

Methoden zur Identifizierung von Modellparametern

C. Budig, J. Orozaliev, O. Kusyy, K. Vajen

Universität Kassel, Institut für Thermische Energietechnik, D-34109 Kassel

Tel. +49 (561)804-3890, www.solar.uni-kassel.de, solar@uni-kassel.de

1. EINLEITUNG

Ertragsvorhersagen für solarthermische Systeme basieren in der Regel auf Simulationen mit mathematischen Modellen der einzelnen Systemkomponenten. Damit ein Modell das thermische Verhalten der jeweiligen Komponente abbilden kann, müssen die im Modell enthaltenen Parameter experimentell oder theoretisch bestimmt werden. In internationalen Normen werden mathematische Modelle und Testverfahren zur Identifizierung der Modellparameter festgelegt. Neben der Darstellung der Standardmethoden zur Parameteridentifizierung wird in dieser Arbeit der im Programm „GenOpt“ implementierte PSO-Algorithmus zur Parameteridentifizierung verwendet und die Ergebnisse mit denen der multilinenen Regression verglichen.

2. METHODEN DER PARAMETERIDENTIFIKATION

Ziel der Parameteridentifikation ist die Nachbildung von n experimentell ermittelten Datenvektoren $(z_{i1}, z_{i2}, \dots, z_{im}, y_i)$ mittels eines Modells mit k Parametern p_j .

$$y(z_1, \dots, z_m) = y(f_1(z_1, \dots, z_q), \dots, f_k(z_1, \dots, z_w), p_1, \dots, p_k) \quad (1)$$

Ein bewährtes Verfahren zur Identifikation der Modellparameter ist die Anpassung an Messdaten: Nach der Definition einer Zielfunktion, welche die Differenz zwischen modellierten und experimentellen Daten quantifiziert, werden die Modellparameter so angepasst, dass die Zielfunktion minimal wird. Die Bestimmung der Modellparameter ist also ein mathematisches Minimierungsproblem in einem multidimensionalen Raum, zu dessen Lösung mathematische Methoden zur Verfügung stehen. In der Regel werden von solarthermischen Testinstituten folgende Methoden verwendet:

- Multilineare Regression (MLR)
 - Methode der kleinsten Fehlerquadrate (MLR-LS)
 - Methode der gewichteten Fehlerquadrate (MLR-WLS)
- Dynamische Parameteranpassung mit dem Levenberg-Marquardt Algorithmus

Eine bisher eher selten angewandte Methode ist die genetische Optimierung mittels des Programms GenOpt. Die genannten Methoden unterscheiden sich grundlegend in dem Minimierungsprozess und damit auch in den Anforderungen, welche die Verfahren an Messdaten und Modell stellen.

MULTILINEARE REGRESSION (MLR)

Man spricht von einem multilinenen Regressionsmodell, sofern jeder Datenvektor durch Gl. 2 beschreibbar ist. Der Regressand y ist sowohl von den Regressoren

$x_j = f_j(z_1, \dots, z_w)$ als auch von den Modellparametern p_j abhängig. Das Residuum ε ist ein Fehlerterm, welcher die Abweichung zwischen modellierten und experimentellen Wert beschreibt.

$$\begin{aligned} y_i &= p_0 + p_1 \cdot x_{i1} + p_2 \cdot x_{i2} + \dots + p_k x_{ik} + \varepsilon_i \\ &= p_0 + \sum_{j=1}^n p_j x_{ij} + \varepsilon_i \quad i = 1, 2, \dots, n \end{aligned} \quad (2)$$

Das Modell definiert i. A. eine nicht linear geformte Hyperebene im k-dimensionalen Raum. Mit anderen Worten: Die Gleichungen $f_j(z_1, \dots, z_w) = x_j$ hinter den Regressoren x_j können hoch nicht-linear sein.

Die Modellparameter p_0, p_1, \dots, p_k können sowohl mit der *Methode der kleinsten Fehlerquadrate (MLR-LS)* als auch mit der *Methode der gewichteten Fehlerquadrate (MLR-WLS)* bestimmt werden. Der grundsätzliche Unterschied beider Methoden liegt in der Definition der Zielfunktion. Die MLR-LS definiert die Zielfunktion über das Residuum, also über die Abweichung zwischen experimentellen y_i und modellierten \hat{y}_i Wert. Die Unsicherheiten der MLR-LS werden u. a. in (Kratzenberg, 2006) diskutiert.

$$L = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n \left(y_i - p_0 - \sum_{j=1}^k p_j x_{ij} \right)^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \rightarrow \min \quad (3)$$

Die MLR-WLS wichtet das Residuum in der Zielfunktion mit dessen jeweiliger Unsicherheit. Die Unsicherheiten des Residuums und der Modellparameter sind dabei abhängig von dem anzupassenden Modell. Unsicherheitenanalysen wurden für das stationäre Kollektormodell der EN 12975 von (Müller-Schöll und Frei., 2000) und für das dynamische Modell der EN12975 von (Kratzenberg et al., 2006) durchgeführt.

Zur Anwendbarkeit der MLR müssen folgende Anforderungen an Messdaten und Modell erfüllt sein: Normalverteilung der Residuen, unkorrelierte Regressoren (Multikollinearität) sowie unkorrelierte Residuen (Autokorrelation). Zur Überprüfung dieser Anforderungen muss vor der eigentlichen Parameteranpassung eine Datenanalyse der Messdaten erfolgen. Bei der Verwendung der MLR-LS werden weiterhin heteroskedastische Residuen vorausgesetzt. Diese Bedingung ist i. A. bei „solarthermischen Messdaten“ nicht erfüllt, da die Unsicherheit der Residuen abhängig von den Regressoren ist (z.B. ist die Unsicherheit der Strahlungsmessung bei geringer Solarstrahlung größer als bei hoher Solarstrahlung). Gleichwohl ist die multilineare Regression das vorgeschlagene Verfahren zur Parameteridentifikation in der (EN 12975), da es in den meisten Tabellenkalkulations- sowie Statistikprogrammen implementiert sowie schnell und einfach durchführbar ist.

Neben den Anforderungen der Verfahren an die Messdaten, existieren auch Einschränkungen bzgl. der Modelle. Sofern sich die Modellgleichung nicht in die Form von Gl. 2 transformieren lässt oder ein iteratives Modell vorliegt, ist die MLR nicht anwendbar.

DYNAMISCHE PARAMETERANPASSUNG

Eine dynamische Parameteranpassungsmethode stellt das von (Spirkl, 1996) entwickelte Programm „DF“ da, welches den iterativen Levenberg-Marquardt Algorithmus (Press, 1992) zur Optimierung nutzt. Eine Abschätzung der Parameterunsicherheit ist durch die berechnete Kovarianzmatrix der Parameter möglich.

Die Verfahren MLR-LS und DF wurden in (Fischer et al., 2003) miteinander verglichen, wobei ähnliche Ergebnisse als Modellparameter identifiziert wurden. Gegenüber der MLR besitzt die dynamische Methode den Vorteil der Anwendbarkeit bei sowohl nichtlinearen als auch iterativen Modellen.

DF ist auf die gleichzeitige Identifizierung von 20 Parametern beschränkt und läuft instabil, falls die Parameter stark unterschiedliche Werte annehmen (Bales, 2001). Weiterhin liegt der Source-Code von DF nicht offen, womit sowohl eine Erweiterung als auch die Nachvollziehbarkeit der Berechnung nicht möglich ist.

GENETISCHE OPTIMIERUNG MIT GENOPT

GenOpt (Generic Optimization Program) ist ein plattformunabhängiges, frei zugängliches genetisches Optimierungsprogramm, welches die in einem externen Simulationsprogramm (z.B. TRNSYS) definierte Zielfunktion minimiert (GenOpt, 2009). Das Simulationsprogramm wird beim Optimierungsprozess iterativ von GenOpt aufgerufen, wobei beide Programme über Textdateien miteinander kommunizieren. In GenOpt sind diverse globale sowie lokale Optimierungsalgorithmen implementiert. Ein Performancevergleich der implementierten Algorithmen ist in (Wetter, 2004) zu finden. Die Standardbibliothek ist leicht durch eigene Optimierungsalgorithmen erweiterbar.

In der vorliegenden Arbeit wird der PSO-Algorithmus (Particle Swarm Optimization) verwendet, welcher von (Kennedy und Eberhart, 1995) erstmals vorgestellt wurde. Der Algorithmus simuliert einen aus vielen einzelnen Partikeln bestehenden Schwarm, welcher den Lösungsraum auf der Suche nach einer möglichst guten Lösung durchforstet. Der Algorithmus ist an das Schwarmverhalten von Tieren (z.B. Vögeln) angelehnt und besitzt eine hohe Resistenz gegenüber lokalen Minima. Eine detaillierte Beschreibung des PSO-Algorithmus ist in (Poli et al., 2007) gegeben.

Der PSO-Algorithmus liefert aber keine Aussage über die Unsicherheit des identifizierten Optimums. Ein erster Ansatz zur Unsicherheitsangabe wurde in (Budig et al., 2009) entwickelt.

3. MESSWERTE UND KOLLEKTORMODELL

MLR-LS und der PSO-Algorithmus wurden zur Parameteridentifikation des stationären Kollektormodells der EN12975 angewendet. Es wurden Messdaten eines unter kontinentalen Klima betriebenen unabgedeckten Kollektors verwendet (Vajen et al., 2008), welche als 1-min Mittelwerte aufgenommen wurden. Die Auswertungen beziehen sich auf 10-min Mittelwerte, welche im Zeitraum zwischen 11.08.2008 und 30.09.2008 gewonnen wurden. Es fanden nur Datenvektoren Berücksichtigung, wel-

che die Forderungen der EN12975 erfüllen (z.B. $G^* > 650 \text{ W/m}^2$), wobei abweichend zur Norm Windgeschwindigkeiten zwischen 1 and 2 m/s verwendet wurden. Der Kollektorwirkungsgrad berechnet sich nach (Rockendorf et al., 2001 und prEN 12975-2, 1997):

$$\eta_{mo} = \eta_0 (1 - b_u \cdot v_w) - (b_1 + b_2 \cdot v_w) \frac{(T_f - T_a)}{G^*} \quad \text{mit} \quad G^* = G + \frac{\varepsilon}{\alpha} (E_L - \sigma T_a^4) \quad (5)$$

Um die Modellparameter η_0 , b_u , b_1 and b_2 mit Hilfe der MLR-LS anzupassen, wird Gl. 5 in die Form von Gl. 2 transformiert.

$$\eta_{mo} = \underbrace{\eta_0}_{p_0} - \underbrace{\eta_0 b_u}_{p_1} \cdot \overbrace{v_w}^{x_1} - \underbrace{b_1}_{p_2} \frac{\overbrace{(T_f - T_a)}^{x_2}}{G^*} - \underbrace{b_2}_{p_3} \cdot v_w \frac{\overbrace{(T_f - T_a)}^{x_3}}{G^*} \quad (6)$$

Die zu minimierende Zielfunktion ergibt sich nach Gl. 3 als quadratische Abweichung der modellierten η_{mo} und gemessenen η_{me} Wirkungsgrade.

$$L = \sum_{i=1}^n (\eta_{me,i} - \eta_{mo,i})^2 \rightarrow \min \quad (7)$$

4. ERGEBNISSE

Zur Prüfung der Anforderungen der MLR-LS fand vor der eigentlichen Parameteranpassung eine detaillierte Datenanalyse statt. Die geforderte Normalverteilung des Residuums ist nach Abb. 1 (links) näherungsweise erfüllt.




Abb. 1: Verteilung der Residuen im Vergleich zur Normalverteilung (links); Kennlinie des unabgedeckten Kollektors unter kontinentalen Bedingungen nach MLR-LS (rechts)

Mit Hilfe der Korrelationsmatrix der Regressoren (Tab. 1, links) ist zu erkennen, dass die Forderung nach unkorrelierten Regressoren nicht erfüllt ist. Diese Korrelation lässt sich aber eher auf die Form der Modellgleichung und der Regressoren an sich als auf unzulängliche Messdaten zurückführen. Des Weiteren ist auch die Forderung heteroskedatischer Residuen nicht erfüllt.

In Tab. 1 (rechts) sind die identifizierten Kollektorparameter nach MLR-LS und GenOpt aufgeführt. Mit Hilfe der jeweiligen Kollektorwerte wurde eine Simulation im

Messzeitraum des unabgedeckten Kollektors durchgeführt und die Simulationsergebnisse mit den Messdaten verglichen. Die Simulation mit den von GenOpt identifizierten Parametern führte zu einem Solarertrag, welcher um knapp 3 % besser mit dem experimentell ermittelten Ertrag übereinstimmt. Für die Zielfunktion ergab sich ein 11 % kleinerer Wert bei Verwendung von GenOpt verglichen mit der MLR-LS. Diese Ergebnisse sind noch über Nutzung umfangreicherer Datensätze zu bestätigen.

Tab 1.: Korrelationsmatrix der Regressoren (links); Identifizierte Kollektorparameter des stationären Modells (EN 12975) unter kontinentalem Klima (rechts).

	v_w	$\frac{(T_f - T_a)}{G^*}$	$v_w \frac{(T_f - T_a)}{G^*}$		MLR-LS	GenOpt
v_w	1,00			η_0	0,82	0,84
$\frac{(T_f - T_a)}{G^*}$	-0,13	1,00		b_u in s/m	0,04	0,01
$v_w \frac{(T_f - T_a)}{G^*}$	-0,45	0,93	1,00	b_1 in W/(m ² K)	5,9	8,2
				b_2 in J/(m ³ K)	5,5	6,1

5. ZUSAMMENFASSUNG UND AUSBLICK

Zum Vergleich der MLR-LS und des in GenOpt implementierten PSO-Algorithmus wurden beide Methoden auf das stationäre Kollektormodell der EN 12975 angewendet, wobei Messdaten eines unter kontinentalem Klima betriebenen unabgedeckten Kollektors verwendet wurden. Die Ergebnisse legen den Schluss nahe, dass die Parameterwerte durch GenOpt genauer identifiziert werden. Die schlechteren Ergebnisse der MLR-LS könnten sich durch die nur zum Teil erfüllten Voraussetzungen zur Anwendbarkeit der MLR-LS erklärt werden. Diese Ergebnisse sind noch über Nutzung umfangreicherer Datensätze zu bestätigen.

Das Optimierungsprogramm GenOpt bietet die Möglichkeit einer stabilen, reproduzierbaren Parameteridentifikation, wobei keine Voraussetzungen bezgl. der Eingangsdaten oder des Modells vorliegen. Es ist geplant, Sensitivitätsanalysen der Kollektorparameter mittels GenOpt durchzuführen. Damit würde ein großer Vorteil darin bestehen, dass mithilfe ein und des selben Programms Parameteranpassung und Sensitivitätsanalyse erfolgen könnten.

NOMENKLATUR

b_1	windunabhängiger Wärme-verlustkoeffizient, W/(m ² K)	G	hemisphärische Strahlung, W/m ²
b_2	windabhängiger Wärmeverlustkoeffizient, J/(m ³ K)	G^*	Nettostrahlung, W/m ²
b_u	Windabhängigkeit des Konversions-faktors, s/m	L	Zielfunktion, versch.
E_L	Langw. Strahlungsaust., W/m ²	T_a	Umgebungstemperatur, °C
		T_f	Mittlere Fluidtemperatur, °C
		p_j	Modellparameter (MLR), versch.

v_w	Windgeschwindigkeit, m/s	ε_i	Residuum (MLR), versch.
$x_{i,j}$	Regressoren (MLR), versch.	η_0	Konversionsfaktor Kollektor
y_i	experimenteller Wert (MLR), versch.	η_{me}	Wirkungsgrad (experimentell)
\hat{y}_i	modellierter Wert (MLR), versch.	η_{mo}	Wirkungsgrad (modelliert)
$z_{1..m}$	experimentelle Daten, versch.	σ	Stefan-Boltzmann-Konstante, W/m ² K ⁴
α	Absorptionskoeffizient		
ε	Emissionskoeffizient		

LITERATUR

- Bales, C. (2001): *Parameter identification manual for TRNSYS models at SERC*, Ekos Publication
- Budig, C, Orozaliev, J. de Keizer A.C., Kusyy, O. und Vajen, K. (2009): *Collector parameter identification methods and their uncertainties*, Proceedings ISES Solar World Congress, Johannesburg
- GenOpt (2009): *Generic Optimization Program – user manual*, version 3.0.0, Simulation Research Group, Lawrence Berkeley Laboratory
- Kennedy, J. und Eberhart, R. (1995): *Particle Swarm Optimization*, Proceedings of Neuronal Networks, Perth, Australia
- Fischer, S., Heidemann, W., Müller-Steinhagen, H. und Perers, B. (2003): *Collector parameter identification -- iterative methods versus multiple linear regression*, Proceedings ISES Solar World Congress, Gothenburg
- Kratzenberg, M.G. et al. (2005): *Assessment of the partial model stability of the quasi-dynamic collector test under outdoor conditions en 12975 by the application of uncertainty analysis*, Proceedings ISEES Solar World Congress, Orlando, Florida
- Mathioulakis, E., Voropoulos, K. und Belessiotis, V (1999): *Assessment of uncertainty in solar collector modelling and testing*, Solar Energy 66, 337-347
- Müller-Schöll, C. und Frei, U. (2000): *Uncertainty analyses in solar collector measurement*, Proceedings EuroSun, Copenhagen, Denmark
- Perers, B. (1993): *Dynamic method for solar collector array testing and evaluation with standard database and simulation programs*, Solar Energy 6, 517 - 526
- prEN 12975-2 (1995): *Thermal solar systems and components – Solar collectors – Part 2 – Test methods*, European Committee for Standardization, Belgium
- Press, W., Teukolsky, S.A., Vetterling, WT und Flannery, BP (1996): *Numerical Recipes*, second edition, Cambridge University Press, Oxford
- Poli, R, Kennedy, J. und Blackwell, T. (2007): *Particle swarm optimization – an overview*, Springer Science + Business Media
- Rockendorf, G. ,Sillmann, R., Bethe, T. und Köln, H. (2001): *Solare Freibadbeheizung – Absorberprüfung und Testergebnisse*, Institut für Solarenergieforschung GmbH
- Spirkl, W. (1996): *Dynamic System Testing - Program Manual*, LMU München
- Wetter, M. und Wright, J. (2004): *A comparison of deterministic and probabilistic optimization algorithms for nonsmooth simulation-based optimization*, Building and Environment 39, 989 - 999
- Vajen, K, Budig, C, Orozaliev, J, Frank, E, Rose, C, Borodin, V., Botpaev, R, Obozov, A. Orths, R. (2008): *Solarunterstützte Fernwärmeversorgung in der GUS, Tagungsbericht Symposium Thermische Solarenergie, Staffelstein*

