
Verteilte nichtlineare modellprädiktive Regelung von unbemannten Luftfahrzeug-Schwärmen

Vom Fachbereich Maschinenbau
an der Technischen Universität Darmstadt
zur
Erlangung des Grades eines Doktor-Ingenieurs (Dr.-Ing.)
genehmigte

DISSERTATION

vorgelegt von

Dipl.-Ing. Armin Strobel
aus Sigmaringen

Berichterstatter: Prof. Dr.-Ing. Uwe Klingauf
Mitberichterstatter: Prof. Dr.-Ing. Jürgen Adamy

Tag der Einreichung: 24.11.2015
Tag der mündlichen Prüfung: 24.02.2016

Darmstadt 2016

D17



Erklärung

Hiermit erkläre ich, dass ich die vorliegende Arbeit, abgesehen von den in ihr ausdrücklich genannten Hilfen, selbständig verfasst habe.

Datum, Unterschrift



Kurzfassung

Diese Arbeit basiert auf Forschungsergebnissen aus meiner Zeit am Institut für Flugsysteme und Regelungstechnik an der Technischen Universität Darmstadt. Um einen Schwarm von *Unmanned Aerial Vehicles* (UAVs) sinnvoll einsetzen zu können, muss es dem Bediener (Systemmanager) oder einer kleinen Gruppe möglich sein, eine größere Anzahl an UAVs zu koordinieren. Hierfür benötigen die UAVs ein Mindestmaß an Autonomie, deren spezifische Gestaltung Gegenstand vorliegender Arbeit ist.

Die in dieser Arbeit beschriebene Regelung ist das Resultat aus einer systematischen Untersuchung bekannter Ansätze und den Anforderungen an einen Schwarm. Sie basiert auf einer modellprädiktiven Regelung. Die Bewertung der generierten Trajektorie erfolgt in diesem Fall durch multiple Potenzialfelder und nicht wie üblich durch eine Referenztrajektorie. Vorteile bestehen hinsichtlich der Möglichkeit, komplexere Vorgaben als bei einer Referenztrajektorie zu implementieren. Die Optimierung bei dieser Art der modellprädiktiven Regelung erfolgt durch einen evolutionären Algorithmus, welcher neben anderen Vorteilen auch möglicherweise vorhandene lokale Minima vermeiden kann.

Die Regelung wird theoretisch, analytisch und mittels Simulation auf ihre Eignung zur Koordination eines Schwarms untersucht. Unter Berücksichtigung bekannter Forschungsergebnisse und systematischer Schlussfolgerungen werden die nötigen Anforderungen ermittelt. Analytisch und durch Simulation wird die Wahrscheinlichkeit eines Versagens der Regelung, unter extremen Bedingungen, für grundlegende Funktionen des Schwarms bestimmt. In mehreren Szenarien werden unterschiedliche Missionen, für einzelne UAVs sowie für einen Schwarm von UAVs, untersucht. Weiter werden Simulationen der Szenarien mit Varianten der Regelung, welche unterschiedliche Optimierungsverfahren nutzen, durchgeführt. Abschließend werden die Ergebnisse auf die Robustheit bezüglich der Variation von Parametern und Modellen untersucht, um einen Eindruck zu gewinnen, in wieweit die Performanz abhängig von einer optimalen Parametrierung ist.

Das Ergebnis dieser Arbeit ist eine Regelung, die vorausschauend agiert und Zielkonflikte (mit Randbedingung und anderen Zielen) intelligent löst. Unter Einbezug von unterschiedlichen Zielsetzungen und variierenden Randbedingungen, ermöglicht die Regelung effektive Lösungen der Erfüllung einer Mission. Dies ist eine neue und effektive Methode, um einzelne UAVs oder einen Schwarm von UAVs zu regeln.



Vorwort

Ich möchte meinem Doktorvater, Prof. Dr.-Ing. Uwe Klingauf für die Unterstützung und den eingeräumten Freiraum zur Erstellung der Arbeit danken. Weiter möchte ich Prof. Dr.-Ing. Jürgen Adamy für die Übernahme des Co-Referats bedanken.

Bei der Deutschen Forschungsgemeinschaft (DFG) möchte ich mich für mein Stipendium bedanken. Meinen Kollegiaten und Kollegiatinnen im DFG-Graduiertenkolleg „Cooperative, Adaptive and Responsive Monitoring in Mixed Mode Environments“ (GRK 1362) sowie den beteiligten Professoren danke ich für die vielen horizonterweiternden Diskussionen und Gespräche.

Allen Mitarbeitern des Instituts für Flugsysteme und Regelungstechnik danke ich für die Unterstützung und anregenden Diskussionen sowie für das sehr angenehme Arbeitsklima. Im Besonderen möchte ich Dr.-Ing. Heike Meinert als auch Dr.-Ing. Frank Schmidt-Brücken für das ausdauernde Korrekturlesen danken.

Weiter möchte ich all meinen Freunden für die moralische Unterstützung während dieser Zeit danken. Besonderer Dank gebührt meinen Eltern Walburga und Franz Strobel als auch meinem Bruder Jörg Strobel für den familiären Rückhalt als auch für die Unterstützung.



Inhaltsverzeichnis

Kurzfassung	5
Vorwort	7
Symbole und Abkürzungen	11
1 Einleitung	15
1.1 Regelung von Schwärmen	19
1.2 Zielsetzung und Beitrag der Arbeit	20
1.3 Struktur der Arbeit	22
2 Stand der Forschung zur Schwarmregelung von UAVs	23
2.1 Schwarmregelung	23
2.1.1 Formationsregelung im Schwarm	24
2.1.2 Verfolgen von beweglichen Objekten	26
2.1.3 Exploration von Skalar- und Vektorfeldern	28
2.2 Vor- und Nachteile von zentralen und dezentralen Ansätzen	30
2.3 Flugregelung	31
2.3.1 Regelung mit Neuronalen Netzen	32
2.3.2 Modellprädiktive Regelung	33
2.4 Missionsplanung	44
2.4.1 Verhaltensbasierende Ansätze	44
2.4.2 Potenzial-/Vektorfeld Ansätze	46
2.4.3 Graphenbasierende Ansätze	49
2.5 Fazit	53
3 Konzeption einer dezentralen Regelung von Schwärmen	55
3.1 Auswahl des Verfahrens	55
3.1.1 Struktur des Verfahrens (Algorithmus)	57
3.1.2 Parallelen zu menschlichem Verhalten	59
3.2 Aufbau der Schwarmregelung	60
3.2.1 Modell der UAVs	60
3.2.2 Prädiktion	64
3.2.3 Potenzialfeld / Gütefunktional	65
3.2.4 Optimierer	76
3.3 Aufbau der Simulation	80
3.3.1 Umwelt	81

3.3.2	Sensoren/Schätzer	83
3.4	Fazit	84
4	Simulationstechnische Untersuchung mittels ausgewählter Szenarien	85
4.1	Konflikte mit Hindernissen	88
4.1.1	Analytische Betrachtung eines Konflikts mit einem Hindernis . . .	88
4.1.2	Problem der lokalen Minima	91
4.2	Konflikte mit anderen UAVs	99
4.3	Ausgewählte Missionsszenarien	109
4.3.1	Formationsflug als Missionsziel	109
4.3.2	Wegpunkte als Missionsziel	120
4.3.3	Identifikation eines Skalarfeldes als Missionsziel	127
4.4	Robustheit der Regelung	137
4.4.1	Robustheit des Optimierungsverfahrens	137
4.4.2	Robustheit gegenüber Modellungenauigkeiten und Störungen . . .	138
4.4.3	Robustheit gegenüber Variation der Parameter des Potenzialfeldes	139
5	Bewertung der Schwarmregelung	143
6	Zusammenfassung und Ausblick	147
	Literaturverzeichnis	151
	Anhang	161
A	Extended Kalman Filter (EKF)	161
B	Konflikte mit anderen UAVs	163
B.1	Statistik zu den Szenarien	163
B.2	Weitere Szenarien	168
C	Wegpunkte als Missionsziel	175
C.1	Szenarien ohne Hindernisse	175
C.2	Szenarien mit Hindernissen	178
D	Robustheit/Sensitivität der Regelung	182

Symbole und Abkürzungen

Variablen

α	Schrittweite / Allgemeine Konstante
ν	Messrauschen
ϕ	Rollwinkel
ψ	Azimutwinkel
Φ	Potenzial
γ	Flugbahnwinkel
λ	Ausfallrate
ρ	Luftdichte
a	Beschleunigung / Allgemeine Konstante
a^*	Spezifische Schub
c	Konzentration
c_w	Widerstandsbeiwert
C_w	Erweiterter Widerstandsbeiwert ($C_w = \frac{1}{2} \frac{\rho S c_w}{m}$)
d	Distanz
D	Diffusionskoeffizient
\vec{e}	Fehlervektor
E	Energie / Fehlervektorfolge [$\vec{e}(k) \ \vec{e}(k+1) \ \dots \ \vec{e}(k+K_H)$]
\vec{F}	Kraftvektor
g	Erdbeschleunigung / Gewichtung
\dot{h}	Vertikale Geschwindigkeit
\vec{j}	Potenzial- / Gütevektor
J	Potenzial / Gütevektor / Teilchenstromdichte
\bar{J}	Akkumuliertes Potenzial / Gütevektor
k	Diskreter Zeitpunkt
K	Kalman Gain
K_H	Länge des Prädiktionshorizonts
\vec{l}	Gewichtungsvektor der Potenziale (Missionsvektor)
m	Masse
n	Anzahl
N	Anzahl
P	Leistung / Wahrscheinlichkeit / Population
pos	Position
S	Bezugsflügelfläche
t	Zeit

T	Zeitkonstante / Periode
u	Eingang
\vec{u}	Eingangsvektor
U	Eingangsvektorfolge $[\vec{u}(k) \ \vec{u}(k+1) \ \dots \ \vec{u}(k+K_H)]$
V	(Flug-) Geschwindigkeit
\dot{V}	Horizontale Beschleunigung
\vec{w}	Referenzvektor
W	Widerstand / Referenzvektorfolge $[\vec{w}(k) \ \vec{w}(k+1) \ \dots \ \vec{w}(k+K_H)]$
x	Zustand / Lokale Position
\vec{x}	Zustandsvektor
X	Zustandsvektorfolge $[\vec{x}(k) \ \vec{x}(k+1) \ \dots \ \vec{x}(k+K_H)]$
y	Ausgang / Lokale Position
\vec{y}	Ausgangsvektor
Y	Ausgangsvektorfolge $[\vec{y}(k) \ \vec{y}(k+1) \ \dots \ \vec{y}(k+K_H)]$
z	Messwert / Lokale Position
\vec{z}	Messvektor
Z	Messvektorfolge $[\vec{z}(k) \ \vec{z}(k+1) \ \dots \ \vec{z}(k+K_H)]$

Matrizen

A	Systemmatrix
B	Eingangsmatrix
C	Ausgangsmatrix
D	Durchgangsmatrix
G	Gewichtungsmatrix (Allgemein)
H	Erweiterte Eingangsmatrix (MPC)
I	Einheitsmatrix
\mathbb{I}	Einsenmatrix / -Vektor $[1 \ 1 \ \dots \ 1]^T$
P	Kovarianzmatrix / Erweiterte Systemmatrix (MPC)
Q	Gewichtungsmatrix Zustand
R	Gewichtungsmatrix Stellgrößen

Index

*	Dimensionslos $x^* = \frac{x}{x_0}$
$\hat{}$	Schätzwert
0	Start / Anfangs (-Wert) / Auslegungs-
$4dt$	Vierdimensional
<i>avo</i>	Kollisionsvermeidung mit UAVs

<i>c</i>	Soll (-Wert)
<i>dis</i>	Diskret / Distanz
<i>end</i>	End (-Wert)
<i>f</i>	Freiheitsgrad
<i>fatal</i>	Fatal
<i>for</i>	Formation
<i>G</i>	Generation
<i>ges</i>	Gesamte
<i>H</i>	Horizont
<i>hig</i>	Flughöhe
<i>i</i>	Laufvariable
<i>imm</i>	Immigration
<i>j</i>	Laufvariable
<i>max</i>	Maximal
<i>min</i>	Minimal
<i>mod</i>	Modifikation
<i>NE</i>	<i>Never Exceed</i>
<i>obs</i>	Kollisionsvermeidung mit Hindernissen
<i>opt</i>	Optimal
<i>p</i>	Prädiktion
<i>P</i>	Population
<i>pol</i>	Schadstoff
<i>rec</i>	Rekombination
<i>t</i>	Zeit (Zeitlich)
<i>way</i>	Wegpunkt

Abkürzungen

<i>BF</i>	<i>Brute-Force</i> Optimierer
<i>CC&C</i>	<i>Command, Control and Communication (Link)</i>
<i>CPU</i>	<i>Central Processing Unit</i>
<i>DNMPC</i>	<i>Distributed Nonlinear MPC (Verteilte Nichtlineare MPC)</i>
<i>DRDC</i>	<i>Defence Research and Development Canada</i>
<i>EKF</i>	<i>Extended Kalman Filter</i>
<i>ES</i>	Evolutionsstrategie
<i>FMS</i>	<i>Flight Management System</i>
<i>GA</i>	Genetischer Algorithmus
<i>GNRON</i>	<i>Goals NonReachable with Obstacles Nearby</i>
<i>IFR</i>	<i>Instrument Flight Rules</i>
<i>GR</i>	Gradientenbasierender Optimierer
<i>LQR</i>	Linear Quadratischer Regler
<i>MILP</i>	<i>Mixed Integer Linear Programming</i>

MPC	<i>Model Predictive Control</i> (Modellprädiktive Regelung)
MPR	Modellprädiktive Regelung
NMPC	Nichtlineare MPC
NN	Neuronales Netz
OPV	<i>Optionally Piloted Vehicle</i>
PID	Proportional Integral Differenzial (-Regler)
ppm	parts per million (10^{-6} Anteile)
RHC	<i>Receding Horizon Control</i>
RPA	<i>Remotely Piloted Aircraft</i>
RPAS	<i>Remotely Piloted Aircraft System</i>
SNMPC	<i>Suboptimal Nonlinear Model Predictive Control</i>
UA	<i>Unmanned Aircraft</i>
UAS	<i>Unmanned Aerial System</i>
UAV	<i>Unmanned Aerial Vehicle</i>
VFR	<i>Visual Flight Rules</i>
WP	Wegpunkt

1 Einleitung

Ein unbemanntes Flugzeug bzw. Drohne wird als *Unmanned Aerial Vehicle* (UAV) oder *Unmanned Aircraft* (UA) bezeichnet. Das UAV wird zusammen mit Datenlink und Kontrollstation auch *Unmanned Aerial System* (UAS) genannt. Üblicherweise bezeichnet man nur Flugzeuge mit einem Mindestmaß an Automatisierung als UAVs. Sie werden für Aufgaben eingesetzt, die im Englischen als D^3 -Aufgaben bezeichnet werden:

- *Dull*-Aufgaben, die sehr einfach und eintönig sind, sowie einen Piloten nur ermüden würden
Beispiel: Atmosphärische Messungen, Langzeitobservierungen oder Überwachungen
- *Dirty*-Aufgaben, die für Personen sehr unangenehm sein können
Beispiel: Vermessung eines Erz- oder Kohlelagers
- *Dangerous*-Aufgaben, die ein hohes Risiko beinhalten
Beispiel: Zieldarstellungen oder Messungen von Radioaktivität oder Giften im Falle einer Katastrophe (Reaktorunfall in Fukushima)

UAVs variieren je nach Aufgabe und Anforderung in Größe, Fähigkeit und Form. Hierbei reicht die Spanne vom wenige Zentimeter messenden Helikopter (Abbildung 1.1) bis hin zum 40m Spannweite messenden Global Hawk (Abbildung 1.2).

Eine Einteilung von Luftfahrzeugen nach ihrem Grad der Autonomie (Fähigkeit Aufgaben oder Missionen selbständig durchzuführen) ist in Tabelle 1.1 dargestellt. Bemannte Luftfahrzeuge besitzen in der Regel keine oder nur sehr geringe Autonomie. Der verantwortliche Luftfahrzeugführer (Pilot) trifft in diesem Fall alle Entscheidungen. Er wird jedoch im Regelfall durch bordeigene Systeme wie dem Autopiloten, *Flight Management System* (FMS), *Flight Envelope Protection* und extern durch *Air Traffic Management* (Fluglotsen) unterstützt.

Bei *Optionally Piloted Vehicles* (OPV) handelt es sich um Luftfahrzeuge, bei denen sich der Systemmanager an Bord befindet. Dies ermöglicht jederzeit ein Eingreifen des Systemmanagers als Pilot. Neben dem Einsatz als Forschungsplattform wird angestrebt, OPVs zu nutzen, um die Anzahl der Piloten von üblicherweise zwei auf einen zu reduzieren (Einmann-Cockpit).

Remotely Piloted Aircraft Systems (RPAS) oder *Remotely Piloted Aircrafts* (RPA) werden durch einen verantwortlichen Luftfahrzeugführer (Pilot) am Boden kontrolliert. Dessen Aufgabe ist es, sowohl die Kommunikation mit dem Fluglotsen als auch das Bedienen des UAVs aus der Ferne zu gewährleisten. Ein elementarer Bestandteil von RPAS ist die *Command Control & Communication* (CC&C) Verbindung. Sie ermöglicht es, das UAV wie



Abbildung 1.1: Koaxial-Hubschrauber UAV (15cm Rotordurchmesser) [DNH07]



Abbildung 1.2: HALE-UAV Global Hawk [NASA]

ein bemanntes Flugzeug in den Luftraum zu integrieren. Dies sind üblicherweise kontrollierte Lufträume, in denen die Instrumentenflugregeln (IFR) gelten. Die Separation der Luftfahrzeuge ist in diesem Fall die Aufgabe des Fluglotsen. Der Luftfahrzeugführer am Boden agiert hier als Pilot und spricht die Bewegungen des UAVs mit dem Fluglosen ab. RPA werden primär für Aufgaben der Überwachung im militärischen und zivilen Bereich eingesetzt.

Autonom fliegende UAVs treffen selbständig Entscheidungen in dem durch den Systemmanager und den autonomen Fähigkeiten des UAVs vorgegebenen Rahmen. Der Systemmanager am Boden definiert das Ziel der Mission und überwacht, wenn möglich, deren Ausführung. Somit wird der Systemmanager von der unmittelbaren Kontrolle des UAVs entlastet und kann sich auf die Auswertung der gewonnenen Daten konzentrieren und gegebenenfalls das Missionsziel entsprechend anpassen. Gesetzliche Regelungen über die Verantwortlichkeit bei autonom fliegenden UAVs ohne Überwachung durch den Systemmanager existieren noch nicht.

Tabelle 1.1: Grade der Autonomie bei unterschiedlichen Arten von Luftfahrzeugen (nach [ICA11])

Grad der Autonomie	Kategorie	Beispiele
Hoch	Vollständig autonom fliegende UAVs → Systemmanager am Boden	Barracuda
Mittel	<i>Remotely Piloted Aircraft System</i> (RPAS) → Verantwortlicher Luftfahrzeugführer am Boden	Global Hawk
Gering	<i>Optionally Piloted Vehicle</i> (OPV) → Systemmanager im Cockpit	EC145 OPV
Sehr Gering	Bemannte Luftfahrzeuge → Verantwortlicher Luftfahrzeugführer im Cockpit	A320

Für Aufgaben, wie die Vermessung von Schadstoffwolken in einer hindernisreichen Umgebung, wie nach dem Reaktorunfall in Fukushima, sind mehrere UAVs nötig, wenn möglichst schnell ein Überblick über die Verteilung der radioaktiven Partikel erforderlich ist. Hierfür können gleichartige UAVs mit entsprechenden Sensoren verwendet werden. Sie müssen jedoch in der Lage sein, koordiniert und gemeinsam eine Aufgabe zu erfüllen. Dies erfordert zusätzliche Autonomie für die einzelnen UAVs, da der Systemmanager nicht wie bei einem RPA jedes einzelne UAV bedienen kann. Im Gegensatz zu einer Konstellation oder Formation (Tabelle 1.2) erfolgt die Regelung verteilt, wobei die Erfüllung eines gemeinsamen Missionsziels durch die Schwarmregelung erhalten bleibt. Ein Cluster, wie definiert in Tabelle 1.2, ist eine Erweiterung des Schwarms mit nicht gleichartigen Einheiten und Sensoren.

Die sich in der Entwicklung befindlichen UAVs unterscheiden sich von den bereits im Einsatz befindlichen UAVs durch ein höheren Grad an Automatisierung, Intelligenz und Fähigkeiten. Durch Fortschritte in der Mikroelektronik, Miniaturisierung und Kostenreduktion von UAVs ist die Implementierung von realen UAV-Schwärmen verglichen zu älteren Modellen deutlich praktikabler.

UAV-Schwärme sind noch nicht ausgereift, intelligent und flexibel genug für den realen Einsatz. Verschiedene Forschungsgruppen befassen sich mit der intelligenten Regelung

Tabelle 1.2: Klassifikation von kooperativen Systemen (nach [Sch13])

Begriff	Merkmale	Beispiele
Konstellation	Ähnliche Trajektorien ohne relative Regelung (Zentrale Steuerung/Regelung)	Anflugstaffelung
Formation	Relative Regelung der Position (<i>Leader/Follower</i>)	Luft-Luft Betankung
Schwarm	Gruppe von gleichen Einheiten Gemeinsames Missionsziel Individuelle Regelung	Roboterfußball
Cluster	Gruppe aus heterogenen Einheiten Gemeinsames Missionsziel Verteilte Regelung	Mobile, heterogene Sensornetzwerke

von Schwärmen. Ein Beispiel ist das *SMAVNET* Projekt [JPBG⁺12], dessen Fokus es ist, eine Kommunikationsinfrastruktur auf der Basis eines *WiFi*-Netzwerks nach einer Katastrophe zur Verfügung zu stellen. Ein weiteres Beispiel, mit einem ähnlichen Ziel, ist ein Projekt der *Johns Hopkins* Universität [BWSM06].

Bei der intelligenten Koordination und Regelung von UAVs, welche in einer komplexen Umgebung niedrig fliegen, besteht nach jetzigem Forschungsstand noch ein Bedarf an neuartigen, innovativen Lösungen [BK03]. Vor allem hinsichtlich der Regelung/Koordination von UAV-Schwärmen besteht ein Aufholbedarf in der Forschung. Im Folgenden soll diese Arbeit einen Beitrag liefern, um UAV-Schwärme in einer komplexen Umgebung autonom operieren zu lassen.

Im Gegensatz zu einem einzelnen großen UAV können viele kleine UAVs zur selben Zeit an unterschiedlichen Orten Sensorwerte erfassen. Für viele Anwendungen kann dies ein entscheidender Vorteil sein, wenn beispielsweise die Verteilung einer Größe gemessen werden soll, die Sensoren jedoch nur lokal Messwerte erfassen können. Existiert bei dieser Größe keine zeitliche Veränderung, so kann diese durchaus mit einem einzelnen UAV erfasst werden. Verändert sich allerdings innerhalb der dafür benötigten Zeit das zu messende Feld oder dauert die Messung mit einem einzelnen UAV zu lange, so ist der Einsatz von mehreren UAVs sinnvoll. Beispiele solcher Größen sind einfach zu messende Skalare, wie Lufttemperatur, Luftfeuchtigkeit, Radioaktivität oder dergleichen.

Weitere Beispiele für die Anwendung von UAV-Schwärmen sind:

- Einsatz von mehreren UAVs, um aus verschiedenen Blickwinkeln zur selben Zeit eine Aufnahme derselben Stelle zu machen.
- Dokumentation von Ereignissen aus mehreren Blickwinkeln zugleich. Dies ermöglicht eine 3D-Rekonstruktion (Fotogrammetrie).

-
- Einsatz bei Großereignissen, um einen Überblick über die Lage in einem bestimmten Bereich flexibel und in Echtzeit zu erhalten. Diese Anwendung ist besonders interessant für Behörden, Polizei, Feuerwehr oder Katastrophenschutz.
 - Kommerzieller Einsatz bei sportlichen Großereignissen, wie den Olympischen Spielen oder Weltmeisterschaften, z.B. bei Radrennen, Ereignisse also, bei denen es für den Zuschauer interessant ist, frei bewegliche Kameraperspektiven zu erhalten.
 - Für sämtliche mögliche Such- und Überwachungsaufgaben, bei denen in möglichst geringer Zeit eine große Fläche oder ein großes Volumen nach Personen oder Objekten abgesucht werden soll.
 - Messungen und Erforschung von physikalischen, chemischen oder biologischen Größen in der Atmosphäre und am Boden.

1.1 Regelung von Schwärmen

Die Missionskontrolle und Flugpfadplanung kann als Regelung betrachtet werden, da es ihre Aufgabe ist, die UAVs so zu regeln, dass der Sollwert (das Missionsziel) erreicht wird. Der UAV-Operator oder Systemmanager ist in diesen Fällen in dem Regelkreis eingebunden. Aufgrund der Automation ist hier keine kontinuierliche Korrektur notwendig. Der Systemmanager korrigiert, wann er es für nötig hält oder vom UAV dazu aufgefordert wird (*Non-Uniform Sampling*). Die Häufigkeit und Art dieser Korrekturen ist neben anderen Faktoren vor allem vom Grad der Automatisierung/Autonomie abhängig. Der Begriff Regelung wird hier bewusst so weit gefasst verwendet, da die in dieser Arbeit vorgestellte Methodik die Flugregelung, Flugpfadplanung und Missionskontrolle integriert und eine kontinuierliche Korrektur der Missionsparameter erfolgt.

Im Allgemeinen ist in einem Schwarm ein weitaus größerer Grad an Autonomie für jedes einzelne UAV erforderlich, als für ein einzelnes UAV. Voraussetzung hierfür ist, dass die Arbeitsbelastung die Belastbarkeit des Systemmanagers nicht übersteigt. Abgeleitet von der Arbeitsbelastung eines Fluglotsen [KSMR09] kann die Arbeitsbelastung des/der Systemmanager/s proportional zu der Anzahl der UAVs betrachtet werden. Folglich muss bei einem Schwarm von UAVs die Anzahl der Systemmanager oder der Grad der Autonomie erhöht werden. Wobei letzteres im Regelfall erwünscht ist, da der personelle Aufwand geringer ist.

Probleme, die bei einem einzelnen UAV vom Systemmanager bewältigt werden können, müssen bei einem Schwarm selbständig vom UAV gelöst werden. Zusätzlich muss eine Koordination der UAVs erfolgen, deren Aufwand abhängig von der Aufgabe und der Größe des Schwarms ist. Zudem stellt die Beschaffenheit des Luftraumes (Beschränkungen, Hindernisse, Komplexität der Mission) weitere Anforderungen an die Koordinierung der UAVs, die im Folgenden genauer diskutiert werden.

Die einzelnen Aufgaben einer Schwarmregelung, wie Kollisionsvermeidung und Erfüllung des Missionsziels, können Konflikte generieren. Diese entstehen durch teilweise widersprüchliche Ziele oder Randbedingungen. Ein Beispiel hierfür ist, wenn ein UAV zu einem Zielpunkt fliegen soll, der direkte Weg dorthin aber durch Hindernisse versperrt ist. Dies erzeugt einen Konflikt, zwischen der Aufgabe ein Ziel zu erreichen und der Kollisionsvermeidung. Die Regelung muss in der Lage sein, solche Konflikte robust und effizient zu lösen.

Weiter muss die Regelung in der Lage sein, Konflikte in der Zukunft zu erkennen und diese rechtzeitig zu vermeiden. Ein Beispiel einer solchen Situation ist ein enges, geschlossenes Tal, bei dem die Steigleistung des UAVs (Flächenflugzeug) nicht ausreicht, um eine Kollision zu verhindern (Sackgasse). Die Regelung muss, sofern dies bei den zur Verfügung stehenden Informationen möglich ist, das vorhersehen und verhindern.

1.2 Zielsetzung und Beitrag der Arbeit

Diese Arbeit wird zeigen, dass ein Schwarm intelligenter UAVs in der Lage ist, durch Verwendung ausschließlich abstrakter Zielvorgaben, seine Bewegungen sowohl global als auch lokal autonom zu koordinieren. Die hierzu entwickelte Regelung soll dem Systemmanager die Möglichkeit geben, das Ziel der Mission zu definieren ohne selbst den Weg zum Ziel beschreiben zu müssen. Im Weiteren soll ihm die Möglichkeit gegeben werden, Randbedingungen zu definieren, unter denen das Missionsziel erreicht werden soll. Der Systemmanager soll außerdem die Möglichkeit haben, die Ziele der Mission und die unterschiedlichen Randbedingungen zu priorisieren. Randbedingungen sind Einschränkungen unter denen die Erfüllung der Mission erfolgen soll. Sie sind im einfachsten Fall Bedingungen, die für einen Menschen selbstverständlich sind. Ein Beispiel hierfür ist die Einhaltung eines Mindestabstands zu anderen UAVs und Hindernissen. Weitere Randbedingungen sind das Einhalten einer Formation/Konstellation oder das Vermeiden solcher Konstellationen.

Widersprüche lösen

Widerspricht die Definition des Missionsziels in Teilen oder zu einem Zeitpunkt den Randbedingungen, so soll der Systemmanager nicht eingreifen müssen, sondern lediglich Prioritäten setzen. Diese Prioritäten sollten nach Möglichkeit nicht während eines Einsatzes geändert werden müssen.

Vorausschauendes Agieren

Situationen, die zwangsweise zu einem fatalen Ereignis, wie dem Zusammenstoßen mit einem Hindernis oder einem anderen Schwarmteilnehmer, führen, müssen vermieden werden. Um nicht in solche Situation zu geraten, sollten die UAVs vorausschauend agieren.

Zuverlässigkeit

Es muss sichergestellt sein, dass die UAVs des Schwarms die gestellte Aufgabe erfüllen. Die Regelung soll zuverlässig eine Kollision mit Hindernissen und anderen Luftfahrzeugen vermeiden. Die gestellte Aufgabe soll, ohne in einer Endlosschleife zu enden, erfüllt werden.

Robustheit

Von einem Schwarm wird erwartet, dass er robust ist bezüglich Störungen, Ausfall von Sensoren, Ausfall von einzelnen UAVs, oder bezüglich wiederholten Fliegens von Mustern ohne Zielerreichung.

Zusammengefasste Anforderungen für einen Schwarm

Anforderungen an die Regelung bezüglich der Bedienung:

- intuitive Definition des Missionsziels
- intuitive Definition der Randbedingungen, die eingehalten werden müssen
- intuitive Priorisierung der Ziele und Randbedingungen der Mission

Anforderungen an die Regelung bezüglich der Erfüllung der Mission:

- selbstständiges und sinnvolles Lösen von widersprüchlichen Vorgaben
- vorausschauendes Agieren
- zuverlässiges Erfüllen der gestellten Aufgaben
- robustes Verhalten bezüglich Änderungen in der Umwelt und in der Konfiguration des Schwarmes

Aus den hier definierten Anforderungen wird in Kapitel 3 eine Regelung erarbeitet. Eine Prädiktion basierend auf Modellen ermöglicht vorausschauendes Verhalten. Diese Prädiktion ist ein wesentlicher Bestandteil der modellprädiktiven Regelung. Die Prädiktion ermöglicht ein Optimieren der Stellgrößen. Bei der Verwendung von evolutionären Optimierungsalgorithmen können lokale Minima und die Nutzung von zuvor erfolgreichen Manövern durch die Vererbung von Informationen zur nächsten Generation genutzt werden. Hierdurch wird ein deutlicher Gewinn an Zuverlässigkeit bezüglich der Erfüllung einer Mission erreicht. Die Bewertung der Güte einer Prädiktion für die Optimierung erfolgt durch künstliche Potenzialfelder. Diese ermöglichen eine intuitive Definition von Zielen und Randbedingungen. Neu ist hierbei die Nutzung eines evolutionären Optimierungsalgorithmus als Teil der *Model Predictive Control* (MPC) zur Regelung von UAVs als Einzelnes und im Schwarm.

1.3 Struktur der Arbeit

Kapitel 2 beschreibt den Stand der aktuellen Forschung, wobei aufbauend auf den Anforderungen für die Regelung eines Einzelnen sowie eines Schwarms von UAVs geeignete Ansätze zur Diskussion stehen. Die Vor- und Nachteile dieser Ansätze werden hier erläutert. Im Weiteren werden Anwendungen von UAV-Schwärmen und deren spezifischen Regelungsansätze betrachtet.

Im folgenden Kapitel 3 wird aus der Zielsetzung aus Kapitel 1 eine Methode entwickelt, um diese Anforderungen zu erfüllen. Hierzu werden Schrittweise die Vor- und Nachteile der einzelnen Verfahren analysiert. Die Nachteile der gewählten Verfahren werden herausgearbeitet, mögliche Lösungen aufgezeigt und ausgewählt. Das Resultat dieser Analyse wird detailliert beschrieben und die Wahl von Parametern und deren Variationen begründet.

Die simulationstechnische Untersuchung der in Kapitel 3 entwickelten Methode erfolgt in mehreren Schritten. Zunächst werden elementare Funktionen der einzelnen UAVs, wie das Ausweichen von Hindernissen und anderen UAVs mittels einzelner ausgesuchter Szenarien untersucht. Die Plausibilität der simulationstechnischen Untersuchung wird mit einer analytischen Betrachtung eines Beispiels überprüft. Durch die Auswertung der Simulation werden Problemfälle, wie lokale Minima, bestimmt, detailliert betrachtet und diskutiert. Im Weiteren wird mittels unterschiedlicher Szenarien demonstriert, wie durch die Priorisierung der unterschiedlichen Ziele und Randbedingungen die Zielsetzung der jeweiligen Szenarien erfüllt werden. Um zu demonstrieren, dass es sich bei der hier entwickelten Methode nicht um ein speziell optimiertes Expertensystem handelt, wird die Sensitivität bezüglich Parametervariationen untersucht. Weiter werden Modellungenauigkeiten sowie der Einfluss unterschiedlicher Optimierungsverfahren untersucht und diskutiert.

Eine Bewertung und Diskussion der Regelung erfolgt in Kapitel 5.

Abschließend werden die Ergebnisse der Arbeit in Kapitel 6 zusammengefasst und ein Ausblick über mögliche Verbesserungen und Ergänzungen gegeben.

2 Stand der Forschung zur Schwarmregelung von UAVs

In diesem Kapitel wird ein Überblick über den Stand der Forschung zur allgemeinen Regelung von UAVs und im Speziellen zur Regelung bei einem Schwarm gegeben. Hierbei liegt der Fokus auf Flächenflugzeugen.

2.1 Schwarmregelung

Im Vergleich zur Regelung von einzelnen UAVs ist die Regelung eines UAVs im Schwarm komplexer, da eine Koordinierung erwünscht ist. Die Koordinierung eines solchen Schwarms ist üblicherweise Bestandteil der Missionsregelung oder einer überlager-ten Ebene. Speziell im Fall eines Schwarms ist ein hoher Grad an Autonomie notwendig. Ein Systemmanager kann aufgrund der Anzahl der Schwarmteilnehmer nur den Schwarm als solches bedienen. Das einzelne UAV muss hierbei weitgehend autonom agieren und sich dem Schwarm unterordnen. Die Regelung eines Schwarms muss durch eine abstrak- te Beschreibung der Aufgaben erfolgen.

Abstrakte Ziele können Formationen, Folgen von beweglichen Objekten, Exploration von Gebieten und andere Ziele sein. Im Folgenden werden mittels dieser drei Anwendungen Möglichkeiten zur Regelung eines Schwarmes vorgestellt. Diese Anwendungen werden gewählt, da sie in Zukunft die wahrscheinlichste Form des Gebrauchs von Schwärmen darstellen.

Meist besteht die Schwarmregelung aus einer kaskadierten Struktur, welche auf einer Ebene der Flugregelung aufbaut. In Abbildung 2.1 ist ein Beispiel solch einer kaskadieren- ten Struktur dargestellt. Diese Struktur besteht aus mehreren Regelkreisen. Der innerste Regelkreis ist die Flugregelung und besteht oftmals wiederum aus mehreren kaskadierten Reglern. Die Flugpfadplanung oder Flugpfadregelung generiert mittels Informationen von Sensoren und der Missionskontrolle Sollwerte für die Flugregelung.

Nachstehend werden die beiden Begrifflichkeiten Flugpfadplanung/-regelung und Missi- onskontrolle als Missionsregelung zusammengefasst, da die in dieser Arbeit entwickelte Regelung diese beiden Komponenten vereint.

Einen Überblick über den gesamten Bereich der UAV-Schwarmregelung ist in einem Dokument der Kanadischen Forschungsorganisation für Verteidigung (DRDC) enthalten

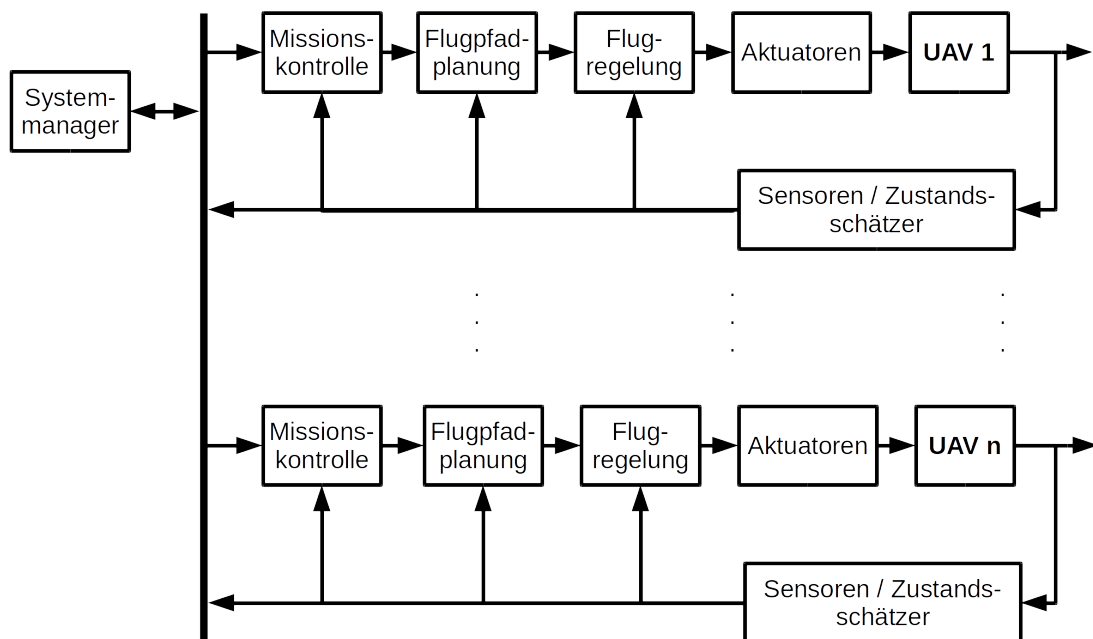


Abbildung 2.1: Kaskadierte Struktur eines Reglers für UAVs

[BK03]. Die in dieser Veröffentlichung betrachteten Methoden der Schwarmregelung werden im Teilkapitel 2.4 behandelt. Jedoch wird zunächst ein Überblick zur Schwarmregelung gegeben. Da die angewendeten Methoden meist abhängig vom Missionsziel sind, ist dieser Überblick nach Anwendungen gegliedert.

2.1.1 Formationsregelung im Schwarm

Eine der einfachsten und am häufigsten angewendeten Arten Schwärme zu organisieren, ist eine Formation. Viele Anwendungen erfordern, dass zwei oder mehrere UAVs relativ zueinander fliegen, um ihre Aufgabe zu erfüllen. Meist wird hierfür eine hierarchische Struktur verwendet. Ein Anführer (Leader) fliegt hierbei eine Trajektorie, die anderen UAVs (Follower) versuchen, ihre Position relativ zu diesem zu halten.

Ein klassisches Beispiel für eine Schwarmregelung ist das Verhalten eines Vogelschwarms. Bei diesem bildet sich aus einfachen Regeln eine für Vogelschwärme typische Formation. In ihr nutzt, mit Ausnahme des ersten Vogels, jeder Vogel den entstehenden Randwirbel seines Vorderfliegers, um Energie zu sparen. Eine weitere Anwendung von verhaltensbasierenden Regelungen (Kapitel 2.4.1) zur Regelung einer Formation im militärischen Bereich wird in [TB98] beschrieben. Hier werden einfache Regeln, wie „vermeide ein Zusammenstoßen mit Hindernissen“, „vermeide ein Zusammenstoßen mit anderen Robotern“, „bewege dich auf das Ziel zu“ und „halte Formation“ genutzt, um eine Gruppe von unbemannten Fahrzeugen zu regeln.

Beispiele für die Regelung eines Schwarms mithilfe eines konventionellen Reglers sind in [RWB06] und [IGP03] beschrieben. In diesem Fall wird ein Schwarm mithilfe eines Linear-Quadratischen-Reglers (LQR) geregelt. Dabei wird, aus einem zentral für das ganze System entworfenen Regler, für jedes einzelne UAV ein Regler generiert. Um eine Koordinierung des Schwarms zu erreichen, wird eine weitere Regelschleife hinzugefügt. Eine Sammlung von Forschungsergebnissen im Bereich der Kooperativen Regelung von UAVs wird von Ryan [AR04] beschrieben.

Eine sehr verbreitete Möglichkeit, eine Formation einfach zu erreichen, ist die Generierung von einzelnen Trajektorien, die bei der Planung so aufeinander abgestimmt werden, dass sich die gewünschte Formation ergibt. Meist werden einfache Folge-Regler verwendet, um eine feste Formation zu Regeln. Dabei hat jeder Roboter (Agent) eine feste Position innerhalb dieser Formation. Die gesamte Formation wiederum folgt einer festgelegten Trajektorie. Somit ist für den jeweiligen Agenten die einzelne Trajektorie fest vorgegeben. Randbedingungen wie Hindernisse und dergleichen können hierbei nicht oder nur durch eine übergeordnete Planung (Kapitel 2.4.3) berücksichtigt werden [WD08].

Einen etwas flexibleren Ansatz verfolgt Mathia [MLT07]. Hierbei werden in einer zentralen Regelung die Abstände der jeweiligen UAVs zueinander mithilfe einer Mehrgrößenregelung geregelt. Diese Lösung ist für eine einfache Formation geeignet, kann aber nicht auf komplexere Aufgaben und Umgebungen angewendet werden, da keine weiteren Randbedingungen, wie Hindernisse, direkt in die Regelung integriert werden können. Anstatt eines Mehrgrößenreglers verwendet Borrelli [BKB04] für jedes einzelne UAV einen MPC-basierten Regler (Kapitel 2.3.2). Jedoch werden hier Parameter für einen linearen Zustandsregler offline berechnet und in eine *Lookup*-Tabelle eingetragen.

Ein ähnliches Vorgehen für Bodenfahrzeuge (*Unicycles*) nutzt Fukushima [FKM05]. Im Unterschied zum vorherigen Vorgehen wird hierbei das Gütefunktional der MPC durch einen Term für die Vermeidung von Kollisionen zwischen den *Unicycles* erweitert und die Optimierung des Gütefunktionals erfolgt mit *Mixed Integer Linear Programming* (MILP). Die Formation besteht aus einem Leader, dem rechts und links zwei *Unicycles* (Follower) folgen. Da jedoch mit MILP in diesem Fall nicht gewährleistet ist, dass eine Lösung gefunden werden kann, wird in der Veröffentlichung durch Variation der Startpositionen untersucht, unter welchen Umständen eine Lösung möglich ist [YK04] [KRSH06].

Ein anderer Ansatz wird von Phan [PB08] beschrieben. Dort sind nicht nur Terme für Kollisionen mit anderen Agenten integriert, sondern zusätzlich solche für Kollisionsvermeidung, für Formationshaltung, für Regelaufwand und Terme zum Folgen einer Trajektorie. Zusätzlich wird zur Glättung der Flugbahn noch die Änderungen der Stellgrößen im Gütefunktional berücksichtigt. Primär befasst sich diese Veröffentlichung mit der Gestaltung jener Terme, die das Erreichen des gewünschten Verhaltens ermöglichen.

2.1.2 Verfolgen von beweglichen Objekten

Das Verfolgen von Zielen zu unterschiedlichsten Zwecken ist eine sehr verbreitete Anwendung von einzelnen UAVs als auch von kleinen Schwärmen [MNB03], [RS99], [SMT03]. In den meisten Fällen kreisen die einzelnen UAVs in einem definierten Abstand zur Beobachtung um die Ziele. Bei der Beobachtung von Konvois und einzelnen Fahrzeugen, zu deren Schutz oder Überwachung, ergeben sich durch die Bewegung des Ziels in diesen Szenarien spiralförmige Flugbahnen.

Eine weitere Lösung der Verfolgungsaufgabe wird von Wise [Wis06] beschrieben. Dort erfolgt die Regelung mittels eines Lyapunov-Vektorfelds (Kapitel 2.4.2). Dies ermöglicht dem UAV ein stabiles Verfolgen von Zielen, auch wenn sich diese bewegen. Zum Vergleich wird diesem Vorgehen ein modellprädiktives Verfahren mit einem evolutionären Optimierer für ein einzelnes UAV gegenübergestellt (Abbildung 2.2).

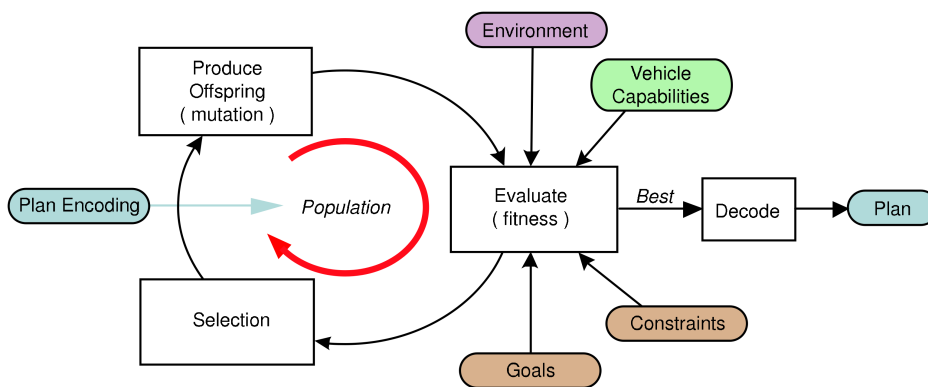


Abbildung 2.2: Schema der Pfadplanung von Wise [Wis06]

Im Unterschied zu einer modellprädiktiven Regelung wird hier eine Pfadplanung über einen kurzen Zeitraum durchgeführt. Die Güte einer Trajektorie wird mittels einer Fitnessfunktion bestimmt. Diese dient dem Optimierer zur Evaluation der Trajektorie. Sie berücksichtigt die Umgebung, die Flugmechanik, die Ziele und Beschränkungen. Anhand dieser Fitnessfunktion erfolgt die Selektion der Trajektorien. Ein Set von selektierten Trajektorien (Population) wird mittels Mutation (Abbildung 2.3) und Rekombination (Abbildung 2.4) modifiziert, sodass ein neues Set bestehend aus dem alten Set und dem Teil durch Rekombination und Modifikation neu generierten entsteht.

Diese Trajektorien werden erneut evaluiert und durch Selektion auf die ursprüngliche Größe der Population reduziert. Dieser Zyklus wird mehrfach durchlaufen, bis durch eine abschließende Evaluation die beste Trajektorie gefunden wurde. Diese wird hier in eine Sollwertvorgabe überführt und stellt die kurzzeitig geplante Trajektorie dar.




Abbildung 2.3: Mutation des Flugpfads
[Wis06]




Abbildung 2.4: Rekombination des Flugpfads
[Wis06]

Dieses Vorgehen ermöglicht es, lokale Minima zu vermeiden und generiert durch die integrierte Flugmechanik eine fliegbare Trajektorie. Jedoch handelt es sich in diesem Fall nicht um eine Regelung, sondern um eine Pfadplanung für einen kurzen Zeitraum.

Es können nicht nur einzelne Ziele zum Zwecke der Überwachung verfolgt werden, sondern mehrere. Ein Beispiel hierfür ist in der Veröffentlichung von Kaminer [IIK04] beschrieben. In diesem Fall handelt es sich um einen Schwarm von drei UAVs, die auf einem Schiff bei Wellengang landen sollen, wobei hier eine sogenannte Netzlandung durchgeführt wird. Dabei wird am Heck des Schiffes ein Netz vertikal aufgespannt. Wenn die UAVs dieses Netz treffen, bleiben sie darin hängen und können ohne Beschädigungen manuell geborgen werden. Um dieses Netz zu treffen, wird für jedes UAV koordiniert eine eigene Trajektorie generiert, sodass die UAVs nacheinander das Netz erreichen. Diese Trajektorien sind keine geographisch-fixen Trajektorien, sondern sie sind relativ zum Schiff bzw. zum Netz. Das eigentliche Abfliegen der Trajektorie erfolgt mithilfe eines einfachen PID-Reglers.

2.1.3 Exploration von Skalar- und Vektorfeldern

Zur Erschließung von neuen Erz- und seltene Erdvorkommen verwenden Geophysiker oft hochpräzise Magnetfeldkarten (Abbildung 2.5). Um diese zu erstellen, fliegt üblicherweise ein Flugzeug mit mehreren Magnetometern ausgerüstet in sehr niedriger Höhe (10–80m) über das zu kartografierende Gebiet. Dieses Gebiet wird in sehr dichten Suchmustern überflogen. Da sich in den relevanten Größenordnungen das Magnetfeld selbst während eines kurzen Fluges ändern kann, wird das Gebiet mehrmals in verschiedenen Richtungen überflogen. Auf der Sonne abgewandten Seite der Erde sind die Störungen des Magnetfeldes durch den Sonnenwind am geringsten. Deshalb werden solche Flüge von UAVs bei Nacht durchgeführt. Bemannte Flüge dieser Art sind aufgrund der geringen Höhe zu riskant. Inzwischen gibt es kommerzielle Anbieter, die solche Explorationen mithilfe von einem UAV oder mehreren UAVs anbieten. Diese fliegen in einem kurzen Abstand ein zuvor festgelegtes Muster ab.




Abbildung 2.5: Eine mithilfe eines UAVs erstellte Magnetfeldkarte (Magnitude) [Aer12]

Ein übliches Vorgehen bei der Exploration mit UAVs (sofern es nicht notwendig ist, mehrmals dasselbe Gebiet zu explorieren) ist es, das Gebiet in einzelne Bereiche aufzuteilen. So können die UAVs in möglichst kurzer Zeit das gesamte Gebiet erkunden. Diese untersuchen wiederum unabhängig von den anderen ihren eigenen Bereich. Abhängig von der Gestalt des Gebietes, den Fähigkeiten und der Verteilung der einzelnen UAVs können unterschiedlichste Aufteilungen oder Partitionierungen sinnvoll sein. Ein Beispiel für die Aufteilung eines Gebietes ist die Voronoi-Partitionierung [ML05]. Sie halbiert jeweils die Abstände zu den Nachbarn und definiert damit den zu erkundenden Bereich für den jeweiligen Agenten. Die Agenten (UAVs) müssen zunächst über das Gebiet verteilt werden; danach kann das aufgeteilte Gebiet erkundet werden. Die Koordinierung des Schwarms erfolgt hierbei nur am Anfang durch die Aufteilung des Gebietes. Diese Koordinierung des Schwarmes kann nur dann als Regelung aufgefasst werden, wenn aufgrund neuer Gegebenheiten eine kontinuierliche Neuanpassung der Aufteilung des Gebietes erfolgt.

Wahrscheinlichkeitsbasierende Ansätze, wie der von Tisdale [TRK⁺08] beschriebene Algorithmus, lösen das Problem der Koordinierung nicht. Sie ermöglichen jedoch eine

einfache und logische Darstellung der Wahrscheinlichkeitsverteilung des zu suchenden Objekts. Tisdale [TRK⁺08] vergleicht zwei Arten von wahrscheinlichkeitsbasierenden Ansätzen der Exploration: beim Partikelfilter werden einzelne Partikel zufällig über das Gebiet verteilt. Die Dichte der Partikel symbolisiert dabei die Wahrscheinlichkeit, dass sich das gesuchte Objekt dort befindet. Eine andere Möglichkeit der Darstellung ist die Aufteilung des Gebietes in gleich große Zellen. Jeder dieser Zellen wird ein Wahrscheinlichkeitswert zugewiesen. Ausschließlich die Werte in den Zellen und nicht die Größe der Zellen ändern sich bei einem Update. Diese Art der Exploration wird im Englischen auch als *Occupancy Grid Map* bezeichnet. Diese Wahrscheinlichkeitsverteilung dient der Regelung als Vorgabe, um beispielsweise in Richtung der Position des größten Wahrscheinlichkeitswerts zu steuern. Die Wahrscheinlichkeitsverteilung wiederum wird fortlaufend durch Messungen oder Schätzungen angepasst.

Ein weiterer Anwendungsbereich ist die Exploration von Skalarfeldern mithilfe eines Modells. So kann man zum Beispiel die Ausbreitung einer Schadstoffwolke explorieren. In diesem Fall werden die Messwerte genutzt, um die Parameter des Modells zu bestimmen. Dies kann online mithilfe eines Schätzers wie dem *Extended-Kalman-Filter* (EKF) (Kapitel A) oder offline mit einem *Least-Square* Verfahren erfolgen [OS07] [OSM02]. Die Regelung hat hierbei sicherzustellen, dass ausreichend Informationen zur Schätzung der Parameter des Modells zur Verfügung stehen. Wird die Schätzung der Parameter online durchgeführt, so kann diese Einfluss auf die Regelung nehmen, um beispielsweise den Informationsgehalt der Messungen zu maximieren.

Beispiele für Skalarfelder, bei denen Modelle angewendet werden, sind Aufgaben, wie die Bestimmung einer Schadstoffwolke oder das Zentrieren eines thermischen Aufwindes [AN08]. Für das Auffinden und Anzeigen von Schadstoffwolken wird in der Literatur bevorzugt die Nutzung von Schwärmen von UAVs beschrieben [AHP⁺07], [SS06]. Allred [AHP⁺07] verwendet einen Schwarm, der mit Sensoren ausgestattet ist, um giftige Schadstoffwolken einzugrenzen und deren Quelle zu lokalisieren. Die Regelung solcher Schwärme lässt sich in verhaltensbasierende Regelungen [TZW07] [RBTH02] und in klassische Methoden der Regelungstechnik einteilen.

2.2 Vor- und Nachteile von zentralen und dezentralen Ansätzen

Zuverlässigkeit wird im Bereich von UAVs immer wichtiger. Durch die geplante Nutzung in zivilen Bereichen und damit außerhalb von speziellen Sperrgebieten ist eine Betrachtung der Risiken notwendig. Ein Aspekt dieser Risikobetrachtung ist die Zuverlässigkeit bzw. die Robustheit bezüglich Ausfällen. Robustheit bedeutet nicht nur, dass das einzelne UAV robust gegenüber Fehlern oder Ausfällen sein muss, sondern auch, dass der Schwarm beim Ausfall eines oder mehrere UAVs, dennoch seine Aufgabe erfüllen kann.

Ein Ausfall des gesamten Schwarms kann nur erfolgen, wenn ein *Single Point of Failure* eintritt. Im Fall eines Schwarms wäre das zentrale Element die Einheit, die die Koordinierung der UAVs übernimmt. Zentrale Strukturen sind per Definition zumindest in ihrem zentralen Element ein möglicher *Single Point of Failure*. Ein kompletter Ausfall des Systems durch einen Ausfall des zentralen Elements wird häufig durch Redundanzen abgefangen. Diese müssen zusammen mit der Kommunikationsinfrastruktur redundant vorhanden sein, um bei einem Ausfall nicht zu einem Ausfall des Systems zu führen.

Wird eine dezentrale Struktur verwendet, ist diese zentrale Einheit nicht notwendig. Durch den Wegfall einer zentralen Einheit kann zudem der Rechenaufwand für die Regelung auf mehrere kleinere Einheiten verteilt werden. Allerdings kann eine verteilte Regelung nie zu einem besseren Ergebnis führen, als ein zentral geregelter Schwarm [Par09]. Jedoch lässt sich eine zentrale Struktur meist in der Realität aufgrund der beschränkten Kommunikationsbandbreite, Rechenleistung und Sensoren nicht umsetzen. Ab einer bestimmten Größe des Schwarms existiert keine Alternative zur dezentralen Struktur, da der Aufwand zur Koordinierung exponentiell mit der Größe des Schwarms steigt [Par09].

Ein Beispiel für eine dezentrale Struktur zur effektiven Regelung von UAV-Schwärmen ist die von Dunbar [Dun04] und Fukushima [FKM05] beschriebene Dezentrale Nichtlineare Modellprädiktive Regelung (DNMPC). Bisher kann die Forschung für das beschriebene Problem keine adäquate Lösung aufzeigen, denn durch die große Anzahl von Freiheitsgraden ist die zentrale Lösung der Optimierungsaufgabe nicht oder nur extrem begrenzt möglich. Nachteilig in diesem Fall ist, dass nur konkrete Trajektorien vorgegeben werden können.

2.3 Flugregelung

Die Aufgabe der Flugregelung ist es, ein stabiles System zu erzeugen, welches den Sollwerten der höheren Ebene folgt. Ein Beispiel einer Ebene als Teil der Flugregelung bei einem Flächenflugzeug ist die Regelung der Rollrate, eine Ebene höher die Regelung des Rollwinkels. Die darauf folgende Regelung könnte der Azimut Winkel oder dessen zeitliche Ableitung sein. Die Regelung auf eine Sollstandlinie oder einen Wegpunkt ist ein elementarer Bestandteil der Flugregelung.

Viele Regelungen auf Basis von Wegpunktnavigation oder Sollstandlinien/Kurven existieren, in Simulation wie auch in real existierenden Systemen [RST05] [MWO05]. In diesen Systemen werden Wegpunkte oder Trajektorien von einer übergeordneten Steuerung oder Regelung definiert. Bei vielen im Einsatz befindlichen Systemen gibt der Operator oder Systemmanager die Wegpunkte mit Attributen oder ganzen Trajektorien vor.

Oft sind beim Überfliegen eines geplanten Wegpunktes Randbedingungen notwendig, die Einfluss auf die Art des Überfluges haben [Abbildung 2.6]. Übliche Nebenbedingungen bei der Wegpunktregelung sind:

- *Fly-Over* (Überfliegen des Wegpunktes und anschließendes Schwenken auf den nächsten Wegpunkt) [Ser]
- *Fly-By* (Schwenkt kurz vor dem Wegpunkt auf den nächsten Wegpunkt) [Ser]




Abbildung 2.6: Links: *Fly-Over*; Rechts: *Fly-By*

Im Gegensatz zum *Fly-Over* ist beim *Fly-By* eine vorausschauende Regelung notwendig. Dieses Vorausschauen oder Prädizieren kann in diesem Fall geometrisch erfolgen. Bei einem *Fly-Over* wird im Regelfall nach dem Überfliegen des Wegpunkts auf die nächste Sollstandlinie oder den nächsten Wegpunkt umgeschaltet. Hierbei ist die Trajektorie, auf der das Luftfahrzeug die neue Sollstandlinie erreicht (Übergangstrajektorie), nicht direkt vorgegeben. Sie ist vielmehr ein Resultat der Wendigkeit des Luftfahrzeugs, des Windes und der Parametrierung des Sollstandlinienreglers. In einer Umgebung mit Hindernissen kann diese Unschärfe der Übergangstrajektorie zwischen den beiden Sollstandlinien problematisch sein. Beim *Fly-By* ist die Trajektorie in Form eines Bogens vorgegeben und kann gegebenenfalls direkt als Sollwert dem Regler übergeben werden.

Bei der Flugregelung werden meist kaskadierte Eingrößenregler verwendet [BAL11]. Für die Flugregelung existieren ausreichend Lösungen. In seltenen Fällen werden Mehrgrößenregler verwendet. Neuartige Konzepte wie Neuronale Regler [DJ10][NI03],

Fuzzy-Regler, inverse modellbasierende Regelungsverfahren und weitere werden bis auf wenige Ausnahmen nur experimentell eingesetzt.

Im Folgenden wird auf Neuronale Netze und modellprädiktive Regelung eingegangen. Sie sind zwei Beispiele, die zur Flugregelung genutzt werden können und im weiteren Verlauf der Arbeit zur Konzeption der dezentralen Regelung von Schwärmen diskutiert werden.

2.3.1 Regelung mit Neuronalen Netzen

Neuronale Netze [Yeg09] können sehr gut in Grenzen nichtlineare Funktionen abbilden. Zur Regelung sind sie aufgrund des hohen Trainingsaufwands und des fehlenden Extrapolationsvermögens nur bedingt geeignet. Wenn sie dennoch eingesetzt werden, dann meist zur Regelung von nichtlinearen Systemen [SP96].

Bei der Regelung von künstlichen Schwärmen werden gerne Analogien zu Regelungen von realen Schwärmen aus der Biologie verwendet [Rey87]. Eine dieser Analogien ist die Verwendung eines einfachen Neuronalen Netzes, einer einfachen Sensorik und Aktuatorik. Ein Beispiel hierfür beschreibt Kriesel [KCSL08]. Hierbei sollen kleine Roboter möglichst viel Licht sammeln.

Mithilfe eines Lichtsensors regelt das Neuronale Netze die Bewegungsrichtung des Roboters. Die von Kriesel verwendete Struktur des Neuronalen Netzes kommt häufig zur Anwendung: eine Eingangsschicht, eine Ausgangsschicht und eine mittlere Schicht aus Neuronen. Die Eingangsschicht i_n und die Ausgangsschicht Ω_n bestehen aus jeweils zwei Neuronen. In der Mittleren-Schicht h_n werden drei Neuronen verwendet (Abbildung 2.7). Trainiert wird das Neuronale Netz mithilfe eines evolutionären Algorithmus. Für die Evaluation des Trainings wird das gesammelte Licht des Schwarms verwendet.




Abbildung 2.7: Typischer Aufbau eines Neuronalen Netzes [Kri09]

In diesem Fall handelt es sich um ein sehr einfaches Neuronales Netz. In Einzelfällen kann dies eine sehr effektive Regelung sein. Jedoch wird hier weder der Abstand

der einzelnen Roboter zueinander noch der Abstand zu Hindernissen berücksichtigt. Zudem ist keine vorausschauende Komponente vorhanden. Bei kleinen am Boden agierenden Robotern ist diese Art der Regelung durchaus ausreichend. Für die Anwendung bei UAVs ist diese jedoch nicht geeignet, da eine Kollision mit einem Hindernis fatal wäre.

Bei Neuronalen Netzen lassen sich die Verläufe der inneren Zustände im Allgemeinen nur schwer einem Eingangsverhalten zuordnen. Eine analytische Berechnung der Wahrscheinlichkeit eines Versagens der Regelung mit Neuronalen Netzen ist somit nur schwer möglich. Das Versagen einer Regelung, die auf Neuronalen Netzen beruht, kann nur verhindert werden, wenn alle möglichen Zustände und Eingänge beim Training ausreichend berücksichtigt werden. Eine Extrapolation durch Neuronale Netze ist nur bedingt möglich. Mit zunehmender Anzahl von Zuständen und Eingängen wird das Trainieren des Neuronalen Netzes zunehmend schwieriger.

Neuronale Netze sind deshalb nur sehr bedingt für die Regelung von UAVs oder Schwärmen von UAVs geeignet. Eine Zusammenfassung der Anwendungen von Neuronalen Netzen zur Schwarmregelung ist bei Kriesel [Kri09] zu finden. Im Regelfall wird bei den insektenähnlichen Regelungen davon ausgegangen, dass die Agenten (Insekten) unempfindlich gegenüber Zusammenstößen sind und der Verlust eines Agenten weitgehend unerheblich ist. Für eine Regelung eines UAV-Schwarms ist dies üblicherweise nicht erwünscht.

2.3.2 Modellprädiktive Regelung

Die modellprädiktive Regelung (MPR oder englisch MPC für *Model Predictive Control*) [GP11] [AZ00] basiert, wie ihr Name schon andeutet, auf einer Prädiktion mithilfe eines Modells der Strecke. Diese Prädiktion ermöglicht die Optimierung der Steuergrößen über den Prädiktionshorizont. Gelegentlich wird die MPC als *Receding Horizon Control* (RHC) bezeichnet.

Bei der MPC wird mittels eines Modells eine Steuerfolge

$$U = [\vec{u}(k) \quad \vec{u}(k+1) \quad \cdots \quad \vec{u}(k+K_H)] \quad (2.1)$$

generiert, die den Fehler

$$E = [\vec{e}(k) \quad \vec{e}(k+1) \quad \cdots \quad \vec{e}(k+K_H)] \quad (2.2)$$

des Ausgangs

$$Y = [\vec{y}(k) \quad \vec{y}(k+1) \quad \cdots \quad \vec{y}(k+K_H)] \quad (2.3)$$

zu einer Referenztrajektorie

$$W = [\vec{w}(k) \quad \vec{w}(k+1) \quad \dots \quad \vec{w}(k+K_H)] \quad (2.4)$$

innerhalb des zeitlichen Horizonts T_H (diskret: K_H) minimiert (Abbildung 2.8). Wobei der zeitliche Horizont vorausseilt, sodass dieser von t (diskret: k) bis $t + T_H$ (diskret: $k + K_H$) eingegrenzt wird.

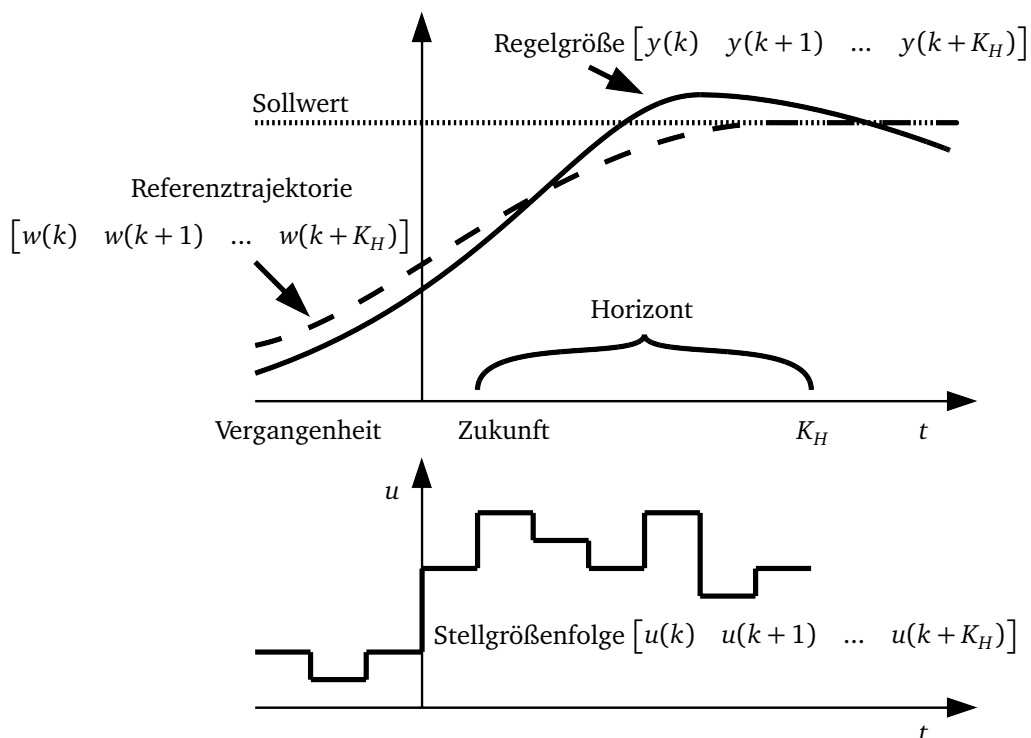


Abbildung 2.8: Visualisierung der Prädiktion einer MPC/RHC (nach [Pan06])

Für ein lineares, diskretes System (Gleichung (2.5), (2.6)) kann der Ausgangsvektor \vec{y} für einen Eingangsvektor \vec{u} mit Gleichung 2.7 - 2.9 beschrieben werden [GP11]. Wobei wie üblich A die Systemmatrix, B die Eingangsmatrix, C die Messmatrix und D die Matrix für ein sprungfähiges System ist.

$$\vec{x}(k+1) = A\vec{x}(k) + B\vec{u}(k) \quad (2.5)$$

$$\vec{y}(k) = C\vec{x}(k) + D\vec{u}(k) \quad (2.6)$$

Im Fall eines linearen Systems kann mithilfe der beiden Matrizen P und H der zukünftige Verlauf der Ausgänge Y bestimmt werden.

$$Y = P\vec{x}(k) + HU \quad (2.7)$$

$$P = \begin{bmatrix} C \\ CA \\ \vdots \\ CA^{N-1} \end{bmatrix} \quad (2.8)$$

$$H = \begin{bmatrix} D & & & & \\ CB & D & & & \\ \vdots & & \ddots & & \\ CA^{N-2}B & \dots & CB & D & \end{bmatrix} \quad (2.9)$$

Meist wird bei der modellprädiktiven Regelung ein quadratisches Gütefunktional der Form 2.10 verwendet. Das Gütefunktional $\bar{J}(U|\vec{x}_0)$ ist abhängig vom Verlauf des Eingangsvektors (Eingangsvektorfolge) U und dem Zustand \vec{x}_0 zum Zeitpunkt t_0 (2.10).

$$\bar{J}(U|\vec{x}_0) = \sum_{i=0}^N \|Q_p \vec{e}(i)\|^2 + \sum_{j=0}^{N_u-1} \|R_p \vec{u}(j)\|^2 \quad (2.10)$$

Wobei der Fehler $\vec{e} = \vec{y}_c - \vec{y}$ definiert ist, als die Differenz zwischen dem erwünschten Verlauf des Ausgangs \vec{y}_c und dem prädizierten Ausgang \vec{y} . Q_p gewichtet die Abweichungen von den Sollwerten \vec{e} . R_p gewichtet die Bestrafung des Regelaufwands.

Ziel der MPC ist es, den optimalen Verlauf des Eingangsvektor U_{opt} zu finden, sodass das Gütefunktional $\bar{J}(\vec{x}_0, U)$ minimal wird (2.11).

$$\bar{J}(U_{opt}|\vec{x}_0) = \min(\bar{J}(U|\vec{x}_0)) \quad (2.11)$$

Die Optimierung wird in jedem Regelzyklus erneut durchgeführt. Deshalb wird von der Steuerfolge U nur jeweils die Stellgröße \vec{u}_0 bis zu einem erneuten Regelzyklus an das System weitergegeben. Die Frequenz des Regelzyklus muss nicht zwingend der zeitlichen Diskretisierung der Stellgröße entsprechen. Häufig ist dies aber der Fall, da sich bei linearen Systemen kein Vorteil gegenüber unterschiedlichen Frequenzen ergeben würde [Pan06].

Bei der MPC erfolgt die Optimierung für einen beschränkten Horizont. Im Gegensatz dazu erfolgt bei der LQ-Regelung (LQR) eine Optimierung für einen unendlichen Horizont. Ähnlich wie die Ricatti-Gleichung beim LQR hat auch die MPC ein Gütefunktional. Unter definierten Bedingungen lässt sich die MPC, wie die LQR, analytisch lösen. Dies ist jedoch für die praxisrelevanten Anwendungen selten der Fall.

Durch die MPC lässt sich ein regelungstechnisches Problem in ein Optimierungsproblem transformieren. Alle aus der Optimierung bekannten Vorgehensweisen lassen sich deshalb auf die MPC anwenden. Für unbeschränkte lineare Systeme ist eine analytische

Lösung möglich. Für nichtlineare Systeme besteht die Möglichkeit einer Aufteilung des Optimierungsraums (Zustandsraums) in einzelne, beschränkte, lineare Systeme, die als solche behandelt werden können [GP11]. Die Übergänge der einzelnen, linearen Systeme müssen gesondert betrachtet werden. Dies kann bei stark nichtlinearem Verhalten sehr aufwendig sein. In solch einem Fall ist es sinnvoll, numerische Verfahren zur Lösung von nichtlinearen Problemen anzuwenden [Wei09].

Zum Folgen einer Trajektorie von unbemannten Fahrzeugen werden unterschiedliche Optimierer in der nichtlinearen MPC (NMPC) verwendet. Sehr weit verbreitet sind Optimierer, die auf einem Gradientenabstieg basieren. Die einfachste Version eines Gradientenabstiegs besitzt eine feste Schrittweite. Varianten, die eine flexible Schrittweite nutzen, erreichen in weniger Schritten die selben Ergebnisse [CMC08]. Auch evolutionäre Algorithmen finden bei der NMPC Anwendung [HCDP07] [Yan09]. Eine Variante der evolutionären Algorithmen ist ein genetischer Algorithmus. Dieser wird zur Regelung von autonomen Unterwasser Fahrzeugen eingesetzt [Nae04]. Auch *Support Vector Machines* (SVM) werden zur Optimierung bei der MPC für Tracking-Anwendungen eingesetzt [DZ08]. Evolutionäre oder Hybride-Optimierer ermöglichen die Anwendung von MPC auf *Black-Box* Systeme. Hierbei ist auch die Anwendung von lernfähigen Modellen möglich [Rau03].

Die MPC wird fast ausschließlich als Folgeregelung verwendet. Aufgabe der MPC ist es, das UAV möglichst exakt der zuvor definierten Trajektorie folgen zu lassen [Fre05]. Im Gegensatz zu einem PID-Regler optimiert die MPC das Umschalten von Wegpunkt oder Sollstandlinien. So entsteht je nach Definition des Gütefunktional eine Kombination aus minimalem Überschwingen und einem *Fly-By*. Ein Beispiel für eine Vorgabe der Wegpunkte ist bei Keviczky [KB06] beschrieben. Hier wird ein linearisiertes Modell mit Beschränkungen und eine linearquadratische Optimierung verwendet. Ein Vergleich zwischen einer PID-Regelung und einer MPC wird von Castillo in [CMV07] beschrieben. Ein Hubschrauber soll in diesem Fall, wie in Abbildung 2.9 gezeigt, einer spiralförmigen Trajektorie folgen. Diese werden gewählt, um alle Stellgrößen zu nutzen und den Schwierigkeitsgrad zu erhöhen.

Durch eine Transformation am Eingang und Ausgang der Regelung kann ein lineares Modell für die MPC angewendet werden. Die MPC folgt deutlich präziser der spiralförmigen Trajektorie. Dies ist auch der Fall bei Abweichungen zwischen Modell und realem Hubschrauber. Hierbei handelt es sich um ein anschauliches Beispiel der Vorteile der MPC und dessen vorausschauenden Verhaltens mithilfe des Modellwissens. Eine PID-Implementierung ist im Gegensatz zur MPC wesentlich weniger aufwendig und rechenintensiv. Jedoch wird dieser Nachteil der MPC mit steigender Rechenleistung immer weniger bedeutsam.

Üblicherweise werden schon bei der Vorgabe der Trajektorie Hindernisse berücksichtigt. Dies kann im einfachsten Fall durch den Bediener (Systemmanager) geschehen oder

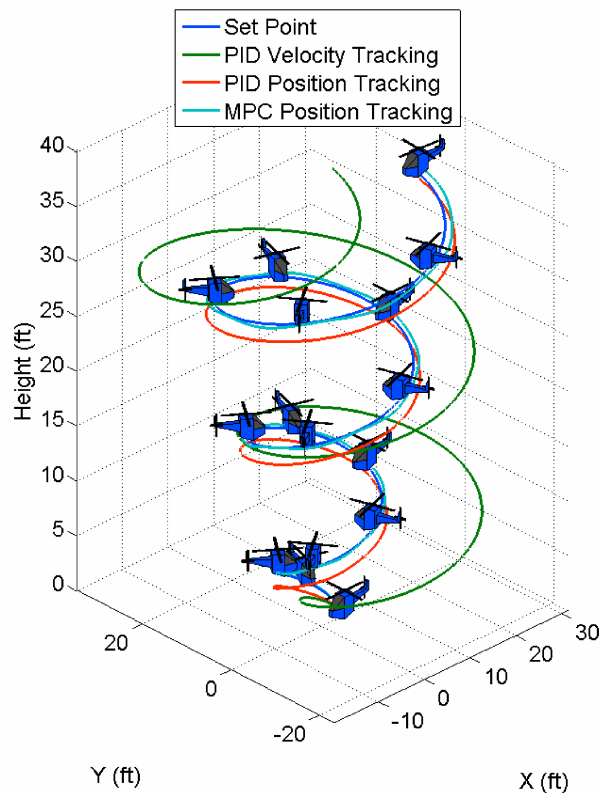


Abbildung 2.9: Resultierende Trajektorien eines Vergleichs von MPC und PID-Regelung [CMV07]

durch einen übergeordneten Algorithmus. Eine weitere Möglichkeit ist es, bei der Wahl der Trajektorie Hindernisse nicht zu berücksichtigen. Das Ausweichen vor Hindernissen erfolgt in diesem Fall durch die MPC [KSS03]. Das Gütefunktional wird um einen Term erweitert, der eine Kollision mit einem Hindernis vermeiden soll. So wird erreicht, dass das UAV möglichst exakt der Trajektorie folgt, solange es sich keinen Hindernissen nähert. Kommt es Hindernissen zu nahe, ist eine Abweichung von der Trajektorie zulässig. Diese Erweiterung wird auch bei der Potenzialfeldmethode häufig angewendet.

Der Kern der Regelung der UAVs besteht aus einer modifizierten modellprädiktiven Regelung. Für den Fall, dass das Modell der UAVs ein lineares System wäre oder linearisiert werden könnte, kann die lineare MPC angewendet werden. Jedoch sind die Modelle in Realität wie auch hier meist nichtlinear, deshalb wird hier nochmal besonders auf nichtlineare MPC eingegangen.

Nichtlineare modellprädiktive Regelung (NMPC)

Bei der NMPC werden Optimierungsalgorithmen verwendet, die nichtlineare Probleme lösen können. Da diese nichtlinearen Optimierungsverfahren meist deutlich komplexer und rechenintensiver sind, ist auch eine NMPC Regelung gemeinhin deutlich rechenin-

tensiver als eine lineare modellprädiktive Regelung. Mit einer geschickten Linearisierung kann dies jedoch umgangen werden. In der Arbeit von Meinert [Mei11] wird ein solches Verfahren beschrieben. Allerdings ist die Linearisierung nicht in allen Fällen möglich.

Suboptimale nichtlineare modellprädiktive Regelung (SNMPC)

Die suboptimale nichtlineare modellprädiktive Regelung (SNMPC) [WC09] basiert auf der Annahme, dass bei einem evolutionären Optimierungsalgorithmus (siehe im folgenden Teilkapitel), wenn die optimale Stellgrößenfolge gefunden wurde, im nächsten Regelzyklus die Stellgrößenfolge um einen Wert verschoben werden kann. In diesem Fall muss nur der fehlende Wert am Ende des Horizonts optimiert werden, um eine optimale Stellgrößenfolge zu erreichen.

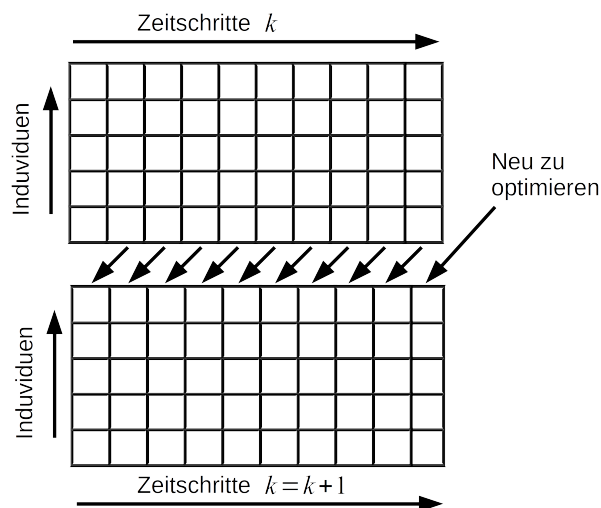


Abbildung 2.10: Darstellung der Vererbung (nach [WC09])

Diese Annahme besteht nur unter der Voraussetzung, dass der vererbte Teil der vorherigen Trajektorie oder einer anderen Trajektorie in der Population Teil der optimalen Trajektorie im folgenden Zeitschritt ist. Eine weitere Voraussetzung ist, dass die initiale Stellgrößenfolge ein Optimum darstellt oder zu einem vorherigen Zeitpunkt das Optimum erreicht wurde. Da unter diesen Bedingungen in jedem Regelzyklus nur ein Wert optimiert werden muss, kann die Optimierung in sehr wenigen Optimierungsschritten (Generationen) erfolgen. Der daraus resultierende, relativ geringe Rechenaufwand stellt einen erheblichen Vorteil dar.

Allerdings existiert in der Realität keine Garantie, dass der vererbte Teil der vorherigen Trajektorie auch Teil der optimalen Trajektorie im folgenden Zeitschritt ist. Üblicherweise ist die optimale initiale Stellgrößenfolge unbekannt. In diesem Fall wird eine suboptimale Lösung erreicht. Diese kann aber durch entsprechende Parametrierung (Steigerung des Rechenaufwands) beliebig nahe an die optimale Lösung gebracht werden.

Optimierungsverfahren

Ein entscheidender Baustein der MPC neben dem Modell für die Prädiktion ist die Optimierung. Aus diesem Grund werden im Folgenden einige ausgewählte Beispiele von globalen und lokalen Optimierungsverfahren, wie sie bei der MPC eingesetzt werden, beschrieben.

Hier werden evolutionäre Optimierungsalgorithmen betrachtet, da sie im Weiteren aufgrund ihrer hier diskutierten Vorteile eingesetzt werden. Die *Brute-Force*-Methode und das gradientenbasierte Optimierungsverfahren werden als Referenz zu diesen genutzt.

Alle lokalen Optimierungsverfahren versuchen, ausgehend von einem Startpunkt im Optimierungsraum, ein Optimum zu finden. Da sie nur ein Optimum suchen, ist nicht gewährleistet, dass das gefundene lokale Optimum auch ein globales Optimum ist. Ein sehr oft verwendeter Vertreter dieser Klasse von Optimierungsverfahren sind die gradientenbasierten Verfahren. Sie korrigieren den Lösungsvektor in Richtung des negativen Gradienten (2.12), (2.13) [Jän01]. In einigen Fällen wird in Richtung des positiven Gradienten optimiert. Die Iterationsgleichung des Gradientenverfahrens lautet:

$$\vec{x}(j+1) = \vec{x}(j) - \alpha(j)\nabla f(\vec{x}(j)) \quad (2.12)$$

$$\nabla f(\vec{x}_{(1,\dots,n)}) = \left[\frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right]^\top \quad (2.13)$$

Die Optimierer der Gruppe gradientenbasierter Verfahren unterscheiden sich im Wesentlichen durch die Berechnung und Wahl der Schrittweite α . Vorteil dieser Verfahren ist, dass sie sehr effektiv das nächste Minimum finden. Allerdings kann es sich bei dem gefundenen Minimum um ein lokales handeln, da es sich um ein lokales Optimierungsverfahren handelt.

Das Bestimmen eines lokalen Minimums ist vergleichsweise einfach zu dem Bestimmen eines globalen Minimums. Das Finden eines globalen Minimums in endlicher Zeit ist selbst mit globalen Verfahren nicht garantiert. Globale Verfahren ermöglichen es jedoch, mehrere Minima zu finden. Im Gegensatz zu lokalen Verfahren sind globale Verfahren zur Lösung von globalen Optimierungsproblemen geeignet. Ein Nachteil ist jedoch, dass sie im Vergleich zu den lokalen Verfahren weitaus rechenintensiver sind.

Evolutionäre Algorithmen

Evolutionäre Algorithmen sind von der Natur inspirierte Algorithmen, die auf einem Set von möglichen Lösungen basieren. Dieses Set von möglichen Lösungen stellt eine Population dar. Die Individuen der Population werden hierbei bewertet und qualifiziert. Anhand dieser Qualifikation wird ein gewisser Teil der Population durch Selektion verworfen. Durch Rekombination, Mutation und Migration wird die Population wieder ergänzt. Dies

bildet eine immer wiederkehrende Folge von Rekombination, Mutation, Migration und Selektion [Whi01] (Abbildung 2.11).

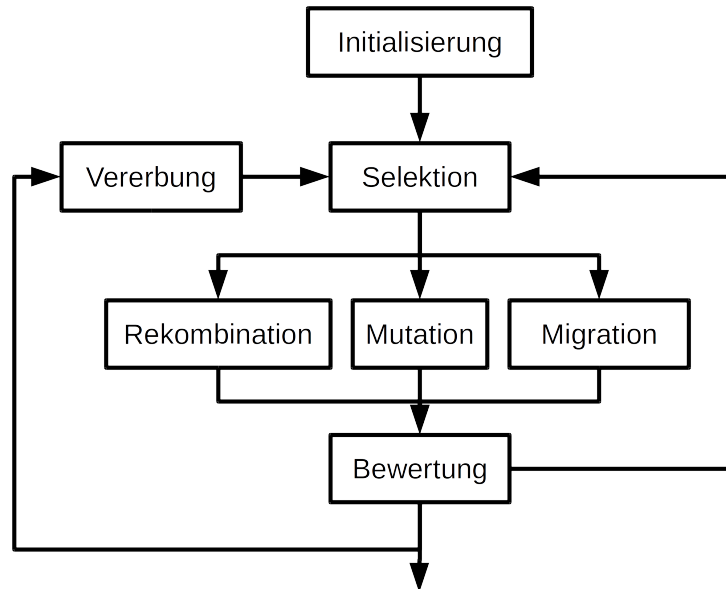


Abbildung 2.11: Aufbau eines evolutionären Optimierungsalgorithmus

Bei der Rekombination werden aus zwei oder mehreren Individuen neue Individuen gebildet. Hierbei kann die Art der Auswahl der Eltern, sowie die Art der Auswahl der zu übernehmenden Teile beliebig variiert werden.

Mutation ist das zufällige Verändern einzelner Individuen. Hierbei werden einzelne Bereiche der Individuen durch Zufallszahlen ausgetauscht. Diese Mutation kann bei einer festen Anzahl von Individuen mit einem gewissen Grad angewendet werden. Dieser Grad wird als Mutationsrate bezeichnet. Variiert zusätzlich per Zufall die Anzahl der Individuen, die mutiert werden, so spricht man von einer spontanen Mutation.

Migration wird in der Evolutionstheorie als das Hinzufügen neuer, meist zufälliger Individuen bezeichnet. Dies ist neben der Mutation die einzige Möglichkeit Individuen mit neuen Werten in die Population einzufügen. Für die initiale Population ohne Vorwissen wird in der Regel eine vollständige Migration verwendet.

Die Selektion entscheidet anhand einer Fitnessfunktion, welche Individuen der Population verworfen werden. Die so verworfenen Individuen werden durch Rekombination und Migration ersetzt. Eine Variation der Größe der Population findet nur selten in der Praxis Anwendung, da für die variable Größe der Population ein weiterer Algorithmus implementiert und angepasst werden muss. Dieser Aufwand lohnt sich jedoch nur in wenigen Fällen. Untersuchungen, wie [EMV04] zeigen aber, dass durch eine variable Anpassung der Populationsgröße deutlich bessere Ergebnisse erzielt werden können. Meist wird die Größe der Population, je nach Anwendung, in der Größenordnung von

mehreren hundert Individuen genutzt [GR02].

Vererbung ist eine Möglichkeit, die speziell bei der Anwendung eines evolutionären Algorithmus für die Optimierung bei der MPC genutzt werden kann. Hierbei kann die gesamte Population zum vorherigen Zeitpunkt $k - 1$ als initiale Population für den Zeitpunkt k verwendet werden. Allerdings muss die ganze Population verschoben werden, sodass $\vec{u}_{(i)}(k + 1)$ zum vorherigen Zeitpunkt $k - 1$ den Wert von $\vec{u}_{(i)}(k)$ zum Zeitpunkt k hat (2.14) [CWL09].

$$\vec{u}_{(i)}(k) = \vec{u}_{(i)}(k - 1) \quad (2.14)$$

Evolutionäre Optimierungsalgorithmen haben im Allgemeinen folgende Vor- bzw. Nachteile [Whi01].

Vorteile:

- Breite Anwendbarkeit
- Anwendbar bei unbekanntem Modellen (*Black-Box* Modellen)
- Keine Ableitungen zur Berechnung nötig
- Keine Anforderungen an die Zielfunktion
- Eignung für komplexe Suchräume
- Kombinierbarkeit mit anderen Optimierungsverfahren (Hybridisierung)
- Sehr einfach parallelisierbar
- Gehört zu der Klasse von Optimierungsalgorithmen, die als *Any-Time-Algorithmus* (auch bei vorzeitigem Abbruch des Verfahrens steht eine Lösung zur Verfügung) bezeichnet werden [Zil96]

Nachteile:

- Fehlende Optimalitätsgarantie
- Relativ hoher Rechenaufwand
- Relativ ineffektiv in der Schlussphase der Optimierung
- Viele Variationsmöglichkeiten der Parametrierung möglich

Für Anwendungen, wie diese ist das Vermeiden von lokalen Minima wichtiger als die fehlende Optimalitätsgarantie. Der Nachteil der fehlenden Optimalitätsgarantie und die relative Ineffektivität in der Schlussphase kann durch die Kombination mit einem nicht evolutionären Algorithmus (Hybridisierung) reduziert werden. Trotz des hohen

Rechenaufwands kann durch Parallelisierung der Berechnung die benötigte Rechenzeit auf einen Bruchteil reduziert werden.

Genetischer Algorithmus

Evolutionäre Algorithmen, die mit diskreten Werten arbeiten, und somit auch eine exakte Lösung ermitteln können, bezeichnet man als genetische Algorithmen. Da die Anzahl der möglichen Lösungen im Gegensatz zu einer klassischen Evolutionsstrategie endlich ist, existiert eine exakte Lösung. Die Anzahl der nötigen Iterationen ist ebenfalls endlich.

Brute-Force-Methode

Brute-Force ist das aufwendigste aller Optimierungsverfahren. Es testet alle möglichen Lösungen und ermittelt daraus das Optimum. Für die Anwendung dieser Methode muss der Lösungsraum diskret sein. Anderenfalls wäre die Anzahl der Lösungsmöglichkeiten unendlich. Vorteil dieser Methode ist die einfache Realisierung und, im Gegensatz zu allen anderen Optimierungsverfahren, die Gewähr, dass immer das globale Optimum gefunden wird. Abhängig von der Größe des Suchraumes und des Grades der Diskretisierung kann die Berechnung sehr zeitintensiv sein. Im Fall der MPC wird der Suchraum durch die Anzahl der Steuergrößen (Freiheitsgrade) n_f und die Anzahl der Zeitschritte K_H bis zum Zeithorizont aufgespannt. Zusammen mit der Anzahl der wertediskreten Schritte der Stellgrößen n_{dis} ergibt sich die Anzahl der möglichen Lösungen n , die in jedem MPC-Regelungszyklus berechnet werden müssen (2.15).

$$n = n_{dis}^{n_f K_H} \quad (2.15)$$

Tabelle 2.1 zeigt zur Verdeutlichung ein Beispiel bei dem nur der Soll-Rollwinkel mit einer Wertediskretisierung in fünf Schritten über einen Prädiktionszeitraum von sieben Sekunden erfolgt. Dieses Beispiel wird bei der simulationstechnischen Untersuchung in Kapitel 4 genutzt. Die Anzahl n der Lösungsmöglichkeiten in jedem MPC-Zeitschritt, die bei der *Brute-Force*-Methode ausgewertet werden müssen, beträgt unter diesen Annahmen 78125.

Tabelle 2.1: Beispiel mit Werten für die Anzahl der Lösungsmöglichkeiten beim *Brute-Force*-Verfahren

Symbol	Werte	Erläuterung
n_{dis}	5	$\{-1 \ -0,5 \ 0 \ 0,5 \ 1\} \phi_{max}$
n_f	1	Soll-Rollwinkel ϕ_c
K_H	7	7s Zeithorizont / $\Delta t = 1s$
n	78125	Lösungsmöglichkeiten pro MPC-Zeitschritt

Stabilität

Generell ist ein Nachweis der Stabilität bei der MPC schwierig. Nur bei einer unbeschränkten MPC mit einem unendlichen (ausreichend großen) Prädiktionshorizont ist ein Nachweis unproblematisch. Im Fall einer linearen MPC gleicht diese dem linear-quadratischen Regler (LQR) [AF02]. Besonders bei der nichtlinearen Regelung ist im Fall von Modellungenauigkeiten, Störungen oder Messfehlern ein Garantie der Stabilität schwierig. Dies ist noch immer ein aktuelles Forschungsgebiet der robusten MPC.

Eine Möglichkeit die Stabilität der nichtlinearen MPC zu gewährleisten, ist mit einem unendlichem oder quasi-unendlichem Prädiktionshorizont [AF02]. Hierbei wird eine *Lyapunov*-Funktion als Gütewert verwendet und neben anderen Bedingungen wird untersucht, ob diese monoton zu einer Lösung konvergiert. Eine weitere Möglichkeit ist die Anwendung von mengentheoretischen Ansätzen [Mei11].

2.4 Missionsplanung

Aufbauend auf der Flugregelung ist die Aufgabe der Missionsplanung, eine Mission oder Teile einer Mission zu planen und durchzuführen. Die Flugregelung unterstützt diese dabei und erhält von der Missionsplanung Sollwerte. Die Missionsplanung besteht aus verhaltensbasierenden Methoden, Potenzialfeldern, Graphen oder anderen Methoden.

Auf welcher Ebene die Flugregelung Sollwerte von der Missionsplanung erhält, variiert je nach Methode. Jedoch werden in vielen Fällen Wegpunkte oder Kurse vorgegeben (Flugpfadplanung). Bei heute im Einsatz befindlichen UAVs übernimmt oft der Systemmanager die Aufgabe der Missionsplanung. Für experimentelle UAVs existieren verschiedene Methoden der Missionsplanung, die im Folgenden betrachtet werden.

Vielversprechende Ansätze, die in anderen Arbeiten zur Regelung von UAVs und UAV-Schwärmen angewendet werden, sind:

- Verhaltensbasierende Ansätze
- Potenzial-/Vektorfeldbasierende Ansätze
- Graphenbasierende Ansätze

2.4.1 Verhaltensbasierende Ansätze

Verhaltensbasierende Ansätze werden bevorzugt in der Informatik angewendet. Beispiele solcher verhaltensbasierender Ansätze im Bereich der Koordinierung von UAVs sind [RWL02] [Rey87] [Rey00] [PR04] [TB98]:

- Endliche Zustandsautomaten: Regeln mit Zuständen
- Regelbasierendes System: Wenn-Dann Regeln
- Agentenbasierende Systeme: Verteilte Regeln
- Neuronale Netze: Nichtlineare trainierte Regeln

Endliche Zustandsautomaten

Endliche Zustandsautomaten bestimmen den Zustand des Systems bzw. weisen dem Zustand des Systems einen vom Programmierer definierten Soll-Zustand zu. Dieser Zustand definiert ein Verhalten. Das UAV verhält sich entsprechend den programmierten Handlungsweisen bis sich der Zustand ändert.

Oft werden Endliche Zustandsautomaten verwendet, um zwischen verschiedenen Regelungen bzw. Aufgaben umzuschalten. Ein Beispiel hierfür beschreibt Oyekan [OH09]. In dieser Arbeit werden anhand der Zustände unterschiedliche Verhaltensweisen, wie

starten, schweben, Wegpunkt anfliegen, folgen, ausweichen und landen, aktiviert.

Ein weiteres Beispiel beschreibt Tooren [VTHKB07]. Hier wird anhand der Zustände entschieden, ob ein Ausweichen anderer Flugzeuge notwendig ist und in welcher Art dies erfolgen soll. Dazu gehört auch die Entscheidung, wann die ursprüngliche Route wieder verfolgt wird.

Typischer Vertreter der Regelung mit endlichen Zustandsautomaten im Bereich Koordination von UAV-Schwärmen, sind die Veröffentlichungen von Marden [MAS09] und Kim [SK07]. Beide beschreiben die Regelung einer festen Formation in einer Umgebung frei von Hindernissen.

Wenn-Dann Regeln

Im Unterschied zum Zustandsautomaten entscheidet hier nicht der gesamte Zustand über das Verhalten, sondern einzelne Zustände, die ein Teilverhalten beeinflussen [PDY09]. Die Anwendung der Regeln beruhen auf Änderungen von einzelnen Zuständen. Der gesamte Zustand wird hierzu nicht benötigt. Dies entspricht am ehesten dem menschlichen Verhalten, da in vielen Fällen ein Überblicken der Vielzahl an Zuständen nicht möglich und meist auch nicht notwendig ist.

Verteilte Regeln

Ein klassischer Ansatz für die sehr verbreiteten verteilten Regeln ist von Parker [Par98] beschrieben. In diesem Fall wird für die Koordination des Schwarms ein marktbasierendes Verhalten verwendet. Bei diesem handeln die Agenten wie auf einem Markt untereinander aus, wer welche anstehenden Aufgaben am besten durchführen kann. Die eigentliche Durchführung der Aufgabe erfolgt meist ohne Koordination.

Neuronale Netze

Die Entscheidung, welches Verhalten zu welchem Zeitpunkt angewendet werden soll, kann auch mithilfe eines trainierten Neuronalen Netzes erfolgen [SML⁺07]. Im Gegensatz zum Neuronalen Regler übernimmt das Neuronale Netz nicht die Ausführung des Verhaltens, sondern nur die diskrete Entscheidung, welches Verhalten aktiviert werden soll. Somit besitzt mindestens die Ausgangsschicht des Neuronalen Netzes eine diskrete Aktivierungsfunktion. Einen Überblick über diese Ansätze zur Koordination von Schwärmen mit verhaltensbasierenden Ansätzen vermittelt Prieditis [PDA⁺04].

Vor- und Nachteile verhaltensbasierender Ansätze

Ein besonderer Vorteil der verhaltensbasierenden Ansätze ist, dass das resultierende Verhalten deterministisch und die Reaktionen der Koordination vorhersehbar sind. Dies ist besonders für die Zertifizierbarkeit von Bedeutung.

Ein entscheidender Nachteil der verhaltensbasierenden Ansätze ist, dass alle möglichen Fälle vom Programmierer berücksichtigt werden müssen. Im Fall der Neuronalen Netze müssen die Fälle ausreichend trainiert werden. Ist ein Fall nicht berücksichtigt und tritt dieser in der Realität ein, so kann dies zu einem Ausfall oder unvorhersehbarem Verhalten führen. Bei einer großen Anzahl von Eingängen kann die Anzahl der zu behandelnden Fälle sehr umfangreich sein. Dies wiederum kann eine Programmierung aufwendig und fehleranfällig machen. Die Intelligenz des UAVs ist abhängig von der Intelligenz seines programmierten Verhaltens. Die Zuverlässigkeit dieses Verhaltens ist wiederum von der Sorgfalt des Programmierers abhängig. Generell können diese Verfahren keine Situationen behandeln, welche zuvor nicht bedacht wurden, und sind damit für eine autonome Regelung, die auch auf unvorhersehbare Situationen reagieren müssen, wenig geeignet.

2.4.2 Potenzial-/Vektorfeld Ansätze

Bei potenzialfeldbasierenden Ansätzen werden Ziele, Hindernisse und andere Randbedingungen durch Potentiale dargestellt. Sie generieren einen Weg entlang des geringsten Gradienten, um das Ziel mit dem geringsten Potenzial zu erreichen (Abbildung 2.12).




Abbildung 2.12: Ein Beispiel für ein Potenzialfeld mit Hindernissen [GMH08]

Potenzial- und Vektorfelder werden hier zusammen betrachtet, da Potenzialfelder in Vektorfelder überführt werden können (Abbildung 2.13).

Die Fähigkeit eines konservativen Kraftfeldes, eine Arbeit zu verrichten, wird als Potenzial bezeichnet. Dabei ist das konservative Kraftfeld \vec{F} der Gradient des Potenzialfelds Φ .

$$-m \vec{\nabla} \Phi = \vec{F} \quad (2.16)$$

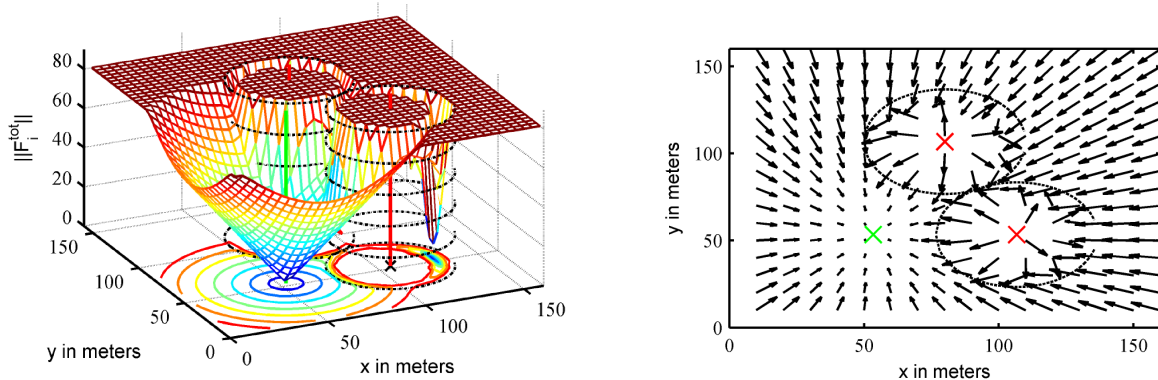


Abbildung 2.13: Beispiel eines Potenzialfeldes und dessen zugehörigen Vektorfeldes [PKG08]¹

Klassische Anwendungsfälle von Potenzialfeldern sind Berechnungen von aero- oder fluiddynamischen Strömungen oder elektromagnetischen Feldern basierend auf der Potenzialfeldtheorie. Um beispielsweise Strömungen zu simulieren, werden Potenzialfelder aus einzelnen Potenzialen, wie Quellen oder Senken, zusammengesetzt. Diese bilden die Form des zu umströmenden Körpers nach. Mit einer weiteren Quelle und Senke wird eine Strömung simuliert. Das sich daraus ergebende Vektorfeld bildet im inkompressiblen und reibungsfreien Fall die Strömung nach. Jede Stromlinie des Vektorfeldes umfließt, wie in der Realität, die Körper.

Künstliche Potenzialfelder finden schon sehr lange Anwendung im Bereich der Robotik. Goodrich beschreibt einen allgemeinen Überblick und Grundlagen zu künstlichen Potenzialfeldern und Algorithmen [Goo02]. Im Weiteren werden diese auch als Potenzialfelder und nicht notwendigerweise als künstliche Potenzialfelder bezeichnet.

Ein Beispiel für die Anwendung eines klassischen Potenzialfeldansatzes ist dargestellt bei Daily [DB08]. Das Besondere in diesem Fall ist die direkte Anwendung der Potenzialfeldtheorie aus der Fluidodynamik. Hier wird aus Quellen- und Senken-Kombinationen eine Stromlinie generiert, die wie bei einer realen Stromlinie alle Hindernisse umfließt. Hierbei wird der komplette Weg berechnet und als Pfadplanung verwendet.

Der Vorteil der Potenzial-/Vektorfelder besteht darin, dass beliebige Potenziale hinzugefügt werden können. Damit lassen sich komplexe Umgebungen abbilden. Potenzialfelder können im Gegensatz zu vielen anderen Methoden der Regelungstechnik widersprüchliche Nebenbedingungen, wie Hindernisse und Ziele, berücksichtigen.

Üblicherweise setzt sich das Potenzial für eine Pfadplanung aus mehreren Potenzialen zusammen. Die einzelnen Potenziale stellen die Ziele, Hindernisse oder andere UAVs dar. Oft werden sie zunächst als einzelne Potenzialfelder behandelt. Diese werden an-

¹ Zur besseren Visualisierung werden die Darstellung des Potenzial beschränkt $\|F_i^{tot}\| > 80 \Rightarrow 80$) [PKG08]

schließlich gewichtet und zu einem Potenzialfeld akkumuliert. Das daraus gebildete Potenzialfeld ist gleichbedeutend mit einem einzelnen Potenzialfeld, in dem alle Potenziale schon gewichtet eingetragen sind.

Ein anderer Ansatz bestimmt die Gradienten aus den einzelnen Potenzialfeldern und addiert diese [PKG08]. Der sich ergebende Vektor wird als Vorgabe für einen Regler verwendet. Dabei werden die Richtung und der Betrag dieses Vektors als Geschwindigkeitsvektor interpretiert. In diesem Ansatz werden vier Potenzialfelder verwendet, um für jedes einzelne UAV in einem dezentral organisierten Schwarm eine Formation zu regeln.

Dieses Vorgehen besitzt allerdings zwei wesentliche Nachteile. Einer besteht darin, dass es die Dynamik des Fluggeräts nicht immer zulässt, dem sich ergebenden Flugweg zu folgen. Dieses lässt sich allerdings durch Hinzufügen des dynamischen Verhaltens in das Potenzial [SKI05] bzw. Vektorfeld [HPP⁺06],[Fre07],[LFP07] erreichen. Ein weiterer Nachteil sind lokale Minima, in denen sich das UAV sprichwörtlich verfangen kann.

Ein klassisches Beispiel für solch ein Minimum ist ein U-förmiges Hindernis (Abbildung 2.14). Dies wird auch als *Goals NonReachable with Obstacles Nearby* (GNRON) bezeichnet. Gerät ein UAV in solch ein lokales Minimum müsste es sich, um diesem zu entkommen, zunächst in Richtung eines höheren Potenzialwerts bewegen. Dies widerspricht jedoch der Vorgabe, wonach sich das UAV immer in Richtung des niedrigeren Potenzialwertes bewegen soll, um das Ziel, das globale Minimum, zu erreichen. In Abbildung 2.14 ist das UAV gefangen zwischen dem Potenzial der Kollisionsvermeidung mit Hindernissen, welches die Bewegung nach drei Seiten verhindert, und dem Potenzial, welches das UAV zum eigentlichen Ziel drängen soll.

Prinzipiell könnte das Ziel eines Potenzialfeldalgorithmus die Maximierung des Potenzials sein. Dies wird jedoch üblicherweise nicht angewendet, da die Minimierung des Potenzials physikalisch wesentlich anschaulicher ist.

Für das Problem der lokalen Minima existieren verschiedene Lösungen. Eine dieser Lösungen ist die *Waterfall*-Methode. Bei dieser wird virtuell das lokale Minimum mit Wasser aufgefüllt, sodass dieses an der niedrigsten Stelle überläuft. Dabei wird ausgehend von dem lokalen Minimum konzentrisch und inkrementell nach einer horizontalen Tangente gesucht. Diese stellt den Ort dar, bei dem das Wasser abfließen bzw. das UAV das lokale Minimum verlassen kann. Zusammen mit eventuell weiteren vorhanden lokalen Minima ergibt sich ein Wasserfall hin zum globalen Minimum (Abbildung 2.15) [MHM08] [YZ09].

Eine weitere Möglichkeit, einem solchen lokalem Minimum zu entweichen, ist die sogenannte *Wall-Following*-Methode, bei der nach Erkennen eines lokalen Minimum ein




Abbildung 2.14: Beispiel für ein lokales Minimum durch ein U-förmiges Hindernis vor einem Ziel [Goo02]




Abbildung 2.15: Visualisierung der Water-Fall-Methode

Ausweg entlang der Grenzen des Minimums gesucht wird.

Ein effizienteres Vorgehen ist es, das Potenzialfeld von Anfang an so zu gestalten und zu parametrieren, dass keine lokalen Minima vorhanden sind. Jia [JW10] beschreibt eine Möglichkeit die Gewichtung zwischen an- und abstoßenden Potenzialen entsprechend zu modifizieren, sodass keine lokalen Minima entstehen. Erreicht wird dies durch eine analytische Betrachtung der ersten Ableitung des Potentials, die nur im Ziel zu null (horizontale Tangente) werden darf. Daraus ergeben sich Bedingungen für die Gewichtungen, die das Ziel zum alleinigen Minimum werden lassen.

Allerdings ist die Grundvoraussetzung für dieses Verfahren, dass das gesamte Potenzial analytisch formuliert werden kann. Um dies gewährleisten zu können, muss die gesamte Umgebung zu Beginn bekannt sein. Des Weiteren darf das Potenzialfeld nicht zu komplex sein, damit eine analytische Berechnung der Ableitung möglich ist. Die entscheidenden Vorteile der Potenzialfelder, wie die beliebige Gestaltungsmöglichkeit und die dynamischen Updates des Potenzialfelds, wären in diesem Fall nicht nutzbar.

2.4.3 Graphenbasierende Ansätze

Graphenbasierende Ansätze sind Algorithmen, die zur Pfadplanung eingesetzt werden und keine Regelung im eigentlichen Sinne sind. Jedoch lässt sich die Planung in vielen Teilen mit einer Regelung vergleichen. Immer, wenn während der Ausführung der zuvor geplanten Trajektorie keine Änderung der Gegebenheiten eintritt und diese zum Zeitpunkt der Planung vollständig bekannt sind, ist eine Pfadplanung sinnvoll. Nun sind in vielen Fällen die Gegebenheiten dynamisch, sodass eine erneute Planung während der Laufzeit nötig wird. Wird eine solche erneute Planung in festen Zyklen durchgeführt

oder immer dann, wenn sich die Gegebenheiten ändern, ergibt sich ein geschlossener Regelkreis. Aus der Pfadplanung, die eine reine Steuerung ist, wird eine Regelung.

Im täglichen Leben nutzen wir solche graphenbasierende Algorithmen beispielsweise bei Kraftfahrzeug-Navigationssystemen, um den schnellsten oder kürzesten Weg von A nach B zu finden. Diese Algorithmen wählen aus einem Set von Streckenabschnitten das Set mit dem kürzesten Weg oder der kürzesten Fahrzeit.

In der Graphentheorie ist eine Anzahl Knoten (Kreuzungen) mit Kanten (Straßen) verbunden. Da im Fall der Kraftfahrzeug-Navigationssysteme die Länge der Straßen und nicht die Kreuzungen entscheidend sind, werden solche Probleme als Kantengewichte endlicher Graphen bezeichnet. Die Anzahl der möglichen Streckenverläufe ist endlich aber im Regelfall sehr hoch.

Lösbar werden die komplexen Probleme durch die Anwendung effektiver Suchalgorithmen. Ein klassischer Vertreter dieser ist der Dijkstra-Algorithmus [Dij59]. Bei ihm wird ausgehend von einem Startpunkt (a) für jeden Knoten (b,c,d,e,f) die kürzeste Distanz (Kantengewicht) bestimmt (Abbildung 2.16). Die Werte der Knoten werden in jedem Schritt des Algorithmus basierend auf dem vorhergehenden Knotenwert und dem entsprechenden Kantengewicht bestimmt. Hierbei wird immer nur der geringste Wert übernommen und die eventuell vorhandenen Verbindungen mit einem höheren Wert entfernt.

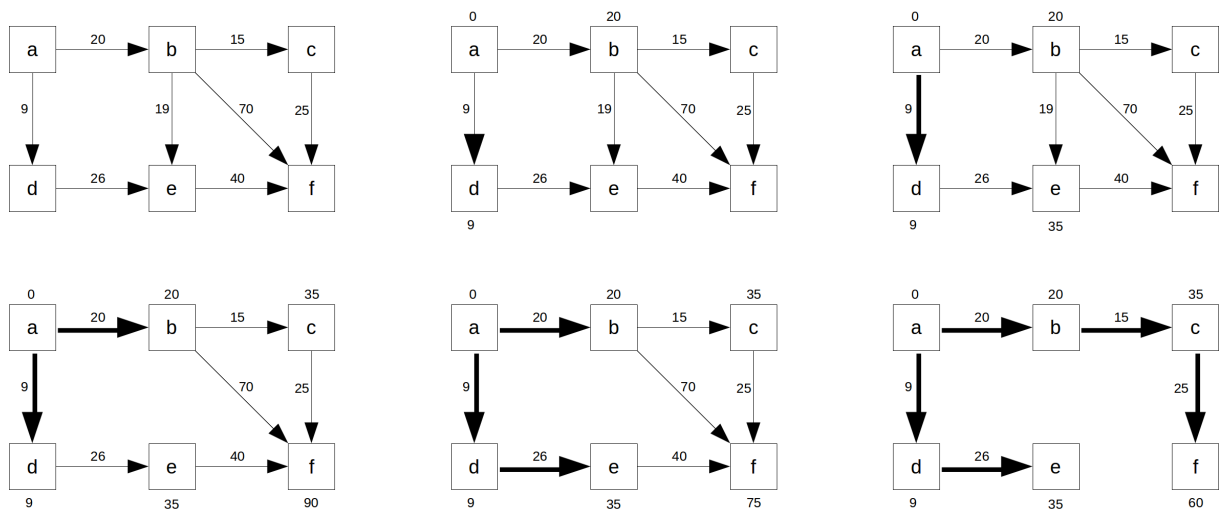


Abbildung 2.16: Beispiel eines *Dijkstra* Algorithmus (nach [Dij59])

Eine Erweiterung des *Dijkstra*-Algorithmus ist der *A**-Algorithmus [HNR68]. Dieser nutzt eine Schätzfunktion, um in jedem Schritt die Anzahl der Kanten und Knoten zu reduzieren. Die Schätzfunktion ermittelt für jede Kante die Wahrscheinlichkeit Teil der

optimalen Lösung zu sein.

UAVs bewegen sich aber nicht auf Straßen (Kanten), weshalb die Anzahl der möglichen Wege bei einem Flug von A nach B selbst mit Hindernissen unbegrenzt ist. Das würde zu einem unbegrenzten Graphen führen, bei der die Suche des kürzesten Weges nicht lösbar wäre. Der kürzeste Weg von A nach B ist der direkte Weg oder ein Weg, der über die Ecke der Hindernisse führt. Verbindet man jede Ecke mit jeder von der entsprechenden Ecke aus sichtbaren Ecke, erhält man einen sogenannten Sichtbarkeitsgraphen (Abbildung 2.17). Sichtbarkeitsgraphen sind beschränkte Graphen, die durch die zuvor genannten Algorithmen lösbar sind.




Abbildung 2.17: Ein Beispiel für Sichtbarkeitsgraphen in einer Umgebung mit Hindernissen [GMH08]

Richards beschreibt eine Koordinierung für einen UAV-Schwarm, welcher Wegpunkte in einer Umgebung mit Hindernissen abfliegt [RBTH02]. Dieser Algorithmus nutzt Sichtbarkeitsgraphen, welche über die Ecken der Hindernisse und die Wegpunkte gebildet werden. Die Optimierung weist jedem UAV eine Trajektorie bzw. ein Set an Wegpunkten zu.

Ein spezielles Problem der Graphen ist das Problem des Handelsreisenden oder das Rundreiseproblem. Übertragen auf UAVs bedeutet dies, es müssen von einem einzelnen UAV alle Wegpunkte einmal überflogen werden. Ist die Anzahl der zu überfliegenden Wegpunkte n , so beträgt die Anzahl der möglichen Lösungen $n!$.

Bertuccelli beschreibt eine weitere Möglichkeit der Pfadplanung zur Kontrolle eines Schwarms [BAH04]. Hier sollen Wegpunkte in einer Umgebung mit Hindernissen erreicht werden. Im ersten Schritt werden die Aufgaben einzelnen UAVs zugeteilt.

Anschließend erfolgt im zweiten Schritt die Pfadplanung mit einem Gütefunktional. Mit *Mixed Integer Linear Programming* (MILP) [Flo95] wird in diesem Fall der optimale Weg berechnet. Solch eine Regelung kann nur aufgrund der Aufteilung von weitgehend unabhängigen Aufgaben angewendet werden. Ist eine größere Interaktion bzw. eine ständige Interaktion notwendig, ist dieses Vorgehen nicht praktikabel.

2.5 Fazit

In diesem Kapitel sind unter anderem verhaltensbasierende Ansätze beschrieben worden. Sie ermöglichen eine deterministische Regelung. Jedoch steigt die Komplexität bei dieser Art der Regelung exponentiell mit der Größe des zu regelnden Systems. Eine Anwendung von verhaltensbasierenden Ansätzen zur Regelung eines Schwarms ist somit sehr aufwendig. Alle möglichen Zustände des Systems müssen bei der Programmierung bedacht werden, um ein unkontrolliertes Verhalten zu verhindern. Damit ist die Intelligenz der Regelung definiert durch die Programmierung.

Graphenbasierte Ansätze sind zunächst nur zur Pfadplanung geeignet. Jedoch können sie durch kontinuierliche Neuplanung als Regelung verwendet werden. Für das Integrieren von zusätzlichen Randbedingungen, wie sie für einen Schwarm benötigt werden, sind diese nicht geeignet.

Im Gegensatz sind bei einer Regelung mit Potenzialfeldern Randbedingungen und mehrfache Ziele einfach integrierbar. Dies erlaubt eine beliebige Gestaltung des Potenzialfeldes. Jedoch ist die Fliegbarkeit der auf dieser Regelung basierenden Trajektorie nicht sichergestellt. Auch können lokale Minima entstehen, die nur durch analytische Betrachtung des Potenzialfeldes vermieden werden könnten. Dies schränkt die Möglichkeiten der Gestaltung des Potenzialfeldes ein und erfordert die analytische Bestimmung des Gradienten für das gesamte Potenzialfeld.

Neuronale Netze können komplexe, nichtlineare Zusammenhänge abbilden und sind deshalb für die nichtlineare Regelung geeignet. Ein ausreichendes Training für den gesamten Zustandsraum ist die Voraussetzung. Bei einem Schwarm ist dies allerdings mit sehr hohem Aufwand verbunden.

Bei der Einhaltung einer Formation werden oft zwei unterschiedliche Ansätze verwendet. Im einem Fall plant oder regelt nur ein UAV seinen Flugweg und die anderen UAV halten relativ zu diesem ihre Flugbahn. Im anderen Fall werden vorab die Flugbahnen aller UAVs geplant. Die UAVs regeln sich dann eigenständig auf den zuvor definierten 4D-Trajektorien. Dabei muss in beiden Fällen die Planung Zusammenstöße mit Hindernissen vermeiden. In einer sich verändernden Umgebung ist eine ständige Neuplanung notwendig. Es existieren aber Ansätze welche zur Regelung eines Schwarmes einen Mehrgrößenregler nutzen. Die Implementierung von Randbedingungen ist hierbei schwierig. Die MPC wird zur Formationsregelung in unterschiedlichen Varianten eingesetzt. In einem Fall enthält die MPC zur Vermeidung von Hindernissen einen zusätzlichen Term im Gütefunktional. Dies ermöglicht eine Vermeidung von einfachen Hinderniskonstellationen.

Bei der Anwendung zum Verfolgen von bewegten Objekten ist ein Ansatz zu finden welcher, für kurze Zeiträume eine modellprädiktive Pfadplanung anwendet. Zur Opti-

mierung verwendet diese einen evolutionären Algorithmus. Dies erlaubt ein komplexes Gütefunktional, da ein evolutionärer Optimierungsalgorithmus keinerlei Anforderungen an die Gestalt stellt und es sich um ein Verfahren handelt, welches zur Lösung von globalen Optimierungsproblemen geeignet ist.

Ein sehr häufiges Anwendungsgebiet für UAV-Schwärme ist die Exploration. Hierbei kann nach einzelnen Objekten gesucht, oder Vektor- bzw. Skalarfelder erkundet werden. Schadstoffe oder radioaktive Wolken nach Katastrophen sind Anwendungsmöglichkeiten hierfür. Oft erfolgt eine Planung (Aufteilung des Suchgebietes) zuvor. Es existieren auch Ansätze bei denen abhängig von der Wahrscheinlichkeitsverteilung eine kontinuierliche Aufteilung erfolgt. Auch werden die Parameter von analytischen Modellen mittels eines *Extended-Kalman-Filter* während des Fluges geschätzt. Das so parametrisierte Modell kann wiederum während des Fluges zur Regelung des Schwarms verwendet werden.

Grundsätzlich sind dezentral organisierte Schwärme robuster gegenüber Ausfällen, da kein zentrales Element existiert. Im Gegensatz hierzu sind bei einer zentralen Struktur bessere Ergebnisse zu erwarten, da alle Informationen zur Verfügung stehen und eine bessere Koordinierung ermöglicht wird. Jedoch steigt der Aufwand zur Optimierung der Koordinierung exponentiell mit der Größe des Schwarms. Wenn ein Schwarm skalierbar und robust gegenüber Ausfällen sein soll, ist eine dezentrale Struktur erforderlich.

Weiter existiert keine Untersuchung zur verteilten nichtlinearen modellprädiktiven Regelung mit einem Potenzialfeld und einem evolutionären Optimierungsalgorithmus bei der Anwendung zur Regelung von einzelnen UAVs und Schwärmen von UAVs.

3 Konzeption einer dezentralen Regelung von Schwärmen

3.1 Auswahl des Verfahrens

Im Folgenden wird ein Konzept zur Koordinierung eines Schwarms abgeleitet. Dazu werden die Anforderungen aus Kapitel 1 genutzt, um eine Auswahl zu treffen. In Abbildung 3.1 ist der im weiteren Verlauf beschriebene Entscheidungsprozess grafisch dargestellt.

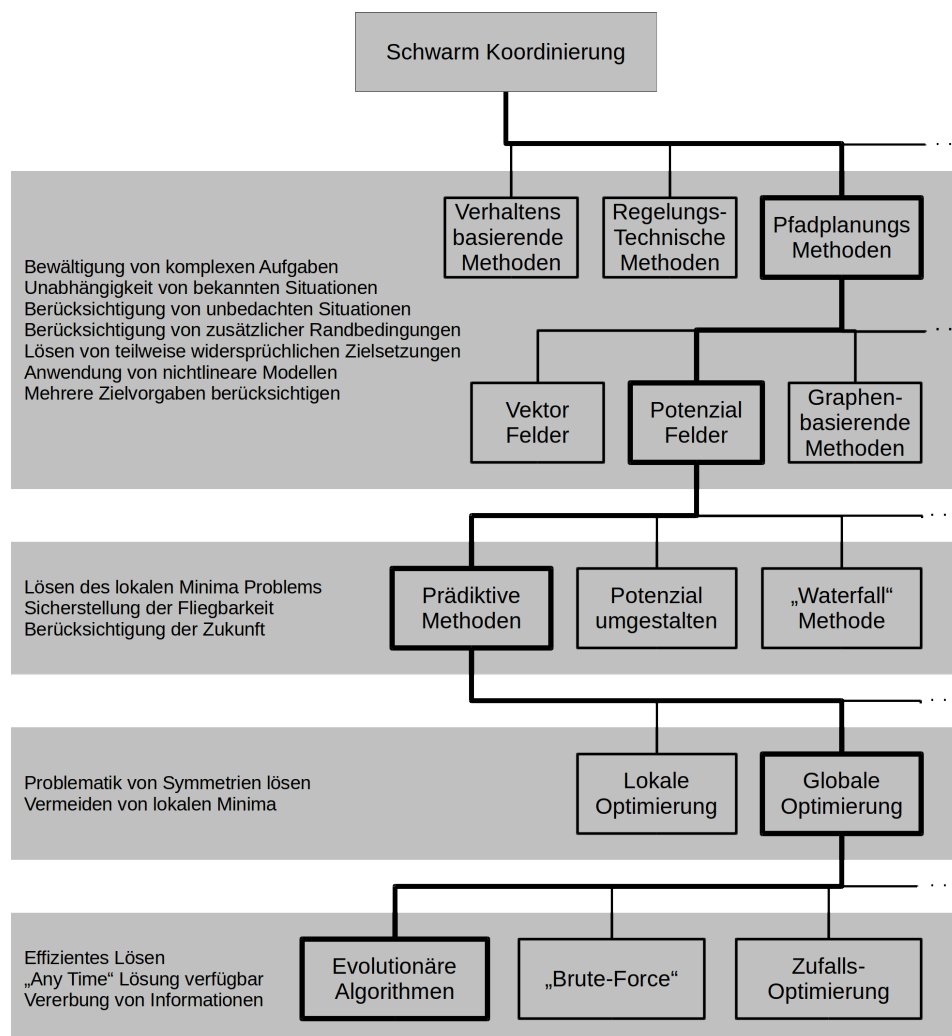


Abbildung 3.1: Grafische Darstellung des Entscheidungsprozesses

Die meisten Verfahren zur Koordinierung eines Schwarms lassen sich in drei Arten aufteilen: verhaltensbasierende Methoden, regelungstechnische Methoden und Pfadplanungsmethoden (Kapitel 2.4). Zur Koordinierung eines Schwarms wird hier die Potenzialfeldmethode gewählt, da sie im Gegensatz zu verhaltensbasierenden Methoden Situationen, die von dem Programmierer nicht berücksichtigt sind, lösen kann. Im Fall der verhaltensbasierenden Methoden erhöht sich die Gefahr mit steigender Komplexität, dass einzelne Situationen vom Programmierer nicht ausreichend oder überhaupt nicht bedacht werden. Dadurch kann unerwünschtes Verhalten des Schwarms oder einzelner UAVs auftreten. Im Gegensatz zu den regelungstechnischen Methoden können bei der Potenzialfeldmethode mehrere Ziele und Randbedingungen vorgegeben werden, welche sich auch widersprechen können. Deshalb werden sie nur einfache Aufgaben in Kombination mit einer übergeordneten Instanz (im Regelfall verhaltensbasierenden Methoden), welche diese Widersprüche lösen, angewendet.

Vektorfelder und Potenzialfelder können unter zuvor genannten Bedingungen ineinander überführt werden. Sie repräsentieren folglich die selbe Information, jedoch ist die Gestaltung eines Potenzialfeldes weniger restriktiv und intuitiver als die Gestaltung eines Vektorfeldes. Weiter können Potenzialfeldmethoden im Gegensatz zu graphenbasierenden Methoden zusätzliche, nicht-geometrische Randbedingungen berücksichtigen, wie sie bei der Koordinierung eines Schwarms zur Erfüllung einer Aufgabe in einer komplexen Umgebung notwendig sind.

Zur Vermeidung von lokalen Minima existieren unterschiedlichste Ansätze (Kapitel 2.4.2). Das Potenzialfeld kann so gestaltet werden, dass es keine lokalen Minima enthält. Dazu muss für das gesamte Potenzialfeld der Gradient analytisch berechenbar sein. Anschließend müssen die Gewichtungen der unterschiedlichen Ziele und Randbedingungen so verändert werden, dass nur an einer Stelle ein Minimum entsteht. Dies schränkt die Flexibilität und die Gestaltungsmöglichkeit der Potenziale ein. Andere Möglichkeiten sind Methoden, wie der *Water-Fall-* oder *Wall-Following-Algorithmus*, die das Verlassen eines lokalen Minimums ermöglichen, wenn es erreicht wird. Effektiver sind vorausschauende Methoden, wie die modellprädiktive Regelung. Mit ihnen kann ein lokales Minimum schon vor dessen Erreichen erkannt und somit vermieden werden. Der modellprädiktive Ansatz hat den Nebeneffekt, dass die Fliegbarkeit der generierten Trajektorie durch das inhärente flugmechanische Modell gewährleistet ist. Darüber hinaus werden zukünftige Randbedingungen und andere Gegebenheiten innerhalb des zeitlichen Horizonts mitberücksichtigt.

Obwohl das Problem der lokalen Minima sich durch die modellprädiktive Regelung reduzieren lässt, können nicht alle lokalen Minima vermieden werden. Durch die Akkumulation, über die Zeitspanne, bis zum Horizont können ebenfalls lokale Minima entstehen, welche allein durch die Prädiktion nicht vermieden werden können. Dies ist insbesondere bei Symmetrien der Fall. Um diesem Problem zu begegnen, kann das in der modellprädiktiven Regelung üblicherweise verwendete lokale Optimierungsverfahren

durch einen Optimierer ersetzt werden, welcher zur Lösung von globalen Optimierungsproblemen geeignet ist. Im Regelfall besitzen diese Optimierer eine geringere Konvergenzrate als die lokalen Optimierer [Lan10]. Für diese Anwendung ist jedoch ein Optimierungsverfahren, welches zur Lösung von globalen Optimierungsproblemen geeignet ist von höherem Nutzen, als eine hohe Konvergenzrate.

Es existiert eine Vielzahl von globalen Optimierungsverfahren. Der Bereich der evolutionären Algorithmen wird gewählt, da er universell einsetzbar ist und keinerlei Einschränkungen bezüglich der zu optimierenden Funktion hat. Zusätzlich verfügt er im Gegensatz zu *Brute-Force* [PSL06] und anderen Algorithmen über eine Art Gedächtnis. Stellgrößenfolgen, die in vorherigen Optimierungsschritten zu guten Lösungen geführt haben, werden auch in folgenden Optimierungsschritten verwendet. Weiter gehören evolutionäre Algorithmen zu der Klasse der *Any-Time-Algorithmen* [Zil96]. Dies garantiert eine Lösbarkeit auch mit geringer Rechenleistung.

Das Resultat dieser Diskussion ist eine modellprädiktive Regelung basierend auf Potenzialfeldern und einem evolutionären Algorithmus (Abbildung 3.2). Dies stellt eine Kombination ähnlich der von Shim [KSS03] und Wise [Wis06] veröffentlichten Algorithmen dar.

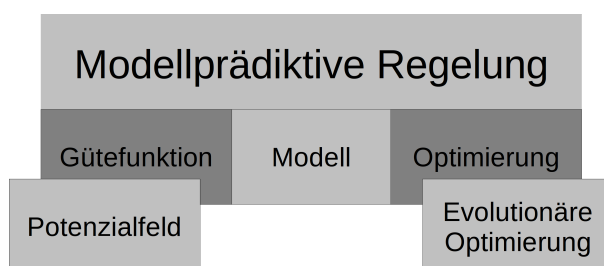


Abbildung 3.2: Resultat der Diskussion des Regelungsalgorithmus

3.1.1 Struktur des Verfahrens (Algorithmus)

Die Struktur des entwickelten Algorithmus besteht aus zwei Kreisen. Einem äußeren Regelkreis und einem inneren Kreis für die Optimierung (Abbildung 3.3). Sollvorgaben erfolgen durch den Systemmanager in Form der Gewichtungen der Potenzialfelder \vec{l} (Kapitel 3.2.3). Diese Gewichtung \vec{l} ist die einzige Vorgabe des Systemmanagers und definiert das Ziel der Mission. In dieser Arbeit sind für jedes UAV des Schwarms die Gewichtungen gleich. Dies gewährleistet einen homogenen Schwarm und jedes UAV kann gegen ein anderes ausgetauscht werden.

In einzelnen Situationen wäre es jedoch vorstellbar, dass eine unterschiedliche Gewichtung sinnvoll sein könnte. Dies wäre eine Art von gezielter Verteilung von Aufgaben, fest

vorgegeben durch den Systemmanager. Weitaus sinnvoller ist eine Aufgabenverteilung, welche in ein Potenzialfeld eingebaut ist. Dadurch kann das einzelne UAV basierend auf der jeweiligen Situation selbst entscheiden, welche Aufgabe es übernimmt.

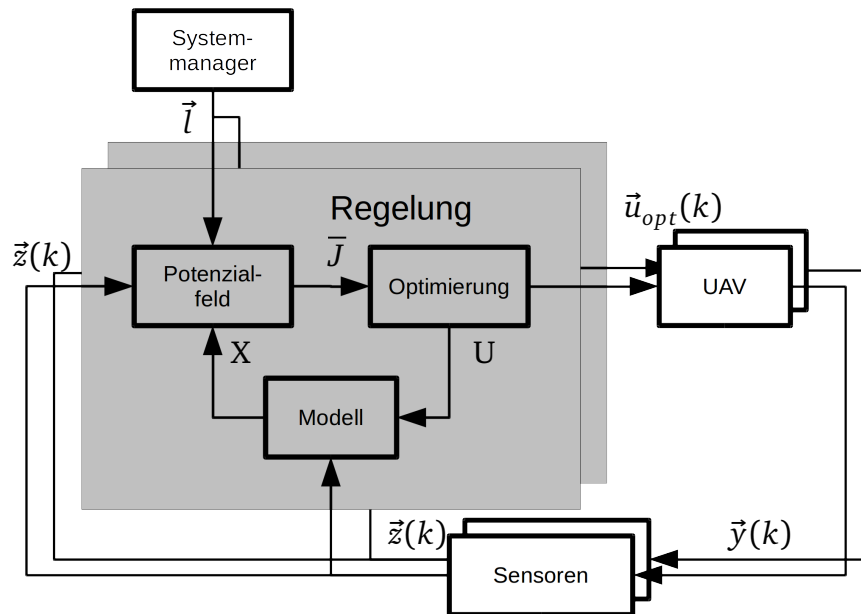


Abbildung 3.3: Struktur dieser modifizierten modellprädiktiven Regelung

Der innere Kreis besteht aus einem Optimierungsalgorithmus, einem künstlichen Potenzialfeld und dem Modell. Optimiert wird das akkumulierte Potenzial \bar{J} (Kapitel 3.2.3) des aktuellen diskreten Zeitpunkts k bis zum Ende des Prädiktionshorizontes $k + K_H$. Das akkumulierte Potenzial wird gebildet aus der Potenzialfolge $\vec{\Phi} = [\Phi(k) \ \Phi(k+1) \ \dots \ \Phi(k+K_H)]$ (Kapitel 3.2.3) und den vom Systemmanager definierten Gewichtungen G (Kapitel 3.2.3). Die Potenzialfolge $\vec{\Phi}$ wird mithilfe der prädizierten Zustandsvektorfolge $X = [\vec{x}(k) \ \vec{x}(k+1) \ \dots \ \vec{x}(k+K_H)]$ und aktuellen Messwerten $\vec{z}(k)$ durch das Potenzialfeld ermittelt.

Das mehrmalige Iterieren des inneren Kreises (Optimierung) erfolgt, um eine optimierte Stellgröße zu generieren. Zusätzlich sollte bedacht werden, dass je nach Hardware oder Implementierung Algorithmen nicht parallel ausgeführt werden können. In solch einem Fall erfolgt die Berechnung seriell.

Die mithilfe der Optimierung im inneren Kreis bestimmte Lösung hat nur solange Bestand, wie keine neue Lösung existiert. Üblicherweise wird das Zeitintervall der Stellgrößen Δt_h gleich dem Zeitintervall Δt_c des äußeren Regelkreises gewählt. In diesem Fall wird in jedem Regelungszyklus nur der erste Zeitschritt der Stellgrößen $\vec{u}_{opt}(k)$ berücksichtigt. Die folgenden Zeitschritte $[\vec{u}(k+1) \ \vec{u}(k+2) \ \dots \ \vec{u}(k+K_H)]$ in der Stellgrößenfolge $U = [\vec{u}(k) \ \vec{u}(k+1) \ \dots \ \vec{u}(k+K_H)]$ werden nicht berücksichtigt, da zu diesem Zeit-

punkt eine neue Stellgrößenfolge zur Verfügung steht. Von dieser wird wiederum nur der erste Zeitschritt angewendet.

3.1.2 Parallelen zu menschlichem Verhalten

Die Zielsetzung dieser Arbeit erfordert UAVs, die einzelne Aufgaben oder eine Mission mit einem ähnlichen Grad an Autonomie durchführen können, wie es ein Mensch kann. Auch wenn diese Regelung noch weit davon entfernt ist, die Intelligenz und den Grad an Autonomie eines Menschen abzubilden, so zeigt sie doch Parallelen zum menschlichen Verhalten auf.

Das oft verwendete Beispiel eines Kraftfahrzeugs, das durch eine enge Kurve fährt, veranschaulicht dies besonders gut. Ein Kraftfahrzeugfahrer hat in der Regel ein Gefühl, mit welcher Geschwindigkeit er durch eine Kurve fahren kann. Dieses Wissen kann als Modell betrachtet werden. Fährt nun dieser Kraftfahrzeugfahrer mit hoher Geschwindigkeit auf eine enge Kurve zu, so kann er mithilfe seiner Erfahrung (Modell) vorhersagen, dass er, wenn er die Geschwindigkeit nicht zuvor reduziert, Probleme haben wird, dem Kurvenverlauf zu folgen. Sein Wissen über das Kraftfahrzeug und die Kurve ermöglichen es ihm, eine Vorhersage (Prädiktion) für einen kurzen Zeitraum zu treffen. Aufgrund dieser Erfahrung, entscheidet er vor der Kurve, die Geschwindigkeit zu reduzieren.

Eine weitere, wenn auch unwahrscheinliche Lösung könnte die Wahl einer anderen Trajektorie sein. In diesem Fall würde der Kraftfahrzeugfahrer nicht der Kurve folgen, sondern geradeaus oder eine Kurve mit einem größeren Radius fahren, sofern sich dort keine Hindernisse befinden. In der Realität ist dieser Fall sehr selten möglich, aber nicht ausgeschlossen. Durch die Wahl eines globalen Optimierungsverfahrens werden auch Lösungen berücksichtigt, die nicht offensichtlich erscheinen, aber eine bessere Lösung darstellen, als das Geradeausfahren. Bei der Verwendung eines auf Evolution basierenden Optimierers entsteht eine Art Gedächtnis (Quasi-Gedächtnis). Dieses ermöglicht es, wie beim Menschen, auf Lösungen zurückzugreifen, die zuvor bei ähnlichen Problemstellungen erfolgreich waren.

Zusammengefasst beinhaltet die Regelung folgende Komponenten, die zumindest teilweise vergleichbar mit menschlichen Verhalten sind:

- Modell \implies Vorstellungsvermögen
- Prädiktives Verhalten \implies Vorausschauendes Verhalten
- Quasi-Gedächtnis \implies Gedächtnis / Erfahrungsschatz

3.2 Aufbau der Schwarmregelung

Die Regelung besteht, wie in Abbildung 3.4 dargestellt, aus den künstlichen Potenzialfeldern, dem Optimierer und dem Modell für die Prädiktion.

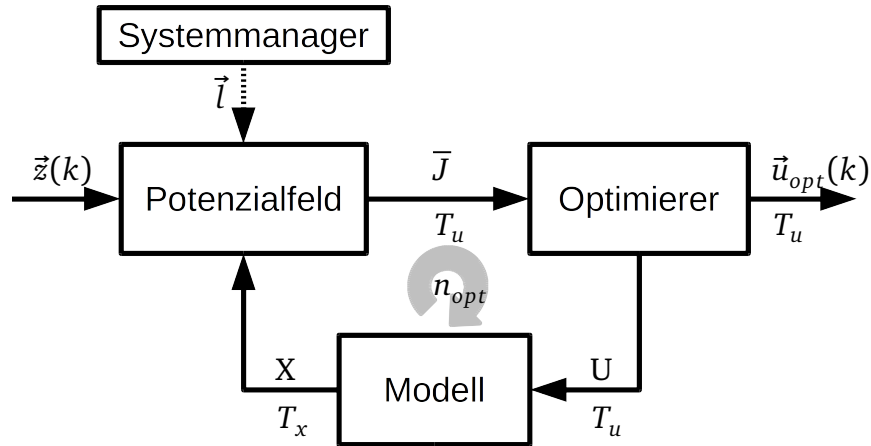


Abbildung 3.4: Aufbau des Reglers

In der hier implementierten Simulation ist die Anzahl der Durchläufe n_{opt} für die Optimierung während der Simulationszeit konstant. Es wäre jedoch auch möglich zu optimieren, bis entweder das globale Optimum gefunden oder eine neue Lösung der Regelung als Eingang für die Strecke notwendig wird. In dieser Arbeit wird die Update Rate der Stellgröße $\vec{u}_{opt}(k)$ mit 1s gewählt. Höhere Update-Raten bzw. kürzere Zeitschritte sind hier nicht notwendig, da die Zeitkonstante des stabilisierten Systems dieselbe Größenordnung hat. Aus jeder Stellgrößenfolge U wird mithilfe des Modells eine Folge von Zuständen X ermittelt. Diese nutzt das Potenzialfeld zusammen mit Messwerten \vec{z} und Schätzungen, um ein Potenzial oder Gütewert \bar{J} zu bestimmen. Dieser Gütewert dient dem Optimierer als Bewertung der zuvor bestimmten Stellgrößenfolge und ermöglicht es ihm, die optimale Stellgrößenfolge zum jeweiligen Zeitpunkt zu ermitteln. Das Ziel der Regelung bestimmt der Systemmanager mit den Gewichtungen von \vec{l} .

3.2.1 Modell der UAVs

Die Bewegung der einzelnen UAVs wird durch ein basisstabilisiertes flugmechanisches Modell simuliert. Es handelt sich hierbei um ein vereinfachtes Modell eines Flächenflugzeuges in Drachenkonfiguration. Die Seiten- und Längsbewegungen werden hierbei entkoppelt betrachtet. Als Eingang \vec{u} wird der Steuervektor (3.1) mit dem Soll-Rollwinkel ϕ_c , der spezifische Soll-Schub des Antriebs a_c^* und der Soll-Flugbahnwinkel γ_c verwendet.

$$\vec{u} = [\phi_c \quad a_c^* \quad \gamma_c]^T \quad (3.1)$$

Seitenbewegung

Bei der Seitenbewegung wird ein schiefbefreier ($\beta = 0$) Flug ohne Windeinfluss betrachtet. Weiter wird angenommen, dass sich das UAV im Horizontalflug befindet (Flugbahnwinkel $\gamma = 0$ und dessen Ableitung $\dot{\gamma} = 0$). Die Gleichungen (3.2) bis (3.4) beschreiben die Seitenbewegung basierend auf der Fluggeschwindigkeit V und dem Azimuthwinkel ψ [Kli07]. Die Änderung des Azimuthwinkels kann bei einem koordinierten Flug aus der Erdbeschleunigung g , der Fluggeschwindigkeit V und dem Rollwinkel ϕ bestimmt werden (3.4). Die Koordinaten x, y und z sind im *NED*-Koordinatensystem (*North, East, Down*) dargestellt. Der Ursprung des lokalen Koordinatensystems befindet sich am Startpunkt des UAVs.

$$\dot{x} = V \cos(\psi) \quad (3.2)$$

$$\dot{y} = V \sin(\psi) \quad (3.3)$$

$$\dot{\psi} = \frac{g}{V} \tan(\phi) \quad (3.4)$$

Die Übertragungsfunktion des kommandierten Rollwinkels ϕ_c auf den Rollwinkel ϕ wird in der Gleichung (3.5) mit einem PT_1 Übertragungsverhalten mit der Zeitkonstante T_ϕ angenähert. Der maximale Rollwinkel wird auf $\pm\phi_{max}$ beschränkt (3.5).

$$\dot{\phi} = \frac{\phi_c - \phi}{T_\phi} \quad -\phi_{max} \leq \phi_c \leq \phi_{max} \quad (3.5)$$

Längsbewegung

Bei der Längsbewegung wird angenommen, dass sich das UAV schiefbefrei und nicht im Kurvenflug befindet ($\beta = \phi = \dot{\phi} = \dot{\psi} = 0$). Weiter wird der Windeinfluss vernachlässigt. Die Gleichung 3.6 beschreibt die Längsbewegung (Längsbeschleunigung \dot{V}) eines Flächenflugzeuges im Geradeausflug in Abhängigkeit des Schub F , des Luftwiderstandes W , des Flugbahnwinkels γ , der Masse des Flugzeuges m und der Erdbeschleunigung g [BAL11].

$$\dot{V} = \frac{F}{m} - \frac{W}{m} - g \sin(\gamma) \quad (3.6)$$

Als Stellgrößen für die Längsbewegung werden der spezifische Schub a_c^* und der Flugbahnwinkel γ_c verwendet. Der spezifische Schub a_c^* wird hier definiert als Verhältnis aus dem Schub F und der Masse des Flugzeuges m (3.7).

$$a^* = \frac{F}{m} \quad (3.7)$$

Der Zusammenhang zwischen den beiden kommandierten Größen und den Ist-Werten der Größen wird mithilfe eines PT_1 -Verhaltens in Gleichung (3.11) und (3.8) angenähert. Wobei T_{a^*} die Zeitkonstante für das Übertragungsverhalten des gewünschten spezifischen Schub a_c^* auf den spezifischen Schub a^* ist (3.7).

$$\dot{a}^* = \frac{a_c^* - a^*}{T_{a^*}} \quad (3.8)$$

Die Verwendung des spezifischen Schubs ermöglicht eine allgemeine Betrachtung. Die obere Grenze für den spezifischen Schub wird so gewählt, dass dieser dem Doppelte des Schubs $C_w V_0^2$ entspricht, der nötig ist, um im Horizontalflug die Auslegungsgeschwindigkeit V_0 zu fliegen. Dies entspricht einer Maximalgeschwindigkeit im Horizontalflug von $\sqrt{2}V_0$.

$$0 \leq a_c^* \leq 2C_w V_0^2 \quad (3.9)$$

Der spezifische Widerstand W/m wird hier als proportional zum Quadrat der Fluggeschwindigkeit $C_w V^2$ approximiert. Wobei es sich bei $C_w = \frac{1}{2} \frac{\rho S c_w}{m}$ um einen erweiterten Widerstandsbeiwert handelt, welcher alle Faktoren zur Berechnung des Luftwiderstands zusammenfasst, die in diesem Fall als konstant angenommen werden. Die Änderung der Fluggeschwindigkeit wird durch den Spezifischen Schub a^* , den Widerstand $C_w V^2$ und die Komponente der Erdbeschleunigung in Flugrichtung $g \sin(\gamma)$ bestimmt.

$$\dot{V} = a^* - C_w V^2 - g \sin(\gamma) \quad (3.10)$$

T_γ ist die Zeitkonstante für das Übertragungsverhalten des Soll-Flugbahnwinkels γ_c auf den Flugbahnwinkel γ (3.11).

$$\dot{\gamma} = \frac{\gamma_c - \gamma}{T_\gamma} \quad (3.11)$$

Die Vertikalgeschwindigkeit \dot{z} lässt sich aus der Fluggeschwindigkeit V und dem Flugbahnwinkel γ bestimmen.

$$\dot{z} = -V \sin(\gamma) \quad (3.12)$$

Soll bei maximalen spezifischem Schub $2C_w V_0^2$ die Auslegungsgeschwindigkeit noch gehalten werden, so darf der Flugbahnwinkel γ_{max} nicht überschreiten:

$$\dot{V} = 0 = 2C_w V_0^2 - C_w V^2 - g \sin(\gamma_{max}) \quad (3.13)$$

$$\gamma_{max} = \sin^{-1} \frac{C_w V_0^2}{g} \quad (3.14)$$

Der minimale Flugbahnwinkel wird betragsmäßig gleich dem maximalen Flugbahnwinkel gesetzt (3.15) (3.16). Dies entspricht einer Maximalgeschwindigkeit im Gleitflug von V_0 .

$$\gamma_{min} = -\gamma_{max} \quad (3.15)$$

$$\gamma_{min} \leq \gamma_c \leq \gamma_{max} \quad (3.16)$$

Wird die Mindestgeschwindigkeit V_{min} unterschritten, so wird durch Verringern des Flugbahnwinkels γ die Fluggeschwindigkeit über der Mindestgeschwindigkeit gehalten, auch wenn der spezifische Schub reduziert wird. Beim Überschreiten der maximal zulässigen Fluggeschwindigkeit $V_{max} = V_{NE}$ wird der Flugbahnwinkel γ erhöht, damit die Fluggeschwindigkeit nicht weiter zunimmt (3.17).

$$V_{min} \leq V \leq V_{max} \quad (3.17)$$

Die Flugmechanik zusammengefasst

Zusammengefasst ergibt sich für die Seitenbewegung in der Form $\dot{x} = f(x, u)$:

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\psi} \\ \dot{\phi} \end{bmatrix} = \begin{bmatrix} V \cos(\psi) \\ V \sin(\psi) \\ \frac{g}{V} \tan(\phi) \\ \frac{\phi_c - \phi}{T_\phi} \end{bmatrix} \quad (3.18)$$

Mit der Beschränkung:

$$-\phi_{max} \leq \phi_c \leq \phi_{max} \quad (3.19)$$

Für die Längsbewegung ergibt sich:

$$\begin{bmatrix} \dot{V} \\ \dot{z} \\ \dot{a}^* \\ \dot{\gamma} \end{bmatrix} = \begin{bmatrix} a^* - C_w V^2 - g \sin(\gamma) \\ -V \sin(\gamma) \\ \frac{a_c^* - a^*}{T_{a^*}} \\ \frac{\gamma_c - \gamma}{T_\gamma} \end{bmatrix} \quad (3.20)$$

Mit den Beschränkungen:

$$-\sin^{-1} C_w V_0^2 \leq \gamma_c \leq \sin^{-1} C_w V_0^2 \quad 0 \leq F_c \leq 2C_w V_0^2 \quad V_{min} \leq V \leq V_{max} \quad (3.21)$$

3.2.2 Prädiktion

Die Prädiktion besteht aus der Berechnung der Flugmechanik mittels der Stellgrößenfolge. Wünschenswert ist eine sehr lange Prädiktion (Prädiktionshorizont), da dadurch die Vorteile der modellprädiktiven Regelung genutzt werden können und ein Vermeiden von größeren lokalen Minima möglich ist. Allerdings steigt mit der Länge des Prädiktionshorizontes exponentiell der dafür nötige Rechenaufwand (Gleichung 2.15 in Unterkapitel 2.3.2). Darüber hinaus sollten die Reichweiten der Sensoren und die Extrapolation der Schätzer auch den Bereich, den das UAV während dieses Prädiktionshorizonts zurücklegt, abdecken. Die Länge des Prädiktionshorizonts ist ein Kompromiss zwischen Maximierung der Effekte durch die Prädiktion und der zur Verfügung stehenden Rechenleistung unter Berücksichtigung der Sensorreichweite. Ein Kompromiss ist ein Prädiktionshorizont von 10s bei einer Diskretisierung der Zeitschritte der Stellgrößenfolge von $T_u = 1s$. Dies bedeutet, die Länge der Stellgrößenfolge ist $n_k = 10$. Für die zeitliche Diskretisierung der Stellgrößenfolge T_u wird 1s gewählt, da eine gröbere zeitliche Diskretisierung die Wendigkeit des UAVs nicht ausnutzen würde. Eine feinere Diskretisierung bietet keine Vorteile aufgrund der beschränkten Wendigkeit des UAVs. Ohne eine Verkürzung des Prädiktionshorizont würde bei einer feineren Diskretisierung der Rechenaufwand steigen (Abbildung 3.5).




Abbildung 3.5: Verlauf der Prädiktion.

Für die Berechnung aller Zustände wird die Abtastzeit $T_x = 0.01s$ verwendet. Dies ist ungefähr Faktor 100 kleiner als die kleinste Zeitkonstante der Flugmechanik des UAVs und damit quasi kontinuierlich. Dies entspricht bei einem Prädiktionshorizont von 10s 1000 Werten pro Zustand. Für jeden Zustandswert wird ein Potenzial berechnet. Jede einzelne Potenzialfolge $\vec{\Phi}_{xxx}$ besteht aus 1000 Werten. Aus diesen Reihen wird mithilfe von Gewichtungen ein Gütewert \bar{J} für die Optimierung berechnet (Abbildung 3.4).

3.2.3 Potenzialfeld / Gütefunktional

Wie zuvor beschrieben, ist es die Aufgabe des Potenzialfeldes, die Mission mit ihren Nebenbedingungen zu definieren. Das Potenzialfeld besteht aus mehreren Potenzialen, welche die unterschiedlichen Aufgaben und Nebenbedingungen definieren. In dieser Arbeit werden 7 verschiedene Einzelpotenziale implementiert. Es können jedoch weitaus mehr Potenziale implementiert werden. Zur Demonstration und simulationstechnischen Untersuchung sind jedoch die hier implementierten Einzelpotenziale ausreichend, da sie alle nötigen Potenziale für die in dieser Arbeit untersuchten Szenarien besitzen. Die implementierten Einzelpotenziale sind im Folgenden aufgelistet und werden im anschließenden Teilkapiteln näher betrachtet:

- 1 obs - Potenzial zur Vermeidung einer Kollision mit Hindernissen
- 2 avo - Potenzial zur Vermeidung der Kollision mit anderen UAVs
- 3 hig - Potenzial, um die Flughöhe vorzugeben
- 4 for - Potenzial, um eine Formation zu definieren
- 5 pol - Potenzial, um eine Schadstoffwolke zu lokalisieren und zu vermessen
- 6 way - Potenzial, um Wegpunkte abzufliegen
- 7 4dt - Potenzial, um eine 4D-Trajektorie zu definieren

Jedem einzelnen Potenzial wird eine Nummer n und zur besseren Übersicht ein Kürzel $xxx \in \{\text{obs}, \text{avo}, \text{hig}, \text{for}, \text{pol}, \text{way}, \text{4dt}\}$ zugewiesen. Für die Gesamtheit der Einzelpotenziale wird das generische Kürzel xxx verwendet.

Der Optimierer benötigt einen Skalar \bar{J} , um die generierte Stellgrößenfolge U zu bewerten und zu optimieren. Dieser Wert beschreibt die Güte dieser Steuervektorfolge U . Um aus den einzelnen Potenzialfeldern einen einzelnen Gütewert \bar{J} zu erhalten, werden, wie in Abbildung 3.6 gezeigt, unter Verwendung der einzelnen Potenzialfelder die entsprechenden Potenzialfolgen $\vec{\Phi}_{xxx}$ berechnet.

Aus diesen Potenzialfolgen werden die Maximalwerte (max), Mittelwerte (mid), Minimalwerte (min) und die Endwerte (end) bestimmt (3.25). Grund hierfür ist, dass je nach Aufgabe des Potentials andere Werte als der Mittelwert, notwendig sind. Im Regelfall wird der Mittelwert bzw. äquivalent dazu die Aufsummierung der Potenzialfolgen verwendet. Allerdings ist wie im Beispiel der Kollisionsvermeidung mit Hindernissen auch der Maximalwert der Potenzialfolge in Folge eines minimalen Abstandes zu einem Hindernis entscheidend.

Alle Potenziale in dieser Arbeit sind so gestaltet, dass Fälle die unter allen Umständen vermieden werden sollen, einen unendlichen Potenzialwert erzeugen. Dem Systemmanager

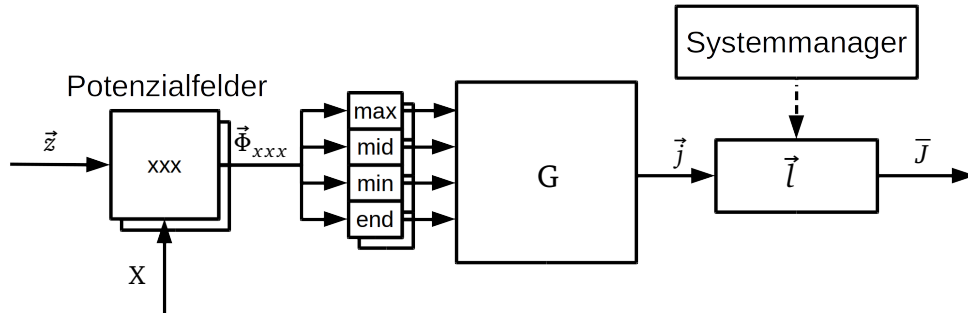


Abbildung 3.6: Grafische Darstellung der Bestimmung des akkumulierten Potentials / Gütewerts

wird durch die Wahl der Gewichtungen G die Möglichkeit gegeben, diese frei zu variieren. Diese Gewichtungen sind so gewählt, dass die Summe der einzelnen Komponenten den Wert 1 ergibt. Dies ermöglicht ein anteiliges Bewerten der einzelnen Komponenten ohne die Skalierung der Potentiale zu beeinflussen. So ergibt sich die Gewichtungsmatrix:

$$G = \begin{bmatrix} \vec{g}_{obs} \\ \vec{g}_{avo} \\ \vec{g}_{hig} \\ \vec{g}_{for} \\ \vec{g}_{pol} \\ \vec{g}_{way} \\ \vec{g}_{4dt} \end{bmatrix} = \begin{bmatrix} g_{obs_{max}} & g_{obs_{mid}} & g_{obs_{min}} & g_{obs_{end}} \\ g_{avo_{max}} & g_{avo_{mid}} & g_{avo_{min}} & g_{avo_{end}} \\ g_{hig_{max}} & g_{hig_{mid}} & g_{hig_{min}} & g_{hig_{end}} \\ g_{for_{max}} & g_{for_{mid}} & g_{for_{min}} & g_{for_{end}} \\ g_{pol_{max}} & g_{pol_{mid}} & g_{pol_{min}} & g_{pol_{end}} \\ g_{way_{max}} & g_{way_{mid}} & g_{way_{min}} & g_{way_{end}} \\ g_{4dt_{max}} & g_{4dt_{mid}} & g_{4dt_{min}} & g_{4dt_{end}} \end{bmatrix} \quad (3.22)$$

Wobei die Summe der Reihen der Gewichtungsmatrix den Wert 1 besitzen:

$$\vec{g}_{xxx} = [g_{xxx_{max}} \quad g_{xxx_{mid}} \quad g_{xxx_{min}} \quad g_{xxx_{end}}] \quad (3.23)$$

$$|\vec{g}_{xxx}| = 1 \quad (3.24)$$

Aus der Gewichtungsmatrix G und den Maximal- ($max(\vec{\Phi}_{xxx})$), Mittel- ($mid(\vec{\Phi}_{xxx})$), Minimal- ($min(\vec{\Phi}_{xxx})$) und Endwerten ($end(\vec{\Phi}_{xxx})$) der einzelnen Potentiale wird der Gütevektor \vec{j} der Trajektorie berechnet:

$$\vec{j} = G \circ \begin{bmatrix} max(\vec{\Phi}_{obs}) & mid(\vec{\Phi}_{obs}) & min(\vec{\Phi}_{obs}) & end(\vec{\Phi}_{obs}) \\ max(\vec{\Phi}_{avo}) & mid(\vec{\Phi}_{avo}) & min(\vec{\Phi}_{avo}) & end(\vec{\Phi}_{avo}) \\ max(\vec{\Phi}_{hig}) & mid(\vec{\Phi}_{hig}) & min(\vec{\Phi}_{hig}) & end(\vec{\Phi}_{hig}) \\ max(\vec{\Phi}_{for}) & mid(\vec{\Phi}_{for}) & min(\vec{\Phi}_{for}) & end(\vec{\Phi}_{for}) \\ max(\vec{\Phi}_{pol}) & mid(\vec{\Phi}_{pol}) & min(\vec{\Phi}_{pol}) & end(\vec{\Phi}_{pol}) \\ max(\vec{\Phi}_{way}) & mid(\vec{\Phi}_{way}) & min(\vec{\Phi}_{way}) & end(\vec{\Phi}_{ways}) \\ max(\vec{\Phi}_{4dt}) & mid(\vec{\Phi}_{4dt}) & min(\vec{\Phi}_{4dt}) & end(\vec{\Phi}_{4dt}) \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \quad (3.25)$$

Die Wahl der Gewichtungen wird im Folgenden beschrieben. Diese werden anhand der nachfolgenden Überlegungen definiert und nicht weiter verändert (Tabelle 3.1).

Beim Potenzial zur Vermeidung einer Kollision mit Hindernissen (obs) ist nicht zwingend der Mittelwert des Potenzials entscheidend. Viel mehr ist hier der Maximalwert innerhalb des Prädiktionshorizonts entscheidend, da dieser einen minimalen Abstand zu einem Hindernis darstellt. Wird ausschließlich der Mittelwert zur Bewertung der Trajektorie genutzt, so hat der minimale Abstand nur indirekt Einfluss auf die Bewertung der Trajektorie. In Abbildung 3.7 ist solch ein Beispiel dargestellt. In diesem besitzen die beiden Trajektorien der UAVs den selben Mittelwert, aber der minimale Abstand unterscheidet sich deutlich. Im oberen Bereich sind die Trajektorien der UAVs in der Draufsicht dargestellt. Darunter befindet sich der resultierende zeitliche Verlauf des Potenzial Φ_{obs} der jeweiligen Trajektorie bis hin zum Prädiktionshorizont.

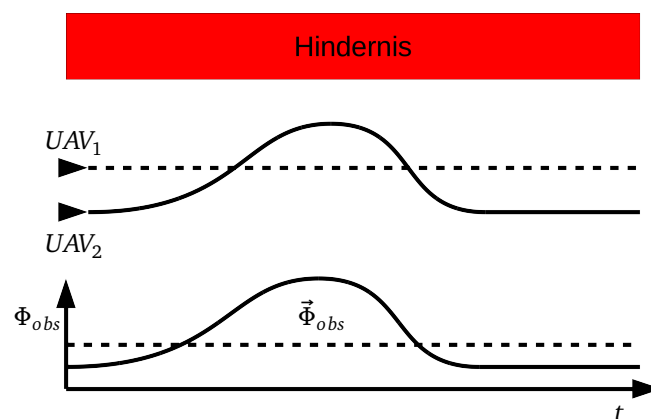


Abbildung 3.7: Beispiel zweier UAVs mit unterschiedlichen Trajektorien aber gleichem Mittelwert des Potenzials zur Vermeidung von Zusammenstößen mit Hindernissen ($\vec{\Phi}_{\text{obs}}$)

Zur Definition der exakten Werte der Gewichtung des Mittel- und Maximalwerts existieren keine Regeln, deshalb werden diese basierend auf Erfahrungswerten festgelegt (Tabelle 3.1). Die Verteilung der Werte ist hierbei jedoch unkritisch, da durch die Gestalt der Potenziale ein Mindestabstand garantiert wird, sofern der Mittelwert bei der Bewertung berücksichtigt wird.

Äquivalent dazu erfolgt auch die Parametrierung des Potenzials zur Vermeidung der Kollision mit anderen UAVs. Da durch die Prädiktion die örtliche Veränderung der Hindernisse berücksichtigt werden, kann dies äquivalent zum statischen Fall parametriert werden (Tabelle 3.1).

Aus den zuvor genannten Gründen wird auch bei dem Potenzial für die Höhe Anteile bei der Gewichtung des Maximal- und Mittelwerts gewählt. In diesem Fall wird jedoch

auch der Endwert berücksichtigt, da die Änderung der Höhe im Vergleich zur Länge des Prädiktionshorizonts vergleichsweise gering ist. Abhängig von der Flugleistung des UAVs und der Länge des Prädiktionshorizonts kann diese variieren. In dieser Arbeit wird angenommen, dass es sich bei den UAVs um kleine und relativ langsam fliegende UAVs handelt, deren maximales Steigvermögen innerhalb des hier verwendeten Prädiktionshorizonts gering ist. Die Berücksichtigung des Endwertes von $\vec{\Phi}_{hig}$ bewirkt, dass bei einer zu geringen Höhe ein kontinuierlicher Steigflug erreicht wird. Die exakten Werte werden basierend auf Erfahrungen festgelegt. Sie verbessern die Leistung der Regelung, jedoch ist die exakte Wahl dieser Werte unkritisch (Tabelle 3.1).

Bei den anderen Potenzialen (for, pof, way, 4dt) handelt es sich um anwendungsspezifische Potenziale. Die Gewichtungen werden zunächst auf den Mittelwert beschränkt. Diese können jedoch nach Bedarf angepasst werden (Tabelle 3.1).

Tabelle 3.1: Wahl der Parameter für G

	obs	avo	hig	for	pol	way	4dt
max	0.8	0.8	0.3	0.0	0.0	0.0	0.0
mid	0.2	0.2	0.3	1.0	1.0	1.0	1.0
min	0.0	0.0	0.0	0.0	0.0	0.0	0.0
end	0.0	0.0	0.4	0.0	0.0	0.0	0.0

Aus der Summe der Gewichtungen ergibt sich ein einzelner Wert j_{xxx} für jedes Potenzial (Abbildung 3.6). Diese können zu einem Vektor \vec{j} zusammengefasst werden 3.26. Da jedes Potenzial einer Aufgabe oder Nebenbedingung entspricht, können diese mit einer weiteren Gewichtung \vec{l} zueinander gewichtet werden 3.27. Abhängig von der Mission kann der Systemmanager damit die Wichtigkeit der einzelnen Aufgaben und Nebenbedingungen zueinander festlegen bzw. einzelne Aufgaben oder Randbedingungen nach Bedarf ein- oder ausschalten. Ausschließlich durch die Wahl von \vec{l} definiert der Systemmanager die Art der Mission.

$$\vec{j} = [j_{obs} \quad j_{avo} \quad j_{hig} \quad j_{for} \quad j_{pol} \quad j_{way} \quad j_{4dt}]^T \quad (3.26)$$

$$\vec{l} = [l_{obs} \quad l_{avo} \quad l_{hig} \quad l_{for} \quad l_{pol} \quad l_{way} \quad l_{4dt}] \quad (3.27)$$

Durch die Gewichtung des Gütevektors \vec{j} mit dem Missionsvektor \vec{l} und anschließender Aufsummierung wird ein einzelnes akkumuliertes Potenzial \bar{J} gebildet:

$$\bar{J} = \vec{l}\vec{j} \quad (3.28)$$

Dies ist eine Funktion der Stellgröße U und ermöglicht eine Bewertung dieser zur Optimierung:

$$\bar{J} = f(U) \quad (3.29)$$

Das Ziel der Optimierung ist die Minimierung des akkumulierten Potentials \bar{J} . Dies entspricht einer Minimierung der einzelnen Potentiale. Es wäre ebenso eine Maximierung der Optimierung bei entsprechenden angepassten Potentialen denkbar. Die Minimierung wird verwendet, da sie dem physikalischen Bestreben der Minimierung der potenziellen Energie in einem Schwerfeld entspricht.

Im Folgenden werden die einzelnen Potentiale erläutert.

Potenzial zur Vermeidung einer Kollision mit Hindernissen/UAVs (obs/avo)

Gleichung 3.30 und Abbildung 3.8 zeigen ein Potenzial, um einen Zusammenstoß mit Hindernissen (obs) und anderen Luftfahrzeugen (avo) zu vermeiden. Die Potentiale Φ_{obs} und Φ_{avo} sind definiert über den minimalen Schrägabstand zum Hindernis (d_{obs}) bzw. zum nächsten UAV (d_{avo}).

Um den Mindestabstand $d_{xxx,c0}$ sicherzustellen, wird beim Unterschreiten der Funktionswert (Potential) Φ_{xxx} zu Unendlich. Wobei es sich bei $d_{obs,c0}$, um den gewünschten Mindestabstand zum nächsten Hindernis, und äquivalent bei $d_{avo,c0}$, um den gewünschten Mindestabstand zum nächsten UAV, handelt.

$$\Phi_{xxx} = \begin{cases} \infty & \text{wenn } d_{xxx} < d_{xxx,c0} \\ \frac{\Phi_{xxx,c0}}{d_{xxx,c0} - d_{xxx,c1}} d_{xxx} + \frac{d_{xxx,c1} \Phi_{xxx,c0}}{d_{xxx,c1} - d_{xxx,c0}} & \text{wenn } d_{xxx,c0} \leq d_{xxx} < d_{xxx,c1} \\ 0 & \text{wenn } d_{xxx} \geq d_{xxx,c1} \end{cases} \quad (3.30)$$

Die Abbildung 3.8 bildet folgende Eigenschaften ab (3.30):

- Annäherung an Hindernis darf nie weniger als $d_{obs,c0}$ betragen
- Wenn möglich Einhaltung eines Abstands von $d_{obs,c1}$ oder mehr
- Ein Abstand von über $d_{obs,c1}$ hat keinen Einfluss auf die Wahl der Stellgrößen

Zur Vermeidung von anderen UAVs (avo) wird dieselbe Art Potenzial wie für feste Hindernisse (obs) verwendet. Üblicherweise wäre zu erwarten, dass hierbei die Richtung und die Fluggeschwindigkeit zu berücksichtigen sind. Eine Ausweitung des Mindestabstands in Flugrichtung, wie bei [Bar10], wäre die Konsequenz. Dies ist durch die Prädiktion nicht notwendig, da sie die Bewegungen des anderen und des eigenen UAVs berücksichtigt und innerhalb eines diskreten Zeitschrittes $T_x = 0.01s$ die Bewegung vernachlässigbar ist.

Die Parametrierung dieser Potentiale muss entsprechend der Größe der UAVs, der Genauigkeit der Positionsbestimmung der UAVs, der Genauigkeit der Positionsbestimmung




Abbildung 3.8: Potenzial Φ_{obs} in Abhängigkeit des Abstands d_{obs} zu Hindernissen

der Hindernisse sowie deren Prädiktionen geeignet gewählt werden. In dieser Arbeit werden für alle Versuche folgende Parameter der Potentiale verwendet.

Tabelle 3.2: Wahl der Parameter des Potentials zur Vermeidung von Kollisionen

Hindernisse (obs)	Andere UAVs (avo)
$\Phi_{obs,c0} = 10^5$	$\Phi_{avo,c0} = 10^5$
$d_{obs,c0} = 5m$	$d_{avo,c0} = 5m$
$d_{obs,c1} = 30m$	$d_{avo,c1} = 30m$

Diese Werte basieren auf der Verwendung von kleinen UAVs deren Position relativ zueinander genauer als 5m bekannt ist. Es wird angenommen, dass die Störung durch den Randwirbel eines anderen UAVs gering ist. Somit wird, im Gegensatz zur bemannten Luftfahrt, kein zusätzlicher Sicherheitsabstand benötigt.

Potenzial zur Vorgabe einer Flughöhe (hig)

Die Abbildung 3.9 zeigt ein Beispiel für das Potenzial, das die UAVs zwingt, in einer Höhe zwischen $d_{hig,c0}$ und $d_{hig,c6}$ zu fliegen, wobei eine Höhe von $d_{hig,c3}$ bevorzugt wird. d_{hig} entspricht der Flughöhe $|pos_z|$.




Abbildung 3.9: Potenzial Φ_{hig} in Abhängigkeit der Höhe d_{hig}

$$\Phi_{hig} = \begin{cases} \infty & \text{wenn } d_{hig} < d_{hig,c0} \\ \frac{\Phi_{hig,c1} - \Phi_{hig,c0}}{d_{hig,c1} - d_{hig,c0}} d_{hig} + \frac{d_{hig,c1} \Phi_{hig,c0} - d_{hig,c0} \Phi_{hig,c1}}{d_{hig,c1} - d_{hig,c0}} & \text{wenn } d_{hig,c0} \leq d_{hig} < d_{hig,c1} \\ \vdots & \vdots \\ \frac{\Phi_{hig,c6} - \Phi_{hig,c5}}{d_{hig,c6} - d_{hig,c5}} d_{hig} + \frac{d_{hig,c6} \Phi_{hig,c5} - d_{hig,c5} \Phi_{hig,c6}}{d_{hig,c6} - d_{hig,c5}} & \text{wenn } d_{hig,c5} \leq d_{hig} < d_{hig,c6} \\ \infty & \text{wenn } d_{hig,c6} \leq d_{hig} \end{cases} \quad (3.31)$$

Äquivalent zu (3.31) können alle Potentiale, die auf einer Größe basieren, beliebig definiert werden.

Potenzial zur Definition einer Formation (for)

Bei einer Formation soll jedes UAV eine Position relativ zu den anderen UAVs halten. Als Beispiel für eine starre Formation (bestimmte Formation) können 3 UAVs angesehen werden, die in einer Ebene einen definierten Abstand zueinander halten sollen.

Das Ziel der Formation ist somit ein gleichseitiges Dreieck mit der Seitenlänge d_c zu erreichen und zu halten. Das Potenzial hierfür ist definiert als:

$$pos_{x,y} = \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.32)$$

$$d_{ij} = \sqrt{(pos_i - pos_j)^T (pos_i - pos_j)} \quad (3.33)$$

Nummer des UAVs i , für welches das Potenzial berechnet werden soll:

$$i \in 1, \dots, n \quad (3.34)$$

Nummer der anderen UAVs j , zu denen der Abstand d_c gehalten werden soll:

$$j \in 1, \dots, n \cap j \neq i \quad (3.35)$$

Potenzial für das UAV i aus den Abständen zu den anderen UAVs für eine starre Formation:

$$\Phi_{i_{for}} = \alpha_{for} \sum |d_{ij} - d_c| \quad (3.36)$$

Ein Beispiel für eine flexible Formation (unterbestimmte Formation) besteht, wenn nur zu einem einzigen UAV ein Abstand d_c gehalten werden soll. In solch einem Fall kann das Potenzial für das UAV i definiert werden als:

$$\Phi_{i_{for}} = \alpha_{for} \max |d_{ij} - d_c| \quad (3.37)$$

Der Faktor α_{for} ist die triviale Abbildung von d_{for} auf Φ_{for} , welche einen linearen Zusammenhang darstellt.

Potenzial zur Lokalisierung und Vermessung einer Schadstoffwolke (pol)

Das Ziel ist hier, eine definierte Konzentration c_c des Schadstoffes sowie dessen Quelle zu finden. Im einfachsten Fall würde man den Betrag der Differenz zwischen gemessener bzw. geschätzter Konzentration \hat{c} und der Zielkonzentration als Potenzial $\Phi_{pol} \sim |\hat{c} - c_c|$ nutzen. Testreihen zeigen, dass es weitaus praktikabler ist, diesen Zusammenhang in einen geometrisch Vergleichbaren zu übersetzen. Dies ermöglicht es dem Systemmanager, die unterschiedlichen Potenziale wesentlich einfacher zueinander zu gewichten (Abbildung 3.10).

Basierend auf einem einfachen Ausbreitungsmodell für Gaswolken (siehe Kapitel 3.3.1) und den geschätzten Parametern $(\hat{a}_{pol}, \hat{c}_0)$ kann der Abstand d_c entsprechend der Zielkonzentration c_c zur Quelle bestimmt werden (3.38):

$$d_c = \frac{1}{\hat{a}_{pol}} \ln \frac{c_c}{\hat{c}_0} \quad (3.38)$$

Aus dem Abstand zur geschätzten Position der Quelle (3.39) und dem geschätzten Zielabstand (3.38) wird das Potenzial der Schadstoffwolken bestimmt (3.40). Dabei dient α_{pol} zur Skalierung des Potenzials und Anpassung der Einheiten. Da das verwendete Ausbreitungsmodell für Schadstoffe punktsymmetrisch um die Quelle verläuft, kann das Potenzial ausschließlich durch Betrachtung der Abstände berechnet werden.

$$\hat{d} = \sqrt{(pos_{UAV} - p\hat{os}_{pol})^T (pos_{UAV} - p\hat{os}_{pol})} \quad (3.39)$$

$$\Phi_{pol} = \alpha_{pol} |\hat{d} - d_c| \quad (3.40)$$




Abbildung 3.10: Abstände zur Quelle einer Schadstoffwolke. Dunkle Grautöne entsprechen einer hohen Konzentration an Schadstoff

Potenzial zum Abfliegen von Wegpunkten (way)

Für das Potenzial der Wegpunkte wird der minimale Abstand d_{way} der prädizierten Trajektorie zu allen Wegpunkten berechnet (3.41). Aus diesem minimalen Abstand zu jedem Wegpunkt wird mithilfe der Gleichung (3.44) ein Potenzial generiert. Dies hat ein Minimum, wenn ein oder mehrere Wegpunkte erreicht werden.

$$d_{way} = \sqrt{\min((\mathbb{I}_{UAV} pos_{x_{WP}}^T - pos_{x_{UAV}} \mathbb{I}_{WP}^T)^2 + (\mathbb{I}_{UAV} pos_{y_{WP}}^T - pos_{y_{UAV}} \mathbb{I}_{WP}^T)^2)} \quad (3.41)$$

$$\mathbb{I} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \quad (3.42)$$

Die Länge des Einheitsvektors \mathbb{I}_{WP} entspricht der Anzahl der aktiven Wegpunkte in der Liste. Die Länge von \mathbb{I}_{UAV} entspricht der Länge der Zustandsfolge der Prädiktion. Bei einem Prädiktionshorizont $T_H = 10s$ und einem Zeitschritt von $T_x = 0.01s$ würde sich damit eine Länge von 1000 ergeben.

Die Gleichung (3.43) zeigt zur besseren Veranschaulichung den Teil (3.41), welcher den Abstand in x-Richtung zu jedem Zeitpunkt innerhalb des Prädiktionshorizonts und zu jedem Wegpunkt berechnet.

$$\mathbb{I}_{UAV} pos_{x_{WP}}^T - pos_{x_{UAV}} \mathbb{I}_{WP}^T = \begin{bmatrix} pos_{x_{WP1}} & pos_{x_{WP2}} & \cdots \\ pos_{x_{WP1}} & pos_{x_{WP2}} & \cdots \\ \vdots & \vdots & \vdots \\ pos_{x_{WP1}} & pos_{x_{WP2}} & \cdots \end{bmatrix} - \begin{bmatrix} pos_{x_{UAV},t+0.01} & pos_{x_{UAV},t+0.01} & \cdots \\ pos_{x_{UAV},t+0.02} & pos_{x_{UAV},t+0.02} & \cdots \\ \vdots & \vdots & \vdots \\ pos_{x_{UAV},t+T_H} & pos_{x_{UAV},t+T_H} & \cdots \end{bmatrix} \quad (3.43)$$

Hierbei ist $pos_{x_{WP}}$ ein Vektor aus den Positionen der Wegpunkte und $pos_{x_{UAV}}$ ein Vektor aus den Positionen aller UAVs des Schwarms in x-Richtung. Dies erfolgt äquivalent für die y-Richtung. Aus diesen wird der minimale Abstand zu jedem Wegpunkt d_{way} ermittelt. Der Faktor α_{way} ist wiederum die triviale Abbildung von d_{way} auf Φ_{way} , welche einen linearen Zusammenhang darstellt.

$$\Phi_{way} = \alpha_{way} \sqrt{\min((\mathbb{I}^T pos_{x_{WP}} - pos_{x_{UAV}}^T \mathbb{I})^2 + (\mathbb{I}^T pos_{y_{WP}} - pos_{y_{UAV}}^T \mathbb{I})^2)} \quad (3.44)$$

Potenzial zur Definition einer 4D-Trajektorie (4dt)

Die Aufgabe dieses Potenzials ist es, ein UAV eine 4D-Trajektorie fliegen zu lassen. Dazu wird eine solche Trajektorie ausgehend von der initialen Position pos_0 durch Vorgabe der Geschwindigkeit V_c und Flugrichtung ψ_c definiert (3.45)-(3.47).

$$p\dot{os}_c = \begin{bmatrix} V_c \cos(\psi_c) \\ V_c \sin(\psi_c) \\ \dot{h}_c \end{bmatrix} \quad (3.45)$$

Durch Integration wird die jeweilige Sollposition pos_c für jeden Zeitpunkt der 4D-Trajektorie bestimmt:

$$pos_c = pos_0 + \int p\dot{os}_c dt \quad (3.46)$$

Die Sollposition ist somit ein zeitabhängiger Vektor:

$$pos_c = [x(t)_c \quad y(t)_c \quad z(t)_c]^T = f(t) \quad (3.47)$$

Das Potenzial Φ_{4dt} wird über eine Zwischengröße d_{4dt} bestimmt, die den Abstand zum 4D-Punkt zum jeweiligen Zeitpunkt definiert. Der Tensor G_{4dt} dient zur Gewichtung der einzelnen Abweichungen in den drei Freiheitsgraden. Dieser Tensor kann als Ellipsoid dargestellt werden. Im Fall $g_x = g_y = g_z$ ergibt sich eine Kugel, bei der Abweichungen in allen Freiheitsgraden gleich bewertet werden. Dies ist sinnvoll, wenn die Abweichung der gemessenen Höhe zur realen Höhe in etwa den Abweichungen in der horizontale entsprechen.

$$G_{4dt} = \begin{bmatrix} g_x & 0 & 0 \\ 0 & g_y & 0 \\ 0 & 0 & g_z \end{bmatrix} \quad (3.48)$$

$$d_{4dt} = \sqrt{(pos_{UAV} - pos_c)^T G_{4dt} (pos_{UAV} - pos_c)} \quad (3.49)$$

Der Faktor α_{4dt} ist wiederum die triviale Abbildung von d_{4dt} auf Φ_{4dt} , welche einen linearen Zusammenhang darstellt. Diese berücksichtigt die Zeit implizit und definiert die 4D-Trajektorie als wanderndes Potenzialfeld (Abbildung 3.11).

$$\Phi_{4dt} = \alpha_{4dt} d_{4dt} = \alpha_{4dt} \sqrt{(pos_{UAV} - pos_c)^T G_{4dt} (pos_{UAV} - pos_c)} \quad (3.50)$$




Abbildung 3.11: Visualisierung des wandernden Potentials einer 4D-Trajektorie. Dunkle Grautöne entsprechen einem niedrigen Potenzialwert

3.2.4 Optimierer

Ein entscheidender Baustein der MPC ist die Optimierung. In dieser Arbeit werden aus diesem Grund zum Vergleich mehrere Verfahren untersucht. Dazu werden folgende Optimierungs-Verfahren implementiert:

- Evolutionsstrategie (*ES1/ES3*)
- Genetischer Algorithmus (*GA1/GA3*)
- Gradientenabstieg (*GR1*)
- *Brute-Force* (*BF1*)

Neben den evolutionären Algorithmen wird ein gradientenbasiertes Verfahren implementiert, um den Vergleich zu einem lokalen Optimierungsverfahren zu ermöglichen. Weiter ist ein *Brute-Force*-Algorithmus implementiert, um den Vergleich mit dem bestmöglichen globalen Optimum zu ermöglichen. Beim Evolutionsstrategie-Algorithmus wird zwischen dem Optimierer unterschieden, der nur den Rollwinkel ϕ_c optimiert ohne die Höhe oder die Fluggeschwindigkeit zu beeinflussen (*ES1*), und demjenigen, der den Rollwinkel ϕ_c , den spezifischen Schub a_c^* als auch den Flugbahnwinkel γ_c (*ES3*) optimiert. Äquivalent ist die Namensgebung beim genetischen Algorithmus (*GA1/GA3*). Beim Gradientenabstieg (*GR1*) und *Brute-Force* (*BF1*) wird jeweils nur der Rollwinkel ϕ_c optimiert, da dies für einen Vergleich ausreichend ist. Somit wird der Rechenaufwand deutlich reduziert.

Evolutionstrategie

Die Population P des Evolutionstrategie Optimierungsalgorithmus besteht aus n_p Individuen. Diese Individuen sind die Stellgrößenvektorfolgen U aus dem Stellgrößenvektor \vec{u} (Gleichung 3.51 - 3.54).

$$\vec{u} = [\phi_c \quad a_c^* \quad \gamma_c]^T \quad (3.51)$$

$$U = [\vec{u}(k) \quad \vec{u}(k+1) \quad \cdots \vec{u}(k+K_H)] \quad (3.52)$$

$$P = \begin{bmatrix} U_{(1)} \\ U_{(2)} \\ \vdots \\ U_{(n_p)} \end{bmatrix} \quad (3.53)$$

$$P = \begin{bmatrix} \vec{u}_{(1)}(k) & \vec{u}_{(1)}(k+1) & \cdots \vec{u}_{(1)}(k+K_H) \\ \vec{u}_{(2)}(k) & \vec{u}_{(2)}(k+1) & \cdots \vec{u}_{(2)}(k+K_H) \\ \vdots & \vdots & \vdots \\ \vec{u}_{(n_p)}(k) & \vec{u}_{(n_p)}(k+1) & \cdots \vec{u}_{(n_p)}(k+K_H) \end{bmatrix} \quad (3.54)$$

Die Initialisierung der Population erfolgt mit Zufallswerten im Bereich von -1 bis 1 . Die Skalierung erfolgt mit den entsprechenden maximal zugelassenen Stellgrößen (ϕ_{max} , a_{max}^* oder γ_{max}). Im Falle der Stellgröße ϕ_c entspricht dies einem Soll-Rollwinkel von:

$$\phi_c = \{-1 \leq x \leq 1 | x \in \mathbb{R}\} \phi_{max} \quad (3.55)$$

Äquivalent gilt dies für die beiden anderen Stellgrößen.

$$a_c^* = \{0 \leq x \leq 1 | x \in \mathbb{R}\} a_{max}^* \quad (3.56)$$

$$\gamma_c = \{-1 \leq x \leq 1 | x \in \mathbb{R}\} \gamma_{max} \quad (3.57)$$

Mit Hilfe der Potenzialfelder wird die Güte \bar{J} jedes einzelnen Individuums bestimmt (3.58). Diese Individuen werden entsprechend der Güte neu geordnet, sodass die besten Stellgrößenfolgen die niedrigsten Indizes haben.

$$P = \begin{bmatrix} \vec{u}_{(1)}(k) & \vec{u}_{(1)}(k+1) & \cdots & \vec{u}_{(1)}(k+K_H) \\ \vec{u}_{(2)}(k) & \vec{u}_{(2)}(k+1) & \cdots & \vec{u}_{(2)}(k+K_H) \\ \vdots & \vdots & & \vdots \\ \vec{u}_{(n_p)}(k) & \vec{u}_{(n_p)}(k+1) & \cdots & \vec{u}_{(n_p)}(k+K_H) \end{bmatrix} \Rightarrow \begin{bmatrix} \bar{J}_{(1)} \\ \bar{J}_{(2)} \\ \vdots \\ \bar{J}_{(n_p)} \end{bmatrix} \quad (3.58)$$

Ausgehend von der Evaluation wird durch Modifikation (mod), Rekombination (rec) und Migration (imm) die darauf folgende Generation gebildet (3.59). Diese wird dann erneut mit den Potenzialfeldern bewertet und sortiert. Dieser Zyklus erfolgt n_{opt} mal. Das Ergebnis dieser Optimierung ist der Wert von $\vec{u}_{(1)}(k+1)$.

$$P(j+1) = \begin{bmatrix} P_{mod} \\ P_{rec} \\ P_{imm} \end{bmatrix} \quad (3.59)$$

P_{mod} besteht aus den ersten Individuen, die $n_{P_{mod}}$ mal kopiert werden. Diese werden zufällig mit zufälligen Werten zwischen -1 und 1 modifiziert. Die Parameter sind so gewählt, dass einige unveränderte Individuen existieren, aber dennoch ein Maximum an zufälliger Modifikation erfolgt.

P_{rec} besteht aus Einzelteilen der ersten $n_{P_{rec}}$ Individuen. Einzelne Teile dieser Individuen werden durch zufällige Wahl eines Teils eines anderen Individuums ersetzt. Der Start und das Ende dieses ersetzten Teils ist ebenfalls zufällig gewählt. Damit lässt sich erreichen, dass Teile von Individuen, die bereits gute Ergebnisse erreicht hatten, in Kombination mit anderen Individuen ein besseres Ergebnis erzielen können.

P_{imm} besteht aus $n_{P_{imm}}$ Individuen mit zufälligen Werten im Bereich von -1 bis 1 . Durch sie werden neue Kombinationen (Stellgrößenfolgen) in die Population eingebracht. Dies ermöglicht es neue, von vorherigen Individuen unabhängige Lösungen zu generieren.

Als Abbruchkriterium wird eine feste Anzahl von Iteration n_{opt} gewählt, da in einer realen Implementierung feste Zyklen eingehalten werden müssen. Ist eine Lösung ermittelt, so wird für den nächsten Zeitschritt k eine Lösung gesucht. Als Start hierfür könnte erneut eine zufällige Population gewählt werden. Diese würde jedoch nicht das Wissen der Optimierung im vorherigen Zeitschritt nutzen. Dieses Wissen wird durch die Vererbung genutzt (3.60) (3.61).

$$k \leftarrow k+1 \quad (3.60)$$

$$\begin{aligned}
& P(j+1) = \\
& \left[\begin{array}{ccc} \vec{u}_{(1)}(k) & \vec{u}_{(1)}(k+1) & \cdots \vec{u}_{(1)}(k+K_H-1) \\ \vec{u}_{(2)}(k) & \vec{u}_{(2)}(k+1) & \cdots \vec{u}_{(2)}(k+K_H-1) \\ \vdots & \vdots & \vdots \\ \vec{u}_{(n_p)}(k) & \vec{u}_{(n_p)}(k+1) & \cdots \vec{u}_{(n_p)}(k+K_H-1) \end{array} \right] \begin{array}{c} \left[\begin{array}{l} \{-1 \leq x \leq 1 | x \in \mathbb{R}\} \phi_{max} \\ \{0 \leq x \leq 1 | x \in \mathbb{R}\} a_{max}^* \\ \{-1 \leq x \leq 1 | x \in \mathbb{R}\} \gamma_{max} \end{array} \right] \\ \left[\begin{array}{l} \{-1 \leq x \leq 1 | x \in \mathbb{R}\} \phi_{max} \\ \{0 \leq x \leq 1 | x \in \mathbb{R}\} a_{max}^* \\ \{-1 \leq x \leq 1 | x \in \mathbb{R}\} \gamma_{max} \end{array} \right] \\ \vdots \\ \left[\begin{array}{l} \{-1 \leq x \leq 1 | x \in \mathbb{R}\} \phi_{max} \\ \{0 \leq x \leq 1 | x \in \mathbb{R}\} a_{max}^* \\ \{-1 \leq x \leq 1 | x \in \mathbb{R}\} \gamma_{max} \end{array} \right] \end{array} \quad (3.61)
\end{aligned}$$

Genetischer Algorithmus

Im Unterschied zur Evolutionsstrategie ist beim genetischen Algorithmus der Wertebereich diskret [Wei09]. Alle Stellgrößen sind mit 5 Werten diskretisiert (Gleichung 3.62-3.64). Diese ermöglicht eine weitere Unterteilung zwischen den beiden Maximalwerten und dem Nullpunkt.

$$\phi_c = \{x | x \in \{-1, -0.5, 0, 0.5, 1\}\} \phi_{max} \quad (3.62)$$

$$a_c^* = \{x | x \in \{0, 0.25, 0.5, 0.75, 1\}\} a_{max}^* \quad (3.63)$$

$$\gamma_c = \{x | x \in \{-1, -0.5, 0, 0.5, 1\}\} \gamma_{max} \quad (3.64)$$

Diese Diskretisierung schränkt den Suchraum ein, was den Rechenaufwand reduziert, aber auch gleichzeitig die Auflösung einschränkt. Da sich zwischen den Stellgrößen und den Größen, welche in die Berechnung der Potenziale eingehen, mindestens eine Integrationsstufe befindet, ist diese Auflösung ausreichend.

Gradientenabstieg

Der gradientenbasierte Optimierungsalgorithmus ist wie folgt implementiert (3.65)(3.66).

$$u(j+1) = u(j) - \alpha(j) \nabla f(u(j)) \quad (3.65)$$

$$\nabla f(u) = \left[\frac{\partial \bar{J}}{\partial u_{k+1}}, \dots, \frac{\partial \bar{J}}{\partial u_{K_H}} \right]^T \quad (3.66)$$

Der Wertebereich der zu optimierenden Stellgröße u ist dabei auf den Bereich zwischen -1 bis 1 eingeschränkt. Eine variable Schrittweitensteuerung ist deshalb nur bedingt sinnvoll. Die Schrittweite α wird auf 0.01 festgelegt. Dies erlaubt eine ausreichende Auflösung der Stellgröße. Bei 200 Iterationen als Abbruchkriterium wird sichergestellt, dass der gesamte Wertebereich auch im ungünstigsten Fall ausgenutzt werden kann. Als Ausgangsbasis der Optimierung in jedem Zeitschritt k wird die im vorherigen Zeitschritt bestimmte optimierte Stellgrößenfolge verwendet. Dies entspricht der zuvor bei der Evolutionsstrategie beschriebenen Vererbung.

Brute-Force-Methode

Die *Brute-Force-Methode* sucht, unter allen möglichen Lösungen n , nach der besten. Die Anzahl der möglichen Lösungen ist nur dann beschränkt, wenn sie aus diskrete Werten bestehen. Da der Berechnungsaufwand exponentiell mit der Anzahl der Zeitschritte des Prädiktionshorizonts K_H und der Anzahl der Freiheitsgrade n_f steigt, müssen diese eingeschränkt werden (3.67). Der Wertebereich n_{dis} ist, wie beim genetischen Algorithmus, diskret (3.68).

$$n = n_{dis}^{n_f K_H} \quad (3.67)$$

$$\phi_c = \{x | x \in \{-1, -0.5, 0, 0.5, 1\}\} \phi_{max} \quad (3.68)$$

Um den Berechnungsaufwand in vertretbaren Grenzen zu halten, wird bei der *Brute-Force-Optimierung* in dieser Arbeit ausschließlich der Soll-Rollwinkel optimiert. Weiter wird der Zeithorizont auf sieben Zeitschritte eingeschränkt. Dies erlaubt nur eine beschränkte Vergleichbarkeit mit anderen Algorithmen, jedoch kann durch verkürzen des Zeithorizonts auf sieben Zeitschritten bei allen Algorithmen ein Vergleich erfolgen. Ein Beispiel hierfür ist in Kapitel 4.2 zu sehen.

3.3 Aufbau der Simulation

Jedes einzelne UAV des Schwarms wird als Simulationsmodell abgebildet. Diese bestehen wiederum aus mehreren Modellen, welche die Flugmechanik, die Regelung und Sensoren bzw. Schätzer mit einem Modell der Umwelt beinhalten (Abbildung 3.12). Da alle UAVs ihre Informationen untereinander austauschen, hat jedes UAV dasselbe Modell der Umgebung.

Die Modellierung der Umgebung erfolgt in einem kartesischen Koordinatensystem auf einer planaren Erdoberfläche. Die Kommunikation zwischen den einzelnen UAVs erfolgt ohne Latenzen, ohne Beschränkung der Bandbreite, ohne Fehler und ohne Ausfälle. **Der Einfluss des Windes wird in der Arbeit nicht berücksichtigt. Eine Berücksichtigung des Windes würde die Simulation realistischer gestalten. Dies würde allerdings die Simulation komplexer gestalten und nicht zur grundsätzlichen Untersuchung beitragen in wie weit diese Methode zur Koordinierung eines Schwarms geeignet ist.** Bei Bedarf könnte der Wind jedoch durch Sensoren und Schätzer modelliert und durch die Optimierung berücksichtigt werden.

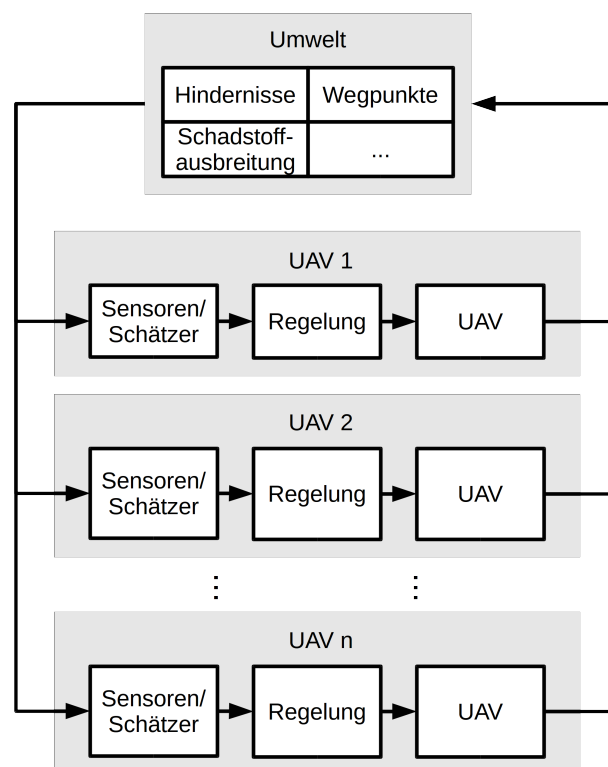


Abbildung 3.12: Aufbau der Simulation

Um eine möglichst einfache Implementierung, Fehlersuche und komfortable Entwicklungsumgebung zu erreichen, ist die komplette Simulation in MATLAB[®] implementiert. MATLAB[®] ist sehr effektiv in der Berechnung, auch im Vergleich zu C/C++ Implementierungen. Alle Simulationen werden auf einem 2GHz Core 2 Duo[®] Prozessor unter Verwendung eines Kerns durchgeführt.

3.3.1 Umwelt

Die Simulation der Umwelt beinhaltet Hindernisse, Schadstoffausbreitung, Wegpunkte, die Darstellung der Umwelt sowie die Darstellung der UAVs in der Umwelt.

Hindernisse

Die Hindernisse sind als Quader modelliert, die in ihren Abmessungen, in der Position und ihrer Anzahl frei variiert werden können. Bei der simulationstechnischen Untersuchung stellen die Hindernisse Gebäude dar. Für die Berechnung der Distanzen zwischen UAV und den Hindernissen werden die Oberflächen der Quader zu senkrechten Linien auf der Erdoberfläche transformiert. Die Länge der Linien entspricht der Höhe des Quaders. Durch einen Sperrradius ergibt sich aus den Linien eine Reihe von Säulen. Dieser Sperrradius entspricht dem Abstand der diskreten Linien. Damit ist eine Überlappung der Säulen gewährleistet und die Diskretisierung der Quader kann beliebig fein erfolgen. Dieses Vorgehen hat den Vorteil, dass es durch einfache Matrix-Operationen implementiert werden kann.

Schadstoffausbreitung

Da der Fokus der Arbeit auf der Regelung liegt, wird für diese Anwendung ein vereinfachtes Ausbreitungsmodell einer Schadstoffwolke ohne Windeinfluss verwendet. Nach der *Maxwell-Stefan*-Diffusion der kinetischen Gastheorie breitet sich ein Gas in einer ungestörten Umgebung nach Gleichung (3.69) bis (3.71) aus. Wobei D der Diffusionskoeffizient, c die Konzentration, d die Distanz und J die Teilchenstromdichte ist [Fro79].

$$J = -D \frac{\partial c}{\partial d} \quad (3.69)$$

$$\frac{\partial c}{\partial t} = -\frac{\partial J}{\partial d} \quad (3.70)$$

$$\frac{\partial c}{\partial t} = D \frac{\partial^2 c}{\partial d^2} \quad (3.71)$$

Die Lösung dieser Differential-Gleichung 2. Ordnung hat die Form (3.72). Die Konstante c_0 entspricht der Konzentration an der Quelle ($d = 0$). Es wird angenommen, dass an der Quelle der Schadstoff in reiner Form vorliegt. Damit ist die Konzentration des Schadstoffes dort $c_0 = 1$.

$$c = c_0 e^{a_{pol} d} \quad (3.72)$$

Die Messwerte der einzelnen UAVs werden anhand dieses Modells berechnet. Um die Messwerte etwas realistischer zu gestalten, wird weißes Rauschen $v_{c_{pol}}$ addiert (3.73).

$$c = c_0 e^{a_{pol} d} + v_{c_{pol}} \quad (3.73)$$

3.3.2 Sensoren/Schätzer

Zur Bestimmung des Gütewertes der prädizierten Trajektorien über den gesamten Prädiktionshorizont sind alle Informationen innerhalb dieses Bereiches notwendig. Diese Informationen können direkt von einem Sensor, von einem Modell, das unmittelbar aus den Sensorwerten bestimmt wird oder einem Modell dessen Parameter mithilfe von Sensorwerten geschätzt werden, stammen. Generell werden hier die Sensorwerte als fehlerfrei betrachtet. Sofern dies nicht explizit angegeben ist, sind die Sensorwerte frei von Rauschen.

Die eigene Position des UAV sowie die Positionen der anderen UAVs sind exakt und fehlerfrei bekannt. Jedes UAV teilt zusätzlich jedem anderen UAV im Schwarm zu jedem Zeitpunkt seinen geplanten Weg mit. So kann die Gefahr eines Zusammenstoßes frühzeitig erkannt und vermieden werden. Ebenso werden Informationen wie Wegpunktlisten zwischen den einzelnen UAVs ausgetauscht. Wenn eines der UAVs einen neuen Wegpunkt erreicht hat, teilt es diesen den anderen UAVs mit, sodass alle diesen Wegpunkt als erreicht markieren können. Da eine ideale Kommunikation angenommen wird, sind die Listen der Wegpunkte identisch.

Bei der Detektion der Hindernisse wird angenommen, dass es sich um ideale Sensoren mit einer Reichweite handelt, die größer ist als der Prädiktionshorizont. Damit unterscheidet sich das Modell der Hindernisse für jedes einzelne UAV nicht von der simulierten Umwelt.

Bei den Schadstoffmessungen wird davon ausgegangen, dass diese an der jeweiligen Position des UAVs einzelne Messwerte generieren. Um für den gesamten Bereich bis zum Prädiktionshorizont Informationen zu erhalten, wird dasselbe vereinfachte Modell der Gasausbreitung (Kapitel 3.3.1) in jedem UAV implementiert (3.76).

$$pos_{pol} = [x_{pol} \quad y_{pol}]^T \quad (3.74)$$

$$pos_{UAV} = [x_{UAV} \quad y_{UAV}]^T \quad (3.75)$$

$$c = e^{-\alpha_{pol} \sqrt{(pos_{pol} - pos_{UAV})^T (pos_{pol} - pos_{UAV})}} \quad (3.76)$$

Das Modell wird mithilfe eines *Extended Kalman Filters* (EKF) [Vie08] [PDY09] parametrisiert. Es wird angenommen, dass der Messwert c und die zugehörigen Positionen der UAVs pos_{UAV} per Broadcast ausgetauscht werden. Somit verfügen alle UAVs über alle Informationen, aber es bleibt dennoch eine dezentrale Struktur erhalten. Bei der Implementierung in der Simulation ist nur eine EKF implementiert, da alle über dieselben Informationen verfügen und somit über dasselbe Ergebnis. Informationen zur exakten Implementierung des Schätzers sind in Kapitel A zu finden.

3.4 Fazit

In diesem Kapitel ist eine Regelung basierend auf den Anforderungen und dem bisherigen Stand der Forschung beschrieben. Diese Regelung besteht aus einer modellprädiktiven Regelung, bei der die Bestimmung der Güte mittels gewichteten Potenzialfeldern bestimmt wird. Die Optimierung dieses Gütewertes erfolgt durch einen evolutionären Algorithmus.

Der Aufbau der Potenzialfelder ist abhängig vom Zweck, den sie erfüllen sollen. Jedoch sind besonders die Potenzialfelder, welche grundlegende Randbedingungen, wie das Vermeiden einer Kollision, bewirken sollen, systematisch aufgebaut. Die nötigen Parameter sind für kleine UAVs welche sich in einer hindernisreichen Umgebung befinden, dimensioniert. Eine Anpassung an die Erfordernisse der Umgebung und Fluggeräte ist jederzeit möglich. Um den zeitlichen Verlauf eines Potenzial entsprechend den Erfordernissen abweichend von dem üblicherweise verwendeten Mittelwert zu ermöglichen, sind weitere Funktionen, wie der Maximal- oder Endwert, implementiert. Diese können durch einen Parametervektor entsprechend gewählt werden. Eine weitere Gewichtung der einzelnen Potenziale zueinander ermöglicht es, die unterschiedlichen Ziele der Mission zu definieren und deren Randbedingungen zu relativieren.

Im Folgenden wird durch simulationstechnische und analytische Untersuchungen anhand von unterschiedlichen Szenarien bestimmt, in wie weit die hier vorgestellte Regelungen die Anforderungen einer Schwarmregelung erfüllen. Der Aufbau, der hierzu notwendigen Simulationsumgebung mit dessen Modellen und deren Parametern, wird in diesem Kapitel ebenfalls beschrieben.

4 Simulationstechnische Untersuchung mittels ausgewählter Szenarien

Im Folgenden wird die Erfüllung der Anforderungen an die Regelung, welche in Kapitel 1 genannt sind, überprüft. Hierzu werden zunächst die Grundfunktionen (das Ausweichen vor Hindernissen und anderen UAVs) für ein einzelnes UAV untersucht. Diese beiden Funktionen sind grundlegend für alle folgenden Anwendungen und Szenarien. Die Plausibilität der Ergebnisse wird Anhand von analytischen Untersuchungen oder Vergleichen mit anderen Arbeiten überprüft.

Das Ausweichen des UAVs vor Hindernissen wird mittels eines Hindernisszenarios analysiert, bei dem nur eine einzige Trajektorie unter Verwendung eines diskreten Optimierungsverfahrens (*GA* und *BF*) durch die Anordnung führt. Für dieses Szenario wird mittels einer analytischen Betrachtung die obere Schranke der Wahrscheinlichkeit eines Zusammenstoßes mit einem Hindernis ermittelt. Eine simulationstechnische Untersuchung wird am selben Szenario durchgeführt. Dies ermöglicht einen Vergleich zur analytischen Betrachtung. Zusätzlich werden bekannte Szenarien, bei denen Probleme erwartet werden, betrachtet. Dies sind U-förmige Hindernisse und das im weiteren Verlauf beschriebene Schwenkproblem.

In allen Szenarien werden neben den evolutionären Algorithmen (*ES/GA*) weitere Optimierungsverfahren untersucht, um deren Vorteile gegenüber weniger aufwendigen Optimierungsalgorithmen zu ermitteln. Ein gradientenbasierter Algorithmus wird angewendet, um die erwarteten Vorteile gegenüber *GA* und *ES* zu bestimmen. Das *Brute-Force*-Optimierungsverfahren ermittelt die optimale Lösung und ermöglicht somit einen Vergleich zu dieser.

Das Ausweichen von beweglichen Hindernissen (UAVs) wird nicht analytisch untersucht, da ein äquivalenter Extremfall dieselbe Wahrscheinlichkeit eines Zusammenstoßes wie im Fall der festen Hindernisse hat. Dieser Extremfall ist definiert als der Fall, in dem nur eine einzige Trajektorie bei einer vorgegebenen Diskretisierung der Stellgrößen, die das Ausweichen ermöglicht, existiert.

Neben den grundlegenden Funktionen werden in diesem Kapitel Funktionen untersucht, die zur Erfüllung unterschiedlicher Missionen notwendig sind. Diese beinhalten Funktionen für den Formationsflug, das Abfliegen von Wegpunkten sowie die Identifikation eines Skalarfelds. Sie stellen beispielhafte Implementierungen für eine Vielzahl von möglichen

Anwendungen dar.

Der Formationsflug wird gewählt, weil es die einfachste Art ist, mehrere UAVs koordiniert eine Trajektorie fliegen zu lassen. Der Formationsflug ist die Basis für viele Anwendungen (wie z.B. Photogrammetrie). Hierbei werden zwei grundlegende Varianten, die starre und die flexible Formation, unterschieden. Bei der starren Formation ist die Position der UAVs relativ zueinander fest vorgegeben. Im Gegensatz hierzu ist bei der flexiblen Formation die relative Position nur unvollständig vorgegeben. So können sich die UAVs flexibel und an jeder Position relativ zueinander mit dem vorgegebenen Abstand befinden.

Die starre Formation wird untersucht, da sie die klassische Art einer Formation ist. Hierbei sind die Positionen der einzelnen UAVs relativ zueinander vorgegeben. Flexible Formationen werden betrachtet, da sie ein weites Anwendungsspektrum ermöglichen. Beispiel für solch eine Anwendung ist eine Formation in der Form einer Kette, bei der eine gewisse Distanz zu einem anderen UAV gehalten werden soll.

Ein weiteres Beispiel ist eine flexible Formation mit UAVs, bei denen ein extremer Geschwindigkeitsunterschied zwischen den Teilnehmern besteht. Dies wird untersucht, da sie ein Extremfall einer Formation ist, welche vergleichbar ist mit einer Überwachung eines sehr langsam fliegenden UAVs, Bodenfahrzeug oder Konvois.

Eine weitere gebräuchliche Anwendung von einzelnen UAVs und Schwärmen ist das Abfliegen von Wegpunkten. Zur Analyse dieser Funktion wird zunächst ein Szenario mit einem UAV, welches mehrere Wegpunkte in beliebiger Reihenfolge abfliegt, analytisch betrachtet. Dasselbe Szenario wird in der simulationstechnischen Untersuchung der unterschiedlichen Optimierungsverfahren angewendet, um Vor- bzw. Nachteile der evolutionären Optimierungsalgorithmen (*ES/GA*) zu betrachten. Weitere Analysen werden mit Hindernissen und mehreren UAVs durchgeführt, um realistische Szenarien zu simulieren.

Das Szenario zur Identifikation eines Skalarfeldes mithilfe von UAVs unterscheidet sich zu den vorherigen Aufgaben. Die Regelung nutzt in diesem Szenario Informationen von einem Modell, dessen Parameter während der Mission geschätzt werden. Aus diesem Grund wird in mehreren Schritten die Untersuchung der Regelung in diesem Anwendungsszenario durchgeführt. Zunächst wird die Regelung in Szenarien untersucht, bei denen das Skalarfeld als solches bekannt ist. Zum Vergleich werden dieselben Szenarien mit einem unbekanntem Skalarfeld, bei der die Schätzung der Parameter verwendet wird, betrachtet.

Um zu untersuchen, inwieweit es sich bei dieser Regelung um ein Expertensystem handelt, welches nur bei einer exakten Wahl der Parameter entsprechende Ergebnisse liefert, wird eine Sensitivitätsanalyse durchgeführt. Weiter wird die Robustheit der Regelung bezüglich Parameter und Abweichungen des Modells von der Realität analysiert.

Folgende Funktionen und Eigenschaften der Regelung werden in diesem Kapitel untersucht:

- Ausweichen vor Hindernissen
 - Analytische Betrachtung eines Hindernisszenarios
 - Simulationstechnische Untersuchung des selben Szenarios
 - Probleme der lokalen Minima
- Ausweichen von anderen UAVs
 - Nicht ausweichende Intruder
 - Ausweichende Intruder
- Formationsflug von UAVs
 - Starre Formation
 - Flexible Formation
- Abfliegen von Wegpunkten
 - Einzelnes UAV
 - Mehrere UAVs
- Identifikation eines Skalarfeldes
 - Ohne Schätzung des Skalarfeldes
 - Mit Schätzung des Skalarfeldes
- Robustheit
 - Robustheit des Optimierungsverfahrens
 - Robustheit gegenüber Modellungenauigkeiten und Störungen
 - Robustheit gegenüber Parameter der Potenzialfelder

4.1 Konflikte mit Hindernissen

Das Ausweichen vor Hindernissen ist eine elementare Aufgabe der vorgestellten Regelung. Daher wird diese Funktion besonders ausführlich betrachtet. Zunächst wird mit einer analytischen Abschätzung die Wahrscheinlichkeit einer Kollision mit einem Hindernis in einem künstlich generierten Extremfall betrachtet.

Bei diesem Extremfall handelt es sich um eine Anordnung von Hindernissen, bei welcher nur eine einzige Trajektorie, bei einer Regelung mittels eines diskreten Optimierungsverfahrens, ohne eine Kollision zum Ziel führt. Um dieses Szenario zu gestalten, wird zunächst eine beliebige Trajektorie mit diskreten Stellgrößen erstellt. Die Hindernisse werden seitlich der Trajektorie entsprechend angeordnet, sodass jede Abweichung von der Stellgrößenfolge einen Zusammenstoß zur Folge hat. Dasselbe Szenario wird anschließend zum Vergleich in der Simulation betrachtet.

4.1.1 Analytische Betrachtung eines Konflikts mit einem Hindernis

Die Wahrscheinlichkeit eines Zusammenstoßes mit einem nicht-ortsveränderlichen Hindernis hängt entscheidend von der Form des Hindernisses, der Wendigkeit des UAVs und der intelligenten Ausnutzung der Wendigkeit durch die Regelung ab. Dabei darf nicht nur die Wahrscheinlichkeit in einem Zeitschritt berücksichtigt werden, sondern auch die akkumulierte Wahrscheinlichkeit durch das Quasi-Gedächtnis der evolutionären Algorithmen. Der Grund hierfür ist, dass in jedem Zeitschritt eine erneute Optimierung der gesamten Trajektorie bzw. Stellgrößenfolge erfolgt (Kapitel 2.3.2).

In der Abbildung 4.1 ist ein Beispiel für eine extreme Hindernissituation dargestellt. Es wird so gestaltet, dass bei einer Wertediskretisierung (Kapitel 3.2.4), wie in Gleichung (4.1) gezeigt, bei einer konstanten Fluggeschwindigkeit und Höhe nur eine einzige Stellgrößenfolge existiert, deren resultierende Trajektorie einen Zusammenstoß mit einem Hindernis verhindert.

$$\phi_c = \{x | x \in \{-1, -0.5, 0, 0.5, 1\}\} \phi_{max} \quad (4.1)$$

Um eine Aussage über die Wahrscheinlichkeit eines Zusammenstoßes mit einem Hindernis treffen zu können, wird angenommen, dass der Suchraum der Stellgröße im Wert- und Zeitbereich diskret ist. Deshalb bezieht sich diese analytische Betrachtung ausschließlich auf den genetischen Optimierer.

Für eine konservative Betrachtung wird angenommen, dass ein Ausweichen in der Vertikalen nicht möglich ist. Damit ist die einzige Stellgröße, die einen Zusammenstoß mit einem Hindernis vermeiden kann, der Rollwinkel ϕ_c (4.1). Weiter wird die geometrische Anordnung der Hindernisse entsprechend gewählt, dass bei der in Gleichung (4.1) benutzten Diskretisierung nur eine einzige Trajektorie den Zusammenstoß verhindert.




Abbildung 4.1: Extremfall eines Hindernis-Szenarios, bei dem eine einzige Lösung existiert

Die Stellgrößenfolge, welche die optimale Trajektorie (die einzig mögliche in diesem Szenario) zur Folge hat, wird als ϕ_{opt} bezeichnet. Unter diesen Randbedingungen ist $\phi_c = \phi_{opt}$, innerhalb des Horizonts, die Lösung.

Unter der Annahme, dass bei dem verwendeten genetischen Optimierer der Anteil der Migration überwiegt, kann dieser als Zufallsoptimierer angesehen werden. Dies ist eine konservative Annahme, da jeder genetisch basierende Algorithmus schneller konvergiert als ein auf Normalverteilung basierender Zufallsoptimierer. Im Fall eines Zufallsoptimierers wäre die Wahrscheinlichkeit, die richtige Lösung ($\phi_c = \phi_{opt}$) zu finden, in diesem Szenario $P_{opt} = 0.2$ für jeden einzelnen Zeitschritt des Horizonts. Dies entspricht einer Wahrscheinlichkeit für einen Zusammenstoß $P_{fatal} = 0.8$.

Werden, wie zuvor, die Populationsgröße n_p und die Anzahl der Generationen n_G berücksichtigt, so lässt sich eine Wahrscheinlichkeit für ein Zusammenstoßen mit einem Hindernis P_{ges} berechnen (4.2).

$$P_{ges} = \frac{P_{fatal}}{n_p n_G} \quad (4.2)$$

$$\lambda = \frac{P_{ges}}{T_u} \quad (4.3)$$

Bei einer Populationsgröße $n_p = 200$, Generationen $n_G = 10$ und einer Diskretisierung der Zeitschritte der Stellgröße $T_u = 1s$ ergibt sich eine Ausfallrate (Zusammenstoßes mit einem Hindernis) $\lambda = 4 \cdot 10^{-4}s^{-1}$. Dies erscheint auf den ersten Blick als ein sehr hoher Wert, jedoch sollte bedacht werden, dass es sich hierbei um einen künstlich gestalteten Extremfall handelt, der innerhalb von wenigen Sekunden durchflogen wird. Zudem werden zuvor extrem konservative Annahmen getroffen, sodass diese Ausfallrate die obere Grenze eines Extremfalls darstellt.

Die analytischen Betrachtung begleiten Simulationen, die aus 500 Läufen bestehen, bei denen sich das UAV ca. 10s im relevanten Bereich befindet. Nach der vorherigen analytischen Betrachtung tritt bei einer Ausfallrate von $\lambda = 4 \cdot 10^{-4}s^{-1}$ in 500 Flügen mit einer Dauer von jeweils 10s in maximal zwei Fällen ein Zusammenstoß ein. In der Simulation ist dies nur einmal der Fall, wobei das aufgrund der limitierten Anzahl der Simulationsläufe kein Beweis der theoretischen Schranke ist und im Bereich des Erwarteten liegt.

Um einen Vergleich der unterschiedlichen Optimierungsverfahren bei diesem Szenario zu ermöglichen, werden Simulationen mit weiteren Optimierungsverfahren durchgeführt, welche nicht Bestandteil der analytischen Betrachtung sind (Tabelle 4.1).

Tabelle 4.1: Ergebnisse zur analytischen Betrachtung der Kollisionsvermeidung

Optimierer	Anteil der erfolgreichen Läufe
Genetisch (GA1)	99.8%
Evolutionär (ES1)	99.8%
Gradientenabstieg (GR1)	0.0% ²
Brute-Force (BF1)	100% ²

Beim genetischen (GA1) als auch beim Evolutionsstrategie Optimierungsverfahren (ES1) (Kapitel 3.2.4) ereignet sich jeweils ein Zusammenstoß mit einem Hindernis innerhalb eines untersuchten zeitlichen Bereiches von 5000s. Wie zu erwarten ist, findet die Regelung bei Verwendung des *Brute-Force*-Optimierungsverfahren den Weg durch dieses Szenario. Es wäre zu erwarten, dass diese Problemstellung durch das gradientenbasierte Verfahren erfolgreich zu bewältigen ist. Dies ist jedoch nicht der Fall. Durch die extrem dichte Anordnung der Hindernisse ist der Bereich, in dem das Potenzial zur Vermeidung eines Hindernisses ansteigt, zu dem Bereich, in dem das Potenzial den Wert Unendlich besitzt, sehr klein. Aus diesem Grund gerät bei der ersten nötigen Kursänderung die prädierte Trajektorie in den Bereich, in dem das Potenzial den Wert Unendlich annimmt.

² Auf Grund der Deterministik des Optimierungsverfahrens wird ein einziger Lauf durchgeführt

Im Gegensatz zu den anderen hier verwendeten Optimierungsverfahren benötigt *GR1* einen Gradienten zur Berechnung. Eine Berechnung ist in diesem Fall nicht möglich, da sich für kleine Änderungen der Stellgrößenfolge immer der Wert Unendlich ergibt.

Das Ergebnis der Simulation bei Verwendung der Regelung mit dem genetischen Algorithmus *GA1* stimmt mit dem Ergebnis der analytischen Betrachtung für dieses Szenario überein. Damit deckt sich die analytische Untersuchung mit den Ergebnissen der simulationstechnischen Betrachtung. Bei Verwendung des Evolutionstrategie Optimierungsverfahrens *ES1* zur Regelung ergibt sich bei der simulationstechnischen Untersuchung dieselbe Ausfallrate infolge einer Kollision. Das lässt darauf schließen, dass die Diskretisierung der Stellgröße in diesem Fall keinen oder nur einen geringen Einfluss auf die Wahrscheinlichkeit einer Kollision hat. Weiter zeigt dieser Befund, dass die beiden evolutionären Optimierungsverfahren *GA1* und *ES1* auch unter extremen Bedingungen (das hier verwendete Szenario) ohne den Berechnungsaufwand einer *Brute-Force* Optimierung (*BF1*) in der Lage sind, eine Kollision zu vermeiden.

Das in diesem Teilkapitel untersuchte Szenario stellt einen Extremfall bezüglich der möglichen Trajektorien durch die Hindernisanordnung dar. Jedoch bestehen in diesem Szenario keine lokalen Minima. Szenarien, bei denen ein lokales Minima entstehen kann, werden deshalb im Folgenden betrachtet.

4.1.2 Problem der lokalen Minima

Lokale Minima stellen ein generelles Problem für alle Algorithmen basierend auf Potenzialfeldern dar. Viele lokale Minima können alleine schon durch das vorausschauende Verhalten der MPC umgangen werden. Jedoch trifft dies nicht für alle Problemfälle zu. Dazu werden zwei Szenarien betrachtet, bei denen ein lokales Minimum existiert. Bei diesen wird untersucht, unter welchen Bedingungen dieses lokale Minimum verlassen bzw. vermieden werden kann.

U-Problem

Ein U-förmiges Hindernis stellt einen klassischen Fall dar, bei dem ein lokales Minimum durch symmetrische Anordnung von Hindernissen und ein anschließendes Versperren des Ziels auftritt. Abbildung 4.2 zeigt, dass im Fall der Nutzung eines lokalen Optimierers, wie dem Gradientenabstieg, keine Lösung gefunden wird bzw. ein Zusammenstoß mit dem Hindernis unvermeidbar ist. Die Abbildung 4.3 zeigt, dass ein globaler Optimierer aus der Klasse der evolutionären Optimierer eine Lösung für das exakt selbe Szenario findet.

Dieser erkennt aufgrund der Prädiktion, dass der zunächst gewählte, direkte Weg zu keiner Lösung führt, da für diesen der Potenzialwert zu $\bar{J} = \infty$ wird, wenn die Prädiktion auf das Hindernis trifft. Damit wird diese Lösung verworfen und die nächstbessere




Abbildung 4.2: Trajektorie eines gradientenbasierten Optimierers

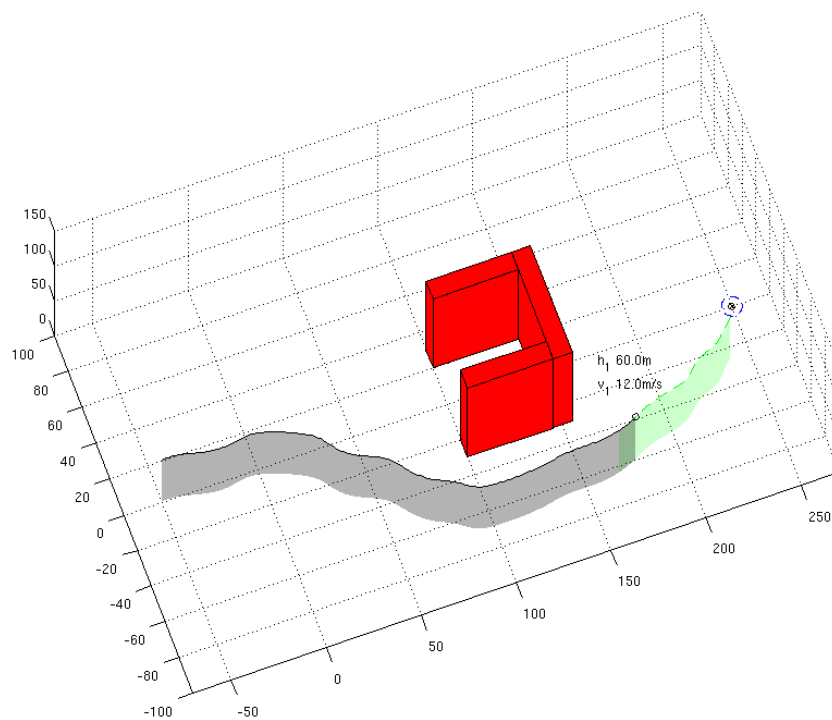


Abbildung 4.3: Trajektorie eines Evolutionsstrategie Optimierers

Lösung in der Population wird verwendet. Sollte der unwahrscheinliche Fall eintreten, dass keine der Lösung der Population einen Potenzialwert \bar{J} von Unendlich verschieden

hat, so hat das UAV in den folgenden Optimierungsschritten erneut die Möglichkeit, eine Lösung zu finden. So kann das UAV ein lokales Minimum mithilfe eines *ES* oder *GA* vermeiden oder verlassen.

Bei *ES* und *GA* ist das Vermeiden oder Verlassen eines U-förmigen Hindernisses nur möglich, wenn die Ausdehnung der Prädiktion die Größe des lokalen Minimum ein Verhältnis nicht unterschreitet. Hierzu wird eine Untersuchung mit variierender Größe des U-förmigen Hindernisses d_U und variierendem Prädiktionshorizont t_H durchgeführt. In diesem Szenario wird die Fluggeschwindigkeit V konstant gehalten. Damit lässt sich die Länge des Prädiktors ($t_H V$) und das Verhältnis a_U zur Größe des Hindernisses d_U bestimmen (4.4).

$$a_U = \frac{t_H V}{d_U} \quad (4.4)$$

Die Ergebnisse dieser Untersuchung bezüglich des Verhältnisses a_U sind in Abbildung 4.4 gezeigt. Bei einer Hindernislänge d_U von mehr als 70m ist die nötige Länge der Prädiktion $t_H V$, um das Hindernis zu umfliegen oder zu verlassen, in etwa proportional zu Größe des Hindernisses.




Abbildung 4.4: Bewältigung eines U-Hindernisses abhängig von der Länge des Hindernisses ³

³ o erfolgreich / * nicht erfolgreich

Der Faktor a_U beträgt ca. 1.06. Somit muss die Länge der Prädiktion geringfügig mehr als die Hindernislänge sein, um das Hindernis erfolgreich zu umfliegen oder zu verlassen. Die Unregelmäßigkeit bei einer Hindernislänge geringer als 70m erklärt sich u. a. durch die Breite des Hindernisses. Die Breite des Hindernisses verursacht bei kleineren Längen eine anteilig größere Distanz, welche die Prädiktion abdecken muss, um zu erkennen, dass ein Weg um das Hindernis herum existiert.

Somit kann abhängig von der Länge der Prädiktion jedes lokale Minimum dieser Art vermieden oder verlassen werden. Die mögliche Länge der Prädiktion ist primär begrenzt durch die Rechenleistung und die Reichweite der Sensoren. Ist die Reichweite der Sensoren der begrenzende Faktor, so können die nötigen Informationen über die Zeit ermittelt werden bzw. abhängig vom Szenario aus einer Karte gewonnen werden. Dies kann jedoch nur im Fall einer statischen Umgebung erfolgen. Ist die Rechenleistung der begrenzende Faktor, so können im begrenzten Umfang die Geschwindigkeit oder die Länge der Zeitschritte der Prädiktion erhöht werden. Der Nachteil in diesem Fall ist jedoch, dass sich der minimale Kurvenradius erhöht bzw. sich die Auflösung der Stellgröße verringert.

Schwenkproblem

Das hier als „Schwenkproblem“ bezeichnete Phänomen ist dem zuvor beschriebenen U-Problem sehr ähnlich. Auch hier kann das lokale Minimum nicht in Richtung des globalen Minimums verlassen werden. Im Unterschied zum U-Problem kann auf dem indirekten Weg dennoch das globale Minimum erreicht werden (Abbildung 4.6). Die Abbildung 4.5 zeigt die Ausgangskonstellation des Schwenkproblems.

Ziel des UAVs ist es, einen Wegpunkt (markiert als Kreis mit Punkt) zu erreichen. Der initiale Prädiktor (grün dargestellt) und somit auch die initiale Stellgrößenfolge für den Rollwinkel ϕ_c zeigt auf die dem Ziel abgewandte Seite (rechts) des Hindernisses. Diese initiale Konstellation kann entweder bei der Initialisierung der Simulation oder durch dynamische Komponenten entstehen. Ein Beispiel hierfür ist ein anderes UAV, welches kurzzeitig den direkten Weg zum Ziel versperrt.

Ausgehend von dieser Situation kann abhängig von dem zur Regelung verwendeten Optimierungsverfahren das UAV sein Ziel auf direktem Weg anfliegen, da ein Schwenken des Prädiktors und somit die daraus resultierende Trajektorie nicht zu einer Kollision mit dem Hindernis führt.

Das Resultat bei Verwendung einer Regelung mit gradientenbasierten Optimierungsalgorithmus ist in der Abbildung 4.6 gezeigt. Das UAV versucht in diesem Fall das Ziel auf dem direkten Weg zu erreichen. Es ist ihm durch das verwendete Optimierungsverfahren nicht möglich den Prädiktor in Richtung des Ziels zu drehen. Das Resultat ist eine Ausbuchtung der Trajektorie in Richtung des Ziels. Jedoch erreicht auch in diesem




Abbildung 4.5: Darstellung der Ausgangskonstellation für das Schwenkproblem

Fall das UAV, wenn auch auf Umwegen, sein Ziel durch umfliegen des Hindernisses (Abbildung 4.6). Im Fall der Verwendung eines Evolutionstrategie (*ES*) oder genetischen Algorithmus (*GA*) erreicht das UAV auf dem direkten Weg sein Ziel (Abbildung 4.7).




Abbildung 4.6: Resultierende Trajektorie bei der Verwendung eines gradientenbasierten Optimierers




Abbildung 4.7: Resultierende Trajektorie bei der Verwendung eines genetischen Optimierers

Bei einem gradientenbasierten Optimierer wird ausgehend von dem zuvor prädizierten Weg optimiert. Ist dieser prädizierte Weg auf der abgewandten Seite des Hindernisses, ergibt sich für die Optimierung über den gesamten Prädiktionshorizont ein ähnlicher Verlauf wie in Abbildung 4.9 gezeigt.

Eine Regelung mit einem gradientenbasierten Optimierungsalgorithmus kann in diesem Szenario nicht auf direktem Weg das Ziel erreichen, da bei der Bestimmung der Gradienten der Stellgrößenfolge für jeden Wert ein nach links (in Richtung des Ziels) schwenken eine Erhöhung des Potentials zur Folge hat. In Abbildung 4.8 ist dieses Phänomen visualisiert.

Im oberen Bereich der Abbildung 4.8 ist das Szenario aus Abbildung 4.5 mit fünf Variationen der initial prädizierten Trajektorie schematisch dargestellt. Die mit 1-5 nummerierten Trajektorien sind Derivative der initialen Steuerfolge des Rollwinkels ϕ . Im unteren Bereich der Abbildung 4.8 sind die Variationen des Rollwinkels mit $-d\phi$ für die Trajektorien 1-5, wie sei bei einer gradientenbasierten Optimierung genutzt werden, dargestellt. Jede Variation der initialen Trajektorie in Richtung von $-d\phi$ hat eine Erhöhung des Potentials Φ_{obs} zur Folge, da sich das UAV, wie im oberen Bereich der Abbildung dargestellt, dem Hindernis nähert. Deshalb wird bei diesem Szenario jeder gradientenbasierte Optimierungsalgorithmus die Trajektorie in Richtung von $+d\phi$ optimiert. Dies entspricht einer Bewegung des UAV nach Rechts. Obwohl bei einer scharfen Bewegung nach links ein direktes Erreichen des Ziels und somit des globalen Minimum, möglich wäre.




Abbildung 4.8: Visualisierung des Schwenkproblems

Betrachtet man den Verlauf des Potentials Φ_{obs} über die Variation des Rollwinkels $\phi(k+1)$ des nächsten Zeitschritts (Trajektorie 1), so ergibt sich ein Verlauf ähnlich dem in Abbildung 4.9 dargestellten.




Abbildung 4.9: Beispiel für den Verlauf des Potentials Φ_{obs} über $\frac{\phi}{\phi_{max}}$ für den ersten Optimierungsschritt beim gradientenbasierten Algorithmus

Die initiale Stellgrößenfolge und somit der Wert für den folgenden Zeitschritt $\phi(k+1)$ dienen als Ausgangspunkt für die Optimierung, welche in der Abbildung 4.9 als Start markiert ist. Ausgehend von diesem Startwert wird beim gradientenbasierten Optimierungsverfahren der Gradient bestimmt und der Wert in Richtung des fallenden Gradienten verändert. In diesem Fall führt dies zu einem lokalen Minimum. Um das globale Minimum und somit das Ziel auf direktem Weg zu erreichen, müsste das Optimierungsverfahren die Stellgröße zunächst in Richtung des steigenden Gradienten korrigieren. Das widerspricht dem Vorgehen bei gradientenbasierten Optimierungsverfahren. Nur Optimierungsverfahren die für globale Optimierungsprobleme geeignet sind, wie *GA* und *ES*, können in diesem Szenario das globale Minimum bestimmen und auf direktem Weg das Ziel erreichen (Abbildung 4.7).

Fazit

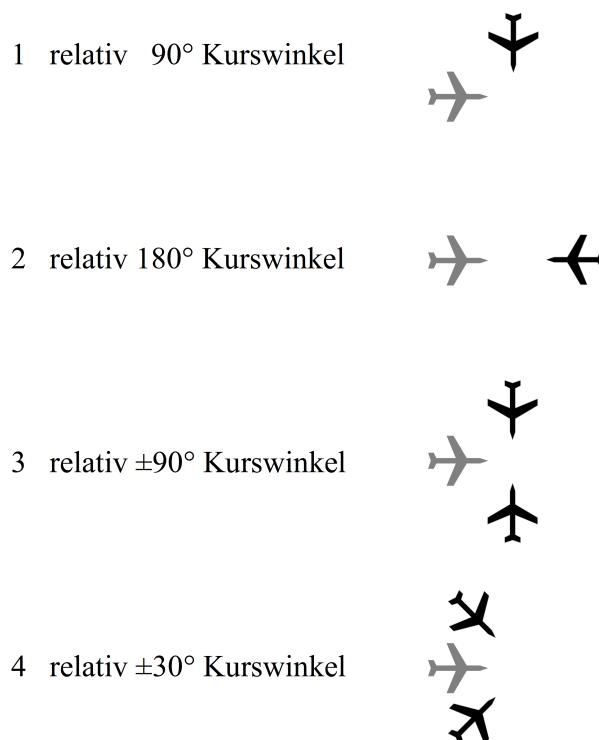
In diesem Unterkapitel wird die Fähigkeit der Regelung einem Hindernis auszuweichen, analytisch und in Simulationen untersucht. Die simulierten Ergebnisse decken sich hierbei mit dem analytischen Ergebnis. Einzig die Regelung mit dem *GR1* Optimierungsverfahren ist nicht in der Lage den Hindernissen auszuweichen.

Im Gegensatz zur Regelung mit einem lokalen Optimierungsverfahren, wie dem *GR1*, kann die Regelung mit globalen Optimierungsverfahren (*ES1*, *GA1*, *ES3*, *GA3*, *BF1*) U-förmigen Hindernissen ausweichen. Hierfür muss jedoch der Prädiktionshorizont eine ausreichende Größe besitzen. Der Wert für die notwendige Größe des Prädiktionshorizont wird in diesem Unterkapitel für das U-Problem ermittelt.

In einem weiteren Fall, welcher ein lokales Minimum zur Folge hat (dem Schwenkproblem), kann mittels der Regelung, welche eine evolutionäres Optimierungsverfahren nutzt, das lokale Minimum vermeiden werden und das globale Minimum (sein Ziel) auf direktem Weg erreicht werden.

4.2 Konflikte mit anderen UAVs

Für die Validierung des Vermeidens von beweglichen Hindernissen bzw. anderer UAVs werden verschiedene Szenarien - basierend auf der Arbeit von Barraci [Bar10] - definiert. Die Szenarien aus dieser Arbeit werden gewählt, da mittels einfachen Beispielen die Vor- und Nachteile der Regelung untersucht und verglichen werden können. Ein exakter Vergleich mit den Ergebnissen der Arbeit von Barraci ist nicht angestrebt, da der Fokus in der Arbeit auf der Optimierung der 4D-Trajektorie (bezüglich der Abweichung der Trajektorie, der Separation der Flugzeuge und dem Treibstoffverbrauch) liegt. Als Luftfahrzeug werden dort Airliner verwendet, die weitaus exakter bezüglich der zuvor genannten Zielsetzungen modelliert sind. Die dort definierten Szenarien werden als Grundlage für die hier genutzten Szenarien verwendet und erweitert. Diese werden im Vergleich zur Arbeit von Barraci um weitere Varianten ergänzt. Die untersuchten Varianten sind im Folgenden aufgelistet.



Alle Szenarien werden in der Art gestaltet, dass sich ohne eine Ausweichbewegung ein Zusammenstoß an der Position (0|0) ereignet. Für diese Szenarien werden folgende Gewichtungen der Potenziale zueinander verwendet (Kapitel 3.2.3):

$$\vec{l} = [1 \ 1 \ 1 \ 0 \ 0 \ 0 \ 1]^T \quad (4.5)$$

Diese Gewichtung berücksichtigt die grundlegenden Anforderungen, wie die Vermeidung einer Kollision mit Hindernissen, anderen UAVs und die Haltung einer Höhe, die in allen Szenarien in dieser Arbeit aktiv sind. Zusätzlich ist für dieses Szenario das spezifische Potenzial der 4D-Trajektorie aktiv.

Bewertungskriterien sind der minimalen Abstands zwischen den UAVs und der durch die Ausweichbewegung verursachte Zeitverlust. Da es sich bei *ES* und *GA*, um nicht deterministische Verfahren handelt, werden mehrere Simulationsläufe durchgeführt. Um den Berechnungsaufwand in Grenzen zu halten, werden nur 100 Simulationsläufe untersucht. Aus diesen werden die Mittelwerte und die ungünstigsten Extremwerte zur Bewertung herangezogen. Die ungünstigsten Extremwerte sind in diesem Fall der kleinste minimale Abstand zwischen den UAVs und der größte Zeitverlust in allen Läufen. Eine Angabe von Mittelwert und Varianz wäre ebenfalls möglich, jedoch sind die kritischen Werte, wie der kleinste minimale Abstand oder der größte Zeitverlust, in diesem Zusammenhang informativer. Die Verteilung der Ergebnisse und eine eventuell vorhandene Korrelation von geringstem Abstand und Zeitverlust können im Anhang B betrachtet werden.

Szenarien und Ergebnisse

In den beiden Szenarien 1 und 2 fliegt das UAV₂ (Intruder) mit einem relativen Kurswinkel von 90° bzw. 180° zu UAV₁ ohne auszuweichen auf die Position (0|0) zu (Abbildung 4.10 und 4.11).




Abbildung 4.10: Beispiel für Szenario 1 mit *GR1* bei einem Prädiktionshorizont von 10s




Abbildung 4.11: Beispiel für Szenario 2 mit GR1 bei einem Prädiktionshorizont von 10s

Beide Abbildungen zeigen Beispiele von Trajektorien, die Resultate der Ausweichbewegung durch die Regelung mit gradientenbasierten Optimierungsalgorithmus (GR1) und einem Prädiktionshorizont von 10s sind.

In Abbildung 4.10 weicht das UAV₁ nach rechts aus und kreuzt vor UAV₂ dessen Flugbahn. Der zeitliche Verlust in Folge der Ausweichbewegung beträgt 1,1s. Der minimale Abstand zwischen den beiden UAVs ist 29m. Dies liegt weit über dem durch das Potenzialfeld geforderten Minimums von 5m.

In Abbildung 4.11 weicht UAV₁ nach rechts aus und fliegt parallel in entgegengesetzter Richtung zu UAV₂ um eine Kollision zu vermeiden. Der zeitliche Verlust beträgt hier 0,7s bei einem minimalen Abstand zwischen den beiden UAVs von 30m.

In den Tabellen 4.2 und 4.3 sind die Ergebnisse zu diesen beiden Szenarien gezeigt. Der kleinste minimale Abstand ist das Minimum des geringsten Abstandes aus allen 100 Simulationsläufen.

Wie zu erwarten, ist der Unterschied zwischen ES und GA gering, da die verwendeten Parameter dieselben sind (Tabelle 4.2 und 4.3). Sie unterscheiden sich nur durch die Diskretisierung im Wertebereich.

Im Unterschied zu den Verfahren, bei welchen nur der Soll-Rollwinkel ϕ_c optimiert wird (ES1,GA1), ist bei den Verfahren ES3 und GA3 bei einem ähnlichen Mindestabstand ein deutlich geringerer Zeitverlust zu registrieren. Dies resultiert daraus, dass bei diesen beiden Optimierungsverfahren alle Steuergrößen optimiert werden. Dies ermöglicht es

Tabelle 4.2: Ergebnisse des Szenario 1 mit einem Prädiktionshorizont von 10s

Optimierer (Kapitel 3.2.4)	<i>ES1</i>	<i>GA1</i>	<i>ES3</i>	<i>GA3</i>	<i>GR1</i> ⁴
Kleinster minimaler Abstand [<i>m</i>]	29	29	27	28	29
Mittlerer minimaler Abstand [<i>m</i>]	30,7	31,2	32,5	33,4	29
Mittlerer Zeitverlust [<i>s</i>]	1,4	1,4	0,4	0,5	1,1
Größter Zeitverlust [<i>s</i>]	2,8	2,6	1,4	2,1	1,1

Tabelle 4.3: Ergebnisse des Szenario 2 mit einem Prädiktionshorizont von 10s

Optimierer	<i>ES1</i>	<i>GA1</i>	<i>ES3</i>	<i>GA3</i>	<i>GR1</i> ⁴
Kleinster minimaler Abstand [<i>m</i>]	29	29	29	28	30
Mittlerer minimaler Abstand [<i>m</i>]	31,4	31,5	34,8	33,0	30
Mittlerer Zeitverlust [<i>s</i>]	0,9	1,0	0,2	0,2	0,7
Größter Zeitverlust [<i>s</i>]	1,8	2,0	1,1	1,6	0,7

dem UAV entsprechend zu beschleunigen, um den Zeitverlust nach dem Ausweichen wieder aufzuholen. Die Werte in Tabelle 4.2 und 4.3 sind auf eine Simulationszeit von 21s bezogen. Erhöht man diese, so wird im Fall der beiden Optimierungsverfahren *ES3* und *GA3* der Zeitverlust aufgeholt und das UAV folgt entsprechend der vorgegebenen 4D-Trajektorie ganz ohne Zeitverlust. Wie erwartet, liefern die Versuche im Fall des gradientenbasierten Optimierers (*GR1*) ein Ergebnis nahe des bestmöglichen, sofern dieser eine Lösung findet. Mit einem Zeitverlust von 1,1s liefert der Optimierer *GR1* das beste Ergebnis aller Optimierer.

Im Fall des *Brute-Force*-Optimierers (*BF1*) ist ein maximaler Prädiktionshorizont von 7s bei einer Rate von 1s möglich. Dies ist der maximale Prädiktionshorizont mit einem vertretbaren zeitlichen Aufwand bei der verwendeten Hardware. Um die Ergebnisse vergleichen zu können, werden alle zuvor durchgeführten Simulationen erneut mit einem Prädiktionshorizont von 7s durchgeführt. Diese Ergebnisse sind in Tabelle 4.4 und 4.5 aufgelistet.

Tabelle 4.4: Ergebnisse des Szenario 1 mit einem Prädiktionshorizont von 7s

Optimierer	<i>ES1</i>	<i>GA1</i>	<i>ES3</i>	<i>GA3</i>	<i>GR1</i> ⁴	<i>BF1</i> ⁴
Kleinster minimaler Abstand [<i>m</i>]	24	25	28	28	26	31
Mittlerer minimaler Abstand [<i>m</i>]	29,8	30,3	31,1	31,7	26	31
Mittlerer Zeitverlust [<i>s</i>]	1,9	2,0	0,6	0,5	1,7	1,7
Größter Zeitverlust [<i>s</i>]	4,5	4,5	3,4	2,4	1,7	1,7

Im Vergleich zu einem Prädiktionshorizont von 10s haben die Ergebnisse bei einem Prädiktionshorizont von 7s deutlich höhere Zeitverluste und teilweise deutlich geringere Abstände. Im Fall der Optimierung mit *ES3* und *GA3* unterscheiden sich die Ergebnisse

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist

Tabelle 4.5: Ergebnisse des Szenario 2 mit einem Prädiktionshorizont von 7s

Optimierer	ES1	GA1	ES3	GA3	GR1 ⁴	BF1 ⁴
Kleinster minimaler Abstand [m]	29	29	29	29	30	30
Mittlerer minimaler Abstand [m]	30,7	30,9	32,0	32,0	30	30
Mittlerer Zeitverlust [s]	1,1	1,1	0,2	0,2	0,9	0,8
Größter Zeitverlust [s]	1,5	1,6	0,8	1,0	0,9	0,8

im Vergleich zu den Ergebnissen mit dem längeren Prädiktionshorizont nur geringfügig. Dies lässt vermuten, dass die Möglichkeit des Beschleunigens den Nachteil eines kürzeren Prädiktionshorizonts teilweise ausgleicht. Wie zu erwarten ist, liefert der *Brute-Force*-Algorithmus (*BF1*) die besten Ergebnisse. Mit einem Zeitverlust von 1,7s bei Verwendung des *BF1* und *GR1* ist der Zeitverlust etwas geringer als bei der Verwendung des *ES1* und *GA1*. Der *BF1* ist in der Lage einen größeren Abstand zum Intruder zu halten, was allerdings einen höheren Rechenaufwand impliziert. Zusammenfassend wäre in den beiden Szenarien 1 und 2 ein gradientenbasiertes Verfahren absolut ausreichend, weil es nur geringfügig schlechtere Ergebnisse im Vergleich zur *Brute-Force*-Methode liefert.




Abbildung 4.12: Beispiel für Szenario 3 mit einem gradientenbasierten Optimierer (*GR1*)

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist

In den beiden Szenarien 3 (Abbildung 4.12) und 4 (Abbildung 4.13) sind zwei Intruder (UAV₂ und UAV₃) auf Kollisionskurs mit dem auszuweichenden UAV₁. Im Falle von zwei Intrudern können Szenarien, die symmetrisch zur geplanten Trajektorie des UAVs sind und solche die es nicht sind, unterschieden werden. Da Symmetrien lokale Minima erzeugen können, werden hier zwei symmetrische Szenarien untersucht. In beiden Szenarien bewegt sich ein Intruder von links und rechts auf den denselben Punkt (0|0) zu. In Szenario 3 ist der Winkel zwischen der Trajektorie des UAVs und den Intrudern $\pm 90^\circ$ (Abbildung 4.12) in Szenario 4 sind es nur $\pm 30^\circ$ (Abbildung 4.13).




Abbildung 4.13: Beispiel für Szenario 4 mit einem gradientenbasierten Optimierer (GR1)

Die Abbildung 4.12 zeigt ein Beispiel für die resultierende Trajektorie in Szenario 3 unter Verwendung des GR1 Optimierungsverfahrens. In diesem Fall weicht das UAV₁ nach rechts aus, um die Trajektorie von UAV₂ vor und die Trajektorie von UAV₃ nach diesen zu kreuzen.

Die Abbildung 4.13 zeigt ein Beispiel für die resultierende Trajektorie in Szenario 4 ebenfalls unter Verwendung des GR1 Optimierungsverfahrens. Hier weicht das UAV₁ durch Verzögerung mittels einer S-Schleife einer Kollision mit beiden Intruder (UAV₂ und UAV₃) aus. Ein Verzögern durch Reduzierung der Geschwindigkeit ist in diesem Fall nicht möglich, da nur der Rollwinkel als Stellgröße verwendet wird.

In beiden Szenarien ist der Zeitgewinn in Folge der beiden Verfahren *ES3* und *GA3* durch Beschleunigen gering. Die Verteilung von Zeitverlust und minimalen Abstand und deren Korrelationen sind im Anhang B zu finden.

In Szenario 4 werden bei Verwendung des *GR1* Optimierers der Abstand zu einem der Intruder von 20m unterschritten. Dies ist deutlich geringer, als der geringste Abstand in allen anderen Szenarien und mit allen anderen Optimierungsverfahren.

Erklärbar ist dies, da durch die Symmetrie ein Ausweichen zu einer der beiden Seiten das Potenzial zunächst ansteigen lässt. Dies hat wiederum ein lokales Minimum zur Folge. Nur mithilfe des Prädiktionshorizonts ist es dem UAV überhaupt möglich, im Falle des *GR1* Optimierers, eine Kollision mit einem der Intruder zu vermeiden.

Tabelle 4.6: Ergebnisse des Szenario 3 mit einem Prädiktionshorizont von 10s

Optimierer	<i>ES1</i>	<i>GA1</i>	<i>ES3</i>	<i>GA3</i>	<i>GR1</i> ⁴
Kleinster minimaler Abstand [<i>m</i>]	24	24	25	24	28
Mittlerer minimaler Abstand [<i>m</i>]	29,9	30,0	31,6	31,3	28
Mittlerer Zeitverlust [<i>s</i>]	2,4	2,6	1,6	1,5	1,4
Größter Zeitverlust [<i>s</i>]	5,8	5,4	4,5	4,1	1,4

Tabelle 4.7: Ergebnisse des Szenario 4 mit einem Prädiktionshorizont von 10s

Optimierer	<i>ES1</i>	<i>GA1</i>	<i>ES3</i>	<i>GA3</i>	<i>GR1</i> ⁴
Kleinster minimaler Abstand [<i>m</i>]	29	29	25	27	17
Mittlerer minimaler Abstand [<i>m</i>]	30,2	30,4	30,3	30,6	17
Mittlerer Zeitverlust [<i>s</i>]	2,8	2,8	1,9	1,9	2,0
Größter Zeitverlust [<i>s</i>]	3,2	3,2	3,0	2,8	2,0

Bei den vorherigen Szenarien handelte es sich ausschließlich um solche, bei denen sich die Intruder kooperativ im Sinne dessen verhalten, dass sie ihre Position als auch ihre geplante Trajektorie austauschen. Die Intruder selber weichen nicht aus. In einem Schwarm ist zu erwarten, dass sich die anderen Schwarmteilnehmer nicht als Intruder verhalten, sondern ebenfalls ausweichen. Zwei extreme Beispiele hierfür sind in Abbildung 4.14 und 4.15 dargestellt. Simulationen, bei denen alle Schwarmteilnehmer ausweichen, wurden auch für die zuvor beschriebenen Szenarien durchgeführt. Diese sind hier nicht dargestellt, da die Gefahr eines Zusammenstoßens geringer wird, wenn alle Beteiligten einander ausweichen. Jedoch trifft diese Aussage nicht für alle Szenarien und Optimierungsverfahren zu.

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist




Abbildung 4.14: Ergebnis eines Szenarios mit 4 ausweichenden Schwarmteilnehmern mit einem gradientenbasierten Optimierungsalgorithmus (GR1)




Abbildung 4.15: Ergebnis eines Szenarios mit 5 ausweichenden Schwarmteilnehmern mit einem Evolutionsstrategie Optimierungsalgorithmus (ES1)

In Abbildung 4.14 ist ein Szenario dargestellt, in dem vier UAVs mit einem gradientenbasierten Algorithmus (*GR1*) aufeinander zu steuern. Wie zu erkennen ist, bildet sich eine Art „Kreisverkehr“ aus, bei dem sich alle UAVs in eine Richtung entgegen dem Uhrzeigersinn bewegen. In welche der beiden Richtungen (mit oder gegen den Uhrzeigersinn) sich die UAVs bewegen, ist im Fall des *GR1* zufällig. Durch numerische Ungenauigkeiten bzw. minimale Abweichungen der Trajektorien ergibt sich die Richtung der Ausweichbewegung zufällig. Weicht eines der UAVs nur geringfügig in eine der beiden Richtungen aus, so folgen diesem die anderen UAVs, um die beste Lösung zu generieren. Wird ein ähnliches Szenario mit 5 UAVs simuliert, so versagt die Regelung mit einem gradientenbasierten Verfahren. In diesem Fall verhindern bei jedem UAV die beiden Nachbarn ein Ausweichen in eine der beiden Richtungen, da dies in jedem Fall eine Erhöhung des Potentials ähnlich dem Szenario 4 wäre. Bei 4 UAVs handelt es sich um ein instabiles Gleichgewicht. Bei 5 UAVs wandelt sich dies zu einem stabilen Gleichgewicht um, welches ein Ausweichen verhindert. Die Klasse der evolutionären Algorithmen ist jedoch in der Lage, diesen Konflikt zu lösen, da es sich um Verfahren handelt welche zur Lösung von globalen Optimierungsproblemen geeignet sind, die von solchen lokal begrenzten Erscheinungen unbeeinflusst sind. In Abbildung 4.15 ist solch ein Beispiel dargestellt. Wie bei dem Beispiel mit vier UAVs bildet sich auch eine „Kreisverkehr“ ähnlicher Konstellation aus.

Fazit

In diesem Teilkapitel wird anhand von vier unterschiedlichen Szenarien das Ausweichen eines UAVs vor einem anderen oder vor zwei anderen UAVs untersucht. Dabei werden die hier verwendeten Varianten der evolutionären Algorithmen (*ES1*, *GA1*, *ES3*, *GA3*) zueinander wie auch zu den beiden als Referenz verwendeten Algorithmen (*GR1*, *BF1*) bewertet. Als Bewertungskriterien werden der minimale Abstand und der Zeitverlust herangezogen. Bei den nicht deterministischen Algorithmen wird ein Set von 100 Simulationsläufen durchgeführt und die Bewertung anhand der Mittel- bzw. der kritischen Extremwerte vorgenommen.

Mit einer Ausnahme ist in allen Szenarien und bei allen hier untersuchten Optimierungsverfahren der minimale Abstand zu einem der Intruder im Bereich von 24 – 32m. Im Fall des Szenario 4 unter der Verwendung des *GR1* Optimierungsverfahrens ergibt sich ein minimaler Abstand von 17m. Dies ist über dem durch das Potenzialfeld geforderten minimalen Abstand, es zeigt jedoch den Nachteil eines lokalen Optimierungsverfahrens (*GR1*) gegenüber allen anderen hier implementierten Optimierungsverfahren (*ES1*, *GA1*, *ES3*, *GA3*, *BF1*) bei vorhandenen Symmetrien. Noch deutlicher ist dieses Problem der lokalen Optimierungsverfahren (*GR1*) beim sternförmigen Flug mit fünf UAVs. In diesem Fall wird jedes einzelne UAV durch seine beiden Nachbarn, welche symmetrisch zu ihm angeordnet sind, gezwungen die Richtung zu halten. Nur eine Regelung mit einem globalen Optimierungsverfahren (Abbildung 4.15) kann eine Kollision bei symmetrischen Anordnungen der Intruder oder anderen Teilnehmern des Schwarms sicher vermeiden.

Diese Art der Regelung (nichtlineare modellprädiktive Regelung auf der Basis von Potenzialfeldern mit evolutionären Optimierungsalgorithmus) ermöglicht es damit dem UAV statischen Hindernissen wie auch anderen UAVs auszuweichen. Allgemein lässt sich feststellen, dass alle Optimierungsverfahren für diese Szenarien geeignet sind. Das *Brute-Force*-Verfahren (*BF1*) ist aufgrund der erforderlichen Rechenleistung nicht praktikabel und das gradientenbasierte (*GR1*) Verfahren versagte in Extremfällen.

4.3 Ausgewählte Missionsszenarien

4.3.1 Formationsflug als Missionsziel

Bei der Erfassung von 3D-Geländedaten mithilfe der Photogrammetrie werden Fotos derselben Stelle aus unterschiedlichen Positionen benötigt. Eine Formation aus UAVs kann diese Fotos effektiv bereitstellen. Zudem ist die Formation eine einfache Möglichkeit, eine größere Anzahl von UAVs gemeinsam koordiniert eine Strecke zurücklegen zu lassen.

Alle Formationen können in zwei Klassen aufgeteilt werden, starre geometrische und flexible Formationen. Unter starren geometrischen Formationen versteht man Formationen bei denen eine exakte Geometrie eingehalten wird. Dabei sind die Abstände, die Winkel oder die relativen Positionen der UAVs fest vorgegeben. Unter einer flexiblen Formation versteht man eine Formation, bei der mindestens einer dieser Freiheitsgrade variiert werden kann. So können beispielsweise die Abstände der UAVs fest definiert sein, während die Winkel variieren können. Die Formation kann unter dieser Randbedingung variieren, um zusätzliche Randbedingungen, wie das Ausweichen vor Hindernissen, zu erfüllen, ohne die Formation zu verlassen.

Für dieses Szenario werden folgende Gewichtungen der Potenziale zueinander verwendet (Kapitel 3.2.3):

$$\vec{l} = [1 \ 1 \ 1 \ 1 \ 0 \ 0 \ 0]^T \quad (4.6)$$

Dies berücksichtigt die grundlegenden Potenziale, wie die Vermeidung einer Kollision mit Hindernissen, anderen UAVs und die Haltung einer Höhe, die in allen Szenarien in dieser Arbeit aktiv sind. Zusätzlich ist das für dieses Szenario spezifische Potenzial zum Halten einer Formation aktiv.

Starre Formation

In einer starren Formation sollen die UAVs relative Positionen zueinander halten. In diesem Szenario ist das Ziel der Formation einem Wegpunkt (Kreis mit Punkt in der Mitte) möglichst nahe zu kommen und gleichzeitig die Formation zu halten. Das Ziel der UAVs ist in diesem Fall einen Wegpunkt anzufliegen und eine Formation in der Gestalt eines gleichseitigen Dreiecks mit der Seitenlänge d_c zu erreichen bzw. zu halten. In allen simulierten Szenarien halten die UAVs die Formation mit geringen Abweichungen. Einige ausgesuchte Szenarien sind hier dargestellt und deren Ergebnisse werden diskutiert.

Zwei Beispiele von Simulationen einer starren Formation sind in Abbildung 4.16 und 4.17 dargestellt. Hier fliegen drei UAVs in einem definierten Abstand zueinander in der

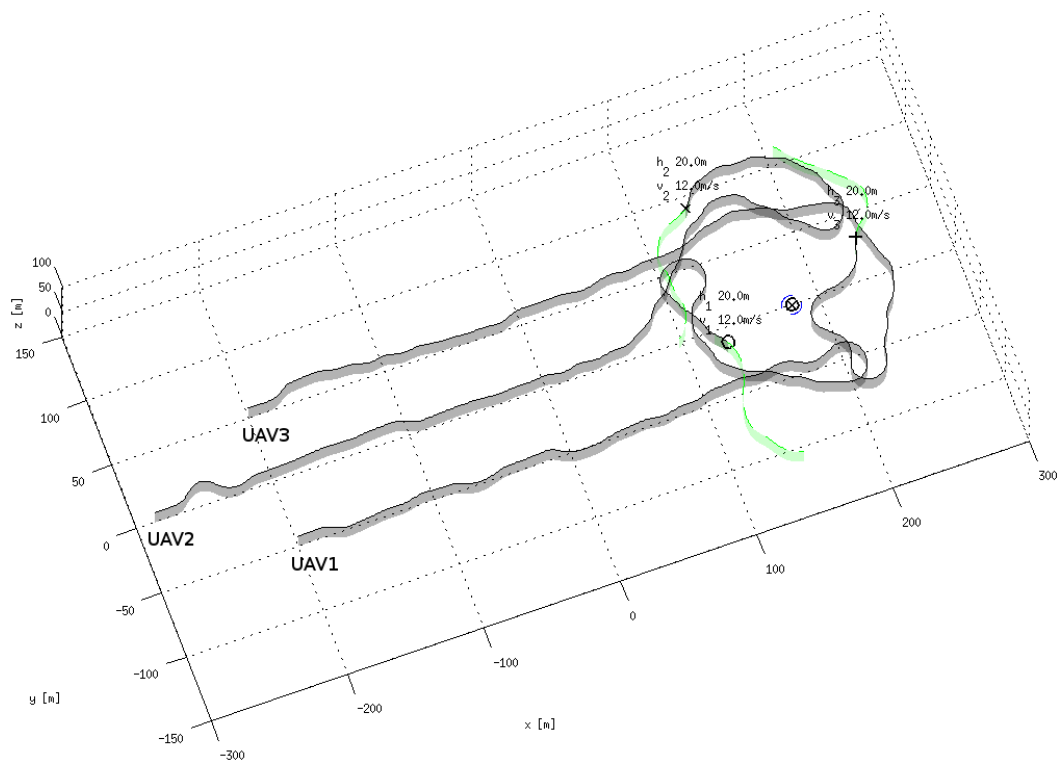


Abbildung 4.16: Beispiel einer starren Formation von drei UAVs ohne Hindernis (ES1)

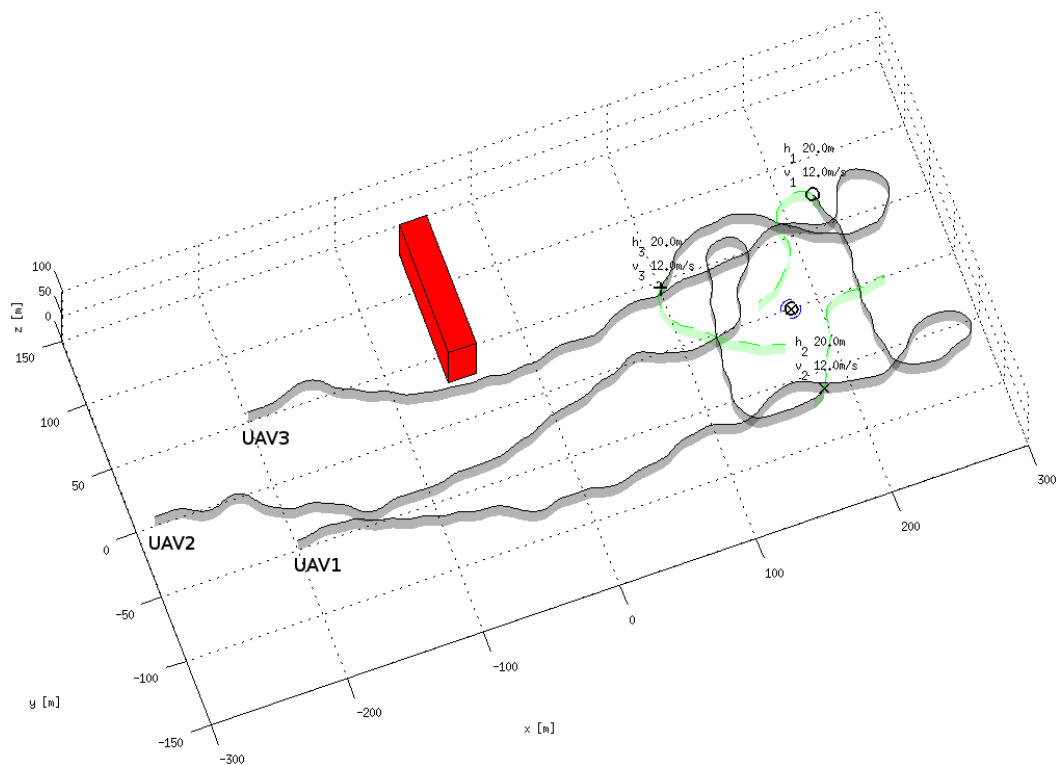


Abbildung 4.17: Beispiel einer starren Formation von drei UAVs mit Hindernis (ES1)




Abbildung 4.18: Abstände der starren Formation ohne Hindernis




Abbildung 4.19: Abstände der starren Formation mit Hindernis

gleichen Höhe.

In Abbildung 4.18 und 4.19 ist der Verlauf der Abstände der UAVs zueinander dargestellt. In beiden Fällen (mit und ohne Hindernis) halten die UAVs den Abstand zueinander mit $100 \pm 10m$.

Die Schwankungen der Abstände sind eine Folge des Evolutionsstrategie (*ES1*), welche unterschiedliche Lösungen während der Simulationszeit generiert. Diese Schwankungen erscheinen dem Betrachter unästhetisch, sie stören aber nicht die Funktion der Regelung.

Durch das Hinzufügen eines Potentials, welches den Steueraufwand bestraft, könnten bei Bedarf diese Schwankungen reduziert werden. Da evolutionäre Algorithmen zur Lösung von globalen Optimierungsproblemen geeignet sind, jedoch weniger effektiv bei der Findung der exakten Lösung sind, kann eine Kombination mit einem weiteren Optimierungsverfahren (Hybride Optimierung) diese Schwankungen weiter reduzieren. Bei der genannten Hybriden Optimierung wird zunächst eine Optimierung mittels eines globalen Optimierungsverfahrens durchgeführt. Das Ergebnis dieser Optimierung dient als Ausgangspunkt für ein lokales Optimierungsverfahren, welches die Lösung weiter verfeinert.

Vergleicht man Abbildungen 4.18 und 4.19 so lässt sich feststellen, dass das Hindernis in Abbildung 4.19 keinen erkennbaren Einfluss auf die Abstände der UAVs untereinander hat. Beim Erreichen des Wegpunkts tritt in beiden Fällen eine kurzzeitige Abweichung des Abstands von ca. 80m auf. Diese Abweichung reduziert sich deutlich nach ca. 10s. Dennoch ist die Abweichung von der gewünschten Formation in beiden Fällen erhöht. Es ist zu erwarten, dass sich nach einer gewissen Zeit eine regelmäßige Struktur der UAVs einstellt und sich die Abweichung von der gewünschten Formation reduziert. Aus Gründen der Übersichtlichkeit ist dieses „Einschwingen“ nicht dargestellt. In beiden Szenarien ist zu erkennen, dass sich alle UAVs am Ende der Simulationszeit auf einem Kreis äquidistant zu den anderen UAVs und zum Wegpunkt in dieselbe Richtung fliegend anordnen.

Flexible Formation

Ein Beispiel einer flexiblen Formation entsteht, wenn nur zu einem einzigen der anderen UAVs ein Abstand d_c eingehalten werden soll. Auch dieses Potential ist in Kapitel 3.2.3 definiert. Die Rahmenbedingungen bleiben bis auf die Initialisierung der UAVs in einer Reihe gleich. Somit befindet sich immer eines der UAVs in einem Abstand von $d_c = 100m$. Diese initiale Konstellation wird gewählt, da sie jene Konstellation darstellt, welche sich nach einiger Zeit bei einem ungestörten Flug einstellt.

In Abbildung 4.22 ist der Verlauf der Abstände der UAVs zueinander für den Fall ohne Hindernis (Abbildung 4.20) gezeigt. Bei diesem Beispiel ist das Ziel, dass mindestens zwei der drei Abstände d_c betragen sollen. Dies ist in dem Fall ohne Hindernis, bis auf die zuvor genannten Schwankungen, der Fall.

Beim Erreichen des Wegpunktes erfolgt eine Umkonfigurierung der Formation, sodass kurzzeitig der Abstand zwischen zwei der UAVs von $d_c = 100m$ auf fast 150m ansteigt. Diese Umkonfigurierung der Formation erfolgt ohne eine Einflussnahme des Systemmanagers. Sie ist das Resultat der Notwendigkeit, die Formation auch nach Erreichen des Wegpunktes zu halten. Während dieser Umkonfigurierung reduziert sich der Abstand zwischen UAV₃ und UAV₁ auf den Wert d_c , sodass sich dieselbe Konstellation, wie bei der starren Formation zuvor, ausbildet. Dies ist zulässig, da auch in diesem Fall zu mindestens einem UAV der Abstand d_c gehalten wird. Das Halten des Abstands d_c ist bei dieser Vor-

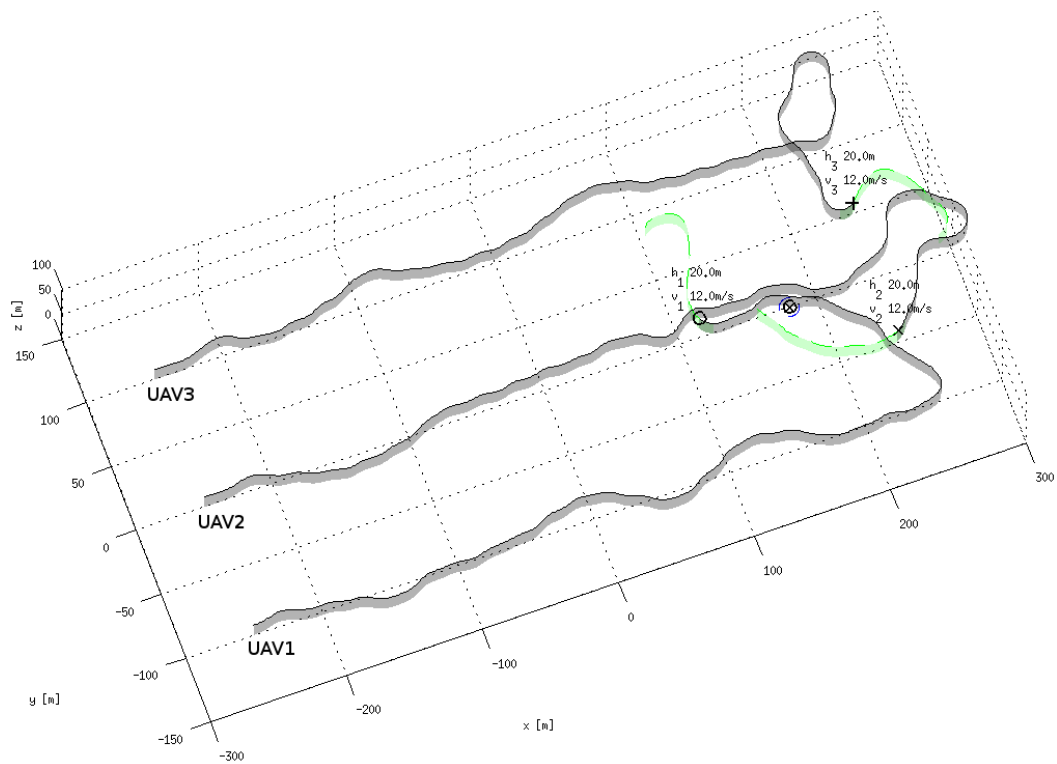


Abbildung 4.20: Flexible Formation von drei UAVs zueinander ohne Hindernis (ES1)




Abbildung 4.21: Flexible Formation von drei UAVs zueinander mit Hindernis (ES1)




Abbildung 4.22: Abstände einer flexiblen Formation von drei UAVs zueinander ohne Hindernis (ES1)




Abbildung 4.23: Abstände einer flexiblen Formation von drei UAVs zueinander mit Hindernis (ES1)

gabe der flexiblen Formation nicht zwingend notwendig, aber auch nicht unerwünscht. Es ist eine mögliche Konstellation der flexiblen Formation. Sollte der Fall eintreten, dass der Abstand zweier UAVs sich deutlich ändert, so sind dennoch die Randbedingungen der Formation erfüllt.

Im Fall der flexiblen Formation mit Hindernis (Abbildung 4.21) ist der Verlauf der Abstände (Abbildung 4.23) nicht exakt wie erwünscht. Gefordert ist auch in diesem Fall,

dass immer mindestens zwei der Abstände der Vorgabe $d_c = 100m$ entsprechen.

Beim Erreichen des Hindernisses tendiert UAV₃ zunächst dazu, das Hindernis mit einer Ausweichbewegung nach links zu umfliegen. Die beiden anderen UAVs folgen ihm und bewegen sich auch nach links, um den gewünschten Abstand $d_c = 100m$ zu halten. Dadurch gerät auch UAV₂ in die Nähe des Hindernisses. Das Ausweichen des UAV₂ vor dem Hindernis erfolgt nach rechts, um die kürzeste Zielführung zu ermöglichen. Dies jedoch bewirkt, dass UAV₃ nun doch das Hindernis mit einer Ausweichbewegung nach rechts umfliegt. Durch diese wechselnde Bewegung entsteht ein Abstand zwischen UAV₃ und den anderen beiden in Richtung des Ziels, welcher nur durch Beschleunigen aufzuholen ist. Da in diesem Szenario nur der Rollwinkel optimiert wird, um den Schwierigkeitsgrad für die Regelung zu erhöhen, kann diese nicht die Geschwindigkeit erhöhen. Die Regelung des UAV₃ reduziert den seitlichen Abstand, sodass ein schräger Abstand von weniger als $130m$ gehalten wird. Beim Erreichen des Wegpunkts wird die gewünschte Konstellation der Formation erreicht und, wie in allen Beispielen zuvor, bildet sich eine Trajektorie äquidistant zum Wegpunkt (Kreis) aus.

Alle zuvor für die Formation durchgeführten Simulationen beruhen auf einem Evolutionsstrategie Optimierungsalgorithmus (*ES1*). Es werden Simulationen für alle hier implementierten Optimierungsalgorithmen durchgeführt. Zum Vergleich ist in Abbildung 4.24 der Verlauf der Trajektorien einer flexiblen Formation bei der Anwendung des gradientenbasierten Optimierungsverfahren *GR1* gezeigt. Der Verlauf der Abstände über der Simulationszeit ist in Abbildung 4.25 gezeigt. Beim Erreichen des Hindernisses erhöht sich nur kurzzeitig der Abstand zwischen zwei UAVs. Die anderen beiden UAVs bewegen sich in diesem Fall in Richtung des UAVs, welches dem Hindernis ausgesetzt ist, um die Formation möglichst schnell wiederherzustellen. Beim Erreichen des Wegpunktes stellt sich kein Kurvenflug ein, da sich eines der UAVs bevorzugt direkt um den Wegpunkt bewegt. Es ist nicht zu erwarten, dass sich schnell eine statische Konstellation einstellt. Grund hierfür ist, dass gradientenbasierte Algorithmen, wie *GR1*, nur zur lokalen Optimierung geeignet sind.

Die größte längerfristige Abweichung (ca. $30m$) des geforderten Sollabstand von $100m$ wird unter Verwendung des *ES1* bei der flexiblen Formation durch das Ausweichen vor dem Hindernis beobachtet. Kurzzeitige Abweichungen (bis zu $90m$) werden bei der festen Formation unter Verwendung des *ES1* Optimierungsalgorithmus beobachtet. Diese kurzzeitigen Abweichungen treten bei allen hier implementierten Optimierungsalgorithmen beim Erreichen des Wegpunktes ein. Das Erreichen des Wegpunktes erfordert eine Rekonfiguration des Schwarms. Der Schwarm wird aus einer linearen Bewegung in Richtung Wegpunkt in eine rotatorische Bewegung der Formation um den Wegpunkt rekonfiguriert. In allen Fällen wird nach dieser Rekonfiguration die Formation wieder erreicht. Bei allen Versuchsanordnungen wird eine Kollision mit dem Hindernis oder anderen UAVs vermieden.




Abbildung 4.24: Flexible Formation von drei UAVs zueinander mit Hindernis (GR1)




Abbildung 4.25: Abstände einer flexiblen Formation von drei UAVs zueinander mit Hindernis (GR1)

Flexible Formation mit mehr als drei UAVs

Die Anzahl der UAVs ist frei wählbar. Zur Verdeutlichung werden Simulationsläufe mit sechs UAVs durchgeführt (Abbildung 4.26). Hierbei handelt es sich um dasselbe Szenario wie zuvor (Abbildung 4.20), aber mit drei weiteren UAVs. Diese drei zusätzlichen UAVs sind in einer Reihe 50m hinter den schon in dem vorherigen Szenario vorhandenen UAVs angeordnet. Somit haben die hinzugefügten UAVs zu den vor ihnen fliegenden UAVs initial mit 50m einen kürzeren Abstand als der hier in der losen Formation geforderte Abstand $d_c = 100m$. Dies ermöglicht eine Betrachtung, wie die Regelung, im Gegensatz zu den vorherigen Beispielen, auf einen initialen Zustand reagiert, welcher nicht der vorgegeben losen Formation entspricht. Es werden mit allen hier implementierten Optimierungsalgorithmen Simulationen dieses Szenarios durchgeführt. In jedem dieser Simulationsläufe wird der Wegpunkt in einer Formation ohne Kollisionen erreicht.

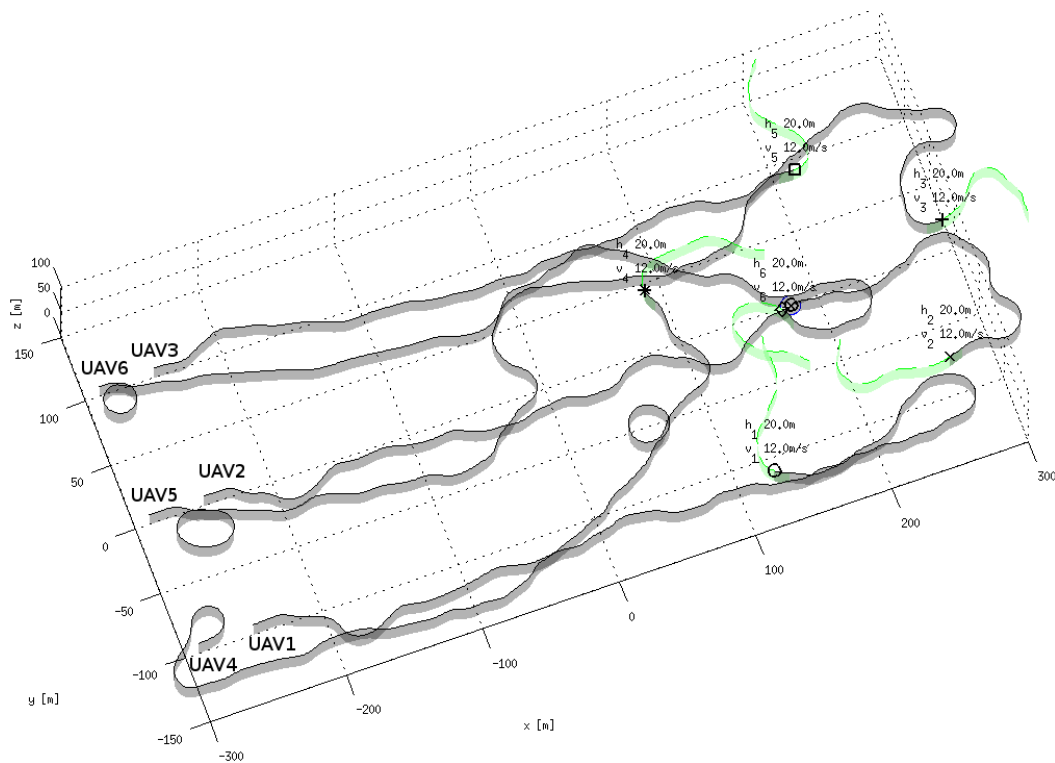


Abbildung 4.26: Flexible Formation von sechs UAVs (ES1)

In Abbildung 4.26 ist zu sehen, dass die nachfolgenden UAVs eine Schleife nach der Initialisierung ziehen, um den gewünschten Abstand zu den vorhergehenden UAVs zu halten. Nach Erreichen des Wegpunktes bildete sich, wie in den anderen Szenarien, andeutungsweise eine kreisförmige Konstellation aus. In diesem Fall jedoch verbleibt ein UAV in der Mitte des Kreises um den Wegpunkt. Es ist anzunehmen, dass es für das UAV in der Mitte des Kreises zu fliegen günstiger ist, als sich in den Kreis um den Wegpunkt einzureihen. Wenn sich dieses UAV einreihen würde, dann würde der Radius des Kreises

und somit der Abstand für ihn, als auch für jedes andere UAV, zum Wegpunkt vergrößern. Dieses Szenario zeigt, dass die Anzahl der UAVs erhöht werden kann ohne, dass sich Zusammenstöße ereignen oder die Aufgabe nicht erfüllt wird.

Flexible Formation mit extrem unterschiedlichen Geschwindigkeiten

Wird eine Formation aus UAVs gebildet, deren vorgegebenen Geschwindigkeiten sich extrem voneinander unterscheiden, müssen die verschiedenen Fähigkeiten der UAVs, die Formation zu halten, unterschiedlich berücksichtigt werden. Ein sehr langsames UAV kann weitaus weniger Einfluss auf das Halten der Formation nehmen als ein sehr schnelles. Dies kann mithilfe von unterschiedlichen Potenzialen abhängig von der Flugeschwindigkeit geschehen.

Eine weitaus elegantere Lösung für dieses Problem ist, die Potenziale entsprechend des Quotienten der Geschwindigkeit zu gewichten. Dies ermöglicht es, ein korrigiertes Potenzial (Φ_{forV}) ausgehend von dem Potenzial zur Haltung einer Formation (Φ_{for}) zu berechnen.

$$\Phi_{forV}(i, j) = \left(\frac{V_i}{V_j} \right)^a \Phi_{for}(i, j) \quad (4.7)$$

V_i ist die Eigengeschwindigkeit des UAVs i . V_j ist die Geschwindigkeit des UAV j und a ermöglicht ein Abschwächen ($a < 1$) oder Überkompensieren ($a > 1$) der Anpassung für das Potenzial der Abstände Φ_{for} zwischen den einzelnen UAVs. Zur Demonstration dieser Anpassung werden zwei UAVs mit erheblichem Geschwindigkeitsunterschied mit der Aufgabe beauftragt, einen weit entfernten Wegpunkt zu erreichen, unter der Randbedingung einen Abstand d_c zu halten (Abbildung 4.27). Die Geschwindigkeit des schnellen UAVs beträgt das sechsfache der Geschwindigkeit, des langsameren. Durch die Berücksichtigung der unterschiedlichen Möglichkeiten der beiden UAVs die Formation zu halten, erreichen beide UAVs zusammen in der flexiblen Formation den Wegpunkt. Das Ergebnis ist eine Trajektorie, bei der das schnellere UAV um das langsamere kreist. Dies ist die effektivste mögliche Trajektorie, um den gewünschten Abstand d_c während des gesamten Fluges zu halten. Als menschlicher Betrachter ist diese Trajektorie offensichtlich. Der Regelung wird aber nicht diese Trajektorie vorgegeben, sondern nur die Randbedingung der Formation den Abstand d_c zueinander zu halten. Sie ist somit nur das Ergebnis dieser Vorgabe.

Die Regelung mithilfe eines gradientenbasierten Verfahrens versagt bei diesem Szenario. Grund hierfür ist, dass keine stetige Monotonie des zu optimierenden Potenzials existiert. Für die Regelung solcher komplexer Aufgaben kann dabei nur ein Optimierungsverfahren wie *ES* oder *GA* verwendet werden.




Abbildung 4.27: Flexible Formation mit der Randbedingung einen konstanten Abstand zu halten (ES1)

Fazit

In diesem Teilkapitel werden Beispiele von starren und flexiblen Formationen mit und ohne Hindernisse untersucht. Die Bewertung, ob eine Formation gehalten wird oder nicht, kann nur durch eine Definition dieser, abhängig von der Aufgabe, die durch die Formation erfüllt werden soll, erfolgen. Da in diesen Fällen keine konkrete Aufgabe vorgegeben ist, außer der abstrakten Aufgabe die Formation zu halten, kann keine sinnvolle Grenze definiert werden, in wie weit eine Formation gehalten wird. Aus diesem Grund werden die Szenarien ausschließlich qualitativ betrachtet.

Die auftretenden Abweichungen von der erwünschten Formation lassen sich in allen Fällen plausibel erklären. Auch bildet sich in nahezu allen simulierten Beispielen eine intelligente Lösung, um die Formation zu erreichen bzw. zu halten. Beispiel hierfür ist unter anderem das kontinuierliche Kreisen des schnelleren UAV um das langsamere UAV der Formation. Bei extremen Geschwindigkeitsunterschieden, wie in diesem Beispiel, müssen somit die unterschiedlichen Möglichkeiten der einzelnen UAVs eine Formation zu halten berücksichtigt werden. Eine Möglichkeit, welche diese Anpassung erlaubt, wird aufgezeigt. Die resultierende Trajektorie der UAVs stellt die optimale Lösung dar, in welcher die Anforderungen der Formation für den gesamten Flug gehalten wird. In keinem der Szenarien erfolgt ein Zusammenstoß mit einem Hindernis oder einem anderen Teilnehmer der Formation.

4.3.2 Wegpunkte als Missionsziel

Eine weitere häufige Aufgabenstellung für UAVs oder einen Schwarm von UAVs ist das Abfliegen von Wegpunkten. Mehrere Wegpunkte in einer nicht spezifizierten Reihenfolge zu erreichen und jeden Wegpunkt dabei nur einmal zu besuchen, wird auch als Rundreiseproblem oder Problem des Handelsreisenden bezeichnet. Ziel ist es, die zurückgelegte Strecke zu minimieren. Diese ist gleichbedeutend mit der Minimierung der dafür nötigen Zeit, unter der Voraussetzung, dass die Geschwindigkeit konstant ist. Um die Komplexität für die analytische Betrachtung in Grenzen zu halten, wird der minimale Kurvenradius des UAVs vernachlässigt. In diesem Fall kann das Ergebnis als untere Schranke betrachtet werden.

Für dieses Szenario werden folgende Gewichtungen der Potenziale zueinander verwendet (4.11) (Kapitel 3.2.3).

$$\vec{l} = [1 \ 1 \ 1 \ 0 \ 0 \ 1 \ 0]^T \quad (4.8)$$

Dies berücksichtigt die grundlegenden Potenziale wie die Vermeidung einer Kollision mit Hindernissen, anderen UAVs und die Haltung einer Höhe, die in allen Szenarien in dieser Arbeit aktiv sind. Zusätzlich ist das für dieses Szenario spezifische Potenzial zum Anfliegen von Wegpunkten aktiv.

Analytische Betrachtung mit einem UAV ohne Hindernisse

Ist der Start einer der Wegpunkte, so ist die Anzahl der Lösungsmöglichkeiten wie folgt [ABCC01] definiert:

$$(n - 1)! \quad (4.9)$$

Ist der Start kein Wegpunkt, so ist die Anzahl der Lösungsmöglichkeiten wie folgt [ABCC01] definiert:

$$n! \quad (4.10)$$

Für $n = 10$ (Anzahl der Wegpunkte) existieren 3.628.800 mögliche Lösungen. Die optimale Lösung lässt sich in diesem Fall sehr einfach mit der *Brute-Force*-Methode in relativ kurzer Zeit lösen. In Abbildung 4.28 ist für solch einen Fall die optimale Lösung dargestellt. Die akkumulierte Distanz beträgt 1932m. Dies entspricht bei einer angenommenen konstanten Fluggeschwindigkeit von $12 \frac{m}{s}$, bei den Optimierungsverfahren *ES1*, *GA1*, *GR1* und *BF1*, einer Flugzeit von 161s. Bei den beiden Optimierungsverfahren *ES3* und *GA3* kann das UAV die Fluggeschwindigkeit in Grenzen variieren. Bei einer maximalen Fluggeschwindigkeit von $\sqrt{2} \cdot 12 \frac{m}{s}$ (Kapitel 3.2.1) - bei den beiden Optimierungsverfahren *ES3* und *GA3* - beträgt die minimale Flugzeit 114s. Diese minimale Flugzeit stellt das

theoretische Minimum bei den entsprechenden Optimierungsverfahren dar. Ein reales UAV (mit einem Kurvenradius > 0) benötigt mehr Zeit, um die Aufgabe zu lösen.

Simulation mit einem UAV ohne Hindernisse

Die Abbildung 4.29 bildet das gleiche Szenario ab wie Abbildung 4.28. Auch hier wird die Fluggeschwindigkeit und Flughöhe konstant gehalten. In diesem Fall handelt es sich um eine Simulation mit einem genetischen Optimierer (GA1). Tabelle 4.8 zeigt die mittleren Flugzeiten, die zur Erfüllung der Aufgabe mit verschiedenen Optimierungsverfahren der MPC nötig sind. Die Berechnung des Mittelwerts erfolgt aus 20 Simulationsläufen pro Optimierungsverfahren.




Abbildung 4.28: Ergebnis der analytischen Betrachtung

Tabelle 4.8: Simulationsergebnisse für das in Abbildung 4.28 dargestellte Szenario mit verschiedenen Optimierungsalgorithmen

Optimierer	ES1	GA1	ES3	GA3	GR1 ⁴
Maximale Zeit [s]	203	204	183	177	∞
Durchschnittliche Zeit [s]	177	179	162	159	∞
Minimale Zeit [s]	165	163	144	147	∞

Die resultierenden Zeiten der Simulation sind nur wenig größer als das zuvor berechnete theoretische Optimum von 161s. Ein Übereinstimmen der Reihenfolge mit dem theoretischem Ergebnis (Abbildung 4.28) wäre zufällig, da der zeitliche Horizont für die Optimierung in diesem Beispiel 10s beträgt. Um das theoretische Optimum erreichen zu können, müsste neben anderen Randbedingungen der Prädiktionshorizont mindestens

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist




Abbildung 4.29: Exemplarisches Ergebnis eines genetischen Optimierers (GA1)

161s betragen. Ein solcher Prädiktionshorizont erfordert extreme Rechenleistung sowie Sensoren und Modelle, die für diesen Zeitraum eine Prädiktion erlauben.

Das zuvor verwendete Szenario wird nun erweitert mit zufällig platzierten Hindernissen. Tabelle 4.9 zeigt die Ergebnisse der Simulationen mit Hindernissen (Abbildung 4.30).

Tabelle 4.9: Simulationsergebnisse für das in Abbildung 4.30 dargestellte Szenario mit verschiedenen Optimierungsalgorithmen und Hindernissen

Optimierer	ES1	GA1	ES3	GA3	GR1 ⁴
Maximale Zeit [s]	217	237	232	250	∞
Durchschnittliche Zeit [s]	196	205	198	192	∞
Minimale Zeit [s]	185	186	182	170	∞

Der gradientenbasierte Optimierungsalgorithmus liefert in anderen Szenarien konstante und meist auch bessere Ergebnisse. Allerdings sind Richtungsänderungen mit Hindernissen problematisch, da ein daraus entstehendes lokales Minimum zumindest in die Richtung des globalen Minimums nicht verlassen werden kann. Dieses Problem ist weitaus weniger problematisch als lokale Minima die zum Scheitern der Mission führen. In Abbildung 4.30 ist ein Beispiel gezeigt, bei dem sich das UAV fortlaufend von der eigentlichen Aufgabe entfernt. Durch eine ungeschickte Lage von Wegpunkten und Hindernissen ergibt sich ein lokales Minimum, welches mithilfe eines gradientenbasierten Optimierungsalgorithmus nicht verlassen werden kann. Bei der Verwendung eines Evolutionsstrategie Optimierungsalgorithmus (Abbildung 4.31) ist dies nicht der Fall.

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist




Abbildung 4.30: Anfliegen von mehreren Wegpunkten mithilfe eines gradientenbasierten Optimierungsalgorithmus

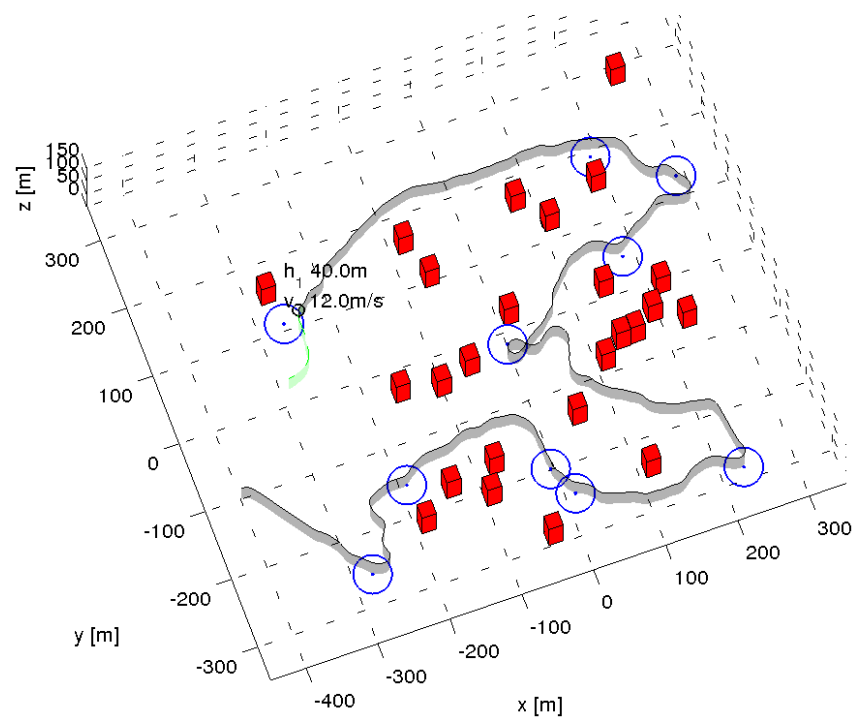


Abbildung 4.31: Anfliegen von mehreren Wegpunkten mithilfe eines genetischen Optimierungsalgorithmus

Anwendung eines Schwarms für das Abfliegen von Wegpunkten

Ein Schwarm von drei UAVs löst nun dieselbe Aufgabe wie zuvor. Wie zu erwarten ist, benötigen drei UAVs deutlich weniger Zeit als ein einzelnes UAV. Die kürzeste gemessene Zeit mit einem einzelnen UAV bei konstanter Geschwindigkeit beträgt im vorherigen Szenario 163s. Mit 64s (Tabelle 4.10) benötigen die drei UAVs nun etwas mehr als $\frac{1}{3}$ der Zeit eines einzelnen UAVs. Dies ist nicht generalisierbar, da die Aufteilung abhängig vom Szenario ist.




Abbildung 4.32: Szenario mit mehreren Wegpunkten, die jeweils einmal von einem UAV überflogen werden sollen (GR1)

Tabelle 4.10: Simulations-Ergebnisse für das in Abbildung 4.32 abgebildete Szenario mit unterschiedlichen Optimierungsalgorithmen

Optimierer	ES1	GA1	ES3	GA3	GR1 ⁴
Maximale Zeit [s]	81	84	82	76	86
Durchschnittliche Zeit [s]	77	78	71	69	86
Minimale Zeit [s]	75	72	64	64	86

In Abbildung 4.32 ist die resultierende Trajektorie einer gradientenbasierten Regelung beispielhaft dargestellt. UAV₁ wählt in diesem Beispiel den Weg zum nächstgelegenen Wegpunkt. Das UAV₂ muss folglich auf einen weiter entfernten Wegpunkt ausweichen.

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist

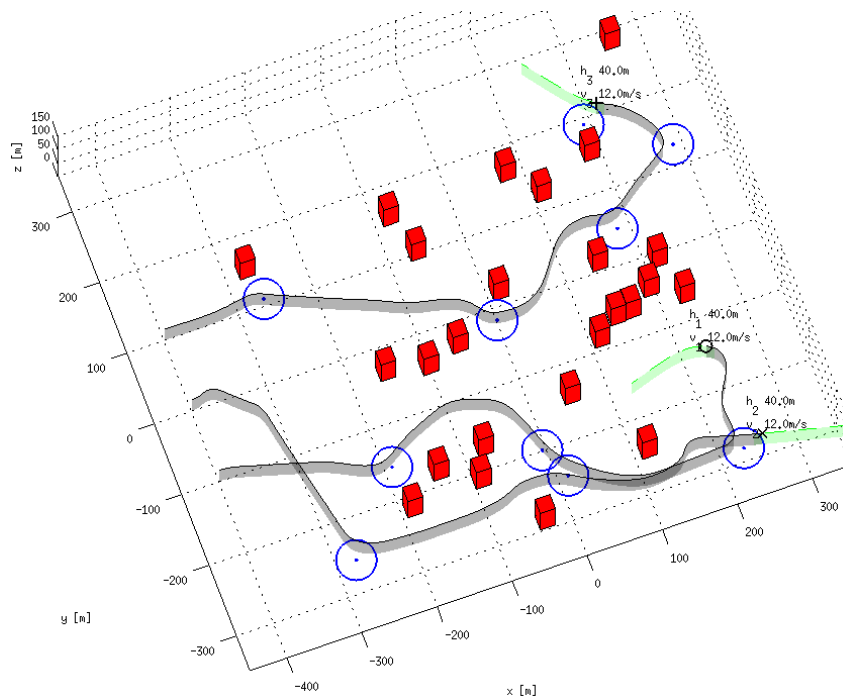


Abbildung 4.33: Szenario mit Hindernissen und mehreren Wegpunkten, die jeweils einmal von einem UAV überflogen werden sollen (GR1)

Daraus resultiert eine ca. 15s längere Flugzeit zur Erfüllung der Aufgabe. Globale Optimierer können solche Aufgaben besser lösen (Tabelle 4.10), da sie in der Lage sind, ein lokales Minimum zu umgehen. Selbst die maximalen Zeiten der globalen Algorithmen sind alle geringer, als die Zeit mit einem gradientenbasierten Optimierer.

Wie im Fall des Wegpunktszenarios mit einem UAV und Hindernissen, ist hier eine Berechnung der theoretisch möglichen Zeit nur mit extremem Aufwand möglich, da der zu berechnende Graph zu einem Sichtbarkeitsgraph (Kapitel 2.4.3) erweitert werden muss. Die untere Schranke für dieses Szenario muss der unteren Schranke ohne Hindernisse entsprechen oder größer als diese sein.

Die Hindernisse haben auf die benötigte Zeit einen geringfügigen Einfluss (Tabelle 4.11). Unerwarteterweise benötigt die gradientenbasierte Regelung mit Hindernissen weniger Zeit als ohne Hindernisse. Denn in diesem Fall bewirken die Hindernisse, dass die Aufteilung der Wegpunkte günstiger erfolgt (Abbildung 4.33). Dies beruht jedoch auf Zufall durch die Anordnung der Hindernisse und kann nicht als allgemein gültig angesehen werden. Die zufällig gewählte Anordnung der Hindernisse verursacht, dass UAV₂ den Wegpunkt in der oberen rechten Ecke bei (190|190) nicht ansteuert. Da UAV₂ gegen Ende der Mission den anderen UAVs nun nicht mehr mitteilt, dass es erwartet diesen Wegpunkt innerhalb seines Prädiktionshorizonts anzufliegen, ermöglicht es dabei UAV₃ diesen Wegpunkt anzufliegen. Durch die kurze Flugzeit für UAV₃ zwischen dem letzten und vorletzten Wegpunkt, werden alle Wegpunkte in einer etwas kürzeren Zeit erreicht,

als dies ohne Hindernisse der Fall ist.

Tabelle 4.11: Simulationsergebnisse für das in Abbildung 4.33 abgebildete Szenario mit unterschiedlichen Optimierungsalgorithmen

Optimierer	<i>ES1</i>	<i>GA1</i>	<i>ES3</i>	<i>GA3</i>	<i>GR1</i> ⁴
Maximale Zeit [s]	87	83	79	78	72
Durchschnittliche Zeit [s]	80	80	71	71	72
Minimale Zeit [s]	76	77	66	66	72

Mit Ausnahme des gradientenbasierten Algorithmus liefern somit alle Optimierungsverfahren konstant gute Ergebnisse ohne eine Kollision. Die gradientenbasierte Regelung benötigt in dem Szenario mit Hindernissen signifikant weniger Zeit, erfüllt aber in beiden Fällen die Aufgabe. Die Position der Hindernisse verursacht, dass die Aufteilung der Wegpunkte unter den UAVs zufälligerweise besser ist als ohne Hindernisse.

Fazit

In allen Szenarien werden mit Ausnahme des gradientenbasierten Optimierungsverfahrens bei der Verwendung eines UAVs alle Wegpunkte erreicht. In allen Simulationsläufen benötigt das UAV zum Abfliegen aller Wegpunkte weniger als 27% mehr Zeit als die theoretisch mögliche minimale Zeit. Dies ist der Fall, obwohl der Prädiktionshorizont deutlich kürzer ist, als der für das Optimum nötige.

Bei der Verwendung von drei UAVs zur Erfüllung dieser Aufgabe führen alle Optimierungsverfahren zu einer Lösung. Da jedes UAV nur drei bis vier Wegpunkte anfliegen muss, ist diese Aufgabe weniger komplex für das einzelne UAV. So kann selbst die Regelung mit dem gradientenbasierten Optimierungsverfahren *GR1* die Aufgabe lösen. In diesem Fall beträgt die Differenz zwischen der maximalen und minimalen Zeit 20% der Zeit bei Simulationsläufen mit konstanter Geschwindigkeit. In keinem der Szenarien erfolgt ein Zusammenstoß mit einem Hindernis oder einem anderen Teilnehmer.

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist

4.3.3 Identifikation eines Skalarfeldes als Missionsziel

Die Identifikation eines Skalarfeldes ist eine mögliche Anwendung, um die Regelung eines Schwarmes zu untersuchen. Ein vereinfachtes Ausbreitungsmodell einer Schadstoffwolke wird hier als Beispiel für ein Skalarfeld verwendet (Kapitel 3.3.1). Für dieses Szenario werden folgende Gewichtungen der Potenziale zueinander verwendet (Kapitel 3.2.3):

$$\vec{l} = [1 \ 1 \ 1 \ 0 \ 1 \ 0 \ 0]^T \quad (4.11)$$

Diese hier genutzte Gewichtung \vec{l} berücksichtigt die grundlegenden Potenziale, wie die Vermeidung einer Kollision mit Hindernissen bzw. anderen UAVs sowie die Haltung einer bestimmten Höhe, die in allen Szenarien in dieser Arbeit aktiv sind. Zusätzlich ist das für dieses Szenario spezifische Potenzial zur Identifikation eines Skalarfeldes aktiv.

Die Abbildung 4.34 zeigt ein Beispiel für die Schätzung der Parameter (4.12) des Skalarfeldes mit einem einzelnen UAV. Ziel des UAVs ist es, die Parameter des Skalarfeldes anhand von lokalen Messungen an der jeweiligen Position zu bestimmen, um auf einer Linie gleicher Magnitude des Skalars zu fliegen, wenn diese erreicht ist. Der Parametervektor \vec{x} besteht aus dem Diffusionskoeffizient a_{pol} und der Position der Schadstoffquelle (x_{pol} / y_{pol}):

$$\vec{x} = [a_{pol} \ x_{pol} \ y_{pol}]^T \quad (4.12)$$

Der gestrichelte Kreis in Abbildung 4.34 stellt diese Linie mit konstanter Magnitude des Skalarfeldes dar, welche erreicht werden soll. Im Fall einer Schadstoffwolke ist das die Ziel-Konzentration c_c des Schadstoffes. Für das UAV ist diese Linie unbekannt. Sie ist nur zur Kontrolle für den Betrachter dargestellt. Die kleinen Kreise markieren den Mittelpunkt bzw. die Quelle der geschätzten Schadstoffwolke zum jeweiligen Zeitpunkt. Zur besseren Darstellung der Reihenfolge der geschätzten Quelle sind diese entsprechend der Reihenfolge miteinander verbunden. Das zur Schätzung der Parameter verwendete Modell ist in Kapitel 3.3.1 erläutert. Es ist eine abstrakte Modellierung einer idealen Gasausbreitung ohne Windeinfluss. Diese ist ausreichend, um die Fähigkeiten der Regelung zu demonstrieren. Zur besseren Übersicht wird hier zunächst der Fall mit einem UAV, welches die Schätzung einer Schadstoffwolke in einer Umgebung mit Hindernissen durchführt, dargestellt. Folglich nimmt die Schätzung der Parameter des Skalarfeldes längere Zeit in Anspruch, als es im Fall eines Schwarms wäre. In einem Schwarm sollte dies deutlich schneller erfolgen, da die Anzahl der Messungen mit der Anzahl der Schwarmteilnehmer steigt.

Für die Zustände des Schadstoffmodells, des in Abbildung 4.34 dargestellten Szenarios, werden folgende Werte verwendet:

$$\vec{x} = [0.01 \ 180 \ 0]^T \quad (4.13)$$

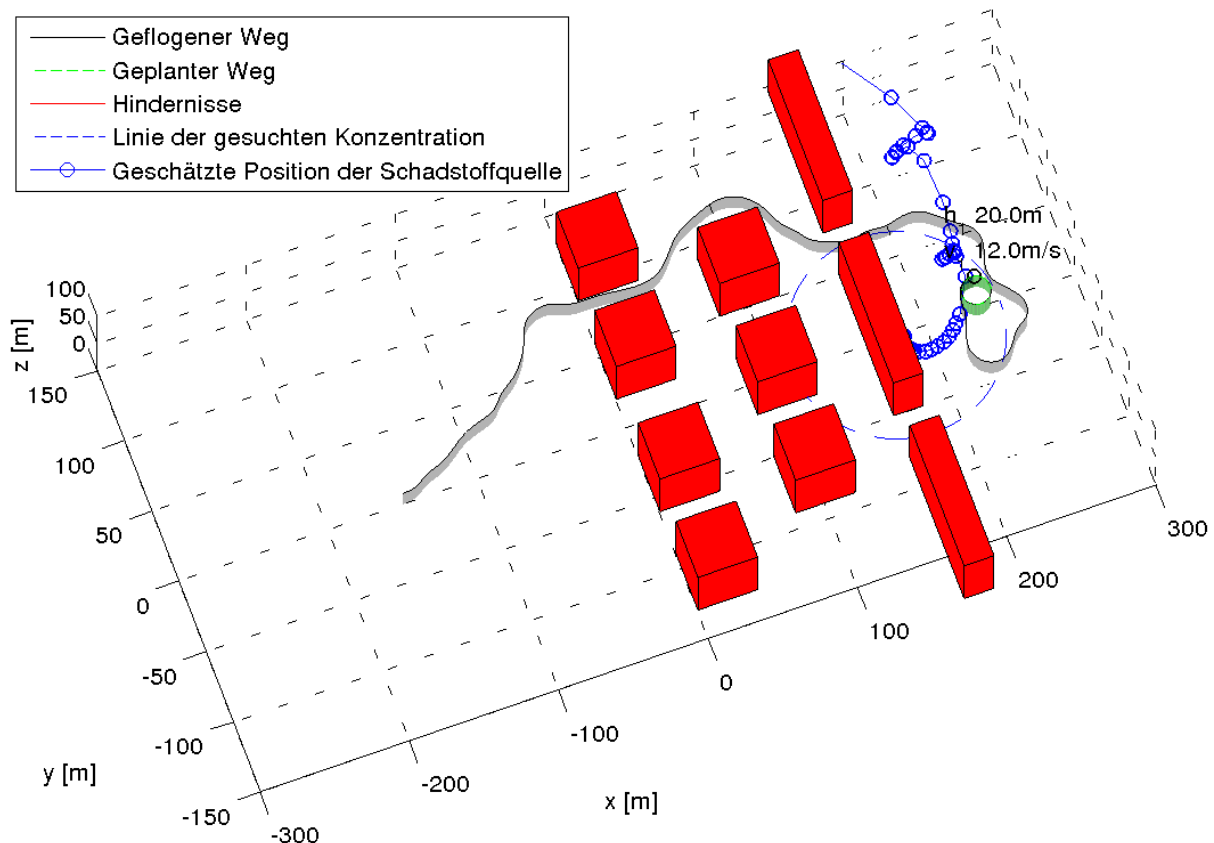


Abbildung 4.34: Beispiel zur Veranschaulichung der Schätzung eines Skalarfelds mithilfe eines einzelnen UAVs basierend auf einem Evolutionstrategie Optimierungsalgorithmus (ES1)

Um einen Eindruck zu erhalten wie sich die Schätzung der Modellparameter des Skalarfeldes auf die Regelung auswirkt, werden im Folgenden Simulationsergebnisse ohne und mit Schätzung des Skalarfeldes verglichen. Ohne Schätzung des Skalarfeldes bedeutet in diesem Fall, dass das gesamte Skalarfeld bekannt ist.

Szenario ohne Schätzung mit bekanntem Skalarfeld

Ein vollständig bekanntes Skalarfeld würde eine Prädiktion des kompletten Flugweges für den gesamten Schwarm im Voraus ermöglichen. Diese kann in der Realität aber nicht vorausgesetzt werden und würde auch dem Ziel der Regelung (dem Vermessen eines unbekanntes Skalarfeldes) widersprechen. Deshalb soll dieses Szenario den Unterschied zwischen der Regelung mit und ohne bekanntem Skalarfeld zeigen. Damit kann der Einfluss der Schätzung des Skalarfeldes, die nicht primär das Ziel der Arbeit ist, für diese Anwendung qualitativ erfasst werden.

Bei der Verwendung eines gradientenbasierten Optimierers, wie *GR1*, würde man ein Ergebnis erwarten, welches symmetrisch zur x -Achse ist, da die initiale Anordnung symmetrisch ist und es sich um ein deterministisches Optimierungsverfahren handelt.

Dies ist in Abbildung 4.35 nicht der Fall. Anfangs verhalten sich die UAVs symmetrisch, kurz vor dem Ziel weicht jedoch eines der UAVs nach rechts aus. Alle UAVs versuchen auf dem kürzesten Weg, dasselbe Ziel zu erreichen. Zugleich versuchten sie, den Abstand zueinander nicht zu reduzieren. Dies erhöht für die inneren UAVs die Wahrscheinlichkeit, dass eine geringfügige Abweichung vom Optimum zu einer alternativen Lösung führt. In diesem Fall handelt es sich um ein Ausweichen eines UAVs nach rechts.

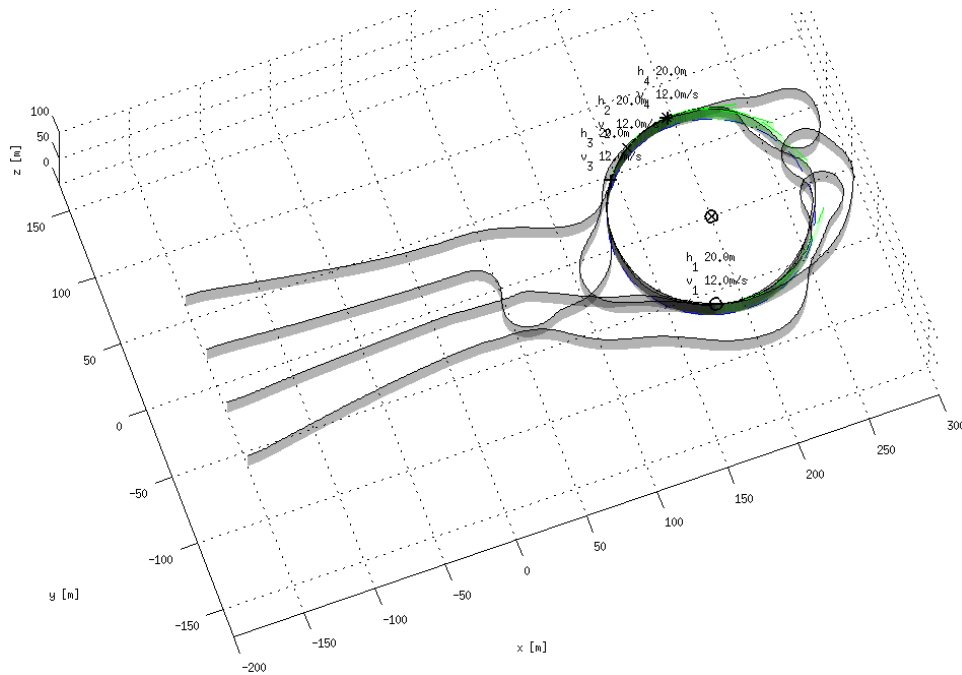


Abbildung 4.35: Vier UAVs in einem bekannten Skalarfeld ohne Hindernisse mit einem gradientenbasierten Optimierer (GR1)

Durch die beschränkte Genauigkeit der numerischen Berechnung des gradientenbasierten Optimierungsverfahrens ergibt sich eine extrem geringe Abweichung von der symmetrischen Trajektorie des Schwarms. Diese unsymmetrische Anordnung der UAVs bewirkt, zusammen mit dem steigenden Bedürfnis der UAVs einander auszuweichen, eine Ausweichbewegung. Andere Optimierungsverfahren beinhalten eine zufällige Komponente, welche zu einer unsymmetrischen Trajektorie führen. In Abbildung 4.36 ist ein Beispiel visualisiert.

Im Gegensatz zu Abbildung 4.36 verhalten sich die UAVs, bis auf die zuvor beschriebene Ausnahme in Abbildung 4.35, symmetrisch zur X-Achse. Dies bedeutet auch, dass sich die UAVs nicht anordnen können, um in der selben Richtung die Schadstoffquelle auf der entsprechenden Konzentrationslinie zu umkreisen, wie dies in Abbildung 4.36 mit einem *ES1* Optimierer nach einer kurzen Anpassungsphase der Fall ist. Wie zuvor in anderen Beispielen bereits dargestellt sind die evolutionären (*ES1/3,GA1/3*) Optimierungsalgorithmen in der Lage, die Trajektorien entsprechend anzupassen. Dies ist auch der Fall, wenn ein kurzzeitiges Verlassen des Optimums nötig ist, um insgesamt ein




Abbildung 4.36: Vier UAVs in einem bekannten Skalarfeld ohne Hindernisse mit einem Evolutionsstrategie Optimierer (ES1)

besseres Ergebnis zu erreichen. Das bessere Ergebnis in diesem Fall ist, dass die UAVs ohne Unterbrechung (ohne einem entgegenkommenden UAV ausweichen zu müssen) auf der Linie der gleichen Schadstoffkonzentration fliegen können.

Szenario mit Schätzung und unbekanntem Skalarfeld

In Abbildung 4.37 ist das gleiche Szenario darstellt, wie in der vorherigen Abbildung 4.36. Im Unterschied zur vorherigen ist das Skalarfeld hier unbekannt. Die Parameter des Skalarfeldes werden anhand von Messungen der einzelnen UAVs bestimmt.

Für die Parameterschätzung mit einem EKF werden folgende Werte verwendet (Kapitel A).

Initialer Zustand

$$\vec{x}_0 = [0.1 \quad -250 \quad 0]^T \quad (4.14)$$

Realer Zustand

$$\vec{x} = [0.01 \quad 200 \quad 0]^T \quad (4.15)$$

Kovarianz des Prozess-Rauschens Q

$$Q = \begin{bmatrix} 10^{-4} & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 10 \end{bmatrix} \quad (4.16)$$

Kovarianz des Mess-Rauschens R

$$R = 10^{-3} \quad (4.17)$$

Die initiale Fehler-Kovarianz P_0^-

$$P_{k-1} = \begin{bmatrix} 10^{-4} & 0 & 0 \\ 0 & 10^4 & 0 \\ 0 & 0 & 10^4 \end{bmatrix} \quad (4.18)$$

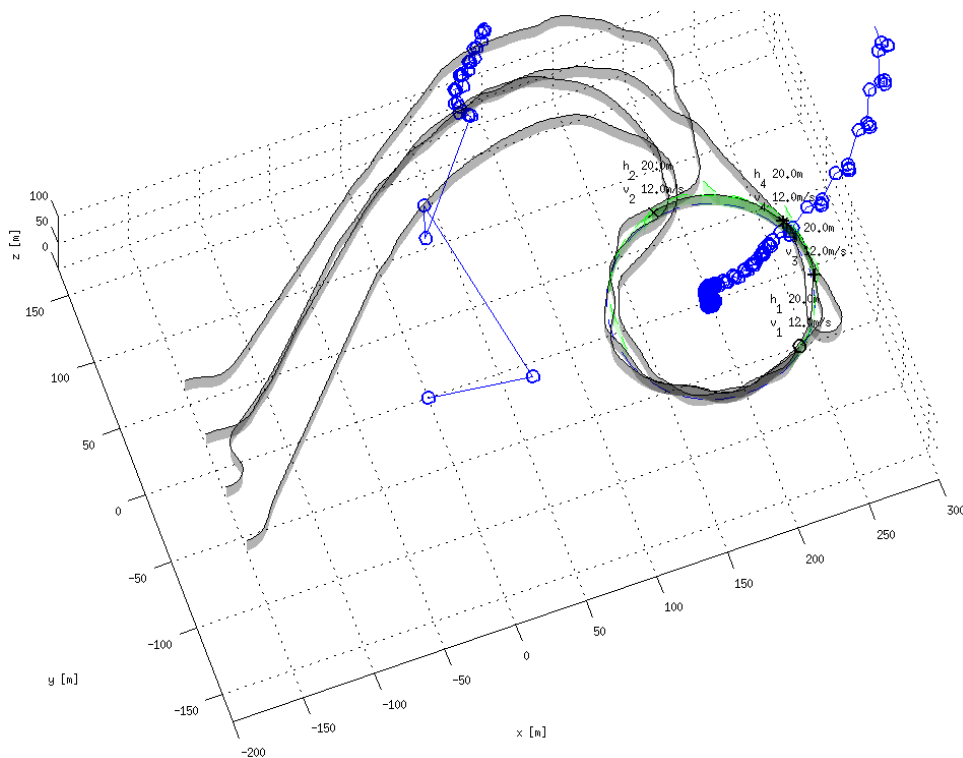


Abbildung 4.37: Vier UAVs in einem unbekanntem Skalarfeld ohne Hindernisse mit einer Evolutionsstrategie Optimierung (Schätzung des Skalarfeldes anhand der Messungen mit einem Kalmanfilter)

Zusätzlich ist die Positionsschätzung der (Schadstoff-)Quelle des Skalarfeldes dargestellt. Die einzelnen Schätzungen (kleine Kreise) werden zur Verdeutlichung der Reihenfolge miteinander verbunden. Jedes der UAVs liefert eine Messung pro Sekunde. In diesem Fall (mit vier UAVs) erfolgen in jeder Sekunde vier Updates. Da angenommen wird, dass sich die realen Parameter nicht oder vergleichsweise nur sehr langsam verändern, ist die Reihenfolge der Updates unerheblich.

Abhängig von den anfänglichen Parametern zeigen sich ähnliche Charakteristika der Schätzung. Die Wahl der initialen Positionsschätzung hat einen starken Einfluss auf die Flugbahn sowie die Zeit, die benötigt wird, um die Quelle zu bestimmen.

Szenario mit bekanntem Skalarfeld und Hindernissen

Um die Aufgabe für die UAVs schwieriger zu gestalten und die Grenzen der Regelung zu bestimmen, werden zusätzlich Hindernisse eingefügt. Sie bestehen aus Quadern, die in mehreren Reihen angeordnet sind. Die Abstände sind so gewählt, dass nur jeweils ein UAV in der vorgegebenen Höhe zwischen den Hindernissen durchfliegen kann.

Des Weiteren werden die Hindernisse versetzt zueinander angeordnet, sodass die Lücken zwischen den Hindernissen nicht in einer Reihe liegen. Zusätzlich werden die UAVs durch die Vorgabe der Potenziale gezwungen, in der gleichen Höhe zu fliegen. Dies ist nicht unbedingt realitätsnah. Es ermöglicht aber, die Vorteile dieser Regelung unter schwierigsten Bedingungen darzustellen.

Die Abbildung 4.38 zeigt ein Beispiel mit einem bekannten Skalarfeld und mit einem Evolutionsstrategie Optimierer. Der gradientenbasierte Optimierer versagt in diesem Beispiel.




Abbildung 4.38: Vier UAVs, die sich in einer Umgebung mit Hindernissen koordinieren

Die UAVs bewegen sich hier direkt in Richtung der Schadstoffquelle die als bekannt angenommen wird. UAV₃ verzögert zunächst, um nicht zur gleichen Zeit durch dieselbe Lücke wie UAV₂ fliegen zu müssen. Bei Erreichen der gewünschten Linie gleicher Konzentration kreisen zwei der UAVs um die Quelle, während die zwei anderen sich nur auf dem Teil der Linie bewegen, der sich außerhalb des Bereichs der Hindernisse befindet. Die beiden UAVs verbleiben außerhalb des Bereichs, da für sie zum Zeitpunkt des Eintritts

in den Bereich der Hindernisse ein Verbleiben außerhalb eine bessere Lösung darstellt. Bei längeren Simulationszeiten zeigt sich, dass nach einer gewissen Zeit sich alle UAVs direkt auf der Linie gleicher Konzentration durch den Bereich mit Hindernissen bewegen.

Szenario mit unbekanntem Skalarfeld und Hindernissen

Die resultierenden Trajektorien des gleichen Szenarios mit Schätzung des Skalarfeldes ist in den folgenden Abbildungen (4.39 - 4.41) gezeigt.

Die Abbildung 4.39 zeigt das gleiche Szenario wie Abbildung 4.38, nur ist in diesem Beispiel das Skalarfeld unbekannt. Die blauen Kreise zeigen das Ergebnis für die Schätzung der Quelle des Skalarfeldes (Ort der höchsten Konzentration).

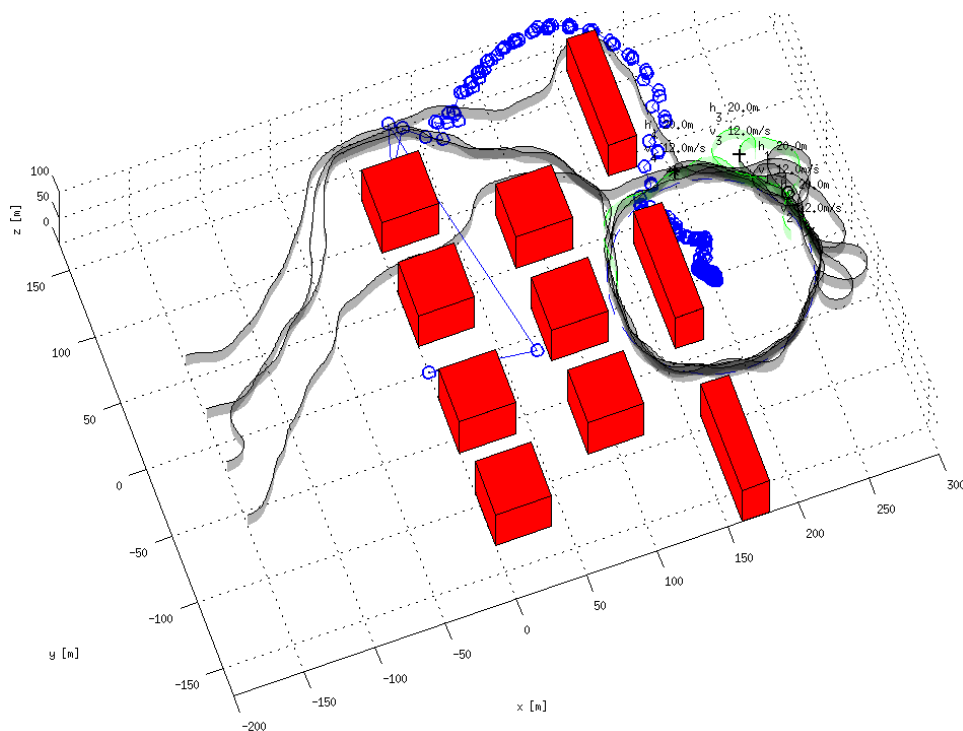


Abbildung 4.39: Das gleiche Szenario, wie in Abbildung 4.38, nur mit unbekanntem Skalarfeld

Im Unterschied zu Abbildung 4.38 bewegen sich in Abbildung 4.39 die UAVs nicht im direkten Weg auf die tatsächliche Quelle zu, sondern in einem Bogen.

Dieser Bogen entsteht dadurch, dass die UAVs zunächst auf die geschätzte Position der Quelle der Schadstoffwolke zufliegen. Dies bewirkt, dass abhängig von der Anzahl der UAVs und deren Ausbreitung nur weniger Informationen seitlich zu deren Flugrichtung für die Schätzung gesammelt werden. Durch den geringeren Informationsgewinn erfolgt eine geringere Korrektur der geschätzten Position der Quelle in diese Richtung. Die Folge dessen ist der bogenförmiger Verlauf der geschätzten Position der Quelle der Schadstoff-

wolke.

Im besten Fall werden die UAVs so geregelt, dass der Informationsgehalt der einzelnen Messungen maximiert und zugleich das Ziel erreicht wird. Die Konditionierung des Kalman-Gains K kann als Basis für ein Potenzial dienen, welches den Informationsgehalt der Messung durch eine günstige Trajektorie des UAVs maximiert. Dies ist im Rahmen der Arbeit nicht implementiert, da die Regelung sowie deren vielseitige Anwendbarkeit und Robustheit das Ziel ist.

Die Größe und die Gestalt des Bogens sind von unterschiedlichen Faktoren abhängig. Die wichtigsten Faktoren sind die initiale Position der UAVs, der initiale Zustand der Schätzung und die Genauigkeit der Messungen. Diese Abhängigkeiten werden durch Variationen dieser ermittelt. Als Beispiel wird in Abbildung 4.40 das Rauschen der Messung variiert. Im Unterschied zur vorherigen Abbildung werden die Messwerte mit einem RMS von $50.000ppm$ verrauscht. Es sind somit mehr Messungen nötig, um die Position der wahren Quelle zu schätzen. Dies wiederum hat zur Folge, dass der zuvor erwähnte Bogen größer ausgeprägt ist.

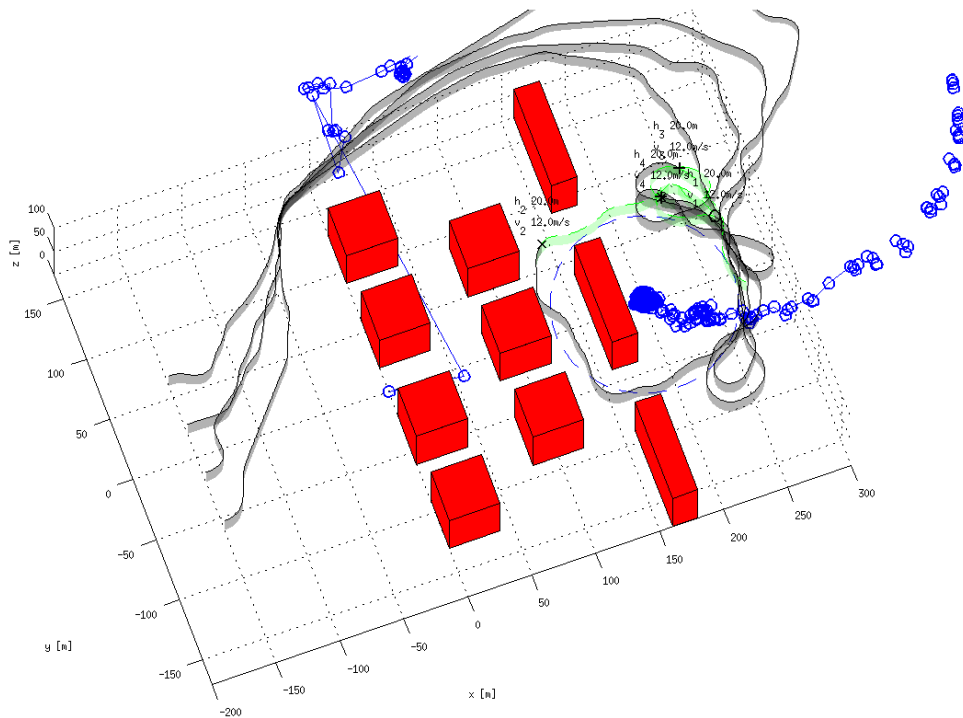


Abbildung 4.40: Dasselbe Szenario wie in Abbildung 4.39 mit Messrauschen RMS von $50.000ppm$

Wird unter denselben Voraussetzungen ein gradientenbasierter Algorithmus verwendet, ergibt sich der in Abbildung 4.41 gezeigte Verlauf.

Die Position der Quelle wird nicht innerhalb der Simulationszeit bestimmt. Der Grund hierfür ist, dass sich bei der gradientenbasierten Regelung alle UAVs direkt in Richtung

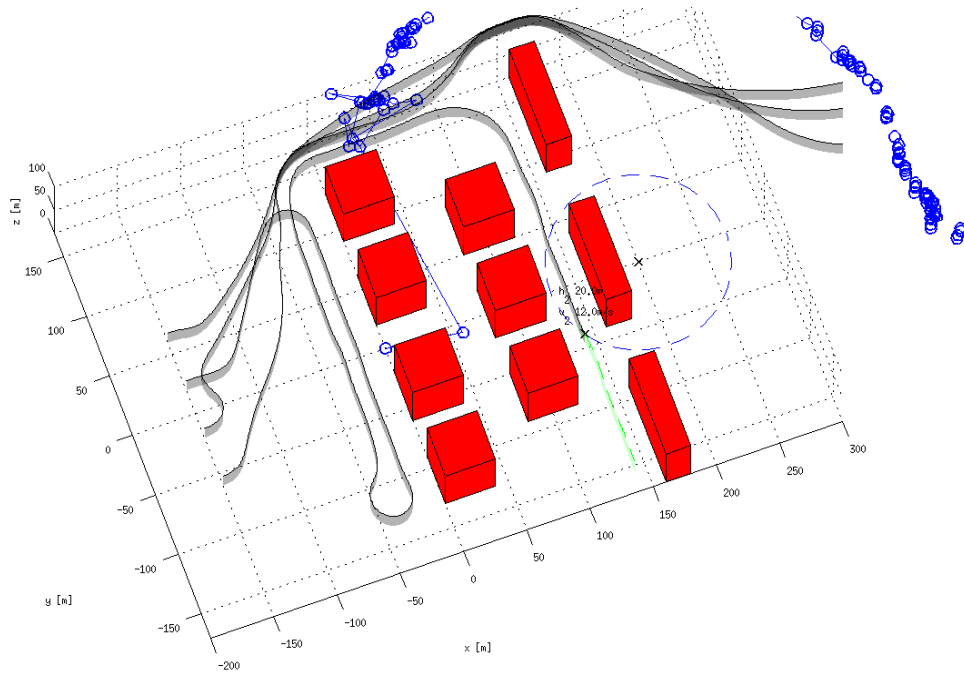


Abbildung 4.41: Das gleiche Szenario der vorherigen Abbildung 4.40, nur in diesem Fall wird ein gradientenbasierter Optimierer verwendet

der geschätzten Quelle bewegen. Der Informationsgehalt für die Schätzung wird dadurch reduziert. Die evolutionären Optimierungsalgorithmen verursachen Abweichungen vom direkten Weg zur geschätzten Quelle. Diese Abweichungen erhöhen den Informationsgehalt der entsprechenden Messungen, da nicht alle UAVs in dieselbe Richtung fliegen und verkürzt damit die Zeit, die notwendig ist, um eine hinreichend genaue Schätzung des Skalarfeldes zu erreichen.

Fazit

Die Untersuchungen werden schrittweise mit und ohne Hindernisse sowie bekanntem und unbekanntem Skalarfeld durchgeführt. In allen untersuchten Fällen kann die Regelung mit globalen Optimierungsverfahren (*ES1,GA1,ES3,GA3*) die Linie des gewünschten Skalarwerts erreichen. Weiter werden Untersuchungen mit verrauschten Messwerten, wie sie in der Realität vorkommen, durchgeführt. Auch in diesen Fällen wird das Ziel erreicht.

Die Untersuchung mit den verrauschten Messwerten bestätigt auch die Vermutung, dass die Größe des Bogens, welcher den zeitlichen Verlauf des geschätzten Ortes der Quelle darstellt, unter anderen Einflussfaktoren auch von der Größe des Rauschen, der Messwerte abhängt. Bei größerem Rauschen ist der beobachtete Bogen größer, da der Informationsgehalt jeder einzelnen Messung geringer ist.

In allen simulierten Szenarien werden die minimalen Abstände zu den Hindernissen und anderen UAVs eingehalten.

4.4 Robustheit der Regelung

Die hier verwendete Regelung ist keine klassische NMPC, die als Vorgabe eine Zustandstrajektorie verwendet. Die Vorgabe für die NMPC ist hier das Ziel der Mission. Mit welcher Zustandstrajektorie das Ziel erreicht wird, ist hier nicht vorgegeben.

Die hier vorgestellte Regelung baut auf einer Ebene der Flugregelung auf. Diese Ebene der Flugregelung erhält ihre Sollwerte $(\phi_c, a_c^*, \gamma_c)$ von der ihr überlagerten Regelung. Es wird vorausgesetzt, dass die Flugregelung mit der Strecke unter allen Umständen stabil ist und die Sollwerte bei den vorgegebenen Grenzen (Kapitel 3.2.1) erreicht werden.

Für das Überleben der UAVs ist die Stabilität der überlagerten Regelung weit weniger wichtig als die zuverlässige Vermeidung eines Zusammenstoßes mit Hindernissen oder anderen UAVs. Wie robust die Regelung diese Randbedingungen und Aufgaben erfüllt, soll hier untersucht werden.

Die Robustheit der Regelung wird durch eine Sensitivitätsanalyse basierend auf Daten der Simulationen untersucht. Diese einzelnen Bestandteile der Robustheit können wie folgt aufgeteilt werden:

- Robustheit der Optimierungsverfahren und deren Parametern
- Robustheit der Regelung gegenüber Modellungenauigkeiten und Störungen
- Robustheit gegenüber Variationen der Parameter der Potenzialfeldern

Im Folgenden werden diese einzelnen Bestandteile betrachtet.

4.4.1 Robustheit des Optimierungsverfahrens

In den vorherigen Untersuchungen wird bereits der Einfluss von unterschiedlichen Optimierungsverfahren auf die Stabilität und Effektivität untersucht. Die evolutionären (*ES/GA*) Verfahren zeigen in jeder einzelnen der vielzähligen Simulationen ein stabiles Verhalten. Die Effektivität dieser Verfahren variiert je nach Parametrierung und Aufgabe. Qualitativ weicht jedoch die Effektivität dieser Verfahren nur gering vom Optimum (*Brute-Force-Methode*) ab.

Im Gegensatz dazu zeigen die Simulationsergebnisse, dass der als Referenz implementierte gradientenbasierte Algorithmus (*GR1*) das Ziel oft in der kürzesten Zeit erreicht. Dies ist nicht in jedem Fall zutreffend. In einigen Fällen versagt die Regelung unter Verwendung des *GR1* Optimierungsverfahrens komplett (Abbildung 4.30).

4.4.2 Robustheit gegenüber Modellungenauigkeiten und Störungen

Das Verhalten der UAVs hängt unter anderem davon ab, wie exakt die Modelle in der Regelung der Realität entsprechen bzw. wie empfindlich oder sensitiv der Schwarm auf vorhandene Abweichungen oder Störungen reagiert. Um die Auswirkungen von Modellungenauigkeiten zu untersuchen, werden die Parameter der Modelle abweichend zu den realen Modellen variiert und deren Resultate analysiert.

Als Basis für diese Sensitivitätsanalyse wird ein Szenario gewählt, in dem drei UAVs die Aufgabe haben, Wegpunkte in einer Umgebung mit Hindernissen anzufliegen (Abbildung 4.33). Diese Untersuchung wird mit dem genetischen (GA1) und evolutionären Optimierungsalgorithmus (ES1) durchgeführt. Da die Ergebnisse der Simulationen mit beiden Optimierungsverfahren sehr ähnlich sind, werden hier nur die Ergebnisse der Simulationen mit dem genetischen Algorithmus (GA1) dargestellt.

Zur Untersuchung der Sensitivität werden die zwei entscheidenden Parameter (Zustände), die momentane Geschwindigkeit und der momentane Rollwinkel variiert. Alle anderen Parameter des Modells beeinflussen diese beiden Werte indirekt durch die Integration. Somit ist eine Variation dieser beiden Werte ausreichend, um die Abweichung dieser Parameter von der Realität abzubilden. Beide werden ausgehend vom realen Nominalwert mit bis zu $\pm 50\%$ zufällig variiert, da beide Parameter entscheidend die Wenigkeit und die Größe des Bereichs zur Optimierung beeinflussen. Die Variation dieser Werte mit $\pm 50\%$ des realen Nominalwert stellt einen extremen Fall dar, der in Realität unwahrscheinlich ist.

In Abbildung 4.42 ist das Resultat aus 100 Simulationsläufen gezeigt. Die benötigte Zeit für die Aufgabe t ist in Abhängigkeit der prozentualen Abweichung von v^* und ϕ^* dargestellt. Wie zu erkennen ist, wird in allen Fällen die Aufgabe innerhalb eines Bereiches von 65 – 95s erfüllt.

Aufgrund der hohen Komplexität ergibt sich kein erkennbarer Zusammenhang zwischen der benötigten Zeit und der Abweichung der Modellparameter von den realen Werten. Entscheidend ist, dass in allen Fällen die Aufgabe erfüllt und keinerlei Tendenz zum Versagen oder Instabilität der Regelung erkennbar ist. Weiter ist auch keine Häufung zu erkennen, welche auf eine Gesetzmäßigkeit hindeuten würde.

Störungen oder Instabilitäten durch Latenzen in der Kommunikation werden als unerheblich betrachtet, da das Datenvolumen vergleichsweise gering ist und nur linear mit der Größe des Schwarmes skaliert. Jedes UAV sendet seine Position, sein prädizierte Trajektorie und eventuell vorhandene Sensorwerte (Schadstoffkonzentration). Je nach Auflösung der prädizierten Trajektorie beträgt das Datenvolumen wenige 100 Bytes pro UAV. Bei einem großen Schwarm wenige Kilobytes. Diese können mit aktuellen Standards




Abbildung 4.42: Resultat einer Sensitivitätsanalyse für das UAV-Modell mit 50% Variation

und entsprechenden Protokollen mit vernachlässigbaren Latenzen (bezüglich der Zeit eines Regelzyclus von einer Sekunde) übertragen werden.

4.4.3 Robustheit gegenüber Variation der Parameter des Potenzialfeldes

Die Gestalt und die Parametrierung der Potenzialfelder bestimmt entscheidend, wie sich die UAVs verhalten. Die Variation dieser Parameter sollte zeigen, dass es sich bei dieser Regelung nicht um ein Expertensystem handelt, dessen Parameter speziell optimiert werden. Um eine qualitative Aussage über die Sensitivität der Regelung in Folge der Parametrierung der Potenzialfelder treffen zu können, wird im Folgenden die Sensitivität bezüglich der Parametrierung der Potenzialfelder untersucht. Diese Betrachtung erfolgt anhand des in Abbildung 4.43 dargestellten Szenarios. Dieses Szenario wird gewählt, da die UAVs unter allen Umständen gezwungen sind, durch den Ring aus Hindernissen zu fliegen, um den Wegpunkt bei (0|0) zu erreichen.

Die Bewertung erfolgt mit dem minimalen Abstand zu den Hindernissen $d_{obs_{min}}$, dem minimalen Abstand zu den anderen UAVs $d_{avo_{min}}$ und die benötigte Zeit t_{way} bis die UAVs den Wegpunkt (0|0) erreichen.

Der Einfluss der Variation der Potenziale zur Vermeidung eines Zusammenstoßes mit einem Hindernis Φ_{obs} , mit anderen UAVs Φ_{avo} und zum Anfliegen eines Wegpunkts Φ_{way} werden hier untersucht. Die Skalierung der Potenzialwerte erfolgt mit jeweils einer Größenordnung zu kleineren und größeren Werten. Dies begrenzt den Berechnungsaufwand auf ein vertretbares Maß. Da bei der Analyse davon ausgegangen wird, dass ein komplexer nichtdeterministischer Zusammenhang existiert, erfolgt die Bestimmung




Abbildung 4.43: Szenario für die Variation der Potenziale

der Sensitivität durch eine statistische Betrachtung. Um den Rechenaufwand in einem vertretbaren Maß zu halten, werden nur die zuvor erwähnten Variationen betrachtet. Die statistische Auswertung erfolgt auf der Basis von 100 Simulationen. Für eine qualitative Aussage ist dies ausreichend.

In den Abbildungen (4.44-4.46) ist auf der linken Seite der Einfluss der Variation der Parameter auf den minimalen Abstand zu einem Hindernis, in der Mitte ist der resultierende minimale Abstand zwischen den UAVs und auf der rechten Seite die benötigte Zeit um den Wegpunkt zu erreichen, dargestellt.

Die Abbildung 4.44 zeigt den Einfluss der Variation des Potentials Φ_{obs} , um die Kollision mit Hindernissen zu vermeiden. Im linken Teil der Abbildung ist zu sehen, dass die Variation des Potentials zur Vermeidung einer Kollision mit Hindernissen im Bereich von 10^{-1} bis 10^1 keinen Einfluss auf den minimalen Abstand zu den Hindernissen $d_{obs_{min}}$ hat. Ähnlich verhält es sich bei dem minimalen Abstand zu anderen UAVs $d_{avo_{min}}$ (Abbildung 4.44 Mitte). Jedoch ergibt sich bei einer Reduzierung des Potentials Φ_{obs} eine Konzentration des minimalen Abstands zwischen den UAVs bei 10m und 50m. Da der vorgeschriebene Mindestabstand von 5m in allen Fällen eingehalten wird, ist dies nicht negativ zu bewerten. Erstaunlich ist, dass bei einer Reduzierung des Potentials zur Vermeidung einer Kollision mit Hindernissen die durchschnittlich benötigte Zeit zum Erreichen des Wegpunktes t_{way} ansteigt (Abbildung 4.44 rechts). Der Grund hierfür ließ sich nicht ermitteln. Dies wird nicht weiter untersucht, da es sich um eine Tendenz aber

keine Gesetzmäßigkeit handelt.




Abbildung 4.44: Ergebnisse aus der Variation des Potentials zur Vermeidung eines Zusammenstoßes mit Hindernissen

Bei der Variation des Potentials zur Vermeidung einer Kollision mit anderen UAVs Φ_{avo} lässt sich kein Einfluss auf den minimalen Abstand zu Hindernissen feststellen (Abbildung 4.45 links). Wie zu erwarten ist, vergrößert sich der minimale Abstand zu den anderen UAVs bei Erhöhung des Potentials zur Vermeidung einer Kollision mit anderen UAVs Φ_{avo} (Abbildung 4.45 Mitte). Es resultiert eine Erhöhung der benötigten Zeit (Abbildung 4.45 rechts).




Abbildung 4.45: Ergebnisse aus der Variation des Potentials zur Vermeidung eines Zusammenstoßes mit anderen UAVs

Wird das Potenzial zum Anfliegen von Wegpunkten Φ_{way} variiert, so zeigt sich nahezu kein Einfluss auf den minimalen Abstand zu den Hindernissen $d_{obs_{min}}$ (Abbildung 4.46

links). Allerdings verringert sich der durchschnittliche minimale Abstand der UAVs zu einander $d_{avo_{min}}$ im selben Fall (Abbildung 4.46 mitte).

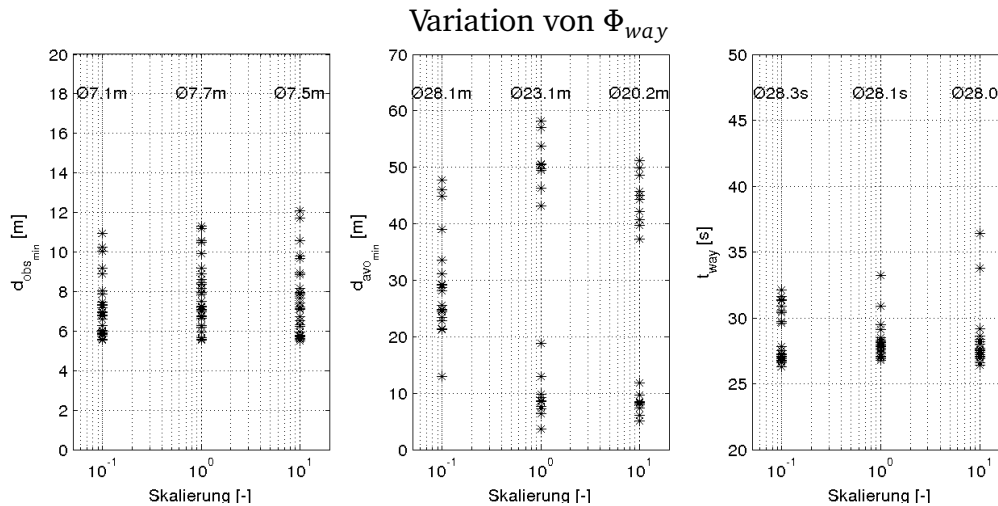


Abbildung 4.46: Ergebnisse aus der Variation des Potentials zum Anfliegen des Wegpunktes

Besonders ist hier, dass bei der Skalierung mit dem Faktor 10^{-1} , des Potentials zum Anfliegen von Wegpunkten, eine Häufung des minimalen Abstands $d_{avo_{min}}$ der UAVs bei höheren Werten auftritt. Durch die Reduzierung des Potentials zum Anfliegen des Wegpunktes sind die UAVs weniger gezwungen, direkt den Wegpunkt anzufliegen und können somit einander besser ausweichen. Bei einem höheren Potenzial zum Anfliegen von Wegpunkten entstehen wie zuvor zwei Varianten von Trajektorien, die eine Häufung des Abstandes der UAVs zueinander bei 10m und 50m haben. Die benötigte Zeit, um den Wegpunkt t_{way} zu erreichen, nimmt erwartungsgemäß ab, jedoch ist diese Abnahme sehr gering (Abbildung 4.46 rechts). Dies ist zu erwarten, da eine Optimierung der benötigten Zeit aufgrund der Strecke und der konstanten Geschwindigkeit der UAVs begrenzt möglich ist.

Letztendlich resultiert, dass diese Parameter in einem weiten Bereich - einer Größenordnung (Zehnerpotenz) zu kleineren und größeren Werten - variiert werden können ohne die Regelung zu destabilisieren oder Randbedingungen zu verletzen.

5 Bewertung der Schwarmregelung

Die in dieser Arbeit beschriebene Regelung wird in Kapitel 3 basierend auf den Anforderungen aus Kapitel 1 entwickelt. In Kapitel 4 werden analytische und simulationstechnische Untersuchungen der Regelung mittels unterschiedlicher Szenarien durchgeführt. Die einzelnen Ergebnisse aus diesem Kapitel werden nun im Zusammenhang mit den Anforderungen betrachtet.

Anforderungen an die Regelung bezüglich der Bedienung

Intuitive Definition des Missionsziels

Die Definition des Ziels (Aufgabe) der Mission erfolgt bei dieser Regelung intuitiv durch Potenzialfelder. Das Missionsziel wird hierbei durch einen niedrigen Potenzialwert dargestellt. Die Regelung ermöglicht es beliebige Potenziale zu definieren, da das verwendete Optimierungsverfahren keinerlei Bedingungen an die zu optimierende Funktion stellt. In dieser Arbeit werden auf einfachen Überlegungen basierend Potenziale implementiert und in den entsprechenden Szenarien durch Simulation erfolgreich getestet.

Potenzialfelder ermöglichen die Definition von einfachen Aufgaben, wie einen Wegpunkt zu erreichen, als auch komplexe Aufgaben, wie die Vermessung einer Schadstoffwolke in einem Schwarm. Dies wird durch die Szenarien in simulationstechnischen Untersuchungen bestätigt. Die Robustheitsuntersuchung in Kapitel 4.4 zeigt, dass es sich hierbei nicht um ein speziell eingestelltes Expertensystem handelt, sondern um eine Regelung bei der die Parameter in einem weiten Bereich eingestellt werden können. Somit ist auch eine intuitive Wahl der Parameter der Potenzialfelder möglich.

Intuitive Definition von erforderlichen Randbedingungen

Genauso wie die Ziele können auch die Randbedingungen definiert werden. Im Unterschied zu Zielen sind bei Randbedingungen oft Vorgaben notwendig, die unter allen Umständen eingehalten werden müssen und somit ein Ausschlusskriterium für eine Trajektorie sind. Dies wird ermöglicht durch ein Potenzial, welches in solch einem Fall zu Unendlich wird. Tritt solch ein Fall in irgendeinem der einzelnen Potenziale ein, so wird das gesamte Potenzial durch die Akkumulation unendlich. Beispiele hierfür sind die beiden Potenziale zur Vermeidung von Kollisionen (obs und avo). Bei ihnen wird durch ihre Gestalt das Potenzial unendlich, wenn der minimale Abstand, welcher unter allen Umständen eingehalten werden soll, unterschritten wird. Simulationen von Hindernisszenarien (Beispiele in Kapitel 4.1.1) zeigen, dass dies ein effektiver Ansatz ist, um Randbedingungen in eine Regelung zu implementieren.

Intuitive Priorisierung der Missionsziele und Randbedingungen

Die Gewichtung L ermöglicht die Priorisierung der Randbedingungen und Ziele (Aufgaben) relativ zueinander. Dies ermöglicht die Abbildung der Prioritäten analog zur Priorisierung durch einen Menschen. Die Gewichtung der unterschiedlichen Aufgaben und Randbedingungen ermöglicht zudem die Definition einer Mission. Bei den in dieser Arbeit untersuchten Szenarien wird nur durch Verändern der Gewichtungen von L die Anpassung der Zielsetzungen der Regelung vorgenommen.

Anforderungen an die Regelung bezüglich der Erfüllung der Mission

Selbstständiges und sinnvolles Lösen von widersprüchlichen Vorgaben

Die Priorisierung der Ziele und Randbedingungen durch den Nutzer erlaubt es der Regelung, sich entsprechend der Vorgaben selbständig zu verhalten und Konflikte entsprechend dieser Vorgaben zu lösen. Dies wird in mehreren Beispielen erfolgreich demonstriert. Unter anderem anhand des U-Problems, in dem das Vermeiden eines Zusammenstoßes und das Erreichen des Zielpunktes einen Konflikt darstellt. Die Regelung ist in der Lage diesen vermeidlichen Konflikt zu lösen und erreicht den Zielpunkt, sofern die in Kapitel 4.1.2 genannten Bedingungen erfüllt sind.

Ein weiteres Beispiel ist das Vermeiden einer Kollision mit anderen Luftfahrzeugen beim gleichzeitigen Abfliegen einer 4D-Trajektorie. Die Regelung ermöglicht es dem UAV, einzelnen oder mehreren anderen Luftfahrzeugen auszuweichen und einen Kompromiss zwischen Abstand zu diesen, anderen Luftfahrzeugen und der Haltung der 4D-Trajektorie zu finden. Im Fall von 5 UAVs ergibt sich eine Art von Kreisverkehr als Folge der Randbedingung jedes einzelnen UAVs, jedem anderen UAV auszuweichen. Dies stellt eine intelligente Lösung des Konfliktes dar, welche nicht vorgegeben ist, sondern sich aus den Definitionen der Potenzialfelder und deren Gewichtungen ergibt. Widersprüchliche Vorgaben oder Konflikte können in allen komplexen Szenarien mit Randbedingungen auftreten. Jedes einzelne untersuchte Szenario demonstriert somit das Lösen von widersprüchlichen Vorgaben entsprechend ihrer Gewichtung.

Vorausschauendes Agieren

Ein vorausschauendes Agieren wird bei dieser Regelung durch die Prädiktion in Zusammenhang mit der Bewertung dieser durch die Potenzialfelder erreicht. Auf diese Weise hat das UAV die Möglichkeit, bis zum Prädiktionshorizont eine optimale Trajektorie bzw. eine nahe dem Optimum befindliche Trajektorie zu wählen. Anschaulich zeigt dies das U-Problem, denn in den meisten Fällen wird schon das Einfliegen in das U-Förmige Hindernis durch die Prädiktion verhindert.

Das vorausschauende Agieren zeigt sich besonders bei der Berücksichtigung von beweglichen Hindernissen, wie andere UAVs. Die Bewegung wird hier durch die zeitliche Betrachtung mittels des Prädiktionshorizonts berücksichtigt. Somit ist keine Anpassung

des gewünschten Mindestabstand durch den Geschwindigkeitsvektor, wie es Barraci [Bar10] beschreibt, notwendig. Bestätigung findet sich in alle Szenarien, in welchen mehrere UAVs zusammen fliegen und festen oder beweglichen Hindernissen ausweichen.

Zuverlässiges Erfüllen der gestellten Aufgaben

In fast allen untersuchten Szenarien erreichen die UAVs einzeln oder im Schwarm ihre Ziele. In zwei Fällen wird das jeweilige Ziel nicht erreicht. Bei dem extrem gestalteten Hindernisszenario in Kapitel 4.1.1 versagt die Regelung mit einer analytisch berechneten Wahrscheinlichkeit. Diese wird zusätzlich durch eine simulationstechnische Untersuchung auf ihre Plausibilität überprüft. Im anderen Fall versagt die Regelung bei einem U-förmigen Hindernis, wenn der Prädiktionshorizont nicht ausreichend groß ist, um dem Hindernis auszuweichen oder es zu verlassen. Die notwendigen Bedingungen zum Vermeiden oder Verlassen solch eines Hindernisses werden in Kapitel 4.1.2 durch eine simulationstechnische Untersuchung bestimmt.

Diese Zuverlässigkeit wird durch das vorausschauende Agieren und durch das globale Optimierungsverfahren erreicht. Zusätzlich verhindert der Nichtdeterminismus des Optimierungsverfahren, dass Endlosschleifen entstehen. Nur bei dem zur Referenzierung genutzten gradientenbasierte Optimierungsverfahren versagt die Regelung in einigen Fällen und erreicht nicht die ihm gestellte Aufgabe.

Robustes Verhalten bezüglich Änderungen in der Umwelt und in der Konfiguration des Schwarms

Durch die dezentrale Struktur der Schwarmregelung ist keine zentrale Einheit zur Koordinierung oder Regelung notwendig. Auch sind die Regelungen aller UAVs gleich. Dadurch können einzelne UAVs einfach ausgetauscht, ergänzt oder reduziert werden, ohne dass Änderungen an der Regelung vorgenommen werden müssen. Dies wird in mehreren Szenarien in dieser Arbeit gezeigt, in welchen durch einzelne, drei oder sechs UAVs die selben Aufgaben ohne Anpassung der Regelung erfüllt werden. Zusätzlich ist die Regelung robust gegenüber Ungenauigkeiten des Modells, wie die Ausführungen im vorherigen Kapitel zeigen.

In Kapitel 4.4 werden Faktoren, die Einfluss auf die Performance, Stabilität oder Robustheit der Regelung haben betrachtet. Einflussfaktoren wie Modellungenauigkeiten von Messfehler, Windeinfluss oder Parameterabweichungen werden mittels einer Sensitivitätsanalyse anhand eines Beispielszenarios untersucht (Kapitel 4.4.2). Die UAVs benötigen in diesem Szenario eine längere Zeit als dies ohne diese Störungen der Fall wäre. Sie erreichen dennoch in allen betrachteten Fällen das Ziel.

Generelle Bewertung

Sofern die darunterliegende Flugregelung (Stabilisierung) zuverlässig arbeitet, sollte eine Implementierung in ein reales System ohne weiteres möglich sein. Um die Regelung zu komplettieren und eine praktikable Anwendung zu ermöglichen, sollten auch Start und Landung autonom erfolgen. Dies kann entweder durch das Hinzufügen eines abstrakten Potenzial zur Landung oder durch die Definition einer entsprechenden 4D-Trajektorie erfolgen.

6 Zusammenfassung und Ausblick

Kapitel 1 bietet einen Überblick über die unterschiedlichen Klassen von UAVs und deren Aufgaben. Der Begriff Schwarm wird definiert und dessen mögliche Anwendungsgebiete beschrieben. Es wird ein einleitender Überblick über die Schwarmregelung von UAVs und die damit verbundenen Herausforderungen gegeben. Darauf basierend werden Anforderungen für die hier entwickelte Schwarmregelung definiert.

In Kapitel 2 wird die typische Struktur einer Regelung eines einzelnen UAVs sowie eines Schwarms von UAVs beschrieben. Basierend auf dieser werden die unterschiedlichen Arten zur Regelung eines UAVs bzw. eines UAV-Schwarms gegliedert und im Folgenden beschrieben. Die Vor- und Nachteile der einzelnen Möglichkeiten zur Regelung werden herausgearbeitet. Die Methoden, auf denen das Konzept der Regelung in dieser Arbeit basiert, werden ausführlicher betrachtet.

In Kapitel 3 wird aus den Anforderungen und den zuvor betrachteten Arten der Regelungen systematisch eine Regelung erarbeitet, welche nicht die Nachteile der zuvor beschriebenen Methoden aufweisen. Dies wird durch die Kombination aus modellprädiktiver Regelung mit Potenzialfeldern und evolutionären Optimierungsalgorithmen erreicht. Die Methoden kompensieren gegenseitig ihre Nachteile bzw. ermöglichen erst eine Regelung. Im Weiteren werden die erhofften Vorteile, die durch diese Kombination entstehen, herausgearbeitet.

Die Regelung ermöglicht durch die Verwendung von Potenzialfeldern eine einfache Definition von Zielen und Randbedingungen, unter denen die Ziele erreicht werden sollen. Besonders im vorhergehenden Kapitel 4.4 wird untersucht und gezeigt, dass eine stabile und robuste Regelung bei Variation der Parameter und bei Abweichungen des Modells erreicht werden kann.

Auch kann die Regelung selbständig widersprüchliche Vorgaben lösen. Das Lösen dieser vermeintlichen Widersprüche erfolgt mithilfe des vorausschauenden Verhaltens und dem evolutionären Algorithmus. In diesem Zusammenhang zentral ist das U-Problem, denn hier widerspricht das Erreichen des Ziels scheinbar dem Vermeiden eines Hindernisses. In Kapitel 4.1.2 wird untersucht, unter welchen Bedingungen diese Regelung das U-Problem lösen kann.

Die dezentrale Gestalt der Regelung, der homogen Aufbau des Schwarms und der Austausch aller relevanten Daten zwischen den UAVs ermöglicht eine Regelung die unempfindlich gegenüber Ausfall von einzelnen UAVs oder dem Einsatz einer beliebigen

Anzahl von UAVs ist. In Kapitel 4 werden sowohl einzelne UAVs als auch mehrere UAVs für identische Aufgaben eingesetzt und deren Performanz verglichen. Wie zu erwarten ist, erfüllen mehrere UAVs dieselbe Aufgabe in kürzerer Zeit. In allen Fällen wird das Ziel erreicht.

In Kapitel 4.2 generieren die jeweils anderen UAVs durch ihre Bewegung eine sich verändernde Umgebung. Dies erfolgt entweder durch die bloße Anwesenheit oder durch die Informationen der UAVs. Informationen, welche das Modell der Umwelt beeinflussen, sind Messungen von Schadstoffkonzentrationen (Kapitel 4.3.3) oder Änderungen der Wegpunktliste (Kapitel 4.3.2). In all diesen Fällen erfolgt eine Anpassung an die veränderte Umgebung.

Die Koordinierung der einzelnen UAVs gelingt hier durch den Austausch von Informationen, die wiederum Einfluss auf die Potenzialfelder jedes einzelnen UAVs haben. Wie in Kapitel 4.3.1 zu sehen ist, ermöglicht dies eine intelligente Koordinierung für eine Formation, Anfliegen von Wegpunkten im Schwarm und dem Vermessen von skalaren Feldern (Lokalisierung von Schadstoffen) im Schwarm. Dabei berücksichtigt jedes einzelne UAV die für ihn geltenden Randbedingungen, wie das Vermeiden eines Zusammenstoßes mit Hindernissen und anderen UAVs. In allen simulierten Fällen erfolgt die Koordinierung, sodass selbst bei extrem unterschiedlichen Geschwindigkeiten eine Formation gehalten werden kann (Kapitel 4.3.1).

Potenziale für Randbedingungen, wie die Vermeidung eines Zusammenstoßes mit einem Hindernis oder anderen UAVs, müssen nicht vom Systemmanager des Schwarms definiert werden. Der Systemmanager ist darauf beschränkt, das Ziel der Mission durch die Wahl der Gewichtungen der Potenziale (\vec{l}) zu definieren. Wenn nötig kann er während der Mission die Gewichtung anpassen. Bei Missionen, bei denen das Missionsziel sich nicht ändert, ist ein Eingreifen durch eine Person nicht notwendig. Der Schwarm kann in diesem Fall voll autonom die durch die Potenzialfelder definierte Mission erfüllen.

Die vorgestellte Methode ermöglicht es dem Systemmanager, einen Schwarm von UAVs oder einzelne UAVs auf einer höheren Ebene zu kontrollieren. Ähnlich wie bei einem Menschen kann er das Ziel der Mission definieren und der Schwarm bzw. das einzelne UAV kümmert sich selbst um die Durchführung der Mission unter den vorgegeben Randbedingungen.

Hybride Optimierer können für diese Art der Regelung eine weitere Verbesserung ermöglichen. Eine Kombination aus evolutionären und gradientenbasierten Optimierern kann die Vorteile beider Verfahren nutzen. Hierbei wird zunächst eine grobe Optimierung mittels des evolutionären oder genetischen Optimierers durchgeführt. Dieses grobe Ergebnis dient anschließend als Ausgangspunkt der gradientenbasierten Optimierung. Das Resultat ist ein geringer Rechenaufwand und die Vorteile eines globalen Optimie-

rungsverfahrens.

Die Interaktion mit dem Systemmanager ist ein wichtiger Bestandteil, um einen realen Schwarm einsetzen zu können. In dieser Arbeit wird die Interaktion mit dem Systemmanager von der regelungstechnischen Seite betrachtet. Um die Vorteile der Regelung voll nutzen zu können, muss ein schlüssiges HMI-Konzept entwickelt werden. Dieses ermöglicht, dass die Potenziale und somit das Verhalten des Schwarms an die Wünsche des Systemmanagers angepasst werden können.

Für Anwendungen bei denen Skalarfelder identifiziert werden, sollten die UAVs so geregelt werden, dass der Informationsgehalt der einzelnen Messungen maximiert wird. Die Konditionierung des Kalman-Gains K könnte als Basis für ein Potenzial dienen, welches den Informationsgehalt der Messung durch eine günstige Trajektorie des UAVs maximiert.



Literaturverzeichnis

- [ABCC01] APPLETGATE, David ; BIXBY, Robert ; CHVÁTAL, Vašek ; COOK, William: TSP cuts which do not conform to the template paradigm. In: *Computational Combinatorial Optimization* (2001)
- [Aer12] AERONAUTICS, Stratus: Stratus Aeronautics magnetometer payload. (2012), Oktober
- [AF02] ALLGÖWER, Frank ; FINDEISEN, Rolf: An Introduction to Nonlinear Model Predictive Control. In: *21st Benelux Meeting on Systems and Control* (2002)
- [AHP⁺07] ALLRED, Jude ; HASAN, Ahmad B. ; PANICHSAKUL, Saroch ; PISANO, William ; GRAY, Peter ; HUANG, Jyh ; HAN, Richard ; LAWRENCE, Dale ; MOHSENI, Kamran: Sensorflock: an airborne wireless sensor network of micro-air vehicles. In: *Proceedings of the 5th international conference on Embedded networked sensor systems* ACM, 2007, S. 117–129
- [AN08] AKOS, Zsuzsa ; NAGY, Mate: Thermal soaring flight of birds and UAVs. In: *Laboratory of Intelligent Systems, Ecole Polytechnique Federale de Lausanne, Switzerland* (2008)
- [AR04] ALLISON RYAN, et a.: An Overview of Emerging Results in Cooperative UAV Control. In: *43rd IEEE Conference on Decision and Control* (2004)
- [AZ00] ALLGÖWER, Frank ; ZHENG, Alex: *Nonlinear model predictive control*. Bd. 26. Birkhäuser Basel, 2000
- [BAH04] BERTUCCELLI, L. F. ; ALIGHANBARI, M. ; HOW, J. P.: Robust Planning For Coupled Cooperative UAV Missions. In: *43rd IEEE Conference on Decision and Control* (2004)
- [BAL11] BROCKHAUS, Rudolf ; ALLES, Wolfgang ; LUCKNER, Robert: *Flugregelung*. Springer-Verlag, 2011
- [Bar10] BARRACI, Nima: *Conflict resolution in autonomous operations area airspace*, TU Darmstadt, Diss., 2010
- [BK03] BUMSOO KIM, Dan N. Paul Hubbard H. Paul Hubbard: Swarming Unmanned Aerial Vehicles: Concept Development and Experimentation, A State of the Art Review on Flight and Mission Control. (2003)
- [BKB04] BORRELLI, Francesco ; KEVICZKY, Tamás ; BALAS, Gary J.: Collision-free UAV formation flight using decentralized optimization and invariant sets. In: *43rd IEEE Conference on Decision and Control* Bd. 1 IEEE, 2004, S. 1099–1104

-
- [BWSM06] BAMBERGER, Robert J. ; WATSON, David P. ; SCHEIDT, David H. ; MOORE, Kevin L.: Flight demonstrations of unmanned aerial vehicle swarming concepts. In: *Johns Hopkins APL technical digest* 27 (2006), Nr. 1, S. 41–55
- [CMC08] CONCEIÇÃO, André S. ; MOREIRA, A P. ; COSTA, Paulo J.: A nonlinear model predictive control strategy for trajectory tracking of a four-wheeled omnidirectional mobile robot. In: *Optimal Control Applications and Methods* 29 (2008), Nr. 5, S. 335–352
- [CMV07] CASTILLO, CL ; MORENO, W ; VALAVANIS, KP: Unmanned helicopter waypoint trajectory tracking using model predictive control. In: *Mediterranean Conference on Control & Automation IEEE*, 2007, S. 1–8
- [CWL09] CHEN, Hai ; WANG, Xin-min ; LI, Yan: A Survey of Autonomous Control for UAV. In: *International Conference on Artificial Intelligence and Computational Intelligence* (2009)
- [DB08] DAILY, Robert ; BEVLY, David M.: Harmonic potential field path planning for high speed vehicles. In: *American Control Conference IEEE*, 2008, S. 4609–4614
- [Dij59] DIJKSTRA, Edsger W.: A note on two problems in connexion with graphs. In: *Numerische mathematik* 1 (1959), Nr. 1, S. 269–271
- [DJ10] DIERKS, Travis ; JAGANNATHAN, Sarangapani: Output feedback control of a quadrotor UAV using neural networks. In: *Neural Networks, IEEE Transactions on* 21 (2010), Nr. 1, S. 50–66
- [DNH07] DE NARDI, Renzo ; HOLLAND, Owen: Ultraswarm: A further step towards a flock of miniature helicopters. In: *Swarm Robotics*. Springer, 2007, S. 116–128
- [Dun04] DUNBAR, William B.: *Distributed receding horizon control of multiagent systems*, California Institute of Technology, Diss., 2004
- [DZ08] DU ZHIYING, Wang X.: Nonlinear Generalized Predictive Control Based on Online SVR. In: *Second International Symposium on Intelligent Information Technology Application* (2008)
- [EMV04] EIBEN, Agoston E. ; MARCHIORI, Elena ; VALKO, VA: Evolutionary algorithms with on-the-fly population size adjustment. In: *Parallel Problem Solving from Nature-PPSN VIII* Springer, 2004, S. 41–50
- [FKM05] FUKUSHIMA, Hiroaki ; KON, Kazuyuki ; MATSUNO, Fumitoshi: Distributed model predictive control for multi-vehicle formation with collision avoidance constraints. In: *European Control Conference. 44th IEEE Conference on Decision and Control IEEE*, 2005, S. 5480–5485

-
- [Flo95] FLOUDAS, Christodoulos A.: *Nonlinear and mixed-integer optimization: fundamentals and applications*. Oxford University Press, 1995
- [Fre05] FREW, Eric W.: Receding Horizon Control Using Random Search for UAV Navigation with Passive, Non-cooperative Sensing. In: *AIAA Guidance, Navigation, and Control Conference and Exhibit* (2005)
- [Fre07] FREW, Eric W.: Lyapunov Guidance Vector Fields for Unmanned Aircraft Applications. In: *American Control Conference Marriott Marquis Hotel at Times Square New York City* (2007)
- [Fro79] FROHN, Arnold: *Einführung in die kinetische Gastheorie: Studienbuch für Studierende d. Ingenieurwiss., d. Physik und physikal. Chemie*. Akadem. Verlag-Ges., 1979
- [GMH08] GABRIEL M. HOFFMANN, et a.: Quadrotor Helicopter Trajectory Tracking Control. In: *AIAA* (2008)
- [Goo02] GOODRICH, Michael A.: Potential fields tutorial. In: *Class Notes* (2002)
- [GP11] GRÜNE, Lars ; PANNEK, Jürgen: *Nonlinear model predictive control*. Springer, 2011
- [GR02] GOTSHALL, Stanley ; RYLANDER, Bart: Optimal population size and the genetic algorithm. In: *Population 100* (2002), Nr. 400, S. 900
- [HCDP07] HU, Xiao-Bing ; CHEN, Wen-Hua ; DI PAOLO, Ezequiel: Multiairport capacity management: genetic algorithm with receding horizon. In: *Intelligent Transportation Systems, IEEE Transactions on* 8 (2007), Nr. 2, S. 254–263
- [HNR68] HART, Peter E. ; NILSSON, Nils J. ; RAPHAEL, Bertram: A formal basis for the heuristic determination of minimum cost paths. In: *IEEE Transactions on Systems Science and Cybernetics* 4 (1968), Nr. 2, S. 100–107
- [HPP⁺06] HASAN, A ; PISANO, W ; PANICHSAKUL, Saroch ; GRAY, Pete ; HUANG, JH ; HAN, Richard ; LAWRENCE, Dale ; MOHSENI, Kamran: Sensorflock: A mobile system of networked micro-air vehicles. In: *Department of Computer Science University of Colorado at Boulder, Tech. Rep* (2006)
- [ICA11] ICAO: *ICAO Cir 328, Unmanned Aircraft Systems (UAS)*. International Civil Aviation Organization, 2011
- [IGP03] INNOCENTI, M ; GIULIETTI, F ; POLLINI, L: Intelligent Management Control for Unmanned Aircraft Navigation and Formation Keeping / DTIC Document. 2003. – Forschungsbericht
- [IIK04] ISAAC I. KAMINER, et a.: Cooperative Control of Small UAVs for Naval Applications. In: *43rd IEEE Conference on Decision and Control* (2004)

-
- [Jän01] JÄNICH, Klaus: *Vector analysis*. Springer Science & Business Media, 2001
- [JPBG⁺12] JIMENEZ-PACHECO, Alberto ; BOUHIRE, Denia ; GASSER, Yannick ; ZUFFEREY, J ; FLOREANO, Dario ; RIMOLDI, Bixio: Implementation of a wireless mesh network of ultra light MAVs with dynamic routing. In: *Globecom Workshops (GC Wkshps)* IEEE, 2012, S. 1591–1596
- [JW10] JIA, Qian ; WANG, Xingsong: An Improved Potential Field Method for Path Planning. In: *Chinese Control and Decision Conference* (2010)
- [KB06] KEVICZKY, Tamas ; BALAS, Gary J.: Software-enabled receding horizon control for autonomous unmanned aerial vehicle guidance. In: *Journal of guidance, control, and dynamics* 29 (2006), Nr. 3, S. 680–694
- [KCSL08] KRIESEL, David M. ; CHEUNG, Eugene ; SITTI, Metin ; LIPSON, Hod: Beanbag robotics: Robotic swarms with 1-dof units. In: *Ant Colony Optimization and Swarm Intelligence*. Springer, 2008, S. 267–274
- [KGa11] KGAA, Dräger Safety AG & C.: Dräger-Sensorhandbuch. In: *DrägerSensor & Gasmessgeräte-Handbuch* (2011)
- [Kli07] KLINGAUF, Prof. Dr.-Ing. U.: *Flugmechanik I*. FSR Technische Universität Darmstadt, 2007
- [Kri09] KRIESEL, David: *Verteilte, evolutionäre Optimierung von Schwärmen*, Rheinische Friedrich-Wilhelms-Universität Bonn, Mathematisch-Naturwissenschaftliche Fakultät, Institut für Informatik, Diplomarbeit, 2009
- [KRSH06] KUWATA, Yoshiaki ; RICHARDS, Arthur ; SCHOUWENAARS, Tom ; HOW, Jonathan P.: Decentralized Robust Receding Horizon Control for Multi-vehicle Guidance. In: *American Control Conference Minneapolis* (2006)
- [KSMR09] KOPARDEKAR, Parimal ; SCHWARTZ, Albert ; MAGYARITS, Sherri ; RHODES, Jessica: Airspace Complexity Measurement: An Air Traffic Control Simulation Analysis. In: *International Journal of Industrial Engineering* 16 (2009), S. 61–70
- [KSS03] KIM, HJ ; SHIM, DH ; SASTRY, S: Decentralized nonlinear model predictive control of multiple flying robots in dynamic environments. In: *IEEE Conference on Decision and Control*, 2003, S. 5
- [Lan10] LANGE, Kenneth: Local and Global Convergence. In: *Numerical Analysis for Statisticians*. Springer New York, 2010 (Statistics and Computing), S. 277–296
- [LFP07] LAWRENCE, Dale ; FREW, Eric ; PISANO, William: Lyapunov vector fields for autonomous UAV flight control. In: *AIAA Guidance, Navigation and Control Conference and Exhibit*, 2007, S. 2007–6317

-
- [MAS09] MARDEN, Jason R. ; ARSLAN, Gürdal ; SHAMMA, Jeff S.: Cooperative control and potential games. In: *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on* 39 (2009), Nr. 6, S. 1393–1407
- [Mei11] MEINERT, Heike S.: *Untersuchung von robusten modellprädiktiven Regelungen zur Anwendung in der Flugführung*. Verlag Dr. Hut, 2011
- [MHM08] MOHAMED H. MABROUK, Colin R. M.: An Emergent Wall Following Behaviour to Escape Local Minima for Swarms of Agents. In: *IAENG International Journal of Computer Science* (2008)
- [ML05] MAGNUS LINDHE, et a.: Flocking with Obstacle Avoidance: A New Distributed Coordination Algorithm Based on Voronoi Partitions. In: *Proceedings of the IEEE International Conference on Robotics and Automation* (2005)
- [MLT07] MATHIA, Karl ; LAFFERRIERE, Gerardo ; TITENSOR, Todd: Cooperative control of UAV platoons – a prototype. In: *Euro UAV Conference and Exhibition, Paris, France, 2007*, S. 13–15
- [MNB03] MADJIDI, Hossein ; NEGAHDARIPOUR, Shahriar ; BANDARI, Esfandiar: Vision-based positioning and terrain mapping by global alignment for UAVs. In: *IEEE Conference on Advanced Video and Signal Based Surveillance IEEE*, 2003, S. 305–312
- [MWO05] MATTHEW W. ORR, et a.: Framework for Developing and Evaluating MAV Control Algorithms in a Realistic Urban Setting. In: *American Control Conference* (2005)
- [Nae04] NAEEM, W.: A genetic algorithm-based model predictive control autopilot design and its implementation in an autonomous underwater vehicle. In: *Proc. Instn Mech. Engrs Vol. 218 Part M: J. Engineering for the Maritime Environment* (2004)
- [NAS] NASA: *NASA Photograph by Carla Thomas*. <http://earthobservatory.nasa.gov/IOTD/view.php?id=43291>
- [NI03] NAKANISHI, Hiroaki ; INOUE, Koichi: Development of Autonomous Flight Control System for Unmanned Helicopter by Use of Neural Networks. In: *Department of Aeronautics and Astronautics, Kyoto University, Japan* (2003)
- [OH09] OYEKAN, John ; HU, Huosheng: Towards autonomous patrol behaviours for UAVs. In: *Proceedings of UK EPSRC Workshop on Human Adaptive Mechatronics, Staffordshire University, Stafford, UK, 2009*, S. 15–16
- [OS07] OLFATI-SABER, Reza: Distributed Kalman filtering for sensor networks. In: *46th IEEE Conference on Decision and Control IEEE*, 2007, S. 5492–5498

-
- [OSM02] OLFATI-SABER, R. ; MURRAY, R. M.: Distributed Cooperative Control of Multiple Vehicle Formations using Structural Potential Functions. In: *The 15th IFAC World Congress , Barcelona, Spain* (2002)
- [Pan06] PANNEK, Jürgen: Modellprädiktive Regelung. In: *Seminarskript - Mathematisches Institut - Universität Bayreuth* (2006)
- [Par98] PARKER, Lynne E.: Alliance: An architecture for fault tolerant multirobot cooperation. In: *Robotics and Automation, IEEE Transactions on* 14 (1998), Nr. 2, S. 220–240
- [Par09] PARKER, Lynne E.: Path planning and motion coordination in multiple mobile robot teams. In: *Encyclopedia of complexity and system science* (2009), S. 5783–5800
- [PB08] PHAN, Minh Q. ; BARLOW, Jonathan S.: Optimal model predictive control formations. In: *Chinese Control and Decision Conference IEEE*, 2008, S. 55–64
- [PDA⁺04] PRIEDITIS, Armand ; DALAL, Mukesh ; ARCILLA, Andrew ; GROEL, Brett ; VANDER BOCK, Michael ; KONG, Richard: SmartSwarms: Distributed UAVs that Think / DTIC Document. 2004. – Forschungsbericht
- [PDTY09] PACK, Daniel J. ; DELIMA, Pedro ; TOUSSAINT, Gregory J. ; YORK, George: Cooperative control of UAVs for localization of intermittently emitting mobile targets. In: *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on* 39 (2009), Nr. 4, S. 959–970
- [PKG08] PAUL, T. ; KROGSTAD, T.R. ; GRAVDAHL, J.T.: UAV formation flight using 3D potential field. In: *16th Mediterranean Conference on Control and Automation*, 2008, S. 1240 –1245
- [PR04] PONGPUNWATTANA, Anawat ; RYSDYK, Rolf: Real-time planning for multiple autonomous vehicles in dynamic uncertain environments. In: *Journal of Aerospace Computing, Information, and Communication* 1 (2004), Nr. 12, S. 580–604
- [PSL06] PRICE, Kenneth ; STORN, Rainer M. ; LAMPINEN, Jouni A.: *Differential evolution: a practical approach to global optimization*. Springer Science & Business Media, 2006
- [Rau03] RAU, Martin: *Nichtlineare modellbasierte prädiktive Regelung auf Basis lernfähiger Zustandsraummodelle*, Technische Universität München Fakultät für Elektrotechnik und Informationstechnik, Diss., 2003
- [RBTH02] RICHARDS, Arthur ; BELLINGHAM, John ; TILLERSON, Michael ; HOW, Jonathan: Coordination and control of multiple UAVs. In: *AIAA guidance, navigation, and control conference, Monterey, CA*, 2002

-
- [Rey87] REYNOLDS, Craig W.: Flocks, herds and schools: A distributed behavioral model. In: *ACM Siggraph Computer Graphics* 21 (1987), Nr. 4, S. 25–34
- [Rey00] REYNOLDS, Craig W.: Interaction with groups of autonomous characters. In: *Game Developers Conference*, 2000, S. 449–460
- [RS99] ROSALES, Romer ; SCLAROFF, Stan: 3D trajectory recovery for tracking multiple objects and trajectory guided recognition of actions. In: *IEEE Computer Society Conference on Computer Vision and Pattern Recognition* Bd. 2 IEEE, 1999
- [RST05] RYOO, Chang-Kyung ; SHIN, Hyo-Sang ; TAHK, Min-Jea: Optimal waypoint guidance synthesis. In: *Proceedings of IEEE Conference on Control Applications* IEEE, 2005, S. 1349–1354
- [RWB06] RANDAL W. BEARD, et a.: Decentralized Cooperative Aerial Surveillance Using Fixed-Wing Miniature UAVs. In: *Proceedings of the IEEE* 94 (2006), S. 1306–1324
- [RWL02] R. W. LAWTON, B. J. Y. J. R. T. Beard B. J. R. T. Beard: A Decentralized Approach to Formation Maneuvers. In: *IEEE Trans. on Robotics and Automation* (2002)
- [Sch13] SCHILLING, Klaus: Technologies to realize distributed networked pico-satellite systems. In: *IAA Small Satellite Conference, Berlin* (2013)
- [Ser] SERVICE, FAA Flight S.: *Advanced Avionics Handbook, 2009*. U.S. Department of Transportation
- [SK07] SEUNGKEUN KIM, Youdan K.: Three Dimensional Optimum Controller for Multiple UAV Formation Flight Using Behavior-based Decentralized Approach. In: *International Conference on Control, Automation and Systems* (2007)
- [SKI05] SHIMODA, S. ; KURODA, Y. ; IAGNEMMA, K.: Potential Field Navigation of High Speed Unmanned Ground Vehicles on Uneven Terrain. In: *IEEE International Conference on Robotics and Automation*, 2005, S. 2828 – 2833
- [SML⁺07] SINSLEY, Gregory L. ; MILLERT, Jodi A. ; LONG, Lyle N. ; GEIGER, Brian R. ; NIESSNER, Albert F. J. ; HORN, Joseph F.: An Intelligent Controller for Collaborative Unmanned Air Vehicles. In: *IEEE Symposium on Computational Intelligence in Security and Defense Applications* (2007)
- [SMT03] SHERKNIES, Denis ; MEUNIER, Jean ; TARDIF, J-C: 3D path recovery of an ivus transducer with single-plane angiography. In: *Canadian Conference on Electrical and Computer Engineering* Bd. 3 IEEE, 2003, S. 1489–1492
- [SP96] SPOONER, Jeffrey T. ; PASSINO, Kevin M.: Stable adaptive control using fuzzy systems and neural networks. In: *Fuzzy Systems, IEEE Transactions on* 4 (1996), Nr. 3, S. 339–359

-
- [SS06] SARA SUSCA, Francesco B. Sonia Martinez M. Sonia Martinez: Monitoring Environmental Boundaries with a Robotic Sensor Network. In: *American Control Conference Minneapolis (2006)*
- [TB98] T. BALCH, R. A.: Behavior-based formation control for multi-robot teams. In: *IEEE Trans. on Robotics and Automation* 14 (1998), S. 926–939
- [TRK⁺08] TISDALE, John ; RYAN, Allison ; KIM, Zu ; TORNQVIST, D ; HEDRICK, J K.: A multiple UAV system for vision-based search and localization. In: *American Control Conference IEEE, 2008*, S. 1985–1990
- [TZW07] TSOURDOS, Antonios ; ZBIKOWSKI, Rafal ; WHITE, BA: Cooperative control strategies for swarm of unmanned aerial vehicles under motion uncertainty. In: *Institution of Engineering and Technology Conference on Autonomous Systems IET, 2007*, S. 1–5
- [Vie08] VIEIRA, H: Modified multiple sample correlation algorithm for electronic target location. In: *Aerospace and Electronic Systems Magazine, IEEE* 23 (2008), Nr. 8, S. C–1
- [VTHKB07] VAN TOOREN, J ; HENI, M ; KNOLL, A ; BECK, J: Development of an autonomous avoidance algorithm for UAVs in general airspace. In: *Proceedings of First CEAS European Air and Space Conference, 2007*
- [WB06] WELCH, Greg ; BISHOP, Gary: An Introduction to the Kalman Filter. In: *University of North Carolina: Chapel Hill, North Carolina, US (2006)*
- [WC09] WEI CHEN, Mei C. Xin Li L. Xin Li: Suboptimal Nonlinear Model Predictive Control Based on Genetic Algorithm. In: *Third International Symposium on Intelligent Information Technology Application Workshops (2009)*
- [WD08] WENJIE DONG, Jay A. F.: Cooperative Control of Multiple Nonholonomic Mobile Agents. In: *IEEE TRANSACTIONS ON AUTOMATIC CONTROL* 53 (2008)
- [Wei09] WEISE, Thomas: *Global optimization algorithms-theory and application*. Citeseer, 2009
- [Whi01] WHITLEY, Darrell: An overview of evolutionary algorithms: practical issues and common pitfalls. In: *Information and software technology* 43 (2001), Nr. 14, S. 817–831
- [Wis06] WISE, Richard: *UAV Control and Guidance for Autonomous Cooperative Tracking of a Moving Target*, University of Washington, Diss., 2006
- [Yan09] YANOU, Akira: Two Degree-of-Freedom of Generalized Predictive Control Based on Polynomial Approach Using a Genetic Algorithm. In: *IEEE International Conference on Networking, Sensing and Control, Okayama, Japan (2009)*

-
- [Yeg09] YEGNANARAYANA, B: *Artificial neural networks*. PHI Learning Pvt. Ltd., 2009
- [YK04] YOSHIKI KUWATA, Jonathan H.: Three Dimensional Receding Horizon Control for UAVs. In: *AIAA Guidance, Navigation, and Control Conference and Exhibit* (2004)
- [YZ09] YI ZHU, et a.: An Improved Wall Following Method for Escaping from Local Minimum in Artificial Potential Field Based Path Planning. In: *Joint 48th IEEE Conference on Decision and Control and 28th Chinese Control Conference* (2009)
- [Zil96] ZILBERSTEIN, Shlomo: Using anytime algorithms in intelligent systems. In: *AI magazine* 17 (1996), Nr. 3, S. 73



Anhang

A Extended Kalman Filter (EKF)

Der hier verwendete EKF ist nach einer Veröffentlichung von Greg Welch und Gary Bishop [WB06] implementiert. Die Abbildung 6.1 zeigt den Ablauf des EKF-Algorithmus, wobei folgende Zustände, Eingänge, Gleichungen und Parameter verwendet werden:

$$\hat{x} = [a_{pol} \quad x_{pol} \quad y_{pol}]^T \quad (6.1)$$

$$\hat{x}_k^- = \hat{x}_{k-1}^- \quad (6.2)$$

$$h = e^{-a_{pol} \sqrt{(x_{pol} - x_{UAV})^2 + (y_{pol} - y_{UAV})^2}} \quad (6.3)$$

$$z_k = c_{UAV} \quad (6.4)$$

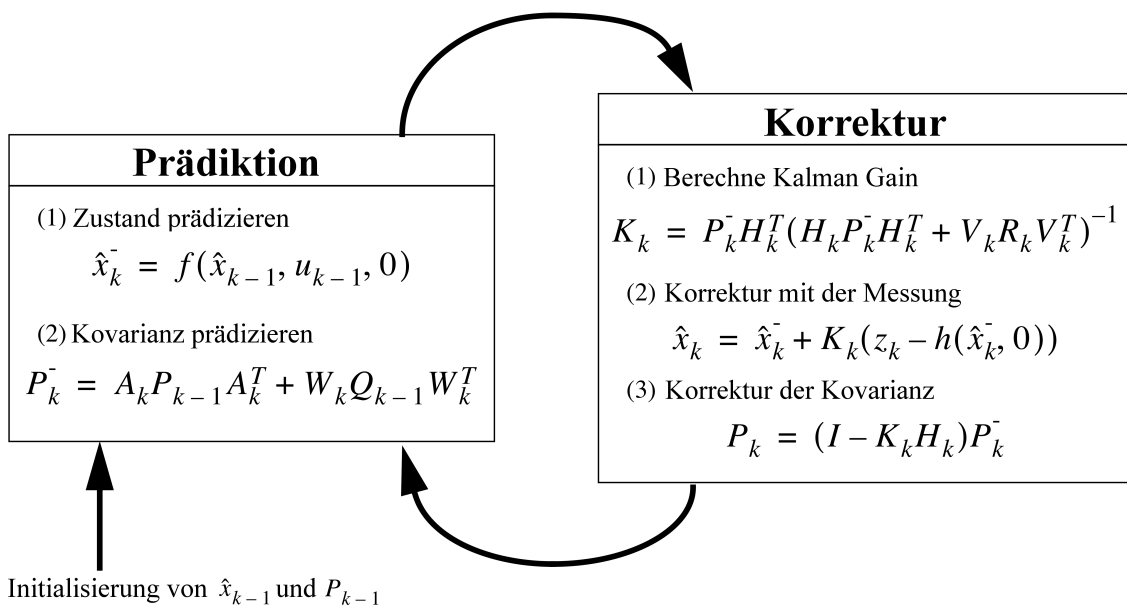


Abbildung 6.1: Extended Kalman Filter nach [WB06]

Die Initialisierung erfolgt mit:

$$\hat{x}_{k-1}^0 = [a_{pol_0} \quad x_{pol_0} \quad y_{pol_0}]^T \quad (6.5)$$

$$P_{k-1}^0 = \begin{bmatrix} 10^{-4} & 0 & 0 \\ 0 & 10^4 & 0 \\ 0 & 0 & 10^4 \end{bmatrix} \quad (6.6)$$

$$A_k = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (6.7)$$

$$W_k = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (6.8)$$

$$V = 1 \quad (6.9)$$

Die H-Matrix wird durch partielle numerische Differentiation von h nach den Zuständen gebildet. Eine Analytische Differentiation ist möglich, aber wird bewusst nicht genutzt, da die Berechnung möglichst generisch gehalten werden soll.

$$H = \frac{\partial h}{\partial x} \quad (6.10)$$

Das Prozessrauschen Q wird als sehr gering bzw. praktisch nicht vorhanden angenommen.

$$Q = \begin{bmatrix} 10^{-4} & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 10 \end{bmatrix} \quad (6.11)$$

Das Messrauschen R wird mit 10^{-3} pessimistisch angenommen. Kostengünstige Sensoren zur Detektion von CO , CO_2 und C_nH_m besitzen typischerweise eine Auflösung von wenigen ppm und ein Rauschen von ca. 50 ppm (Spitze/Spitze) [KGa11].

$$R = 10^{-3} \quad (6.12)$$

Die Beobachtbarkeit ist nur durch mehrere Messungen an verschiedene Orten gewährleistet. Dies kann durch eine einziges UAV als auch durch einen Schwarm von UAVs geschehen.

B Konflikte mit anderen UAVs

Im Folgenden sind die statistischen Auswertungen der Szenarien in Kapitel 4.2 mit unterschiedlichen Optimierungsverfahren dargestellt. Im linken Teil der Abbildungen ist die Verteilung des minimalen Abstands zu den anderen UAVs dargestellt. In der Mitte ist die Verteilung des Zeitverlustes durch die Ausweichbewegung dargestellt. Im rechten Teil ist die Korrelation des minimalen Abstands und dem Zeitverlust gezeigt.

B.1 Statistik zu den Szenarien

Szenario 1




Abbildung 6.2: Statistik für das Szenario 1 mit evolutionären Optimierer (EA1)




Abbildung 6.3: Statistik für das Szenario 1 mit genetischen Optimierer (GA1)




Abbildung 6.4: Statistik für das Szenario 1 mit evolutionären Optimierer (EA3)




Abbildung 6.5: Statistik für das Szenario 1 mit genetischen Optimierer (GA3)

Szenario 2




Abbildung 6.6: Statistik für das Szenario 2 mit evolutionären Optimierer (EA1)




Abbildung 6.7: Statistik für das Szenario 2 mit genetischen Optimierer (GA1)




Abbildung 6.8: Statistik für das Szenario 2 mit evolutionären Optimierer (EA3)




Abbildung 6.9: Statistik für das Szenario 2 mit genetischen Optimierer (GA3)

Szenario 3




Abbildung 6.10: Statistik für das Szenario 3 mit evolutionären Optimierer (EA1)




Abbildung 6.11: Statistik für das Szenario 3 mit genetischen Optimierer (GA1)




Abbildung 6.12: Statistik für das Szenario 3 mit evolutionären Optimierer (EA3)




Abbildung 6.13: Statistik für das Szenario 3 mit genetischen Optimierer (GA3)

Szenario 4




Abbildung 6.14: Statistik für das Szenario 4 mit evolutionären Optimierer (EA1)




Abbildung 6.15: Statistik für das Szenario 4 mit genetischen Optimierer (GA1)




Abbildung 6.16: Statistik für das Szenario 4 mit evolutionären Optimierer (EA3)




Abbildung 6.17: Statistik für das Szenario 4 mit genetischen Optimierer (GA3)

B.2 Weitere Szenarien

Es folgen weitere Szenarien, die Beispiele für das Ausweichen von mehreren UAVs darstellen.

Szenario A

Hier soll das UAV zwei Intrudern ausweichen, welche sich unter einem Winkel von 90° aufeinander zu bewegen (Abbildung 6.18). Die Auswertung dieses Szenario ist in den Abbildungen 6.20 bis 6.24 zu sehen. Deren Resultate sind in Tabelle 6.19 zusammengefasst.




Abbildung 6.18: Beispiel für das Szenario A mit evolutionären Optimierer (EA1)

Abbildung 6.19: Resultate des Szenario mit einem Prädiktionshorizont von 10s. Bei den EA- und GA-Optimierern handelt es sich um Mittelwerten aus 100 Simulationen

Optimierer	EA1	GA1	EA3	GA3	GR1 ⁴
Kleinster geringster Abstand [m]	29	29	25	28	18
Mittlerer geringster Abstand [m]	30,2	30,4	30,3	30,6	18
Mittlerer Zeitverlust [s]	2,8	2,8	1,9	1,9	2,0
Größter Zeitverlust [s]	3,3	3,3	3,0	2,8	2,0

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist.




Abbildung 6.20: Statistik für das Szenario A mit evolutionären Optimierer (EA1)




Abbildung 6.21: Statistik für das Szenario A mit genetischen Optimierer (GA1)




Abbildung 6.22: Statistik für das Szenario A mit evolutionären Optimierer (EA3)




Abbildung 6.23: Statistik für das Szenario A mit genetischen Optimierer (GA3)




Abbildung 6.24: Beispiel für das Szenario A mit gradientenbasierten Optimierer (GR1)

Szenario B

Hier soll das UAV einem Intrudern ausweichen, welcher sich unter einem Winkel von 30° (Abbildung 6.25) nähert. Die Auswertung dieses Szenarios ist in den Abbildungen 6.26 bis 6.30 zu sehen. Deren Resultate sind in Tabelle 6.1 zusammengefasst.

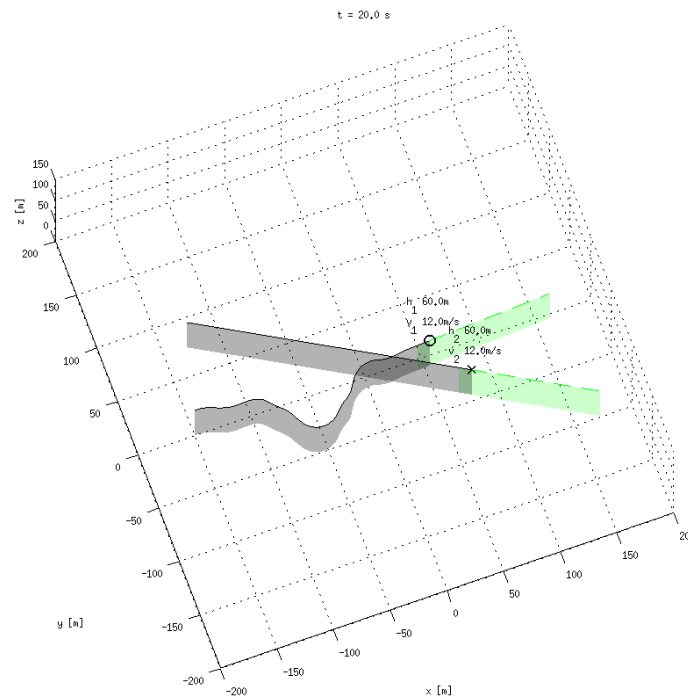


Abbildung 6.25: Beispiel für das Szenario B mit evolutionären Optimierer (*EA1*)

Tabelle 6.1: Resultate des Szenario B mit einem Prädiktionshorizont von 10s. Bei den *EA*- und *GA*-Optimierern handelt es sich um Mittelwerten aus 100 Simulationen

Optimierer	<i>EA1</i>	<i>GA1</i>	<i>EA3</i>	<i>GA3</i>	<i>GR1</i> ⁴
Kleinster geringster Abstand [m]	29	24	29	27	50
Mittlerer geringster Abstand [m]	30,5	30,6	31,1	31,56	50
Mittlerer Zeitverlust [s]	3,0	2,9	2,2	2,0	8,0
Größter Zeitverlust [s]	4,4	4,4	4,6	4,8	8,0

⁴ Einzelne Simulation, da das Optimierungsverfahren deterministisch ist.




Abbildung 6.26: Statistik für das Szenario B mit evolutionären Optimierer (EA1)




Abbildung 6.27: Statistik für das Szenario B mit genetischen Optimierer (GA1)




Abbildung 6.28: Statistik für das Szenario B mit evolutionären Optimierer (EA3)




Abbildung 6.29: Statistik für das Szenario B mit genetischen Optimierer (GA3)




Abbildung 6.30: Beispiel für das Szenario B mit gradientenbasierten Optimierer (GR1)

C Wegpunkte als Missionsziel

Beispiele aus der Untersuchung der Szenarien aus Kapitel 4.3.2 mit unterschiedlichen Optimierungsalgorithmen.

C.1 Szenarien ohne Hindernisse




Abbildung 6.31: Anfliegen von Wegpunkten ohne Hindernisse im Schwarm unter der Verwendung eines evolutionären Algorithmus(EA1)




Abbildung 6.32: Anfliegen von Wegpunkten ohne Hindernisse im Schwarm unter der Verwendung eines genetischen Algorithmus (GA1)

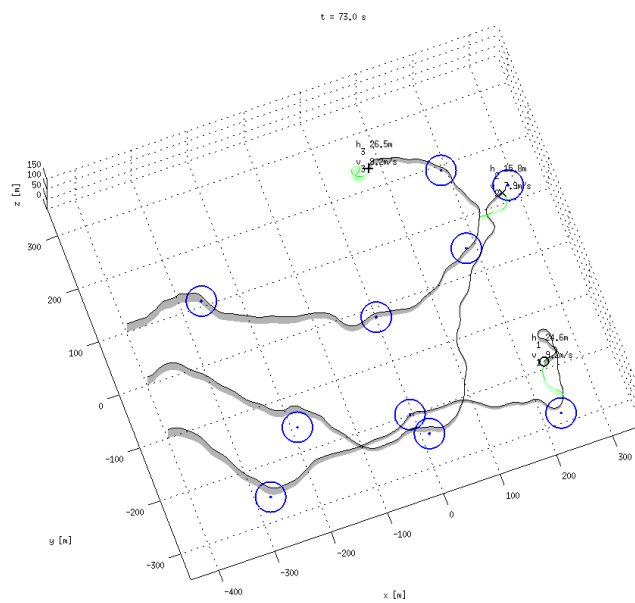


Abbildung 6.33: Anfliegen von Wegpunkten ohne Hindernisse im Schwarm unter der Verwendung eines evolutionären Algorithmus (EA3)




Abbildung 6.34: Anfliegen von Wegpunkten ohne Hindernisse im Schwarm unter der Verwendung eines genetischen Algorithmus (GA3)




Abbildung 6.35: Anfliegen von Wegpunkten ohne Hindernisse im Schwarm unter der Verwendung eines gradientenbasierten Algorithmus (GR1)




Abbildung 6.36: Anfliegen von Wegpunkten ohne Hindernisse im Schwarm unter der Verwendung eines *Brute-Force-Algorithmus (BF1)*

C.2 Szenarien mit Hindernissen

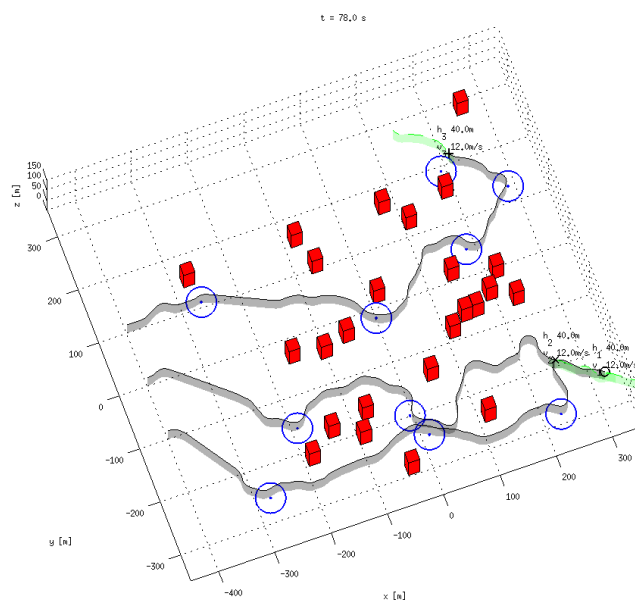


Abbildung 6.37: Anfliegen von Wegpunkten mit Hindernissen im Schwarm unter der Verwendung eines evolutionären Algorithmus (*EA1*)

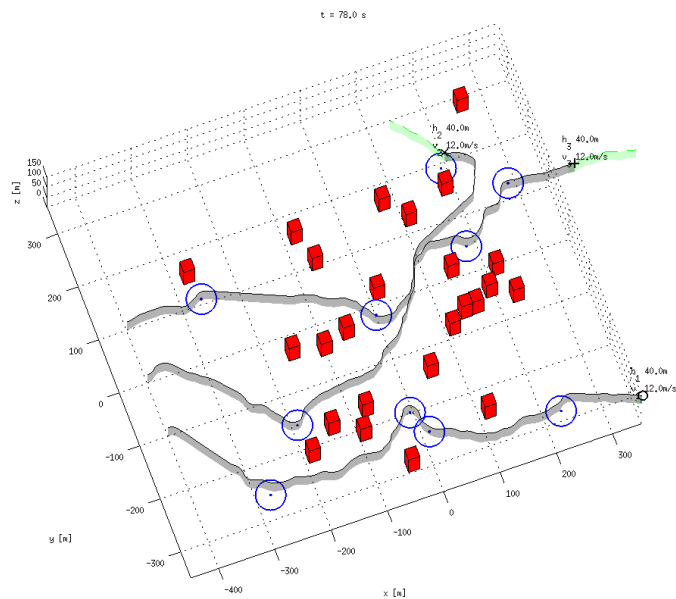


Abbildung 6.38: Anfliegen von Wegpunkten mit Hindernissen im Schwarm unter der Verwendung eines genetischen Algorithmus (GA1)




Abbildung 6.39: Anfliegen von Wegpunkten mit Hindernissen im Schwarm unter der Verwendung eines evolutionären Algorithmus (EA3)

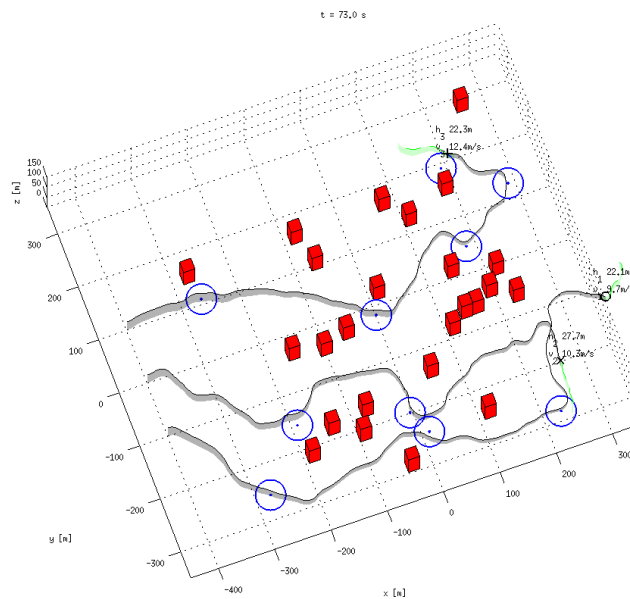


Abbildung 6.40: Anfliegen von Wegpunkten mit Hindernissen im Schwarm unter der Verwendung eines genetischen Algorithmus (GA3)

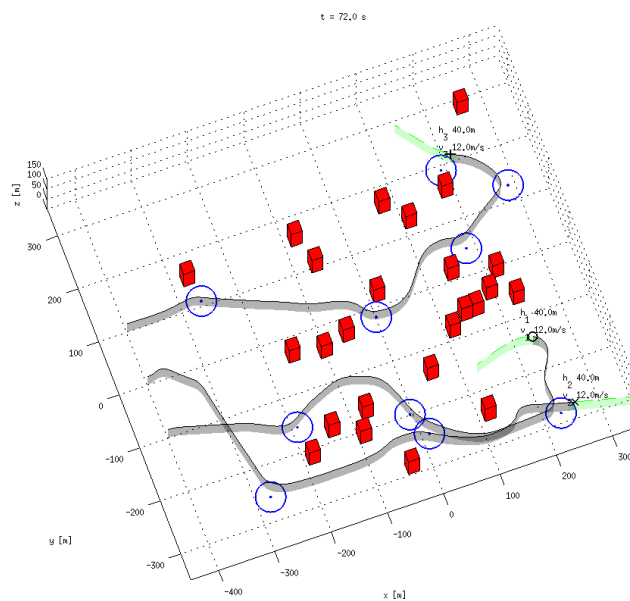


Abbildung 6.41: Anfliegen von Wegpunkten mit Hindernissen im Schwarm unter der Verwendung eines gradientenbasierten Algorithmus (GR1)

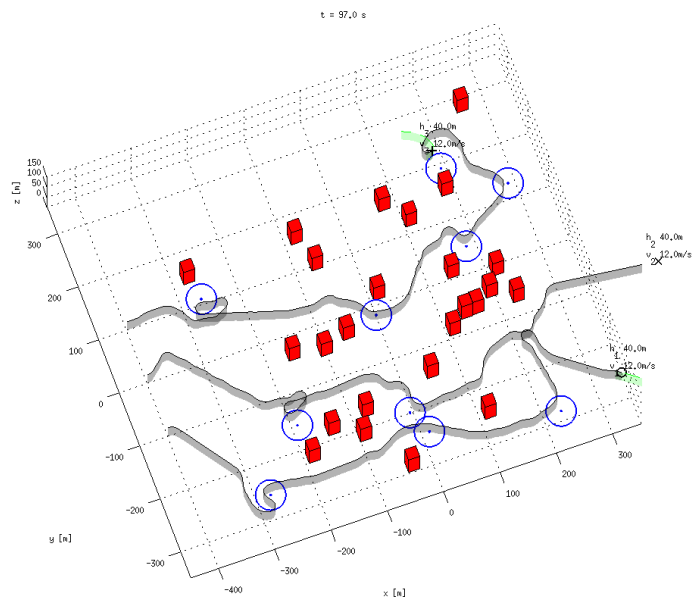


Abbildung 6.42: Anfliegen von Wegpunkten mit Hindernissen im Schwarm unter der Verwendung eines *Brute-Force-Algorithmus* (*BF1*)

D Robustheit/Sensitivität der Regelung

Resultate der Variation der Modellzustände v^* und ϕ^* um 50% (Abbildung 6.43) bzw. 70% (Abbildung 6.44) auf Basis des genetischen Algorithmus (GA1).




Abbildung 6.43: Resultat einer Sensitivitätsanalyse für das UAV-Modell mit 50% Variation - Benötigte Zeit für die Aufgabe t in Abhängigkeit von v^* und ϕ^* (GA1)




Abbildung 6.44: Resultat einer Sensitivitätsanalyse für das UAV-Modell mit 70% Variation (GA1)