

7 Design of Experiments (LK 12)

7.1 Erkennen des Einflusses von Faktoren

- Das Systemverhalten (response) eines Simulationsmodells hängt von vielen Parametern (Modellfaktoren, factors) ab.
 - Beispiel: Wartezeiten bei einem M/M/1-Wartesystem hängen ab von der
 - mittleren Zwischenankunftszeit und von der
 - mittleren Bedienzeit.
 - Unterschiedliche Werte der Faktoren können für ein System realistisch und damit interessant zu untersuchen sein. Diese Wertebereiche sind für die Simulation von Interesse.
- Problem: Es ist in der Praxis oft nicht klar, welche Faktoren für das Systemverhalten wichtig sind. Das soll ja gerade herausgefunden werden.
- Ziel:
 - Ermittlung der wichtigsten Faktoren durch möglichst wenige Simulationsexperimente
 - Wie beeinflussen die Faktoren die Resultate?
 - Wie beeinflussen Kombinationen von Faktoren die Resultate?

7.1.1 Erschöpfende Simulation aller Faktoren

- Simulation aller Kombinationen aus den Faktorwertebereichen
- aus Rechenzeitgründen nicht möglich, da Anzahl der Simulation exponentiell mit der Anzahl der Faktoren steigt

7.1.2 Versuch & Irrtum Ansätze

- Faktorkombinationen werden zufällig gewählt und simuliert.
- Risiko zu hoch, entscheidende Faktoren zu übersehen.

7.1.3 Untersuchung von Einzelfaktoren

- Es gibt ein Referenzsystem
- Das System wird untersucht, indem für jeden Faktor einmal ein großer und ein kleiner Wert untersucht wird, wobei die restlichen Faktoren gleich bleiben
- Nur lineare Effekte erkennbar ($r=c_1*f_1+c_2*f_2*$...); Effekte auf Grund einer Kombination aus Faktoren nicht erkennbar ($r=c_{12}*f_1*f_2+c_{23}*f_1*f_3$).

7.1.4 2^k -Faktor-Designs (LK 12.2)

- Jeder Faktor hat nur zwei Werte (bezeichnet mit '+' und '-')
 - Bei k Faktoren sind dadurch 2^k Kombinationen der Faktorwerte möglich
 - Daher der Name: „ 2^k factorial design“
 - Jede dieser Kombinationen von k Faktoren ist ein *Designpunkt*
 - Ermittlung einer *Systemantwort* R_i für jeden Designpunkt i durch Simulationsläufe
 - Zusammenfassung der Designpunkte und Systemantworten in der *Designmatrix*

Beispiel: Designmatrix eines 2^3 factorial design:

Designpunkt	Faktor 1	Faktor 2	Faktor 3	Systemantwort
1	+	+	+	R_1
2	-	+	+	R_2
3	+	-	+	R_3
4	-	-	+	R_4
5	+	+	-	R_5
6	-	+	-	R_6
7	+	-	-	R_7
8	-	-	-	R_8

- Idee: Berechne: mittlere Änderung der Systemantwort bei der Änderung von Faktor j von '+' nach '-' ohne Änderung der anderen Faktoren
- Berechnung sogenannter Effekte von Faktorkombinationen (z.B. $x=f_1, f_2$)
- Beispiele

- Berechnung des Effektes von Faktor f_1 :

$$e_1 = \frac{(R_1 - R_2) + (R_3 - R_4) + (R_5 - R_6) + (R_7 - R_8)}{4}$$

- Berechnung des Effektes des Faktorkombination f_1, f_2 :

$$e_{12} = \frac{[(R_1 - R_2) - (R_3 - R_4)] + [(R_5 - R_6) - (R_7 - R_8)]}{4}$$

- Berechnung des Effektes des Faktorkombination f_1, f_2, f_3 :

$$e_{123} = \frac{\{[(R_1 - R_2) - (R_3 - R_4)] - [(R_5 - R_6) - (R_7 - R_8)]\}}{4}$$

- Allgemeine Berechnung der Effekte für eine Faktorkombination: Summe über alle Systemantworten multipliziert mit den Vorzeichen (s_l, s_m, s_n) in der Designmatrix der entsprechenden Faktoren und geteilt durch 2^{k-1} :

- $e_l = \frac{1}{2^{k-1}} \cdot \sum_{1 \leq i \leq 2^k} s_l(i) \cdot R(i)$

- $e_{lm} = \frac{1}{2^{k-1}} \cdot \sum_{1 \leq i \leq 2^k} s_l(i) \cdot s_m(i) \cdot R(i)$

- $e_{lmn} = \frac{1}{2^{k-1}} \cdot \sum_{1 \leq i \leq 2^k} s_l(i) \cdot s_m(i) \cdot s_n(i) \cdot R(i)$

- Interpretation

Der Effekt einer Faktorkombination korreliert mit der Qualität und Stärke ihres Einflusses auf die Systemantwort

- Beispiel: Systemantwort

$R(f_1, f_2, f_3) = a_1 \cdot f_1 + a_2 \cdot f_2 + a_3 \cdot f_3 + a_{12} \cdot f_1 \cdot f_2 + a_{13} \cdot f_1 \cdot f_3 + a_{23} \cdot f_2 \cdot f_3 + a_{123} \cdot f_1 \cdot f_2 \cdot f_3$
In diesem Fall gilt sogar

- $a_1 = \frac{1}{2} e_1$

- $a_{1m} = \frac{1}{2} e_{1m}$

$$\circ a_{lmn} = \frac{1}{2} e_{lmn}$$

Probleme:

- Voraussetzung linearer Abhängigkeit der Systemantwort von Faktorkombinationen
- Nur für beschränkte Anzahl von Faktoren anwendbar
- Einschränkung auf zwei Werte pro Faktor \Rightarrow Einschränkung der Aussagekraft der beobachteten Effekte

Praktische Durchführung:

- Mehrfache Simulation ($n \geq 10$) der Systemantworten für die 2^k Designpunkte der Designmatrix
- Erstellen von Konfidenzintervalle für die Systemantworten
- Einfluss einer Faktorkombination evident, falls das Konfidenzintervall der dazugehörigen Systemantwort die 0 nicht enthält.
- Aber: aus der statistischen Signifikanz eines Effekts folgt nicht notwendigerweise die praktische Signifikanz.

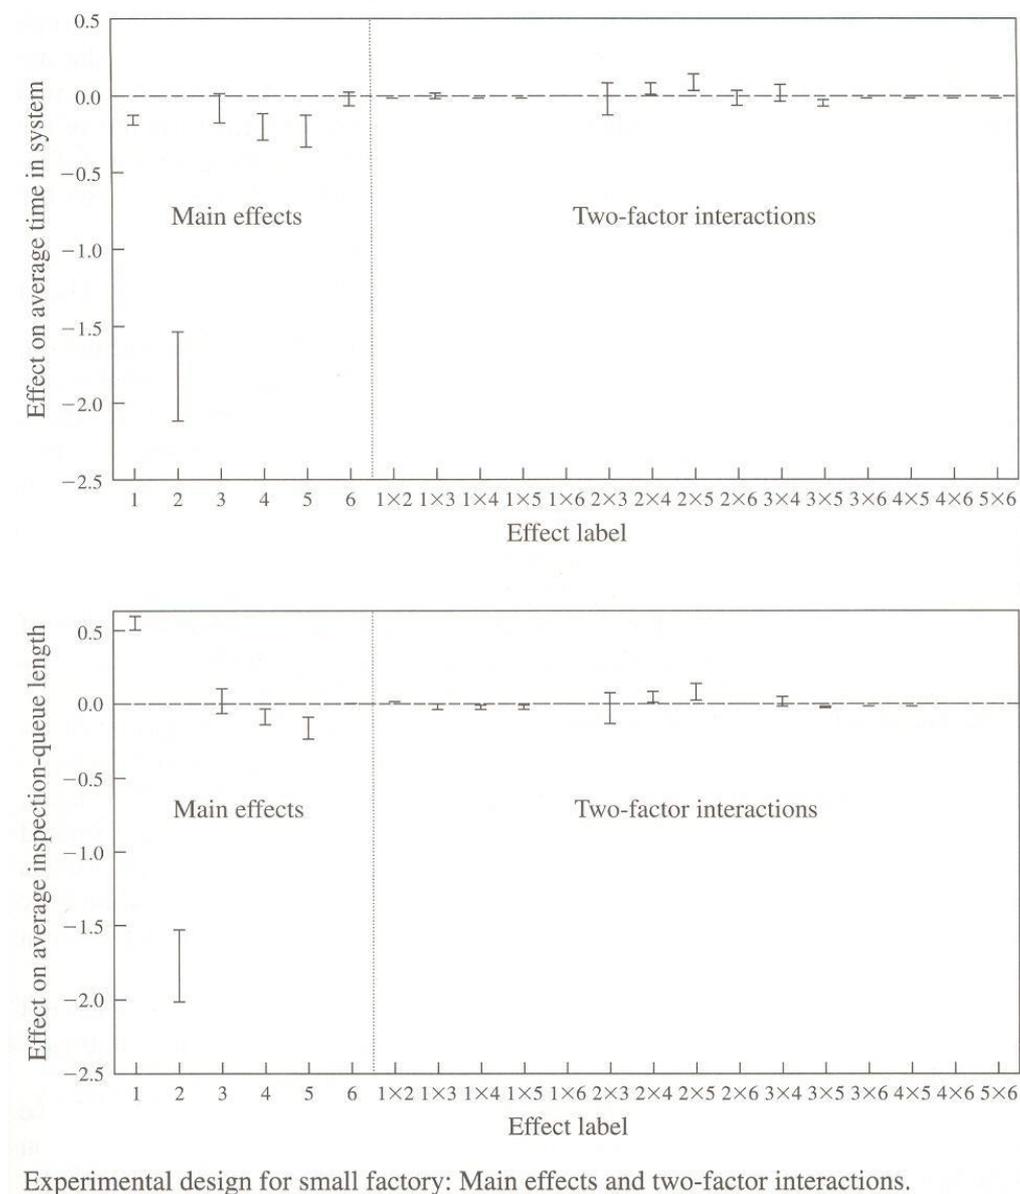


Abbildung 7.1: Ergebnisse eines Faktor Designs: Faktor 2 hat entscheidenden Einfluss auf die jeweilige Systemantwort, Faktoren 1, 4 und 5 haben geringen Einfluss, spezielle Faktorkombinationen haben keine Auswirkungen. (aus Law/Kelton: "Simulation Modeling and Analysis", 3rd Edition, S. 635)

Lösung für große Anzahl von Faktoren: 2^{k-p} fractional factorial design

- Nur 2^{k-p} Zeilen der kompletten Designmatrix werden untersucht
- Durch Streichung von Zeilen wird Aussagekraft verringert
- Herausforderung: geschicktes Streichen von Zeilen, so dass Effekte von einzelnen Faktoren sowie Effekte auf Grund von Zweierkombinationen von Faktoren noch erkennbar sind.
- Mehr dazu in LK 12.3.1

7.2 Systemverständnis und Reduktion von Parameteruntersuchungen

- System mit Eingangsparametern $\{x_1, \dots, x_n\}$
 - Durch Systemkenntnis: Zerlegung des Gesamtproblems
 - Erkennen der Auswirkung von Teileffekten in einem System (z.B. Verkehrsmenge) auf das Gesamtverhalten des Systems (z.B. Auslastung)
 - Erkennen von Parameterteilmengen, die den Teileffekt beeinflussen
 - Untersuchung der Auswirkung dieser Parameter auf den jeweiligen Teileffekt im System
 - Untersuchung des Einflusses der Teileffekte auf das Verhalten des Gesamtsystems indem z.B. nur der wichtigste Parameter eines Teileffektes verändert wird, Restparameter bleiben konstant \Rightarrow Reduktion von Parameteruntersuchungen.
 - Bei der Komposition von mehreren Teilsystemen: symmetrischer Versuchsaufbau zur besseren Kontrolle der Parameters (z.B. gleiche Ausfallwahrscheinlichkeit für alle Links eines Netzes)
 - Erfassung und Untersuchung aller Systemparameter, z.B. auch die der Netztopologie
 - Netzgröße: Knoten und Linkanzahl
 - Vermaschungsgrad
 - Zusammenhangstärke (wie viele Knoten kann man wegnehmen, ohne dass das Netz zerfällt)
 - Durchschnittliche Pfadlänge, Durchmesser
 - Zu welchen schon bekannten Teileffekten im System tragen sie bei?
 - Beispiel: Paketverlustwahrscheinlichkeit auf einem Link beeinflusst durch
 - Linkkapazität c
 - Angebotene Last a in Erlang (Anzahl der angeschlossenen Teilnehmer, Teilnehmeraktivität, ...)
 - Durchschnittliche Verbindungsrate r (Art der Applikation, unterschiedliche Benutzerklassen)
 - Variabilität der Verbindungen (Verkehrsarten, unterschiedliche Benutzerklassen)
- Durch Überlegung:
- Anzahl der angeschlossenen Teilnehmer, Teilnehmeraktivität etc. beeinflussen angebotene Last (Teileffekt)
 - Auslastung $u = a \cdot r / c$ wichtig für Leistungsbetrachtungen
 - Erkennen von Skalierungsparametern im System, z.B. c, a, r

- Die Paketverlustwahrscheinlichkeit liegt ausgelasteten Systemen in der Größenordnung $p = \frac{\max(a \cdot r - c, 0)}{a \cdot r}$
- Parameterstudien über a bei gleich bleibender Auslastung: Je größer die angebotene Last a ist, desto weniger schwankt das Gesamtverkehrsaggregat und desto kleiner ist p
- Variabilität des Gesamtverkehrsaggregats kann auch durch Variabilität der Verbindungen erhöht werden: erhöht auch die Paketverlustwahrscheinlichkeit p
- Untersuchung uninteressanter Parameterbereiche vermeiden, z.B. Parameterbereiche mit niedriger Auslastung führen zu 0% Paketverlusten

7.3 Quantifizieren und Darstellung des Einflusses von Faktoren

Faktoren haben i. A. nicht-linearen Einfluss auf die Systemantwort.

Problem: Wie können logarithmische, polynomielle, oder exponentielle Zusammenhänge erkannt und dargestellt werden?

Idee: Koordinatentransformation durch Skalierung der x- bzw. y-Achse
Platzierung der Koordinaten:

- Lineare Skalierung: $\hat{x}(x) = x$ bzw. $\hat{y}(y) = y$
- Logarithmische Skalierung: $\hat{x}(x) = \ln(x)$ bzw. $\hat{y}(y) = \ln(y)$
- Messpunkte sollen auch bei logarithmischen Skalierung der x-Achse in der Graphik gleichen Abstand voneinander haben, das erfordert einen exponentiellen Abstand der Eingangsparameter im Wertebereich.
- Beispiel:
 - Gewünscht: 10 Messwerte im Parameterbereich 1 bis 1000
 - Abstand der Messwerte im logarithmischen Bereich: $\frac{3-0}{10-1} = \frac{3}{9} = \frac{1}{3}$
 - Wähle Messwerte $x_k = 10^{\left(\frac{k}{3}\right)}$ mit $k \in [0;9]$

7.3.1 Skalierung zur Darstellung exponentiellen Wachstums

- Faktor x beeinflusst Systemantwort exponentiell: $y(x) = \exp(\lambda \cdot x)$
- Linear skalierte x-Achse: $\hat{x}(x) = x$
- Logarithmisch skalierte y-Achse: $\hat{y}(x) = \ln(y(x)) = \ln(\exp(\lambda \cdot x)) = \lambda \cdot x = \lambda \cdot \hat{x}(x)$
- Punkte im Koordinatensystem: $(\hat{x}(x), \lambda \cdot \hat{x}(x))$ ergeben eine Ursprungsgerade mit Steigung λ

7.3.2 Skalierung zur Darstellung logarithmischen Wachstums

- Faktor x beeinflusst Systemantwort logarithmisch: $y(x) = \ln(\lambda \cdot x)$
- Logarithmisch skalierte x-Achse: $\hat{x}(x) = \ln(x)$
- Linear skalierte y-Achse: $\hat{y}(x) = y(x) = \ln(\lambda \cdot x) = \ln(\lambda) + \ln(x) = \ln(\lambda) + \hat{x}(x)$
- Punkte im Koordinatensystem: $(\hat{x}(x), \ln(\lambda) + \hat{x}(x))$ ergeben eine Gerade, die die y-Achse bei $\ln(\lambda)$ schneidet

7.3.3 Skalierung zur Darstellung polynomiellen Wachstums

- Faktor x beeinflusst Systemantwort polynomiell: $y(x) = x^\lambda$
- Logarithmisch skalierte x-Achse: $\hat{x}(x) = \ln(x)$
- Logarithmisch skalierte y-Achse: $\hat{y}(x) = \ln(y(x)) = \ln(x^\lambda) = \lambda \cdot \ln(x) = \lambda \cdot \hat{x}(x)$

- Punkte im Koordinatensystem: $(\hat{x}(x), \lambda \cdot \hat{x}(x))$ ergeben eine Ursprungsgerade mit Steigung λ

7.3.4 Skalierung zur Darstellung linearen Wachstums

- Faktor x beeinflusst Systemantwort polynomiell: $y(x) = \lambda \cdot x$
- Linear skalierte x - und y -Achse: $\hat{x}(x) = x$, $\hat{y}(x) = y(x) = \lambda \cdot x = \lambda \cdot \hat{x}(x)$
 - Punkte im Koordinatensystem: $(\hat{x}(x), \lambda \cdot \hat{x}(x))$ ergeben eine Ursprungsgerade mit Steigung λ .
 - Evtl. Abweichungen im Bereich kleiner Parameter ist kaum sichtbar, da bei äquidistantem Abtasten der x -Achse nur große Parameter betrachtet werden.
- Logarithmisch skalierte x - und y -Achse: $\hat{x}(x) = \ln(x)$,
 $\hat{y}(x) = \ln(y(x)) = \ln(\lambda \cdot x) = \ln(\lambda) + \ln(x) = \ln(\lambda) + \hat{x}(x)$
 - Punkte im Koordinatensystem: $(\hat{x}(x), \ln(\lambda) + \hat{x}(x))$ ergeben eine Ursprungsgerade mit Steigung 1 .
 - Evtl. Abweichungen im Bereich kleiner Parameter sind gut sichtbar, da alle Größenordnungen bei äquidistantem Abtasten der x -Achse untersucht werden.

7.3.5 Organisation der Ergebnisse in PivotTables zur flexiblen Darstellung

Problembeschreibung

- Man hat es oft mit sehr vielen Systemfaktoren zu tun, z.B. mit $x_1, x_2, x_3, x_4, \dots$ und hat für deren Kombinationen Systemantworten ermittelt.
- Die Daten liegen oft in folgender Form vor:

x1	x2	x3	R(x1,x2,x3)	
1	4	6	24	
1	4	7	28	
1	5	6	30	
1	5	7	35	
2	4	6	48	
2	4	7	56	
2	5	6	60	
2	5	7	70	
3	4	6	72	
3	4	7	84	
3	5	6	90	
3	5	7	105	

Ergebnistabelle

- Darstellungsmöglichkeiten für die Systemantwort
 - Zweidimensionales Diagramm: $R(x_1, x_2, x_3)$ auf y-Achse, ein Faktor auf x-Achse, z.B. x_1 , ein anderer, z.B. x_2 , wird als Parameter für eine Kurvenschar benutzt.
 - Dreidimensionales Diagramm: $R(x_1, x_2, x_3, \dots)$ auf y-Achse, zwei Faktoren, z.B. x_1 und x_2 , werden auf den zwei x-Achsen dargestellt.
- Für die nicht berücksichtigten Faktoren kann dabei
 - entweder ein fester Wert angenommen werden, z.B. $x_3=6$,
 - oder die Systemantwort wird über alle werte von x_3 , also $x_3=6$ und $x_3=7$, gemittelt.
- Problem: oft ist der Haupteinflussfaktor für die Systemantwort a priori noch nicht bekannt und muss noch gefunden werden.
 - Probiere x_1, x_2 , und x_3 jeweils als x-Achse für die Darstellung aus!
- Randbedingung vieler Darstellungsprogramme wie z.B. Excel
 - x- und y-Werte müssen als Vektoren gegeben sein, indem sie in einer Spalte oder Zeile aufeinander folgen.
 - Problem: das ist in der obigen Ergebniszusammenstellung nur für x_3 mit festem x_1 und x_2 gegeben. Beispiel: $x_3=[6,7]$ mit $R(1,4,[6,7])=[24,28]$.
 - Für andere Darstellungen muss die Ergebnistabelle umorganisiert werden, das übernimmt der Pivot-Table.

Benutzung einer Pivot-Tabelle in Excel

- Organisation der Daten wie in der Ergebnistabelle nebenan
 - Oberste Zeile: Parameterbezeichnungen
 - Restliche Zeilen: Ergebniswerte
- Durchführung des PivotTable-Assistenten (Daten->Pivot-Tabelle)
 - Einlesen der gesamten Tabelle inklusive Überschrift
 - Konfiguration des PivotTables
 - Es erscheint eine PivotTable-Feldliste
 - Ziehe den Faktor für die x-Achse in das Zeilenfeld
 - Ziehe den Faktor für die Kurvenschaar in das Spaltenfeld
 - Ziehe die restlichen Faktoren in die Seitenfelder
 - Ziehe die Systemantwort in das Datenfeld
 - Doppelklicke in das linke obere Eck des PivotTables, wo sich Spalten- und Zeilenfelder kreuzen und stelle von Summe auf Mittelwert um!

x3	(Alle)
----	--------

Mittelwert von R(x1,x2,x3)	x2		
x1	4	5	Gesamtergebnis
1	26	32,5	29,25
2	52	65	58,5
3	78	97,5	87,75
Gesamtergebnis	52	65	58,5

Pivot-Tabelle

- In den Datenfeldern stehen keine Einzelwerte sondern die Durchschnitte über alle sonstigen Faktoren in den Seitenfeldern, man kann aber auch auf einen bestimmten Wert umstellen.
- Parameter im Seitenfeld, Zeilenfeld, Spaltenfeld können beliebig verschoben werden und somit ist es einfach Vektoren im Datenfeld gegen unterschiedliche Vektoren im Zeilenfeld zu plotten.
- Zum Plotten selber: kopiere die Vektoren aus dem PivotTable und erstelle mit hilfe des Diagramm-Assistenten eine XY-Graphik! Wähle aus, ob Spalten oder Zeilen gegeneinander geplottet werden sollen.