

# Berechnung szenario-invarianter optimaler Investitionsentscheidungen unter Unsicherheiten mittels Benders Decomposition

Themenbereich: Energiesystem- und Klimamodellierung  
Stefan STRÖMER<sup>(1)</sup>

(<sup>1</sup>) AIT Austrian Institute of Technology GmbH

## Motivation und zentrale Fragestellung

Je weiter der Planungshorizont gängiger Energiesystemoptimierungsmodelle in die Zukunft blickt, desto bedeutender wird der Einfluss unterschiedlicher Unsicherheiten in der Parametrisierung (Kostenannahmen, unterschiedliche Klima- und Wettervorhersagen, ...). Verschiedenste Ansätze wie herkömmliche *zweistufige stochastische Optimierung* (SO) (z.B. [1]), oder *Modelling to Generate Alternatives* (MGA) (z.B. [2]) können bereits Resultate über vielfältige Szenarien hinweg liefern, beantworten jedoch nicht direkt die Fragestellung, wie eine Entscheidung „heute“ getroffen werden kann, die „morgen“ (über alle Szenarien hinweg) möglichst keine schlechten Realisierungen nach sich zieht. SO betrachtet meist eine erwartungswert-optimale Entscheidung (die von Extremszenarien zwar beeinflusst ist, aber gerade bei Verteilungen – bezogen auf die einzelnen Szenarioergebnisse – mit schweren Rändern schwer zu interpretieren sein kann). MGA in Kombination mit Szenarien (siehe z.B. [6]) kann zwar eine Zulässigkeit aller Szenarien betrachten, hängt aber stets von der manuellen Wahl des genutzten  $\varepsilon$  ab. Der vorgeschlagene Ansatz kombiniert die für SO oft genutzte Benders Decomposition, mit der „near-optimality“ eines MGA-Ansatzes und ergänzt weiters eine modell-endogene Wahl des optimalen  $\varepsilon$  und die Möglichkeit, worst-case Szenarien automatisch auszuschließen.

## Methodische Vorgangsweise

Wir betrachten vorerst ein Problem der Form

$$\min_{y \in Y} \max \left\{ \min_{x_s \in X(y,s)} f_s(y, x_s) \cdot f_s(y_s^*, x_s^*)^{-1} \right\},$$

in dem  $y$  für die Investitionsentscheidungen in der ersten Stufe („heute“) steht und  $x$  die stündlichen Entscheidungen des Betriebs eines kostenoptimalen Energiesystems („morgen“) darstellt. Hierbei enthält  $S$  alle Szenarien und  $f_s(y_s^*, x_s^*)$  (konstant!) beschreibt den Zielfunktionswert in Szenario  $s$  unter einer (nur für dieses Szenario) optimalen Entscheidung  $(y_s^*, x_s^*)$ .

Das Maximum beschreibt somit die höchsten relativen<sup>2</sup> Teuerungen über alle Szenarien für eine gegebene Investitionsentscheidung. Diese Entscheidung wiederum wird in der äußeren Optimierung bestimmt, um jene maximale Teuerung zu minimieren.

Dieses Problem kann in ein lineares Optimierungsproblem umformuliert werden<sup>3</sup>:

$$\begin{aligned} & \min_{y \in Y, z} z, \quad s. t. \\ z & \geq \min_{x_s \in X(y,s)} f_s(y, x_s) \cdot f_s(y_s^*, x_s^*)^{-1} \quad \forall s \in S \end{aligned}$$

---

<sup>1</sup> Jungautor | Giefinggasse 6, +43664 78588307, [stefan.stroemer@ait.ac.at](mailto:stefan.stroemer@ait.ac.at), [www.ait.ac.at](http://www.ait.ac.at)

<sup>2</sup> Dies verhindert, dass potentielle Teuerungen in Szenarien mit unterschiedlichen Kostenparametern unter- bzw. überbewertet werden.

<sup>3</sup> Diese Darstellung kann als *Bilevel Optimization Problem* [3] aufgefasst werden.

Um weiters den Einfluss von Extremszenarien zu kontrollieren (in der genannten Formulierung könnte ein einzelnes Szenario alle anderen dominieren und somit zu "verzerrten" Ergebnissen führen - die unnötig schlecht in allen anderen Szenarien sind, nur um ein einzelnes Extremszenario zu verbessern), können die Nebenbedingungen durch  $q_s \in \{0, 1\}$  und die Wahl eines geeigneten  $M$  unter Zuhilfenahme der *Big-M-Methode* umformuliert werden in

$$z \geq \min_{x_s \in X(y,s)} f_s(y, x_s) \cdot f_s(y_s^*, x_s^*)^{-1} - M \cdot q_s \quad \forall s \in S$$

$$\sum_{\{s \in S\}} q_s \cdot w_s \leq 1 - q$$

um ein beliebiges Quantil  $q$  (unter Gewichtung der Szenarien mittels  $\sum_{\{s \in S\}} w_s = 1$ ) zu betrachten. Dieses Problem lässt sich durch Trennung der Variablen in die Sets  $(y, z, \hat{\theta}_s, q_s)$  und  $(x_s)$  mittels Benders-Decomposition lösen. Hierbei bestimmt das Master-Problem in Iteration  $k$  eine fixe Investitionsentscheidung  $y^{(k)}$  unter Zuhilfenahme der Hilfsvariablen  $\hat{\theta}_s$  (die die Zielfunktionswerte der Subprobleme approximieren). Zur iterativen Verbesserung werden die Auswertungen der Subprobleme und der zugehörigen dualen Variablen herangezogen.

## Ergebnisse und Schlussfolgerungen

Als Grundlage wurde für erste Berechnungen ein vereinfachtes Strommarktmodell von Österreich im Jahr 2030, unter Wetterunsicherheiten, in insgesamt 41 Szenarien untersucht<sup>4</sup>. Diese wurden auf Basis von öffentlich verfügbaren Daten durchgeführt:

- Investitionskostenannahmen für Solar, Wind und Batteriespeicher laut *PyPSA* [4]
- Aktuell installierte Leistungen für Kraftwerke laut *ENTSO-E Transparency* [5]
- Wetter- und Verbrauchsdaten anhand von *Grochowicz et al.* [6]

Aufgrund der Analyse von relativen Teuerungen (im Gegensatz zu absoluten Werten wie bei der Anwendung eines ähnlichen Ansatzes zur Lösung einer SO), ist das auftretende Problem in der initialen Formulierung bei der Lösung mittels konventioneller gemischt ganzzahliger (MILP) Solver numerisch instabil. Triviale Skalierungen<sup>5</sup> der (Un-)Gleichungen führen jedoch ohne manuellen Eingriff zu einer raschen Konvergenz.

Abbildung 1 zeigt die optimalen Investitionsentscheidungen der einzelnen Technologien, welche unter  $q = 0.8$  zu einer maximalen Teuerung von 10.8% im Vergleich zu den individuellen Optimalentscheidungen führt. Im Vergleich zu den Einzelszenarien kommt es zu einer geringfügigen Unterinvestition in Solarenergie, während deutlich mehr Windausbau gewählt sowie keine Investition in Batteriespeicher getätigt werden.

Der vorliegende Algorithmus ist (bis auf die Auswertung des Master-Problems) vollständig parallelisierbar und konvergiert innerhalb von sechs Iterationen (benötigt folglich lediglich die sechsfache Zeit einer Modellauswertung).

<sup>4</sup> Dies stellt nur einen "Proof-of-Concept" des Algorithmus dar. Die Wahl der (Kosten-) Parameter ist stark vereinfacht und wurde keiner genauen Betrachtung unterworfen. Des Weiteren bewirkt das Vernachlässigen des Europäischen Restsystems eine Verfälschung der Ergebnisse.

<sup>5</sup> Nachdem die Systemkosten von der Zielfunktion in eine Nebenbedingung geschoben werden und dort (um statt absoluten Teuerungen relative zu beschreiben) durch den "Optimalwert" des einzelnen betrachteten Szenarios dividiert werden, enthalten diese Nebenbedingungen extrem kleine Koeffizienten. Eine Skalierung – z.B. auf Basis der ungefähren Größenordnung der durchschnittlichen Systemkosten – verhindert auftretende numerische Probleme.

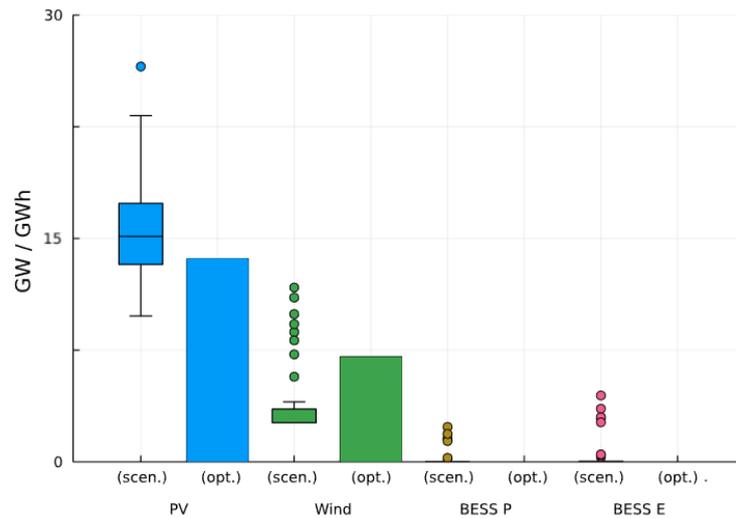


Abbildung 1: Gegenüberstellung der Ergebnisse für die getrennte Einzeloptimierung aller Szenarien („scen.“ mittels Boxplot) und der vorgestellten szenario-übergreifenden Methode („opt.“ mittels Barplot). BESS P beschreibt die Lade-/Entladeleistung (GW), BESS E den maximalen Energiegehalt (GWh).

## Literatur

- [1] Mavromatidis, G., Orehounig, K., & Carmeliet, J. (2018). Design of distributed energy systems under uncertainty: A two-stage stochastic programming approach. *Applied energy*, 222, 932-950.
- [2] Neumann, F., & Brown, T. (2021). The near-optimal feasible space of a renewable power system model. *Electric Power Systems Research*, 190, 106690.
- [3] Sinha, A., Malo, P., & Deb, K. (2017). A review on bilevel optimization: from classical to evolutionary approaches and applications. *IEEE Transactions on Evolutionary Computation*, 22(2), 276-295.
- [4] <https://pypsa-eur.readthedocs.io/en/latest/costs.html>
- [5] <https://transparency.entsoe.eu/>
- [6] Grochowicz, A., van Greevenbroek, K., Benth, F. E., & Zeyringer, M. (2022). Intersecting near-optimal spaces: European power systems with more resilience to weather variability. *arXiv preprint arXiv:2206.12242*.