

Ruhr-Universität Bochum
Institut für Unternehmensführung (ifu)

14. Dezember 2010

Risikomanagement in der Energiewirtschaft mittels stochastischer Optimierung

Rüdiger Schultz
Universität Duisburg-Essen
Fakultät für Mathematik

Übersicht:

- ▶ Didaktischer Aufhänger: Newsboy
- ▶ Wie geht man (formal) mit der Unsicherheit um ?
Los wird man sie nie ! Stochastische Optimierung \neq Hellseherei !
- ▶ Intermezzo: Mathematische Problemformulierungen
- ▶ Beispiel (I): Betriebsoptimierung für virtuelles Kraftwerk
- ▶ Wie kann man das rechnen ?
- ▶ Optima für unterschiedliche stochastische Gütekriterien
- ▶ Optimieren oder Akzeptieren ?
- ▶ Beispiel (II): Stromhändler: Forward-Verträge vs. Börse
- ▶ Was können die gezeigten Modelle nicht ?
- ▶ Beispiel (III): Pool-Strategie für Stromproduzent

Didaktischer Aufhänger: Newsboy

Zeitungsjunge – Lagerhaltung

Bestelle x Einheiten zur Deckung des Bedarfs $d(\omega)$, der jedoch bei Bestellung noch mit Zufall behaftet ist.

Kosten (pro Einheit):

Bestellung $c \geq 0$. Nachbestellung $b > c$, bei $d(\omega) > x$.

Lagerung h , bei $d(\omega) < x$.

Gesamtkosten (Gut unendlich teilbar):

$$f(x, \omega) := cx + b \cdot \max\{d(\omega) - x, 0\} + h \cdot \max\{x - d(\omega), 0\}$$

Formulierung als Optimalwert eines (zweistufigen) Optimierungsproblems:

$$f(x, \omega) = cx + \min\{by^+ + hy^- : y^+ - y^- = d(\omega) - x, y^+ \geq 0, y^- \geq 0\}$$

Wird es komplexer, so ist diese Sicht hilfreich.

Wie geht man formal mit der Unsicherheit um ?

$$\begin{aligned}F(x; d) &= c \cdot x + b \cdot \max\{d - x, 0\} + h \cdot \max\{x - d, 0\} \\&= 3x + 6 \cdot \max\{d - x, 0\} + 4 \cdot \max\{x - d, 0\}\end{aligned}$$

Situation 1: Man weiß, daß unbekannter Bedarf zwischen 0 und 100.

Lösungsbegriff “Worst Case” (Robuste Optimierung):

Wähle die Bestellung so, daß die dann im ungünstigsten Fall entstehenden Gesamtkosten so klein wie möglich sind.

$$\begin{aligned}&\min_{0 \leq x \leq 100} \max_{0 \leq d \leq 100} F(x; d) \\&= \min_{0 \leq x \leq 100} \left\{ 3x + \max_{0 \leq d \leq 100} \{6 \max\{d - x, 0\} + 4 \max\{x - d, 0\}\} \right\} \\&= \min_{0 \leq x \leq 100} \left\{ 3x + \max \{4x, 6(100 - x)\} \right\} = \min_{0 \leq x \leq 100} \max \{7x, 600 - 3x\} = 420 \\&\quad \text{Optimum: } x_R = 60\end{aligned}$$

Situation 2:

Wahrscheinlichkeitsverteilung des Bedarfs bekannt, z.B. gleichverteilt zwischen 0 und 100.

Lösungsbegriff “Minimaler Erwartungswert” der Gesamtkosten
(Stochastische Optimierung):

Wähle die Bestellung so, daß die zu erwartenden Gesamtkosten im Mittel so klein wie möglich werden.

$$\begin{aligned} \min_{0 \leq x \leq 100} \quad & \mathbf{E}_\omega [F(x; d(\omega))] \\ \mathbf{E}_\omega [F(x, d(\omega))] &= b \mathbf{E}_\omega [d(\omega)] + (c - b)x + (h + b) \int_0^x P_\omega [d(\omega) \leq z] dz \\ &= 300 - 3x + \frac{1}{20}x^2 \end{aligned}$$

Optimum: $x_S = 30$ Optimale Kosten: 255

Situation 0: Ersetze zufällige Daten durch ihre Erwartungswerte und rechne deterministisch.

Schlechte Idee !

$$\min_{0 \leq x \leq 100} F(x; \mathbf{E}_\omega[d(\omega)])$$

Optimale Lösung: $x_M = \mathbf{E}_\omega[d(\omega)] = 50$

Optimale Kosten: 150 “Stuttgart 21” $F(x; \mathbf{E}_\omega[d(\omega)]) \leq \mathbf{E}_\omega[F(x; d(\omega))]$

Kostenvergleich	Robust	Stochastisch
$x_R = 60$	420	300
$x_S = 30$	510	255
$x_M = 50$	450	275

Optimierung **mit** Mittelwerten **vs.** Optimierung **von** Mittelwerten

Bilder sagen mehr als Worte

Formoptimierung bei Linearer Elastizität und Stochastischer Last

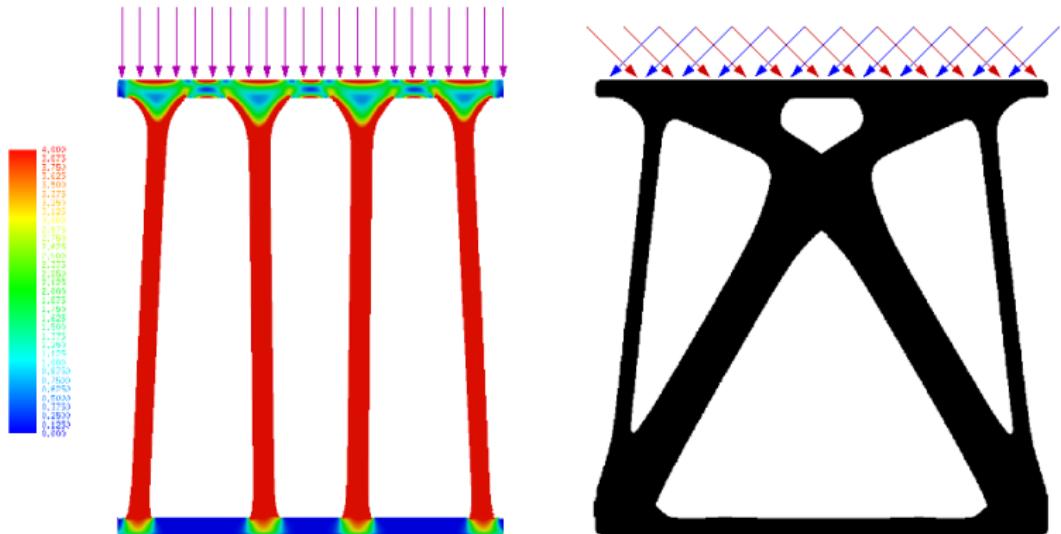
- ▶ Form \mathcal{O} (= offene Menge in \mathbf{R}^2 or \mathbf{R}^3).
- ▶ $h(\omega)$ und $g(\omega)$ zufallsbehaftete Volumenkräfte und Oberflächenlasten.
- ▶ Elastizitätsgleichung

$$\begin{aligned}-\operatorname{div}(Ae(u)) &= h(\omega) && \text{in } \mathcal{O}, \\ u &= 0 && \text{auf } \Gamma_D, \\ (Ae(u))n &= g(\omega) && \text{auf } \Gamma_N, \\ (Ae(u))n &= 0 && \text{auf } \partial\mathcal{O} \setminus \Gamma_N \setminus \Gamma_D.\end{aligned}$$

liefert Deformation $u(\mathcal{O}, \omega)$.

- ▶ Zielfunktion: **Minimiere** Compliance (Nachgiebigkeit)

$$J(\mathcal{O}, \omega) := \int_{\mathcal{O}} h \cdot u(\mathcal{O}, \omega) \, dx + \int_{\Gamma_N} g \cdot u(\mathcal{O}, \omega) \, d\mathcal{H}^{d-1},$$



Lösungsvergleich von risikoneutraler stochastischer Optimierung und deterministischer Optimierung mit gemittelter Last,

Links: Optimierung mit Mittelwert.

Rechts Optimierung des Mittelwerts.

Abstraktes Intermezzo: Mathematische Problemformulierungen

Zufallsbehaftetes Optimierungsproblem

$$\min \{ c^\top x + q^\top y : Tx + Wy = z(\omega), x \in X, y \in Y \}$$

(X, Y Lösungsmengen linearer Ungleichungssysteme mit Ganzzahligkeit.)

Nichtantizipativität == Informationsbedingung

entscheide $x \mapsto$ beobachte $z(\omega) \mapsto$ entscheide $y = y(x, \omega)$

Dann:

$$f(x, \omega) := \underbrace{c^\top x + \min_y \{ q^\top y : Wy = z(\omega) - Tx, y \in Y \}}_{\text{im allg. nichtkonvex, unstetig in } x}$$

“Optimierungsproblem”

$\min \{ f(x, \omega) : x \in X \}$ Finde eine “kleinste” Zufallsvariable ! ?

Modellierung (Richtlinien, Grundfragen):

1. Akzeptiere ich eine Entscheidungsfindung nach nichtdeterministischen Kriterien ?
2. Welche Kriterien wären das dann ?
3. Wann ist eine Zufallsvariable einer anderen vorzuziehen ?
4. Kann ich das mathematisch exakt erfassen ?
5. Kann ich das dann für reale Anwendungen noch rechnen ?

Vergleich auf Grundlage statistischer Parameter: Mean-Risk-Modelle

$$\min\{Q_{MR}(x) : x \in X\}$$

wobei

$$Q_{MR}(x) = E[f(x, \omega)] + \rho \cdot \mathcal{R}[f(x, \omega)]$$

und E Erwartungswert sowie \mathcal{R} eine Quantifizierung von Risiko, wie z.B.

Überschußwahrscheinlichkeit

$$\mathcal{R}[f(x, \omega)] = P[\{\omega : f(x, \omega) > \eta\}] \quad (\eta \in \mathbb{R} \text{ fixiert})$$

Gemittelter Überschuss

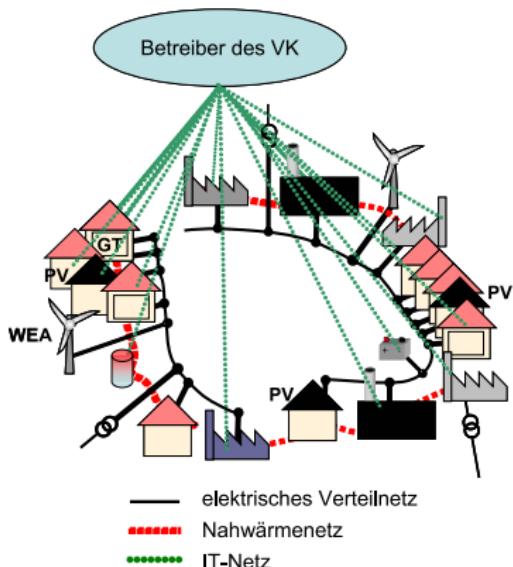
$$\mathcal{R}[f(x, \omega)] = E[\max\{f(x, \omega) - \eta, 0\}] \quad (\eta \in \mathbb{R} \text{ fixiert})$$

Conditional Value-at-Risk

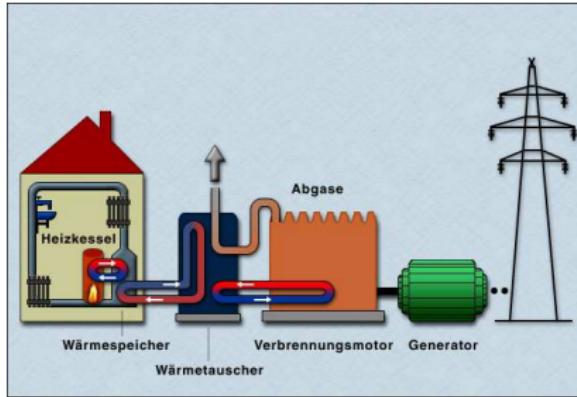
Für gegebenes α , der Mittelwert der $(1 - \alpha) \cdot 100\%$ ungünstigsten (größten) Realisierungen.

Beispiel aus der Energiewirtschaft (I)

Betrieb eines Energiesystems mit verteilter Erzeugung (Virtuelles Kraftwerk)



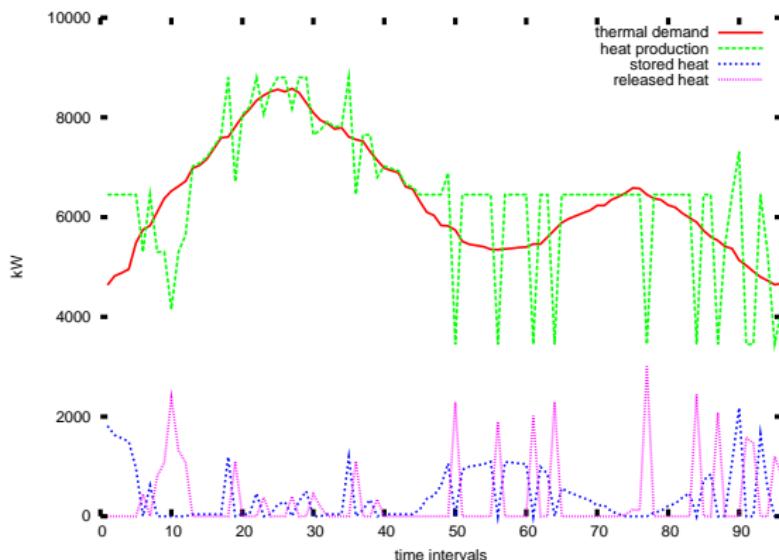
- ▶ Betrieb über eine Zeitspanne.
- ▶ **Optimierungsziel:** Kosten (= Betriebskosten - Handelserlöse)
- ▶ **Zufall:** Lasten, Energiepreise, erneuerbare Einspeisung.
- ▶ Daten vollständig bekannt für initiale Zeitperiode. Danach zufällig mit **bekannten Verteilungen**.
- ▶ Zweistufiges lineares Modell mit Ganzzahligkeit.



Virtuelles Kraftwerk:

- ▶ 5 KWK-Anlagen, jede mit thermischem Speicher und Kühler und zusammen 8 Gasboilern, 9 Gasmotoren und einer Gasturbine,
- ▶ 12 Windturbinen und ein Wasserkraftwerk,
- ▶ Stochastik an Input (Wind) und Output (Last, Preise),
- ▶ Zeithorizont 24 h, unterteilt in viertelstündliche Abschnitte.

- ▶ System wird als **zufallsbehaftetes MILP** modelliert,
- ▶ Deterministisches Problem (9.000 Boolesche, 8.500 stetige Variablen; 22.000 Restriktionen) lösbar mit Standardsoftware (CPLEX) in weniger als 20 Sekunden,
- ▶ **Bild:** Optimale Erzeugung und Speicherbewirtschaftung in KWK-Anlage (Ausschnitt, Wärmeproduktion, 24 h)



Nichtantizipativität:

Zufällige Daten sind bekannt für die ersten vier Stunden, danach stochastisch mit bekannter (geschätzter) Verteilung.

Literatur:

- ▶ Handschin, E.; Neise, F.; Neumann, H.; Schultz, R.:
Optimal operation of dispersed generation under uncertainty using mathematical programming, **International Journal of Electrical Power & Energy Systems** 28 (2006), 618–626.
- ▶ Schultz, R.; Neise, F.:
Algorithms for mean-risk stochastic integer programs in energy, **Revista de Investigación Operacional** 28 (2007), 4–16.

Wie kann man das rechnen ?

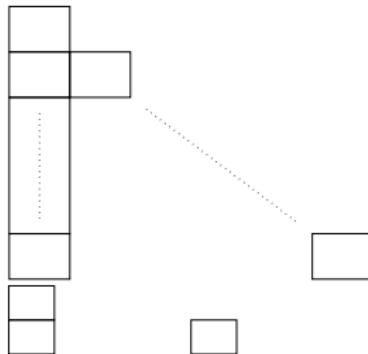
Endliche Diskrete Verteilungen – Blockstrukturierte Gemischt-Ganzzahlige Lineare Programme (MILPs)

$z(\omega)$ habe endlich viele Realisierungen z_j mit Wktn. $\pi_j, j = 1, \dots, J$.

$\Rightarrow \min\{Q_E(x) : x \in X\}$ äquivalent zu Large-Scale MILP

$$\min \left\{ c^\top x + \sum_{j=1}^J \pi_j q^\top y_j : Tx + Wy_j = z_j, x \in X, y_j \in Y, j = 1, \dots, J \right\}.$$

$$Q_E(x) = E_\omega [f(x, \omega)] = E_\omega \left[c^\top x + \min_y \{q^\top y : Wy = z(\omega) - Tx, y \in Y\} \right]$$



Für $\mathcal{R}(f(x, \omega)) := P[\{\omega : f(x, \omega) > \eta\}]$ (Überschusswahrscheinlichkeit), ergibt sich folgendes äquivalente MILP:

$$\begin{aligned}
 \min\{c^\top x + \sum_{j=1}^J \pi_j q^\top y_j + \rho \cdot \sum_{j=1}^J \pi_j \theta_j : \\
 Tx + Wy_j = z_j, \\
 c^\top x + q^\top y_j - \eta \leq M \cdot \theta_j, \\
 x \in X, y_j \in Y, \theta_j \in \{0, 1\}, \\
 j = 1, \dots, J\}.
 \end{aligned}$$

Günstige Blockstruktur:

Keine Zweitstufenvariablen aus unterschiedlichen Realisierungen in derselben Nebenbedingung.

Algorithmen

Die Mean-Risk-Modelle mit ihren unterschiedlichen Spezifikationen sind nichtkonvex und nichtlinear. Wir verfügen über zwei Darstellungen:

- ▶ Kompakte Formulierung: $\min\{Q_{MR}(x) : x \in X\}$.
- ▶ Expandierte Formulierung als MILP wie gerade gesehen.

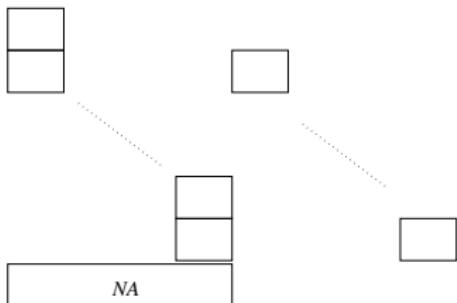
Lösung mittels Branch-and-Bound, wobei untere Schranken durch **Lagrange-Relaxation der Nichtantizipativität** berechnet werden.

Das volle Problem **dekomponiert** dabei realisierungsweise, wenn **günstige Blockstruktur** vorliegt.

- 1 Zerlege X .
- 2 Finde obere und untere Schranken für die Optimalwerte auf den Elementen der Zerlegung.
- 3 Schneide Elemente der Zerlegung ab (optimale, unzulässige, chancenlose).

Untere Schranken durch **Lagrange-Relaxation** der Nichtantizipativität (NA):

Führe Kopien $x_j, j = 1, \dots, J$ ein, und füge $x_1 = \dots = x_J$ hinzu.



- ▶ Zielfunktion im Lagrange-Dualproblem wird realisierungsweise berechnet.
Decomposition !!
- ▶ Heuristiken für obere Schranken.

Dimensionen der stochastischen Programme (äquivalente MILPs) im risikoneutralen Fall:

Realisierungen	Boolesche Var.	Stetige Var.	Restriktionen
1	8.959	8.453	22.196
5	38.719	36.613	96.084
10	75.919	71.813	188.444
50	373.519	353.413	927.324

Nicht länger direkt behandelbar mit Standard-MILP-Lösern.

Lösungszeiten und -güten für Erwartungswertmodell

Anzahl Realisierungen	Dekomposition		
	Zielfunktion	Optimalitätslücke (%)	Zeit (Sek.)
5	7.150.903	0,0067	8
10	5.987.578	0,0087	52
20	5.837.559	0,0088	172
30	5.928.542	0,0093	364
40	5.833.191	0,0093	487
50	5.772.268	0,0094	611

Anzahl Realisierungen	CPLEX		
	Zielfunktion	Optimalitätslücke (%)	Zeit (Sek.)
5	7.150.945	0,0072	11
10	5.987.642	0,0099	253
20	5.837.584	0,0093	1.769
30	5.928.500	0,0091	9.486
40	5.833.156	0,0107	26.286
50	5.772.335	0,0129	22.979

Mean-Risk-Modell mit Überschusswahrscheinlichkeit, Dekompositionsverfahren

Anzahl Realisierungen	Zeit (Sek.)	ρ	Q_E	Q_R	Lücke (%)
5	300	0	7.150.866	–	0,0062
		0,0001	7.150.913	0,400	0,0066
		10.000	7.150.930	0,400	0,0348
10	450	0	5.987.526	–	0,0078
		0,0001	5.987.554	0,370	0,0084
		10.000	5.987.556	0,370	0,0302
20	600	0	5.837.500	–	0,0078
		0,0001	5.837.560	0,205	0,0089
		10.000	5.837.556	0,205	0,0183
50	1500	0	5.772.226	–	0,0087
		0,0001	5.772.271	0,205	0,0096
		10.000	5.772.287	0,205	0,0151

Mean-Risk-Modell mit Überschüßwahrscheinlichkeit, CPLEX

Anzahl Realisierungen	Zeit (Sek.)	ρ	Q_E	Q_R	Lücke (%)
5	300	0	7.150.850	–	0,0057
		0,0001	7.150.900	0,400	0,0064
		10.000	7.150.880	0,400	0,0342
10	450	0	5.987.670	–	0,0104
		0,0001	5.987.630	0,370	0,0098
		10.000	5.987.630	0,370	0,0315
20	600	0	infeasible		infinity
		0,0001	infeasible		infinity
		10.000	infeasible		infinity
50	1500	0	infeasible		infinity
		0,0001	infeasible		infinity
		10.000	infeasible		infinity

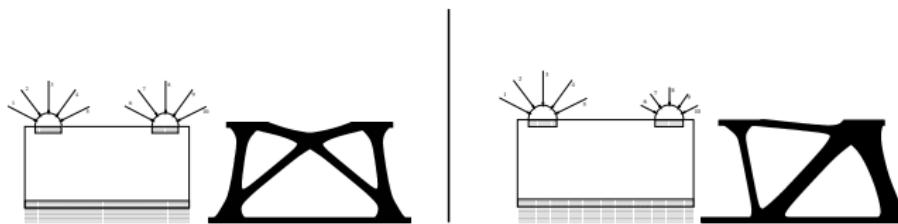
Unterschiedliche stochastische Gütekriterien
liefern unterschiedliche Optima

Risikoaverse Lösungen können sich beträchtlich von risikoneutralen unterscheiden.

(Lassen erneut Bilder sprechen.)

Risikoneutrales Modell: $E_\omega[J(\mathcal{O}, \omega)] \rightarrow \min!$

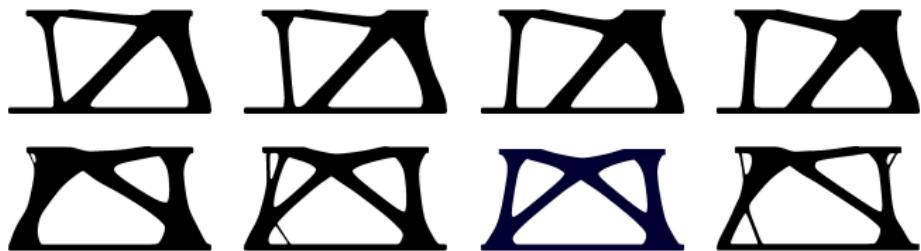
(Gelöst mit Abstiegsverfahren basierend auf Formableitungen.)



Symmetrische stochastische Lastkonfiguration links, asymmetrische rechts

Risikoaverses Modell – Gemittelter Überschuß:

$$E_{\omega} [\max \{J(\mathcal{O}, \omega) - \eta, 0\}] \rightarrow \min!$$



Eine Folge von Lösungen für die Optimierung des gemittelten Überschusses
 $\eta = 0.1, 0.2, 0.3, 0.4, 0.6, 0.8, 1.0., 1.5.$

Optimieren oder Akzeptieren ?

Risikoaversion mit stochastischer Dominanz

- **Idee:** Finde “akzeptable” x durch Vergleich mit einer stochastischen Benchmarkverteilung.
- Vergleich mittels “gewöhnlicher” stochastischer Ordnung:

$$f(x, z) \preceq_1 a$$

falls

$$\nu(a \leq \eta) \leq \mu(f(x, z) \leq \eta) \quad \forall \eta \in R$$

($\mu \in \mathcal{P}(R^s)$ – Verteilung von z , $\nu \in \mathcal{P}(R)$ – Verteilung von a)

(f nimmt kleine Werte mit höherer Wahrscheinlichkeit an als a .)

- Vergleich mittels “Increasing Convex Order”:

$$f(x, z) \preceq_{icx} a$$

falls

$$\int_{R^s} [f(x, z) - \eta]_+ \mu(dz) \leq \int_R [a - \eta]_+ \nu(da) \quad \forall \eta \in R$$

(Im Mittel übersteigt f Schwellen um weniger als a .)

Betrachten mit einem Benchmark $a(\omega)$ die Zulässigkeitsmenge

$$\{x \in X : f(x, z(\omega)) \leq a(\omega)\}$$

... und weiter

$$\min \left\{ g^\top x : x \in X, f(x, z(\omega)) \leq a(\omega) \right\} \quad (1)$$

Beispiel:

- ▶ Finde unter allen wirtschaftlich akzeptablen Auslegungen für ein virtuelles Kraftwerk eine solche, die mit minimalem Verbrauch fossiler Brennstoffe auskommt.
- ▶ Finde unter allen wirtschaftlich akzeptablen Betriebsplänen einen mit den wenigsten Anfahrvorgängen.

Dominance Constrained Stochastic Integer Program

Anmerkungen:

- ▶ Benchmarks verallgemeinern deterministische Schranken:
Einpunktverteilung → Mehrpunktverteilung.
- ▶ Benchmarks lassen sich z.B. aus statistischen Daten ableiten
oder aus “Wünschen” bzw. Expertenmeinungen.
- ▶ Wieder lassen sich äquivalente MILPs formulieren, falls
Datenverteilung $z(\omega)$ und Benchmark $a(\omega)$ endlich diskret sind.
- ▶ Für die äquivalenten MILPs haben wir Dekompositionsverfahren
entwickelt, welche wieder auf einer Kopplung von
Lagrange-Relaxation und B&B beruhen.

Beispiel aus der Energiewirtschaft (II)

- ▶ Carrión, M.; Gotzes, U.; Schultz, R.:
Risk aversion for an electricity retailer with second-order stochastic dominance constraints, **Computational Management Science 6** (2009), 233–250.

Beispiel: Stromgroßhändler

Nichtantizipative Entscheidungen (zu Beginn eines (Geschäfts-) Jahres):

- Forward-Verträge für Einkäufe (Grundlast, Spitzenlast),
- Verkaufspreise für Kunden (industrielle, kommerzielle, Privathaushalte).

Entscheidungen der zweiten Stufe:

- Day-ahead Trading (**ungewisse Poolpreise**),
- Belieferung der Kunden (**ungewisse Nachfrage**).

Benchmark:

- Ein gerade noch für den Händler akzeptables Gewinnprofil.

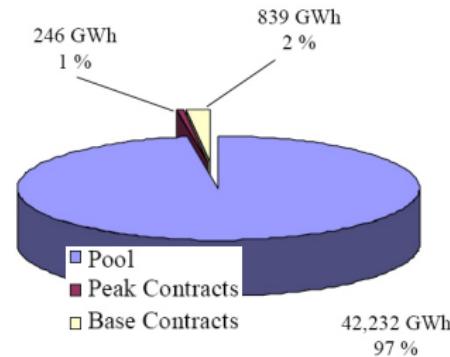
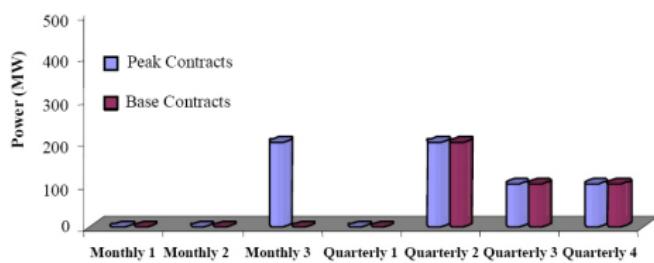
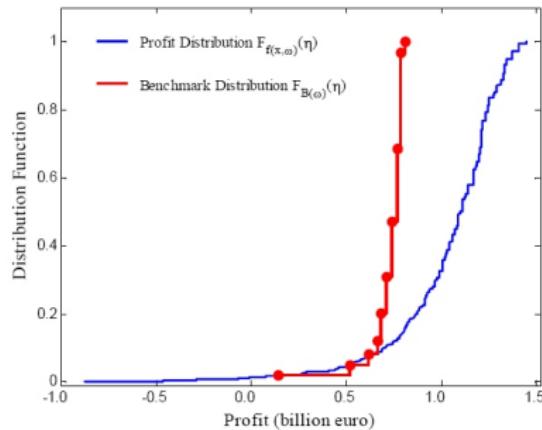
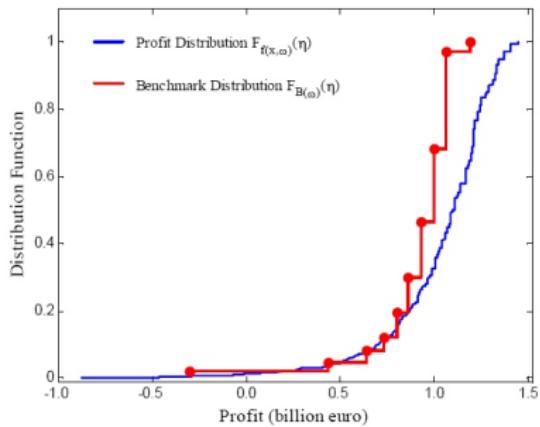
Zielfunktion $g^\top x$:

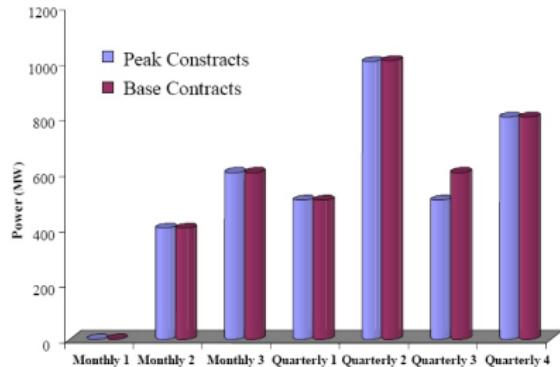
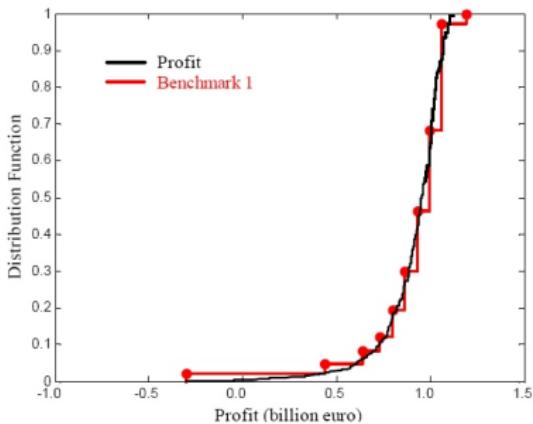
- Die Summe der Verkaufspreise in den einzelnen Kundenkategorien.

Zunächst:

Risikoneutrale Maximierung des erwarteten Gewinns.

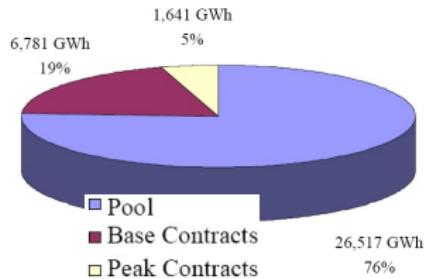
- ⇒ \hat{x} ist optimale Festlegung von Forwards und Verkaufspreisen.
- ⇒ Blau: Verteilungsfunktion des zufallsbehafteten Gewinns $f(\hat{x}, \omega)$

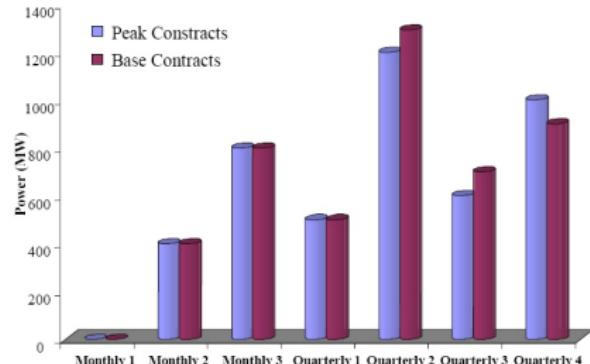
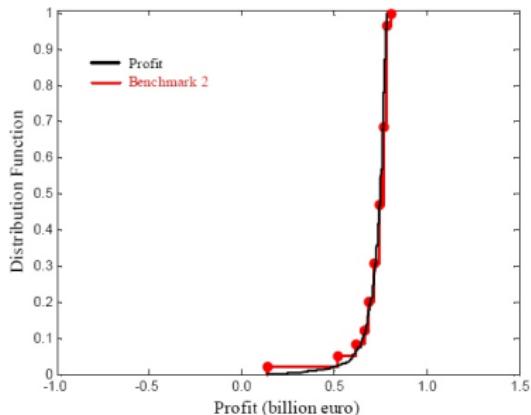




- Expected Profit: 915 M€ (\downarrow 12%)
- Profit Standard Deviation: 183 M€ (\downarrow 36%)
- Worst Scenario Profit: -298 M€ (\uparrow 66%)

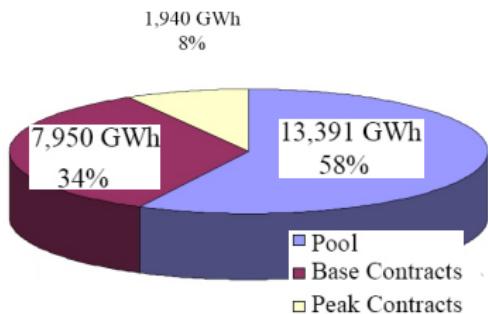
- Selling price:
 - Industrial: 42.32 €/MWh (\uparrow 5%)
 - Commercial: 58.48 €/MWh (\uparrow 9%)
 - Residential: 60.13 €/MWh (\uparrow 3%)





- Expected Profit: 721 M€ ($\downarrow 13\%$)
- Profit Standard Deviation: 142 M€ ($\downarrow 51\%$)
- Worst Scenario Profit: 140 M€ ($\uparrow 116\%$)

- Selling price:
 - Industrial: 51.04 €/MWh ($\uparrow 27\%$)
 - Commercial: 64.55 €/MWh ($\uparrow 21\%$)
 - Residential: 66.67 €/MWh ($\uparrow 14\%$)



Was können die gezeigten Modelle nicht ?

- ▶ Natur der Ungewißheit:

entscheide $x \mapsto$ beobachte $z(\omega) \mapsto$ entscheide $y = y(x, \omega)$

Exogener Zufall:

Verteilung von $z(\omega)$ wird nicht durch die Wahl der Variablen x beeinflußt.

Dies schließt z.B. Modelle aus, in denen Marktteilnehmer mit Marktmacht agieren.

- ▶ Begrenzte Interaktion der Entscheider (leader/follower)

Leader wählt x .

- Follower akzeptiert x und beobachtet $z(\omega)$.
- Follower löst das Optimierungsproblem der zweiten Stufe.
- Follower übermittelt **Optimalwert** $\Phi(z(\omega) - Tx)$ an Leader.
- Leader wählt “beste” Zufallsvariable in

$$f(x, \omega) = c^\top x + \Phi(z(\omega) - Tx), x \in X.$$

Bi-Level-Problem (Stackelberg-Spiel):

Follower gibt **eine Optimallösung** $y_{opt}(x, \omega)$ zurück an den Leader.

Zweistufiges stochastisches Programm aus Bi-Level-Sicht

$$\min \{ c^\top x + q^\top y : Tx + Wy = z(\omega), x \in X, y \in Y \}$$

Äquivalent:

$$\begin{aligned} \min \{ & c^\top x + q^\top y : x \in X, \\ & y = y(x, \omega) \text{ löst } \min \{ q^\top y : Wy = z(\omega) - Tx, y \in Y \} \} \end{aligned}$$

Optimalwert des Follower-Problems geht zurück an den Leader.

Bi-level Modell:

$$\begin{aligned} \min \{ & c^\top x + d^\top y : x \in X, \\ & y = y(x, \omega) \text{ löst } \min \{ q^\top y : Wy = z(\omega) - Tx, y \in Y \} \} \end{aligned}$$

Eine optimale Lösung geht zurück.

Beispiel aus der Energiewirtschaft (III)

Ruiz, C.; Conejo, A.:

Pool strategy of a producer with endogenous formation of locational marginal prices, IEEE Transactions on Power Systems 24 (2009), 1855 - 1866.

Pool-Strategie für strategischen Stromproduzenten:

Leader-Problem:

Strategischer Stromproduzent sucht stündliche Angebotskurven für Day-Ahead-Markt mit dem Ziel der Gewinnmaximierung.

Follower-Problem:

Marktklärung (Nachfragen der Verbraucher, Angebote der Produzenten) und Preisformierung mit dem Ziel der Maximierung des sozialen Wohls - "social welfare" (mehrperiodisch, netzwerkrestriktiv).

Leader übermittelt:

Preis-Mengen-Offerten für einzelne Gruppen von Erzeugereinheiten in gewissen Zeitperioden.

Follower gibt zurück:

Ortsbezogene Marginalpreise und Produktionsmengen (Strom).

Ungewißheit:

Verbrauchernachfragen, Angebote der Mitbewerber.

Ergänzende Literatur

- ▶ Shapiro, A.; Dentcheva, D.; Ruszczyński, A.:
Lectures on Stochastic Programming - Modeling and Theory,
SIAM, Philadelphia, 2009.
- ▶ Wallace, S.W.; Ziemba, W.T. (Eds.):
Applications of Stochastic Programming, *SIAM, Philadelphia, 2005.*
- ▶ Schultz, R., Wagner, H.-J. (Eds.):
Innovative Modellierung und Optimierung von Energiesystemen,
LIT Verlag, Dr. W. Hopf, Berlin, 2009.