in die gleiche Richtung fortbewegen.

Komplexe Muster über die Zeit und zwischen Objekten betrachten verschiedene Objekte und verschiedene Zeitpunkte. Ein einfaches Beispiel für diese Art von Mustern ist das „Trend-Setting“-Muster. Dieses Muster besagt auf den Richtungswinkel bezogen, dass sich ein Objekt bereits mehrere Zeitpunkte lang in eine bestimmte Richtung fortbewegt und sich danach auch andere in diese Richtung fortbewegen. Sie folgen also seinem Beispiel.

Viele Muster lassen sich allein unter Nutzung der Analysematrix und den dort befindlichen Werten zum Richtungswinkel, der Geschwindigkeit und der Änderungen der Geschwindigkeit erkennen und beschreiben. Jedoch gibt es auch Muster, für die zusätzliche Informationen über die Umgebung, also z.B. Positionen der Objekte, nötig sind. Ein gutes Beispiel hierfür ist die „Herde“. Mitglieder einer Herde bewegen sich unter anderem zur gleichen Zeit in die gleiche Richtung, da sie zusammenbleiben. Jedoch reicht diese Definition von Herde nicht, da auch fälschlicherweise Herden bei Objekten erkannt werden könnten, die sich gar nicht in der gleichen Umgebung befinden. Die

Gefahr, dass dies passiert ist umso größer, je höher die Abstände zwischen den Messungen sind. So könnten beim Vogelflug verschiedene Tiere als zum gleichen Schwarm zugehörig erkannt werden, obwohl sie sich in ganz verschiedenen Teilen der Welt befinden. Der Definition von „Herde“ muss also noch der Abstand der einzelnen Objekte als wichtiger Parameter hinzugefügt werden. Nur Objekte, die sich in einem bestimmten Radius befinden, können zu einer „Herde“ gehören. Problematisch ist allerdings hierbei, dass bekannt sein muss, wie groß die Ausdehnung einer „Herde“ in dem betrachteten Beispiel und den Beispieldaten sein kann. Ohne das Einbeziehen von Positionen lassen sich außerdem auch keine Muster erkennen oder beschreiben, die aussagen, dass die Objekte sich zu einer Position hin oder von einer Position weg bewegen.

„REMO“ stellt also einen einfachen und nützlichen Rahmen für unsere Arbeit im Projekt zur Verfügung. Es erlaubt uns, von uns gefundene Muster zu beschreiben und wiederzufinden. Eine Erweiterung des Konzepts ist allerdings unausweichlich, da eines unserer Ziele das automatische Erkennen von Stau oder Staubildung ist. Hierfür ist es wichtig in welchem Bereich sich die Objekte befinden, deren Werte wie z.B. die Geschwindigkeit sich verändern.

5 Abgrenzung und Ausblick

Zu dem wirklichen Endziel, dem Einsatz der Mustererkennung als weitere Validierungsmöglichkeit von Fußgängersimulationen, ließen sich keinerlei Arbeiten auffinden. Die vorgestellten Arbeiten stellen jedoch wie bereits erwähnt jeweils einen wichtigen Teil der auf dem Weg zu diesem Ziel befindlichen Arbeit dar. Das Social Forces Model stellt eine wichtige Datenquelle dar, wobei von großer Wichtigkeit ist, dass die Daten in den betrachteten Szenarien möglichst realistisch sind. Dies konnte gezeigt werden. Auch die Klassifizierung und Definition von Mustern spielt eine wichtige Rolle, so dass die Arbeiten, die sich hiermit befasst haben, ebenfalls eine wichtige Rolle bei der Definition der für die Validierung benutzten Muster spielen. Die in „REMO“ beschriebene Mustererkennungstechnik stellt eine gute und einfache Grundlage zur Erkennung von Mustern dar, mit kleinen Erweiterungen wie der Betrachtung der Positionen der Objekte, wird sie auch für die Mustererkennung bei der Validierung von großer Hilfe sein.

Das weitere Vorgehen besteht nun darin, weitere konkrete Evakuierungsszenarien zu betrachten, um neue Muster zu gewinnen. Es müssen hierbei vor allem die Gefahrstellen und Gefahrensituation analysiert werden. So lassen sich neue Muster beschreiben, die z.B. auf einen Stau hinweisen. Aus dem Auftreten von bestimmten Mustern sollen Schlüsse auf mögliche Folgemuster oder Folgeereignisse getroffen werden können.

6 Literaturverzeichnis

Dodge et al. 2008

DODGE, S. ; WEIBEL, R. ; LAUTENSCHÜTZ, A.-K.: *Towards a Taxonomy of Movement Patterns*. In: Information Visualization, 7. Jg. 2008, Heft 3, S. 240-252.

- Online verfügbar unter: <http://dl.acm.org/citation.cfm?id=1594716>

Letzter Abruf: 28.08.2012

Gloor 2012

GLOOR, C.: *PedSim – A Pedestrian Crowd Simulation*.

URL: <http://pedsim.silmaril.org>

Letzter Abruf: 28.08.2012

Gudmundsson und van Kreveld 2006

GUDMUNDSSON, J. ; VAN KREVELD, M.: *Computing Longest Duration Flocks in Trajectory Data*. In: GIS '06 Proceedings of the 14th annual ACM international symposium on Advances in geographic information systems. New York, NY, USA : ACM, 2006. S. 35-42.

- Online verfügbar unter: <http://dl.acm.org/citation.cfm?id=1183479>

Letzter Abruf: 28.08.2012

Gudmundsson et al. 2004

GUDMUNDSSON, J. ; VAN KREVELD, M. ; SPECKMANN, B.: *Efficient Detection of Motion Patterns in Spatio-Temporal Data Sets*. In: GIS '04 Proceedings of the 12th annual ACM international workshop on Geographic information systems. New York, NY, USA : ACM, 2004. S. 250-257.

- Online verfügbar unter: <http://dl.acm.org/citation.cfm?id=1032222.1032259>

Letzter Abruf: 28.08.2012

Helbing und Johansson 2009

HELBING, D. ; JOHANSSON, A.: *Pedestrian, Crowd and Evacuation Dynamics*. In: Encyclopedia of Complexity and Systems Science (2009), Nr. 16, S. 6476-6496.

- Online verfügbar unter: <http://www.springerlink.com/content/qk06k3x47p26r685>

Letzter Abruf: 28.08.2012

Laube 2001

LAUBE, P.: *A Classification of Analysis Methods for Dynamic Point Objects in Environmental GIS*. In: Proceedings of the 4th AGILE conference on Geographic Information Science. Brünn, CZ : Masaryk University Brno, 2001. S. 121-134.

- Online verfügbar unter: http://plone.itc.nl/agile_old/Conference/brno2001/proceedings/14.pdf

Letzter Abruf: 28.08.2012

Laube und Imfeld 2002

LAUBE, P. ; IMFELD, S.: *Analyzing Relative Motion within Groups of Trackable Moving Point Objects*. In: GIScience '02 Proceedings of the Second International Conference on Geographic Information Science. London, UK : Springer-Verlag London, 2002. S. 132-144.

- Online verfügbar unter: <http://dl.acm.org/citation.cfm?id=646933.710710>

Letzter Abruf: 28.08.2012

Laube et al. 2005

LAUBE, P. ; VAN KREVELD, M. ; IMFELD, S.: *Finding REMO — Detecting Relative Motion Patterns in Geospatial Lifelines*. In: *Developments in Spatial Data Handling* (2005), Nr. 5, S. 201-215.

- Online verfügbar unter: <http://www.springerlink.com/content/t4vg447844v5n595>

Letzter Abruf: 28.08.2012

OpenABM Consortium 2012

OPEN AGENT BASED MODELING CONSORTIUM (Hrsg.): *Traffic Flows*.

URL: <http://www.openabm.org/book/1928/63-traffic-flows>

Letzter Abruf: 28.08.2012

Weiskopf et al. 2010

WEISKOPF, D. ; ANDRIENKO, G. ; ANDRIENKO, N. ; BAK, P.: *Visuelle Bewegungsanalyse in Video- und Geodaten*. In: *Informatik-Spektrum*, 33. Jg. 2010, Heft 6, S. 580-588.

- Online verfügbar unter: <http://www.springerlink.com/content/5161ltp334701432>

Letzter Abruf: 28.08.2012

Woggan 2011

WOGGAN, T.: *Validierung von Gruppensimulationen*. HAW Hamburg, Bachelorarbeit, 2011.

- Online verfügbar unter: <http://opus.haw-hamburg.de/volltexte/2011/1399/>

Letzter Abruf: 28.08.2012

7 Abbildungsverzeichnis

Abbildung 1 - Beispiel-Szenario zur Staubildung an Engstellen in PedSim	6
Abbildung 2 - Grafische Darstellung der Trajektorien der Agenten im Beispiel-Szenario	7
Abbildung 3 - Spurbildung bei zwei entgegengesetzten Fußgängerströmen (Helbing und Johansson 2009).....	8
Abbildung 4 - Rechtslaufen bei zwei entgegengesetzten Fußgängerströmen (Helbing und Johansson 2009).....	9
Abbildung 5 - Wechselnde Flüsse an Engstellen (Helbing und Johansson 2009).....	9
Abbildung 6 - Tabelle zur Beschreibung der Bewegungsdaten (Dodge et al. 2008)	10
Abbildung 7 - Klassen der Bewegungsmuster (Dodge et al. 2008)	11
Abbildung 8 - Erstellung der REMO-Analysematrix (Laube et al. 2005).....	12
Abbildung 9 - Basisarten von Bewegungsmustern mit Beispielen (Laube und Imfeld 2002)	13