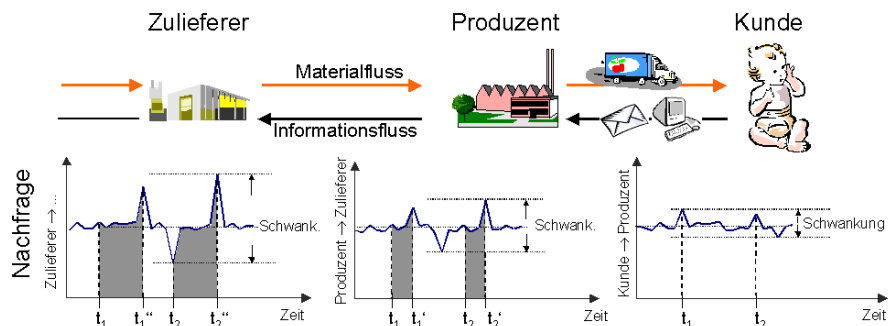


## Der Bullwhip-Effekt

Procter & Gamble hatte in den 90er Jahren ein nicht erklärbares Phänomen bei der Produktion und der Nachfrage von dem Rennerprodukt Pampers. Obwohl die Nachfrage des Marktes, ausgelöst durch die Babies, konstant war, bestellte der Großhändler, der von der P&G-Produktion beliefert wurde, sehr unterschiedliche Mengen. Das führte zu einer schwierigen Kapazitätsplanung, einer unzureichenden Prognosegüte und zum Aufbau von Beständen in der eigenen Produktionsstufe. Die Analyse zeigte weiterhin, dass die Bestellungen, die P&G seinen Zulieferern, hier 3M, übermittelte, noch stärker schwankten. Die Untersuchung ergab, dass die Bestellungen nach der ersten Stufe, d.h. dem Handel, nicht mehr mit dem ursprünglichen Bedarf der Babies korrelierten. Die Zusammenhänge sind schematisch in Abb. 8.1 dargestellt. Der Begriff des *Bullwhip-Effekt* war geboren.



**Abbildung 8.1.** Steigerung der Schwankungen im Bedarfsverlauf in Richtung upstream, am Beispiel Procter & Gamble. Die kleinen Ausschläge des Marktes kommen überhöht und zeitverzögert bei den Zulieferern an.

Auch bei Hewlett-Packard wurde ein ähnliches Verhalten bei der Produktion des Druckers LaserJetIII festgestellt. Hier wurde versucht, dem Effekt

mit überhöhten Kapazitäten, die zu Flautezeiten schlecht ausgelastet waren, hohen Beständen und zusätzlichen Touren etc. zu begegnen. In der gesamten Supply Chain wurde Bestand für 100 Tage vorgehalten. D.h. die Reaktionszeit auf Änderungen der Nachfrage bzw. bei Änderungen der Produkte betrug im schlimmsten Fall 100 Tage. In der High-Tech-Industrie mit einem Internet-Jahr von sechs Monaten und einer Verdopplung der Prozessorleistung alle 18 Monate hat ein Prozessor nach 100 Tagen evtl. nur noch die Hälfte seines Wertes. Auch sind die hohen Bestände zur Sicherung der Lieferfähigkeit nur begrenzt geeignet (siehe Kap. 9).

In den vergangenen Jahren, auch beflügelt durch die erwähnten praktischen Beispiele, hat sich vor allem Hau Lee von der Stanford University mit der Quantifizierung des Bullwhip-Effektes und mit der Strukturierung und Beschreibung von Gegenmaßnahmen beschäftigt. In einem Einführungsartikel (Lee, Padmanabhan und Whang 1997b) stellt er das Problem und Gegenmaßnahmen vor. Er verwendet in (Lee, Padmanabhan und Whang 1997a) mathematische Modelle für die optimale Kontrolle eines mehrstufigen Systems und quantifiziert hiermit die Zunahme der Varianz der Bestellmengen. Auch (Chen, Drezner, Ryan und Simchi-Levi 2000) entwickeln für eine lokale Prognose ein analytisches Modell zur Quantifizierung des Bullwhip-Effektes. Von (Arnold und Faißt 1999) wird der Bullwhip-Effekt in einer sequentiellen Lieferkette als Markov-Prozess modelliert und nachgewiesen.

Diese Modelle werden in Abschn. 8.2 neben anderen Erklärungsmodellen verwendet, um die Ursachen des Bullwhip-Effektes zu beschreiben. Anschließend werden in Abschn. 8.3 Maßnahmen zur Vermeidung bzw. Reduktion des Bullwhip-Effektes vorgeschlagen. Die genannten Arbeiten reduzieren die untersuchten Systeme auf lineare Strukturen und arbeiten mit stationären Bedarfsverläufen. In Abschn. 8.4 werden zwei unterschiedliche Typen des Bullwhip-Effektes, das kurz- und langfristige Überschwingen, eingeführt. Hier werden allgemeine Strukturen und nicht stationäre Bedarfsverläufe berücksichtigt. Eine Möglichkeit, den Bullwhip-Effekt zu reduzieren, liegt in der Verringerung der Variabilität der Bestellmengen der ersten Stufe. In Abschn. 8.5 wird ein Ansatz vorgestellt, der die Rückkopplungseffekte bei der Bestellung untersucht. Ein geglätteter Bestellverlauf führt zu reduzierten Kosten und besserer Planbarkeit in der gesamten Supply Chain. Das Beer Distribution Game zur Motivation der Abstimmung in komplexen Lieferketten wird in Abschn. 8.6 eingeführt. Eine praktische Anwendung zur Vermeidung des Bullwhip-Effektes wird in Abschn. 8.7 vorgestellt.

## 8.1 Historie des Bullwhip-Effektes

Bereits Jay Forrester hat am MIT in den 50er und 60er Jahren das Verhalten von dynamischen Systemen untersucht und eine Zunahme der Schwankungen von Bestellmengen entlang der Supply Chain nachgewiesen, siehe (Forrester 1958) und (Forrester 1961). In seinen Untersuchungen wendete er lineare und

nichtlineare Gleichungssysteme an, um das Verhalten von mehrstufigen Systemen zu modellieren. Der Effekt wird von ihm als *rationales Verhaltensmuster* beschrieben. Er schreibt bereits 1958 „For we can expect to gain, during the next 25 years, a far better understanding of the dynamic ever-changing forces which shape the destiny of a company. This understanding will lead to better usage of available information, to improved understanding of advertising effectiveness and the dynamic behavior of the consumer market ... (the managers) will be able to anticipate clearly:

- How small changes in retail sales can lead to large swings in factory production.
- How reducing clerical delays may fail to improve management decisions significantly.
- How a factory manager may find himself unable to fill orders although at all times able to produce more goods than are being sold to consumers.
- How an advertising policy can have a magnifying effect on production variations.“

Eine weitere Untersuchung geht auf Sterman zurück, der die Effekte von Forrester in ein Management-Spiel, das *Beer Distribution Game* überträgt (siehe (Sterman 1989) und Abschn. 8.6). Vier Spieler übernehmen in einem vierstufigen System, bestehend aus Händler, Großhändler, Produzent und Zulieferer, für jede Stufe die Rolle des Disponenten. Es stehen lediglich lokale Informationen, d.h. die Nachfrage der nächsten Stufe, für die Planung der Bestellmengen zur Verfügung. Das Ziel ist es, kostenminimal zu operieren. Auch hier zeigt sich eine Zunahme der Schwankung der Bestellmengen, was von Sterman durch die individuelle (bzw. nicht vorhandene) Ausbildung der Spieler erklärt wird.

## 8.2 Gründe für die Entstehung des Bullwhip-Effektes

Die beiden Praxisbeispiele bei P&G und Hewlett-Packard haben die Probleme und Effekte, die durch die Steigerung der Variabilität entstehen, aufgezeigt:

- Verzögerte Reaktion auf Änderungen der Kundenbedarfe, geringe Flexibilität sowie schlechte Reaktionsfähigkeit der Supply Chain.
- Überbestände sowie Überkapazitäten auf den Stufen der Supply Chain, um die Planungsunsicherheit abzufangen.
- Schlecht ausgelastete, bzw. überlastete Kapazitäten aufgrund der stark schwankenden Nachfrage.

Die Probleme führen zu hohen Kosten und vor allem zu einem schlechtem Servicegrad, was vermeidbar ist. Die Gründe, die zu dem Bullwhip-Effekt führen, lassen sich zusammenfassen als

- Verarbeitung der Nachfrageinformation lokal auf jeder Stufe. Das umfaßt sowohl die Bestimmung der Bestellmenge als auch die Prognose der zu erwartenden Nachfrage.
- Nicht synchronisierte Ermittlung der Bedarfe und Auslieferung an Kunden bzw. Belieferung von Zulieferern, wird u.a. hervorgerufen durch veraltete Planungssysteme bzw. -verfahren. Keine Transparenz und Visibilität der Supply Chain.
- Materialplanung und damit auch Bestellung zu bestimmten Zeitpunkten, z.B. am ersten Montag eines Monats.
- Batchbildung, d.h. das Zusammenfassen von Bestellungen bzw. die losweise Produktion.
- Preisschwankungen in Form von Promotions oder Mengenrabatten.
- Kontingentierung und Engpasspoker bei begrenzten Kapazitäten der Produktionsressourcen oder Materialverfügbarkeit eines Zulieferers.

### 8.2.1 Lokale Verarbeitung der Nachfrageinformationen

Jede unabhängige Stufe der Supply Chain erstellt eine Prognose des zu erwartenden Bedarfes, um die Belegung der Produktionsressourcen mittelfristig zu planen und Vorprodukte zu bestellen. Als Grundlage dienen die historischen Bestellungen der nächsten (in Richtung des Endkunden, also downstream) Stufe, die beispielsweise als Zeitreihe vorliegen. Diese Daten sind bereits vom Planungssystem der nächsten Stufe bearbeitet worden und korrelieren evtl. nicht mehr mit den Bedarfen der Endkunden. Werden einfache Prognosemodelle verwendet (siehe Kap. 4), führen Trends und Saisoneinflüsse des Marktes zu einer verspäteten Reaktion bzw. zum Unter/Überschätzen der Trends. Bei der Berechnung der zu produzierenden, bzw. zu bestellenden Menge wird der verfügbare Bestand und die Prognose verwendet, es kommt zu einer Überreaktion auf einen Ausschlag der Nachfrage. Die nachfolgende Stufe hat nun das gleiche Problem, somit schaukeln sich Änderungen auf (siehe auch Abschn. 2.1).

**Beispiel 15:** In einer Supply Chain bestehend aus dem Kunden, Händler, Großhändler und dem Produzenten geht der Kundenbedarf, der vorher stabil war, auf 90 Prozent des ursprünglichen Wertes zurück. Der Händler deckt die Nachfrage aus dem vorhandenen Bestand, wird jedoch bei dem Großhändler weniger bestellen, um den Ziel-Sicherheitsbestand auf den neuen geringeren Bedarf anzupassen. Er bestellt also nur 80 Prozent des Kundenbedarfes. Der Großhändler auf der nächsten Stufe wird nun mit dem auf 80 Prozent reduzierten Bedarf konfrontiert. Auch hier wird wiederum eine lokale Prognose erstellt, der Bedarf aus dem Bestand gedeckt, und weniger bestellt, um den Sicherheitsbestandes zu reduzieren. Er bestellt nur noch 60 Prozent des ursprünglichen Bedarfes. Der Produzent denkt schließlich ähnlich und reduziert seine Bestellung auf 30 Prozent. Da nun zuwenig nachgeliefert wird, kehrt sich der Effekt um und die Bestellmengen schlagen in die andere Richtung aus.

Bildlich kann man sich diese Situation, bei der jede Stufe nur die Informationen der nächsten Stufe zur Verfügung hat, als eine Ampel vorstellen, die nur von dem Auto in der ersten Reihe beachtet wird. Alle weiteren Autos in der Schlange achten nur auf ihren Vordermann. Die Ampel symbolisiert den Markt, das erste Auto in der Warteschlange stellt den Händler dar, die wartende Fahrzeugschlange die Supply Chain (Abb. 8.2). Springt die Ampel nun auf grün, fährt das erste Auto los, der nächste gibt nach einer gewissen Reaktionszeit Gas, der Abstand zum Vordermann wird größer. Das setzt sich bis zum letzten Glied fort. Reduziert das vorderste Auto nun wiederum seine Geschwindigkeit, setzt sich das auch durch die Kette fort, bis es sogar zum Stillstand der weiter entfernten Fahrzeuge kommen kann. Dieses Phänomen ist alltäglich auf den Autobahnen zu sehen.



**Abbildung 8.2.** Verzögerte Reaktion der Autoschlange vor der Ampel, wenn nur lokale Information (das nächste Auto) zur Verfügung stehen. Beim Umschalten der Ampel fahren die Autos verzögert los.

Von (Lee, Padmanabhan und Whang 1997b) wird untersucht, wie sich die Varianz der Kunden-Nachfrage zu der eigenen Bestellung bei den Zulieferern verhält. Hierfür untersuchen sie eine Periode, formulieren ein Entscheidungsproblem und bestimmen die Varianzen der Bestellung in Abhängigkeit von der Nachfrage. Dem Modell liegt eine seriell korrelierte Nachfrage auf der Kundenseite zugrunde, für die gilt

$$d_t = \bar{d} + \rho d_{t-1} + e_t \quad (8.1)$$

Hierbei bezeichnet  $\bar{d}$  den Mittelwert der Nachfrage,  $d_t$  die Nachfrage in Periode  $t$ ,  $\rho$  den Korrelationskoeffizienten, für den gilt  $-1 \leq \rho \leq 1$  und  $e$  einen normalverteilten  $N(0, \sigma)$  Störfaktor. Für  $\rho > 0$  gilt nun für die Vari-

anz der Bestellmenge  $Var(x)$  mit der Reaktionszeit  $lt$  und der Varianz der Kundenbestellungen  $Var(d)$

$$Var(x) = Var(d) + \frac{2\rho(1 - \rho^{lt+1})(1 - \rho^{lt+2})}{(1 + \rho)(1 - \rho)^2} \sigma^2 > Var(d) \quad (8.2)$$

Die Varianz steigt bei  $0 < \rho < 1$  ebenso wie bei  $lt \geq 0$ . Auch bei einer Reaktionszeit von  $lt = 0$  nimmt die Varianz zu, es gilt  $Var(x) = Var(d) + 2\rho\sigma^2$ . Ist die Nachfrageverteilung jedoch nicht seriell korreliert, gilt also  $\rho = 0$ , bleibt die Varianz gleich,  $Var(x) = Var(d)$ . Für eine Herleitung sei auf (Lee, Padmanabhan und Whang 1997a) verwiesen.

Von (Chen, Drezner, Ryan und Simchi-Levi 2000) wird das Modell der seriell korrelierten Nachfrage nach Gl. (8.1) verwendet, um die Auswirkungen von lokal angewendeten Prognosen zu quantifizieren. Zur Erstellung der Prognose stehen hier lediglich die historischen Bestellungen der nächsten Stufe zur Verfügung. Bei dem Modell wird das Verfahren des gleitenden Durchschnittes der letzten  $N$  Perioden angewendet. Eine (s,s)-Politik wird rollierend verwendet, d.h.  $s_t$  wird in jeder Periode  $t$  mit  $f_t^N$  als dem gleitenden Mittelwert der vergangenen  $N$  Perioden,  $\epsilon$  der Verteilung des Prognosefehlers und  $\sigma_{\epsilon,t}^N$  der Standardabweichung des Prognosefehlers der letzten  $N$  Perioden bestimmt zu

$$s_t = lt \cdot f_t^N + z \cdot \sigma_{\epsilon,t}^N \cdot \sqrt{lt} \quad (8.3)$$

Nach einigem Umstellen der Gleichungen (für Details sei auf den erwähnten Artikel verwiesen) ergibt sich für die Varianz der Bestellmenge

$$Var(x) = \left[ 1 + \left( \frac{2 \cdot lt}{N} + \frac{2 \cdot lt^2}{N^2} \right) (1 - \rho^N) \right] Var(d) + 2z \left( 1 + 2 \frac{lt}{N} \right) Cov(d_{t-1}, \sigma_{\epsilon,t}^N) + z^2 \cdot Var(\sigma_{\epsilon,t}^N - \sigma_{\epsilon,t-1}^N) \quad (8.4)$$

Aus diesem Ausdruck läßt sich für  $z = 0$  eine untere Schranke ableiten, es ergibt sich

$$\frac{Var(x)}{Var(d)} \geq 1 + \left( \frac{2 \cdot lt}{N} + \frac{2 \cdot lt^2}{N^2} \right) (1 - \rho^N) \quad (8.5)$$

Die Erweiterung des Modells auf die Verwendung von zentraler Information (hier wird einer Lösung des Problems vorgegriffen) ergibt ebenfalls ein Ansteigen der Varianzen

$$\frac{Var(x)}{Var(d)} \geq 1 + \left( \frac{2(\sum_{i=1}^{k-1} lt_i)}{N} + \frac{2(\sum_{i=1}^{k-1} lt_i)^2}{N^2} \right) (1 - \rho^N) \quad (8.6)$$

Hierbei stellt  $lt_i$  die Reaktionszeit zwischen den Stufen  $i$  und  $i + 1$  dar.

**Beispiel 16:** Ein Unternehmen wendet eine rollierende (s,s)-Politik an, die Prognose wird als gleitender Durchschnitt der letzten vier Perioden bestimmt. Der Prognosewert (Ein-Schritt Prognose)  $f_{i,t}$  einer Stufe  $i$  für Periode  $t$  ergibt mit dem Bedarf  $d_{i,t}$  einer Stufe  $i$  zum Zeitpunkt  $t$  zu

$$f_{i,t} = \frac{1}{4} \cdot (d_{i,t-1} + d_{i,t-2} + d_{i,t-3} + d_{i,t-4}) \quad (8.7)$$

Der Auslösebestand (s) bestimmt sich nach Gl. (8.3). Das Niveau des Bedarfes der Kunden fällt auf 80%, also gilt  $d_{1,t-1} = d_{1,t-2} \cdot 0,8$ , damit ergibt sich für die Prognose  $f_{1,t} = f_{1,t-1} \cdot 0,95$ . Bisher wurde im Mittel  $\bar{d}_1$  bestellt, der Lagerbestand war null. Da die Niveauänderung nicht prognostiziert wird, besteht zum Zeitpunkt  $t-1$  ein Restlagerbestand von  $I_{1,t-1} = \bar{d}_1 \cdot 0,2$ . Somit ergibt sich für die Bestellung  $x_{1,t}$

$$x_{1,t} = f_{1,t} - I_{1,t-1} = \bar{d}_1 \cdot 0,95 - \bar{d}_1 \cdot 0,2 = \bar{d}_1 \cdot 0,75$$

Dieser Wert dient der zweiten Stufe als (lokale) Eingabe, hier wird nach dem gleichen Verfahren prognostiziert, es ergibt sich also

$$\begin{aligned} f_{2,t+1} &= f_{2,t} \cdot 0,9375 \\ I_{2,t} &= \bar{d}_2 \cdot 0,25 \\ \rightarrow x_{2,t+1} &= f_{2,t+1} - I_{2,t} = \bar{d}_2 \cdot 0,9375 - \bar{d}_2 \cdot 0,25 = \bar{d}_2 \cdot 0,6875 \end{aligned}$$

Allgemein gilt:

$$x_{i,t} = \bar{d}_{i-1} \cdot \Delta_i \text{ mit } \Delta_i = \Delta_{i-1} - \frac{1 - \Delta_{i-1}}{N} \quad (8.8)$$

Mit  $\Delta_0$  wird das neue Niveau der Kundennachfrage, bezogen auf den Mittelwert der Vergangenheit, beschrieben. Die Überreaktion der Bestellmengen auf eine Änderung des Bestellniveaus stellt sich ein. Ein größeres  $N$  reduziert die Überreaktion, was direkt aus  $\lim_{N \rightarrow \infty} \Delta_{i-1} = \Delta_i$  folgt. Das allerdings geht zu Lasten der Prognose, die immer mehr den Erwartungswert der Zeitreihe approximiert.

**Beispiel 17:** Bei Verwendung von exponentieller Glättung als Prognose gilt  $f_{i,t} = \alpha \cdot d_{i,t-1} + (1 - \alpha) \cdot f_{i,t-1}$ . Gilt nun  $d_{i,t-1} = 0,8 \cdot d_{i,t-2}$ , so gilt für  $f_{i,t}$

$$f_{i,t} = \alpha \cdot d_{i,t-1} + (1 - \alpha) \cdot (\alpha \cdot d_{i,t-2} + (1 - \alpha) \cdot f_{i,t-2})$$

Der Term  $f_{i,t-2}$  ändert sich durch die Niveauänderung nicht, es ergibt sich  $f_{i,t} = (1 - (1 - \Delta) \cdot \alpha) \cdot f_{i,t-1}$ . Der Lagerbestand am Ende von Periode  $t-1$  beträgt aufgrund des Absinkens des Bestellniveaus  $I_{i,t-1} = 0,2 \cdot \bar{d}_i$ , die Bestellung in Periode  $t$  ergibt sich zu

$$\begin{aligned} x_{i,t} &= f_{i,t} - I_{i,t-1} = \bar{d}_i \cdot (1 - (1 - \Delta) \cdot \alpha) - \bar{d}_i \cdot (1 - \Delta) \\ &= \bar{d}_i \cdot (1 - \alpha + \alpha\Delta - 1 + \alpha) = \bar{d}_i \cdot (\Delta + \alpha\Delta - \alpha) \end{aligned} \quad (8.9)$$

Somit läßt sich für  $\Delta_i$  ableiten

$$\Delta_i = \Delta_{i-1} + \alpha\Delta_{i-1} - \alpha \quad (8.10)$$

### 8.2.2 Auftragsbündelung - Zusammenfassen von Bestellungen/Losbildung

Eine Bestellung muss bearbeitet werden, Papiere werden erstellt, etc. All das kostet Geld, was sich in den bestellfixen Kosten widerspiegelt. Diese Kosten haben in der Vergangenheit dazu geführt, dass bei einer Bestellung die Bedarfe von mehreren Perioden zusammengefasst wurden. ERP-Systeme führen in periodischen Abständen (einmal pro Woche/Monat) einen MRP-Lauf durch und bestellen anschließend das Material, das für die Produktion der nächsten Perioden (Woche/Monat) benötigt wird. Die gleiche Logik wird bei den Planungssystemen der Kunden angewendet, so kann es passieren, dass der überwiegende Teil der Bestellungen am letzten Montag im Monat ankommen, was zu einer zusätzlichen Verzerrung und Überhöhung der Nachfrage führt.

Nicht zu unterschätzen sind menschliche Widerstände in den Unternehmen, die verhindern, dass die Bedarfsinformation des Kunden an die Zulieferer weitergereicht werden. Interessanterweise wird die Marktinformation durch das Zusammenfassen von mehreren Perioden verdeckt, das eigene lokale Denken ist gewahrt. So fängt die Automobilindustrie, die in vielen Bereichen eine Vorreiterrolle einnimmt, erst jetzt an, in diesen Bereich der durchgängigen Informationsbereitstellung und Transparenz zu investieren (siehe beispielsweise (Alicke und Becker 2004)).

Werden mengenorientierte Kennzahlen verwendet, um Abteilungen wie Einkauf oder Vertrieb zu bewerten, werden am Ende einer Periode (Monat, Quartal oder Fiskaljahr) Bestellungen auch ohne Kundennachfrage platziert, bzw. Kundenaufträge, die planmäßig zu einem späteren Zeitpunkt ausgeliefert werden sollen, vorgezogen, um sich besser zu stellen und einen höheren Bonus einzustreichen.


#### Zusammenfassen von Bestellungen

In Abb. 8.3 (links) ist ein täglicher Bedarf und die Bestellungen aufgezeigt, die durch Zusammenfassen der Bedarfe von zwei Tagen, einer und zwei Wochen entstehen. Die Bestellintervalle werden größer, bei gleichzeitigem Anstieg der Bestellmengen. Die Analyse der Zeitreihen führt zu dem in Abschn. 3.5 vorgestellten Problemen. Werden die Nullbedarfe mit berücksichtigt, steigt die Variabilität an, wie Abb. 8.3 (rechts) zeigt. Die Normalverteilungsannahme ist nicht mehr gegeben, die Aussagen über Sicherheitsbestände gelten damit nicht mehr. Der Zulieferer kann weiterhin keine Aussage über den wahren Verlauf der Kundennachfrage treffen.

#### Anwendung des EOQ-Modells auf allen Stufen

Der gleiche Effekt tritt auf, wenn auf allen Stufen der Supply Chain das EOQ-Modell zur Bestimmung der Bestellmenge verwendet wird. Die (variablen)





**Abbildung 8.3.** Bestellverlauf (links) bei täglichem Bestellen und bei Zusammenfassen der Nachfrage von zwei Tagen, einer und zwei Wochen. Rechts ist die Entwicklung der Standardabweichung und Variationskoeffizienten gezeigt, wenn die Nullbedarfe (fälschlicherweise) berücksichtigt werden.

Lagerhaltungskosten  $h$  steigen mit der zunehmenden Wertschöpfung in Richtung zum Endkunden an, so dass für eine Supply Chain mit  $n$  Stufen, dem Endkunden auf Stufe 0 mit  $h_i$  als den Lagerhaltungskosten auf Stufe  $i$  gilt  $h_i < h_{i-1}$ . Bestellt nun jede Stufe nach der in Abschn. 5.2 hergeleiteten Formel  $Q = \sqrt{\frac{2dK}{h}}$ , so gilt

$$Q_i > Q_{i-1}, \text{ mit } h_i < h_{i-1}, K_i = K_{i-1}, d_i = d_{i-1} \quad (8.11)$$

Verdeutlicht man sich die Bestellzyklen, d.h. den Abstand zwischen zwei Bestellungen

$$T = \frac{Q}{d} = \sqrt{\frac{2K}{dh}} \Rightarrow T_i > T_{i-1} \quad (8.12)$$

so wird auch hier deutlich, dass mit zunehmender Entfernung vom Markt die Reaktionsfähigkeit und Flexibilität sinkt, da der Bestellzyklus auf  $T_i > T_{i-1}$  steigt und damit die Bestellfrequenz abnimmt.

Wird die (s,S) Lagerhaltungsstrategie in Kombination mit dem EOQ-Modell verwendet, ergibt sich Gl. (5.14):

$$S = \text{MAX}[EOQ, \bar{d} \cdot lt + z \cdot \sigma_d \cdot \sqrt{lt}]$$

Hier verstärkt sich der angesprochene Effekt noch zusätzlich, denn der Sicherheitsbestand hängt von der Standardabweichung der Nachfrage der Stufen ab, die wiederum durch größere Bestellmengen und Bestellzyklen steigt. Es gilt  $\sigma_{d_i} > \sigma_{d_{i-1}}$ , damit steigt bei gleicher Reaktionszeit  $lt$  und gleichem Servicefaktor  $z$  auch der Sicherheitsbestand  $SS_i$  der Stufen

$$z \cdot \sigma_{d_i} \cdot \sqrt{lt} = SS_i > SS_{i-1} = z \cdot \sigma_{d_{i-1}} \cdot \sqrt{lt} \quad (8.13)$$

### Periodisches Bestellen der Kunden

Das geplante oder ungeplante Zusammenfallen von Kundenbestellungen speziell am Ende von Planungsperioden (Monat, Quartal) wird von (Lee, Padmanabhan und Whang 1997a) in einem Modell untersucht, das aus einem Produzenten und  $N$  Händlern besteht. Jeder Händler bestellt mit dem Mittelwert  $\bar{d}$  und der Standardabweichung  $\sigma$  und arbeitet nach einer periodischen Bestellpolitik  $(t,S)$  mit dem Bestellzyklus  $t$ . Lee unterteilt die Nachfrage der Händler weiter nach der zeitlichen Korrelation in

- *zufälliges* Bestellen (0): Die Nachfragen der Händler sind unabhängig, d.h. für den Korrelationskoeffizienten der Nachfrageverteilungen der Händler gilt  $\rho = 0$ .
- *positiv* korreliertes Bestellen (+): Die Zeitpunkte der Nachfragen sind positiv korreliert, d.h. alle Händler bestellen beispielsweise Montags, der Korrelationskoeffizient ist  $\rho = 1$ .
- *ausgeglichenes* Bestellen (-): Hier werden die Bestellungen gleichmäßig auf die vorhandenen Perioden verteilt. Bei einem wöchentlichen Bestellzyklus würden bei acht Händlern jeweils zwei am Montag, Dienstag und Mittwoch bestellen, der Donnerstag und Freitag wäre von einem Händler belegt, es gilt  $\rho = -1$ .

Der Erwartungswert der Bestellmengen ist für alle Fälle gleich, die Varianz steigt vom ausgeglichenen (-) über zufälliges (0) zu positiv korreliertem (+) Bestellen an.

Leider sind Bestellungen in praktischen Systemen häufig positiv korreliert. Ein weiteres Problem sind nicht synchronisierte Kundenbestellungen und Anlieferungen der eigenen Zulieferer. Auch diese Effekte führen wiederum dazu, dass der Bedarf des Kunden nicht mehr mit der eigenen Bestellung korreliert. In der Regel ist nach der zweiten Stufe das Marktverhalten nicht mehr zu erkennen. Die Planbarkeit und Reaktionsfähigkeit der Kette ist sehr stark eingeschränkt.

### 8.2.3 Preisschwankungen, Mengendegressionseffekte

Preispolitische Maßnahmen zur Verkaufssteigerung (Promotions) sind ein Instrument des Marketing, um Kunden anzulocken und den Verkauf der Produkte anzukurbeln. Die Kunden decken sich ein, es wird auf Vorrat gekauft, daher bricht der Verkauf nach der Aktion stark ein, im ungünstigsten Fall bis zur nächsten Promotion. Die Nachfrage korreliert nicht mehr mit dem Bedarf. Im ungünstigsten Fall werden die (regelmäßig durchgeführten) Promotions von dem Prognoseverfahren als Saisoneffekt interpretiert. Bei einigen Produkten sind solche Maßnahmen sogar zum (fragwürdigen) Standard geworden.

Gleiches ist bei einer Überhöhung der Nachfrage aufgrund von Mengendegressionseffekten zu beobachten, beispielsweise durch eine Preispolitik, die

an eine Mengenstaffelung geknüpft ist. Die Kunden kaufen mehr als sie brauchen, um in die nächstgünstigere Mengenstaffel zu kommen, der Bedarf bricht in den folgenden Perioden ein.

#### 8.2.4 Mengenkontingentierung und Engpasspoker

In der High-Tech Industrie tritt häufig der Fall auf, dass ein Lieferant einen Engpass hat und die Lieferungen an seine Kunden dynamisch kontingentiert, d.h. als Anteil der bestellten Menge (siehe Abschn. 7.11). Kann der Zulieferer nur  $X = 600$  [Stk] herstellen, hat aber Bestellungen in Höhe von  $D = \sum_i d_i = 1000$ , so wird jeder Kunde nur 60% seiner Bestellmenge erhalten. Hat ein Kunde  $d_1 = 400$  bestellt, wird nur  $x_1 = 240$  geliefert. Antizipiert nun der Kunde diese Kontingentierung, wird er seine Bestellung überhöhen, um die benötigte Menge zu bekommen. Er bestellt beispielsweise  $d_1 = 800$  und erhält nach Anwendung der Kontingentierungsregel  $x_i = X \cdot \frac{d_i}{D}$  nur  $x_1 = 600 \cdot 800/1400 = 342$  [Stk]. Belassen alle anderen Kunden ihre Bestellung, müsste der Kunde

$$d_1 = 400 \cdot \frac{\sum_{i=1}^n d_i}{X} = \frac{400}{X} \cdot d_1 + \frac{400 \cdot \sum_{i=2}^n d_i}{X} = \frac{400 \cdot \sum_{i=2}^n d_i}{X - 400} = 1200 \text{ [Stk]}$$

bestellen, damit sein kompletter Auftrag erfüllt wird. D.h. die ursprüngliche Bestellung würde um 300% überhöht. Nachdem die Lieferung erfolgt ist, wird der verbleibende Auftrag, der nur zum „Überlisten“ der Kontingentierungsregel platziert wurde, wieder storniert. Der Hersteller hat den Eindruck, dass der Gesamtbedarf nicht  $D = 1000$  [Stk], sondern  $D = 1800$  [Stk] beträgt und entscheidet sich zu einer Verdopplung der Kapazitäten, um zumindest einen Teil der gestiegenen Nachfrage zu befriedigen. Er ist nun in der Lage 1200 [Stk] zu produzieren. Nach der Stornierung liegen nun 200 nicht verkaufte Produkte auf dem Lager, die Produktion wird wieder gedrosselt, die Kapazitäten schließlich wieder (evtl. wieder mit einer Überreaktion) abgebaut. Durch die Überhöhung der Bestellung kommt es nicht nur aufgrund der anschließenden Stornierung zu einer Zunahme der Schwankung, auch die zusätzlich bereitgestellte Kapazität führt zu einer Unruhe in der Supply Chain.

Dieser Effekt ist bei Produkten mit einer sehr kurzen Lebensdauer wie Chips, Computern etc. zu beobachten und führt dazu, dass eine mittelfristige Kapazitätsplanung nahezu unmöglich wird.