

# VERWENDUNG EINES NEURONALEN REGLERS UND EVOLUTIONÄRER ALGORITHMEN ZUR BERECHNUNG OPTIMALER INTERPLANETARER SONNENSEGLERBAHNEN

B. Dachwald

Deutsches Zentrum für Luft- und Raumfahrt e.V.  
Institut für Weltraumsensorik und Planetenerkundung  
Linder Höhe, 51147 Köln

## 1. ÜBERSICHT

Sonnensegler sind Raumfahrzeuge mit großen reflektierenden Flächen (den Sonnensegeln), welche den kontinuierlichen Strahlungsdruck der Sonne als „kostenlose“ Antriebsquelle nutzen (BILD 1). Dies macht sie zu einer effizienten Antriebsoption für Missionen mit hohem Antriebsbedarf.

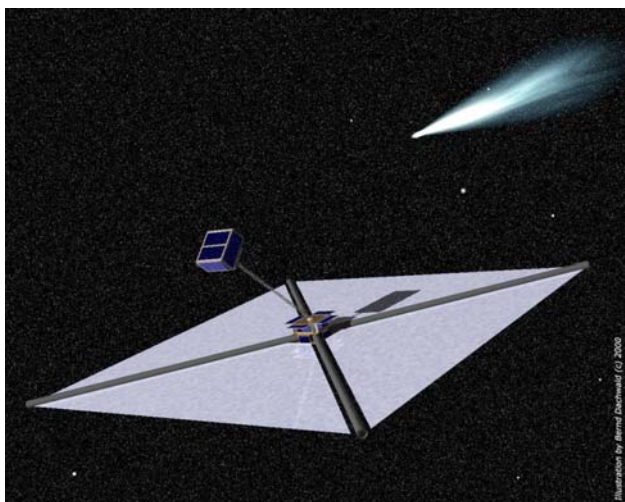


BILD 1: DLR-Sonnenseglerkonzept

Wie bei allen Raumfahrzeugen mit Niedrigschubantrieb ist das Finden von guten Sonnenseglerbahnen eine zeitraubende Arbeit. Normalerweise benutzt man dazu auf der Variationsrechnung basierende numerische Optimierungsverfahren. Das Konvergenzverhalten dieser Verfahren hängt stark von einer adäquaten Anfangsschätzung der Lösung ab, die oft nur schwer zu finden ist. Selbst wenn das Optimierungsverfahren letztendlich gegen eine „optimale Bahn“ konvergiert, so ist diese in der Regel nahe an der Anfangsschätzung und weit entfernt vom (unbekannten) globalen Optimum.

Im Folgenden wird gezeigt, dass ein neuronaler Regler (NR) in Verbindung mit einem evolutionären Algorithmus (EA) erfolgreich zur optimalen Steuerung eines Sonnenseglers eingesetzt werden kann. Diese neuartige Methode der Bahnoptimierung benötigt weder eine Anfangsschätzung noch die Mitwirkung eines Bahnmechanik-Experten. Da ein solcher evolutionärer neuronaler Regler (ENR) den Lösungsraum aller möglichen Bahnen wesentlich gründlicher durchsucht als dies ein menschlicher Experte unter Verwendung kon-

ventioneller Optimierer kann, findet er bessere Bahnen, die näher am globalen Optimum liegen. Dies wird anhand verschiedener interplanetarer Missionen demonstriert: für eine Rendezvous-Mission zu einem erdnahen Asteroiden (1996FG<sub>3</sub>), für eine Merkur-Rendezvous-Mission und für eine Pluto-Fly-By-Mission werden die vom ENR gefundenen Bahnen gezeigt und mit bisher veröffentlichten Bahnen verglichen. Obwohl ENR im vorliegenden Beitrag nur auf interplanetare Sonnenseglerbahnen angewendet werden, sind sie in ihrem Anwendungsbereich jedoch nicht auf diese Problemkategorie beschränkt, sondern können auch auf andere Bahnoptimierungsprobleme angewendet werden (z.B. für andere Antriebssysteme, für planetozentrische Bahnen etc.).

## 2. BAHNMECHANIK VON SONNENSEGLERN

Treffen Photonen auf eine Oberfläche, so übertragen sie auf diese einen Impuls. Der daraus resultierende Druck auf eine ideal reflektierende Oberfläche ist doppelt so groß wie der auf eine total absorbierende „schwarze“ Oberfläche wirkende Strahlungsdruck. Aufgrund dieses Drucks wirkt auf ein Sonnensegel eine Kraft, deren Betrag und Richtung vollständig durch den Abstand  $r$  von der Sonne und durch die Orientierung zur einfallenden Sonnenstrahlung definiert ist. Letztere kann gleichermaßen durch den Segelnormalenvektor  $\mathbf{n}$  oder durch den Uhrzeigerwinkel (clock angle)  $\alpha$  und den Anstellwinkel (cone angle)  $\beta$  beschrieben werden, da  $\alpha, \beta \Leftrightarrow \mathbf{n}$  (BILD 2).

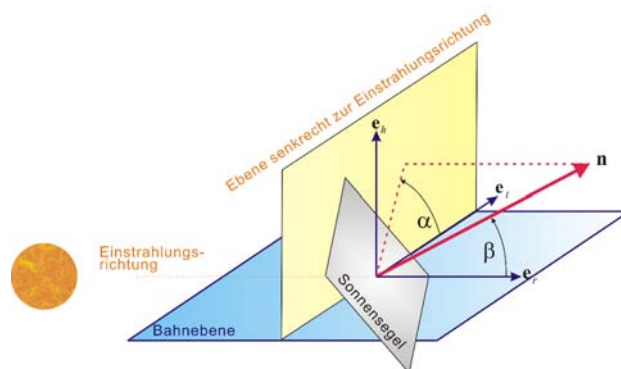


BILD 2: Definition des Uhrzeigerwinkels  $\alpha$  und des Anstellwinkels  $\beta$

BILD 3 skizziert die durch den Strahlungsdruck  $P$  auf den Flächenschwerpunkt eines flachen und ideal reflek-

tierenden Segels (ideales Segel) der Fläche  $A$  wirkenden Kraftkomponenten.

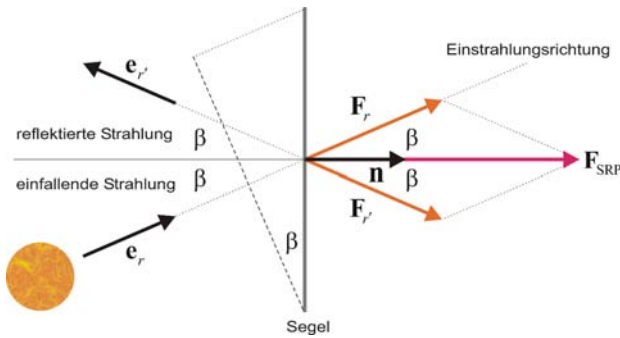


BILD 3: Ideale Reflexion

Aus der in BILD 3 dargestellten Geometrie kann die gesamte Strahlungsdruckkraft  $\mathbf{F}_{\text{SRP}}$  (SRP = Solar Radiation Pressure) einfach berechnet werden:

$$(1) \quad \mathbf{F}_{\text{SRP}} = 2PA \cos^2 \beta \mathbf{n}$$

Wie man sieht, ist  $\mathbf{F}_{\text{SRP}}$  im Falle idealer Reflexion immer in Richtung des Segelnormalenvektors  $\mathbf{n}$  gerichtet. Im Erdbestand  $r_0$  ist der solare Strahlungsdruck  $P_0 \doteq 4.653 \mu\text{N}/\text{m}^2$ . Aufgrund dieses sehr geringen Wertes, muss ein Sonnensegler große und sehr leichte Sonnensegel haben, um eine vernünftige Beschleunigung zu erfahren. Da der solare Strahlungsdruck mit  $1/r^2$  abnimmt, ist  $\mathbf{F}_{\text{SRP}}$  im Abstand  $r$  von der Sonne:

$$(2) \quad \mathbf{F}_{\text{SRP}} = 2P_0 \left(\frac{r_0}{r}\right)^2 A \cos^2 \beta \mathbf{n}$$

Die Bahnmechanik von Sonnenseglern gleicht in vielerlei Hinsicht der Bahnmechanik anderer Raumfahrzeuge, bei denen ein kontinuierlicher Schub verwendet wird, um die Bahn über einen ausgedehnten Zeitraum zu ändern. Jedoch können andere Raumfahrzeuge mit Niedrigschub ihren Schubvektor in jede gewünschte Richtung drehen und den Betrag der Schubkraft variieren. Dagegen ist der Schubvektor eines Sonnenseglers auf die Oberfläche der durch Gleichung (1) bzw. (2) definierten „ $\cos^2 \beta$ -Blase“ begrenzt (BILD 4). Obwohl diese immer von der Sonne wegzeigt, kann der Sonnensegler – je nach Orientierung zur Einstrahlungsrichtung – seinen Bahndrehimpuls erhöhen (wenn  $\mathbf{F}_{\text{SRP}} \cdot \mathbf{e}_t > 0$ ) und nach außen spiralisieren – von der Sonne weg – oder seinen Bahndrehimpuls verringern (wenn  $\mathbf{F}_{\text{SRP}} \cdot \mathbf{e}_t < 0$ ) und nach innen spiralisieren – zur Sonne hin.

### 3. EINSATZBEREICHE VON SONNENSEGLERN

Sonnensegler erlauben die Durchführung einer Vielzahl von interplanetaren Missionen, die aufgrund ihres hohen Antriebsbedarfs nur sehr schwer oder gar nicht mit anderen existierenden Antriebssystemen durchgeführt werden können. Viele dieser hochenergetischen Missionen sind von großer wissenschaftlicher Relevanz, wie z.B. eine Merkur-Mission, Missionen zu erdnahen Objekten (Asteroiden und kurzperiodischen Kometen) mit hoch

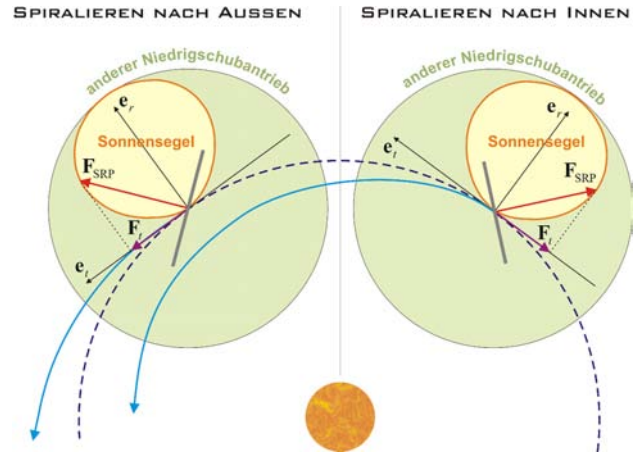


BILD 4: Spiralisieren nach innen und nach außen

inklinierten<sup>1</sup> oder sogar retrograden Bahnen und eine Pluto-Mission (inkl. Edgeworth-Kuiper-Gürtel und Heliopause). Aufgrund ihres (zumindest prinzipiell) unbegrenzten Antriebsvermögens eignen sich Sonnensegler im inneren Sonnensystem (einschließlich des Asteroidengürtels) besonders für *Mehrfach*-Rendezvous/Fly-By-Missionen, für Probenrückführmissionen und für Missionen mit hohen Inklinationsänderungen (z.B. über die Pole der Sonne). Auch Missionen in das äußere Sonnensystem sind möglich, obwohl der Strahlungsdruck der Sonne mit  $1/r^2$  abnimmt. Für solche Missionen muss der Sonnensegler erst möglichst nahe an die Sonne heranfliegen,<sup>2</sup> um seine Bahnenergie so stark zu erhöhen, dass die Bahn hyperbolisch wird (Solar-Photonic-Assist-Manöver) [1, 2, 3]. Auf diese Art und Weise können die äußeren Planeten (und der nahe interstellare Raum) in vernünftiger Zeit erreicht werden. Aufgrund der hohen hyperbolischen Überschussgeschwindigkeiten am Zielkörper sind jedoch nur schnelle Fly-Bys möglich, sofern kein zusätzliches Antriebssystem zur Verfügung steht und kein Aerocapture-Manöver durchgeführt wird.

### 4. SIMULATIONSMODELL UND PROBLEMDEFINITION

Für eine gründliche Missionsanalyse müssen die *realen* optischen Eigenschaften des Sonnensegels berücksichtigt werden, die aufgrund der Degradation durch die Weltraumumgebung zudem zeitabhängig sind. Für Missionsvoranalysen – wie sie im Rahmen dieses Beitrags durchgeführt werden – ist es jedoch zulässig, ein ideales Segel anzunehmen und folgende zusätzliche Vereinfachungen zu treffen:

- Der Sonnensegler bewegt sich unter dem alleinigen Einfluss der solaren Gravitation und Strahlung. Die Sonne ist eine Punktmasse und ein Punktstrahler. Andere Himmelskörper werden vernachlässigt. Ebenso vernachlässigt werden alle Kräfte, die wesentlich kleiner als die Gravitations- und Strahlungs-

<sup>1</sup>Über 55% der erdnahen Objekte haben eine Inklination von mehr als 10°, über 30% sogar mehr als 20°.

<sup>2</sup>evtl. mehrfach

druckkraft der Sonne sind (Sonnenwind, Aberration der Strahlung etc.).

- Die Orientierung des Sonnensegels kann instantan geändert werden.

Dieser Beitrag behandelt das Problem, eine optimale Sonnenseglerbahn (Rendezvous oder Fly-By) zu einem gegebenen Zielkörper zu finden. In der Terminologie der optimalen Steuerungstheorie [4] lautet das Rendezvous-Problem: finde einen Verlauf  $\mathbf{n}[t]$  für den Segelnormalektor (Steuervektor) (für  $t_0 \leq t \leq t_f$ ), welcher den Zustandsvektor  $\mathbf{x}(t) = (\mathbf{r}(t), \dot{\mathbf{r}}(t))$  des Sonnenseglers von seinem Anfangswert  $\mathbf{x}(t_0)$  in den Zustandsvektor  $\mathbf{x}_T(t)$  des Zielkörpers überführt (unter Berücksichtigung der Endbedingung  $\mathbf{x}(t_f) = \mathbf{x}_T(t_f)$ ) und gleichzeitig die Kostenfunktion  $J = \int_{t_0}^{t_f} dt = t_f - t_0$  minimiert.<sup>3</sup> Beim Fly-By-Problem wird lediglich die Anpassung der beiden Ortsvektoren gefordert,  $\mathbf{r}(t_0) \rightarrow \mathbf{r}_T(t_f)$ . Der resultierende Zustandsvektorverlauf  $\mathbf{x}^*[t]$  ist die optimale Bahn für das gegebene Bahnoptimierungsproblem. Das Bahnoptimierungsproblem ist deshalb eigentlich ein Suchproblem für den optimalen Steuervektorverlauf  $\mathbf{n}^*[t]$ .

## 5. OPTIMIERUNG VON SONNENSEGLERBAHNEN MIT HERKÖMMLICHEN VERFAHREN

Um gute Sonnenseglerbahnen zu finden, werden herkömmlicherweise auf der Variationsrechnung basierende numerische Verfahren eingesetzt, wie man sie auch anderweitig für Probleme der optimalen Steuerung von dynamischen Systemen verwendet (z.B. Nichtlineare Programmierung (NLP) und Gradientenabstiegsverfahren). Diese Verfahren benötigen zu Beginn eine Anfangsschätzung der Lösung. Das Konvergenzverhalten dieser Optimierungsverfahren ist oft extrem sensitiv hinsichtlich dieser Anfangsschätzung [1, 5], so dass Bahnoptimierung oft „mehr Kunst als Wissenschaft“ ist [5]. Selbst wenn das Optimierungsverfahren konvergiert, so findet es im Allgemeinen nur das der Anfangsschätzung am nächsten liegende lokale Optimum, welches in der Regel weit vom globalen Optimum entfernt ist. Wenn das Verfahren nicht konvergiert, so muss eine neue Anfangsschätzung ausprobiert werden. Da ähnliche Anfangsschätzungen oft völlig unterschiedliche Ergebnisse liefern, ist es nahezu unmöglich, die Anfangsschätzung iterativ zu verbessern, so dass die Suche nach einer guten Bahn zu einer langwierigen Angelegenheit werden kann.

## 6. NEURONALE NETZE

Neuronale Netze sind ein von der Informationsverarbeitung in biologischen Nervensystemen inspiriertes Berechnungsmodell. Im Gegensatz zu konventionellen Computern, bei denen die Informationen seriell und digital verarbeitet werden, arbeiten neuronale Netze massiv parallel und analog [7, 8, 9]. Aus Anwendersicht können neuronale Netze prinzipiell als schwarzer Kasten betrachtet

<sup>3</sup>Da Sonnensegler keinen Treibstoff verbrauchen, wird nur die Transferzeit minimiert. Die Endmasse  $m(t_f)$  ist deshalb – im Gegensatz zu anderen Raumfahrzeugen – nicht in der Kostenfunktion enthalten.

werden, der für eine bestimmte Eingabe eine bestimmte Ausgabe erzeugen soll. Intern setzen sie sich aus Berechnungseinheiten zusammen, welche die elementarsten Eigenschaften biologischer Neuronen nachahmen und in Analogie zu diesen ebenfalls als Neuronen bezeichnet werden. Miteinander verbunden, offenbaren diese Einheiten einige den biologischen Nervensystemen eigene Charakteristiken: sie können z.B. aus Erfahrung lernen, von gelernten Beispielen abstrahieren und essentielle Merkmale aus verrauschten und/oder teilweise irrelevanten Daten extrahieren [10].




BILD 5: Vorwärts gerichtetes Netz mit Schichtenarchitektur

Im Rahmen des vorliegenden Beitrags werden vorwärtsgerichtete neuronale Netze mit Schichtenarchitektur und sigmoider Aktivierungsfunktion für die Neuronen verwendet [9, 11] (BILD 5 zeigt beispielhaft ein solches neuronales Netz, ein 12-6-10-Netz mit zwölf Eingabeneuronen, einer sog. verdeckten Neuronenschicht mit sechs Neuronen und zehn Ausgabeneuronen). Solche neuronalen Netze können als stetige parametrische Funktion  $\Phi_{\boldsymbol{\pi}} : \mathcal{X} \rightarrow \mathcal{Y}$  (Netzfunktion) betrachtet werden, die eine Menge  $m$ -dimensionaler Eingabevektoren  $\mathcal{X} \subseteq \mathbb{R}^m$  auf eine Menge  $n$ -dimensionaler Ausgabevektoren  $\mathcal{Y} = (0, 1)^n$  abbildet. Der Parametervektor  $\boldsymbol{\pi} = (\pi_1, \dots, \pi_\ell)$  der Netzfunktion besteht aus den  $\ell$  internen Parametern des neuronalen Netzes,<sup>4</sup> den sog. Netzparametern.

Wenn für eine Menge von Eingabevektoren (die Trainingsmenge) der jeweils korrekte Ausgabevektor bekannt ist, so kann aus der Differenz zwischen Soll- und Ist-Ausgabe der sog. Lern- oder Netzfehler berechnet werden. Anhand des Lernfehlers können die internen Netzparameter so angepasst werden, dass der Lernfehler minimiert wird. Auf diese Weise wird die optimale Netzfunktion  $\Phi^* := \Phi_{\boldsymbol{\pi}^*}$  „gelernt“. Für diese Art von Lernproblemen existiert eine Vielzahl von Lernverfahren, mit deren Hilfe die optimalen Netzparameter  $\boldsymbol{\pi}^*$  bestimmt werden können. Das bekannteste von ihnen ist der Backpropagation-Algorithmus, ein Gradientenabstiegsverfahren [9].

## 7. REINFORCEMENT LEARNING UND NEURONALE REGLER

Lernverfahren für neuronale Netze, die eine Trainingsmenge benötigen, versagen, wenn es keine Eingaben gibt, für welche die korrekten Ausgaben bekannt sind. Dies ist der Fall beim sog. Reinforcement Learning<sup>5</sup> (RL).

<sup>4</sup>den Gewichten der Neuronenverbindungen und den Schwellenwerten der Neuronen

<sup>5</sup>dt.: Lernen durch Verstärkung

Bei dieser Kategorie von Lernproblemen kann das lernende System (der sog. Agent) sein optimales Verhalten nur durch Interaktion mit der Umwelt lernen, die dem Agenten eine sofortige oder verspätete Bewertung (reinforcement) seines Verhaltens gibt [12, 13]. Das optimale Verhalten des Agenten ist definiert als das Verhalten, welches die Summe der positiven Bewertungen maximiert und die Summe der negativen Bewertungen minimiert. Erhält der Agent erst verspätet eine Bewertung seines Verhaltens, so spricht man von Delayed Reinforcement Learning (DRL). Diese Art von Lernproblemen tritt häufig bei der optimalen Steuerung dynamischer Systeme auf [12].

Innerhalb von sog. neuronalen Reglern (NR) wurden neuronale Netze erfolgreich auf RL-Lernprobleme angewandt [10]. Die Ansätze dazu lassen sich in *direkte* und *indirekte* Ansätze einteilen [14, 15]. Der direkte Ansatz, der im vorliegenden Beitrag verwendet wird, verwendet ein einzelnes neuronales Netz, das als Handlungsmodell (action model) bezeichnet wird. Das Handlungsmodell steuert das dynamische System, indem es aus einem Eingabevektor, der alle zur Aufgabenerfüllung relevanten Größen enthält (Zustand des Systems, Zustand der Umwelt etc.), einen Steuervektor berechnet.<sup>6</sup> Um die Terminologie nicht unnötig zu verkomplizieren, wird im Folgenden der Begriff „neuronaler Regler“ für das neuronale Netz verwendet, welches eigentlich „das Handlungsmodell des neuronalen Reglers“ ist.

Neuronale Regler können auch für die Optimierung von Sonnenseglerbahnen verwendet werden, da dies ein DRL-Problem ist: wird ein neuronaler Regler verwendet, um den Segelnormalenvektor  $\mathbf{n}(t)$  eines Sonnenseglers zu steuern, dann erhält er nur eine einzige Bewertung für den von ihm gewählten Steuervektorverlauf  $\mathbf{n}[t]$  (d.h. für sein Verhalten), und zwar zum Endzeitpunkt  $t_f$ , da die Bahn erst dann bewertet werden kann. Es ist anzumerken, dass das Verhalten des neuronalen Reglers vollständig durch seine Netzfunktion  $\Phi_{\boldsymbol{\pi}}$  festgelegt ist (die wiederum vollständig durch den Parametervektor  $\boldsymbol{\pi}$  bestimmt ist). Im nächsten Abschnitt wird ein Lernverfahren für DRL-Probleme vorgestellt, welches zur Bestimmung der optimalen Netzfunktion  $\Phi_{\boldsymbol{\pi}^*}$  des neuronalen Reglers verwendet werden kann.

## 8. EVOLUTIONÄRE ALGORITHMEN UND EVOLUTIONÄRE NEURONALE REGLER

Evolutionäre Algorithmen (EA), die zumeist als genetische Algorithmen (GA) bezeichnet werden,<sup>7</sup> haben sich als robuste Verfahren erwiesen, um globale Optima in sehr hochdimensionalen Lösungsräumen zu finden. Sie wurden bisher mit Erfolg auf eine breite Palette von Optimierungsproblemen angewendet, so auch als Lernverfahren für neuronale Netze [15, 17, 18, 19]. Es kann

<sup>6</sup>Der gebräuchlichere indirekte Ansatz, der in der vorliegenden Arbeit nicht verwendet wird, verwendet zusätzlich ein Systemmodell und ein zweites neuronales Netz, das als Bewertungsmodell (evaluation model) bezeichnet wird. Basierend auf dem Systemmodell liefert es eine geschätzte Bewertung für die vom Handlungsmodell intendierte Handlung [10, 14, 16].

<sup>7</sup>EA ist der Oberbegriff für eine breite Klasse von Verfahren, deren bekanntesten Vertreter die GA sind.

deshalb davon ausgegangen werden, dass sie ein effizientes Verfahren sind, um die optimale Netzfunktion eines neuronalen Reglers zu finden.

Bei EA wird eine in großen Teilen der Biologie entnommene Terminologie verwendet. Das Schlüsselement eines EA ist eine Population, die zahlreiche Individuen  $A_k$  ( $k \in \{1, \dots, q\}$ ) umfasst. Diese Individuen sind potenzielle Lösungen des Optimierungsproblems. Alle Individuen der (zu Anfang zufällig generierten) Population werden im Hinblick auf ihre Problemlösungsgüte von einer sog. Fitnessfunktion  $F$  (analog einer Kostenfunktion) bewertet. Die ihnen zugewiesene Fitness  $F(A_k)$  ist ausschlaggebend für die Fortpflanzungswahrscheinlichkeit, da ein Selektionsschema (die Umwelt) fittere Individuen mit einer höheren Wahrscheinlichkeit zur „Paarung“ auswählt als weniger fitte. Für die Erzeugung von Nachkommen werden die ausgewählten Eltern einer Anzahl von stochastischen „genetischen“ Transformationen (Mutation, Rekombination) unterworfen, die dafür sorgen, dass der Nachwuchs aus einer Mischung des elterlichen „Erbguts“ besteht. Unter dem Selektionsdruck der Umwelt kämpfen die Individuen, die auch als Chromosomen oder Strings bezeichnet werden, ums Überleben. Nach einigen Reproduktionsschritten konvergiert die Population gegen *eine* Lösung  $A^*$ , die im Idealfall die global-optimale Lösung des Problems ist.

Die Anwendung von EA auf das Problem, die optimale Netzfunktion für einen neuronalen Regler zu finden, macht sich zunutze, dass der Parametervektor  $\pi_1, \dots, \pi_\ell$  eines neuronalen Reglers auf einen Fließkommastring der Länge  $\ell$  abgebildet werden kann, welcher daher eine äquivalente Darstellung der Netzfunktion  $\Phi$  ist. Indem der EA nach dem fittesten Individuum (String)  $A^*$  sucht, sucht er somit nach der optimalen Netzfunktion  $\Phi^*$ . Solche neuronalen Regler, die einen EA als Lernverfahren verwenden, werden als evolutionäre neuronale Regler (ENR) bezeichnet.

Bevor der neuronale Regler für die Optimierung von Sonnenseglerbahnen verwendet werden kann, müssen seine Eingabemenge  $\mathcal{X}$  und seine Ausgabemenge  $\mathcal{Y}$  problemadäquat definiert werden (d.h. „was soll dem neuronalen Regler eingegeben werden?“ und „wie soll die Ausgabe des neuronalen Reglers interpretiert werden?“ oder vielmehr „was soll der neuronale Regler tun?“). Dies ist entscheidend für seine Leistungsfähigkeit, da nicht erwartet werden kann, dass der neuronale Regler aus problem inadäquaten Eingaben problemadäquate Ausgaben generiert. Bevor die gestellten Fragen beantwortet werden können, muss jedoch noch skizziert werden, wie Sonnensegler anhand von Steuerstrategien gesteuert werden können.

## 9. STEUERUNG EINES SONNENSEGLERS

Ein *reines* lokales Steuergesetz (RLSG) kann als ein Steuergesetz definiert werden, welches *ein* aktuelles Bahnelement (große Halbachse, Exzentrizität, Inklination etc.) eines Raumfahrzeugs mit einer maximalen Rate ändert (vergrößert, verkleinert oder an einen vorgegebenen Wert angleicht). Für die Herleitung von RLSG

können die Lagrange-Gleichungen für die Variation der (oskulierenden) Bahnelemente verwendet werden, da diese Gleichungen die Änderungsrate der Bahnelemente aufgrund einer kleinen Schub- und/oder Störbeschleunigung beschreiben [20]. Sind  $n$  RLSG vorhanden, so definiert jedes RLSG  $i \in \{1, \dots, n\}$  eine optimale Schubrichtung. Diese Richtung kann durch einen Einheitsvektor, den optimalen Schubeinheitsvektor  $\mathbf{f}_i$ , ausgedrückt werden. Wie bereits erwähnt, kann ein Sonnensegler die Strahlungsdruckkraft nicht in jede beliebige Richtung drehen. Er kann aber die Kraftkomponente in  $\mathbf{f}_i$ -Richtung maximieren:  $\mathbf{F}_{\text{SRP}}(\alpha, \beta) \cdot \mathbf{f}_i \max!$ . Dieses Problem kann für ein ideales Segel analytisch gelöst werden, so dass der zu  $\mathbf{f}_i$  gehörige Steuervektor  $\mathbf{n}_{\mathbf{f}_i}$  – und daraus die Steuerwinkel  $\alpha_{\mathbf{f}_i}$  und  $\beta_{\mathbf{f}_i}$  – berechnet werden können.

Um mehr als ein Bahnelement *gleichzeitig* zu ändern, können die  $n$  RLSG gemischt werden. Dafür kann ein Gewichtvektor  $\mathbf{c} \in [0, 1]^n$  so definiert werden, dass jeder Steuergesetz-Gewichtvektor einem anderen gemischten lokalen Steuergesetz (GLSG) entspricht. Mit Hilfe von  $\mathbf{c}$  kann der (gemischte) optimale Schubeinheitsvektor  $\mathbf{f}$  aus den (reinen) optimalen Schubeinheitsvektoren  $\mathbf{f}_i$  berechnet werden:

$$(3) \quad \mathbf{f} = \frac{\sum_{i=1}^n c_i \mathbf{f}_i}{\left| \sum_{i=1}^n c_i \mathbf{f}_i \right|}$$

Aus  $\mathbf{f}$  kann dann wiederum der zugehörige Steuervektor  $\mathbf{n}_{\mathbf{f}}$  (bzw. die zugehörigen Steuerwinkel  $\alpha_{\mathbf{f}}$  und  $\beta_{\mathbf{f}}$ ) berechnet werden.

Eine Segelsteuerstrategie kann als eine Funktion  $S : \mathcal{X} \rightarrow [0, 1]^n$  definiert werden, die aus einem gegebenen Vektor von Eingabevariablen  $\mathbf{X}(t) \in \mathcal{X}$  den aktuellen Steuergesetz-Gewichtvektor  $\mathbf{c}(t) \in [0, 1]^n$  berechnet. Das Rendezvous-Problem kann dann umformuliert werden<sup>8</sup>: finde eine Segelsteuerstrategie  $S : \mathcal{X} \rightarrow [0, 1]^n$  (für  $t_0 \leq t \leq t_f$ ), die den Zustandsvektor  $\mathbf{x}(t)$  des Sonnenseglers von seinem Anfangswert  $\mathbf{x}(t_0)$  in den Zustandsvektor  $\mathbf{x}_T(t)$  des Zielkörpers überführt (unter Berücksichtigung der Endbedingung  $\mathbf{x}(t_f) = \mathbf{x}_T(t_f)$ ) und gleichzeitig die Kostenfunktion  $J = t_f - t_0$  minimiert. Die resultierende Steuerstrategie  $S^*$  ist die optimale Steuerstrategie für das gegebene Bahnoptimierungsproblem. Das Bahnoptimierungsproblem ist deshalb eigentlich ein Suchproblem für die optimale Segelsteuerstrategie  $S^*$ .

Die Verwendung von reinen und gemischten lokalen Steuergesetzen ist jedoch nur *eine* Methode, um Segelsteuerstrategien zu erhalten. Da diese Steuerstrategien Kenntnisse implizieren, wie die Bahnelemente optimal zu ändern sind, können sie als *indirekte* Steuerstrategien bezeichnet werden. Desweiteren können auch *direkte* Segelsteuerstrategien definiert werden, die z.B. den optimalen Schubeinheitsvektor  $\mathbf{f}$  direkt vorgeben. Diese ohne Verwendung lokaler Steuergesetze definierten Strategien implizieren keine Kenntnisse, wie die Bahnelemente optimal zu ändern sind.

<sup>8</sup>Das Fly-By-Problem entsprechend mit  $\mathbf{r}(t_0) \rightarrow \mathbf{r}_T(t_f)$

## 10. OPTIMIERUNG VON SONNENSEGLERBAHNEN MIT EVOLUTIONÄREN NEURONALEN REGLERN

Für die Implementierung einer Segelsteuerstrategie, wie sie oben definiert wurde, kann ein ENR verwendet werden. In diesem Fall definiert jeder Parametervektor  $\boldsymbol{\pi}$  eine Steuerstrategie  $S_{\boldsymbol{\pi}} : \mathcal{X} \rightarrow \mathcal{Y}$ . Der EA wird benutzt, um den optimalen Parametervektor  $\boldsymbol{\pi}^*$  des neuronalen Reglers zu finden, der in der optimalen Steuerstrategie  $S^* := S_{\boldsymbol{\pi}^*}$  resultiert (aus dieser resultiert dann der optimale Steuervektorverlauf  $\mathbf{n}^*[t]$  und aus diesem dann die optimale Bahn  $\mathbf{x}^*[t]$ ).

Für den neuronalen Regler wurden zwei verschiedene Ausgabemengen  $\mathcal{Y}$  untersucht:

- der neuronale Regler gibt den Steuergesetz-Gewichtvektor  $\mathbf{c}$  aus,  $S : \mathcal{X} \rightarrow \{\mathbf{c}\}$  (indirekte Steuerstrategie)
- der neuronale Regler gibt den optimalen Schubeinheitsvektor  $\mathbf{f}$  aus,<sup>9</sup>  $S : \mathcal{X} \rightarrow \{\mathbf{f}\}$  (direkte Steuerstrategie)

Da die Annahme vernünftig erscheint, dass für eine robuste Segelsteuerstrategie die optimale Richtung der Strahlungsdruckkraft  $\mathbf{n}(t)$  zu *jeder* Zeit  $t$  nur vom jeweils aktuellen Zustandsvektor des Sonnenseglers  $\mathbf{x}(t)$  und dem des Zielkörpers  $\mathbf{x}_T(t)$  abhängen sollte, wurde  $\mathcal{X} = \{(\mathbf{x}, \mathbf{x}_T)\}$  für die Eingabemenge des neuronalen Reglers gewählt, so dass  $S : \{(\mathbf{x}, \mathbf{x}_T)\} \rightarrow \mathcal{Y}$ .<sup>10</sup>

Nun ergibt sich das endgültige Bild für die Optimierung von Sonnenseglerbahnen mit einem ENR (BILD 6): zum Auffinden der optimalen Bahn läuft das Verfahren in zwei ineinander verschachtelten Schleifen ab. In der Bahnintegrationsschleife (innere Schleife) steuert ein neuronaler Regler den Sonnensegler, so dass dieser eine Bahn fliegt, die durch den Parametervektor des neuronalen Reglers vollständig festgelegt ist. In der NR-Optimierungsschleife (äußere Schleife) werden durch den EA verschiedene Parametervektoren „durchprobiert“.

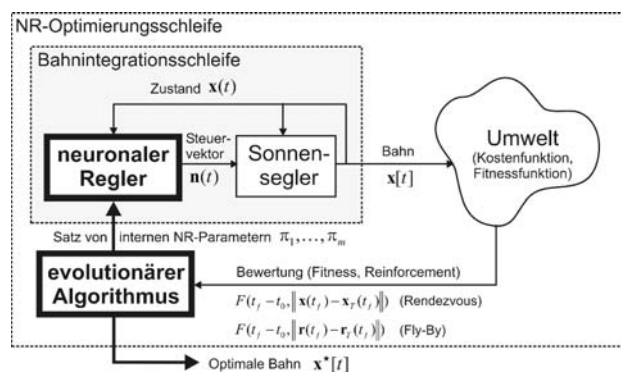


BILD 6: Bahnoptimierung mit einem evolutionären neuronalen Regler

<sup>9</sup>Dieser kann über  $\mathbf{f} = (2\mathbf{Y} - \mathbf{1})/|2\mathbf{Y} - \mathbf{1}|$  aus der Ausgabe  $\mathbf{Y} \in (0, 1)^3$  des neuronalen Reglers berechnet werden.

<sup>10</sup>Es ist anzumerken, dass eine so definierte Segelsteuerstrategie nicht explizit von der Zeit abhängt.

Zur Steuerung des Sonnenseglers erhält der neuronale Regler den aktuellen Zustandsvektor des Sonnenseglers  $\mathbf{x}(t)$  und den aktuellen Zustandsvektor des Zielkörpers  $\mathbf{x}_T(t)$  als Eingabe und bildet diese auf einen Ausgabevektor ab (BILD 7). Wenn der neuronale Regler eine indirekte Steuerstrategie implementieren soll, so wird der  $n$ -dimensionale Ausgabevektor als Steuergesetz-Gewichtvektor  $\mathbf{c}(t)$  interpretiert. Mit diesem kann der optimale Schubeinheitsvektor  $\mathbf{f}(t)$  aus den Lagrange-Gleichungen für die Variation der Bahnelemente berechnet werden. Wenn der neuronale Regler eine direkte Steuerstrategie implementieren soll, so wird der dreidimensionale Ausgabevektor direkt als optimaler Schubeinheitsvektor  $\mathbf{f}(t)$  interpretiert. In beiden Fällen kann aus der Ausgabe des neuronalen Reglers der Steuervektor  $\mathbf{n}_f(t)$  (bzw. die Steuerwinkel  $\alpha_f(t)$  und  $\beta_f(t)$ ) berechnet werden. Nachdem dies geschehen ist, wird der Steuervektor in die Bewegungsgleichungen des Sonnenseglers eingesetzt. Diese werden dann über einen Zeitschritt  $\Delta t$  integriert. Der resultierende Zustandsvektor  $\mathbf{x}(t + \Delta t)$  wird in den neuronalen Regler zurückgeführt. Die Bahnintegrationsschleife endet, wenn die Endbedingung für das Rendezvous- oder Fly-By-Problem näherungsweise erfüllt ist ( $\|\mathbf{x}(t) - \mathbf{x}_T(t)\| \leq \epsilon$  für Rendezvous bzw.  $\|\mathbf{r}(t) - \mathbf{r}_T(t)\| \leq \epsilon$  für Fly-By), oder wenn die maximale Integrationszeit erreicht ist. Anschließend wird in der NR-Optimierungsschleife der Parametervektor des neuronalen Reglers (d.h. die Steuerstrategie bzw. die geflogene Bahn) mit der Fitnessfunktion des EA bewertet. Da man nicht erwarten kann, dass der neuronale Regler die Endbedingung des Bahnoptimierungsproblems exakt erfüllt, wird diese in die Fitnessfunktion mit aufgenommen (so dass  $F = F(t_f - t_0, \|\mathbf{x}(t_f) - \mathbf{x}_T(t_f)\|)$  für das Rendezvous-Problem und  $F = F(t_f - t_0, \|\mathbf{r}(t_f) - \mathbf{r}_T(t_f)\|)$  für das Fly-By-Problem). Wie bereits erwähnt, ist diese Fitness entscheidend für die Fortpflanzungswahrscheinlichkeit eines jeden Individuums (d.h. einer jeden Steuerstrategie). Unter diesem Selektionsdruck generiert der ENR immer bessere Bahnen. Letztendlich konvergiert der EA gegen eine Steuerstrategie, die im Idealfall eine nahe-global optimale<sup>11</sup> Bahn produziert.

## 11. ERGEBNISSE

Das oben beschriebene Verfahren wurde auf eine Vielzahl von Bahnoptimierungsproblemen für Sonnensegler angewendet. Hier sollen beispielhaft die Ergebnisse für drei Missionen gezeigt werden, für die von Experten generierte Bahnen verfügbar sind [1, 2, 21, 22, 23, 24].

Die erste Mission (BILD 8) ist ein Rendezvous mit dem erdnahen Asteroiden 1996FG<sub>3</sub>,<sup>12</sup> eine Mission, die als nicht zu anspruchsvoll für einen Sonnensegler der ersten Generation angesehen wird (charakteristische Beschleunigung = maximale Beschleunigung im Erdabstand =  $a_c = 0.14 \text{ mm/s}^2$ ). Die zweite Mission (BILD 9)

<sup>11</sup> nahe-global, da globale Optimalität nur durch vollständige Enumeration bewiesen werden kann, was aber in diesem Fall nicht realisierbar ist

<sup>12</sup> es wurde auch ein Probenrückführmission zu diesem Asteroiden untersucht, die einen 140 kg schweren Lander und eine 40 kg schwere Rückkehrkapsel vorsieht ( $a_c = 0.10 \text{ mm/s}^2$ ) [25]

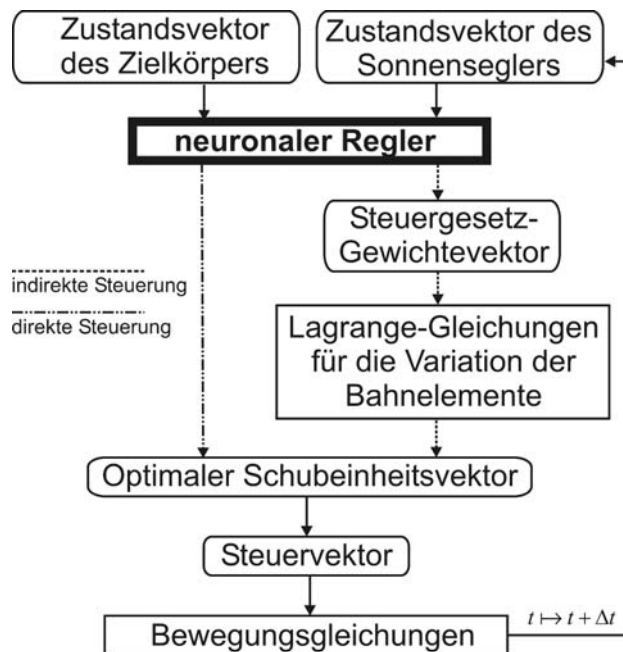


BILD 7: Sonnenseglersteuerung mit einem neuronalen Regler (Bahnintegrationsschleife)

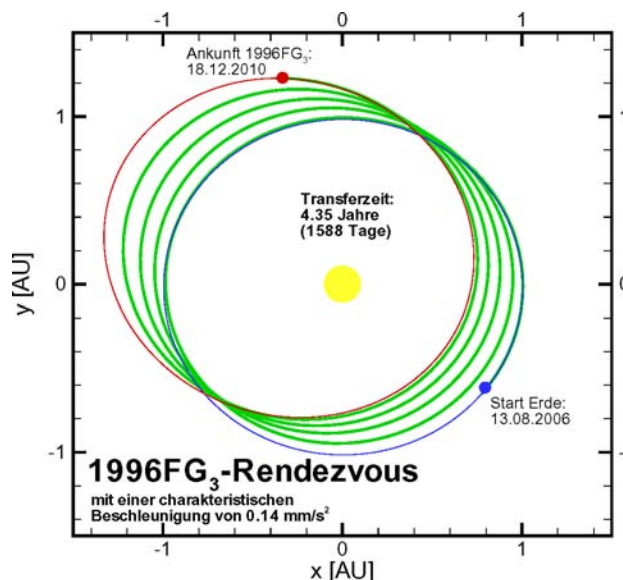


BILD 8: 1996FG<sub>3</sub>-Rendezvous

ist ein Merkur-Rendezvous mit einem fortschrittlichen Sonnensegler ( $a_c = 0.55 \text{ mm/s}^2$ ). Die dritte Mission (BILD 10) ist ein Pluto-Fly-By (mit  $a_c = 1.0 \text{ mm/s}^2$ ). Alle drei Beispielmissionen zeigen, dass sich die mit herkömmlichen Optimierungsverfahren gefundenen Bahnen weit entfernt vom globalen Optimum befinden:

- Die ENR-Bahn für die 1996FG<sub>3</sub>-Rendezvous-Mission ist 52 Tage (3%) schneller als die Vergleichsbahn [23, 24] und reduziert die benötigte hyperbolische Überschussenergie von  $C_3 = 4 \text{ km}^2/\text{s}^2$  auf  $C_3 = 0 \text{ km}^2/\text{s}^2$  (beim Rendezvous ist die Entfernung vom Zielkörper  $\Delta r$  kleiner als 52 000 km und die Relativgeschwindigkeit  $\Delta v$  kleiner als 0.19 km/s).
- Die ENR-Bahn für die Merkur-Rendezvous-Mission

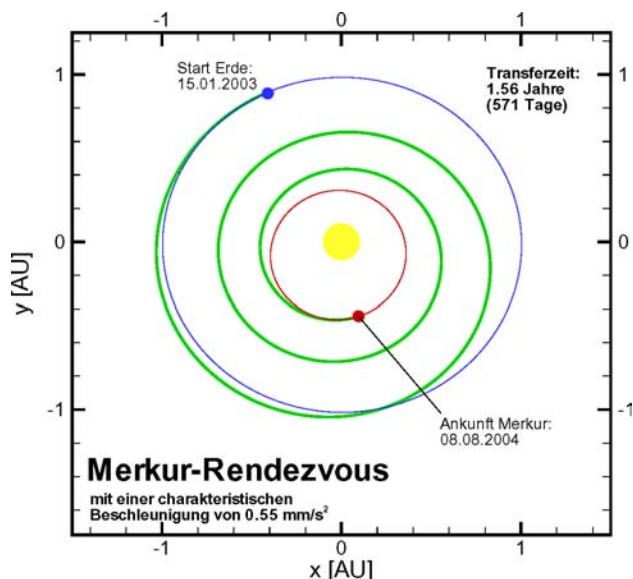


BILD 9: Merkur-Rendezvous

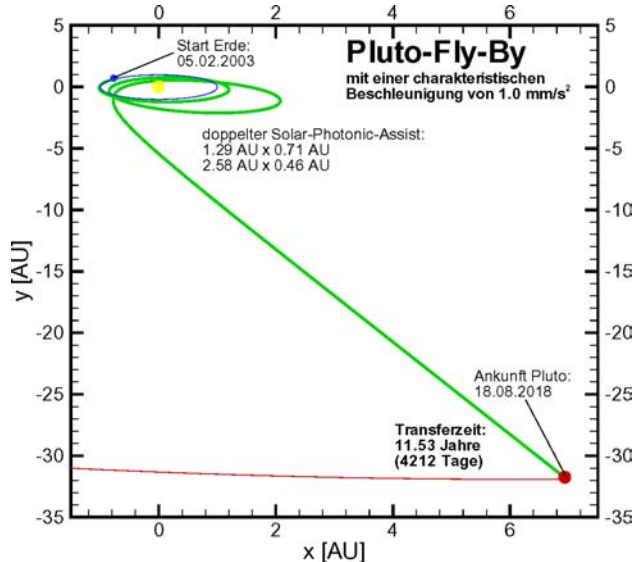


BILD 10: Pluto-Fly-By

ist 94 Tage (14%) schneller als die Vergleichsbahn [1, 2, 21, 22], wobei für beide Bahnen  $C_3 = 0 \text{ km}^2/\text{s}^2$  ist ( $\Delta r < 44.000 \text{ km}$  und  $\Delta v < 0.06 \text{ km/s}$  beim Rendezvous).

- Die ENR-Bahn für die Pluto-Fly-By-Mission ist 593 Tage (12%) schneller als die Vergleichsbahn [1, 2], wobei für beide Bahnen  $C_3 = 0 \text{ km}^2/\text{s}^2$  ist ( $\Delta r = 778 \text{ km}$  und  $\Delta v = 15.84 \text{ km/s}$  beim Fly-By). Es ist bemerkenswert, dass der ENR ohne Zutun ein doppeltes Solar-Photonic-Assist-Manöver findet, wohingegen die Vergleichsbahn nur einen einfachen Solar-Photonic-Assist verwendet.

Da die jeweilige Endbedingung (Rendezvous- bzw. Fly-By-Bedingung) bei keiner Bahn exakt erfüllt ist, sind die vom ENR generierten Bahnen keine optimalen Bahnen im streng mathematischen Sinn. Um die Genauigkeit einer ENR-Bahn weiter zu verbessern, kann diese als Anfangsschätzung für ein traditionelles numerisches

Optimierungsverfahren verwendet werden.

Für die Anwendung von ENR auf Bahnoptimierungsprobleme müssen folgende Parameter festgelegt werden:

- die Eingabemenge des neuronalen Reglers
- die Ausgabemenge des neuronalen Reglers
- die Netzarchitektur des neuronalen Reglers
- einige EA-Parameter (Populationsgröße, Mutationsrate, Selektionsschema etc.)
- die Fitnessfunktion des EA

Es wurden verschiedene Kombinationen dieser Parameter untersucht. Dabei stellte sich heraus, dass die Leistung des ENR relativ robust gegenüber den meisten Parametereinstellungen ist. Jedoch hängt die Leistung des ENR entscheidend von der gewählten Fitnessfunktion ab. Dies ist verständlich, da die Fitnessfunktion nicht nur entscheiden muss, welche Bahnen gut und welche schlecht sind, sondern auch, welche Bahnen vielversprechend für eine weitere „Kultivierung“ sind und welche nicht. Keine abschließende Empfehlung kann hinsichtlich der Frage gegeben werden, ob direkte oder indirekte Steuerstrategien besser geeignet sind. Obwohl für die meisten Probleme beide Steuerstrategien vergleichbare Ergebnisse lieferten, war bei manchen Problemen die eine oder die andere überlegen. Lässt man diese Ergebnisse außer Betracht, so sind die direkten Steuerstrategien eleganter und breiter anwendbar, da indirekte Steuerstrategien nicht mehr sinnvoll verwendet werden können, wenn die Bahn hyperbolisch wird.

Der verwendete ENR hatte zumeist eine einzige verdeckte Neuronenschicht mit ca. 30 Neuronen. Die maximale Zahl der Integrationsschritte wurde zumeist auf Werte zwischen 200 und 1000 gesetzt, was dem neuronalen Regler erlaubt, den Steuervektor alle 1 – 10 Tage zu ändern. In Abhängigkeit von der Zahl der Integrationschritte liegt die Laufzeit einer Bahnoptimierung auf einem 1.3 GHz-Personal Computer bei etwa einer Stunde. Dabei reproduziert und testet der EA etwa 10.000 Steuerstrategien.

## 12. SCHLUSSFOLGERUNGEN

Die obigen Ergebnisse zeigen, dass die neuartige Methode der evolutionären neuronalen Regelung ein vielversprechender Ansatz ist, um nahe-global-optimale interplanetare Sonnenseglerbahnen zu finden. Ihre Genauigkeit reicht für eine Missionsvoranalyse bereits aus. Wird eine genauere Bahn verlangt, so kann die Lösung des evolutionären neuronalen Reglers als Anfangsschätzung für ein klassisches Bahnoptimierungsverfahren verwendet werden. Dennoch, bevor evolutionäre neuronale Regler als vielseitiges und robustes Werkzeug breite Anwendung in der Praxis finden können, sollten weitere Untersuchungen hinsichtlich ihres Konvergenzverhaltens, ihrer Stabilität und robuster Parametereinstellungen durchgeführt werden.

Obwohl die Methode der evolutionären neuronalen Regelung hier nur auf die Optimierung interplanetarer Sonnenseglerbahnen angewendet wurde, ist sie dennoch auch für andere Bahnoptimierungsprobleme (andere Antriebssysteme, planetozentrische Bahnoptimierungsprobleme etc.) geeignet. Ergebnisse dafür stehen aber noch aus. Die weitere Forschung wird sich auch auf *Mehrfach-Rendezvous/Fly-By-Probleme* konzentrieren und auf die Frage, ob (für ein gegebenes Raumfahrzeug) *eine* Steuerstrategie existiert, die für *alle* Rendezvous- bzw. Fly-By-Probleme nahe-global-optimal ist.

## Literatur

- [1] M. Leipold, Solar Sail Mission Design, Dissertation, Lehrstuhl für Flugmechanik und Flugregelung, Technische Universität München 1999, DLR-FB-2000-22
- [2] M. Leipold, To the Sun and Pluto with Solar Sails and Micro-Sciencecraft, *Acta Astronautica*, 45(4-9):549–555, 1999
- [3] C. G. Sauer, Optimum Solar-Sail Interplanetary Trajectories, AIAA/AAS Astrodynamics Conference, San Diego 2000, 76-792
- [4] R. F. Stengel, Optimal Control and Estimation, Dover Publications Inc., New York 1994
- [5] J. W. Hartmann, Low-Thrust Trajectory Optimization using Stochastic Optimization Techniques, Master Thesis, University of Illinois at Urbana-Champaign 1996
- [6] M. Leipold, M. Eiden, C. E. Garner et al., Solar Sail Technology Development and Demonstration, 4<sup>th</sup> IAA International Conference on Low-Cost Planetary Missions, Laurel 2000, IAA-L-0707
- [7] M. Caudill, C. Butler, Naturally Intelligent Systems, MIT Press, Cambridge, London 1990
- [8] R. Rojas, Was können neuronale Netze? in: R.-H. Schulz (Hrsg.), *Mathematische Aspekte der angewandten Informatik*, S. 55–88, Wissenschaftsverlag, Mannheim 1994
- [9] R. Rojas, *Neural Networks. A Systematic Introduction*, Springer, Berlin, Heidelberg, New York 1996
- [10] D. C. Dracopoulos, *Evolutionary Learning Algorithms for Neural Adaptive Control*, Springer, Berlin, Heidelberg, New York 1997
- [11] B. Dachwald, W. Seboldt, Optimization of Interplanetary Rendezvous Trajectories for Solar Sailcraft using a Neurocontroller, AIAA/AAS Astrodynamics Specialist Conference, Monterey, 2002, AIAA-2002-4989
- [12] S. S. Keerthi, B. Ravindran, A Tutorial Survey of Reinforcement Learning, Technical Report, Department of Computer Science and Automation, Indian Institute of Science, Bangalore 1995
- [13] R. S. Sutton, A. G. Barto, *Reinforcement Learning*, MIT Press, Cambridge, London 1998
- [14] A. Likas, I. Lagaris, Training Reinforcement Neurocontrollers using the Polytope Algorithm, *Neural Processing Letters*, (9):119–127, 1999
- [15] D. Whitley, S. Dominic, R. Das, C. W. Anderson, Genetic Reinforcement Learning for Neurocontrol Problems, *Machine Learning*, 13:259–284, 1993
- [16] A. G. Barto, Connectionist Learning for Control, in: W. Miller, R. S. Sutton, P. J. Werbos (Eds.), *Neural Networks for Control*, pp. 5–58, MIT Press, Cambridge, London 1990
- [17] Z. Michalewicz, *Genetic Algorithms + Data Structures = Evolution Programs*, Third, Revised and Extended Edition, Springer, Berlin, Heidelberg, New York 1999
- [18] L. Tsinas, B. Dachwald, A Combined Neural and Genetic Learning Algorithm, in: *Proceedings of the First IEEE Conference on Evolutionary Computation*, pp. 770–774, 1994
- [19] X. Yao, Evolutionary Artificial Neural Networks, in: A. Kent et al. (Eds.), *Encyclopedia of Computer Science and Technology*, Volume 33, pp. 137–170, Marcel Dekker Inc., New York 1995
- [20] R. H. Battin, *An Introduction to the Mathematics and Methods of Astrodynamics*, Revised Edition, American Institute of Aeronautics and Astronautics, Reston 1999
- [21] M. Leipold, W. Seboldt, S. Lingner et al., Mercury Sun-Synchronous Polar Orbiter with a Solar Sail, *Acta Astronautica*, 39(1-4):143–151, 1996
- [22] M. Leipold, E. Pfeiffer, P. Groepper et al., Solar Sail Technology for Advanced Space Science Missions, 52<sup>nd</sup> International Astronautical Congress, Toulouse 2001, IAF-01-S.6.10
- [23] W. Seboldt, M. Leipold, M. Rezazad et al., Ground-based Demonstration of Solar Sail Technology, 51<sup>st</sup> International Astronautical Congress, Rio de Janeiro 2000, IAF-00-S.6.11
- [24] E. K. Jessberger, W. Seboldt et al., ENEAS – Exploration of Near-Earth Asteroids with a Sailcraft, Vorschlag für eine Kleinmission im Rahmen des Programms Extraterrestrische Grundlagenforschung des DLR, 2000
- [25] B. Dachwald, W. Seboldt, B. Häusler, Performance Requirements for Near-Term Interplanetary Solar Sailcraft Missions, International Symposium on Propulsion for Space Transportation of the XXI<sup>st</sup> Century, Versailles 2002