

Populationsbasierte Optimierungsmethoden zur Entscheidungsunterstützung im Energiesystemdesign: Diskussion einiger Ansätze

Alexander Wanitschke, Stephen Bosch

Reiner Lemoine Institut gGmbH
Ostendstraße 25, 12459 Berlin
alexander.wanitschke@rl-institut.de

Zusammenfassung:

Entscheidungsprobleme im Energiesystemdesign sind charakterisiert durch widersprüchliche Zielstellungen und unterliegen dabei oft großen Unsicherheiten. Klassische Systeme zur Entscheidungsunterstützung im Energiesystemdesign sind bisweilen defizitär und respektieren die Komplexität der realen Problemstellung oft nur unzureichend. Populationsbasierte Verfahren können helfen mit einer strukturierten Analyse von Lösungsmengen die grundlegenden Zusammenhänge zu identifizieren und so die Komplexität der Entscheidung für den Entscheidungsträger verständlich aufzubereiten.

1 Einleitung


Politische und wirtschaftliche Entscheidungen zu energiesystemischen Fragestellungen fundieren bestenfalls auf Wissen über aktuelle und zukünftige Möglichkeiten, welches mit den entsprechenden Analysverfahren erzeugt, aufbereitet und kommuniziert wird. Insbesondere in Energiesystemen spielen dabei verschiedenste Bewertungsdimensionen ebenso eine Rolle wie die systematische Berücksichtigung der Unsicherheiten bzgl. zukünftiger Entwicklungen und Zustände. Klassische Systeme zur Entscheidungsunterstützung im Energiesystemdesign sind bisweilen defizitär und respektieren die Komplexität der realen Problemstellung oft nur unzureichend. In den folgenden Kapiteln werden populationsbasierte Verfahren zur Optimierung und Robustheitsanalyse im Energiesystemdesign demonstriert, die helfen können, die Komplexität der Entscheidung in einer Form aufzubereiten, die es dem Entscheidungsträger ermöglicht, die bestmögliche Entscheidung auf Basis seiner subjektiven Präferenzen zu treffen. In den folgenden zwei Kapiteln wird die Bedeutung der Mehrzieloptimierung für Energiesystementscheidungen erläutert und an einem Beispiel demonstriert. Anschließend wird die Robustheitsanalyse zur Betrachtung von Unsicherheiten im Energiesystemdesign diskutiert.

2 Mehrzieloptimierung

Klassische Ansätze der Energiesystemoptimierung konzentrieren sich bisweilen allein auf die Minimierung der Systemkosten (volks- oder betriebswirtschaftlich). Zusätzliche Anforderungen an das System (z.B. Sicherheit, Umwelteffizienz) werden dabei höchstens als Nebenbedingungen berücksichtigt oder fließen über eine monetäre Bewertung entsprechend gewichtet in den Gesamtnutzen ein. Diese Ansätze werden aus vielerlei Gründen den Anforderungen an das moderne Energiesystemdesign nicht gerecht. Abgesehen davon, dass der Entscheidungsträger explizites Vorwissen und Verständnis über die Beschaffenheit der Bewertungsgrößen besitzen muss um eine passende Gewichtung oder Bedingungsgrenze zu finden, kann die Aggregation mehrerer Ziele in einen skalaren Indikator zu negativen Entscheidungsverzerrungen führen weil verschiedene Aspekte der Systembewertung in einer Art und Weise bevorzugt oder benachteiligt werden die vom Entscheidungsträger nicht a priori vorhergesehen werden kann (Franssen, 2005). Des Weiteren führt die Zusammenführung mehrerer Optimierungsziele zu einer Verkleinerung des mathematischen Suchraumes, sodass ein Teil der optimalen Lösungen gar nicht mehr zur Verfügung steht (Fleming, Purshouse, & Lygoe, 2005; Simon, 2013; Zitzler, 1999).

I. Gewichtung:

$$f^* = w_1 \cdot f_1(\vec{x}) + w_2 \cdot f_2(\vec{x})$$



II. Nebenbedingung:

$$f^* = f_1(\vec{x}), f_2(\vec{x}) \leq c$$




Abbildung 1. Klassische Ansätze zur Behandlung mehrerer Optimierungsziele

Die grundlegende Herausforderung bei der Berücksichtigung mehrerer Ziele im Energiesystemdesign besteht in der Existenz des Zielkonfliktes, in dem keine der zulässigen Lösungen alle Zielstellungen vollständig befrieden kann, da diese zumindest teilweise widersprüchlich sind. Aufgrund dieses Konfliktes und der Entscheidung gegen eine Aggregation gibt es keine Lösung die als optimal bezüglich aller Ziele angesehen werden kann. Die vollständige Lösung eines Mehrzielproblems besteht somit aus einer Menge an Lösungen, die den optimalen Tradeoff (auch Paretofront genannt) zwischen den Zielstellungen im Energiesystemdesign beschreibt. Auch wenn jeder pareto-optimale Zustand aus mathematischer Sicht eine gleichwertige Designalternative darstellt, so ist es i.Allg. wünschenswert, eine einzige

Lösung auszuwählen. Mehrzieloptimierung bietet ein vollständiges Bild über alle möglichen optimalen Handlungsoptionen im Spannungsfeld der Zielkonflikte. Sie erzeugt auf Seiten des Entscheidungsträgers Verständnis für die zentralen Probleme im Systemdesign, sodass eine informierte Entscheidung auf Basis subjektiver Präferenzen a posteriori möglich wird. Die Abbildung des optimalen Zielkonfliktes hat noch einen weiteren Vorteil. Jedes Energiesystemmodell ist eine Vereinfachung der Realität. In Fällen, in denen dies zu falschen Kausalitäten in der Modellierung führt, kann das Ergebnis einer Mehrzieloptimierung helfen, die fehlerhaften Teile des Modells zu identifizieren und auszubessern. Die Zahl der Veröffentlichungen über das Thema der Mehrzieloptimierung ist seit Beginn des 21. Jhd exponentiell angestiegen (Fadaee & Radzi, 2012). So ist es an der Zeit, dass das Thema auch stärker im Energiesystemdesign diskutiert und angewandt wird.

3 Beispiel einer Auslegung: Micro Smart Grid Campus EUREF

Auf dem EUREF-Campus in Berlin Schöneberg wird ein Micro Smart Grid (MSG) zu einem Forschungs- und Erprobungsnetz ausgebaut. Dabei sollen unterschiedliche lokale Energieerzeuger, Verbraucher, sowie Speicher intelligent miteinander verknüpft werden. Das Netzmanagement soll einen ökonomischen und ökologischen Betrieb des MSG gewährleisten und im Einklang mit den regenerativen Erzeugern einen Netzbezug aus dem öffentlichen Netz Schritt für Schritt reduzieren. Der Einsatz von Speichertechnologien gewinnt in diesem Zusammenhang zunehmend an Bedeutung. Für die optimale Auslegung des Systems entwickelte das RLI ein Simulationsmodell für die Auslegungshilfe für das Micro Smart Grid.




Abbildung 2. Schematische Topologie des MSG EUREF

Eines der Entscheidungsprobleme bzgl. der Dimensionierung der einzelnen Komponenten des MSG EUREF besteht in dem Konflikt zweier Zielstellungen, der Maximierung der Selbstversorgung (**Self-Sufficiency Ratio**) als auch der Minimierung der Gestehungskosten (**Levelized Cost of Energy**).

Die Levelized Cost of Energy (*LCOE*) entsprechen dem Quotienten aus nivellierten Jahresenergiekosten und dem erwarteten Jahresenergiebedarf. Der zeitbezogene Self-sufficiency ratio (SSR_t) beschreibt den zeitbezogenen Grad der Selbstversorgung im System und entspricht der Anzahl aller Stunden im Jahr, in denen weder Energiebezug noch -abgabe aus der übergelagerten Netzebene stattfindet, bezogen auf 8760 Stunden.

Die Optimierung wird mit einem Multi-objective evolutionary algorithm durchgeführt, der speziell für die Anforderungen der MSG-Optimierung angepasst wurde (Wanitschke, 2015). Evolutionäre Algorithmen sind populationsbasierte meta-heuristische Optimierungsverfahren die auf den Prinzipien der Darwinisten Evolutionstheorie basieren (Selektion, Rekombination, Mutation). Sie gehören zu den vielversprechendsten heuristischen Verfahren für die Auslegung hybrider Energiesysteme (Baños et al., 2011; Fadaee & Radzi, 2012).




Abbildung 3. Verlauf und Ergebnis der evolutionären Mehrzieloptimierung

Abbildung 3 zeigt das Ergebnis des Optimierungslaufs. Die erste Generation der Lösungen wird zufällig im Parameterraum verteilt und konvergiert im Optimierungsverlauf gegen die Paretofront, welche den optimalen Tradeoff zwischen LCOE-Minimierung und SSR_t -Maximierung repräsentiert. Einerseits zeigt das Ergebnis, welcher Entscheidungskonflikt bzgl. der Auslegungsziele auftritt, andererseits legt es den Nachteil offen, der sich bei einer reinen Kostenoptimierung

ergeben hätte: Insbesondere im Bereich geringer SSR_t führt eine leichte Entspannung der Kostenminimierungsanforderung zu erheblichen Verbesserungen in der Selbstversorgung. Gleichzeitig verdeutlicht das Ergebnisbild die Problematik in der Anforderung kompletter Selbstversorgung, da die höchsten Wertebereiche der Selbstversorgung einen überproportionalen Kostenanstieg verursachen. Um das Konfliktbild besser zu verstehen und die Ergebnisanalyse zu vervollständigen, wird von der Bewertungsebene in die Ebene der Entscheidungsvariablen (Parameterebene) gewechselt, hier beispielhaft zur Diskussion der Rolle der verschiedenen Energiespeichertechnologien (Abbildung 4).

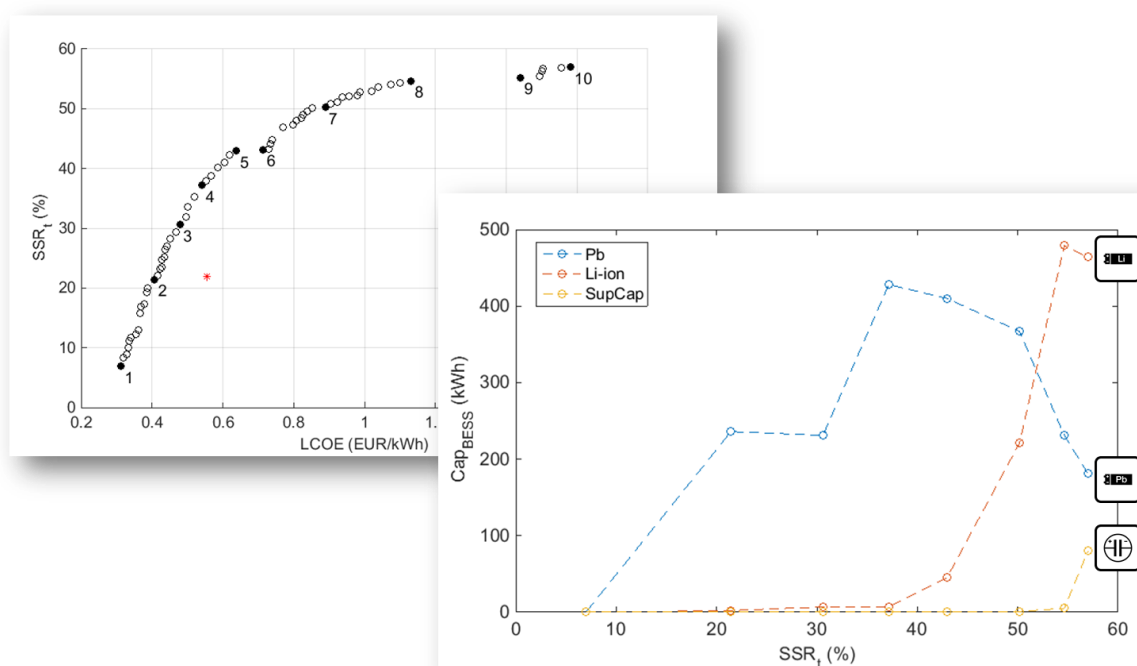


Abbildung 4. Analyse des Zielkonflikts auf Parameterebene

Die drei dem Entscheidungsträger zur Verfügung stehenden Speichertechnologien unterscheiden sich grundsätzlich in zwei Punkten: ihrer maximalen C-Rate (Quotient aus dem maximal zulässigen Lade- und Entladestrom und der Kapazität des Speichers) und ihrer kapazitätsspezifischen Kosten. Grundsätzlich nehmen in dem hier demonstrierten Fall die Kosten mit der Leistungsfähigkeit des Speichers zu.

Für Lösungen im unteren SSR_t -Bereich kommt eine Blei-Säure-Batterie zum Einsatz, da sie die geringsten Kosten verursacht und ihre Leistung ausreicht um die überschüssige erneuerbare Energie zu speichern, die notwendig ist, um die Selbstversorgung grundsätzlich anzuheben. Ab einer Selbstversorgungsrate von ca. 40% kommt ebenfalls ein Lithium-Ionen-Speicher zum Einsatz, da für höhere Selbstversorgung neben der Energiespeicherung die Leistungsspeicherung an Bedeutung gewinnt. Mit Zunahme der Kapazität des Lithium-Ionen-Speichers sinkt die Kapazität der Blei-Säure-Batterie. Im obersten Bereich der Selbstversorgung

wiederholt sich der Substitutionseffekt bei Einsatz des Superkondensators, des Speichers mit der höchsten maximalen C-Rate.

Das Beispiel verdeutlicht die Komplexität der Antwort auf die Frage nach der „besten“ Systemauslegung. Das Verfahren der Mehrzieloptimierung kann den Entscheidungsträger unterstützen, die grundsätzlichen Zusammenhänge der Fragestellung zu verstehen, um sie im Anschluss subjektiv bewerten zu können. So könnte der Entscheidungsträger im oben gezeigten Beispiel entscheiden, Teile der Paretofront zu „überspringen“, um langfristig Kosten zu sparen, z.B. indem auf den kostengünstigen Speicher verzichtet wird, da dieser langfristig durch einen leistungsfähigeren Speicher ersetzt werden müsste, um eine hohe Selbstversorgung zu erreichen.

4 Robustheitsanalyse

Der Aspekt des Risikos und die Berücksichtigung von Unsicherheiten erfahren in Anwendungen komplexer Entscheidungsfindung (z.B. Technik, Medizin oder Ökonomie) eine wachsende Aufmerksamkeit und werden mittlerweile auch von Sozialforschern, Psychologen und Rechtswissenschaftlern diskutiert (Roeser, Hillerbrand, Sandin, & Peterson, 2012).

Gerade im Energiesystemdesign sind viele Unsicherheiten nur in geringem Maße explizit quantifizierbar, was deren Einbettung in die Systemanalyse und die systematische Untersuchung des Einflusses auf das Ergebnis durch eine wie auch immer geartete Sensitivitätsanalyse unverzichtbar macht (Bert Droste-Franke, 2015). Hierzu existieren bereits erste Ansätze, wie der der „Kontextszenarien“ (W Weimer-Jehle & Prehofer, 2013; Wolfgang Weimer-Jehle, 2006) oder der „Szenarioidentifikation innerhalb tiefer Unsicherheit“ (Popper, Griffin, Berrebi, Light, & Min, 2009), jedoch hat bisher der Aspekt der Unsicherheit als Entscheidungsunterstützung im Energiesystemdesign eine zu geringe Aufmerksamkeit erfahren (Dieckhoff, 2015).

Wenn die Simulation eine Zeitkomponente hat (was sehr oft der Fall ist), dann ist ein zeitvariantes Modell der Umgebung nötig. Dieses weitere Modell ist eine Vorhersage des zukünftigen Zustands und Verhalten der Umgebung. Allerdings sinkt die Verlässlichkeit solcher Vorhersagen mit der Entfernung zum Zeithorizont, ein alltägliches Beispiel dafür ist die Wettervorhersage. Um dieser Schwäche entgegenzutreten, wird oft mit Szenarien gerechnet. Es wird dabei (z.T. stillschweigend) angenommen, dass die gewählten Szenarien die plausiblen Entwicklungen abdecken. Allerdings ist diese Herangehensweise für systematische Fehler anfällig. Wer soll entscheiden, welche Szenarien zu wählen sind, vor allem bei hochkomplexen Systemen mit vielen Variablen? Tiefe Unsicherheit (engl. deep uncertainty) beschreibt Situationen, in denen Entscheidungsträger sich nicht auf ein Modell einigen können, oder die Verteilungsfunktionen der Eingangsvariablen oder

die Kostenfunktionen zur Priorisierung der Ausgangslage nicht kennen (Groves & Lempert, 2007).

Bei den Methoden der robusten Entscheidung (engl. robust decision-making, RDM) wird nicht versucht, das Verhalten eines Modells genau vorherzusagen. Stattdessen werden die Bedingungen (von den Namensgebern des RDM als „Weltzustände“, engl. „states of the world“ bezeichnet) und das Verhalten der Umgebung in einem breiten Bereich variiert (Monte-Carlo-Simulation). Dabei wird untersucht, ob das zu untersuchende Modell ein akzeptables Verhalten im größtmöglichen Anteil der Zustände hat, auch wenn dieses Verhalten nicht optimal ist (Popper, Lempert, & Bankes, 2005).

Konkret kann eine solche Robustheitsanalyse wie folgt aussehen: Eine Konfiguration des Modells wird unter einer großen, vielfältigen Menge von Weltzuständen geprüft. Für jeden Zustand wird die Konfiguration mit der verglichen, die bei vollkommener Vorhersage optimale Ergebnisse liefert. Die Differenz zwischen den Ergebnissen kann als Metrik für den Gütegrad der Lösung unter diesen Bedingungen genommen werden. Erwünscht ist eine Lösung, die unter möglichst vielen Weltzuständen hinreichend gute Ergebnisse liefert.

Die großen Datensätze auszuwerten, die durch eine solche Stichprobenmethode entstehen, bleibt eine Herausforderung. Die Patient Rule Induction Method (PRIM) wurde für die Auswertung hoch-dimensionaler Daten konzipiert (Friedman & Fisher, 1999). Der PRIM-Algorithmus lässt sich vielfältig einsetzen, u.a. für die Funktionsoptimierung selbst, aber auch für die Klassifizierung. Wegen der günstigen Eigenschaften der „Geduld“ (engl. patience) und der „Abdeckung“ wird er häufig bei RDM-Analysen angewandt. Geduld bedeutet hier, dass der Algorithmus keine vollständigen Schritte in Richtung des steilsten Anstiegs im Zielraum nimmt. Bei nichtlinearen, mehrdimensionalen Modellen bedeutet dies bessere Chancen, einen effizienten Weg zum Optimum zu finden. Bei der Abdeckung (engl. covering) werden Stichproben, die zu einer optimalen Region gehören, abgedeckt und beim nächsten Durchlauf nicht berücksichtigt. Somit kann weitere Struktur in den Daten sichtbar werden. Durch diese Eigenschaften werden tendenziell mehr Informationen aus den Daten behalten als bei gierigen Algorithmen. PRIM sucht innerhalb der mit der Monte-Carlo-Simulation generierten Datenmenge Regionen im Modellparameterraum die zu großen (oder kleinen) Mittelwerten im Bewertungsraum führen. Diese Regionen werden „Boxen“ genannt und können in mehreren Parameterdimensionen definiert werden. Abbildung 5 zeigt beispielhaft, wie eine PRIM-Box anhand der sie definierenden Parameter beschrieben werden kann. Je kleiner der Bereich eines Parameters, desto entscheidender ist dieser Parameter für die Definition der Box.

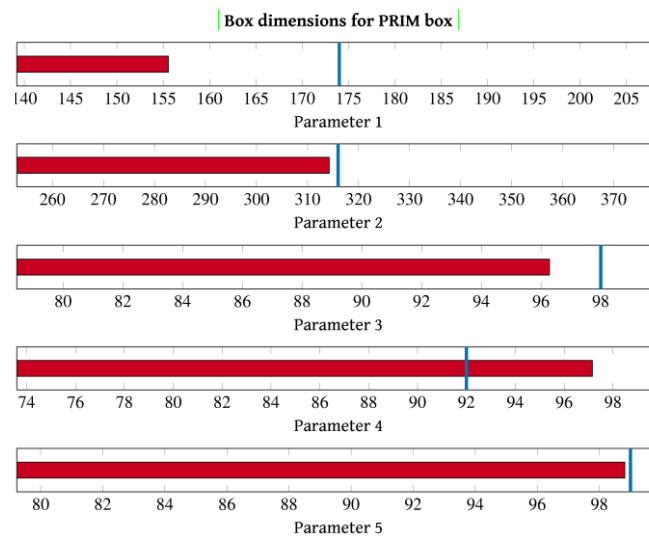


Abbildung 5. Parameterbereich innerhalb der PRIM-Box

Andere Verfahren die zu den Monte-Carlo-Filter-Verfahren gehören wie z.B. RSA (engl. Regionalized Sensitivity Analysis) und TSDE (Baumstrukturierte Dichteschätzung, engl. Tree-Structured Density Estimation) sind nur bedingt einsetzbar (Saltelli et al., 2008; Spear, Grieb, & Shang, 1994). CART (engl. Classification and Regression Trees (Breiman, Friedman, Olshen, & Stone, 1984)) ist ein weiteres Entscheidungsbaumverfahren, das den Eingaberaum in disjunkte Regionen aufteilt. CART hat in der Modellierung von Umweltsystemen Anwendung gefunden, leidet jedoch unter der vergleichsweise schlechten Interpretierbarkeit seiner Ergebnisse. PRIM hat weitere Vorteile, die für die Wahl dieses Algorithmus sprechen. Der Nutzer kann die Regelinduktion parametrisieren, um die Genauigkeit der Ergebnisse entsprechend der Ziele der Untersuchung einzustellen. PRIM findet Modi im Zielraum unter Berücksichtigung von Parametern wie Minimaldichte (Stichproben pro Hypervolumeneinheit im Parameterraum) oder Größe des Trägers (Anteil der Boxregion an der gesamten Menge). Darüber hinaus kann PRIM auch Boxen berechnen, die zu einer bestimmten binären Klasse gehören. So können Stichproben anhand eines bestimmten Verhaltens im Bewertungsraum klassifiziert werden: in erwünschte und in nicht erwünschte Lösungen. Auf Basis dieser subjektiven vom Entscheidungsträger getroffenen Klassifikation kann PRIM die entsprechenden Bereiche im Parameterraum identifizieren, welche zu erwünschtem oder unerwünschtem Verhalten führen. Diese Informationen geben Aufschluss über die Robustheit der Lösung bzgl. der untersuchten Modellparameter. Modellverhalten, für das die Boxen wenige Variablen umfassen, kann als robust hinsichtlich der nicht enthaltenden Variablen verstanden werden.

Bezüglich der oben diskutierten Optimierungsergebnisse könnten PRIM-basierte Analysen auf Lösungen in einer beschränkten Region der Paretofront angewendet werden, um die Eigenschaften bestimmter Systemauslegungen bzgl. ihrer Robustheit zu untersuchen und zu vergleichen (siehe Abbildung 6).

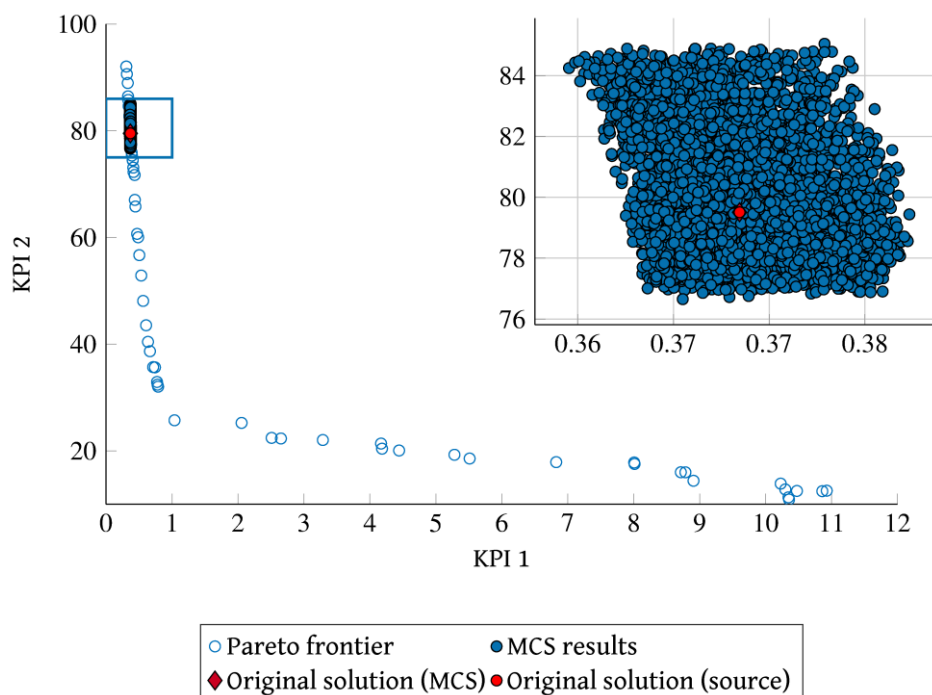


Abbildung 6. Populationsbasierte Robustheitsanalyse entlang einer Paretofront

5 Fazit

Die gezeigten Verfahren können helfen, die Komplexität der Entscheidungsfragen im Energiesystemdesign strukturiert zu analysieren und auf die wesentlichen Aspekte zu reduzieren. Die Identifikation der Zielkonflikte als auch der kritischen Parameter der Robustheit bietet dem Entscheidungsträger die Möglichkeit das Entscheidungsproblem besser zu verstehen und eine informierte Entscheidung auf Basis subjektiver Präferenzen zu treffen. Mehrzieloptimierung und Robustheitsanalyse bieten aufgrund ihres Populationscharakters grundsätzlich gute Kopplungsmöglichkeiten. So können, wie oben skizziert, nach abgeschlossener Optimierung einzelne Lösungen der pareto-optimalen Menge anhand ihrer Robustheit bewertet und miteinander verglichen werden. Denkbar wäre auch, die Robustheit einer Lösung als zusätzliche Zielstellung bereits Teil der Optimierung werden zu lassen.

Danksagung

Diese Arbeit wurde gefördert durch das *Bundesministerium für Wirtschaft und Energie (BMWi)* innerhalb des *Schaufensters Elektromobilität Berlin-Brandenburg*.

Literaturangaben

- Baños, R., Manzano-Agugliaro, F., Montoya, F. G., Gil, C., Alcayde, A., & Gómez, J. (2011). Optimization methods applied to renewable and sustainable energy: A review. *Renewable and Sustainable Energy Reviews* (Vol. 15, pp. 1753–1766).
- Bert Droste-Franke, T. Z. M. Carrier M. Kaiser Miranda Schreurs Christoph Weber. (2015). *Improving Energy Decisions*. Springer International Publishing. doi:10.1007/978-3-319-11346-3
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and regression trees*. (L. Breiman, Ed.). New York [u.a.]: Chapman & Hall/CRC.
- Dieckhoff, C. (2015). *Modellierte Zukunft: Energieszenarien in der wissenschaftlichen Politikberatung*. transcript Verlag.
- Fadaee, M., & Radzi, M. a. M. (2012). Multi-objective optimization of a stand-alone hybrid renewable energy system by using evolutionary algorithms: A review. *Renewable and Sustainable Energy Reviews*, 16(5), 3364–3369.
- Fleming, P., Purshouse, R., & Lygoe, R. (2005). Many-objective optimization: An engineering design perspective. In C. Coello Coello, A. Hernández Aguirre, & E. Zitzler (Eds.), *Evolutionary Multi-Criterion Optimization* (pp. 14–32). Springer.
- Franssen, M. (2005). Arrow's theorem, multi-criteria decision problems and multi-attribute preferences in engineering design. *Research in Engineering Design*, 16(1-2), 42–56. doi:10.1007/s00163-004-0057-5
- Friedman, J. H., & Fisher, N. I. (1999). Bump hunting in high-dimensional data. *Statistics and Computing*, 9(2), 123–143.
- Groves, D. G., & Lempert, R. J. (2007). A new analytic method for finding policy-relevant scenarios, 17, 73–85. doi:10.1016/j.gloenvcha.2006.11.006
- Popper, S. W., Griffin, J., Berrebi, C., Light, T., & Min, E. Y. (2009). *Natural gas and Israel's energy future: a strategic analysis under conditions of deep uncertainty*. RAND.
- Popper, S. W., Lempert, R. J., & Bankes, S. C. (2005). Shaping the Future, (April 2005), 66–71.
- Roeser, S., Hillerbrand, R., Sandin, P., & Peterson, M. (2012). *Essentials of Risk Theory*. Springer Science & Business Media.
- Saltelli, A., Ratto, M., Andres, T., Campolongo, Cariboni, J., Gatelli, D., Saisana, M., et al. (2008). *Global Sensitivity Analysis*. John Wiley & Sons Ltd.
- Simon, D. (2013). *Evolutionary Optimization Algorithms*. John Wiley & Sons, Inc.
- Spear, R. C., Grieb, T. M., & Shang, N. (1994). Parameter uncertainty and interaction in complex environmental models. *Water Resources Research*, 30(11), 3159–3169.

- Wanitschke, A. (2015). Evolutionary multi-objective optimization of micro grids. *Energy, Science and Technology 2015. The energy conference for scientists and researchers. Book of Abstracts, EST, Energy Science Technology, International Conference & Exhibition, 20-22 May 2015, Karlsruhe, Germany*. Karlsruher Institut für Technologie (KIT).
- Weimer-Jehle, W. (2006). Cross-impact balances: a system-theoretical approach to cross-impact analysis. *Technological Forecasting and Social Change*, 73(4), 334–361.
- Weimer-Jehle, W., & Prehofer, S. (2013). Kontextszenarien. Ein Konzept zur Behandlung von Kontextunsicherheit und Kontextkomplexität bei der Entwicklung von Energieszenarien. *Technikfolgenabschätzung - Theorie und Praxis*, 22-2.
- Zitzler, E. (1999). *Evolutionary Algorithms for Multiobjective Optimization : Methods and Applications* (No. 30). Swiss Institute of Technology Zurich.