


Report Series




Investitionsentscheidungen bei mehrfachen Zielsetzungen und künstliche Ameisen

Karl Doerner
Walter J. Gutjahr
Richard F. Hartl
Christine Strauss
Christian Stummer

Report No. 62
September 2001

Report Series



September 2001

SFB
'Adaptive Information Systems and Modelling in Economics and Management
Science'

Vienna University of Economics
and Business Administration
Augasse 2–6, 1090 Wien, Austria

in cooperation with
University of Vienna
Vienna University of Technology

<http://www.wu-wien.ac.at/am>

Papers published in this report series
are preliminary versions of journal articles
and not for quotations.

This paper was accepted for publication in:
Operations Research Proceedings 2001, International Conference on
Operations Research, Duisburg, September 3-5, 2001. Springer Verlag.

This piece of research was supported by the Austrian Science Foundation
(FWF) under grant SFB#010 ('Adaptive Information Systems and Modelling in
Economics and Management Science').

Investitionsentscheidungen bei mehrfachen Zielsetzungen und künstliche Ameisen

Karl Doerner¹, Walter J. Gutjahr², Richard F. Hartl¹, Christine Strauss¹ und Christian Stummer¹

¹ Institut für Betriebswirtschaftslehre, Universität Wien
{karl.doerner,richard.hartl,christine.strauss,christian.stummer}@univie.ac.at

² Institut für Statistik und Decision Support Systems, Universität Wien
walter.gutjahr@univie.ac.at

Zusammenfassung Die Auswahl des attraktivsten Portfolios von Investitionsprojekten zählt zu den kritischen Managementaufgaben. Angesichts mehrfacher Zielsetzungen und komplexer Projektabhängigkeiten bietet sich dazu ein zweistufiges Vorgehen an, das zunächst effiziente Portfolios identifiziert und den Entscheidungsträger anschließend bei der Suche in diesem Lösungsraum unterstützt. Bei einer großen Zahl an Vorschlägen können die möglichen Projektkombinationen aber nicht mehr in akzeptabler Zeit vollständig enumeriert werden. Adaptierte Meta-Heuristiken bieten hier einen Kompromiß zwischen dem Wunsch nach exakter Bestimmung aller Pareto-optimalen Investitionsprogramme und dem dazu nötigen Rechenaufwand. Dieser Beitrag beschreibt den entsprechenden Einsatz künstlicher Ameisen und diskutiert erste numerische Ergebnisse.

1 Einführung

Mit der Auswahl eines Projektportfolios aus einer Menge von Vorschlägen wird das mittel- und langfristige Investitionsprogramm eines Unternehmens festgelegt. In Anbetracht der verplanten umfangreichen Ressourcen – dies gilt im besonderen etwa für die Dotierung von Forschungs- und Entwicklungs- (F&E-) Vorhaben – bzw. der drohenden Opportunitätskosten durch gegebenenfalls nicht realisierte Marktchancen kommt dieser Entscheidung hohe praktische Relevanz zu.

Eine zentrale Rolle spielen mehrfache Zielsetzungen wie beispielsweise hoher Cash-Flow, Technologieführerschaft oder Marktdurchdringung. Die dazu häufig vorgeschlagenen Verfahren der „Amerikanischen Schule“ (vgl. [13]) benötigen jedoch eine Nutzenfunktion, welche die Präferenzen des Entscheidungsträgers mit hinreichender Genauigkeit nachbildet und es somit erlaubt, die unterschiedlichen Erfolgsgrößen zu einem aussagekräftigen Gesamtnutzenwert zu aggregieren. Für die Mehrzahl realer Problemstellungen wäre eine solche Funktion allerdings wegen der nichtlinearen Zusammenhänge – etwa bei abnehmendem Grenznutzen – und der vielfältigen Abhängigkeiten zwischen einzelnen Projekten überaus komplex und kann dem Entscheidungsträger nicht abverlangt werden. Eine alternative Vorgehensweise könnte daher auf diese a priori Informationen verzichten und stattdessen in einer ersten Phase „lediglich“ die effizienten Portfolios ermitteln, damit darin anschließend (interaktiv) nach dem attraktivsten Kandidaten gesucht werden kann.

Die Bestimmung eines solchen Lösungsraums ist jedoch keineswegs trivial. Eine vollständige Enumeration aller Portfolios ist nur für überschaubare Probleme in akzeptabler Zeit möglich, da deren Zahl mit jedem weiteren Projekt exponentiell zunimmt. Heuristische Ansätze bieten hier einen Kompromiß zwischen dem Streben nach einem umfassenden Lösungsraum und dem zu seiner Ermittlung nötigen Rechenaufwand. Beispiele für entsprechende Adaptionen „klassischer“ Meta-Heuristiken finden sich bereits für Genetische Algorithmen, Simulated Annealing sowie Tabu Search (für einen Überblick vgl. [9]). Ein neuerer Ansatz basiert auf der Fähigkeit von Ameisenkolonien, bei der Futtersuche den kürzesten Weg ausfindig zu machen. Für die Suche nach effizienten Portfolios von Investitionsprojekten ergeben sich vor allem angesichts der mehrfachen Zielsetzungen interessante Herausforderungen, die erst durch ein in wesentlichen Teilen neues Konzept für künstliche Ameisen erfolgreich zu bewältigen sind.

Das zweite Kapitel widmet sich zunächst der Modellierung der Investitionsentscheidung. In Kapitel drei wird dann der Einsatz künstlicher Ameisen zur Bestimmung effizienter Projektportfolios diskutiert. Numerische Ergebnisse finden sich schließlich im vierten Kapitel.

2 Zur Modellierung der Investitionsentscheidung

Die Komplexität der Investitionsentscheidung wird insbesondere durch die Anzahl der Ziele mitbestimmt und ist dementsprechend hoch, wenn auch die Entwicklung wesentlicher Kennzahlen im Zeitablauf von Interesse ist (vgl. [11]). Die getrennte Abbildung je Nutzenkategorie (z. B. Cash Flow, Umsatz oder Produktstückzahlen) und Planungsperiode (z. B. Geschäftsjahre) führt dann zum Beispiel bei drei Kategorien und fünf Perioden bereits zu fünfzehn Zielgrößen. Für jede davon können die Beiträge der in dem betreffenden Portfolio enthaltenen Investitionsprojekte addiert und schließlich noch um Effekte durch Projektabhängigkeiten – etwa aufgrund von Synergien – bereinigt werden.

Zulässige Projektkombinationen müssen alle Ressourcenbeschränkungen einhalten sowie gegebenenfalls zusätzliche (strategische) Managementvorgaben erfüllen. Letztere können ausgewählte Projektgruppen positiv oder negativ diskriminieren, weil sie etwa einen wesentlichen Beitrag zur Entwicklung einer zukunftsächtigen Technologie leisten oder sich mit Produkten für einen Markt beschäftigen, aus dem mittelfristig der Ausstieg angestrebt wird. Unter den verbliebenen Portfolios sind schließlich jene (effizienten, Pareto-optimalen) Kandidaten zu ermitteln, für die keine Alternative existiert, welche in allen Zielen zumindest gleich gute und in mindestens einem Ziel bessere Werte aufweist. Für ein detailliertes betriebswirtschaftliches Modell vgl. [12].

3 Zum Einsatz künstlicher Ameisen

Das Anfang der 1990er-Jahre entwickelte Ant System (vgl. [4]) basiert auf einem in der Natur beobachtbaren Phänomen: Einer Gruppe von Ameisen gelingt es – obwohl die Tiere nahezu blind sind – den kürzesten Weg zwischen Nest und Futterstelle zu finden. Jedes Tier hinterläßt dabei auf seinem Weg Pheromon, einen Wirkstoff, der andere Ameisen veranlaßt, diesem Weg zu folgen. Je mehr Ameisen einen bestimmten Weg gewählt haben, desto intensiver die Duft- (Pheromon-) Spur und desto eher wird eine weitere Ameise dieser folgen und selbst wieder zu einer Verstärkung des Pheromons beitragen. Im Zeitablauf werden daher immer mehr Tiere den kürzeren Pfad benützen. Durch diesen autokatalytischen Prozeß wird ein günstiger Weg markiert und schließlich von allen Ameisen als bester Pfad erkannt. Rein zufälliges Verhalten geht auf diese Weise in erlerntes über.

Im nachgebildeten Ant System löst eine Population künstlicher Ameisen als Gemeinschaft kooperierender Individuen eine Optimierungsaufgabe unter Verwendung zusätzlicher globaler Information über das Problem. Künstliche Ameisen unterscheiden sich von ihren natürlichen Vorbildern vor allem durch die Eigenschaft des „Sehvermögens“, mit dem sie ihre Umgebung wahrnehmen und die gewonnenen Informationen auch nutzen können. Es erlaubt den Ameisen, sich bei der Suche zusätzlich auch „greedy“ zu verhalten, und beschleunigt damit den Lernvorgang. Aus dem frühen Ant System entwickelte sich als spezielle Form die „Ant Colony Optimization (ACO)“ (vgl. [8]), die erfolgreich auf Reihenfolgenprobleme (TSP, VRP, SMTTP, etc.; vgl. [7,2,1]) angewendet wurde. Zur Lösung des vorliegenden Portfolioauswahlproblems werden im folgenden ein einfacher heuristischer sowie ein ACO-Ansatz beschrieben.

3.1 Einfache Heuristik

Die einfache Heuristik verzichtet im Gegensatz zur ACO vor allem auf die Auswertung von Lernerfahrungen. Ausgehend von einem anfangs leeren Portfolio werden in jedem Durchlauf so lange Projekte aufgenommen, bis eine Nebenbedingung verletzt wird. Die Wahrscheinlichkeit, daß ein Projekt als nächstes gewählt wird, wird durch einen Attraktivitätswert bestimmt, der widerspiegelt, wie gut es zum aktuellen „Rumpf-Portfolio“ paßt. Er beträgt Null, sofern es zu einer Verletzung einer Ressourcenbeschränkung oder einer Managementvorgabe – derzufolge etwa nicht mehr als eine Maximalzahl an Projekten eines bestimmten Typs in dem Portfolio enthalten sein soll – kommen würde. Andernfalls entspricht er dem Beitrag des Projekts zur Erfüllung von „offenen“ Anforderungen, die beispielsweise eine Mindestanzahl an Vertretern aus einer gegebenen Projektgruppe verlangen. Im günstigsten Fall erfüllt die Hinzunahme alle verbliebenen Vorgaben, der Attraktivitätswert beträgt dann eins.

Nach der „Konstruktion“ des Portfolios wird es mit Hilfe eines Quad-Baums (vgl. [10]) mit anderen bereits identifizierten (potentiell) effizienten Kandidaten verglichen und dabei entweder als dominiert

verworfen oder in diese Menge aufgenommen. Nach einer vorgegebenen Zahl an Durchläufen bricht die Heuristik schließlich ab. Die zu diesem Zeitpunkt im Quad-Baum enthaltenen Portfolios bestimmen dann den Lösungsraum.

3.2 Ant Colony Optimization

In der Initialisierungsphase des modifizierten ACO-Algorithmus (vgl. auch den Pseudo-Code in Abbildung 1) werden zunächst Γ künstliche Ameisen mit leeren (Rumpf-)Portfolios $\Psi := \{0, \dots, 0\}$ und zufällig bestimmten Lebensdauern Ξ bzw. Zielgewichtungen χ generiert.

Abbildung 1. ACO-Algorithmus für Mehrzieloptimierung

```

procedure ACO (...) {
  Initialisierung von ACO;
  for  $v := 1$  to  $max\_iterations$  {
    for  $Ant := 1$  to  $\Gamma$  {
      bestimme zufällig die Lebensdauer  $\Xi$  der Ameise
      aus dem Intervall  $[1..N]$ ;
      /* Die (maximale) Anzahl an Projekten, die eine Ameise wählt,
      entspricht ihrer Lebensdauer  $\Xi$ . */
      initialisiere  $\Psi := \{0, \dots, 0\}$ ;
      bestimme zufällig die Zielgewichtung  $\chi_k$  für jedes Ziel  $k$ ;
       $\xi := \Xi$ ;
      while  $\xi > 0$  and  $\exists \eta_i(\Psi) > 0$  {
        wähle ein Projekt unter Verwendung der Formel (1),
        füge es zu dem Rumpf-Portfolio  $\Psi$ ;
        verringere Pheromoninformation lokal;
        dekrementiere  $\xi$ ;
      }
      prüfe Zulässigkeit des Portfolios  $\Psi$ ;
      if Portfolio  $\Psi$  ist zulässig {
        überprüfe die potentielle Effizienz des Portfolios  $\Psi$ ;
        if Portfolio  $\Psi$  ist potentiell effizient {
          speichere Portfolio  $\Psi$ ;
        } } }
      for each Ziel  $k$  {
        bestimme das beste und das zweitbeste Portfolio  $\Psi_k$ ;
        verstärke die Pheromoninformation global;
      } } }
} } }

```

Anschließend versucht jede künstliche Ameise, unter Verwendung von Attraktivitätswerten $\eta_i(\Psi)$ für die Projektkandidaten i ein zulässiges Portfolio Ψ zu „konstruieren“. Nach der Überprüfung auf Zulässigkeit sowie Effizienz – letzteres wieder unter Einsatz eines Quad-Baums – werden die Pheromonwerte global aktualisiert, wobei für jedes einzelne Ziel das beste Portfolio der aktuellen Iteration zur Gänze und die zweitbeste Lösung zur Hälfte zum Pheromonupdate beiträgt. Abweichend von der klassischen ACO, in der nur eine Pheromonmatrix verwendet wird, werden hier für alle K Ziele Pheromonmatrizen τ (jeweils mit Zeilen bzw. Spalten für alle N Projekte) eingesetzt. Die Pheromoninformation τ_{ij}^k gibt nun in bezug auf Ziel k an, wie sehr sich bisher eine Kombination der Projekte i und j bewährt hat.

Sowohl die einfache Heuristik als auch die Pheromoninformation werden dann berücksichtigt, um aus der Menge der verbleibenden Projektkandidaten $\Omega = \{i \in N : \eta_i(\Psi) > 0\}$ einen weiteren zum Rumpf-Portfolio hinzuzufügen. Wenn q_0 die vorgegebene Wahrscheinlichkeit der „max-Selektion“ und q eine in

$[0, 1]$ gleichverteilte Zufallszahl bezeichnet, lautet die entsprechende Entscheidungsregel

$$i = \begin{cases} \arg \max \left\{ \left[\sum_{k=1}^K \left(\chi_k \cdot \sum_{j \in \Psi} \tau_{ij}^k \right) \right]^\alpha \cdot [\eta_i(\Psi)]^\beta \right\} & \text{if } q \leq q_0 \\ I & \text{sonst,} \end{cases} \quad (1)$$

wobei I eine Zufallszahl ist, die nach der diskreten Verteilung

$$\mathcal{P}_i(\Psi) = \begin{cases} \frac{\left[\sum_{k=1}^K \left(\chi_k \cdot \sum_{j \in \Psi} \tau_{ij}^k \right) \right]^\alpha \cdot [\eta_i(\Psi)]^\beta}{\sum_{h \in \Omega} \left(\left[\sum_{k=1}^K \left(\chi_k \cdot \sum_{j \in \Psi} \tau_{hj}^k \right) \right]^\alpha \cdot [\eta_h(\Psi)]^\beta \right)} & \text{if } i \in \Omega \\ 0 & \text{sonst,} \end{cases} \quad (2)$$

gezogen wird.

Sobald eine künstliche Ameise ein Projekt in ihr Portfolio aufgenommen hat, werden die betreffenden Pheromonwerte zunächst aktualisiert. Dabei verringern sich für ein Projekt i alle Werte τ_{ij}^k in Abhängigkeit von den bereits im Rumpf-Portfolio enthaltenen Projekten j für jedes Ziel k , um identische Portfolios zu vermeiden. Nachdem dann die gesamte Ameisenpopulation Lösungen konstruiert hat, verstärkt die ACO-Prozedur schließlich die Pheromonwerte für die besten (vgl. [3]).

4 Numerische Ergebnisse

Das numerische Beispiel basiert auf einer komplexen Entscheidungssituation mit zwanzig Projekten, drei Nutzenkategorien, fünf Planungsperioden und somit fünfzehn Zielen. Die Projekte unterscheiden sich erheblich sowohl in ihren potentiellen Erfolgsgrößen wie auch im jeweiligen Ressourcenbedarf, so daß manche in einzelnen Planungsperioden und/oder Nutzenkategorien besonders hohe und andere weitgehend durchschnittliche Werte aufweisen. Neben Ressourcenbeschränkungen stellen zehn weitere Managementvorgaben sicher, daß z. B. höchstens eines von drei Projekten mit ähnlichem Auftrag oder mindestens zwei Projekte, die zu einer erwünschten Diversifizierung beitragen, in jedem zulässigen Portfolio enthalten sind. Vier weitere Projektabhängigkeiten bilden Synergismen bzw. Kannibalismen ab.

Einige Parametereinstellungen für den ACO-Algorithmus wurden aus erfolgreichen Anwendungen (z. B. [7]: $\alpha = 1$, $\beta = 1$, $\Gamma = 10$) übernommen, andere an die spezifische Aufgabenstellung angepaßt (wie etwa bei der Reduktion von $q_0 = 0,9$ auf $q_0 = 0,4$ zur Förderung von heterogenen Portfolios). Der damit – gemittelt über jeweils zehn Läufe – nach 100, 200, 300, 400 bzw. 500 Iterationen gefundene Anteil an den tatsächlich effizienten Investitionsprogrammen (vgl. Tabelle 1) spiegelt die Entwicklung der Lösungsgüte wider und läßt sich insbesondere auch mit den Ergebnissen bei Einsatz einer Monte Carlo-Simulation bzw. der einfachen Heuristik vergleichen. In umfangreichen Praxisproblemen wird die Identifikation der effizienten Portfolios allerdings zunehmend schwieriger, so daß dann auch die Bereitstellung von hinreichend guten Approximationen hilfreich sein kann (vgl. [5]). Die Tabellenwerte in Klammern beziehen sich dazu auf als effizient ausgewiesene, jedoch – bei Kenntnis des „wahren“ Lösungsraums – eigentlich dominierte Portfolios: Beispielsweise wurden von der ACO nach 100 Iterationen durchschnittlich 91,6 Projektportfolios entdeckt; 89,4 finden sich auch unter den 138 mit vollständiger Enumeration ermittelten tatsächlich effizienten Kandidaten (das entspricht den in der Tabelle angegebenen 65%), während 48,6 überhaupt nicht gefunden und nicht zuletzt deshalb im Durchschnitt 2,2 (2% von 138) irrtümlich als Pareto-optimal ausgewiesen werden.

Während das heuristische Verfahren nach 200 Iterationen durchschnittlich nur 71% (d. h. 97,9 der 138 Portfolios) findet, entdeckt der ACO-Algorithmus bereits 81% (112,0 Portfolios). Für die Qualität der ACO-Prozedur spricht auch der relativ kleine Bereich des evaluierten Suchraums, der in unserem Beispiel $2^{20} = 1,048.576$ mögliche Portfolios umfaßt: Die jeweils zehn künstlichen Ameisen haben nämlich selbst nach 500 Iterationen erst weniger als ein halbes Prozent davon untersucht und damit aber im Durchschnitt 92% (126,7 Portfolios) der effizienten Kandidaten entdeckt. Das kann zumindest als ein erstes Indiz für die Eignung des Verfahrens auch für noch wesentlich umfangreichere Probleme gelten. Die ebenfalls getestete Monte Carlo-Simulation erweist sich hier hingegen als offensichtlich völlig unzureichend.

Tabelle1. Numerische Ergebnisse

	100 It.	200 It.	300 It.	400 It.	500 It.
Monte Carlo:	0,00 (0,01)	0,00 (0,03)	0,00 (0,04)	0,00 (0,05)	0,08 (0,05)
Heuristik:	0,55 (0,03)	0,71 (0,02)	0,81 (0,02)	0,85 (0,01)	0,90 (0,00)
ACO:	0,65 (0,02)	0,81 (0,01)	0,88 (0,00)	0,91 (0,00)	0,92 (0,00)

5 Resümee

Die Bestimmung des – unter Berücksichtigung mehrfacher Zielsetzungen – „besten“ Investitionsprogramms ist von hoher praktischer Bedeutung. Da häufig ex ante keine geeignete Nutzenfunktion zur Verfügung steht, bietet sich ein zweistufiges Vorgehen an, bei dem zunächst ein Lösungsraum von effizienten Portfolios ermittelt wird. Bei einer größeren Zahl an Projektvorschlägen ist das aber nur mehr durch den Einsatz von Meta-Heuristiken leistbar.

Der hier gewählte Ansatz mit künstlichen Ameisen wurde für diese Aufgabenstellung gegenüber dem ACO-Standardalgorithmus grundlegend modifiziert: (1) Während in der klassischen ACO zur Verwaltung der Pheromonspuren zweidimensionale Pheromonmatrizen ausreichen, wird nunmehr die Spurinformati-on für jedes einzelne Ziel in einer eigenen Pheromonmatrix abgelegt. (2) Um möglichst viele, effiziente und heterogene Portfolios zu finden, wird außerdem in jeder Iteration für jede einzelne künstliche Ameise ein eigener Gewichtsvektor für die betrachteten Ziele zufällig generiert. (3) Statt der Vorgänger- bzw. Nachfolgebeziehungen als Basis der Pheromondekodierung, wurde schließlich der paarweise Vergleich als Dekodierungsschema gewählt.

Die bisherigen numerischen Ergebnisse belegen das Potential von künstlichen Ameisen bei der Suche nach effizienten Investitionsprogrammen. Dadurch motivierte weitere Forschungsaktivitäten beschäftigen sich in einem nächsten Schritt mit dem Einsatz von ACO bei – in bezug auf die Anzahl der zur Wahl stehenden Projektalternativen – noch wesentlich umfangreicheren Entscheidungsproblemen bzw. mit der Weiterentwicklung von Maßzahlen zur Qualitätsbeurteilung der hierbei generierten Lösungsräume.

Literatur

1. Bauer, A., Bullnheimer, B., Hartl, R.F., Strauss, C. (2000): Minimizing total tardiness on a single machine using Ant Colony Optimization. *Central European Journal of Operations Research* **8**, 125–141
2. Bullnheimer, B., Hartl, R.F., Strauss, C. (1999): An improved Ant System algorithm for the vehicle routing problem. *Annals of Operations Research* **89**, 319–328
3. Bullnheimer, B., Hartl, R.F., Strauss, C. (1999): A new rank based version of the Ant System. *Central European Journal of Operations Research* **7**, 25–38
4. Colomi, A., Dorigo, M., Maniezzo, V. (1992): Distributed optimization by Ant Colonies. In: Varela, F., Bourgine, P. (Hrsg.): *Proc. First Europ. Conf. on Artificial Life*. Elsevier, Amsterdam, 134–142.
5. Czyzak, P., Jaskiewicz, C. (1998): Pareto Simulated Annealing. A metaheuristic technique for multiple-objective combinatorial optimization. *Journal of Multi-Criteria Decision Analysis* **7**, 34–47
6. Dorigo, M. (1992): *Optimization, Learning and Natural Algorithms*. Doctoral Dissertation, Politecnico di Milano
7. Dorigo, M., Gambardella, L.M. (1997): Ant Colony System. A cooperative learning approach to the Travelling Salesman Problem. *IEEE Transactions on Evolutionary Computation* **1**, 53–66
8. Dorigo, M., Di Caro, G. (1999): The Ant Colony Optimization meta-heuristic. In: Corne, D., Dorigo, M., Glover, F. (Hrsg.): *New Ideas in Optimization*. McGraw-Hill, London, 11–32
9. Ehrgott, M., Gandibleux, X. (2000): A survey and annotated bibliography of multiobjective combinatorial optimization. *OR Spektrum* **22**, 425–460
10. Habenicht, W. (1983): Quad trees. A datastructure for discrete vector optimization problems. In: Hansen, P. (Hrsg.): *Essays and Surveys on Multiple Criteria Decision Making*. Lecture Notes in Economics and Mathematical Systems 209. Springer, Berlin, 136–145
11. Ringuest, J.L., Graves, S.B. (1990): The linear R&D project selection problem. An alternative to net present value. *IEEE Transactions on Engineering Management* **37**, 143–146

12. Stummer, C. (2000): Ein interaktives Entscheidungsunterstützungssystem zur Portfolioauswahl bei mehrfachen Zielsetzungen. In: Wanka, G. (Hrsg.): Decision Theory and Optimization in Theory and Practice. Shaker, Aachen, 129-149
13. Vincke, P. (1992): Multicriteria Decision-Aid. Wiley, Chichester