

PVactVal: Ein Ansatz für die operationale Validierung von Aufdach-PV Diffusionsmodellen

Simon Johannng¹, Emily Schulte¹, Daniel Abitz^{2,3}, Fabian Scheller⁴, Thomas Bruckner¹

Highlights

- Die Validierung des Modells PVact stellt sicher, dass die Simulation dem modellierten Gegenstand so weit wie möglich entspricht.
- Für die operationale Validierung des Simulationsmodell wurde die fehlerminimierende Parameterwahl evaluiert und ein alternativer Ansatz entwickelt.
- Das Modell weist einen Grad an Stochastizität auf, der bei der Modellkalibrierung zu Inkonsistenzen führt.
- Ein Ansatz über paarweisen Szenariovergleich wurde als Alternative hierzu entwickelt.

Validierung empirisch fundierter Modelle

Unter Modellvalidierung versteht man grob gesagt die Demonstration, dass ein Modell dem modellierten Gegenstand entspricht oder zumindest für die Abbildung des Modellierungskontextes geeignet ist. Sie stellt damit den wichtigsten Teil der Modellerstellung dar.⁵ Zur Validierung betrachtet

¹Institut für Infrastruktur und Ressourcenmanagement, Universität Leipzig

²Institut für Informatik, Universität Leipzig

³Universitätsrechenzentrum, Universität Leipzig

⁴Department of Technology, Management and Economics, Technical University of Denmark

⁵Vgl. Heath u. a., 2009.

man verschiedene Ansätze: Die *theoretische Verifikation* demonstriert eine adäquate Konzeptualisierung des Modellgegenstandes, während die *operationale Validierung* überprüft, inwiefern die Simulationsergebnisse mit den gemessenen Daten übereinstimmen.⁶ Die *Kreuzmodellvalidierung* misst, inwiefern sich die Resultate zweier Modelle entsprechen. Die *interne Validierung* prüft die Korrektheit der Softwareimplementierung, während die *Sicherheitsvalidierung* sicherstellt, dass in der Modellrekonfigurierung dieses nur minimal manipuliert wird. Die *Datenvalidierung* stellt sicher, dass Daten akkurat und adäquat gewählt und aufgearbeitet sind.⁷ In den modellseitigen Teil der Validierung fallen hierbei die theoretische Verifikation, operationale Validierung und Datenvalidierung. Die theoretische Verifikation und die Datenvalidierung des auf dem Innovationsdiffusionsframework IRPact⁸ beruhenden Modells PVact wurde bereits mit der theoretischen und empirischen Fundierung des Modells vorgenommen und im Ansatz dargestellt; daher konzentriert sich dieses Kapitel im Folgenden auf die **operationale Validierung** des Modells.

Carley unterscheidet zwischen 'intellektiven' (eng. *intellective*) Modellen als einfache Modelle, die für die theoretische Überprüfung von Annahmen oder spezifischer Prinzipien geeignet sind, und emulativen Modellen, die auf die Umsetzbarkeit spezifischer Veränderungen an einem tatsächlichen System abzielen. Für emulative Modelle ist eine grundlegendere Validierung notwendig und Modellkalibrierung gerade dann wichtig, wenn das Modell darauf abzielt, explizite Empfehlungen bezüglich eines spezifischen Problems oder einer Organisation zu geben. Dieses unterstreicht die Bedeutung der Modellkalibrierung im Kontext des SUSIC Projektes.⁹ Unter Modellkalibrierung versteht man hierbei die Einstellung des Modells in einer Weise, die sicherstellt, dass die Simulationsergebnisse des Modells den realen Daten entsprechen. Dieses umfasst den Abgleich von Modellparametern und -prozessen.

Während ein sehr großer Teil der Parameter des PVact-Modells bereits durch die empirische und theoretische Fundierung festgelegt werden konnte, war dies nicht für alle Modellparameter möglich. Für die Bestimmung

⁶Vgl. Takadama u. a., 2008.

⁷Vgl. Carley, 1996.

⁸Vgl. Johanning, Scheller u. a., 2020.

⁹Vgl. Carley, 1996.

dieser freien Parameter wurde der Ansatz der Modellkalibrierung gewählt, welcher in diesem Beitrag eruiert und diskutiert wird.

Ansatz zur Modellkalibrierung

Der erste Agentenzustand im Prozessmodell von PVact bildet ab, wie sich das Interesse an PV-Systemen in der Agentenpopulation verbreitet. Erst bei hinreichendem Interesse kann eine individuelle Adoptionsentscheidung getroffen werden.

Das Interesse verbreitet sich im Modell durch die Kommunikation mit Agenten im eigenen sozialen Netzwerk. Nach erfolgter Kommunikation erlangen Agenten je nach Adoptionszustand der Kommunikationspartner eine bestimmte Anzahl sogenannter Interessensepunkte; das Modell unterscheidet dabei zwischen Adoptern, Interessierten¹⁰ und Bewussten¹¹. Erreichen die kumulierten Interessensepunkte einen im Modell gesetzten *Interessenschwellenwert* (IT), gehen sie in den nächsten Zustand (Prüfung der Machbarkeit) über. Mit der Interessepropagierung verfügt das Modell somit über einen Mechanismus zur Verbreitung (Diffusion) von einer entscheidenden Adoptionsvoraussetzung. Dieser Mechanismus hängt wiederum deutlich von den erworbenen Interessensepunkten nach Adoptionsstatus der Kommunikationspartner sowie dem Interessenschwellenwert ab. In dem auf den *Machbarkeitszustand* folgenden *Evaluationszustand* bestimmen die entsprechenden Agenten den für sie individuellen Wert einer Anlage entsprechend einer Nutzwertanalyse. Diesen Wert vergleichen sie mit einem weiteren Parameter, dem *Adoptionsschwellenwert* (AT). Erreicht oder übersteigt der Nutzwert diesen Wert, adoptieren Agenten (sofern sie finanziell dazu in der Lage sind¹²) die Technologie.

Da die diskutierten Variablen modellintrinsisch sind und keine Entsprechung in der empirischen Fundierung des Modells haben, werden diese als *freie Parameter* angesehen, die von den Modellierenden gesetzt werden müssen, um das Modell zu kalibrieren. Diese stellen entsprechend unterschiedliche *Modellparametrisierungen* dar. Die Interessensepunkte, die der

¹⁰Solchen Agenten, die bereits den Interessenschwellenwert erreicht haben.

¹¹Alle Agenten verfügen über Bewusstsein über PV-Systeme.

¹²Siehe hierzu den Beitrag zum Entscheidungsverhalten der Agenten in diesem Band.

kommunizierende Agent in Abhängigkeit des Adoptionszustandes des Kommunikationspartners erhält, werden als *sekundäre Parameter* bezeichnet; von diesen hängt die Geschwindigkeit der Interesseakkumulation der Agenten ab (also wie schnell der Interessenschwellenwert erreicht wird). Ein Überblick der freien Parameter wird in Tabelle 11.1 gegeben.

Tabelle 11.1.: Freie Parameter im PVact Modell

Parameter	Wertebereich	Bedeutung
<i>Primäre freie Parameter</i>		
Adoptionsschwellenwert	$[0, 1]$	Minimaler Nutzenwert für Adoption
Interessenschwellenwert	N_0	Minimales Interesse für Übergang in Machbarkeitsphase
<i>Sekundäre freie Parameter</i>		
Adoptereinfluss	N_0	erhaltene Interessenpunkte durch Kommunikation mit Adoptern
Interessierteneinfluss	N_0	erhaltene Interessenpunkte durch Kommunikation mit interessierten Agenten
Bewussteneinfluss	N_0	erhaltene Interessenpunkte durch Kommunikation mit bewussten Agenten

Vorstudie zur Modellparametrisierung

Eine Betrachtung der sekundären Parameter im Rahmen einer Vorstudie mit reduzierter Agentenanzahl für die Fallstudie 'Leipzig' zeigte, dass der Effekt von Interessenpunkten über nicht-interessierte Agenten zu einer sehr schnellen und sprunghaften Verbreitung von Interesse, und mittelbar auch der Adoption führt, welches wiederum zu einem sehr steilen und mit der

beobachteten Diffusion inkonsistenten Adoptionsverlauf führt. Für den Zusammenhang des Adoptereinflusses AP , Interessierteneinflusses IP und dem Interessenschwellenwert IT ist festzustellen, dass (annähernd) eine Proportionalitätsrelation besteht¹³, welches die betrachtete Parameterzahl einschränkt und den betrachteten Raum auf einen zwei-dimensionalen Raum reduziert. Zwischen den in der Vorstudie betrachteten Parameterkonstellationen der sekundären Parameter¹⁴ wurde (mit Ausnahme des Bewusstseins einfluss) kein drastischer Unterschied gesehen. Die Vorstudie hat gezeigt, dass eine Setzung der sekundären Parameter $(IP, AP) = (1, 5)$ zu guten Ergebnissen führt.

Anhand der durchschnittlichen Abweichung der installierten Anlagen zwischen den Simulationsergebnissen und der tatsächlichen Adoption wurden systematisch Kombinationen der primären freien Parameter innerhalb eines festgelegten Bereiches bewertet. Die untersuchten Parameter beinhalteten die Eckpunkte dieses Bereiches sowie dazwischenliegende Punkte in einem gleichmäßigen Abstand. Von diesen Punkten werden nun die Parameter ausgewählt, die den geringsten Fehler Δ erzeugt haben und als Mittelpunkt einer neuen Verfeinerung des betrachteten Bereiches gesetzt, um sicherzustellen, dass diese Punkte innerhalb des verfeinerten Suchbereiches liegen. Durch den in Kasten 1 beschriebenen Ansatz wird somit der Parameterraum systematisch durchsucht.

Für die Vorstudie der Kalibrierung auf Basis der Fallstudie 'Leipzig' wurden drei Fehlermetriken betrachtet: der durchschnittliche Fehler (mean average error MAE), der die jährliche Abweichung installierter PV-Systeme zwischen den Simulationsergebnissen x_i und den Referenzdaten \hat{x}_i über N Jahre beschreibt (siehe Gleichung 11.1), der quadratische Fehler $RMSE$ (root mean square error als Wurzel der Summe der quadratischen Fehler, siehe Gleichung 11.2) und die kumulative Adoptionsabweichung CAE (cumulative adoption error als den durchschnittlichen Fehler der installierten Systeme zwischen der Simulation und den beobachteten Daten, siehe Gleichung 11.3).

Um eine größere Anzahl von Fällen unter diesen drei Fehlermetriken zu

¹³Also dass bspw. ein Interessenschwellenwert von 40, Adoptereinfluss 1 und Interesseneinfluss von 2 zu dem gleichen Modellverhalten führt wie ein Interessenschwellenwert von 80, Adoptereinfluss 2 und Interesseneinfluss von 4.

¹⁴ $(IP, AP) \in \{(1, 2), (1, 3), (1, 5), (2, 5)\}$.

Algorithm 1 ALGO Grid Depth Search

aktuelles $\Delta \leq$ akzeptables Δ ODER Rekursionstiefe $RT \geq$ max. $RT \rightarrow$ ENDE
 Berechne Gitter $([\underline{IT}, \overline{IT}]) \times ([\underline{AT}, \overline{AT}])$ mit äquidistanten Punktabständen.
 Berechne das Modell für jeden Gitterpunkt und sammle die Ergebnisse in einer Matrix

$$\begin{array}{ccc} ((\underline{IT}, \underline{AT}) & \dots & ((\underline{IT}, \overline{AT}) \\ \dots & \dots & \dots \\ ((\overline{IT}, \underline{AT}) & \dots & ((\overline{IT}, \overline{AT}) \end{array}$$

Für jedes Minimum: berechne Grenzen eines feineren Gitters mit neuem Durchmesser $[\underline{IT}, \overline{IT}] * \text{scaleFactor}^{-1}$ und $[\underline{AT}, \overline{AT}] * \text{scaleFactor}^{-1}$ mit der Ausnahme von Punkten außerhalb von $[0, 128] \times [0.0, 1.0]$ ¹⁵.

betrachten, wurde die Simulation mit einer reduzierten Anzahl von 1.341 Agenten¹⁶ durchgeführt, wobei die sozio-ökonomischen und geografischen Verteilung proportional beibehalten wurden.

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - \tilde{x}_i| \quad (11.1)$$

$$RMSE = \frac{1}{N} \sqrt{\sum_{i=1}^N (x_i - \tilde{x}_i)^2} \quad (11.2)$$

$$CAE = \frac{1}{N} \sum_{i=1}^N \left| \sum_{j=1}^i x_j - \sum_{j=1}^i \tilde{x}_j \right| \quad (11.3)$$

¹⁵Dieser Bereich wurde gewählt, da der Adoptionsschwellenwert nach Definition im Einheitsintervall liegt, und der Interesseschwellenwert eine nicht-negative Zahl darstellt. Der obere Schwellenwert des Interesseschwellenwertes von 128 wurde im Rahmen der Vorstudie entsprechend festgelegt.

¹⁶Die fallstudienabhängige Anzahl reduzierter Agenten wurde so gewählt, dass zu Beginn der Simulation (2008) zwei Agenten bereits über eine PV-Anlage verfügen.

Ergebnisse der Vorstudie zur Wahl der Metrik und Parametereingrenzung

Das Ergebnis der Simulation für die Vorstudie am Fall Leipzig zeigt, dass kleine Parameterwerte *IT* und *AT* über alle Metriken hinweg zu großen Fehlern führen (siehe Abbildung 11.1).




Abbildung 11.1.: Differenz der Simulationsergebnisse und tatsächlicher Adoption entsprechend der Fehlermetriken MAE, RMSE und CAE laut Formeln 11.1, 11.2 und 11.3. Eigene Darstellung und Berechnung.

Für andere Parameterbereiche zeichnet sich ein weniger deutliches Bild ab. Eine engere Betrachtung der Parameterlandschaft mit kleineren Fehlern zeigt eine starke Abweichung der Fehler zwischen ähnlichen Parameterkombinationen, die zwischen den betrachteten Fehlermetriken nicht konsistent sind, wie in Abbildung 11.2 gezeigt ist.




Abbildung 11.2.: Betrachtung der Parameterkombinationen mit beschränktem Fehler zwischen den Referenzdaten und den Simulationsergebnissen. Fehlerbezogene Inklusionsschranke gesetzt bei 4,5 (MAE), 3,6 (RMSE) bzw. 37,2 (CAE). Eigene Darstellung und Berechnung.

Eine genauere Analyse zeigt auf, dass diese deutlichen Unterschiede im Simulationsergebnis nicht allein auf die unterschiedliche Parametrisierung

zurückzuführen sind. Wie vergleichende Analysen mit fixierten Parametrisierungen zeigen, haben stochastische Elemente des Entscheidungsalgorithmus (z.B. die stochastische Agenteninitialisierung, Kommunikationsverhalten oder die Einstellungsdynamik) teilweise einen Einfluss auf die Abweichung zu den beobachteten Werten (vgl. Abbildung 11.3), der den Einfluss einer unterschiedlichen Parameterwahl (in dem in Abbildung 11.2 betrachteten Rahmen) deutlich übersteigt. Dies betont die Notwendigkeit, den Einfluss stochastischer Modellkomponenten auf den Simulationsverlauf im Rahmen der Modellkalibrierung und Modellanwendung explizit zu berücksichtigen.




Abbildung 11.3.: Beispiel für den Einfluss stochastischer Modellkomponenten auf die Simulationsergebnisse anhand des kumulierten Adoptionsverlaufs gleicher Parametrisierung bezüglich des Referenzverlaufs. Parametrisierung der Läufe mit IT von 128 und AT von 0,25 für eine reduzierte Agentenzahl in der Fallstudie Leipzig. Eigene Darstellung und Berechnung.

Fallstudie Dresden: Kalibrierung des Modells PVact

Die Kalibrierung des Adoptionsschwellenwerts für das Modell wurde anhand der Fallstudie Dresden mit voller Agentenpopulation vorgenommen. Die Abweichungen der Referenzdaten wurden hierbei mit dem kumulierten Fehler (CAE) vorgenommen. Die Ergebnisse sind in Abbildung 11.4 dargestellt.

Auch bei dieser Studie zeigt sich ein klares Bild für geringere Interessenschwellenwerten, unter denen im Modell sehr früh in der Simulation sehr

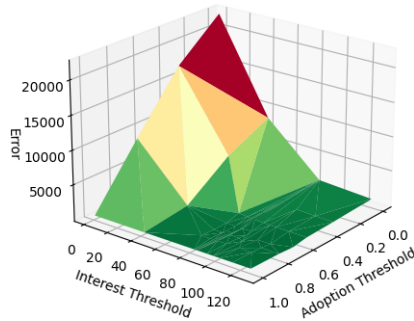


Abbildung 11.4.: Betrachtung der vollen Fallstudie Dresden unter der Fehlermetrik CAE. Eigene Darstellung und Berechnung.

stark adoptiert wird. Bei der näheren Betrachtung zeigt sich ähnliches Verhalten wie in der Vorstudie (siehe Abbildung 11.5); allerdings ist hier der Parameterbereich, in dem das beobachtete Verhalten gut angenähert wird, konzentrierter als dieses in der Vorstudie der Fall war. Dies gilt insbesondere für den Adoptionsschwellenwert, der für den Wert 0,704 qualitativ die besten Ergebnisse hervorbringt (für die Interessenschwellenwerte 84, 94, 104 und 114).




Abbildung 11.5.: Betrachtung einer reduzierten Menge der Ergebnisse für die volle Fallstudie Dresden unter der Fehlermetrik CAE. Eigene Darstellung und Berechnung.

Der Einfluss der Stochastizität zeigt sich bei dieser Studie ebenso wie in der Vorstudie, allerdings fällt dieser weniger drastisch aus. Zwischen Läufen gleicher Parametrisierung sind Abweichungen von bis zu 67% zu

beobachten (siehe hierfür Abbildung 11.6), während sich selbst Läufe mit unterschiedlicher Parametrisierung teilweise nur um gut 1% unterscheiden.




Abbildung 11.6.: Beispiel für den Einfluss stochastischer Modellkomponenten auf die Simulationsergebnisse anhand des kumulierten Adoptionsverlaufs gleicher Parametrisierung bezüglich des Referenzverlaufs. Parametrisierung der Läufe mit IT von 104 und einem AT von 0,704 für die volle Agentenzahl in der Fallstudie Dresden. Abweichungen zu der Referenzzeitreihe betragen 69,25 bzw. 115,42. Eigene Darstellung und Berechnung.

Die Fallstudie Dresden mit der vollen Agentenzahl weist somit zwar weiterhin eine deutliche Abweichung auf; diese ist aber in ihrer Größenordnung nicht mit der oben betrachteten reduzierten Fallstudie Leipzig vergleichbar. Ein gewisser Grad an Stochastizität scheint somit durch die Modellgröße kompensiert zu werden. Dieses könnte auch an der Diskretizität des Systems liegen, da die Adoption einer einzelnen PV-Anlage einen deutlich stärkeren Einfluss hat, wenn die Gesamtanlagen im niedrigen zweistelligen Bereich liegen, als wenn sie sich im hohen dreistelligen Bereich befinden.

Diskussion der Kalibrierungsstudie und des Validierungsansatzes

Diese Ergebnisse zeigen, dass der Ansatz zur Exploration der Parameterlandschaft zwar grundlegend funktioniert sowie Ergebnisse differenziert und nah an der tatsächlichen Adoption darstellen kann (wie im jeweilig linken Verlauf der Abbildungen 11.3 und 11.6 zu sehen ist); jedoch zeigt

sich ebenfalls, dass sich dieser für eine exakte Bestimmung eines Parameteroptimums nur wenig eignet. Der Ansatz der operationalen Validierung von PVact mit einer fehlerminimierenden Parameterkombination der freien Parameter zeigt somit eine fundamentale Herausforderung der Parameteroptimierung von Modellen stochastischer Systeme. Wenn der Unterschied verschiedener Simulationsläufe mit gleicher Parametrisierung größer ist als die Ergebnisse verschiedener Parametrisierung, ist die Unterscheidungskraft verschiedener Parametrisierungen vernachlässigbar und ein neuer Ansatz für die Fundierung der Modellergebnisse notwendig.

Als Lösung für diese Lage war somit ein Ansatz zu finden, der es ermöglicht, die im Anwendungskontext auftretende stochastische Varianz abzubilden, miteinander zu vergleichende Läufe nicht durch stochastische Einflüsse zu überlagern und Szenarien, die verschiedene Handlungsoptionen darstellen, miteinander zu vergleichen können. Der Modellvalidierungsansatz PVactVal basiert auf dieser Beobachtung und wird im Folgenden dargestellt.

PVactVal

PVactVal ist ein Simulationsmodellvalidierungsansatz, der die Stochastizität von Systemdynamiken agentenbasierter Innovationsdiffusionsmodelle als gegeben akzeptiert. Er ist als eine Antwort auf die oben dargestellte Problematik zu verstehen. Anstelle der Optimierung einzelner Parameterkombinationen, die den gemessenen Fehler als beste Annäherung an die Realität minimieren, nimmt dieser die Stochastizität realer komplexer Systeme ernst. Der Ansatz evaluiert dabei nicht Handlungsoptionen einzelner Modellinstanzen, sondern gruppiert vergleichbare Simulationsläufe über verschiedene Parameterkombinationen, stochastische Ereignisse und Szenarios hinweg.

Die Auswertungsphase des Modellierungsprozesses verläuft hierbei wie folgt:

1. Definition der Metrik M , Parameterbereich $[\underline{AT}, \overline{AT}] \times [\underline{IT}, \overline{IT}]$ ¹⁷, Granularität $g \in \mathbb{N}^+$, Interventionsmaßnahmen $K \ni k_0$ (mit k_0 als den

¹⁷Dabei ist \underline{AT} die untere Schranke des Adoptionsschwellenwerts, \overline{AT} die obere Schranke des Adoptionsschwellenwerts, \underline{IT} die untere Schranke des Interessenschwellenwerts und \overline{IT} die obere Schranke des Interessenschwellenwerts.

- Referenzfall (business-as-usual)), und der Anzahl der Wiederholungen n ,
2. Erzeugung von $g^2 * n$ paarweise unterschiedlicher Seeds S_L für den Zufallszahlgenerator, der in der Simulation verwendet wird¹⁸,
 3. Indizierung der Parameterkombination (AT_i, IT_i) mit den Indizes $i \in [0, g^2 - 1]$, sodass $(AT_i, IT_i) = (\underline{AT} + ((i \bmod g) * \frac{\overline{AT} - \underline{AT}}{g}), (IT + (\lfloor \frac{i}{g} \rfloor * \frac{\overline{IT} - \underline{IT}}{g})))$ gilt, um ein gleichmäßiges (äquidistantes) Netz auszuwertender Punkte im Parameterquader zu erzeugen¹⁹,
 4. Für alle Maßnahmen $k \in K, i \in [0, g^2 - 1], j \in [0, n - 1]$ werte das Modell an den Parameterwerten AT_i, IT_i mit Seed $s_l \in S_L, l = i * n + j$ aus, um das Modellverhalten P_{ijk} zu erhalten,
 5. Für alle paarweisen $k, \hat{k} \in K$, analysiere $M(P_{ijk}, P_{ij\hat{k}})$,
 6. Für jede Wiederholung j aggregiere $M(P_{ijk}, P_{ij\hat{k}})$ über alle $i \in [0, n - 1]$ und erzeuge die Parameterfehlermatrix über alle Parameter AT_i, IT_i .

Für Schritt 1) ist es an den Modellierenden sicherzustellen, dass das Parameterintervall im plausiblen Bereich liegt, in dem das Modell Ergebnisse liefert, die 'nahe genug' an den Referenzdaten liegen, um angemessene Modellinstanzen zu analysieren.

Ausblick & zukünftige Arbeiten

Der vorgestellte Ansatz ist Teil aktiver laufender Forschung am Simulationsmodell PVact und ist als solcher Teil weiterer Modelluntersuchungen. Zukünftige Forschung konzentriert sich auf die Integration der Validierungsframeworks in die tiefere Analyse des Modells. Eine vielversprechende Forschungsrichtung wird hierbei in den Auswirkungen einzelner Modelldynamiken auf der Komponentenebene gesehen. Durch Veränderungen bzw. Deaktivierung einzelner Modellelemente kann ihr Effekt,

¹⁸Zwei Simulationsläufe mit dem gleichen Seed erzeugen das exakt gleiche Simulationsverhalten wenn Parallelität der Simulation unterbunden wird (bei exakt gleicher Parametrisierung), sodass Simulationsläufe unterschiedlicher Szenarien mit gleichem Seed direkt vergleichbar sind.

¹⁹Diese Transformation von einem eindimensionalen Index in ein zweidimensionales Netz zerlegt den Bruch $\frac{i}{g}$ in seinen ganzzahligen Teil $\lfloor \frac{i}{g} \rfloor$ (wobei die Abrundungsfunktion $\lfloor x \rfloor : \mathbb{Q} \rightarrow \mathbb{Z}$ eine rationale Zahl auf die nächstkleinere ganze Zahl projiziert) und ihren Rest (i.e., $\frac{i}{g} = \lfloor \frac{i}{g} \rfloor + i \bmod g, \forall i, g \in \mathbb{Z}$).

sowie die Auswirkung auf andere Modellkomponenten untersucht werden. Dieses verbessert nicht nur das Verständnis der einzelnen Komponenten, sondern auch des Modellverhaltens selber.

Weiterhin hat sich die Modellentwicklung eher auf die Validierung des Modells als dessen Anwendung und die Auswertung politischer Instrumente und Maßnahmen konzentriert. Diese Instrumente einzubauen und deren Unterschiede im Modellverhalten zu untersuchen führt zu tieferen Verständnis der Auswirkungen der Instrumente sowie des Modells. Der oben beschriebene Ansatz ist explizit darauf ausgerichtet, verschiedene Maßnahmen zu vergleichen und sollte durch die Anwendung dieser Maßnahmen evaluiert werden.

Eher theoretischer Natur sollte sich zukünftige Forschung verschiedener Ansätze zur Aggregation der Qualität der Ergebnisse widmen. Es ist zu erwarten, dass sich die Struktur der Unterschiede der Ergebnisse darin unterscheidet, ob Maßnahmen zwischen einzelnen Modellläufen verglichen werden oder Läufe der gleichen Parameterkombination vor dem 5. Schritt aggregiert werden. Dieses würde vermutlich ebenso gelten, wenn der Vergleich zwischen den Maßnahmen nach der Erstellung der Parameterfehlermatrix aggregiert wird. Dieses hängt weiterhin stark davon ab *wie* die Maßnahmen verglichen werden. Verschiedene Läufe mit unterschiedlichen Parametern führen zu einer Verteilung der Modellergebnisse auf dessen Basis die Maßnahmen verglichen werden. Konkret betrifft dieses die Frage, ob die verwendeten Fehlermetriken M auf skalaren Werten oder einer Matrix von Werten beruhen, bzw. wie die Abstände innerhalb dieser Metrik gemessen und bewertet werden.

Ein weiterer Einflussfaktor auf die Qualität der Modellergebnisse wird in der Skalierung gesehen. Die Abbildungen zeigen, dass sich stochastische Modellabweichungen ein Stück weit normalisieren, wenn der Modellierungskontext größer gezogen wird. In einer tieferen Untersuchung der Skalierung wird eine weitere wertvolle Forschungsrichtung gesehen.

Schließlich wäre eine stärkere Anbindung an die Literatur zum Umgang mit Unsicherheit (uncertainty) in der Modellierung und Simulation sowie stochastischer Phänomene hilfreich, um die Diskussion theoretisch stärker zu verankern.

Anmerkung

Inhalte dieses Kapitels wurden auf der 'European Energy Market Conference' 2022 in englischer Sprache eingereicht.²⁰

Danksagung

Dieser Beitrag wurde finanziert durch das Projekt „Smart Utilities and Sustainable Infrastructure Change“ (Antragsnummer 100378087 (SAB)).

Diese Maßnahme wird mitfinanziert durch Steuermittel auf der Grundlage des vom Sächsischen Landtag beschlossenen Haushaltes.



DOI: <https://doi.org/10.30819/5413.11>

Literatur

- Carley, K. M. (1996). »Validating Computational Models«. In: *CASOS Working Paper* 0793.
- Heath, B., R. Hill und F. Ciarallo (2009). »A Survey of Agent-Based Modeling Practices (January 1998 to July 2008)«. In: *Journal of Artificial Societies and Social Simulation* 12.4 9.
- Johanning, S., D. Abitz, E. Schulte, F. Scheller und T. Bruckner (Sep. 2022). *PVactVal: A Validation Approach for Agent-based Modeling of Residential Photovoltaic Adoption*. 18th International Conference on the European Energy Market (EEM).
- Johanning, S., F. Scheller, D. Abitz, C. Wehner und T. Bruckner (2020). »A modular multi-agent framework for innovation diffusion in changing business environments: conceptualization, formalization and implementation«. In: *Complex Adaptive Systems Modeling* 8.1. DOI: 10.1186/s40294-020-00074-6.
- Takadama, K., T. Kawai und Y. Koyama (2008). »Micro- and Macro-Level Validation in Agent-Based Simulation: Reproduction of Human-Like Behaviors and Thinking in a Sequential Bargaining Game«. In: *Journal of Artificial Societies and Social Simulation* 11.2 9.

²⁰Vgl. Johanning, Abitz u. a., 2022.