Stefan Notter

Autonomes Segelfliegen – Aufwinde erfassen und intelligent nutzen

Den antriebslosen Flug zu untersuchen und technisch umzusetzen ist die ursprünglichste Form der Wissenschaft in der Luftfahrttechnik [1] [2]. Otto Lilienthal nimmt Wissenschaftler in die Pflicht „nicht eher zu ruhen, als bis wir [...] dasjenige künstlich ausführen lernen, was uns die Natur im Vogelfluge täglich vor Augen führt“ [2]. Von den Anfängen bis heute wurden im Rahmen der Segelfliegerei neue Technologien in der Luftfahrt entwickelt und erprobt – am offenkundigsten in den Fachbereichen Leichtbau und Aerodynamik. Aber auch für neuartige Verfahren in der Regelungstechnik stellt der taktisch geprägte Segelflug ein spannendes Anwendungsfeld dar. Fliegen ohne eigenen Antrieb erfordert ein ständiges Abwägen zwischen völlig gegensätzlichen Handlungsrichtungen: Primäres Ziel beim Überland-Segelflug ist eine vorgegebene Strecke schnellstmöglich zurückzulegen. Zugleich erfordert das Erreichen des Missionsziels das Nutzen von Aufwinden, um die geforderte Reichweite im antriebslosen Flug zu erzielen. Aufwinde nutzen zu können wiederum erfordert seinerseits ein Erkunden und Kartieren der das Flugzeug umgebenden Atmosphäre.

Dieser Beitrag behandelt zwei Aspekte der Automatisierung des Segelfliegens: Im ersten Teil *Aufwindschätzer und Beobachtbarkeitsanalyse* wird ein Verfahren beschrieben, welches erlaubt, mehrere thermische Aufwinde basierend auf im Flug erfassten Messgrößen automatisiert zu lokalisieren sowie deren Ausprägung zu schätzen. Ein wichtiger Gesichtspunkt im Rahmen der Aufwindschätzung ist die Beurteilung der erreichbaren Schätzgüte. Diese wird anhand der zum jeweiligen Zeitpunkt in der Messtrajektorie enthaltenen Information bewertet. Insbesondere wird gezeigt, dass typische Bewegungsformen von Segelflugzeugen zum Verlust der Beobachtbarkeit führen. Der zweite Teil dieses Beitrags *Intelligente Bewegungsplanung* behandelt die autonome Bewegungsplanung auf der Grundlage der Idee des Bestärkenden Lernens, welche erlaubt, die oben beschrieben taktische Abwägung in Gegenwart einer nur unvollständig be-

Kurzzusammenfassung:

Geschicktes Ausnutzen thermischer Aufwinde erlaubt es Segelflugpiloten große Distanzen emissionsfrei zurückzulegen. Fliegen ohne eigenen Antrieb erfordert dabei ein ständiges Abwägen zwischen völlig gegensätzlichen Handlungsrichtungen. Aufgrund der Notwendigkeit zur taktischen Abwägung sowie wegen des stochastischen, nur schwer zu modellierende Charakters der Umgebung ist die Bahnplanung im Überland-Segelflug eine spannende Aufgabe für die Anwendung und Erprobung von Bestärkendem Lernen. Vorgestellt wird außerdem ein Verfahren zum integrierten Lokalisieren und Charakterisieren mehrerer thermischer Aufwinde auf Basis eines Partikelfilters. Eine Beobachtbarkeitsanalyse erlaubt dabei eine Bewertung der erreichbaren Schätzgüte.
Durch Einsatz der erforschten Verfahren kann beispielsweise das Missionsprofil von unbemannten Flächenflugzeugen mit eingeschränkter Reichweite erweitert werden. Zunächst aber ist die Automatisierung des Segelflugs eine spannende ingenieurtechnische Herausforderung und geeignete Spielwiese zur wissenschaftlichen Auseinandersetzung mit neuartigen Verfahren in der Flugregelung.

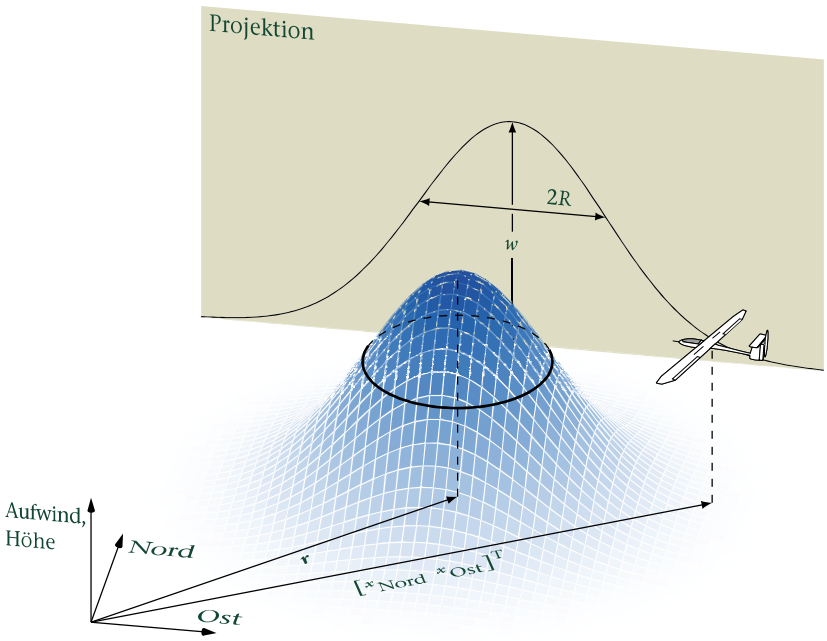

Abbildung 1:
Modell eines thermischen Aufwinds, parametrisiert durch die zu schätzenden Größen: Position (r), Stärke (w), Ausdehnung (R)

kannten, stochastischen Umgebung zu automatisieren.

I. Integrierte Aufwindschätzung

Im Folgenden wird eine Methode dargelegt, welche erlaubt die Position und Ausprägung thermischer Aufwinde zu schätzen. Das hier vorgeschlagene Verfahren erlaubt das integrierte Lokalisieren und Charakterisieren mehrerer Aufwinde. Simulationsergebnisse zeigen die generelle Eignung des Verfahrens. Die Auswertung von im Flug erfassten Messdaten erlaubt eine Einschätzung bezüglich der Zulänglichkeit unter realen Bedingungen. Eine Beobachtbarkeitsanalyse der benannten Schätzaufgabe ist im Abschnitt *Beobachtbarkeit und Erreichbare Schätzgüte* beschrieben.

Partikelfilter und Clusteranalyse

Modellfreie Ansätze zur Schätzung von Aufwindfeldern ermöglichen die Kartierung des Luftmassensteigens von mehreren Aufwindgebilden beliebiger Art und Ausprägung [3] [4]. Dementgegen stehen modellbasierte Schätzer, welche Ort und Struktur eines speziellen Aufwindgebildes, beispielsweise eines idealtypischen thermischen

Aufwinds, schneller erfassen können [5] [6] [7]. Das hier vorgeschlagene Verfahren zielt darauf ab die Vorteile zu vereinen: Einerseits werden Parameter eines physikalisch-motivierten Aufwindmodells geschätzt, andererseits erlaubt der vorgeschlagene Partikelfilter das integrierte Erfassen mehrerer Aufwindgebilde, von zwar gleicher Art aber unterschiedlicher Position und Ausprägung.

Das Standardmodell für thermische Aufwinde beschreibt das Luftmassensteigen als Gauß-Verteilung, parametrisiert durch die zu schätzenden Größen: Position, Stärke und Ausdehnung. Das so beschriebene Aufwindmodell ist in *Abbildung 1* dargestellt. Die Schätzung basiert auf der (pseudo-) Messung des lokalen Luftmassensteigens am Ort des Flugzeugs, welches seinerseits aus der Differenz der Fahrzeug-Geschwindigkeit gegenüber Grund (Satellitennavigation, z. B. GPS) und der Sinkgeschwindigkeit gegenüber der umgebenden Luftmasse (aus Staudruck, Anstell- und Schiebewinkel sowie Lageschätzung) berechnet werden kann. Die Grundidee eines Partikelfilters ist das Approximieren der Wahrscheinlichkeitsdichte durch eine Vielzahl diskreter Zustandshypothesen – der „Partikel". Anders als beispielsweise der (ganz zu Recht) populäre Kalman-Filter stellt dieser Ansatz keine Anforderung an die Form der Dichtefunktion. Dadurch können beliebige Verteilungen erfasst werden. Insbesondere äußert sich eine multimodale Verteilung der Zustandsgrößen in mehreren Häufungspunkten der Partikel im Zustandsraum. *Abbildung 2* illustriert die diskrete Approximation bezüglich der Positionsschätzung für ein Szenario mit zwei Aufwinden. Um diese Häufungen automatisiert separaten Aufwinden zuzuordnen, wird eine Cluster-Analyse durchgeführt. Dabei stellt die vorgestellte Aufgabe Anforderungen an das Verfahren:

- Die Anzahl der zu schätzenden Aufwinde ist im Vorhinein nicht bekannt. Das Verfahren muss eine beliebige Anzahl an Clustern erfassen können.
- Die Verteilung der Partikel innerhalb von Häufungen ist zufällig. Cluster müssen beliebige Formen annehmen können.
- Für eine valide Schätzung müssen die Partikel hinreichend dicht im Zustandsraum verteilt sein. Insbesondere sind nicht alle Partikel einem Aufwind zuzuordnen.

Das dichtebasierte Verfahren *DBSCAN* erfüllt diese Anforderungen [8]. Der geschätzte Zustand eines Aufwinds ergibt sich als gewichtetes Mittel aller einem Cluster zugeordneter Partikel.

„Überland-Segelfliegen erfordert eine ständige taktische Abwägung zwischen dem Verfolgen des Missionsziels, der Suche nach Aufwinden sowie deren Nutzung."

Stefan Notter

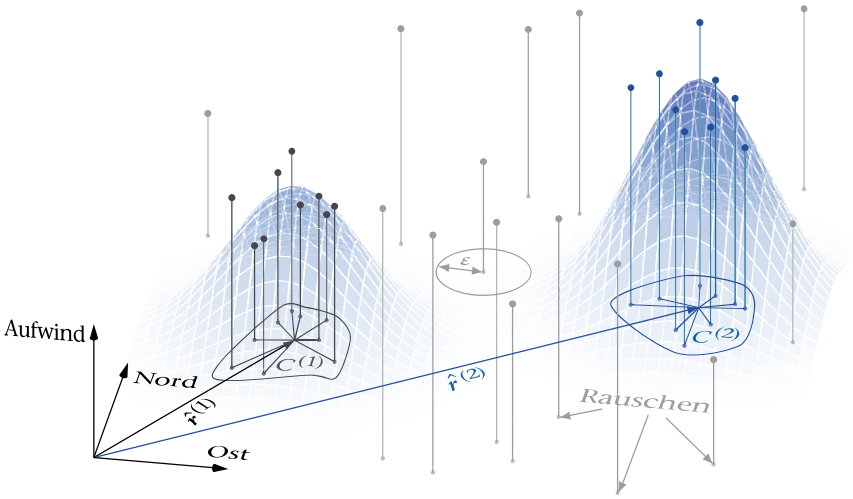

Abbildung 2: *Approximation und Clustering einer bimodalen Verteilung bezüglich der Positionsschätzung durch diskrete Zustandshypothesen*

> *„Segelfliegen ist ein bisschen wie Schach: taktisch geprägt im Angesicht einer nur schwer auszurechnenden Umgebung.“*
>
> *Stefan Notter*

Simulationsergebnisse und Flugdatenauswertung

Abbildung 3 zeigt ein simuliertes Szenario, bei dem ein Gebiet mit mehreren thermischen Aufwinden von einem Segelflugzeug beflogen wird. Neben den simulierten Aufwindverteilungen und der geflogenen Bodenspur ist ein Schnappschuss der Partikelverteilung bezüglich der Horizontalebene dargestellt. Zum abgebildeten Zeitpunkt werden drei Aufwinde vom beschriebenen Schätzer erkannt. Die jeweilige Positionsschätzung ergibt sich aus dem gewichteten Mittel der automatisch gruppierten, in *Abbildung 3* eingefärbten Partikel. Auffallend ist außerdem die relative Partikelarmut entlang der geflogenen Trajektorie zwischen den beiden zuletzt durchflogenen Aufwinden. Da das Vorkommen eines Aufwinds dort unwahrscheinlich ist, werden die Ressourcen auf Bereiche mit höherer Auftretenswahrscheinlichkeit konzentriert.

Um die Zulänglichkeit des vorgeschlagenen Verfahrens unter realen Bedingungen zu bewerten, wurde das bemannten Forschungsflugzeug *icaré 2* mit einem Mess-System ausgestattet, welches erlaubt das Luftmassen-

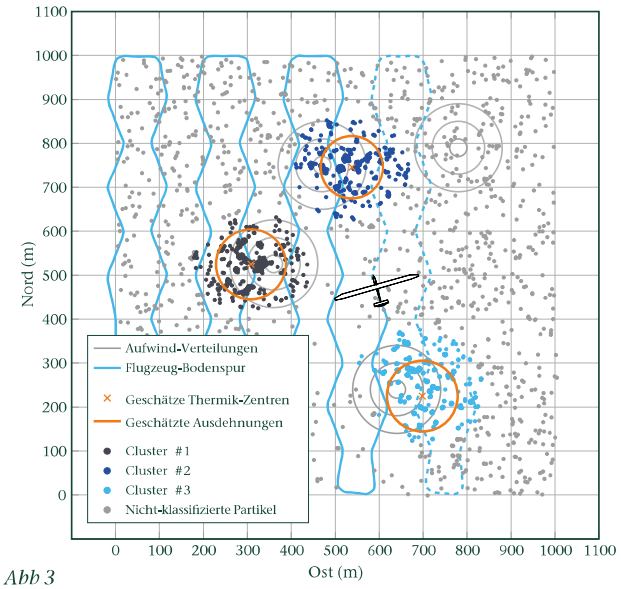

Abb 3

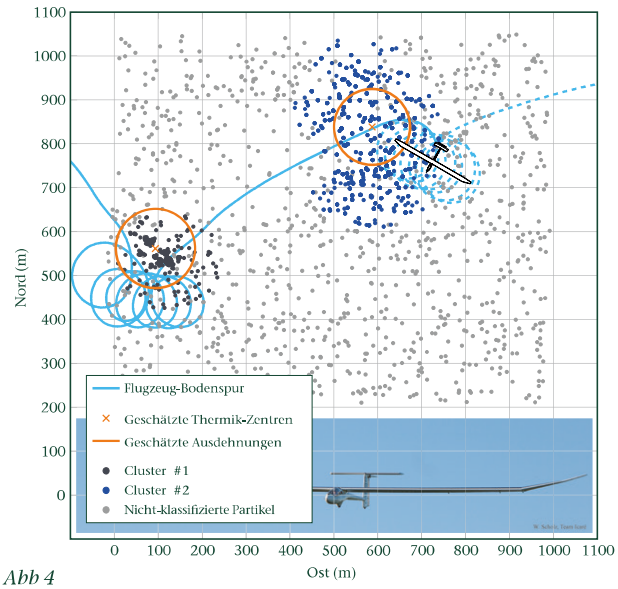

Abb 4

steigen am Ort des Fahrzeugs zu schätzen. *Abbildung 4* zeigt wiederum die Partikelverteilung in der geodätischen Horizontalebene. Im dargestellten Ausschnitt wurden nacheinander zwei separate Aufwinde angeflogen und „ausgekurbelt“. Beide Aufwinde werden zum gezeigten Zeitpunkt erkannt. Der Bereich entlang des Geradeausflug-Segments ist abermals schwach besiedelt. Die nierenförmige Verteilung der dem zweiten Aufwind zugeordneten Partikel ist typisch für das erstmalige, geradlinige Durchfliegen einer Thermik. Die Abhängigkeit der Beobachtbarkeit von der geflogenen Trajektorie wird im nachfolgenden Abschnitt diskutiert.

Beobachtbarkeit und Erreichbare Schätzgüte

Das Kartieren der Umgebung hinsichtlich des Auftretens von Aufwinden ist eine Schätzaufgabe, deren Resultat von der geflogenen Bahn – genauer: dem Zeitverlauf der erfassten Messgrößen – abhängt. Beispielsweise ist in *Abbildung 3* eine Diskrepanz der Schätzgüte zwischen den beiden Raumrichtungen offenkundig: Der Schätzfehler in Ost-Richtung ist um etwa eine Größenordnung schlechter als der Schätzfehler in Nord-Richtung. Dieser Umstand ist eine Folge des Durchfliegens der Aufwinde in Süd-Nord-, beziehungsweise Nord-

Abbildung 3:
Lokalisieren mehrerer thermischer Aufwinde (Simulationsergebnis)

Abbildung 4:
Lokalisieren mehrerer thermischer Aufwinde (Flugdatenauswertung)

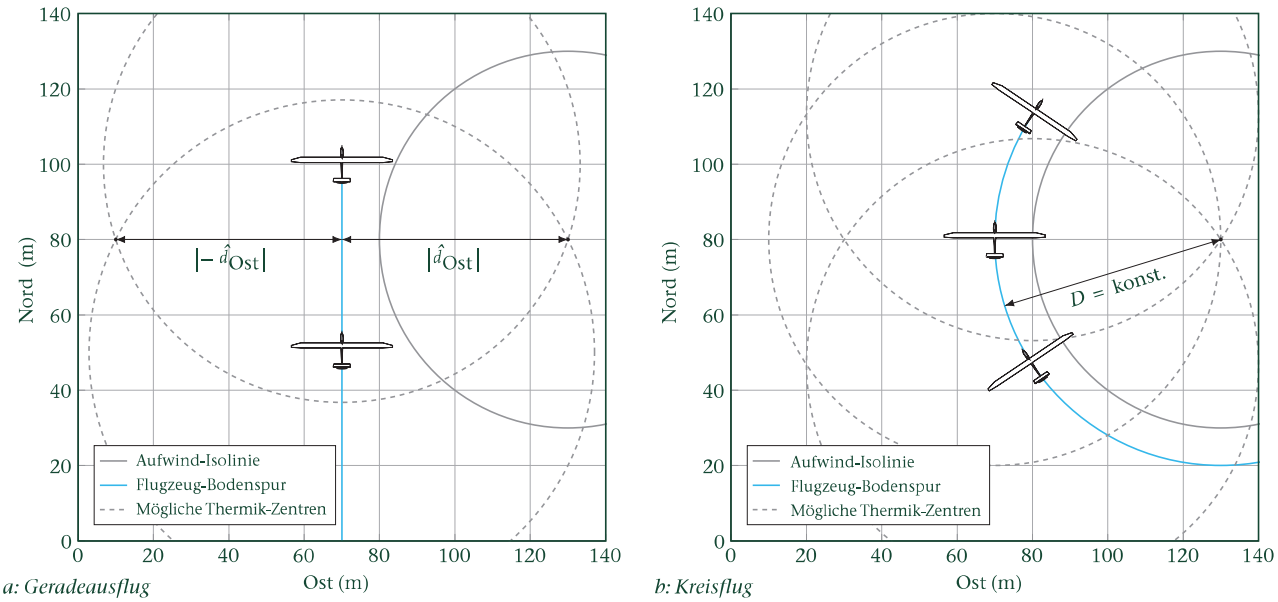

Abbildung 5:
Einfluss typischer Bewegungsformen auf die Beobachtbarkeit
a: Geradeausflug
b: Kreisflug

Süd-Richtung. Diese Trajektorie begünstigt die Schätzgüte senkrecht zur Haupt-Flugrichtung. Gerade umgekehrt stellt sich die Situation beim einmaligen, geradlinigen Durchfliegen eines Aufwindfelds dar. Wie in *Abbildung 5a* illustriert kann aufgrund des Zeitverlaufs des gemessenen Luftmassensteigens die Position des Thermik-Zentrums senkrecht zur Flugbahn dann nicht bestimmt werden. Diese Mehrdeutigkeit äußert sich beispielsweise in der nierenförmigen Verteilung der in *Abbildung 4* dem *Cluster #2* zugeordneten Partikel. Um die Beobachtbarkeit senkrecht zur Bahn zu verbessern, ist dem Suchmuster in der Simulation ein Mäandern überlagert (vgl. *Abbildung 3*). Wie der Geradeausflug beeinträchtigt auch der Kreisflug die Beobachtbarkeit. Zwar ist durch mindestens drei Messungen die Position eines idealtypischen Aufwinds beobachtbar, eine Unterscheidung zwischen einem starken Aufwind geringer Ausdehnung und einer weitläufigen, schwachen Thermik ist jedoch nicht möglich (vgl. *Abbildung 5b*).

Während sich die Beeinflussung der Beobachtbarkeit durch die Flugzeugbewegung für die beiden diskutierten Sonderfälle recht einfach darstellt, ist eine intuitive Bewertung für die nicht-lineare, zeitvariante Schätzaufgabe im Allgemeinen schwie-

rig. Die Analyse der Fisher-Information erlaubt über die binäre Aussage (Beobachtbarkeit: Ja/Nein) hinaus eine Quantifizierung der erreichbaren Schätzgüte [9] [10]. Dabei wird die in den Messungen enthaltene Information bezüglich der zu schätzenden Größen und der Informationsverlust durch Prozessrauschen bilanziert [11]. Die Inverse der Fisher-Information entspricht der Kovarianz (-Matrix), die von einem effizienten Schätzer erreicht wird. Ist die Fisher-Information null, beziehungsweise die Fisher-Informations-Matrix nicht regulär, sind die Zustandsgrößen nicht beobachtbar. Andernfalls erlaubt die so genannte Cramér-Rao-Schranke eine Abschätzung der zu erwartenden Güte und stellt eine naheliegende Zielgröße für eine, die Beobachtbarkeit maximierende, Bewegungsplanung dar.

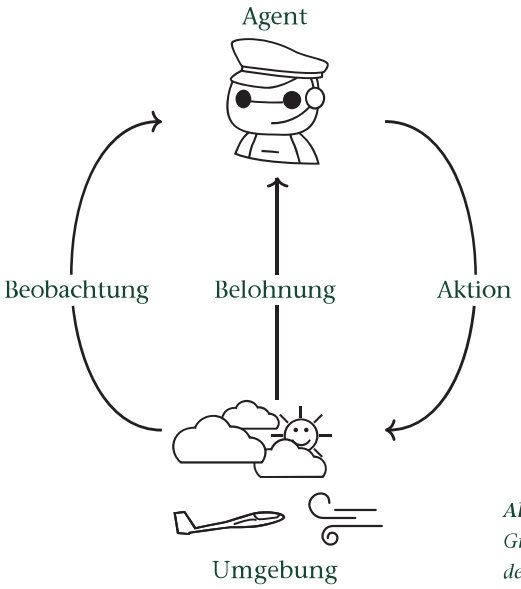

Abbildung 6:
Grundprinzip des Bestärkenden Lernen

II: Intelligente Bewegungsplanung

Die Bewegungsplanung im Segelflug, insbesondere im Überland-Segelflug, stellt den Pilot vor die Aufgabe fortlaufend taktische Entscheidungen zwischen sich widersprechenden Aktionen zu treffen. Einen Segelflug-Wettbewerb gewinnt derjenige Teilnehmer, der ein durch vorgegebene Wendepunkte aufgespanntes Dreieck schnellstmöglich abfliegt. Die Bewegungsplanung zwischen den Wendepunkten ist dem Piloten freigestellt. Insbesondere erfordert das Zurücklegen der vorgegebenen Strecke im antriebslosen Flug das Nutzen von Aufwinden. Aufwinde nutzen zu können wiederum erfordert seinerseits ein Erkunden und Kartieren der das Flugzeug umgebenden Atmosphäre. Sowohl die Exploration als auch das Nutzen von Aufwinden steht dabei zunächst im Konflikt mit der Anforderung sich dem Ziel so schnell wie möglich anzunähern, zahlt sich womöglich jedoch auf lange Sicht aus. Ambitionierte Segelflug-Piloten und Wissenschaftler haben immer wieder an der (Weiter-) Entwicklung einer optimalen Strategie gearbeitet [12] [13] [14]. Trotzdem ist das erfolgreiche Abschneiden im Wettbewerb eine Frage fliegerischer Fähigkeiten, gemachter Erfahrungen und guter Intuition geblieben.

„KI ist auch ein Hype.“
Stefan Notter

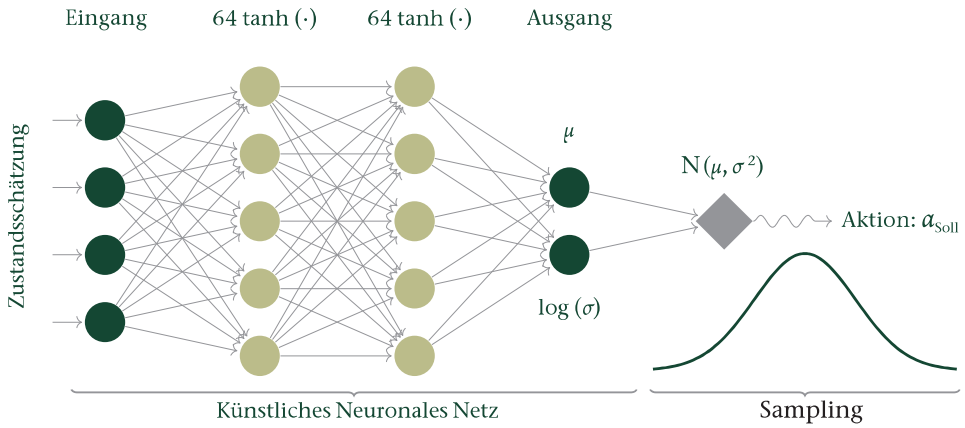

Abbildung 7: *Umsetzung des stochastischen Regelgesetzes – der „Policy“*

Bestärkendes Lernen

Verfahren aus dem Bereich des Maschinellen Lernens werden vermehrt für Aufgabestellungen der Flugregelung eingesetzt. Der Einsatz von Bestärkendem Lernen in diesem Fachgebiet ist oft „neuartig“. Weniger oft ist dabei die Herangehensweise durch die Problemstellung motiviert. Allein von der Methode auszugehen ist in der Wissenschaft nicht unüblich, aus Sicht eines Ingenieurs aber fragwürdig.

Die grundlegende Idee des Bestärkenden Lernens ist das schrittweise Optimieren des Handelns („Lernen“) allein durch wiederholte Interaktion mit der Umgebung. Dieses Grundprinzip ist in *Abbildung 6* illustriert. Ziel der Optimierung (des „Trainings“) ist das Maximieren der kumulierten Belohnung. Die Aufgabe selbst wird dabei als Markow-Entscheidungsproblem formuliert. Abweichend vom klassischen, modellbasierten Reglerentwurf wird eine Kenntnis der Zustandsübergangswahrscheinlichkeit, das heißt ein Modell der Systemdynamik, nicht explizit im Entwurf des Regelgesetzes (der „Policy“) ausgewertet. Information über die Systemdynamik ist ausschließlich in Sequenzen aus Aktionen und Beobachtungen enthalten. Bestärkendes Lernen wird daher oft als „modellfrei“ klassifiziert.

Die folgenden Aspekte einer regelungstechnischen Aufgabenstellung begünstigen den Einsatz Bestärkenden Lernens:

- Das Ziel ist leicht zu formulieren, die resultierende (Optimierungs-) Aufgabe hingegen ist komplex. Letzteres ist insbesondere dann gegeben, wenn sich kurzfristige Entscheidungen langfristig auswirken.
- Die Systemdynamik selbst kann nicht hinreichend genau formal beschrieben werden. Das gilt insbesondere für stochastische Systeme, zeitvariante Systeme oder Systeme, deren zugrundeliegenden physikalischen Mechanismen unzureichend verstanden sind.

Die Notwendigkeit zur taktischen Abwägung sowie der stochastische, nur schwer zu modellierende Charakter der Umgebung prädestiniert die Bahnplanungsaufgabe im Überland-Segelflug für die Anwendung und Erprobung von Bestärkendem Lernen im Rahmen der Flugregelung [15]. Die Aufgabe gleicht gewissermaßen dem Schachspiel: Einfaches Spielziel und taktische Prägung im Angesicht eines schwer auszurechnenden Gegenübers.

Überland-Segelflug in der Vertikalebene

Die Bahnplanungsaufgabe im Überland-Segelflug wird zunächst bezüglich der Bewegung in der Vertikalebene behandelt . Bestärkendes Lernen von Grund auf durch Interaktion mit der realen Umgebung ist für Flugregelungsaufgaben nicht praktikabel. Mindestens solange das resultierende Regelgesetz zu Abstürzen führt, bedarf die Interaktion des Agenten mit der Umgebung eines Simulationsmodells. Dieses setzt sich im diskutierten Fall aus zwei Teilmodellen zusammen:

1. Einem flugmechanischen Massepunkt-Modell der Systemdynamik mit bewegter Atmosphäre; der flugmechanische Zustand wird durch Position und Bahngeschwindigkeit beschrieben. Als Stellgröße wird der Anstellwinkel, also ein Maß für die Länge des Auftriebsvektors, gewählt.
2. Einem Modell der Atmosphäre; im Speziellen werden Wind und thermische Aufwinde modelliert. Bei letzteren werden Anzahl, Position und Ausprägung zufällig gezogen.

Das Optimierungsziel wird durch eine Abbildung des Systemzustands und der Aktion auf ein skalares Belohnungssignal ausgedrückt. Diese Funktion soll das Ziel einerseits eindeutig repräsentieren, andererseits spielt sie eine wichtige Rolle beim Konvergenzverhalten während des Trainings. Im vorliegenden Fall soll eine vorgegebene Distanz schnellstmöglich zurückgelegt werden. In jedem simulierten Zeitschritt, deren Gesamtheit die benötige Zeit bildet, erhält der Agent

„Maschinelles Lernen methodisch einzuordnen hilft, die entstandene Lücke zwischen „Robotik“ und „Regelungstechnik“ zu schließen.“

Stefan Notter

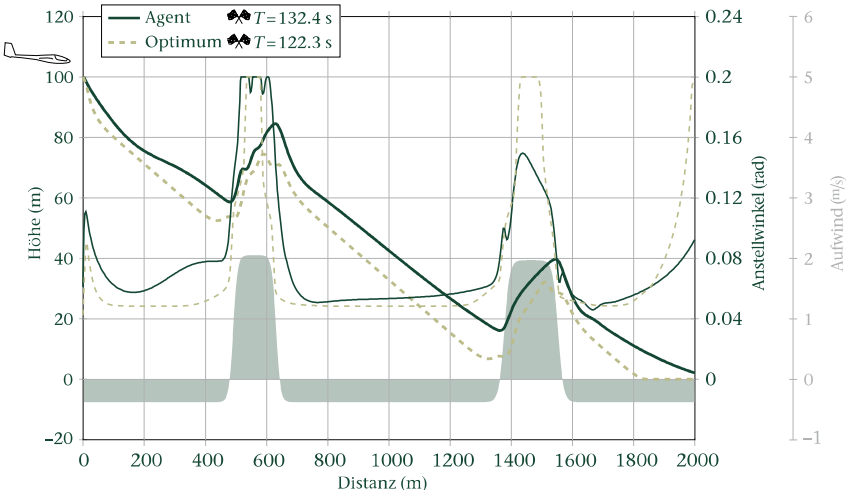

Abbildung 8:
Vergleich der Positions- und Steuerverläufe zwischen trainiertem Agent und Optimalsteuerung

einen Malus. Ebenfalls bestraft wird ein Absturz, beziehungsweise vorzeitiges (Außen-) Landen.

Das stochastische Regelgesetz (die „Policy“) ist wie in *Abbildung 7* dargestellt als Künstliches Neuronales Netz umgesetzt. Künstliche Neuronale Netze sind (nicht mehr und nicht weniger als) generische Ansatzfunktionen, deren Struktur das Optimieren ihrer Parameter numerisch begünstigt. Das Netz bildet eine Schätzung des flugmechanischen Zustands sowie des Windvektors am Ort des Fahrzeugs, bestehend aus Luftmassensteigen und Gegen-, beziehungsweise Rückenwind, auf Parameter einer Normalverteilung ab. Aus der parametrisierten Verteilung wird der kommandierte Anstellwinkel gezogen. Im Laufe des Trainings nähert sich der Erwartungswert dem Optimum bezüglich der erwarteten, kumulierten Belohnung an. Gleichzeitig wird die, für die Exploration des Zustands- und Steuerraums notwendige, Varianz reduziert.

„Bestärkendes Lernen“ bezeichnet das im vorangegangenen Abschnitt beschriebene Prinzip, nicht aber einen konkreten Algorithmus. Die Entwicklung konkreter Verfahren, die darauf abzielen aus Sequenzen aus Aktionen, Beobachtungen und Belohnungssignalen eine optimale Handlungsvorschrift abzuleiten, ist ein dynamisches Forschungsfeld in der Mathematik und der Informatik. Für die behandelte Aufgabe wird *Trust Region Policy Optimization (TRPO)* verwendet [16]. *TRPO* bezeichnet einen gradientenbasierten Algorithmus zur stabilen, schrittweisen Optimierung der Parameter des Regelgesetzes, das heißt der Gewichte

und Schwellenwerte des in *Abbildung 7* dargestellten Künstlichen Neuronalen Netzes.

Der trainierte Agent

Abbildung 8 stellt den Positions- und Steuerverlauf eines, wie im vorangegangenen Abschnitt beschrieben, trainierten Agenten dem Ergebnis der Optimalsteuerung für das dargestellte Szenario gegenüber. Die gezeigte Aufwindverteilung ist zufällig gezogen. So wie sich die Vorstellung eines Segelflugpiloten bezüglich der ihn erwartenden Aufwinde in erster Linie auf seine Erfahrung stützt, sind dem trainierten Agenten Anzahl, Position und Ausprägung der Aufwinde zunächst ebenfalls nicht bekannt. Die gegenübergestellte Optimalsteuerung hingegen setzt die vollständige Kenntnis der Umgebung voraus. Trotz des Informationsrückstands folgen Positions- und Steuerverlauf des trainierten Agenten qualitativ dem Optimum. Sinnvollerweise ist die gelernte „Policy“ konservativer als die Optimalsteuerung. So würde der trainierte Agent das Ziel beispielsweise auch dann noch erreichen, wenn er die zweite gezeigte Thermik nicht anträfe.

Gegenüber einem erfahrenen Piloten wird ein Algorithmus auf Basis der hier vorgestellten Verfahren in einem realen Segelflugwettbewerb nicht bestehen. Auch wird autonomes Segelfliegen kaum die kommerzielle Luftfahrt revolutionieren. Die wissenschaftliche Auseinandersetzung damit bleibt aber eine spannende Aufgabe.

Literatur

[1] J. W. Rayleigh, „The Soaring of Birds,“ Nature, pp. 534–535, April 1883.

[2] O. Lilienthal, Der Vogelflug als Grundlage der Fliegekunst: Ein Beitrag zur Systematik der Flugtechnik, Heyfelder, 1889.

[3] J. Bird und J. Langelaan, „Spline Mapping to Maximize Energy Exploitation of Non-Uniform Thermals,“ Technical Soaring, pp. 38–44, 3 2013.

[4] N. Depenbusch, J. Bird und L. Jack, „The AutoSOAR Autonomous Soaring Aircraft, Part 1: Autonomy Algorithms,“ Journal of Field Robotics, pp. 868–889, 6 2018.

[5] D. Edwards und L. Silberberg, „Autonomous Soaring: The Montague Cross-Country Challenge,“ Journal of Aircraft, pp. 1763–1769, 5 2010.

[6] A. Kahn, „Atmospheric Thermal Location Estimation,“ Journal of Guidance, Control, and Dynamics, pp. 2363–2369., 9 2017.

[7] P. Oettershagen, T. Stastny, T. Hinzmann, K. Rudin, T. Mantel, A. Melzer, B. Wawrzacz, G. Hitz und R. Siegwart, „Robotic Technologies for Solar-Powered UAVs: Fully Autonomous Updraft-Aware Aerial Sensing for Multiday Search-and-Rescue Missions,“ Journal of Field Robotics, pp. 612–640, 4 2018.

[8] M. Ester, . H.-P. Kriegel, J. Sander und X. Xu, „Density-based Algorithm for Discovering Clusters in Large Spatial Databases,“ in Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, Portland, Oregon, 1996.

[9] H. Cramér, „Mathematical Methods of Statistics,“ Princeton University Press, 1945.

[10] R. C. Rao, „Information and the Accuracy Attainable in the Estimation of Statistical Parameters,“ Bulletin of the Calcutta Mathematical Society, pp. 81–91, 1945.

[11] P. Tichavsky, C. Muravchik und A. Nehorai, „Posterior Cramer-Rao Bounds for Discrete-Time Nonlinear Filtering,“ IEEE Transactions on Signal Processing, pp. 1386–1396, 5 1998.

[12] P. B. MacCready Jr., „Optimum Airspeed Selector,“ Soaring, pp. 10–11, 1 1958.

[13] H. Reichmann, Cross-Country Soaring, Thomson Publications, 1978.

[14] J. H. Cochrane, „MacCready Theroy with Uncertain Lift and Limited Altitude,“ Technical Soaring, pp. 88–96, 3 1999.

[15] J. Wharington, „Autonomous Control of Soaring Aircraft by Reinforcement Learning,“ Royal Melbourne Institute of Technology, 1998.

[16] J. Schulman, S. Levine, M. I. Jordan und P. Abbeel, „Trust Region Policy Optimization,“ CoRR, 2015.