

# Optimierungssysteme als Bestandteil von OR/MS

## Lernziele:

- Allgemeines Verständnis über Operations Research
- Besondere Sicht des Management Science bzw. Decision Support
- Vorgehensmodell in OR-Projekten
- Generelles Verständnis über Optimierungssysteme
- Generelles Verständnis über mathematische Programmierung

## Online-Lernmodule:

- Einführung in OR/MS
- Einführung in Optimierungssysteme



<http://dsor-lectures.upb.de/>

## 1.1 Operations Research, Management Science und Decision Support

Dieses Lehrbuch beschäftigt sich mit computergestützten Optimierungssystemen, die zur Lösung von Optimierungsproblemen aus der betriebswirtschaftlichen – und teilweise auch aus der volkswirtschaftlichen oder ingenieurtechnischen – Praxis benutzt werden können. Solche Optimierungssysteme sind Bestandteil der Wirtschaftsinformatik und gleichzeitig ein wichtiges Teilgebiet der Disziplin des Operations Research.

Unter dem Begriff *Operations Research* (OR) verstehen wir allgemein die Entwicklung und den Einsatz quantitativer Modelle und Methoden zur Entscheidungsunterstützung in Unternehmen und Organisationen. Typische Ansätze des Operations Research sind Optimierung und Simulation. Dabei wird für einen Ausschnitt

der Realität ein abstraktes Modell gebildet, mit dessen Hilfe Analysen durchgeführt werden können, um somit eine gute Basis für Entscheidungen zu schaffen. In Deutschland werden gelegentlich auch die Begriffe Unternehmensforschung und Operationsforschung benutzt.

Der Begriff *Management Science* (MS) wird insbesondere in Nordamerika für „praktisches Operations Research“ angewandt. Es geht dabei um „scientific methods for management“. In Management Science liegt der Schwerpunkt auf der Unterstützung von Führungskräften bei Entscheidungen. Während zu Operations Research auch die Entwicklung von formal-mathematischen Methoden gehört, geht es bei Management Science eher um die *Anwendung* solcher Methoden. Nach Meinung der Autoren sind Methodenevolution und Anwendung untrennbar miteinander verbunden; daher wird nachfolgend zumeist die Fachbezeichnung „OR/MS“ gewählt. Entscheidungen in der Praxis werden in einem komplexen Umfeld getroffen, wobei oft nicht alle relevanten Aspekte formalisiert werden können. Daher müssen Manager, Disponenten und andere Entscheidungsträger die Möglichkeit haben, einen vom Computer generierten Entscheidungsvorschlag zu bearbeiten und zu ändern. Die Methoden des OR/MS werden also in *Decision Support (DS) Systems* (Entscheidungsunterstützungssysteme) eingebettet, die diese Möglichkeit mit Hilfe der modernen Informations- und Kommunikationstechnologie anbieten.

Abbildung 1.1 präsentiert den typischen Ablauf eines Projektes in OR/MS. Die reale Entscheidungssituation wird in einem formalen bzw. mathematischen Modell abgebildet, das mit Hilfe geeigneter Computer-Software gelöst wird. Die berechnete Lösung ergibt einen Entscheidungsvorschlag, der vom entsprechenden Entscheidungsträger auf seine „Praxistauglichkeit“ überprüft, akzeptiert, verbessert oder in manchen Fällen auch abgelehnt wird. Das Feedback des Entscheidungsträgers hilft oft bei der Verbesserung des Modells im Hinblick auf die genaue Abbildung des Realitätsausschnitts des Problems.

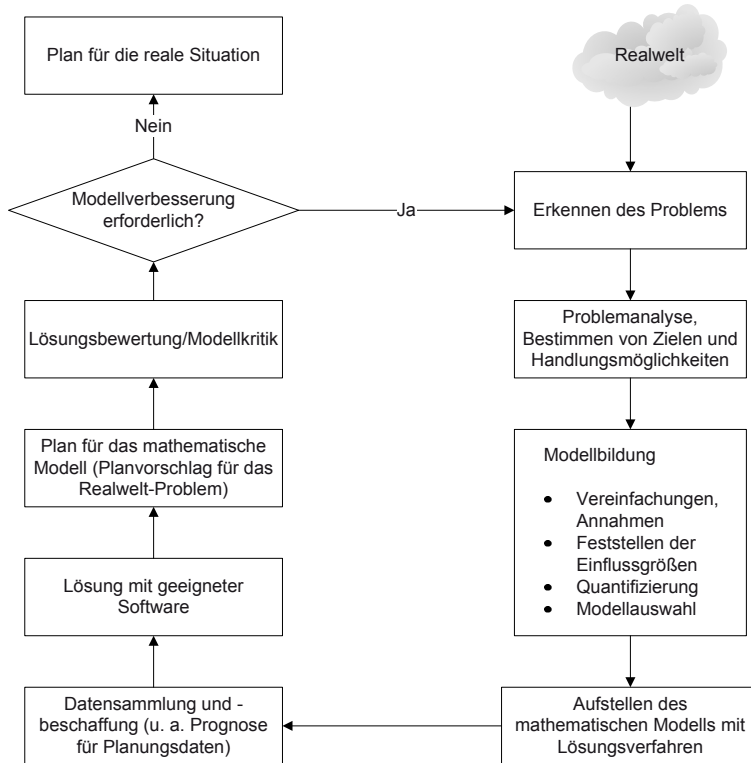
## 1.2 Modellbildung im Operations Research

Die Methoden des Operations Research können verständlicherweise nicht direkt auf die Realität, sondern auf Modelle der Realität angewandt werden. Oft ist es nicht einfach zu sehen, wie das eigentliche Entscheidungsproblem strukturiert ist und welche Aspekte der Realität modelliert werden sollten. Bei einem OR-Projekt muss zunächst geklärt werden, was der Entscheidungsträger wirklich will (Zielfunktion), welche Freiheitsgrade (Entscheidungsvariablen) man hat und welche Nebenbedingungen (Restriktionen) berücksichtigt werden sollen.



*Ein Modell ist eine Abstraktion der Realität und bildet das Planungsproblem in seinen wesentlichen Aspekten korrekt ab. [Littger 1992]*

Es ist wichtig zu verstehen, dass es zu einem Entscheidungsproblem immer mehrere Modelle geben kann, da ein Modell eine Abstraktion der Realität darstellt. Ein zwar korrektes aber ungünstig gewähltes Modell eines Problems kann dazu führen, dass



**Abb. 1.1.** Typisches Vorgehensmodell in Operations Research

OR/MS-Methoden nur schwer oder gar nicht angewandt werden können. Deshalb wird die Erstellung eines guten Modells auch als „Kunst“ bezeichnet, da es auf die Kreativität und Abstraktionsfähigkeit des Modellbildners ankommt. Modellbildner sollten deshalb sowohl ausreichende Kenntnisse über das praktische Problem im betrieblichen Umfeld als auch Kenntnisse über Fähigkeiten und Grenzen der vorhandenen OR/MS Methoden besitzen. OR/MS-Projekte sind daher grundsätzlich interdisziplinär ausgerichtet.

Wenn ein Modell aufgestellt und die „richtigen“, d. h. korrekt erfasste, bereinigte sowie in ausreichendem Maße vorhandene, Daten vorliegen, kann man durch Analyse des Modells Hinweise und Vorgaben (Lösungen des Modells) für gute Entscheidungen generieren, die dann aufgrund der *Isomorphie* des Modells mit der Realität in echte Entscheidungssituationen übertragbar sind. Wenn die oben genannten Komponenten Zielfunktion, Entscheidungsvariablen und Restriktionen formal explizit ausgedrückt werden können, kommt oft ein *Optimierungsmodell* in Frage. Eine Optimierungsmethode kann dann eine optimale Lösung unter Berücksichtigung der Zielfunktion und aller Nebenbedingungen generieren. Wenn es aber keine klar formulierbare Zielsetzung gibt, kann man oft mit Hilfe eines *Simulationsmodells* mit

einem der Realität nachgebauten „Simulator“ verschiedene Entscheidungsvarianten durchspielen und somit wertvolle Informationen gewinnen.

Jedes Modell und die daraus resultierende(n) Lösung(en) muss mit dem Entscheidungsträger auf Korrektheit überprüft werden. Derzeit ist es angesichts von Kommunikationsproblemen schwierig, alle Aspekte und Feinheiten eines komplexen Betriebsproblems zu erfassen. Wichtige Faktoren zur Problemlösung könnten vielleicht nicht erkannt oder dem Modellbildner nicht mitgeteilt worden sein. In dieser Phase gilt es zu überprüfen, ob das Modell valide ist, also die Realität korrekt abbildet. Hierfür gibt es mehrere Vorgehensweisen, beispielsweise ein retrospektiver Test, in dem historische Daten in das Modell eingegeben und das Resultat mit der bereits eingetretenen Wirklichkeit verglichen wird.

Die letzte Phase ist die Implementierung der endgültigen Lösung in der Realität. Hier kommt der Nutzen der erarbeiteten Studie zum Tragen. Die Einführung der Lösung sollte vom Unternehmen und dem Modellbildner gemeinsam durchgeführt werden, um bei der Umsetzung in ein operatives Verfahren bis dahin noch unentdeckte Fehler zu korrigieren. Weiterhin ist anzumerken, dass das Modell in periodischen Abständen überprüft werden muss, da interne oder externe Einflüsse es beeinträchtigen oder sogar unwirksam machen können.

## 1.3 Methoden des Operations Research

Im Folgenden werden einige der wichtigsten Modellierungs- und Lösungstechniken des OR kurz vorgestellt.

### 1.3.1 Lineare Optimierung

Wenn die Zielfunktion und alle Restriktionen eines Optimierungsmodells *Linearkombinationen* der Entscheidungsvariablen sind, können Modellierungs- und Lösungstechnologien der linearen Optimierung (*Linear Programming*, LP) eingesetzt werden. Dabei wird eine gegebene Zielfunktion minimiert oder maximiert, unter Berücksichtigung von linearen Restriktionen, die Gleichungen oder Ungleichungen ( $\leq$  oder  $\geq$ ) sein können.

Die Entwicklung der linearen Optimierung wird vielfach mit zu den bedeutendsten wissenschaftlichen Innovationen in der Mitte des zwanzigsten Jahrhunderts gezählt. Bis heute haben dadurch Unternehmen riesige Mengen an Ressourcen und finanziellen Mitteln gespart. Das gebräuchlichste Einsatzgebiet der linearen Optimierung ist das allgemeine Problem der bestmöglichen Allokation von knappen Ressourcen unter konkurrierenden Möglichkeiten.

Bereits vor und während des zweiten Weltkrieges wurden LP-Modelle von Leonid Kantorovich in der Sowjetunion und George Dantzig in den USA formuliert. Zunächst wurden diese Modelle zur Logistik-Optimierung im zweiten Weltkrieg eingesetzt. Nach dem Krieg haben sie ihren Weg in viele Bereiche in der Wirtschaft gefunden. Praxisrelevante LP-Modelle können nur mit Hilfe von leistungsfähigen

Computern gelöst werden. Daher wird die LP-Technologie, parallel zur Hardwareentwicklung, ständig weiter entwickelt. Durch eine jahrzehntelange, kontinuierliche Entwicklung der Algorithmen und Datenstrukturen ist man heute in der Lage, praktisch alle als relevant betrachteten LP-Modelle optimal zu lösen. Allerdings besteht noch Forschungsbedarf darin, die Lösung großer und numerisch schwieriger Modelle noch effizienter durchführen zu können, so dass diese auch in Echtzeit (während der Benutzer vor dem Bildschirm wartet) gelöst werden können. Große Modelle aus der Praxis können Hunderttausende, manchmal sogar Millionen Variablen und Restriktionen beinhalten.

### 1.3.2 Gemischt-ganzzahlige Optimierung

Viele praktische Probleme sind nur mit ganzzahligen Variablen sinnvoll, da eine Teilbarkeit von Ressourcen oft nicht gegeben ist. Rein-ganzzahlige (Integer Programming, IP) oder gemischt-ganzzahlige (Mixed Integer Programming, MIP) lineare Optimierung unterscheidet sich von der (kontinuierlichen) linearen Optimierung nur durch zusätzliche Bedingungen, wonach einige oder alle Variablen der Ganzzahligkeitsbedingung unterliegen. Manchmal redet man von MILP, weil die Zielfunktion und die Restriktionen auch hier linear sind. Die Variablen sind allerdings nicht mehr kontinuierlich, sondern *diskret*.

Beispielsweise ist es notwendig, Menschen, Fahrzeuge oder Maschinen in ganzzahligen Mengen bestimmten konkurrierenden Möglichkeiten zuzuordnen. Hier ist es sinnlos, dass die Variablen beliebige reelle Werte annehmen können. Außerdem lassen sich binäre ja/nein-Entscheidungen über die Durchführung potentieller Projekte oder Vorhaben mithilfe von 0/1-Variablen darstellen, wobei logische Abhängigkeiten zwischen Projekten mithilfe dieser speziellen ganzzahligen Variablen als lineare Restriktionen darstellbar sind.

Praxisrelevante *kombinatorische* Optimierungsprobleme wie die kostenminimale Belegung von Maschinen mit Jobsequenzen oder die Wegeplanung eines Bohrers auf einer Leiterplatte lassen sich mithilfe von MIP-Modellen darstellen. Aus einer Menge von diskreten Elementen (Gegenstände, Jobs, Orte) ist allgemein ein Konstrukt aus diesen Elementen, also eine Teilmenge (Jobsequenz, Wegeplan, ...), zu konstruieren, die gewisse Nebenbedingungen erfüllt und bezüglich einer Zielfunktion optimal ist (kleinstes Gewicht, minimale Kosten, ...). Obwohl der *zulässige*, d. h. keiner Nebenbedingung widersprechende, Bereich des Lösungsraums (Lösungsmenge) beschränkt und endlich ist, wächst die Anzahl alternativer Lösungen (Konstrukte) in der Regel exponentiell bezüglich der Anzahl der diskreten Elemente der Grundmenge an.

Im Gegensatz zu linearen Optimierungsmodellen sind ganzzahlige und gemischt-ganzzahlige Modelle in der Regel sehr schwer zu lösen. Die Schwierigkeit wird durch die kombinatorische Explosion verursacht: Bereits für kleine Modelle gibt es eine astronomische Anzahl möglicher Wertekombinationen, so dass diese selbst mit schnellen Computern nicht in einer vertretbaren Zeit aufgezählt (enumeriert) werden können. LP-Lösungstechniken reichen hier nicht aus, da optimale Lösungen der LP-Relaxationen (MIP-Modelle ohne Ganzzahligkeitsforderung) fraktionelle Werte

aufweisen können. Daher wurden spezielle Suchstrategien, bspw. Branch&Bound, entwickelt, die allerdings im schlechtesten Fall einen exponentiellen Rechenaufwand bezogen auf die Problemgröße erfordern. Natürlich hat die schnelle Entwicklung von Hard- und Software hier viel bewirkt, jedoch können heute bei weitem nicht alle IP- und MIP-Modelle optimal gelöst werden. Nichtsdestotrotz sind wegen der großen Praxisrelevanz viele Forschungsarbeiten in diesem Bereich entstanden, in denen gezeigt wird, dass mithilfe spezieller Techniken praxisrelevante Modellgrößen gelöst werden können.

*Beispiel: Crew Scheduling im Flugverkehr*

Eine der hochkombinatorischen komplexen Fragestellungen der Praxis ist die Besatzungseinsatzplanung im Flugverkehr. Unter Einhaltung aller gesetzlichen Vorgaben für Flugdienst- und Ruhezeiten für Piloten sind mehrtägige Flugdienstketten (pairings) zu generieren, die alle Flüge genau einmal abdecken. *Set-Partitioning-Modelle* sind IP-Modelle, die diese Anforderung als einzige Restriktionsgruppe beinhalten. Den Nachteil der kombinatorischen Explosion der Anzahl Variablen rührt daher, dass sie mögliche Flugdienstketten darstellen, die für mittelgroße Flugpläne im Millionenbereich liegen. Dieser Explosion entgegengetreten Forscher mit Spezialtechniken wie beispielsweise die Integration von *Column-Generation* in den Branch&Bound-Prozess. Diese Technik erlaubt es, ausgehend von lösbaren Modellen mit einer Auswahl möglicher Flugdienstketten als Variablen, nachweislich vielversprechende Flugdienstketten (Variablen) hinzuzufügen, bis eine Lösung nahe am Optimum erreicht wird (ohne das komplette Modell lösen zu müssen). Eine andere Methodik, der kombinatorischen Explosion entgegenzuwirken, ist eine alternative Modellierung, die es erlaubt, mögliche Flugdienstketten verdichtet in einem geeigneten Netzwerk darzustellen und die Planungsaufgabe als Flussmodell darzustellen, wobei der Fluss dem im Einsatz befindlichen Crew-Mitgliedern entspricht. Basierend auf dieser Methodik wurde vom Zweitautor eine Software für die automatische Crew-Planung entwickelt, die seit mehreren Jahren bei der TUIfly im Einsatz ist [Mellouli 2001, 2003].

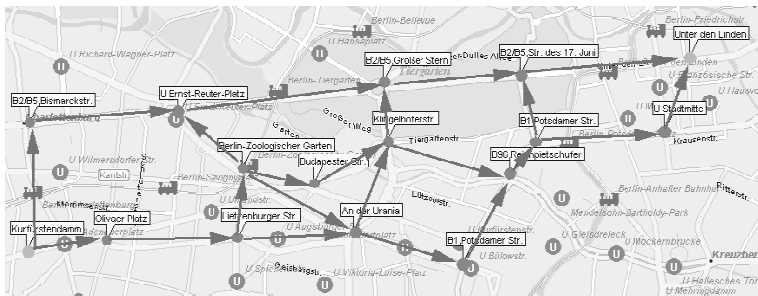
In Kapitel 7 wird eine weitere Fallstudie der Umlaufplanung im ÖPV besprochen, in der gezeigt wird, dass mithilfe geeigneter Aggregationstechniken in Netzwerken die Lösbarkeit von MIP-Modellen mit hunderttausenden Variablen mit heutigen Rechnern ermöglicht wird. Hier konnten große praxisrelevante Umlaufplanungsinstanzen erstmals direkt mithilfe von MIP-Optimierungssoftware gelöst werden.

### 1.3.3 Netzwerkoptimierung

Viele von Menschen gebaute Systeme basieren grundsätzlich auf Netzwerken. Konkrete physikalische Netze sind z. B. das Straßen-, Bahn- und Flugnetz im Verkehr, Strom-, Gas- und Wassernetz in der täglichen Versorgung sowie Telefon- und Datenübertragungsnetze bei der Kommunikation. Abstrakte Netze werden beispielsweise bei der Projektplanung und der Geschäftsprozessoptimierung benutzt.

Klassische Anwendungsfelder der Netzwerkoptimierung sind z. B. der kostenminimale Transport von Gütern zwischen Produzenten und Käufern, die Ermittlung von kürzesten Wegen innerhalb von Verkehrsnetzen, die schnellstmögliche Belieferung von Kunden (Tourenplanung) oder die Planung eines kostengünstigen Versorgungsnetzwerkes (beispielsweise Ölpipelines).

Weil solche Netzwerke sehr verbreitet und teuer sind, kann man durch eine geschickte Planung und Organisation viel einsparen. Daher gibt es spezielle Modellierungs- und Lösungstechniken, die für diverse oft vorkommende Optimierungsaufgaben in Netzwerken anwendbar sind. Netzwerkprobleme kann man als lineare Programme darstellen. Wegen ihrer speziellen Struktur lassen sie sich jedoch mit Hilfe spezieller Algorithmen meist effizienter als unter Benutzung von allgemeiner Optimierungssoftware lösen. Einige dieser Probleme werden im Folgenden beispielhaft kurz skizziert.



**Abb. 1.2.** Abstrahiertes Straßennetz


### Beispiel: Kürzeste-Wege-Problem

Wer kennt das nicht? Als armer Student ist man darauf angewiesen, seinen Lebensunterhalt als Pizzabote abends aufzubessern. Neben dem mickrigen Grundgehalt wird man bei unserem Beispiel dafür bezahlt, wie viele Pizzen man am Abend ausliefert. Um Zeit zu sparen, muss man also einen Weg suchen, der möglichst schnell zum Kunden führt. Wir abstrahieren in unserem Beispiel daher den Stadtplan von Berlin zu einem einfachen Netzplan, der uns mögliche Wege von unserem Ausgangspunkt (Quelle, Pizzeria) zu unserem Ziel (Senke, Kunde) aufzeigt. Außerdem müssen wir natürlich die unterschiedlichen Wege (Kanten, Straßen) gewichten, um zu wissen, welcher Weg uns wie viel Zeit kosten würde.

Das Beispiel ist in der Literatur unter dem Begriff *shortest-path-problem* bekannt. Es gibt unterschiedliche mathematische Algorithmen, die in der Lage sind, dieses Problem exakt zu lösen. Der bekannteste unter ihnen ist wohl zweifelsohne der Dijkstra-Algorithmus.

*Beispiel: Umladeproblem*

Beim Umladeproblem geht es um den kostenminimalen Gütertransport von sogenannten *Angebotsorten* (Produktionswerken oder Anbietern des Gutes) über *Umladeorte* (Transportumschlagsplätze, Zwischenlager, Montageorte) zu *Bedarfsorten* (Verbrauchern der Güter). Es müssen also bei diesem Problem die Routen und die zu transportierenden Güter über die Routen simultan betrachtet werden. Die Realität kann erfordern, dass bestimmte Routen nur eine gewisse maximale Menge an Gütern zulassen, die befördert werden können (beispielsweise die maximale Transportkapazität eines Schiffes bei einem Transport zu Wasser).



**Abb. 1.3.** Umladeproblem

In Abb. 1.3 wird beispielhaft ein Netzwerk der Transportwege für die Distribution der Waren eines Unternehmens mit vier Angebotsorten (Werke), drei im Inland (links), einer im Ausland (rechts), drei Bedarfsorten (rechts) und drei weiteren Umlade-Orten gezeigt. Beachten Sie, dass bei Angebots- und Bedarfsknoten auch umgeladen werden kann. Aus diesen Informationen wird ein Modell erstellt, das mittels Optimierungsmethoden gelöst werden kann.

### 1.3.4 Nichtlineare Programmierung

Wenn die Zielfunktion und/oder Restriktionen eines Optimierungsmodells auch Nichtlinearitäten beinhalten, können die Technologien der linearen und gemischt-ganzzahligen Optimierung nicht mehr genutzt werden. In dem Fall spricht man von der nichtlinearen Optimierung oder Programmierung (NLP). Beispielsweise liegt eine Nichtlinearität vor, wenn die verkaufte Produktionsmenge im umgekehrten Verhältnis zum geforderten Preis steht. Das bedeutet, dass der erzielbare Preis – und damit der Erlös – von der Menge an hergestellten Gütern abhängen. Der Erlös (Teil der Zielfunktion) steht somit nicht mehr in linearem Verhältnis zur verkauften Menge.

Nichtlineare Optimierungsprobleme treten in der Praxis häufig auf. Als Beispiele sind hier unter anderem das Transportkostenproblem mit mengenabhängigen Ver-



sandkosten, eine Depotzusammensetzung mit nicht festverzinslichen Wertpapieren oder die Verringerung der Stückkosten durch den Lerneffekt (d. h. effizientere Produktion durch größere Erfahrung) zu nennen.

Die Modellierung von nichtlinearen Zusammenhängen ist meistens sehr aufwendig. Außerdem können viele der nichtlinearen Modelle mit heutiger Technologie nicht optimal gelöst werden. Es gibt nicht die Lösungstechnologie für nichtlineare Modelle; es kommen vielmehr in Abhängigkeit von der Modellklasse viele unterschiedliche Methoden in Frage. Die Autoren versuchen i.d.R. zunächst, nichtlineare Probleme (stückweise) zu linearisieren; in vielen Fällen ist dies durch spezielle Modellierungstechniken machbar.

### 1.3.5 Heuristiken und Metaheuristiken

Heuristische Suchverfahren können für ähnliche Problemstellungen angewandt werden wie die oben genannten (exakten) Optimierungsverfahren. Sie ermitteln in einem vertretbaren Rechenaufwand möglichst gute Lösungen. Allerdings kann nicht garantiert werden, dass eine im mathematischen Sinne optimale Lösung gefunden wird. Weiterhin besteht im Allgemeinen keine Abschätzung darüber, wie weit die beste gefundene Lösung vom Optimum entfernt ist. Heuristiken sind in der Regel problembasiert. Das heißt, dass die Suchmethode bekannte Eigenschaften des zu lösenden Problems nutzt, um somit schneller gute Lösungen zu generieren.

Metaheuristiken sind dagegen allgemeine Prinzipien und Schemata zur Entwicklung und Steuerung heuristischer Verfahren. Viele Metaheuristiken gehören zu so genannten naturanalogen Verfahren, weil sie die Natur gewissermaßen nachbilden. Solche Verfahren sind z. B. neuronale Netze, Simulated Annealing, genetische Algorithmen und Ameisensysteme. Es handelt sich dabei um allgemeine Suchverfahren, die auf der Suche nach einer optimalen Lösung kurzfristig auch eine Verschlechterung des Zielwertes hinnehmen, weil damit die Hoffnung verbunden ist, dass man aus einem im Verfahrensablauf erreichten lokalen Optimum wieder herauskommt.

### 1.3.6 Simulation

Simulation kann im sprachlichen Gebrauch viele Bedeutungen annehmen. So kann „Simulieren“ bedeuten, dass man sich verstellt oder etwas vortäuscht, aber auch, dass man eine bestimmte Handlung nachahmt. Operations Research und Management Science verstehen unter Simulation die Nachahmung einer realen Situation durch ein Modell, das auf einem Rechner abläuft. Anstatt einer analytischen Lösung eines gegebenen Problems wird bei der Simulation eine Annäherung an die optimale Lösung durch ein experimentelles Ausprobieren einer Vielzahl von Möglichkeiten durchgeführt.



*Simulation ist die Nachbildung eines dynamischen Prozesses in einem Modell, um zu Erkenntnissen zu gelangen, die auf die Wirklichkeit übertragbar sind (VDI-Richtlinie).*

Eine Simulation, d. h. das Durchspielen komplexer Zusammenhänge, empfiehlt sich, wenn entweder ein Ausprobieren in der Realität zu teuer ist oder sich bspw. deswegen verbietet, weil der Untersuchungsgegenstand dabei zerstört werden könnte. Flugsimulatoren sind hierfür gute Beispiele aus der Realität, an denen sich kritische Situationen testen lassen. Tests mit realen Flugzeugen sind auf die Dauer viel kostspieliger als ein Flugsimulator - selbst, wenn es nicht gleich zum Absturz durch Pilotenfehler kommt.

Simulationen werden auch dann eingesetzt, wenn eine Problemstellung in der Realität durch ein mathematisches Modell zwar beschrieben werden kann, aber geeignete Lösungsverfahren entweder nicht existieren oder der Rechenaufwand viel zu groß ist. Das Feld der Simulation ist extrem vielschichtig, u. a. sind sowohl bei der Modellerstellung als auch der Ergebnisauswertung statistische Analysen unumgänglich. An dieser Stelle sollen zwei wichtige Arten der Simulation, die Monte-Carlo-Simulation und die allgemeine, diskrete Simulation kurz vorgestellt werden.

### Monte-Carlo-Simulation

Monte-Carlo, Sinnbild für Glücksspiele und Casinos, wird nicht umsonst als Namenspathe für diese Art der Simulation verwendet. Wie in Monte-Carlo am Roulettetisch wird auch hier auf den Faktor Zufall gesetzt. Wir verstehen unter der Monte-Carlo-Simulation das Nachspielen eines Zufallsvorganges mit Zufallszahlen. Obwohl die Monte-Carlo-Simulation eine sehr alte Technologie ist, wird sie erst seit einigen Jahren in betriebswirtschaftlichen Praxisanwendungen eingesetzt. Der Grund dafür ist, dass die vielen Zufallsexperimente effizient nur mit leistungsfähigen Computern umsetzbar sind. Typischerweise wird die Monte-Carlo-Simulation in Fällen eingesetzt, in denen aus einer Input-Verteilung eine Output-Verteilung generiert wird. Es kann sich bei Input und Output auch um viele unterschiedliche Verteilungen handeln. Der Ausgang eines einzelnen Experiments ist ungewiss, unterliegt aber den Gesetzen der Statistik. Nach dem Gesetz der großen Zahlen nähert sich die experimentelle Verteilung der Ausgangsdaten der theoretischen Verteilung, die der gegebenen Input-Verteilung unterliegt, an.

#### *Beispiel: Produkteinführung*

Ein Unternehmen erwägt das Einführen eines neuen Produktes. Wenn sicher wäre, ob das Produkt profitabel wird oder nicht, fiel die Entscheidung einfach. Die Einführung unterliegt jedoch großen Unsicherheiten, z. B. variieren die Produktionskosten und die Beschaffungspreise. Weiterhin ist die Absatzmenge nicht bekannt und vom Verkaufspreis abhängig. Mit Hilfe der Monte-Carlo-Simulation kann die Zukunft quasi beliebig oft im Computer durchgespielt werden. Aus einer Zusammenfassung der Ergebnisse ergibt sich dann ein Bild über die Wahrscheinlichkeitsverteilung.

### Diskrete Simulation

Gegenstand der diskreten Simulation sind Modelle, in denen die Zeit in diskreten Intervallen betrachtet wird. Die Zeit wird durch sogenannte Ereignisse in Ab-

Optimierungssysteme

Modelle, Verfahren, Software, Anwendungen

Suhl, L.; Mellouli, T.

2013, XVIII, 306 S. 15 Abb., Softcover

ISBN: 978-3-642-38936-8