

2009

EIN OPTIMIERUNGSSYSTEM FÜR DIE STRATEGISCHE PRODUKTIONS- UND KAPAZITÄTSPLANUNG IN DER AUTOMOBILINDUSTRIE

Achim Koberstein
Universität Paderborn

Ralf Bihlmaier
Daimler AG Group

René Obst
Daimler AG Group

Leena Suhl
Universität Paderborn

Follow this and additional works at: <http://aisel.aisnet.org/wi2009>

Recommended Citation

Koberstein, Achim; Bihlmaier, Ralf; Obst, René; and Suhl, Leena, "EIN OPTIMIERUNGSSYSTEM FÜR DIE STRATEGISCHE PRODUKTIONS- UND KAPAZITÄTSPLANUNG IN DER AUTOMOBILINDUSTRIE" (2009). *Wirtschaftsinformatik Proceedings 2009*. 86.

<http://aisel.aisnet.org/wi2009/86>

This material is brought to you by the Wirtschaftsinformatik at AIS Electronic Library (AISeL). It has been accepted for inclusion in Wirtschaftsinformatik Proceedings 2009 by an authorized administrator of AIS Electronic Library (AISeL). For more information, please contact elibrary@aisnet.org.

EIN OPTIMIERUNGSSYSTEM FÜR DIE STRATEGISCHE PRODUKTIONS- UND KAPAZITÄTSPLANUNG IN DER AUTOMOBILINDUSTRIE

Achim Koberstein¹, Ralf Bihlmaier², René Obst,
Leena Suhl¹

Kurzfassung

Optimierungssysteme werden in der produzierenden Industrie oft für die deterministische operative und taktische Planung, aber weniger für die strategische Planung unter Unsicherheiten eingesetzt. Dieser Beitrag diskutiert die Modellierung von Unsicherheiten im Rahmen von Entscheidungsunterstützungssystemen, die auf der stochastischen Optimierung basieren. Als Praxisbeispiel wird die strategische Kapazitäts- und Produktionsplanung in der Automobilindustrie betrachtet, wobei durch unbekannt zukünftige Absatzschwankungen Unsicherheiten gegeben sind. Die Planungsaufgabe wird als zweistufiges stochastisches Programm mit gemischt-ganzzahligen Variablen modelliert. Zur Lösung des Programms werden Nachfrageszenarien mit Hilfe von Monte Carlo Sampling generiert. Es wird gezeigt, dass die Robustheit der Lösungen durch die stochastische Modellierung erhöht werden kann.

1. Strategische Netzwerkplanung in der Automobilindustrie

Stagnierende Preise in Verbindung mit einer Individualisierung und stärkeren Schwankung der Nachfrage charakterisieren die Automobilindustrie in jüngster Vergangenheit. Die steigende Individualisierung bewirkt sinkende Absatzpotenziale auf bestehenden Märkten und eine Verstärkung der Unsicherheit in den Absatzmengen. Der stagnierende Preisverlauf in Verbindung mit der Erhöhung der Variantenvielfalt verstärkt zusätzlich den Kostendruck in der Produktion. Durch eine konsequente Planung von Flexibilitätspotenzialen und Kapazitäten kann eine durchgreifende Senkung der Produktionskosten und Sicherstellung der Nachfragebefriedigung erzielt werden. Im Allgemeinen ist diese Planungsaufgabe im strategischen Design des Wertschöpfungsnetzwerkes eines Unternehmens verankert. Wesentlicher Inhalt dieser Planungsaufgabe ist die Festlegung der Produktwerkzuordnung mit der Installation einer jeweiligen Ausgangskapazität. Hierbei sind folglich Entscheidungen über unterschiedliche Aspekte der Systemflexibilitätsgestaltung in Form von Produktflexibilität, Volumenflexibilität sowie die Anpassungsfähigkeit des Systems über die Zeit zu treffen. Die Planung der Kapazitäten erfolgt dabei in fest vorgegeben, diskreten Stufen. In der Automobilindustrie können Produktionskapazitäten in der Regel nicht in kontinuierlicher Form

¹ Universität Paderborn, Warburger Str. 100, D-33098 Paderborn

² Daimler AG Group, Research & Advanced Engineering, D-89073 Ulm

ausgebaut werden. Gründe hierfür sind standardisierte Fertigungsstraßen (technische Kapazität) und tariflich vereinbarte Arbeitszeitmodelle (organisatorische Kapazität).

Die zeitgleiche optimierende Planung von Flexibilität und Kapazität ist hierbei selbst bei stabilen Einflussgrößen aufgrund der Interdependenzen der Einzelentscheidungen durch eine hohe Komplexität geprägt. Die Planung eines Produktionsnetzwerkes kann in der Realität der Automobilindustrie sehr schnell nicht mehr handhabbare Dimensionen annehmen. Betrachten wir hierzu im Folgenden ein Produktionsnetz für ein zukünftiges Weltmotorenkonzept aus der Automobilindustrie. Der Motor, vier Hauptvarianten und seine jeweiligen fünf Hauptkomponenten können an fünf unterschiedlichen Standorten gefertigt werden. Die Motorvarianten werden jeweils an fünf Konsumenten, in diesem Fall Aufbauwerke des Unternehmens, ausgeliefert. Abbildung 1 verdeutlicht die Stückliste der gefertigten Produkte und Komponenten in verkürzter Schreibweise.

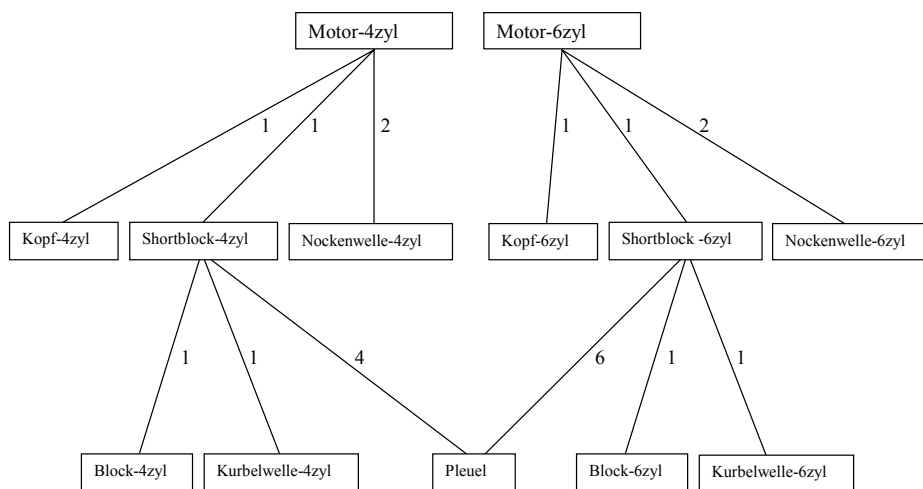


Abbildung 1: Gekürzte Variantenstückliste des betrachteten Produktionsnetzes

An jedem Standort kann über die Implementierung von vier Kapazitätsstufen entschieden werden, welche über die Zeit angepasst werden können. Zielsetzung ist die Minimierung der diskontierten Investitionen und Kosten. Die Komplexität erhöht sich zusätzlich durch den langen und weit in der Zukunft liegenden Zeithorizont - in der Automobilindustrie in der Regel zwischen 8 und 15 Jahren, 5 Jahre in der Zukunft. Ermittelt man für den Fall des sicheren Eintretens der Nachfrageprognose die Anzahl der zu treffenden Entscheidungen ergibt sich folgendes Bild:

Produkte	36
Standorte	5
Produktionslinien	43
Kapazitätsstufen	4
Abnehmer	5
Jahre	8

Tabelle 1: Struktur des Entscheidungsproblems

Produktallokation	112
Kapazitätsinitialisierung	172
Kapazitätsanpassung	344
Produktion/ Transport Endprodukte	3000
Produktion/ Transport Vorprodukte	12000

Tabelle 2: Entscheidungsvariablen des vorliegenden Beispiels

Wegen der vorliegenden Komplexität greifen global ausgerichtete Unternehmen vermehrt auf Optimierungstechniken zur Unterstützung ihres Entscheidungsprozesses zurück, die Einbeziehung von Unsicherheit findet dabei jedoch nur rudimentär, z.B. durch Durchführung von Sensitivitätsanalysen, oder gar keine Berücksichtigung. Soll die Unsicherheit aber direkt in die Optimierung integriert werden, so lässt sich am beschriebenen Beispiel sehr leicht erkennen, dass diese Aufgabe mit konventionellen Lösungsverfahren gar nicht oder nur mit sehr hohem Zeitaufwand durchführbar ist.

Nachdem computerbasierte Optimierungssysteme in den letzten Jahren rasant weiterentwickelt wurden (s. [5, 13]), sollte man heute jedoch nach neuen Ansätzen suchen, die eine effiziente Lösung schwieriger Optimierungsmodelle ermöglichen. Im Folgenden wird daher die Anwendbarkeit der stochastischen Optimierung für die mit Unsicherheiten behaftete, mehrstufige strategische Planungsaufgabe untersucht. Dazu wird ein allgemeines stochastisches Optimierungsmodell für die Aufgabenstellung der Automobilindustrie angepasst. Die (nahezu) optimale Lösung solcher Modelle bildet eine besondere Schwierigkeit, weil die Berücksichtigung der stochastischen Verteilung im Rahmen möglichst vieler Szenarien den erforderlichen Rechenaufwand vervielfältigt. Zur optimalen Lösung des Modells wird ein in eine Monte Carlo Simulation eingebettetes Benders-Dekompositionsverfahren eingesetzt. Im weiteren Verlauf des Beitrags wird insbesondere auf die Implementierung im Rahmen eines Entscheidungsunterstützungssystems und auf den Mehrwert der Lösung des stochastischen Modells im Vergleich zu der des deterministischen Modells eingegangen.

In der Literatur findet man eine Vielzahl an Modellen, welche unterschiedliche Aspekte der Strategischen Netzwerkplanung betrachten. Einen Überblick über bestehende Modelle geben beispielsweise [2], [8] oder [15]. Die Arbeit „Principles on the Benefits of Manufacturing Process Flexibility“ von Jordan und Graves [8] kann im Rahmen der Gestaltung flexibler Produktionssysteme als richtungweisend gewürdigt werden. Die Autoren stellen die Entscheidung über die Produktflexibilität in den Mittelpunkt der strategischen Planung unter Unsicherheit. Dieser Ansatz wird in [10] auf mehrstufige Produktionsnetze erweitert. Auch hier wird durch numerische Studien die Vorteilhaftigkeit von geschlossenen Chains nachgewiesen. Der Aufsatz [7] stellt ein lineares Optimierungsmodell für die integrierte Planung vor. In [6] wird die Robustheit von Chainingstrategien auch für von Produktlebenszyklen beeinflusste, unsichere Nachfrage bestätigt. Alonso-Ayuso et al. entwickeln ein umfassendes Modell [1], das diverse Charakteristika der Netzwerkplanung integriert. Das Modell beinhaltet dynamische und stochastische Faktoren, berücksichtigt die Struktur des Netzwerks und führt eine Flexibilitätsplanung (Baureihen- und Volumenflexibilität) durch.

Eine grundlegende Einführung in die stochastische Optimierung findet sich in [4] und [12]. Santos entwickelt [14] schrittweise ein spezielles Modell zur Optimierung globaler Supply Chains unter Unsicherheit. Das Optimierungsproblem wird als einperiodisches zweistufig stochastisches Programm implementiert. Auf der ersten Stufe werden strategische Entscheidungen bezüglich der Standorte getroffen. Über Binärvariablen wird über die Nutzung der Einrichtungen entschieden, die Fixkosten verursachen. Auf der zweiten Stufe wird die Nutzung der gegebenen Konfiguration

optimiert und bewertet. Die Stochastik wird über das Verfahren Sample Average Approximation (SAA) erfasst, das den erwarteten Zielfunktionswert der zweiten Stufe bei einer hohen gegebenen Szenarioanzahl approximiert. Der SAA verwendet dabei Monte Carlo Simulationen zur Vorhersage der unsicheren Eingangsgrößen. Dieser Ansatz, angewendet auf die strategische Netzwerkplanung, stellt eine Innovation dar, die die Stochastik sehr gut erfasst. Die Optimierung ist jedoch auf vier Ebenen beschränkt: Zulieferer, Produktionsstandorte, Produktionseinrichtung an den Standorten und Lager, eine Betrachtung unterschiedlicher Kapazitäten entfällt. Das Modell eignet sich daher nur bedingt zur Untersuchung von Produktionsnetzwerken, da diese in der Realität aus mehreren verbundenen Fertigungseinrichtungen bestehen.

2. Das Optimierungsmodell

Das Supply Chain Netzwerk wird als gerichteter Graph $G = (N, A)$ abgebildet, wobei N die Menge der Knoten und A die Menge der Kanten darstellt. Die Menge $N = L \cup S \cup M$ enthält die Menge L der Produktionslinien, die Menge S der Kapazitätsstufen und die Menge M der Märkte. Kanten $(e, e') \in A$ werden nur über die disjunkten Teilmengen L, S und M gebildet, d.h. $A \subseteq L \times S \cup S \times M$. Des Weiteren sei K die Menge der Produkttypen, die durch das Netzwerk transportiert werden. Die Entscheidungen der strategischen Ebene werden durch die binären Entscheidungsvariablen

$$y_{lk}^{FL} = \begin{cases} 1 & \text{Linie } l \text{ bearbeitet Produkt } k \\ 0 & \text{Sonst} \end{cases}$$

$$y_{ls}^{KA} = \begin{cases} 1 & \text{Linie } l \text{ nutzt Kapazität } s \\ 0 & \text{Sonst} \end{cases}$$

repräsentiert, wobei y_{lk}^{FL} die Flexibilitätsentscheidung impliziert, ob das Produkt $k \in K$ auf Linie $l \in L$ gefertigt werden soll. Analog geben die y_{ls}^{KA} Aufschluss über die Kapazitätsentscheidung der Linie $l \in L$, welche Kapazität $s \in \{s \mid (l, s) \in A\}$ genutzt werden soll. Die Entscheidungsvariable $x_{ij}^k \in \mathbb{R}^+$ repräsentiert die Menge von Produkt k , die von Knoten i zu Knoten j über die Kante $(i, j) \in A$ transportiert wird. Im Folgenden werden die im Modell verwendeten Parameter kurz vorgestellt. Seien c_{lk}^{FL} die Flexibilitätskosten für die Möglichkeit der Fertigung des Produkts k auf Linie l . Durch die Nutzung der Kapazität s entstehen für die Linie l Kapazitätskosten von c_{ls}^{KA} . Die Parameter d_m^k bilden die Nachfrage des Marktes m für das Produkt k ab. Kapazitäten der Kapazitätsstufen $s \in S$ werden durch m_s angegeben, wobei M^S mit $M^S \geq m_s, \forall s \in S$ die höchste Kapazität darstellt. Die Herstellung einer Einheit von Produkt k auf Linie l in Kapazitätsstufe s verursacht Produktionskosten $q_{ls}^{p^k}$. Es entstehen Transportkosten $q_{lm}^{t^k}$ pro transportierter Einheit des Produkts k von Linie l zu Markt m . Zur Herstellung einer Einheit des Produkts k auf Linie l wird ein Kapazitätsbedarf von $r_l^k \geq 1$ benötigt. Des Weiteren sei $w_{lk}^{FLS} \in \{0, 1\}$ eine politische oder technische Vorgabe, ob das Produkt k auf Linie l gefertigt werden kann. Folgendes gemischtganzzahliges Optimierungsproblem lässt sich zur beschriebenen Planungsaufgabe formulieren:

$$\left. \begin{aligned} & \sum_{l \in L} \sum_{k \in K} c_{lk}^{FL} y_{lk}^{FL} + \sum_{l \in L} \sum_{s: (l,s) \in A} c c_{ls}^{KA} y_{ls}^{KA} + \\ & \sum_{k \in K} \sum_{l \in L} \sum_{j: (i,j) \in A} q_{ij}^{p^k} x_{ij}^k + \sum_{k \in K} \sum_{i \in S} \sum_{j \in M} q_{ij}^{T^k} x_{ij}^k \end{aligned} \right\} \rightarrow \min \quad (1)$$

s.d.

$$\sum_{l: (l,j) \in A} x_{lj}^k - \sum_{m \in M} x_{jm}^k = 0 \quad \forall j \in S, \forall k \in K \quad (2)$$

$$\sum_{i \in S} x_{ij}^k \geq d_j^k \quad \forall j \in M, \forall k \in K \quad (3)$$

$$\sum_{j: (i,j) \in A} x_{ij}^k \geq M^S y_{ik}^{FL} \quad \forall i \in L, \forall k \in K \quad (4)$$

$$\sum_{k \in K} r_i^k x_{ij}^k \leq m_j y_{ij}^{KA} \quad \forall i \in L, \forall j \in S \quad (5)$$

$$\sum_{j: (i,j) \in A} y_{ij}^{KA} \leq 1 \quad \forall i \in L \quad (6)$$

$$y_{ik}^{FL} \leq w_{ik}^{FLS} \quad \forall i \in L, \forall k \in K \quad (7)$$

$$x_{ij}^k \in \mathbb{R}^+ \quad (8)$$

$$y_{lk}^{FL}, y_{ls}^{KA} \in \{0,1\} \quad (9)$$

Das Ziel des Programms ist, alle strategischen und taktischen Entscheidungen y, x zu bestimmen, sodass unter Einhaltung der Nebenbedingungen (2)-(9) die Flexibilitäts-, Kapazitäts-, Produktions- und Transportkosten minimiert werden (1). Die Restriktion (2) stellt die Balance für jede Kapazitätsstufe j zur Flusserhaltung aller Produkte k von den Linien zu den Märkten sicher. Durch (3) werden alle Produktnachfragen der Märkte vollständig erfüllt. Mit (6) wird die Linie i auf die Nutzung von höchstens einer zugehörigen Kapazitätsstufe restringiert. Wird auf Linie i mit Kapazitätsstufe j produziert ($y_{ij}^{KA} = 1$), dann sind die Produktionsmengen über den zur Produktion notwendigen Kapazitätsbedarf durch die zur Verfügung stehende Kapazität m_j der Kapazitätsstufe beschränkt (5). Soll die Kapazitätsstufe j nicht von der Linie i genutzt werden ($y_{ij}^{KA} = 0$), dann kann mit dieser wegen (5) nicht produziert werden, weil $y_{ij}^{KA} = 0 \Leftrightarrow x_{ij}^k = 0 \forall k$. Die Nebenbedingungen (4) und (7) gewährleisten, dass das Produkt k nur dann auf Linie i produziert werden kann, wenn die Vorgabe w_{lk}^{FLS} dies erlaubt. Wird das Produkt k auf Linie i produziert, dann (und genau dann) gilt $y_{ik}^{FL} = 1$, d.h. $x_{ij}^k > 0 \Leftrightarrow y_{ik}^{FL} = 1$. Dabei ist M^S wegen (5) mit $r_i^k \geq 1$ eine kleinste obere Schranke für alle Produktionsmengen.

Die Formeln (1) – (9) stellen das deterministische Grundmodell dar, in dem alle Parameter grundsätzlich vor der Lösung fest definiert sind. In der Praxis müssen jedoch die strategischen Kapazi-

täts- und Flexibilitätsentscheidungen y_{lk}^{FL} und y_{ls}^{KA} viel früher getroffen werden als die taktischen Entscheidungen x_{ij}^k , die von der Nachfrage abhängig sind. Daher wird das Modell im Folgenden durch stochastische Komponenten erweitert, um die Marktnachfrage als Zufallsvariable in Form von repräsentativen Szenarien abbilden zu können.

Zunächst wird die Annahme einer konstanten Marktnachfrage mit der Einbringung von Nachfrageparametern $d_m^k(\omega)$ aufgehoben, welche Zufallseinflüssen mit bekannten diskreten Verteilungsfunktionen unterliegen. Durch die Einführung von Fehlmengen werden Kompensationsaktionen zur Erfüllung der Nebenbedingung (3) ermöglicht, die anhand von Kompensationskosten in der Zielfunktion bestraft werden. Die Kompensationskosten ergeben sich aus Fehlmengenkosten und resultierenden Kosten aus taktischen Entscheidungen. Demnach ist die Zielsetzung des Programms, die Flexibilitäts- und Kapazitätskosten sowie die erwarteten Produktions-, Transport- und Fehlmengenkosten unter der Betrachtung endlich vieler Szenarien ξ^n mit $n = 1 \dots N$ zu minimieren:

$$\Psi(y^{FL}, y^{KA}) = \sum_{n=1}^N p^n Q(y^{FL}, y^{KA}, \xi^n) \quad (10)$$

Dabei ist p^n die Eintrittswahrscheinlichkeit des n-ten Szenarios. Das gemischt-ganzzahlige, zweistufige, stochastische Optimierungsmodell kann mit einem spezialisierten Verfahren gelöst werden, dass auf der Benders Dekomposition basiert (vgl. [3, 14]). In der ersten Stufe werden dabei die strategischen Entscheidungen festgelegt, während in der zweiten Stufe darauf basierend die taktische Planung im Hinblick auf das vorgegebene Nachfrageszenario antizipiert wird. Die Schwankungen der Nachfrage werden durch viele Szenarien abgebildet, die bei der Berechnung des Erwartungswertes für die Kompensationsfunktion berücksichtigt werden (10). Die strategischen Entscheidungen y^{FL}, y^{KA} werden anhand ihrer Kosten unter Berücksichtigung erwarteter zukünftiger Effekte $\Psi(y^{FL}, y^{KA})$ getroffen.

3. Monte Carlo Sampling Methoden

In dem in Abschnitt 3 vorgestellten stochastischen Programm werden ausschließlich die Produktnachfragen als unsichere Größen berücksichtigt. Kosten, Kapazitäten und Kapazitätsbedarfe werden als bekannte Parameter betrachtet. Trotz dieser vereinfachenden Annahmen lässt sich das vorliegende Optimierungsmodell für reale Supply Chain Designprobleme mit geeigneten Optimierungstechniken aufgrund der Schwierigkeit der Berechnung der implizit definierten nichtlinearen Kompensationsfunktion $\Psi(y^{FL}, y^{KA})$ nur für eine sehr kleine Anzahl von Szenarien lösen. Die Wahrscheinlichkeitsverteilung der unsicheren Größen kann dabei lediglich unzureichend in der Entscheidungsfindung berücksichtigt werden. Selbst bei einer sehr ungenauen diskreten Wahrscheinlichkeitsverteilung von $\xi(\omega)$, in der die stochastisch unabhängigen Zufallsgrößen d_m^k beispielsweise jeweils einen von nur drei möglichen Werten annehmen können, steigt die Anzahl $N = 3^{|\mathcal{M}| \times |\mathcal{K}|}$ der zu berücksichtigenden Szenarien exponentiell mit der Problemgröße. Für das unten betrachtete Beispielmodell der Größe eines kleineren realen Problems mit $|\mathcal{M}| = 10$ und $|\mathcal{K}| = 10$ bedeutet dies die Berücksichtigung von $N = 3^{|\mathcal{M}| \times |\mathcal{K}|} = 3^{100}$ Szenarien. Die Berechnung bzw. Einbeziehung einer derart astronomischen Anzahl von Szenarien in stochastische Programme wird auch in absehbarer Zukunft mit leistungsfähigen Rechnern nicht möglich sein. Um dennoch eine hinreichend genaue diskrete Wahrscheinlichkeitsverteilung von $\xi(\omega)$ in der Entscheidungsfindung zu berücksichtigen, ist die Berechnung aller möglichen Szenarien nicht weiter praktikabel.

Das Prinzip der Monte Carlo Simulation bietet eine grundsätzliche Möglichkeit zur Lösung stochastischer Programme, in denen die Kompensationsfunktion aufgrund der Berechnung von mehr-

dimensionalen Integralen mit extrem hohen Dimensionen nicht mehr numerisch bestimmt werden kann. Im Vordergrund der Monte Carlo Sampling Methode steht die Berechnung von statistischen Schätzern und Konfidenzintervallen, mit denen eine Aussage über das gesuchte Ergebnis bei einer deutlich reduzierten und somit handhabbaren Anzahl zu berücksichtigender Szenarien getroffen werden kann. Die Sample Average Approximation, die auch unter den Namen Stochastic Counterpart Method und Sample Path Optimization bekannt ist, stellt eine auf diesem Prinzip basierende Sampling Strategie dar.

Die Grundidee der Sample Average Approximation (SAA) zur Lösung eines zweistufig-stochastischen Kompensationsmodells besteht darin, dass der Erwartungswert $E_{\xi}Q(y, \xi(\omega))$ der Kompensationsfunktion anhand eines zufällig generierten Samples, bestehend aus N realisierten Szenarien $\xi_1, \xi_2, \dots, \xi_N$ von $\xi(\omega)$, durch die Sample Average Funktion

$$\hat{\Psi}_N(y) = N^{-1} \sum_{n=1}^N Q(y, \xi^n) \quad (11)$$

approximiert wird. Mit der Ersetzung des Erwartungswerts der Kompensationsfunktion durch die Sample Average Funktion leitet sich aus dem wahren Problem das SAA-Problem ab, das mit einer angebrachten deterministischen Optimierungstechnik, die die spezielle Struktur des Problems zur Lösung ausnutzt, angemessen gelöst werden kann. Entscheidend bei diesem Vorgehen ist, dass die für den SAA-Ansatz benötigte Anzahl N der Szenarien eines Samples, relativ zur Anzahl aller möglichen Szenarien, sehr klein ist. Das SAA-Problem bleibt daher numerisch lösbar. Durch den Ansatz der SAA konvergiert die Lösung \hat{y}_N des SAA-Problems mit Erhöhung von N exponentiell zu ihrem Pendant im *wahren* Problem.

Sampling Strategien können auf verschiedene Arten eingesetzt werden, mit denen Ansätze zur Lösung stochastischer Programme erzielt werden. Die in diesem Beitrag angewendete Sampling Strategie zählt zur Klasse der externen Ansätze, da die Sample unabhängig von der Optimierungstechnik, d.h. vom deterministischen Algorithmus zur Lösung des konstruierten SAA-Problems, generiert werden. Aus der Trennung von Sampling Strategie und Optimierungstechnik ergeben sich mehrere Vorteile. Beispielsweise kann jeder für das SAA-Problem geeignete deterministische Optimierungsalgorithmus für den SAA-Ansatz verwendet werden. Aber auch der Einsatz paralleler Implementierungen zur Lösungsfindung wird durch diese Separation ermöglicht.

Die Sample Average Funktion $\hat{\Psi}(y)$ stellt eine erwartungstreue Schätzung der Kompensationsfunktion $\Psi(y)$ dar, da jedes ξ^n der gleichen Wahrscheinlichkeitsverteilung unterliegt, durch die auch $\xi(\omega)$ verteilt ist. Falls alle ξ^n stochastisch unabhängig sind, konvergiert $\hat{\Psi}_N(y)$ mit $N \rightarrow \infty$ nach dem Gesetz der großen Zahlen sicher gegen $\Psi(y)$. Anhand der Ersetzung der Kompensationsfunktion durch die Sample Average Funktion wird ein allgemeines zweistufig-stochastisches Problem folglich durch das SAA-Problem

$$\min_y \left\{ \hat{f}_N(y) = c^T y + N^{-1} \sum_{n=1}^N Q(y, \xi^n) \right\} \quad (12)$$

approximiert. Seien im Folgenden v_N und \hat{y}_N der optimale Zielfunktionswert bzw. die optimale Lösung des SAA-Problems, die mit steigender Anzahl von Szenarien N zu ihren Pendants $v^* = f(y^*)$ bzw. y^* konvergieren und als statistische Schätzer dieser Größen betrachtet werden können. Der entscheidende Punkt für die praktische Lösung ist die Wahl eines geeigneten N , da in dieser ein problemspezifischer Zielkonflikt zwischen der Qualität der Lösung und dem Aufwand zur Berechnung des SAA-Problems vorliegt.

4. Implementierung und Ergebnisse

Das zweistufige stochastische Optimierungsmodell mit Monte Carlo Sampling wurde im Rahmen eines Entscheidungsunterstützungssystems (Decision Support System, DSS) implementiert, dessen Architektur in der Abbildung 2 dargestellt wird. Die entwickelte Netzwerkplanungssoftware basiert auf einer Microsoft-Excel-Tabellenkalkulation, deren Programmlogik durch die in Excel integrierte Skriptsprache Visual Basic for Applications (VBA) realisiert wurde.

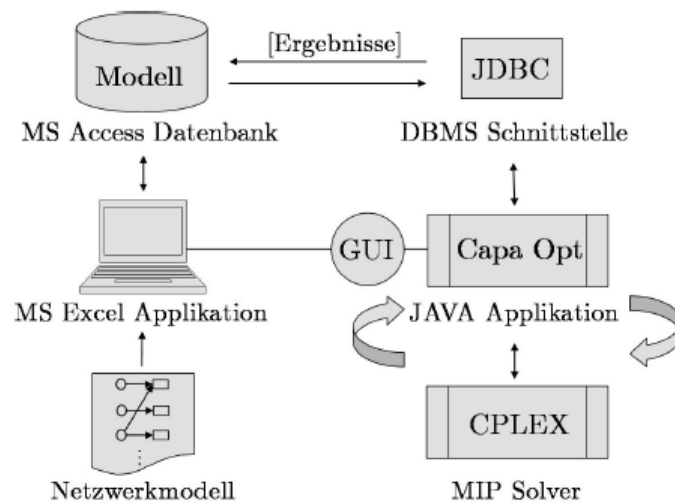


Abbildung 2: Architektur des Entscheidungsunterstützungssystems

Die Netzwerk-Konfiguration kann vom Entscheidungsträger über diese Excel-Applikation in eine angebundene relationale Datenbank (Microsoft Access 2003) exportiert bzw. aus dieser importiert werden. Die Excel-Applikation dient dabei der Ein- und Ausgabe der Daten sowie der grafischen Visualisierung der Optimierungsergebnisse.

Den Kern des Systems bildet das Planungs- und Optimierungsmodul CapaOpt, das in der objektorientierten Programmiersprache Java von Sun Microsystems mit der Open Source Entwicklungsumgebung Eclipse Software Development Kit (SDK) 3.2 auf dem J2SE Development Kit (JDK) der Version 1.5.0.60 programmiert und kompiliert wurde. Das oben beschriebene Lösungsverfahren wurde in CapaOpt implementiert. CapaOpt übernimmt die Applikationslogik des DSS und organisiert mit der relationalen Anfragesprache SQL über die Java Data Base Connectivity (JDBC) Schnittstelle das Datenmanagement mit dem Datenbankmanagementsystem (DBMS). Über diese Schnittstelle wird von CapaOpt zur Laufzeit eine temporäre Datenstruktur geladen. Die für das Lösungsverfahren benötigten mathematischen Modelle werden aus dieser Struktur generiert. Zur Lösung der Modelle wurde der MIP-Solver ILOG CPLEX 10.0 an die Java-Applikation angebunden (s. [11]). Die Interaktion zwischen CapaOpt und dem Solver erfolgt dabei über eine dynamische Bibliothek DLL (Dynamic Link Library) und die ILOG Concert Technology 2.2 Schnittstelle. Des Weiteren stellt CapaOpt dem Entscheidungsträger eine grafische Benutzeroberfläche GUI (Graphical User Interface) zur Verfügung, mit der die Ablaufsteuerung des DSS und die Konfiguration der Lösungsmethodik zu handhaben ist.

Das untersuchte Testproblem stellt eine Netzwerk-Konfiguration dar, die sich durch zehn Produkttypen, zehn Produktionslinien mit jeweils fünf Kapazitätsstufen und zehn Märkte charakterisiert. Die Produktflexibilität der Produktionslinien wird im Testproblem nicht eingeschränkt, d.h. es wird ein vollflexibles Produktionssystem betrachtet, in dem jeder Produkttyp auf jeder Linie produziert werden kann. Die eingegebenen Parameterwerte der Netzwerk-Konfiguration haben keinen Bezug

zu realen Daten und sind frei erdacht. Dabei sind die Produktionskosten und der Kapazitätsbedarf, im Gegensatz zu allen anderen Parameterwerten, für alle Indizes einheitlich gewählt. Für jedes Szenario werden die Produktnachfragen der Märkte durch eine Normalverteilung anhand bekannter Verteilungsparameter zufällig generiert.

Im Folgenden soll ein Qualitätsvergleich der Lösung des stochastischen Problems vorgenommen werden, indem diese Lösung der *erwarteten Lösung* (EEV) des entsprechenden mean value problems (MVP) gegenüber dem *durch Szenarien generierte Lösung* gestellt wird. Beim MVP wird das Modell einmalig mit dem Erwartungswert der Nachfrage gelöst. Die erzielten Ergebnisse beider Lösungsansätze werden insbesondere auf Planungsrobustheit und -genauigkeit untersucht. Die Tests wurden auf einem Intel®Xeon Prozessor mit 3,60 GHz und 3,0 GB RAM durchgeführt. In Tabelle 3 werden die Auswirkungen der unsicheren Größen bei einer Erhöhung der Varianz (bzw. Standardabweichung) auf die resultierenden Gesamtkosten der Lösungsansätze dargestellt.

Lösungsansatz	Kosten	Standardabweichung der Nachfrage		
		30	60	100
MVP	Absolut	6.263,14	7.104,82	8.851,67
	Zuwachs	-	841,68	2.588,53
SAA	Absolut	1.813,16	2.204,37	3.168,37
	Zuwachs	-	391,21	1.355,21
	VSS	4.449,98	4.900,45	5.683,30

Tabelle 3: Kostenvergleich variierender Standardabweichungen (in 1000 GE)

Dabei werden drei verschiedene Standardabweichungen in Betracht gezogen. Davon stellt die erste Größe (30) den Ausgangspunkt der Untersuchung dar. Bei den folgenden Größen wird zusätzlich der Kostenbetrag angegeben, um den sich die Gesamtkosten bezüglich der Kosten des Ausgangspunktes erhöht haben. Zu den jeweils erzielten Ergebnissen wird der Wert der stochastischen Lösung (VSS) aus der Differenz der MVP-Lösung (EEV) und der SAA-Lösung angegeben. Die Gesamtkosten der SAA-Methode werden durch $M = 10$ unabhängig und zufällig generierte Samples mit einer Samplegröße von $N = 51$ bzw. $N' = 1200$ berechnet. Bei der Berechnung des EEV der MVP-Lösung werden 51 Szenarien verwendet. Aus der Tabelle wird ersichtlich, dass der Wert der stochastischen Lösung mit steigender Varianz bzw. Standardabweichung der Nachfrage zunimmt. Des Weiteren zeigt sich, dass die Gesamtkosten der MVP-Lösung bei höheren Nachfrageschwankungen deutlich stärker zunehmen als die Gesamtkosten der SAA-Lösung. Die Planung mit dem stochastischen Ansatz erweist sich in dieser Untersuchung somit als wesentlich robuster. In Tabelle 4 wird die von der Samplegröße N abhängige Genauigkeit der SAA-Lösung aufgezeigt. Dazu werden drei relativ kleine Samplegrößen betrachtet, zu denen jeweils eine Lösung des Testproblems mit der spezifizierten SAA-Methode für $M = 10$ und $N_0 = 1200$ berechnet wird. Für jede Samplegröße sind der erzielte Optimalitäts-Gap gap , die Gap-Abweichung σ_{gap} und die Gesamtkosten ZF-Wert in der Tabelle notiert. In der betrachteten Untersuchung zeigt sich, dass mit zunehmender Samplegröße relativ schnell ein kleiner Optimalitätsgap erreicht wird. Auch die zugehörige Abweichung σ_{gap} des Gaps wird bei einer Samplegröße von 51 deutlich reduziert.

Samplegröße N	gap	σ_{gap}	ZF-Wert
11	4,98	9,14	1.824,94
20	0,34	9,47	1.853,09
51	0,08	5,71	1.813,16

Tabelle 4: Schätzung vom Optimalitätsgap (in 1000 GE)

5. Zusammenfassung

In diesem Beitrag wurden Potentiale von Entscheidungsunterstützungssystemen bei der strategischen Kapazitäts- und Produktionsplanung unter Unsicherheiten für globale Produktionsnetzwerke in der Automobilindustrie eruiert. Dem Planer sollte ein Optimierungssystem zur Verfügung gestellt werden, das die hohe Komplexität bewältigt und in vertretbarer Zeit eine gesamtkostenminimale Produktallokation und Kapazitätsdimensionierung identifiziert sowie die Analyse und Bewertung differenzierter Flexibilitätsstrategien ermöglicht. Das Problem wurde durch ein gemischt-ganzzahliges zweistufig-stochastisches Optimierungsmodell abgebildet, durch die Sampling Average Approximation Strategie gelöst und in ein Entscheidungsunterstützungssystem eingebettet. Da insbesondere die Produktnachfrage der Automobilindustrie einer hohen Unsicherheit unterliegt, führt die Anwendung dieses Ansatzes zu deutlich robusteren Planungsergebnissen mit wesentlichen Kostensenkungspotentialen. Die Ergebnisse zeigen, dass eine im Sinne des Unternehmens optimale Flexibilitätsstrategie nicht ohne Berücksichtigung einer unsicheren Produktnachfrage identifiziert werden kann.

6. Literaturverzeichnis

- [1] ALONSO-AYUSO, A., ESCUDERO, L.F., GARIN, A., ORTUNO, M.T., PEREZ, G.: An approach for strategic supply chain planning under uncertainty based on stochastic 0-1 programming. *Journal of Global Optimization* 26, 2003, S. 97-124.
- [2] BEAMON, B.M.: Supply chain design and analysis: models and methods. *International Journal of Production Economics* 55 (3), 1998, S.281-294.
- [3] BIHLMAIER R., KOBERSTEIN A., OBST R.: Modeling and optimizing of strategic and tactical production planning in the automotive industry under uncertainty. To appear in *OR Spectrum*, 2008. DOI: 10.1007/s00291-008-0147-2
- [4] BIRGE, J.R., LOUVEAUX, F.: *Introduction to Stochastic Programming*. Springer New York, NY 1997.
- [5] BIXBY R.: Solving real-world linear programs: A decade and more of progress. *Operations Research* 50 (1), 2002, S. 3–15.
- [6] FRANCAS, D., KREMER, M., MINNER, S., FRIESE, M.: Strategic process flexibility under lifecycle demand. *International Journal of Production Economics*, doi:10.1016/j.ijpe.2006.12.062, 2007.
- [7] GAJEWSKI, H.: Integrierte Programmplanung im Produktionsnetzwerk der BMW Group unter Verwendung eines linearen Optimierungsmodells. *HMD Praxis der Wirtschaftsinformatik*, Heft 243, 2005, S. 68-77.
- [8] GOETSCHALCKX, M., VIDAL, C.J., DOGAN, K.: Modeling and design of global logistics systems: A review of integrated strategic and tactical models and design algorithms. *European Journal of Operations Research* 143, 2002, S.1-18.
- [9] GRAVES, S.C., JORDAN, W.: Principles on the benefits of manufacturing process flexibility. *Management Science* 41 (4), 1995, S.577-594.
- [10] GRAVES, S., TOMLIN, P.: Process flexibility in supply chains. *Management Science* 49 (7), 2003, S.907-919.
- [11] <http://www.ilog.com>, abgerufen am 29.07.2008.
- [12] KALL, P., WALLACE S.W.: *Stochastic Programming*. John Wiley and Sons, Chichester, England, 1994.
- [13] MOPS GmbH & Co. KG: MOPS White Paper. Contact: www.mops-optimization.com.
- [14] SANTOSO, T.: A Comprehensive Model and Efficient Solution Algorithm for the Design of Global Supply Chains under Uncertainty. Dissertation, Georgia Institute of Technology, 2003.
- [15] SHAPIRO, J.F.: *Modelling the Supply Chain*. Duxbury Press, Canada 2001.