

OPERATIONS MANAGEMENT



- Kurzfristige Kapazitätsplanung -



Helmut M. Dietl

1

Lernziele

Nach dieser Veranstaltung sollten Sie wissen,

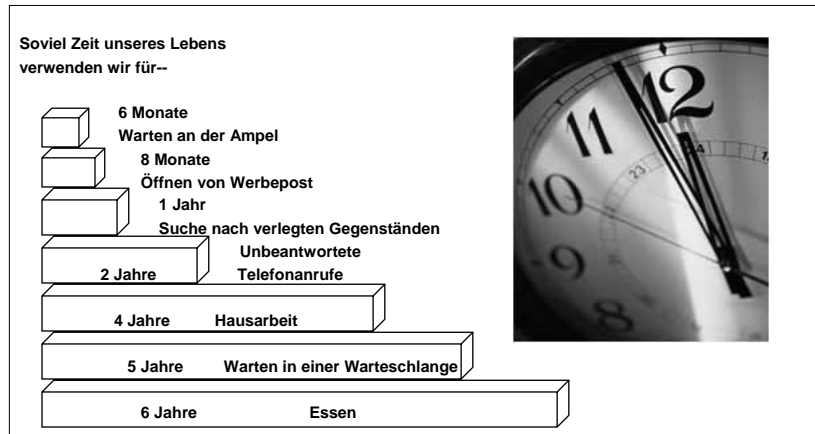
- welcher Trade-off zwischen Warte- und Servicekosten besteht
- wovon das subjektive Wartezeitempfinden abhängt und wie es sich beeinflussen lässt
- aus welchen Grundelementen ein Warteschlangensystem besteht
- inwieweit poissonverteilte Ankunftsdaten dem exponentiellverteilten Zeitabstand zwischen 2 Ankünften entsprechen
- wie man die wichtigsten Warteschlangenmodelle anwendet
- wie die wichtigsten Performancekriterien von Warteschlangensystemen berechnet werden können
- inwiefern Kapazitätsentscheidungen auf der Basis von Warteschlangenmodellen getroffen werden können



Helmut M. Dietl

2

Wie zerrinnt unsere Zeit?



Quelle: U.S. News & World Report, 30.1.1989, S. 81



Helmut M. Dietl

3

Wartephänomene

- **Unausweichlichkeit:** Wartezeit ist das unausweichliche Ergebnis unterschiedlicher Veränderungen bei der Ankunftsrate und der Servicerate
- **Warteökonomik:** Hohe Serverauslastung kann nur durch Wartezeiten der Kunden erkauft werden => Trade off zwischen Auslastung und Wartezeit
 - Auswege:
 - Produktive Wartezeit (Salatbuffet)
 - Profitable Wartezeit (Empfangsbar)



Helmut M. Dietl

4

2 Komponenten des Warteschlangenmanagements


- Tatsächliche Wartezeit
 - Objektiv
 - Messbar
 - Warteschlangenmodelle
- Empfundene Wartezeit
 - Subjektiv
 - Nicht messbar
 - Psychologische Studien
- Beispiel:
 - Verringerung der tatsächlichen Wartezeit durch zusätzlichen Hotelaufzug
- Beispiel:
 - Verringerung der empfundenen Wartezeit durch Spiegel vor den Hotelaufzügen



Helmut M. Dietl

5

Trade-off im Warteschlangenmanagement




Helmut M. Dietl

6

Trade-off-Optimierung

Grenznachteil
Grenzvorteil




Helmut M. Dietl

7

Trade-off und Opportunitätskosten

Grenznachteil
Grenzvorteil



Helmut M. Dietl

8

Warteschlangenpsychologie

<i>Subjektives Zeitempfinden länger</i>	<i>Subjektives Zeitempfinden kürzer</i>
Warten ohne Ablenkung/Beschäftigung	Warten mit Ablenkung/Beschäftigung
Unerwartete Wartezeit	Geplante Wartezeit
Allein warten	In der Gruppe warten
Wartezeit außerhalb des Serviceprozesses	Wartezeit innerhalb des Serviceprozesses
Besorgtes Warten	Entspanntes Warten



Helmut M. Dietl

9

Verringerung der empfundenen Wartezeit


- Gerechte vs. ungerechte Wartezeiten
 - Nummern- und Einschlangensystem (aber: Supermarkt), keine Telefonanrufe!
- Bequeme vs. unbequeme Wartezeiten
 - Empfangsbar in Restaurants, Bestuhlung, Unterhaltung
- Erklärte vs. unerklärte (besorgniserregende) Wartezeit
 - Abflugverzögerung wegen Enteisierung der Tragflächen
- Beschäftigtes vs. beschäftigungsloses Warten
 - Wartelounge mit Fax- und Internetanschluss
- Wartezeiten außerhalb vs. innerhalb des Systems
 - Vorprogramm im Kino



Helmut M. Dietl

10

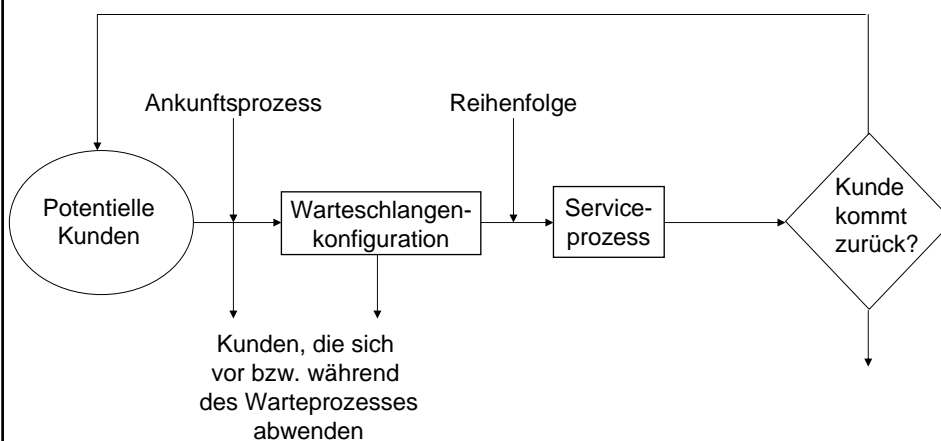
Warteschlangensysteme



Helmut M. Dietl

11

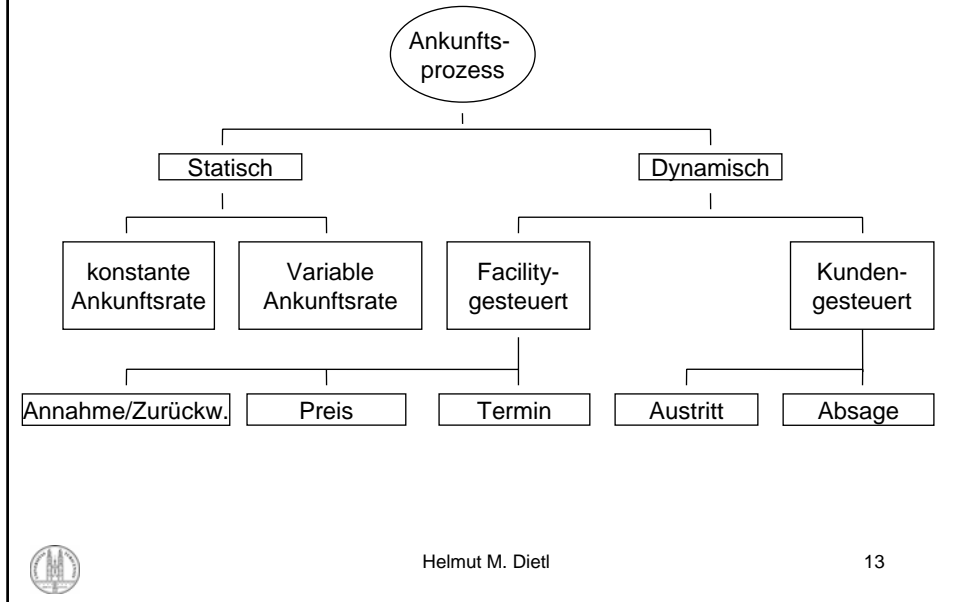
Grundelemente von Warteschlangensystemen



Helmut M. Dietl

12

Ankunftsprozess



Exponentialverteilung (stetig)

Dichtefunktion: $f(t) = \lambda e^{-\lambda t}$ $t \geq 0$

λ = durchschnittliche Ankunftsrate pro Zeiteinheit (z.B. Minuten, Stunden, Tage)
 t = Zeitabstand zwischen 2 Ankünften
 $e = 2.718\dots$

Verteilungsfunktion: $F(t) = 1 - e^{-\lambda t}$ $t \geq 0$

Mittelwert:

Varianz:

Poissonverteilung (diskret)

Dichtefunktion: $f(n) = \frac{(\lambda t)^n e^{-\lambda t}}{n!}$ $n = 0, 1, 2, 3, \dots$

λ = durchschnittliche Ankunftsrate pro Zeiteinheit (z.B. Minuten, Stunden, Tage)
 t = Anzahl der Zeitperioden (i.d.R. 1)
 n = Anzahl der Ankünfte (0, 1, 2, ...)
 $e = 2.718\dots$

Mittelwert:

Varianz:




Helmut M. Dietl

15

Äquivalenz zwischen Poisson- und Exponentialverteilung

Poissonverteilung für die Anzahl der Ankünfte pro Stunde (oben)



Exponentialverteilung der Zeitabstände zwischen 2 Ankünften in Minuten (unten)




Helmut M. Dietl


16

Warteschlangenkonfiguration


Mehrere Warteschlangen



Eine Warteschlange




Nummernsystem



Helmut M. Dietl

17

Reihenfolge



Helmut M. Dietl


18

Serveranordnung

<i>Servicefacility</i>	<i>Serveranordnung</i>
Parkplatz	Selbstbedienung
Cafeteria	Server hintereinander
Mautstelle	Server parallel
Supermarkt	Selbstbedienung (1. Stufe); Parallel-Server (2.Stufe)
Krankenhaus	Viele Servicecenter (parallel und hintereinander)



Warteschlangenmodelle im Überblick



A/B/C Notation: A beschreibt die Verteilung der Zeitabstände zwischen 2 Ankünften, **B** beschreibt die Verteilung der Servicezeit und **s** (oder **c**) die Anzahl der Server. **M** beschreibt die Exponentialverteilung, **G** irgendeine allgemeine Verteilung (z.B. Normalverteilung, Gleichverteilung, etc.)



Standard M/M/1-Modell

- Voraussetzungen:
 - Unbegrenzte oder sehr große Menge potentieller Kunden
 - Zeitabstände zwischen 2 Ankünften sind negativ exponentialverteilt bzw. Ankunftsrate ist poissonverteilt
 - Eine unbegrenzte Warteschlange ohne Abwanderung von Kunden
 - FCFS
 - Ein Server mit negativ exponentiell verteilter Servicezeit bzw. poissonverteilter Servicerate
 - $\lambda < \mu$



M/M/1

Poissonverteilte Ankunfts- und Servicerate ($\lambda < \mu$)

Durchschnittliche Ankunftsrate: λ

Durchschnittliche Servicerate: μ

Durchschnittlicher Auslastungsgrad:

Wahrscheinlichkeit, dass sich genau n Kunden im System befinden:

Wahrscheinlichkeit, dass sich k oder mehr Kunden im System befinden:



M/M/1

Durchschnittliche Anzahl von Kunden im System: $L_s = \frac{\lambda}{\mu - \lambda}$


Durchschnittliche Länge der Warteschlange: $L_q = \frac{\rho\lambda}{\mu - \lambda}$

Durchschnittliche Verweildauer im System: $W_s = \frac{1}{\mu - \lambda}$

Durchschnittliche Verweildauer in der Warteschlange: $W_q = \frac{\rho}{\mu - \lambda}$



Wie ändert sich die Länge der Warteschlange,
wenn $\rho \rightarrow 0$?



$$\rho = \frac{\lambda}{\mu}$$

$$L_s = \frac{\rho}{1 - \rho}$$

ρ	L_s
0	0
0.2	0.25
0.5	1
0.8	4
0.9	9
0.99	99



Beispiel 1: Eisverkäufer

- Pro Stunde kommen durchschnittlich 80 Kunden.
- Der Verkäufer benötigt je Kunde durchschnittlich 30 Sekunden.
- Ankunftsrate der Kunden ist poissonverteilt.
- Servicerate ist poissonverteilt.



Fragen zum Eisverkäufer-Beispiel

1. Wie hoch ist der durchschnittliche Auslastungsgrad des Eisverkäufers?
2. Wie lang ist die durchschnittliche Warteschlange vor dem Eisverkäufer?
3. Wie viele Kunden befinden sich durchschnittlich im „System“ (Warteschlange + Bedienung)?
4. Wie lange verweilt ein Kunde durchschnittlich in der Warteschlange (durchschnittliche Wartezeit)?
5. Wie lange verweilt ein Kunde durchschnittlich im „System“ (durchschnittliche Verweilzeit)?



Eisverkäufer-Beispiel

1. Durchschnittlicher Auslastungsgrad des Eisverkäufers

$$\lambda = 80 \text{ Kunden/Stunde}$$

$$\mu = \frac{1 \text{ Kunde}}{30 \text{ Sekunden} (1 \text{ Stunde} / 3600 \text{ Sekunden})} = 120 \text{ Kunden / Stunde}$$

$$\rho = \frac{\lambda}{\mu} = \frac{80 \text{ Kunden/Stunde}}{120 \text{ Kunden/Stunde}} = 0,67 = 67\%$$



Eisverkäufer-Beispiel

2. Durchschnittliche Länge der Warteschlange

$$Lq = \frac{\lambda^2}{\mu(\mu - \lambda)}$$

3. Durchschnittliche Anzahl der Kunden im System

$$Ls = \frac{\lambda}{\mu - \lambda}$$



Eisverkäufer-Beispiel

4. Durchschnittliche Wartezeit

$$W_q = \frac{\lambda}{\mu(\mu - \lambda)} =$$

5. Durchschnittliche Verweilzeit

$$W_s = \frac{1}{\mu - \lambda} =$$



M/M/1-Modell mit begrenzter Warteschlange

- Eisverkäuferbeispiel:
 - Eisverkäufer möchte einen M1ce Drive in Kiosk betreiben.
 - Wie viele Autos müssen in der Drive-in-Schlange mindestens Platz haben, damit mit mehr als 90%iger Wahrscheinlichkeit keine Autos auf der Strasse warten müssen?

– Ansonsten wie zuvor

– Lösung: $P(n \geq k) = \rho^k$ $P(n \geq 5) = \rho^5 = 0.13$

$$P(n \geq 6) = \rho^6 = 0.09$$



M/G/1-Modell

$$L_q = \frac{\rho^2 + \lambda^2 \sigma^2}{2(1-\rho)}$$

1. Für Exponentialverteilung gilt: $\sigma^2 = \frac{1}{\mu^2} \Rightarrow L_q = \frac{\rho^2 + \lambda^2 / \mu^2}{2(1-\rho)} = \frac{2\rho^2}{2(1-\rho)} = \frac{\rho^2}{(1-\rho)}$

2. Bei konstanter Servicezeit gilt: $\sigma^2 = 0 \Rightarrow L_q = \frac{\rho^2}{2(1-\rho)}$

3. Hieraus folgt, dass die durchschnittliche Länge der Warteschlange (L_q) jeweils zur Hälfte durch die Varianz der Ankünfte sowie die Varianz der Servicezeit erklärt wird.



Helmut M. Dietl

31

Standard-M/M/s-Modell

- Voraussetzungen:
 - Wie bei Standard M/M/1-Modell (u.a. eine unbegrenzte Warteschlange und FCFS)
 - Servicerate der Server ist unabhängig und identisch verteilt

mms.xls M/M/s Queueing Formula Spreadsheet

Inputs:		Definitions of terms:	
lambda	80	lambda	= arrival rate
mu	120	mu	= service rate
		s	= number of servers
		Lq	= average number in the queue
		Ls	= average number in the system
		Wq	= average wait in the queue
		Ws	= average wait in the system
		P(0)	= probability of zero customers in the system
		P(delay)	= probability that an arriving customer has to wait

Outputs:		Lq	Ls	Wq	Ws	P(0)	P(delay)	Utilization
s								
0								
1		1,3333	2,0000	0,0167	0,0250	0,3333	0,6667	0,6667
2		0,0833	0,7500	0,0010	0,0094	0,5000	0,1667	0,3333
3		0,0093	0,6760	0,0001	0,0084	0,5122	0,0325	0,2222
4		0,0010	0,6677	0,0000	0,0083	0,5133	0,0051	0,1667
5		0,0001	0,6668	0,0000	0,0083	0,5134	0,0007	0,1333
6		0,0000	0,6667	0,0000	0,0083	0,5134	0,0001	0,1111
7		0,0000	0,6667	0,0000	0,0083	0,5134	0,0000	0,0952
8		0,0000	0,6667	0,0000	0,0083	0,5134	0,0000	0,0833
9		0,0000	0,6667	0,0000	0,0083	0,5134	0,0000	0,0741
10		0,0000	0,6667	0,0000	0,0083	0,5134	0,0000	0,0667



Helmut M. Dietl

32

Beispiel: Fahrkartenautomat

- Pro Stunde kommen durchschnittlich 20 Kunden
- Servicemanager hat die Wahl zwischen
 - Einem modernen Hochleistungsautomat (bedient durchschnittlich 2 Kunden pro Minute)
 - Zwei alten Automaten (bedienen jeweils durchschnittlich 1 Kunden pro Minute)



Helmut M. Dietl

33

Fahrkartenbeispiel: 1 Hochleistungsautomat

mms.xls M/M/s Queueing Formula Spreadsheet

Inputs:		Definitions of terms:						
lambda	20	lambda	=	arrival rate				
mu	120	mu	=	service rate				
		s	=	number of servers				
		Lq	=	average number in the queue				
		Ls	=	average number in the system				
		Wq	=	average wait in the queue				
		Ws	=	average wait in the system				
		P(0)	=	probability of zero customers in the system				
		P(delay)	=	probability that an arriving customer has to wait				
Outputs:								
	s	Lq	Ls	Wq	Ws	P(0)	P(delay)	Utilization
	0							
	1	0,0333	0,2000	0,0017	0,0100	0,8333	0,1667	0,1667
	2	0,0012	0,1678	0,0001	0,0084	0,8462	0,0128	0,0833



Helmut M. Dietl

34

Fahrkartenbeispiel: 2 Altautomaten

mms.xls M/M/s Queueing Formula Spreadsheet

Inputs:		Definitions of terms:	
lambda	20	lambda	= arrival rate
mu	60	mu	= service rate
		s	= number of servers
		Lq	= average number in the queue
		Ls	= average number in the system
		Wq	= average wait in the queue
		Ws	= average wait in the system
		P(0)	= probability of zero customers in the system
		P(delay)	= probability that an arriving customer has to wait

Outputs:		s	Lq	Ls	Wq	Ws	P(0)	P(delay)	Utilization
	0								
	1		0,1667	0,5000	0,0083	0,0250	0,6667	0,3333	0,3333
	2		0,0095	0,3429	0,0005	0,0171	0,7143	0,0476	0,1667
	3		0,0006	0,3340	0,0000	0,0167	0,7164	0,0050	0,1111



Helmut M. Dietl

35

Trade-offs

- | | |
|---|---|
| <ul style="list-style-type: none"> • 2 Altautomaten | <ul style="list-style-type: none"> • 1 Hochleistungsautomat |
| Lq = 0.0095 | Lq = 0.0333 |
| Ls = 0.3429 | Ls = 0.2 |
| Wq = 0.0005 | Wq = 0.0017 |
| Ws = 0.0171 | Ws = 0.01 |
| P(0) = 71% | P(0) = 83% |
| P(Delay) = 4.8% | P(Delay) = 16.7% |
| Auslastungsgrad = 16.7% | Auslastungsgrad = 16.7% |



Helmut M. Dietl

36

Server-Pooling

- Prinzip: Eine statt mehrere Warteschlangen
- Bessere Auslastung der Server
- Beispiele: Postschalter, Sekretärinnenpool
- Nachteil: „Lange“ Warteschlange schreckt evtl. Kunden ab
- Trade off zwischen Transport- und Wartekosten bei Pooling über mehrere Standorte (1 zentraler Serverpool vs. mehrere dezentrale Server)



Helmut M. Dietl

37

M/M/s-Modell mit begrenzter Warteschlange

- Analog zu M/M/1-Modell mit begrenzter Warteschlange
- N = Maximale Kundenzahl im System $> s$
- Neu ankommender Kunde wird zurückgewiesen, wenn mehr als $N-s$ Kunden warten oder mehr als N Kunden im System sind
- Sonderfall: $N - s = 0$ (Keine Wartemöglichkeit)
- Beispiel: Parkplatz (jeder Parkplatz ist ein Server)



Helmut M. Dietl

38

M/G/∞-Modell

- Bei diesem Modell muss kein Kunde warten, da es unendliche viele Server gibt
- Beispiel: Selbstbedienung
- Die Anzahl der Kunden im System ist poissonverteilt gemäß

- Es gilt

$$P_n = \frac{e^{-\rho}}{n!} \rho^n$$

$$L_s = \rho$$

