

# Wie schnell arbeitet das Simplexverfahren normalerweise?

## Oder: Das Streben nach (stochastischer) Unabhängigkeit

Karl Heinz Borgwardt

1972 stand die Welt der mathematischen Optimierung unter Schock, weil für das wichtigste Optimierungsverfahren, das Simplexverfahren zur Lösung linearer Optimierungsprobleme, mit den Klee-Minty-Polytopen Beispielsprobleme gefunden worden waren, bei denen Varianten dieses Verfahrens einen exponentiellen Rechenaufwand benötigen. Dies stand in krassem Gegensatz zu den bis dahin gemachten – äußerst positiven – Erfahrungen mit diesem Algorithmus und dessen Geschwindigkeit.

Infolgedessen setzte eine Forschungsbewegung ein, die eine Welle von Publikationen und von wertvollen Ergebnissen hervorbrachte. Es ging darum, analytisch nachzuweisen, dass die entdeckten Probleme „Ausreißer“ sind und dass das Simplexverfahren normalerweise viel besser ist als es diese Worst-Case-Resultate besagen. Damit begab man sich auf das Feld der probabilistischen Analyse von Algorithmen. Dort werden bei Unterstellung von Verteilungsannahmen für Probleme Erwartungswerte für den Rechenaufwand analytisch ermittelt oder abgeschätzt. Dieser Aufsatz beschäftigt sich mit dieser Forschungsrichtung in Bezug auf das Simplexverfahren, geht aber aus von einer grundsätzlichen Erörterung des Konzepts der probabilistischen Analyse von Algorithmen.

Im Zeitraum von 1975–1998 wurden viele derartige Untersuchungen zum Average-Case-Verhalten des Simplexverfahrens angestellt. Maßgeblich involviert in diese Forschungsrichtung der analytischen Ermittlung von Erwartungswerten und durchschnittlichen Rechenzeiten waren unter anderem Stephen Smale (Fields-Medaille 1966), Richard Karp (Fulkerson-Preis 1979), Michael Todd (George Dantzig Prize 1988, John von Neumann-Prize 2003), Ilan Adler und Nimrod Megiddo (Lanchester Prize 1988) und der Verfasser dieses Artikels (Lanchester Prize 1982). In all diesen Analysen konnte festgestellt werden, dass die ermittelten Erwartungswerte sehr klein waren.

Ab Beginn des neuen Jahrhunderts entwickelte sich noch eine andere Sicht auf die Beurteilung. Man wollte nun vermeiden, dass der Aufwand bei schweren Problemen dadurch verschleiert werden könnte, dass viele leichte Probleme diese ausgleichen. Anders gesehen, wollte man wissen, ob (oder ob nicht) sich die schweren Probleme irgendwo häufen. Dazu unterzog man die einzelnen festen Probleme leichten Störungen und mittelte dann in diesem kleinen Streubereich. Man war also gespannt darauf zu sehen, ob sich bei dieser Art von Mittelung schon eine Mäßigung des Rechenaufwands erkennen lässt. Diese Forschungsrichtung läuft unter dem Schlagwort Glättungsanalyse (Smoothed Analysis).

Es war das Verdienst von Dan Spielman, zusammen mit Shang-Hua Teng als erste dieses Prinzip erfolgreich auf das Simplexverfahren angewendet zu haben und bewiesen zu haben, dass auch aus dieser neuen Sicht das Normalverhalten besser als das Worst-Case-Verhalten ist. Dafür erhielt Dan Spielman 2010 den Rolf Nevanlinna-Preis.

In diesem Aufsatz sollen die Vorzüge, die Nachteile, aber auch die Missdeutbarkeiten und die manchmal überzogene Erwartungshaltung bei probabilistischen Analysen von Algorithmusgeschwindigkeiten erläutert werden. Dies geschieht konkret am Fall der probabilistischen Analyse des Simplexverfahrens, an deren Entwicklung der Autor maßgeblich beteiligt war. Hier wird gezeigt, wie weit man in den Forschungsbemühungen kommen konnte und welche systematischen Barrieren mathematischer Art einer weitergehenden Durchleuchtung im Wege stehen. Es wird verdeutlicht, dass der Analyseerfolg weitgehend davon abhängt, ob die verschiedenen ineingreifenden Einflussfaktoren auf den algorithmischen Verlauf voneinander separiert und dann einzeln analysiert werden können. Dass das möglich ist, ist nämlich weder selbstverständlich noch in der Praxis einfach durchführbar.

### I Was soll, will und kann die Probabilistische Analyse?

Wir gehen von einem Rechenverfahren aus, das zur Lösung konkreter Einzelprobleme (sogenannten Instanzen)  $I$  einer Problemart  $\Pi$  eingesetzt werden kann und das nachweislich für jedes  $I$  aus  $\Pi$  nach einer gewissen, von  $I$  abhängigen, Rechenzeit die gewünschte Lösung liefert. Wie üblich wollen wir im Folgenden anstelle der Rechenzeit die Anzahl der elementaren Rechenbefehle betrachten. Die in der Komplexitätstheorie oft beachtete Darstellungsgröße der darin verarbeiteten Zahlen (also die Ziffernzahl oder die Kodierungslänge) spielt hier keine Rolle.

Natürlicherweise geht man davon aus, dass in der Regel mit Zunahme der Anzahl von zu verarbeitenden Zahlen der Rechenaufwand wächst. Deshalb teilt man die Menge der Probleminstanzen  $I$  vom Typ  $\Pi$  ein in Kategorien, die nach Größe der Datenmenge sortieren, wie  $\Pi_n = \{I \mid I \text{ ist Instanz von } \Pi \text{ und enthält } n \text{ Zahlen}\}$ .

Innerhalb einer solchen  $n$ -Kategorie können nun Instanzen mit höchst unterschiedlichem Rechenaufwand  $R(A, I)$  auftreten ( $A$  steht für Algorithmus,  $I$  für die Instanz).

97 Der klassische, von extremer Vorsicht geprägte Ansatz  
 98 zur Beurteilung des Algorithmus  $A$  ist die *Worst-Case-*  
 99 *Analyse*. Man versucht dabei, für jedes  $n$  das Maximum  
 100 über  $\{R(A, I) \mid I \in \Pi_n\}$  zu erkennen, und beurteilt nach  
 101 dem Verlauf dieser Maximalwerte in Abhängigkeit von  $n$ .

102 Aber diese Kennzahl bzw. der Verlauf dieser Kennzah-  
 103 len gibt oft keinen stichhaltigen Eindruck vom normalen  
 104 Verhalten des Algorithmus. Um Informationen darüber  
 105 erhalten zu können, müsste man erstmal eine klare Vor-  
 106 stellung davon haben, welche Instanzen  $I \in \Pi_n$  real zu  
 107 lösen sind und wie oft diese auftreten. In der Sprache der  
 108 Wahrscheinlichkeitstheorie müsste man also wissen, wie  
 109 die realen  $I$  über  $\Pi_n$  verteilt sind. Dies weiß niemand,  
 110 aber viele haben dazu individuelle Vorstellungen. Basie-  
 111 rend auf einer klaren Vorstellung wäre man vielleicht in  
 112 der Lage, über Zufallsexperimente den Rechenaufwand  
 113 statistisch zu evaluieren. Jedoch entzieht sich diese Me-  
 114 thodik der empirischen Austestung einer Ausdehnung in  
 115 höhere Dimensionen und das so gewonnene Datener-  
 116 gebnis material liefert meist keinen Einblick in die wirk-  
 117 lichen Zusammenhänge und erlaubt deshalb auch keine  
 118 zutreffende qualitative Deutung.

119 Für den Mathematiker stellt sich nun die folgende Her-  
 120 ausforderung:

121 Kann ich bei Unterstellung der von mir angenommenen  
 122 Verteilung der Instanzen in  $\Pi_n$  eine Analyse von pro-  
 123 babilistischen Kenngrößen (Erwartungswerte, Varianzen  
 124 usw.) analytisch gewinnen?

125 Dass dies meist nur unter außergewöhnlichen Umstän-  
 126 den mit Ja beantwortet werden kann, ist offensichtlich.  
 127 Und deshalb setzt ein rekursiver (eigentlich so nicht ge-  
 128 wollter) Selektionsprozess ein:

129 Unser Mathematiker sucht nach Verteilungen oder Ver-  
 130 teilungsmodellen, die er analysieren kann. Also tritt die  
 131 Frage nach der „realen Verteilung“ (die ja niemand kennt)  
 132 in den Hintergrund. Das Ergebnis der – wenn überhaupt  
 133 – erfolgreichen Analyse basiert also auf einer Unterstel-  
 134 lung, die sowohl vom Produzent als auch vom Abnehmer  
 135 akzeptiert sein muss.

136 Hat man sich auf ein einheitliches stochastisches Mo-  
 137 dell geeinigt, dann kann ein Wettbewerb zwischen ver-  
 138 schiedenen Analysen um eine genauere Approximation  
 139 der gewünschten Größen (z. B. Verkleinerung von Ober-  
 140 schranken) stattfinden. Hüten muss man sich aber vor  
 141 einem Herumbasteln am stochastischen Modell mit dem  
 142 Ziel, die Obergrenzen zu senken. Allzuoft prägt dann  
 143 das stochastische Modell selber das Ergebnis und man  
 144 untersucht in Wirklichkeit nicht mehr die Güte des Al-  
 145 gorithmus. Wie eminent sich solche stochastischen An-  
 146 nahmen auswirken können, wird in den folgenden Ab-  
 147 schnitten verdeutlicht. Aber selbst bei Festhalten an ei-  
 148 nem stochastischen Modell ist die Akzeptanz noch nicht  
 149 gesichert. Nun setzt nämlich die Kritik an dem gewählten  
 150 Modell aus Sicht der Anwender ein. Zu rechtfertigen ist  
 151 nun, dass das verwendete Modell etwas mit Realproble-  
 152 men und deren Auftrittshäufigkeiten zu tun hat.

153 Hinzu kommt noch ein anderer Effekt, der auch in den  
 154 folgenden Abschnitten noch konkret verdeutlicht wird.  
 155 Man tut sich oft schwer damit, eine Analyse basierend  
 156 auf dem Einsatz von Algorithmus  $A$  in Reinform erfolg-  
 157 reich durchzuführen. Oft wird nun der Ausweg gewählt,  
 158 den Algorithmus so zu variieren, dass der variierte Al-  
 159 gorithmus  $\bar{A}$  tatsächlich analysierbar wird. Dessen Über-  
 160 einstimmung mit  $A$  liegt dann vor allem (und manchmal  
 161 nur noch) darin, dass er ebenfalls das Problem  $I \in \Pi_n$   
 162 erfolgreich löst.

163 Bei all diesen Kritikpunkten gegen die genauen qualitati-  
 164 ven und quantitativen Ergebnisse der Analyse sollten aber  
 165 deren Verdienste nicht kleingeredet werden. Durch die  
 166 intensive mathematische Analyse gelingt es oft, die Ur-  
 167 sachen für ein typischerweise auftretendes oder ein kri-  
 168 tisch verlaufendes Verhalten des Algorithmus zu erken-  
 169 nen. Abseits von quantitativen Auswertungen liefert dies  
 170 eine Fülle von nachvollziehbaren Einsichten und Plausibi-  
 171 litäten. Zumeist steht am Ende von vielerlei Bemühun-  
 172 gen der Eindruck, dass der Algorithmus unter all den ver-  
 173 schiedenen unterstellten Verteilungen immer ganz passa-  
 174 bel funktioniert.

## 175 2 Lineare Optimierung mit dem 176 Simplexverfahren

177 Der Autor hat sich in den vergangenen Jahrzehnten in-  
 178 tensiv mit der probabilistischen Analyse des Rechenauf-  
 179 wands beim Lösen Linearer Optimierungsprobleme be-  
 180 fasst. Deshalb soll das im vorigen Abschnitt in genereller  
 181 Form Angesprochene nun in seiner Bedeutung für dieses  
 182 Forschungsfeld konkretisiert und verdeutlicht werden.

Man will also folgendes Problem lösen:


	maximiere $v^T x$	als Zielfunktion
	unter	den Restriktionen
	$a_1^T x \leq b^1$	
	$\vdots$	
	$a_m^T x \leq b^m$	bzw. $Ax \leq b$
(LP)	wobei	$v, x, a_1, \dots, a_m \in \mathbb{R}^n, b \in \mathbb{R}^m.$

185 Also ist hier  $n$  die Dimension oder die Anzahl der Ent-  
 186 scheidungsvariablen,  $m$  ist die Anzahl der Restriktionen,  
 187 und grundsätzlich sei  $m \geq n$ .


188 So entsteht ein Polyeder  $P(A, b) = \{x \in \mathbb{R}^n \mid Ax \leq b\}$   
 189 als Zulässigkeitsbereich für die Wahl des optimalen Va-  
 190 riablenvektors  $x_{opt}$ .

191 Es können folgende Fälle vorkommen:

- 192 – das Polyeder ist leer, weil das Restriktionensystem
- 193 nicht erfüllbar ist;
- 194 –  $v^T x$  (die Zielfunktion) lässt sich in  $P(A, b)$  unbegrenzt
- 195 steigern;
- 196 – in  $P(A, b)$  gibt es Punkte  $x_{opt}$  mit maximalem  $v^T x$ -
- 197 Wert.



198 Jede Ecke ist bestimmt durch drei Restriktionen, die dort straff werden.  
199



200 Von der Optimalecke zur Richtung  $u$  führen mehrere Simplexpfade (unterschiedlicher Länge) zur  $v$ -Optimalecke. Der rote Pfad entspricht dem Schatteneckenalgorithmus.  
201

202 Es wird von einem Lösungsverfahren erwartet, dass es in  
203 den ersten beiden Fällen diesen Sachverhalt meldet und  
204 im letzten Fall einen der Optimalpunkte benennt.

205 Wir unterstellen die Nichtentartung der Problemstellung  
206 (in  $(A, b)$  seien alle quadratischen Untermatrizen von vol-  
207 lem Rang und die  $a_i$  sowie die Zielrichtung  $v$  seien in  
208 allgemeiner Lage).

209 Wenn nun noch gilt  $P(A, b) \neq \emptyset$ , dann besitzt  $P(A, b)$   
210 wegen  $m \geq n$  eine Ecke.

211 Und dann verläuft ausgehend von dieser Ecke  $x_0$  ein  
212 (oder mehrere) Kantenzug, wobei auf jeder Kante der  
213 Zielwert  $v^T x$  strikt ansteigt und der

214 – entweder mit einer ins Unendliche verlaufenden Kante  
215 endet (Unbeschränktheit).

216 Die Ecke, an der diese Kante beginnt, kann als Ab-  
217 bruchecke genutzt werden.

218 – oder bei einer Ecke ( $x_{opt}$ ) endet, für die  $v^T x$  optimal  
219 ist.

220 Damit man diese Methode einsetzen kann, ist entschei-  
221 dend, dass sich bei Polyedern  $P(A, b)$ , die eine Ecke be-  
222 sitzen und auf denen die  $v^T x$ -Werte beschränkt bleiben,  
223 unter den Optimalpunkten eine Ecke befindet.

224 Diese iterierte Wanderung von Ecke über Kante zu einer  
225 Nachbarecke bis hin zur Optimal- oder Abbruchecke ist  
226 das Wesen des Simplexalgorithmus.

227 Jeder Wechsel von einer Ecke zu einer Nachbarecke (also  
228 über eine Kante) hat arithmetisch folgende Bedeutung:

229 Die erste Ecke  $x_\Delta$  werde bestimmt durch eine  $n$ -  
230 elementige Indexmenge  $\{\Delta^1, \Delta^2, \dots, \Delta^n\} \subset \{1, \dots, m\}$   
231 als Lösung des Gleichungssystems

$$232 a_{\Delta^1}^T x = b^{\Delta^1}, \dots, a_{\Delta^n}^T x = b^{\Delta^n}.$$

233 Für die Zulässigkeit von  $x_\Delta$  ist entscheidend, dass auch  
234 für alle  $k \notin \Delta$  gilt  $a_k^T x_\Delta \leq b^k$ .

235 Nun wird ein Eckenwechsel dadurch ausgelöst, dass für  
236 ein einzelnes  $\Delta^i$  die Bedingung  $a_{\Delta^i}^T x = b^{\Delta^i}$  gelockert wird  
237 zu  $a_{\Delta^i}^T x < b^{\Delta^i}$  unter Beibehaltung der anderen  $n-1$  Gle-  
238 chungen. Dadurch wird eine Bewegung auf einer Kante  
239 weg von  $x_\Delta$  initialisiert.

240 Diese Bewegung muss aber dort enden, wo  $P(A, b)$  ver-  
241 lassen werden würde. Dies ist erkennbar daran, dass nun  
242 eine vorher lockere Restriktion  $a_j^T x_\Delta \leq b^j$  mit  $j \notin \Delta$   
243 die Gleichung  $a_j^T x_{neu} = b^j$  erfüllt.  $x_{neu}$  ist dann die Ecke  
244 am anderen Kantenende und erfüllt die Gleichungen

$$245 a_{\Delta^1}^T x_{neu} = b^{\Delta^1}, \dots, a_{\Delta^{i-1}}^T x_{neu} = b^{\Delta^{i-1}}, a_j^T x_{neu} = b^j,$$

$$246 a_{\Delta^{i+1}}^T x_{neu} = b^{\Delta^{i+1}}, \dots, a_{\Delta^n}^T x_{neu} = b^{\Delta^n}.$$

245 Für das Weitere wird zur Vereinfachung der Darstellung  
246 jeweils  $\Delta = \{1, 2, \dots, n\}$  unterstellt.

247 Diese Eckenwechsel (Pivotschritte) werden fortgesetzt,  
248 bis (wie vorher beschrieben) eine Optimal- oder Ab-  
249 bruchecke erreicht ist. Da von jeder Ecke (bei Nichtent-  
250 artung)  $n$  Kanten ausgehen und ein Teil davon die Ziel-  
251 funktion verbessert, steht diese Kantenmenge zur Aus-  
252 wahl und es erfordert eine feste Regel (eine Variante),  
253 um systematisch jeweils eine Kante zum Weiterkommen  
254 zu benutzen.

255 Nun sei noch klargestellt, dass zum Auffinden der er-  
256 wählten Startecke des Hauptproblems ein leicht modi-  
257 fiziertes Problem (statt LP) gelöst werden muss. Des-  
258 sen Lösung geschieht nach dem gleichen erwähnten Prin-  
259 zip. Das modifizierte Problem besitzt aber den Vorzug,  
260 dass man dafür eine Ausgangsecke kennt. Es besitzt je-  
261 doch den Nachteil, dass seine Lösung nur irgendeine Ecke  
262 des Originalpolyeders liefert, nicht etwa die Optimale-  
263 cke. Diese so durch die „Phase I“ gelieferte Ecke wird  
264 dann als Startecke für die beschriebene „Phase II“ be-  
265 nutzt.

266 Die gebräuchlichsten Varianten (der Auswahl der näch-  
267 sten Kante) orientieren sich an ganz unterschiedlichen  
268 Kriterien, wie z. B.

269 – am Zielfunktionsfortschritt, den die Benutzung dieser  
270 Kante bringen wird (größte Verbesserung)

271 – am Abweichungswinkel zwischen der Zielrichtung  $v$   
 272 und der Kantenrichtung (*steilster Anstieg*)  
 273 – an der Darstellung der Zielrichtung  $v$  durch die an der  
 274 aktuellen Ecke straffen (d.h. mit Gleichheit erfüllten)  
 275 Restriktionen  
 276  $v = \sum_{i=1}^n \xi^i a_{\Delta^i}$  („*Regel von Dantzig*“)  
 277 – an den Originalindizes der straffen Restriktionen („*Re-*  
 278 *gel von Bland*“).

279 Eine für die probabilistische Analyse entscheidende Son-  
 280 derrolle spielt hier die parametrische Variante von Gass  
 281 und Saaty [9] (mittlerweile auch bekannt unter dem Na-  
 282 men *Schatteneckenalgorithmus*). Diese soll wegen ihrer  
 283 für das Hiesige wesentlichen Bedeutung näher erläutert  
 284 werden. Die Bedeutung fußt auf dem sogenannten Polar-  
 285 kegelsatz bzw. dem Lemma von Farkas:


286 Eine Ecke  $x_{\Delta}$  ist dann optimal, wenn die Restriktionsvek-  
 287 toren  $a_{\Delta^1}, \dots, a_{\Delta^n}$  zu den dort straffen Restriktionen die  
 288 Zielrichtung konisch erzeugen, d.h. wenn gilt:  
 289  $v$  liegt im Kegel dieser Vektoren bzw. in  $\sum_{i=1}^n \xi^i a_{\Delta^i} = v$   
 290 sind alle  $\xi^i \geq 0$ .

291 Nun betrachtet man die vorliegende Startecke als Op-  
 292 timalecke zu einer Zielrichtung  $u$ , die man als konische  
 293 Kombination aus  $a_{\Delta^1}, \dots, a_{\Delta^n}$  gewinnen kann, also  $u =$   
 294  $\sum_{i=1}^n \xi^i a_{\Delta^i}$  mit  $\xi^i \geq 0$  für  $1 \leq i \leq n$ .


295 Wir sind uns aber bewusst, dass nicht  $u^T x$ , sondern  $v^T x$   
 296 optimiert (maximiert) werden sollte.

297 Deshalb betrachtet man nun Mischzielrichtungen  $w_{\lambda} =$   
 298  $(1 - \lambda)u + \lambda v$  mit  $\lambda \in [0, 1]$ . Während bei  $\lambda = 0$  und  
 299  $w_0 = u$  die Startecke für  $w_0$  optimal ist, wird diese Ecke  
 300 ihre Optimalität allmählich einbüßen, wenn wir  $\lambda$  stei-  
 301 gern. Ab einem  $\bar{\lambda} \geq 0$  ist dann eine andere Ecke optimal  
 302 und dieser Wechsel vollzieht sich etliche Male, bis  $\lambda = 1$   
 303 und  $w_1 = v$  erreicht werden kann. Es zeigt sich, dass  
 304 jeder solche Wechsel der Optimalecke der Wanderung  
 305 von der bisherigen Optimalecke zu einer Nachbarecke  
 306 entspricht, so dass diese Wanderung einen Simplexpfad  
 307 von der  $u^T x$ -Optimalecke zur  $v^T x$ -Optimalecke ergibt.  
 308 Der Aufwand für einen solchen Wechsel ist leicht be-  
 309 stimmbar ( $O(m \cdot n)$ ). Deshalb ist man brennend daran  
 310 interessiert, wie viele Eckenwechsel diese Wanderung er-  
 311 fordert. Das kann man somit auch daran ablesen, wie vie-  
 312 le Ecken denn bei der  $\lambda$ -Steigerung temporär für gewis-  
 313 se  $w_{\lambda}$  die Optimalstellung innehaben. Der parametrische  
 314 Algorithmus folgt mit seiner Eckenwanderung genau die-  
 315 ser Folge von Optimalecken.

316 Der Autor hat in seiner Dissertation 1977 eine geometri-  
 317 sche Bedeutung dieses Prozesses erkannt. Jede erreichte  
 318 Ecke ist ja bezüglich einer Zielrichtung  $w_{\lambda} = (1 - \lambda)u + \lambda v$   
 319 extremal. Projiziert man nun das Polyeder  $P(A, b)$  auf die  
 320 Ebene  $\text{Span}(u, v)$ , so bildet sich ein zweidimensionaler  
 321 Schatten. Die erwähnte Ecke wird wegen ihrer Extrema-  
 322 lität auf eine Ecke des Schattens projiziert. Für diese Art  
 323 von Ecken hat der Autor deshalb den Namen Schatten-



Primale Sicht auf den Schatteneckenalgorithmus



Duale Sicht auf den Schatteneckenalgorithmus

326 ecken und für den obigen Algorithmus den Namen Schat-  
 327 teneckenalgorithmus geprägt [3, 4].

328 Folglich würde eine entdeckte Oberschranke für die Zahl  
 329 der Schattenecken auch eine Oberschranke für die Sim-  
 330 plexschritte auf dem Weg von Start- zu Zielecke abgeben.

331 Dem Beobachter dieser Bemühungen um probabilistische  
 332 Resultate, die in den folgenden Kapiteln beschrieben  
 333 werden, stellt sich die Frage, weshalb eine solche  
 334 Analyse ausgerechnet für den Schatteneckenalgorithmus  
 335 und nicht auch für andere Varianten funktioniert. Denn es  
 336 ist schon auffällig, dass beim Rotationssymmetrie-Modell  
 337 (Kapitel III) beim Umklapp-Modell (Kapitel IV) und bei  
 338 der Glättungsanalyse (Kapitel V) tatsächlich nur Ergeb-  
 339 nisse über den Schatteneckenalgorithmus vorliegen.

340 Der Grund liegt im erkennbar klaren geometrischen  
 341 Konzept des Schatteneckenalgorithmus, das sich mühe-  
 342 los auf die Betrachtung der Einzelkandidaten (das sind in  
 343 diesem Fall die Ecken bzw. Basislösungen) herunterbre-  
 344 chen lässt.

345 Hier wird nämlich jeder Kandidat (das ist etwa die Kom-  
 346 bination aus  $a_1, a_2, \dots, a_n$  bzw. die Lösung  $x_\Delta$  des ent-  
 347 sprechenden Gleichungssystems) daraufhin abgefragt, ob  
 348 simultan

- 349 –  $x_\Delta$  Ecke von  $P(A, b)$  ist bzw. ob  $\text{Conv}(a_1, \dots, a_n)$  Fa-  
 350 ciette von  $\text{Conv}(a_1, \dots, a_m, 0)$  ist
- 351 –  $x_\Delta$  eine Schattenecke ist bzw. ob  $\text{Conv}(a_1, \dots, a_n)$   
 352 und  $\text{Span}(u, v)$  sich schneiden.

353 Damit ergibt sich die Schatteneckenzahl direkt aus der  
 354 Anzahl der Kandidaten, die beides gleichzeitig erfüllen.  
 355 Also setzt sich diese „Summe“ aus den Einzelbeobach-  
 356 tungen zusammen. Den Erwartungswert bekommt man  
 357 entsprechend, wenn man die Wahrscheinlichkeit dafür  
 358 ermittelt, dass unser typischer Kandidat  $\Delta = \{1, \dots, n\}$   
 359 beide Bedingungen gleichzeitig erfüllt.

360 Bei anderen Varianten des Simplexalgorithmus gibt es  
 361 nur eine dynamische Charakterisierung mit Hilfe der Be-  
 362 obachtung des ganzen Pfades. Ob hier eine Ecke oder  
 363 ein Kandidat  $(a_1, \dots, a_n)$  vom Simplexpfad besucht wird,  
 364 kann nicht allein aus der Beobachtung der Daten dieses  
 365 Kandidaten erkannt werden. Vielmehr hängt dies ent-  
 366 scheidend davon ab, wie der Verlauf des Simplexpfades  
 367 war, bevor das  $v^T x$ -Niveau unseres Kandidaten erreicht  
 368 war. Wurden dabei etwa keine Nachbarecken unseres  
 369 Kandidaten erfasst, dann bleibt auch unser Kandidat au-  
 370 ßen vor. Es türmen sich also hier enorme Abhängigkeiten  
 371 zwischen allen Daten auf, die viel zu komplex sind, als  
 372 dass man sie (bisher) in den Griff hätte bekommen kön-  
 373 nen.

### 374 3 Probabilistische Analyse für den 375 Schatteneckenalgorithmus unter dem 376 Rotationssymmetrie-Modell

377 Wenn wir also bei der Variante Schatteneckenalgorithmus  
 378 die Frage nach der Zahl der Ecken auf dem Simplex-  
 379 pfad schlichtweg ersetzen können durch die Frage nach  
 380 der Anzahl von Schattenecken, dann bietet sich die Sto-  
 381 chastische Geometrie zur Beantwortung an.

382 Um stochastische Informationen über diese Anzahl zu ge-  
 383 winnen, müssen wir uns zunächst auf ein stochastisches  
 384 Modell festlegen. Dazu setzen wir (in diesem Abschnitt)  
 385 das sogenannte Rotationssymmetrie-Modell ein.

#### Rotationssymmetrie-Modell

Zur Erzeugung der Probleminstanzen von

$$(LP1) \quad \text{maximiere } v^T x \quad \text{unter } a_1^T x \leq 1, \dots, a_m^T x \leq 1$$

- 386 seien die Zufallsvektoren  $v, a_1, \dots, a_m$  und ein Hilfsvek-  
 tor  $u$  jeweils über  $\mathbb{R}^n \setminus \{0\}$
- stochastisch unabhängig
- identisch
- rotationssymmetrisch erzeugt.

388 (Die Festlegung der rechten Seite  $b^i$  auf 1 ist bedeutungs-  
 389 los, solange  $b^i \geq 0$  gilt. In diesem Fall kann diese Normie-  
 390 rung durch Anpassung der  $a_i$  erfolgen.)

391 Will man stochastische Geometrie betreiben, dann emp-  
 392 fiehlt es sich, den Dualraum zu betrachten, in dem die  
 393 Zufallsvektoren  $v, a_1, \dots, a_m$  direkt erzeugt werden. Dies  
 394 ist günstiger als im Primalraum, wo das Polyeder  $P(A, b)$   
 395 und die Vektoren  $x$  leben, Studien anzustellen, die nur in-  
 396 direkt durch die Wahl der  $v, a_1, \dots, a_m$  geprägt werden.

397 Die folgenden beiden Zusammenhänge besorgen die er-  
 398 forderliche Übersetzung

- 399 (a)  $x_\Delta$  (bestimmt durch  $a_1^T x_\Delta = 1, \dots, a_n^T x_\Delta = 1$ ) ist  
 400 genau dann Ecke von  
 401  $P(A, b) = \{x \mid a_1^T x \leq 1, \dots, a_m^T x \leq 1\}$ ,  
 402 wenn  $\text{Conv}(a_1, \dots, a_n)$  Facette (Randsimplex) von  
 403  $\text{Conv}(0, a_1, \dots, a_m)$  ist.
- 404 (b) Die Ecke  $x_\Delta$  von  $P(A, b)$  ist genau dann Schat-  
 405 tenecke bei Projektion auf  $\text{Span}(u, v)$ , wenn  
 406  $\text{Conv}(a_1, \dots, a_n) \cap \text{Span}(u, v) \neq \emptyset$ .

Da es nur  $\binom{m}{n}$  Auswahlmengen der Art  $\{a_{\Delta^1}, \dots, a_{\Delta^n}\} \subset$   
 $\{a_1, \dots, a_m\}$  gibt, lässt sich die erwartete Anzahl von  
 Schattenecken errechnen als

$$EW(\text{Anzahl Schattenecken}) = \binom{m}{n} P(\text{Conv}(a_1, \dots, a_n) \text{ ist Facette} \\ \text{und } \text{Conv}(a_1, \dots, a_n) \cap \text{Span}(u, v) \neq \emptyset).$$

407 Da hier  $a_1, \dots, a_n$  zufällig erzeugt sind, berücksichtigen  
 408 wir deren Verteilungsfunktionen  $F$  in der folgenden Inte-  
 409 graldarstellung :

$$EW(S) = \binom{m}{n} \int_{\mathbb{R}^n} \dots \int_{\mathbb{R}^n} P([\text{Conv}(a_1, \dots, a_n) \text{ Facette}] \\ \wedge [\text{Conv}(a_1, \dots, a_n) \cap \text{Span}(u, v) \neq \emptyset]) dF(a_1) \dots dF(a_n)$$


410 Es stellt sich heraus, dass das erste Ereignis, nur noch von  
 411 der Lage von  $a_{n+1}, \dots, a_m$  abhängt, sobald  $a_1, \dots, a_n$  ein-  
 412 mal festliegen. Genauso ist für das zweite Ereignis dann  
 413 nur noch entscheidend, wie  $u$  und  $v$  liegen. Somit können  
 414 wir in der Integraldarstellung aufspalten

$$EW(S) = \binom{m}{n} \int_{\mathbb{R}^n} \dots \int_{\mathbb{R}^n} P(\text{Conv}(a_1, \dots, a_n) \text{ Facette}) \cdot \\ \cdot P(\text{Conv}(a_1, \dots, a_n) \cap \text{Span}(u, v) \neq \emptyset) dF(a_1) \dots dF(a_n).$$


415 Man beachte aber, dass, solange sich  $a_1, \dots, a_n$  ändern,  
 416 sicher nicht gilt:

$$P([\text{Conv}(a_1, \dots, a_n) \text{ def. Facette}] \wedge [\text{Span}(u, v) \cap \text{Conv}(a_1, \dots, a_n) \neq \emptyset]) = \\ = P(\text{Conv}(a_1, \dots, a_n) \text{ def. Facette}) \cdot P(\text{Span}(u, v) \cap \text{Conv}(a_1, \dots, a_n) \neq \emptyset).$$

417 Um dies plausibel zu machen, betrachte man die Gleich-  
 418 verteilung auf der Vollkugel des  $\mathbb{R}^n$ .



Bei tiefer Lage des Dreiecks aus  $a_1, a_2, a_3$  öffnet sich  $\text{Cone}(a_1, a_2, a_3)$  stark, die Schnittwahrscheinlichkeit ist demnach groß. Gleichzeitig gibt es oberhalb extrem viel Platz für Punkte  $a_i$ , die die Facetteneigenschaft zerstören könnten. Die beiden Ereignisse sind also negativ korreliert.



Bei hoher Lage des Dreiecks aus  $a_1, a_2, a_3$  öffnet sich  $\text{Cone}(a_1, a_2, a_3)$  nur schwach, die Schnittwahrscheinlichkeit ist demnach klein. Gleichzeitig gibt es oberhalb kaum Platz für Punkte  $a_i$ , die die Facetteneigenschaft zerstören könnten. Die beiden Ereignisse sind also negativ korreliert.

420  $a_1, \dots, a_n$  legen einen Simplex fest, der wiederum als  
 421 affine Hülle eine Hyperebene definiert. Die Facette-  
 422 neigenschaft erfordert, dass sich alle übrigen Vektoren  
 423  $a_{n+1}, \dots, a_m$  unterhalb dieser Hyperebene ansiedeln, d. h.  
 424 in dem Halbraum, der auch den Ursprung enthält. Es  
 425 liegt auf der Hand, dass bei Gleichverteilung aller Punkte  
 426 auf der Vollkugel dieses Ereignis hochwahrscheinlich  
 427 ist, wenn der Ursprung einen sehr großen Abstand  
 428 zur Hyperebene hat, und sehr unwahrscheinlich wird,  
 429 wenn der Abstand zwischen beiden klein ist. Aber ge-  
 430 nau umgekehrt ist es bei der Schnittbedingung. Hier muss  
 431 ja der Kegel  $\text{Cone}(a_1, \dots, a_n)$  von  $\text{Span}(u, v)$  geschnit-  
 432 ten werden. Liegt nun die Hyperebene als Träger von  
 433  $a_1, \dots, a_n$  nahe beim Nullpunkt, dann können  $a_1, \dots, a_n$   
 434 sehr weit voneinander entfernt sein. Das heißt, der be-  
 435 trachtete Kegel kann sich sehr weit öffnen, was die  
 436 Schnittwahrscheinlichkeit in die Höhe treibt. Hat aber  
 437 die Hyperebene einen großen Abstand vom Nullpunkt,  
 438 dann müssen sich die  $n$  Punkte auf einer sehr kleinen  
 439  $n - 1$ -dimensionalen Kreisscheibe ansiedeln. Infolgedes-

440 sen kann sich nur ein kleiner Kegel öffnen und die Schnitt-  
 441 wahrscheinlichkeit wird extrem klein.

442 Dieser gegenläufige Effekt (diese negative Korrelation)  
 443 sorgt nun dafür, dass das genannte Integral ziemlich klein  
 444 bleibt. (Hätte man hier die oben beschriebene Produkt-  
 445 form bzw. die Unabhängigkeit, dann wären die Ober-  
 446 schranken fulminant höher ausgefallen). Obige Unter-  
 447 scheidung hat zu Entstehungszeiten zu erheblichen Fehl-  
 448 interpretationen, Missverständnissen und Anzweiflungen  
 449 geführt. Wir werden im Späteren über andere Verteil-  
 450 ungsmodelle reden, bei denen die hier zuweilen fälsch-  
 451 lich unterstellte Unabhängigkeit wirklich zutrifft, was psy-  
 452 chologisch einige Erklärungen für diese damaligen Aus-  
 453 einandersetzungen liefert. Nun ergab die korrekte Aus-  
 454 wertung dieser negativen Korrelation für die Integraldar-  
 455 stellung folgendes Ergebnis

**Fundamentalsatz (Schattenecken im RSM) [7]**  
 Die erwartete Anzahl von Schattenecken bei  $m$  Re-  
 striktionen und  $n$  Entscheidungsvariablen bei Projektion  
 auf  $\text{Span}(u, v)$  ist für alle rotations-symmetrischen Ver-  
 teilungen nicht größer als

$$m^{\frac{1}{n-1}} n^2 \cdot \text{Const.}$$

457  
 458 Man mache sich an dieser Stelle klar, dass bisher nur der  
 459 Eckenwanderungsweg von der Startecke zur Abbruch-  
 460 ecke unter die Lupe genommen worden ist. Aber zu-  
 461 nächst verfügen wir ja noch gar nicht über die Startecke  
 462 bzw. die Optimalecke zu einer frei gewählten Zielrich-  
 463 tung  $u$ .

464 Und hier kommt man in ein Dilemma. Im obigen Fun-  
 465 damentalsatz über die Schatteneckenanzahl wird nämlich  
 466 verlangt, dass  $u$  unabhängig von den übrigen Problem-  
 467 daten zu wählen ist. Um dann eine Schattenecke zu bekom-  
 468 men, muss man eine Ecke  $x_0$  haben, die  $u^T x$  maximiert.  
 469 Würde man aber zuerst das  $u^T x$ -Optimum suchen, dann  
 470 wäre das Problem eigentlich nur verlagert worden von  
 471  $v$  auf  $u$  und keineswegs leichter geworden. Würde man  
 472  $u$  umgekehrt bestimmen aus  $\text{Cone}(a_{\Delta^1}, \dots, a_{\Delta^n})$ , wobei  
 473  $a_{\Delta^1}, \dots, a_{\Delta^n}$  die straffen Restriktionsvektoren an einer  
 474 irgendwie gewonnenen Startecke sind, dann hätte man  
 475 die Erfordernis der unabhängigen Wahl von  $u$  gegenüber  
 476  $a_1, \dots, a_m$  verletzt und deshalb hätte man keinen rigoros  
 477 richtigen Beweis mehr. Der Leser sei darauf hingewiesen,  
 478 dass sich diese Komplikation durch alle folgenden Kapitel  
 479 dieses Aufsatzes schleppt.

480 Hier eröffnete sich ein Ausweg, der zwar vom effizien-  
 481 testen (Praktiker-)Verhalten abweicht, aber für einen ri-  
 482 gorosen Beweis sorgt. Der sogenannte Dimensionsstei-  
 483 gerungsalgorithmus löst das  $v^T x$ -Maximierungsproblem,  
 484 indem er nacheinander den Schatteneckenalgorithmus  
 485 zur Lösung von Problemen mit wachsender Dimension  
 486 einsetzt. Dazu lösen wir sukzessive die folgenden Proble-  
 487 me in den Stufen  $k$ , wobei  $k$  von 1 bis  $n$  läuft.

$$\begin{array}{ll} \text{maximiere} & v^T x \\ \text{(Stufe } k) \text{ unter} & a_1^T x \leq 1, \dots, a_m^T x \leq 1 \\ & x_{k+1} = 0, \dots, x_n = 0 \end{array}$$

Man kann auf diese Weise den Optimalpunkt der  $k$ -ten Stufe dazu verwenden, um die  $(k+1)$ -te Stufe zu starten. Denn dieser Optimalpunkt der  $k$ -ten Stufe liegt auf einer Schattenecke des  $(k+1)$ -ten Problems bei Projektion auf  $\text{Span}(e_{k+1}, v)$ . Man beachte, dass diese beiden Vektoren das Gebot der Unabhängigkeit von den anderen Eingabedaten erfüllen. Deshalb kann man dort wie gehabt den Schatteneckenalgorithmus einsetzen, um das  $(k+1)$ -te Ergebnis zu erhalten. Die letzte Stufe führt uns (wenn nicht vorher schon abgebrochen worden war) zum Optimalpunkt des Hauptproblems. Dadurch, dass man nun  $n$  Stufen durchläuft, schwillt die Oberschranke, die ja alle Schattenecken berücksichtigt, zunächst einmal um einen Faktor  $n$  an.

Man hat nach [7] und [6] folglich für alle Dimensionspaare  $(m, n)$ :

$$EW(\text{Schatteneckenzahl bei Dimensionssteigerung}) \leq m^{\frac{1}{n-1}} \cdot n^3 \cdot \text{Const.}$$

Jedoch kann man zumindest asymptotisch (d.h. bei  $m \gg n$ ) nachweisen, dass der Korrekturbedarf in den höheren Stufen immer kleiner wird. Weil nämlich die Nachbesserung ja nur die letzte Komponente  $v^{k+1}$  der Zielrichtung betrifft, wird nur noch ein mit  $k$  immer kleiner werdender Anteil der vorhandenen Schattenecken für Simplexschritte genutzt, so dass man bei  $m \gg n$  eine Abschätzung folgender Art hat [12]

$$EW(\text{benutzte Anzahl Ecken bei Dimensionssteigerung}) \leq m^{\frac{1}{n-1}} \cdot n^{\frac{5}{2}} \cdot \text{Const.}$$

Es bleibt zu klären, wie man mit Problemen umgeht, bei denen die rechten Seiten  $b^i$  auch negativ sein können und bei denen die  $b^i$  unabhängig von den  $a_i$  gewählt werden. Leider lassen sich unsere Transformationen in den Dualraum und unsere Skalierungen dann nicht mehr direkt durchziehen. Wir können aber einen rigorosen Beweis für folgendes Vorgehen führen.

Löse zunächst mit dem beschriebenen Dimensionssteigerungsalgorithmus das Problem in der (bis jetzt bearbeitbaren) Einheits-Form, also

$$(LP1) \quad \max v^T x \text{ unter } a_i^T x \leq 1 \text{ für } i = 1, \dots, m$$

und bewahre dessen Optimalecke.

Dann können wir durch Einführung einer zusätzlichen Variable  $x^{n+1}$  eine Stufe an den Dimensionssteigerungsalgorithmus anhängen, bei der wir verlangen

$$\max x^{n+1} \text{ unter } a_i^T x + x^{n+1}(1 - b^i) \leq 1 \quad \forall i = 1 \dots m$$

Dies führt zu folgender Beobachtung

- bei  $x^{n+1} = 0$  liegt immer noch das Original mit Restriktionen  $a_i^T x \leq 1$  vor
- bei  $x^{n+1} = 1$  erfüllen wir die Anforderungen des erweiterten Problems mit allgemeinem  $b^i$ .

Das passt aber in unser Schema vom Dimensionssteigerungsalgorithmus als Stufe  $n+1$ . Als letztes soll sich also  $x^{n+1}$  von 0 lösen dürfen. Ist durch Steigerung von  $x^{n+1}$  der Wert 1 nicht erreichbar, dann ist das Originalproblem nicht zulässig. Ist aber durch Steigerung von  $x^{n+1}$  der Wert 1 erreichbar, dann ist man mit  $(x^1, \dots, x^n)$  zulässig. Hat man auch für diese letzte Stufe den Schatteneckenalgorithmus benutzt, dann ist man beim Erreichen von  $x^{n+1} = 1$  gleich beim optimalen  $x$  angelangt.

Eine Verteilungsannahme für die Werte  $b^1, \dots, b^m$ , für die auf diese Art ein Resultat gewonnen wurde, ist z. B.

- $a_1, \dots, a_m$  sowie  $v$  seien nach dem Rotationssymmetrie-Modell verteilt.
- die  $b^1, \dots, b^m$  seien davon und untereinander unabhängig jeweils gleichverteilt auf  $[-1, 1]$ .

Daraus entsteht dann eine Art Zylinderverteilung für die Vektoren  $(a_i, b^i)$  (Rotationssymmetrie in den ersten  $n$  Komponenten, Gleichverteilung in der letzten).

Während für die ersten  $n$  Stufen die obigen Ergebnisse (Rotationssymmetrie) Bestand haben, muss die letzte Stufe wegen ihrer andersartigen Verteilung anders analysiert werden. Aber auch für diese letzte Stufe wurde bestätigt, dass (bei  $m \gg n$ ) gilt [10]

$$EW(\text{durchlaufene Anzahl von Schattenecken}) \leq m^{\frac{1}{n-1}} \cdot n^{\frac{5}{2}} \cdot \text{Const.}$$

Unter Hinzunahme dieser letzten Stufe lassen sich deshalb auch die Probleme mit beliebigen  $b^i$  unter unserem Modell lösen mit einem Gesamtaufwand von

$$EW(\text{Gesamtaufwand}) \leq m^{\frac{1}{n-1}} \cdot n^{\frac{5}{2}} \cdot \text{Const.}$$

Nun wird der Praktiker entgegenhalten: Ich suche mir in einer ersten Phase eine Startecke (das ist irgendwie vergleichbar mit einem Durchlauf des Schatteneckenalgorithmus). Zu dieser so erhaltenen Startecke bestimme ich ein  $u$ , das diese Ecke  $u^T x$ -optimal macht. Danach optimiere ich in Phase II mit dem Schatteneckenalgorithmus die Zielfunktion  $v^T x$ . Da beides vergleichbare Optimierungsprobleme sind, schätze ich den Aufwand hierfür auf ca.  $m^{\frac{1}{n-1}} n^2$ . Obwohl mannigfache Testläufe diese Hypothese irgendwie bestätigen, kann man nicht davon sprechen, dass diese Oberschranke bewiesen wäre. Wir stellen zwei essentielle Verletzungen der Voraussetzungen für den Beweis fest:

- Das vom Praktiker aufgestellte Phase-I-Problem entspricht nicht den Anforderungen des Rotationssymmetrie-Modells.
- Die nachträgliche Bestimmung der Zielrichtung  $u$  aus dem Polarkegel der gewonnenen Startecke (also aus  $\text{Cone}(a_{\Delta^1}, \dots, a_{\Delta^n})$ ) verletzt offensichtlich die essentiellen Unabhängigkeits-Anforderungen an das Problem im Rotationssymmetrie-Modell.

Also befindet man sich hier tatsächlich in einer Situation, wo man – wie angedeutet – einen um einen Faktor  $n^{\frac{1}{2}}$  (bei  $m \gg n$ ) erhöhten Laufzeitbedarf für einen rigorosen Beweis in Kauf nehmen muss.

577 **4 Stochastische Unabhängigkeit der**  
578 **Ungleichungsrichtungen**

579 Parallel zum Rotationssymmetriemodell wurde ein gänzlich  
580 verschiedenes Modell, das Umklapp-Modell (Sign-  
581 Invariance-Modell) für Average-Case-Analysen herange-  
582 zogen [1, 2, 11, 14, 17].

583 Hier unterstellt man, dass der Zielvektor  $v$  und die Re-  
584 striktionsvektoren  $a_1, \dots, a_m$  zunächst einmal festgelegt  
585 sind (mit der kleinen Einschränkung der Nichtentartung).  
586 Nun besteht die Variation der Probleme darin, dass für  
587 jede Restriktionsungleichung und unabhängig voneinan-  
588 der entschieden wird, ob diese Restriktion von der Form  
589  $a_i^T x \leq b^i$  oder  $a_i^T x \geq b^i$  sein soll. Beide Versionen sol-  
590 len mit Wahrscheinlichkeit  $\frac{1}{2}$  auftreten. Die untersuchten  
591 und zu lösenden Probleme sind also von der Art

592 maximiere  $v^T x$   
593 unter  $a_1^T x \leq b^1, \dots, a_m^T x \leq b^m$   
sowie  $P(\leq) = \frac{1}{2} = P(\geq)$  für jede Einzelrestriktion.

594 Auf diese Weise generiert eine Festlegung der Restrikti-  
595 onsvektoren schon  $2^m$  gleichberechtigte Partnerproble-  
596 me. Bei der Average-Case Analyse werden jetzt fiktiv alle  
597 diese Probleme gelöst, ihre Schrittzahlen werden aufadi-  
598 diert und danach wird durch  $2^m$  geteilt.

599 Bestechend an diesem Ansatz ist die Tatsache, dass (so-  
600 lange die  $a_i$  nichtentartet festgelegt wurden) sich für je-  
601 de Festlegung der gleiche Mittelwert ergibt: Man erspart  
602 sich also hier alle Berücksichtigungen der Variation die-  
603 ser  $a_i, b^i$ . Diese angesprochene Gleichheit ist eine Folge  
604 der altbekannten Ergebnisse von Buck über Hyperebene-  
605 nenarrangements im  $\mathbb{R}^n$ . Danach ergibt sich bei Vorga-  
606 be von  $m$  Hyperebenen (nichtentartet) eine Partition des  
607 Raumes in Zellen, deren Anzahl immer gleich ist, nämlich  
608  $\binom{m}{0} + \binom{m}{1} + \binom{m}{2} + \dots + \binom{m}{n}$  [8].


609 Diese Zellen entsprechen genau denjenigen Umklapp-  
610 Probleminstanzen (unter den  $2^m$  möglichen), die über-  
611 haupt zulässige Punkte  $x$  besitzen. Man beachte aber, dass  
612  $\binom{m}{0} + \binom{m}{1} + \dots + \binom{m}{n} \leq 2^m$  bei  $m \geq n$  und dass der  
613 Quotient

$$\frac{1}{2^m} \cdot \left[ \binom{m}{0} + \dots + \binom{m}{n} \right]$$

614 dramatisch gegen 0 driftet, wenn bei festem  $n$  die Re-  
615 striktionszahl  $m$  gegen  $\infty$  geht.


616 Dies bedeutet, dass allein schon bedingt durch das ange-  
617 setzte stochastische Modell nur in einem verschwindend  
618 kleinen Anteil der Probleminstanzen überhaupt noch eine  
619 Phase II stattfindet.

620 Der entsprechende Effekt wird auch noch dann erzielt,  
621 wenn man auf die zulässigen Probleme konditioniert.  
622 Denn es lässt sich zeigen, dass die Gesamtzahl der Ecken



Bei 5 Hyperebenen entstehen 16 Zellen. Wenn die Ausrichtungen alle passen, wird eine Zelle zulässig.

623



Dreht man bei einer vorher redundanten Restriktion die Ausrichtung um, dann gibt es gar keine Zulässigkeit mehr.

624

625 aller Zellen nicht größer ist als  $2^n \binom{m}{n}$ . Dann entwickelt  
626 sich die Relation

$$\frac{2^n \binom{m}{n}}{\binom{m}{0} + \binom{m}{1} + \dots + \binom{m}{n}}$$

627 und dies wird auch klein bei  $m \gg n$ .

628 Der Grund hierfür liegt im Wesentlichen in der Tatsache  
629 begründet, dass bei  $m \gg n$  eine zusätzliche Hyperebene  
630 eine vorher bestehende Zelle zumeist verfehlt, also  
631 nicht mehr teilt. Dann gibt es in diesem Fall zwei gleich-  
632 wahrscheinliche Möglichkeiten aufgrund der Ausrichtung  
633 dieser Restriktion

634 – die Zulässigkeit dieser Zelle wird vernichtet,

635 – die Zelle bleibt zulässig und komplett unverseht (die  
636 neue Hyperebene hat also nichts zur Eckenvermehrung  
637 bei dieser Zelle und insgesamt beigetragen).

638 So weit hat unser stochastisches Modell also die Zeichen  
639 bereits gesetzt. Man beachte: wir haben bisher noch gar  
640 nicht festgelegt, welche Variante des Simplexalgorithmus  
641 eingesetzt wird.

642 Auch hier erwies sich der Schatteneckenalgorithmus als  
643 einzige auswertbare Option.

Es ergab sich als Resultat der Mittelwertbildung über die in Phase II (der Optimierungsphase) durchgeführten Pivotschritte (= Zahl der Schattenecken) ein Durchschnitt von nicht mehr als  $n$  Schritten pro zulässiger Zelle [1, 2, 11, 17].

646 Noch haben wir aber nicht erörtert, wie man jeweils eine  
647 Startecke (in Phase I) findet. Dazu haben [1, 2] einen  
648 sogenannten *Constraint-By-Constraint-Algorithmus* eingesetzt.  
649

650 Dieser Algorithmus verläuft in  $m-n$  Stufen. In jeder Stufe  
651 wird dafür gesorgt, dass eine weitere Restriktion erfüllt  
652 ist. Zur Erklärung seien gerade die  $\leq$ -Richtungen aktuell.

653 Zunächst sind nur  $n$  Restriktionen erfüllt, wir agieren also  
654 auf  $X^{(n)} = \{x \mid a_1^T x \leq b^1, \dots, a_n^T x \leq b^n\}$ .

655 Nun versucht man ausgehend von der einzigen Ecke von  
656  $X^{(n)}$  die Restriktion  $a_{n+1}^T x \leq b^{n+1}$  auch noch einzuhalten.  
657 Ist dies nicht erreichbar, dann kann man schon wegen  
658 Unzulässigkeit abbrechen.

659 Andernfalls gehen wir zur nächsten Restriktion über und  
660 wiederholen das Verfahren.

661 So wird also in  $X^{(k)} = \{x \mid a_1^T x \leq b^1, \dots, a_k^T x \leq b^k\}$  in  
662 Zielrichtung  $a_{k+1}$  minimiert, bis  $a_{k+1}^T x \leq b^k$  erreicht ist.

663 Bezeichnend ist, dass dazu in jeder Stufe der parametrische  
664 Algorithmus eingesetzt wird. Ausgehend von einer  
665 einmal geschickt lexikographisch gewählten Zielrichtung  
666  $u \in \text{Cone}(a_1, \dots, a_n)$ , die an der einzigen Ecke von  $X^{(n)}$   
667 optimiert wird, und mit Hilfe der Zielrichtung  $a_{k+1}$  kann  
668 dann für jede Stufe eine Schatten-Projektionsebene festgelegt  
669 und damit jeweils der Schatteneckenalgorithmus eingesetzt  
670 werden.

671 Man nutzt hier die Cooptimalitätseigenschaft des parametrischen  
672 Algorithmus aus. Dies bedeutet, dass für jedes erreichte Niveau bzgl.  
673  $a_i^T x$  der auf dem Schatteneckenpfad erreichte Punkt den besten  
674  $u^T x$ -Wert aufweist.

675 Deshalb erreicht dieses Verfahren also im Fall der Zulässigkeit  
676 gleich die  $u^T x$ -optimale Ecke von  $X^{(m)} = P(A, b)$ .  
677 Und von dort aus kann die Phase II starten. Im Fall der  
678 Unzulässigkeit bricht eine der Stufen ab.

In [1, 2] konnten die Autoren so nachweisen, dass auf diese Weise der Gesamtaufwand im Erwartungswert die Schranke von  $2(n+1)^2$  nicht überschreitet.

681 Also verhindert hier eigentlich das Modell (und nicht die  
682 Qualität des Algorithmus) das Anwachsen der Schrittzahlen mit  $m$ .  
683 Die Autoren konstatieren: „These results cannot show a good  
684 behaviour of the algorithm for  $m \gg n$ ,

685 but they are a consequence of the stochastic model per se“ [1].  
686

687 Ein anderer interessanter Aspekt ist aber bei diesem Modell  
688 zu beobachten (ganz im Gegensatz zum Rotations-symmetrie-Modell).  
689 Hier sind nämlich die Ereignisse

690 –  $a_1, \dots, a_n$  definieren über  $a_1^T x = b^1, \dots, a_n^T x = b^n$  eine  
691 Ecke von  $X^m = P(A, b)$

692 – der Polarkegel dieser Basislösung enthält die Zielrichtung  
693  $u$ , also  $u \in \text{Cone}(a_1, \dots, a_n)$

694 tatsächlich stochastisch unabhängig voneinander (denn  
695 hier liegen  $a_1, \dots, a_n$  ja von vornherein fest).

696 Hat man nämlich  $\bar{x}$  ermittelt als Lösung von  $a_1^T \bar{x} = b^1, \dots, a_n^T \bar{x} = b^n$ ,  
697 dann ist für die Eigenschaft der Basislösung unwichtig, ob  
698  $a_i^T \bar{x} \leq b^i$  oder  $a_i^T \bar{x} \geq b^i$  ( $i \leq n$ ) gefordert wurde.  
699

700 Nun aber entscheiden über die primale Zulässigkeit von  $\bar{x}$   
701 die Ausrichtungen der restlichen Ungleichungen, nämlich  
702  $a_i^T \bar{x} \leq b^i$  oder  $a_i^T \bar{x} \geq b^i$  für  $i = n+1, \dots, m$ . Um aber zu  
703 wissen, ob diese Basislösung dual zulässig ist, muss man  
704 für eine Richtung  $v$  (die Zielrichtung) wissen, ob sie im  
705 Polarkegel von  $\bar{x}$  liegt. Dieser hat formal die Beschreibung  
706  $\text{Cone}(\pm a_1, \dots, \pm a_n)$ , wobei  $+$  zu wählen ist bei Ausrichtung  
707  $\leq$  und  $-$  bei Ausrichtung  $\geq$ . Da im Nichtentartungsfall  
708 genau eine Ausrichtungskombination zum Erfolg führt, entscheiden  
709 also die Ausrichtungen zu  $a_1, \dots, a_n$  über die duale  
710 Zulässigkeit. Dagegen wird über die primale Zulässigkeit von  
711 den Ausrichtungen zu  $a_{n+1}, \dots, a_m$  entschieden. Die  
712 Definition des Modells sorgt dann für die stochastische  
713 Unabhängigkeit, da ja die Ausrichtungen unabhängig voneinander  
714 zu wählen sind.

## 715 5 Glättungsanalyse des Simplexverfahrens

716 Anfang des neuen Jahrhunderts kam eine ganz andere  
717 artige Philosophie oder Sicht der Dinge bezüglich der  
718 normalen Laufzeit-Bewertung auf. Unter dem Namen  
719 „Smoothed Analysis“ (Glättungsanalyse) sollte die folgende  
720 Frage geklärt werden:

721 Wenn alle Daten des Problems (also  $a_1, \dots, a_m$ ) geringfügig  
722 Gauß-verteilt gestört werden und das Problem jeweils unter  
723 allen solchen Störungskonstellationen gelöst würde, wird sich  
724 dann eine signifikante Glättung ergeben? Das heißt, werden  
725 diese Erwartungswerte erkennbar tiefer liegen als die extrem  
726 hohen Aufwandswerte, die man bei festen Problemen in Kauf  
727 nehmen muss (Klee-Minty-Probleme)? Wenn man will, kann man  
728 dies als eine andere Art von Average-Case-Analyse ansehen.  
729


730 Eigentlich zu lösen ist also das feste Originalproblem

$$\begin{array}{ll} \text{maximiere} & \bar{v}^T x \\ (\overline{LP}) \text{ unter} & \bar{a}_1^T x \leq \bar{b}^1, \dots, \bar{a}_m^T x \leq \bar{b}^m \\ \text{mit} & \bar{a}_1, \dots, \bar{a}_m \in \mathbb{R}^n, \bar{b}^1, \dots, \bar{b}^m \in \mathbb{R}. \end{array}$$


731 Nun sollen an den Vektoren  $\bar{a}_1, \dots, \bar{a}_m$  und an den  $\bar{b}^i$   
732 Störungen der Form  $N(\bar{a}_i, \sigma)$  (also normal verteilt um  
733  $\bar{a}_i$  bzw.  $\bar{b}^i$  mit Streuung  $\sigma$ ) angebracht werden, so dass  
734 jeweils tatsächlich gelöst wird

735 maximiere  $\bar{v}^T x$   
 736 unter  $a_1^T x \leq b^1, \dots, a_m^T x \leq b^m$   
 mit  $(a_i, b^i) \in N((\bar{a}_i, \bar{b}^i), \sigma)$ .


737 Der erwartete Aufwand, der bei dieser Art Mittelung  
 738 entsteht, orientiert sich also nicht mehr an einer Gesamt-  
 739 verteilung, sondern konkret an diesem festen Original-  
 740 problem. Es besteht die Hoffnung, dass man mit gering-  
 741



Bei einzelnen Problemen ergeben sich extreme Ausschläge der Rechenzeit.



Eine Average-Case Analyse ergibt einen Mittelwert über dem ganzen Raum der Probleme.



Die Glättungsanalyse mittelt in der Nähe eines jeden Festproblems und behebt so die extremen Ausschläge.

743 ffüg wachsendem  $\sigma$  schon die extremen Ausschläge von  
 744 Festproblemen vermeiden (besänftigen) kann. Und man  
 745 hofft, dass für diesen Glättungseffekt eine gleichmäßige  
 746 Obergrenze für alle Originalprobleme gefunden wer-  
 747 den kann. Es ist deshalb angemessen und unvermeidlich,  
 748 dass man bei der Gütemessung der Glättung neben den  
 749 üblichen Dimensionen  $m$  und  $n$  auch die Störungsinten-  
 750 sität einbezieht. Dies sollte konsequenterweise mit  $\sigma^{-1}$ ,  
 751 also indirekt proportional zur Streuung geschehen. Die  
 752 Verfechter dieser Sicht auf die Bewertung der Algorith-  
 753 muslaufzeit führen folgende Argumente ins Feld:

- 754 – Im Gesamtbereich aller Problemstellungen wird der  
 755 einzelne Anwender es oft mit einem oder einzelnen  
 756 Typen zu tun haben. Viele denkbare Problemstellun-  
 757 gen bzw. Datensetzungen haben keinen realen Anwen-  
 758 dungshintergrund (auch wenn eine Abgrenzung zwis-  
 759 chen realen und fiktiven nicht möglich ist).
- 760 – Das eigentlich gleiche Problem wird oft mit unter-  
 761 schiedlicher Technologie und unterschiedlicher Model-  
 762 lierungsgenauigkeit gelöst bzw. beschrieben.
- 763 – Es soll vermieden werden, dass die Effekte bei „ernst-  
 764 zunehmenden“ realen Problemstellungen ausgeglichen  
 765 oder verwässert werden durch fiktive Probleme, die  
 766 rein aus Verteilungs- oder Symmetriegründen den ers-  
 767 ten formal gleichgestellt sind.

768 Die Basis für alle im Folgenden besprochenen Aufwands-  
 769 untersuchungen für die Lösung des Gesamtproblems bil-  
 770 det das Fundamentaltheorem, das eine Obergrenze da-  
 771 für angibt, wie viele Ecken des Zufallspolyeders  $\{x \mid$   
 772  $Ax \leq 1\}$  bei Projektion auf eine (wirklich feste) Ebene  
 773  $\text{Span}(\bar{u}, \bar{v})$  zu Ecken des Bildes dieser Projektion werden.  
 774 Also sind wir wieder bei der Anzahl der Schattenecken.

**Fundamentaltheorem bei Glättung [15, 16]**  
 Seien alle  $\bar{a}_i$  von der Norm  $\|\bar{a}_i\| \leq 1$  und alle  $\bar{b}^i = 1$ .  
 Dann ist der Erwartungswert der Schatteneckenanzahl  
 bei Projektion auf  $\text{Span}(\bar{u}, \bar{v})$  durch  $D(m, n, \sigma)$   
 775 gleichmäßig nach oben beschränkt, wobei

$$D(m, n, \sigma) := \frac{(58.888.678) \cdot m \cdot n^3}{\left[ \text{Min} \left\{ \sigma, \frac{1}{3\sqrt{n \ln m}} \right\} \right]^6}.$$

776  
 777 Setzt man beispielsweise  $\sigma$  so an, dass sich im Nenner  
 778 Gleichheit der beiden Größen in der Minimierungsklam-  
 779 mer ergibt, dann hat man  $D(m, n, \sigma) \approx \text{Const.} \cdot mn^3 \cdot$   
 780  $n^3 \cdot (\ln m)^3$ .

781 Die Herleitung dieses Ergebnisses ist enorm kompliziert  
 782 und spielt in immenser Weise mit dem Instrumentarium  
 783 der Eigenschaften von verknüpften und approximierten  
 784 Normalverteilungen. Eine Verdeutlichung davon kann da-  
 785 her hier nicht vorgenommen werden.

786 Die einschränkende Bedingung  $\|\bar{a}_i\| \leq 1$  erweist sich bei  
 787 der Algorithmusanalyse als sehr hinderlich, weil man ja ei-  
 788 ne gleichmäßige Obergrenze für alle Probleme und alle  
 789 Spielarten der  $a_i$  sucht. Jedoch lassen sich nach diesbe-  
 790 züglicher Relaxierung durch Skalierung auch noch dann

791 Beschränkungen retten, wenn die obige Bedingung ver-  
 792 letzt ist. Allerdings fallen dann die Oberschranken ent-  
 793 sprechend höher aus. Erlaubt man auch höhere Normen  
 794 der  $\bar{a}_i$ , dann ist in obiger Formel  $\sigma$  zu ersetzen durch

$$\frac{\sigma}{\text{Max}\{\|\bar{a}_i\| \mid i = 1, \dots, m\}}.$$

795 Erlaubt man auch Vektorenmengen  $\{a_1, \dots, a_m\}$ , die mit  
 796 unterschiedlichen Covarianzmatrizen  $M_i$  verteilt sind,  
 797 dann braucht man zur grundsätzlichen Erhaltung der obigen  
 798 Abschätzung, dass die Eigenwerte der  $M_i$  zwischen  
 799  $\sigma^2$  und  $\frac{1}{9n \cdot \ln m}$  liegen. Erlaubt man, dass die  $b^i$  positiv  
 800 bleiben, aber von 1 abweichen, dann ist  $\sigma$  nun zu erset-  
 801 zen durch die (nun noch kleinere) Größe

$$\frac{\sigma \cdot \text{Min}\{b^1, \dots, b^n\}}{\text{Max}\{\|a_1\|, \dots, \|a_m\|\} \cdot \text{Max}\{b^1, \dots, b^m\}}$$

802 Wie zu erkennen ist, treibt jede Relaxierung der Vor-  
 803 aussetzungen aus dem Fundamentaltheorem die Ober-  
 804 schranken nach oben. Und da eine gleichmäßige Ober-  
 805 schranke angestrebt wird, muss man alle denkbaren Kon-  
 806 stellationen abdecken. Außerdem ergeben sich die be-  
 807 schriebenen „Überschreitungen“ selbst aus günstigen An-  
 808 fangsdaten, wenn man zur Algorithmusanalyse des Pha-  
 809 senwechsels bzw. des Gesamtalgorithmus kommt.

810 Betrachten wir nun die Problem-Gesamtbearbeitung und  
 811 deren Analyse unter Zuhilfenahme des Fundamentaltheo-  
 812 rems. Denn dazu braucht man zunächst eine Startecke  
 813 und dazu ein festes  $\bar{u}$ . Im Gegensatz zum früher beschrie-  
 814 benen Dimensionssteigerungsalgorithmus kommt man in  
 815 diesem Fall nicht automatisch an der  $\bar{u}$ -optimalen Ecke  
 816 vorbei und kann auch nicht mehr davon ausgehen, dass  
 817 die Ankunftsecke nach Phase I unabhängig von  $(A, b)$   
 818 ist – es ist nicht einmal mehr selbstverständlich, dass  
 819 die erzeugten Störungen dieser Ankunftsecke nach Ab-  
 820 schluss der Phase I dem normalverteilten Störungsbild  
 821 entsprechen, wie es im Fundamentaltheorem von den  
 822 Daten verlangt wird. So wird  $u$  auch noch abhängig  
 823 von  $a_1, \dots, a_n$ , da die  $a_1, \dots, a_n$  ja stochastisch zum Wa-  
 824 ckeln gebracht werden. Es kann z. B. geschehen, dass  
 825  $\bar{u} \in \text{Cone}(\bar{a}_1, \dots, \bar{a}_n)$ , aber  $u \notin \text{Cone}(a_1, \dots, a_n)$ .

826 Natürlich könnte man sich, ausgehend von der Phase-I-  
 827 Ecke, durch Optimierung von  $\bar{u}^T x$  die „richtige“ Starte-  
 828 cke besorgen. Dies hätte die Problematik aber nur von  
 829  $\bar{v}^T x$  auf  $\bar{u}^T x$  verlagert.

830 Deshalb bereinigen Spielman und Teng die obigen Kom-  
 831 plikationen durch angemessene Erhöhung ihrer Ober-  
 832 schranken. Um einen analysierbaren Lösungsalgorithmus  
 833 zu bekommen, werden zwei Schritte ausgeführt. Zu-  
 834 nächst wird ein zulässiges Hilfsproblem künstlich so kon-  
 835 struiert, dass man für eine gewünschte Indexmenge (z. B.  
 836  $\Delta = \{1, \dots, n\}$ ) mit Hilfe der Restriktionen  $a_1, \dots, a_n$  eine  
 837 Startecke erhält. Da  $\Delta$  in aller Regel von vornherein  
 838 noch keine Ecke liefert, werden alle anderen Restriktio-  
 839 nen  $a_{n+1}^T x \leq b^{n+1}, \dots, a_m^T x \leq b^m$  relaxiert, d. h. ihre  
 840 Oberbegrenzungen werden erhöht oder die  $a_j$  werden

841 skaliert. Die künstlichen  $b^i$  werden positiv gewählt, um  
 842 vom Fundamentaltheorem profitieren zu können.

843 Weil die notwendige Stärke dieser Relaxierungen von  
 844 vornherein nicht bekannt ist, werden hierzu vorsichti-  
 845 gerweise Größen verwendet, die aus den Eigenwerten/  
 846 Konditionszahlen der Ausgangsmatrix entnommen wer-  
 847 den können, was wiederum die Oberschranken anhebt.

848 In einem ersten Schritt löst man dieses eben geschaffene  
 849 Hilfsproblem, bedenkt aber, dass eigentlich das Haupt-  
 850 problem (evtl. auch mit negativen  $b^i$ ) zu lösen wäre.  
 851 Unbeschränktheit – auch für das Hauptproblem – wird  
 852 schon in diesem ersten Schritt sichtbar.

853 Nun parametrisiert / interpoliert man zwischen den re-  
 854 laxierten Versionen der  $a_i, b^i$  mit positiven  $b^i$  und den  
 855 originalen Versionen. Auch dafür eignet sich der parame-  
 856 trische Algorithmus (in einer dualen Form). (Dies ent-  
 857 spricht der Vorgehensweise, die schon am Ende von Ka-  
 858 pitel 3 beschrieben worden war). Vorteilhaft dafür ist,  
 859 dass auf diese Weise das Fundamentaltheorem greift.  
 860 Dies ist dann der zweite Schritt, der die Originallösung  
 861 liefert.

862 Hierbei hing im ersten Schritt zwar nicht die Zielrichtung  
 863  $v$ , wohl aber die Anfangsrichtung  $u$  von  $(A, b)$  ab. Im Ge-  
 864 gensatz dazu entspricht der zweite Schritt durchaus den  
 865 Anforderungen des Fundamentaltheorems. Jedoch führen  
 866 die Skalierungen im ersten Schritt und der Phasenwech-  
 867 sel zum Anschwellen der Schranken aus dem Fundamen-  
 868 taltheorem. Auch das Wackeln von  $u$  lässt sich auffangen,  
 869 aber dazu müssen wiederum die Schwellen angehoben  
 870 werden.

871 Als Alternative zu diesem mehrmaligen Schranken-Heben  
 872 käme auch eine Randomisierung in Frage. Die Hoffnung  
 873 ist dabei, dass man hier nur die Schranke so weit wie  
 874 nötig anheben muss. Insbesondere legt man sich hier  
 875 nicht auf eine Wunschbasis wie  $a_1, \dots, a_n$  fest, sondern  
 876 probiert eine (komplexitätstheoretisch noch vertretbare)  
 877 Vielzahl von Anfangsbasen aus. Davon verwendet man  
 878 diejenige, die die geringste Erhöhung der Schranken ver-  
 879 ursachen würde. Es wird dabei stochastisch ausgenutzt,  
 880 dass durch das Wackeln der Vektoren  $a_i$  (im Gegensatz  
 881 zu den festen  $\bar{a}_i$ ) eine relativ hohe Wahrscheinlichkeit da-  
 882 für besteht, dass der kleinste Eigenwert der  $A$ -Teilmatrix  
 883 von 0 erkennbar abweicht und dass die Konditionszahl  
 884 relativ harmlos wird. Schließlich werden auch die  $b^i$  be-  
 885 liebig aus  $\mathbb{R}$  gewählt und gestört. Legt man die Ergebnisse  
 886 der stochastischen Glättungsanalyse alle betont pessimis-  
 887 tisch aus (also so, dass alle Oberschrankenerhöhungen  
 888 notwendig sind), dann kommt Vershynin für die Spielman-  
 889 Teng-Laufzeitschranke auf eine Größenordnung von

$$m^{86} n^{55} \sigma^{-30}.$$

890 Vershynin hat in [18] die Abschätzungsmethodik für sein  
 891 Fundamentaltheorem neu gestaltet. Darin erreicht er für  
 892  $\sigma \leq \frac{1}{6\sqrt{n \ln m}}$  eine Oberschranke von  $Cd^3\sigma^{-4}$ .  
 893 Zusätzlich hat er die Algorithmusdurchführung modifi-  
 894 ziert. Zunächst einmal werden die Übergänge vom Hilfs-

895 problem zum Originalproblem so gestaltet, dass die pa-  
 896 rametrische Interpolation simultan auf die Zielfunktion  
 897 und auf die rechten Seiten  $b^i$  zugreift. Die Variation der  
 898 rechten Seite wird dabei aufgefangen durch eine zusätzli-  
 899 che Variable. Man vermeidet dadurch Verzerrungen von  
 900 gaußverteilten Störungen beim Phasenwechsel.

901 Um das Startproblem in den Griff zu bekommen, geht  
 902 Vershynin einen anderen Weg als Spielman/Teng. Er ver-  
 903 zichtet auf die Auswahl einer Wunschbasis und damit  
 904 auch auf die Relaxierung der restlichen Restriktionen.  
 905 Stattdessen fügt er  $n$  Restriktionen

$$906 \quad a_{m+1}^T x \leq b^{m+1}, \dots, a_{m+n}^T x \leq b^{m+n}$$

907 hinzu und macht diese so restriktiv, dass diese eine Ecke  
 908 generieren. Diese Ecke dient als Startecke und das Bari-  
 909 zentrum dieser Vektoren wird die Startrichtung  $\bar{u}$ . Von  
 910 dieser fiktiven Ecke aus wird nun der parametrische Al-  
 911 gorithmus gestartet.

912 Man gelangt dann zu einer Optimal- oder Abbruch-  
 913 checke. Diese aus dem modifizierten Problem gewonnene Ab-  
 914 bruchchecke wird dann daraufhin überprüft, ob sie nichts  
 915 mehr mit den künstlichen (hinzugefügten) Restriktionen  
 916 zu tun hat (ob diese also dort alle locker sind). Ist dies  
 917 der Fall, dann ist das Problem ja gelöst.

918 Andernfalls (also wenn die erreichte Abbruchchecke noch  
 919 straffe hinzugefügte Restriktionen impliziert) muss der  
 920 Lösungsprozess als misslungener Test verworfen werden.  
 921 Nun wird ein erneuter Test durchgeführt, mit anders ge-  
 922 wählten Vektoren  $a_{m+1}, \dots, a_{m+n}$ . Um zu erreichen und  
 923 um zu zeigen, dass diese Tests nicht oft scheitern, geht er  
 924 wie folgt vor:

925 Er bestimmt gleichverteilt über der Einheitskugel eine  
 926 Richtung  $\tilde{u}$ . Nun bestimmt er  $a_{m+1}, \dots, a_{m+n}$  so, dass  
 927  $\|a_i - \tilde{u}\|$  für alle  $i$  sehr klein ist und dass gilt  $\tilde{u} \in$   
 928  $\text{Cone}(a_{m+1}, \dots, a_{m+n})$ . Zum Nachweis der Erfolgswahr-  
 929 scheinlichkeit betrachtet er den sogenannten *numbset* des  
 930 Problems. Dieser besteht aus dem Bereich/Anteil der  
 931 Einheitskugel, in den man Restriktionen hinzufügen kann,  
 932 ohne dass dies auf das Ergebnis Einfluss haben würde. Es  
 933 ist klar, dass dieser *numbset* immer mindestens die Häl-  
 934 fte der Einheitskugel umfasst (er enthält einen Halbraum).  
 935 Man kann also sicher sein, dass man mit Wahrscheinlich-  
 936 keit nahe bei  $\frac{1}{2}$  alle  $a_{m+i}$  im *numbset* untergebracht hat.

937 Und dies würde zum Erfolg des Tests führen: Eine tat-  
 938 sächliche Unterschranke dafür, dass all diese Vektoren im  
 939 *numbset* liegen, ist  $P = \frac{1}{4}$ .

940 Wiederholt man diese Prozedur, so ergibt sich eine  
 941 Oberschranke für die erwartete Anzahl der nötigen Test-  
 942 läufe (in diesem Falle 4). Somit wurde ein randomi-  
 943 sierter Algorithmus eingesetzt, der (im schlechten Fal-  
 944 le) nicht funktionieren muss, dessen nachhaltige Wie-  
 945 derholung aber mit hoher Wahrscheinlichkeit zum Ziel  
 946 führt. Dadurch, dass es hier zu weniger Systembrüchen  
 947 (Phasenwechseln) und zu weniger Verteilungsanpassun-  
 948 gen kommt, verläuft hier die Kombination der verschie-  
 949 denen Gaußanalysen und die Anwendung des Fundamen-  
 950 taltheorems über Zusatzabschätzungen viel harmloser.

#### Satz [18]

Für diesen beschriebenen randomisierten Algorithmus gilt eine gleichmäßige Oberschranke von der Größenordnung

$$952 \quad O(\ln^2 m \cdot \ln(\ln m)(n^3 \sigma^{-4} + n^5 \ln^2 m + n^9 \ln^4 n)).$$

953 Hier hat man angesichts der Aufgabenstellung die Rando-  
 954 misierung akzeptiert.

955 Ohne Randomisierung (dafür aber mit Hilfe des umständ-  
 956 licheren Dimensionssteigerungsalgorithmus) hat Emanuel  
 957 Schnalzer aufbauend auf den Ergebnissen von Spielman  
 958 & Teng sowie von Vershynin nachweisen können, dass mit  
 959 diesem Algorithmus ein erwarteter geglätteter Aufwand  
 960 von

$$\text{Const} \left( \frac{1}{\sigma^2} + \frac{(n+1)^4}{\sigma^4} + (\ln m)^2 (n+1)^6 \right)$$

961 verbunden ist [13].

962 Diskutabel ist nun, ob man neben Datenzufälligkeit auch  
 963 noch Verfahrenszufälligkeit (Randomisierung) akzeptiert.

964 Und hier schließt sich der Kreis: Was wollte ich eigentlich  
 965 – was soll ich – was kann ich?

#### 966 Literatur

- 967 [1] Adler, I., R. M. Karp, R. Shamir (1987). A Simplex Variant Solving an  $m \times d$  Linear Program in  $O(\min(m^2, d^2))$  Expected Number of Steps. *Journal of Complexity* **3** 372–387.
- 968 [2] Adler, I., N. Megiddo (1985). A Simplex Algorithm where the Average Number of Steps is Bounded Between two Quadratic Functions of the Smaller Dimension. *Journal of the ACM* **32** 871–895.
- 969 [3] Borgwardt, K.H.(1977). *Untersuchungen zur Asymptotik der mittleren Schrittzahl von Simplexverfahren in der linearen Optimierung*, Dissertation Universität Kaiserslautern.
- 970 [4] Borgwardt, K.H.(1982a). Some Distribution-Independent Results About the Asymptotic Order of the Average Number of Pivot Steps of the Simplex Method. *Mathematics of Operations Research* **7** 441–462.
- 971 [5] Borgwardt, K.H.(1982b). The Average Number of Pivot Steps Required by the Simplex-Method is Polynomial. *Zeitschrift für Operations Research* **26** 157–177.
- 972 [6] Borgwardt, K.H. (1987). *The Simplex Method, A Probabilistic Analysis*, Springer Verlag, Heidelberg.
- 973 [7] Borgwardt, K.H. (1999). A sharp upper bound for the expected number of shadow-vertices in LP-polyhedra under orthogonal projection on two-dimensional planes, In *Mathematics of Operations Research*, Vol.24, Nr. 4, 925–984
- 974 [8] Buck, R.C. (1943). Partition of Space, In *American Mathematical Monthly* **50** 541–544
- 975 [9] Gass, S. & Saaty, Th. (1955). The Computational Algorithm for the Parametric Objective Function, *Naval Research Logistics, Quarterly* **2**, 39–45
- 976 [10] Göhl, M. (2013). Der durchschnittliche Rechenaufwand des Simplexverfahrens unter einem verallgemeinerten Rotations-symmetrie-Modell, Dissertation, Universität Augsburg.
- 977 [11] Haimovich, M.(1983). *The Simplex Algorithm is Very Good! - On the Expected Number of Pivot Steps and Related Properties of Random Linear Programs*. Report Columbia University, New York.

- 1002 [12] Höfner, G. (1995). *Lineare Optimierung mit dem Schatteneckenal-*  
 1003 *gorithmus – Untersuchungen zum mittleren Rechenaufwand und*  
 1004 *Entartungsverhalten*, Dissertation Universität Augsburg.
- 1005 [13] Schnalzer, E. (2014). Interner Report Universität Augsburg:  
 1006 *Smoothed Analysis des Dimensionssteigerungsalgorithmus*.
- 1007 [14] Smale, S. (1983). On the Average Speed of the Simplex Method  
 1008 of Linear Programming. *Mathematical Programming* **27** 241–262.
- 1009 [15] Spielman, D. & Tng, Sh.H. (2004). Smoothed Analysis of Al-  
 1010 gorithms: Why the Simplex Algorithm usually takes Polynomial  
 1011 Time, In *Journal of the ACM* **51** (3), 385–463.
- 1012 [16] Spielman, D. & Tng, Sh.H. (2008). Smoothed Analysis of Al-  
 1013 gorithms: Why the Simplex Algorithm usually takes Polynomial  
 1014 Time, 7. Version, Februar 2008, Report.
- 1015 [17] Todd, M.J. (1986). Polynomial Expected Behavior of a Pivoting  
 1016 Algorithm for Linear Complementarity and Linear Program-  
 1017 ming Problems. *Mathematical Programming* **35** 173–192.
- 1018 [18] Vershynin, R. (2009). Beyond Hirsch conjecture: walls on ran-  
 1019 dom polytopes and smoothed complexity of the simplex meth-  
 1020 od, In *SIAM Journal on Computing* **39**(2), 646–678.

1021 Prof. Dr. Karl Heinz Borgwardt, Lehrstuhl für Diskrete Mathema-  
 1022 tik, Optimierung und Operations Research, Institut für Mathema-  
 1023 tik, Universität Augsburg, 86135 Augsburg  
 1024 borgwardt@math.uni-augsburg.de

1025 1949 in Landstuhl/Pfalz geboren, Studium  
 1026 der Mathematik und Betriebswirtschaftslehre  
 1027 in Saarbrücken, 1973–1979 Wissenschaftlicher  
 1028 Mitarbeiter an der TU Kaiserslautern dort Pro-  
 1029 motion 1977 und Habilitation 1985. 1979–1984  
 1030 Planungsabteilung der Deutsche Bank AG Zen-  
 1031 trale (Frankfurt), 1982 Lanchester Prize für  
 1032 den Nachweis der Polynomialität der mittleren  
 1033 Schrittzahl beim Simplexverfahren, 1984–2014 Professor für Opti-  
 1034 mierung und Operations Research am Institut für Mathematik der  
 1035 Universität Augsburg. Forschungsgebiete: Probabilistische Analyse  
 1036 von Algorithmen, Lineare Optimierung, Heuristiken, Stochastische  
 1037 Polyedertheorie



**ETH**

Eidgenössische Technische Hochschule Zürich  
 Swiss Federal Institute of Technology Zurich

## Professor of Insurance Mathematics

The Department of Mathematics (www.math.ethz.ch) at ETH Zurich invites applications for a full professor position in Insurance Mathematics.

We are seeking candidates with an internationally recognized research record and with proven ability to direct research of highest quality in the field of insurance mathematics including mathematical finance or mathematical economics. We expect the successful candidate to integrate scientifically into the Department as well as to take a leading role in communication between academia, insurance and financial industry.

The successful candidate is expected to lead the education program for actuarial mathematics at ETH Zurich and will be expected to teach undergraduate level courses (mainly German) and graduate level courses (English).

**Please apply online at  
 www.facultyaffairs.ethz.ch**

Applications should include a curriculum vitae, a list of publications, and a statement of future research and teaching interests. The letter of application should be addressed **to the President of ETH Zurich, Prof. Dr. Ralph Eichler. The closing date for applications is 15 September 2014.** ETH Zurich is an equal opportunity and family friendly employer and is further responsive to the needs of dual career couples. We specifically encourage women to apply.

1038