

Industrial Management

INSIGHTS



Schriftenreihe der Fakultät Technik: 1/2014

Komplexe Produkte optimieren

Prof. Dr.-Ing. Harald Stuhler, Dr.-Ing. Thomas Kruse



Dr.-Ing. Thomas Kruse ist bei der ETAS GmbH Produktmanager für modellbasierte Applikationslösungen.

E-Mail: thomas.kruse@etas.com



Prof. Dr.-Ing. Harald Stuhler ist Studiengangsleiter Fahrzeug-System-Engineering an der Dualen Hochschule Baden-Württemberg Stuttgart.

Duale Hochschule Baden-Württemberg Stuttgart
Fakultät Technik - Studiengang Maschinenbau
Jägerstr. 56
70174 Stuttgart

E-Mail: harald.stuhler@dhbw-stuttgart.de

*All models are wrong.
But some are useful.*
G.E. Box

Bei der Anpassung und Optimierung komplexer Motorsteuerungssysteme hat sich die statistische Versuchsplanung als Standard etabliert [1-3]. Hierbei werden in bis zu zwölf dimensionalen Parameterräumen die optimalen Einstellwerte bezüglich des Kraftstoffverbrauchs, der Emissionen, der Laufruhe und des Geräuschs ermittelt. Die zum Einsatz kommenden Methoden eignen sich für ein breites Anwendungsgebiet im Bereich von Produkt- und Prozessoptimierung sowie bei der Erstellung von Verhaltensmodellen.

Vorgehen bei der Optimierung komplexer Systeme mit Hilfe der statistischen Versuchsplanung

Die Zielsetzung der statistischen Versuchsplanung kann folgendermaßen zusammengefasst werden: maximaler Informationsgewinn bei minimaler Anzahl von Messpunkten. Das prinzipielle Vorgehen ist in Abbildung 1 vereinfacht dargestellt. Das Vorgehen gliedert sich wie folgt:

1. **Systembeschreibung:** Systemgrenzen sowie Ein- und Ausgangsgrößen werden festgelegt.
2. **Wahl des Modellansatzes:** Basierend auf Vorkenntnissen wird der Modellansatz gewählt.
3. **Versuchsplanerstellung:** Messpunkte werden statistisch im Messraum verteilt; mehrere Eingangsgrößen werden simultan verstellt.
4. **Messung:** Die Messwerte an den im Versuchsplan festgelegten Eingangsgrößen werden bestimmt.
5. **Modellbildung:** Aus den Messwerten wird eine Modellfunktion gebildet, die den gesamten Versuchsraum beschreibt.
6. **Bewertung der Modellqualität:** Modell-, Bias- und Varianzfehler bestimmen die Aussagefähigkeit des Modells.
7. **Optimierung am Modell:** Die gesuchten Maximal- und Minimalwerte sowie die entsprechenden Einstellparameter werden mit Hilfe der Modellfunktion ermittelt.
8. **Verifikation:** Die gefundenen Optima werden durch Nachmessung verifiziert.

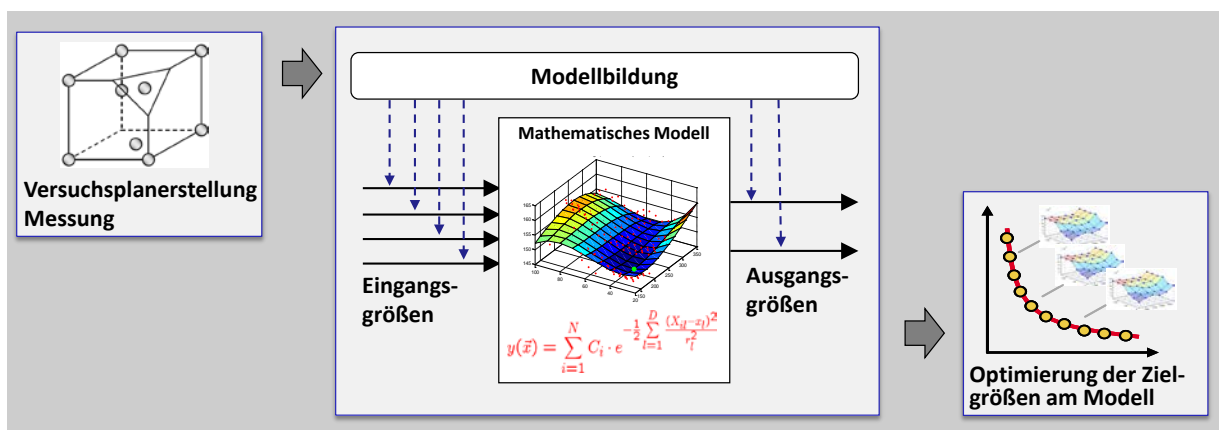


Abbildung 1: Prinzipielles Vorgehen bei der statistischen Versuchsplanung, vereinfachte Darstellung

Der Vorteil der hier beschriebenen Methode kommt besonders dann zum Tragen, wenn die Beschreibung eines komplexen Systems einen großen Aufwand erfordert. Dies ist beispielsweise der Fall, wenn Prototypen erstellt werden müssen, umfangreiche und kostenintensive Messungen erforderlich sind oder wenn Simulationen einen hohen Zeitaufwand benötigen. In solchen Fällen werden aus möglichst wenigen Messungen die prinzipiellen Abhängigkeiten des realen Systems modelliert, um dann mit Hilfe von Modellfunktionen die gesuchten Werte ermitteln zu können.

In den folgenden Kapiteln werden nun die einzelnen Schritte bei der Optimierung komplexer Systeme erläutert.

1 Systembeschreibung

Werden verschiedene Objekte durch eine plausible Abgrenzung von ihrer Umgebung zu einer Gesamtheit zusammengefasst, spricht man von einem System. Auf dieses System wirken von der Umgebung verschiedene Eingangsgrößen \underline{u} ein und es folgt eine Reaktion des Systems, die mit Hilfe der Ausgangsgrößen \underline{y} zusammengefasst wird (siehe Abbildung 2). Ein System ist gemäß dieser Definition eine abstrakte Beschreibung eines technischen Produkts oder Prozesses.

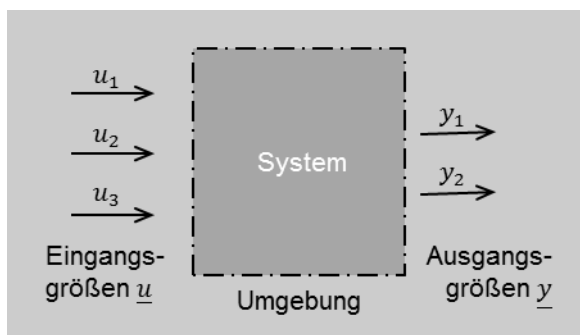


Abbildung 2: System

Die Komplexität eines solchen Systems nimmt mit der Anzahl der Eingangsgrößen zu. Hierbei sind besonders die Interdependenzen (gegenseitige Abhängigkeiten) wichtig. Wird zum Bei-

spiel die Gewichtsoptimierung eines Kraftfahrzeugs betrachtet, so kann das Gesamtgewicht reduziert werden, wenn das Gewicht jedes Teilsystems wie Karosserie, Antriebsstrang, Fahrwerk und Interieur verringert wird. Man kann gedanklich das System in mehrere Teilsysteme zerlegen und jedes System einzeln optimieren. Allerdings ist zu beachten, dass zum Beispiel eine Gewichtsreduzierung der Karosserie die mechanische Beanspruchung des Fahrwerks verringert und somit weitere Gewichtseinsparungen möglich werden. Das Gesamtsystem zeigt also vielfältige gegenseitige Abhängigkeiten.

Neben den Interdependenzen sind starke Nichtlinearitäten weitere Komplexitätstreiber. Wenn kleine Änderungen der Eingangsgrößen oder nichtberücksichtigte Störungen große Auswirkungen auf das Systemverhalten haben, ist bei Modellierung und Analyse eine feine Diskretisierung erforderlich, um größere Abweichungen der Ergebnisse und Fehlinterpretationen zu verhindern. Typische Beispiele sind Resonanzeffekte, aber auch chaotische Systeme zeigen solche Effekte. Weitere aus der Systemtheorie bekannte Komplexitätstreiber wie Emergenz oder selbstorganisierende Systeme werden hier nicht betrachtet.

Um ein System gemäß Abbildung 2 beschreiben zu können, müssen alle relevanten Eingangs- und Ausgangsgrößen bekannt und messbar sein. Sind nicht alle wesentlichen Eingangsgrößen bekannt, wird die Modellgüte unzureichend sein, und das Resultat ist mit großen Unsicherheiten behaftet. Sind die Ausgangsgrößen nicht messbar, wie zum Beispiel, wenn die Behaglichkeit im Fahrzeug verbessert werden soll, so muss auf messbare Hilfsgrößen, wie die Temperaturverteilung oder die Luftdurchströmung, zurückgegriffen werden.

2 Wahl des Modellansatzes

Für die Modellierung der inneren Zusammenhänge zwischen Ein- und Ausgangsgrößen stehen prinzipiell physikalische oder datenbasierte Modelle zur Verfügung.

Bei physikalischen Modellen sind die physikalischen Gesetzmäßigkeiten, zum Beispiel in Form von Bilanz-, Transport- und Diffusionsgleichungen, bekannt und modellierbar. Man spricht hierbei von White Box-Modellen. Datenbasierte Modelle approximieren das prinzipielle Verhalten des untersuchten Problems auf Basis von Messwerten oder Simulationsergebnissen. Werden nur Eingangs- und Ausgangsgrößen betrachtet, spricht man in der Systemtheorie von einem Black Box-Modell. Sind die wesentlichen physikalischen Gesetzmäßigkeiten bekannt, aber die Modellstruktur und Prozessparameter teilweise unbekannt, wird dies als Grey Box-Modell bezeichnet (siehe Abbildung 3).

White Box	Grey Box	Black Box
Physikalische Gesetze sind bekannt	Physikalische Gesetze sind bekannt	Physikalische Gesetze sind nicht bekannt
Physikalische Bestimmung der Prozessparameter	Parameter, Modellstruktur teilweise unbekannt	Modellstruktur ist nicht bekannt
	Signale sind messbar	Signale sind messbar

Abbildung 3: Klassifizierung der Modelle

Sofern möglich, sind physikalische Modelle zu bevorzugen, allerdings ist es bei vielen techni-

schen Problemstellungen nicht möglich, eine geschlossene physikalische Modellierung aufzustellen. In diesen Fällen kommen datenbasierte Modelle zum Einsatz, wobei die Modellgüte erhöht werden kann, wenn verfügbares Vorwissen über die physikalischen Gesetzmäßigkeiten im Modell abgebildet ist.

Bei datenbasierten Modellen wird das Systemverhalten mit Hilfe einer mathematischen Formulierung beschrieben. Im Allgemeinen können diese Modelle nicht alle Merkmale, Eigenschaften und Störeinflüsse erfassen und es treten Abweichungen zwischen dem realem Systemverhalten, welches durch die Messwerte $\underline{y}(t)$ beschrieben wird, und dem Verhalten des Modells $\hat{y}(\beta_i, t)$ auf. Diese Abweichungen zwischen realem Systemverhalten und Modellverhalten werden als Modellfehler $\underline{e}(\beta_i, t)$ bezeichnet. Die Modellfehler werden für alle Einzelmessungen erfasst und die Modellparameter β_i mit Hilfe von Optimierungsverfahren so angepasst, dass der verbleibende Modellfehler minimal wird (siehe Abbildung 4).

Für die Modellbildung mit mehreren Eingangsgrößen stehen die Methode der kleinsten Fehlerquadrate, neuronale Netze oder Gauß-Prozesse [5,6] zur Verfügung. Die Eigenschaften sowie die Vor- und Nachteile der verschiedenen Methoden werden in Kapitel 5 diskutiert.

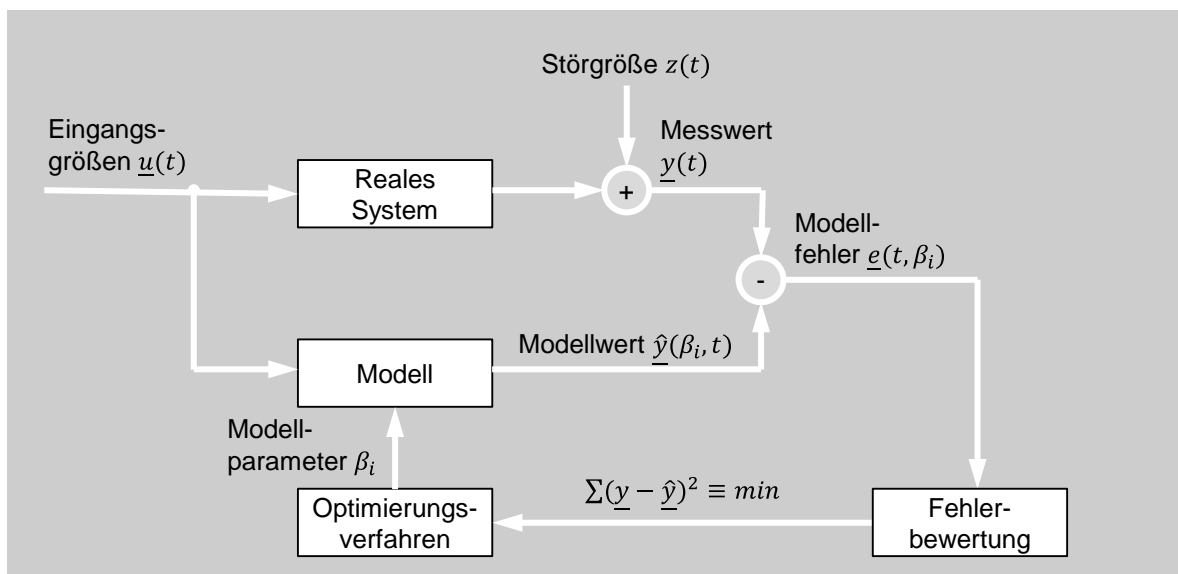


Abbildung 4: Minimierung der Modellfehler $\underline{e}(\beta_i, t)$ durch Anpassung der Modellparameter β_i

3 Versuchsplanerstellung

Die prinzipielle Aufgabe des Versuchsplans ist, mit möglichst wenigen Messpunkten ein möglichst genaues Abbild des Prozesses zu erhalten. Hierfür werden mehrere Eingangsgrößen gleichzeitig variiert und die Messpunkte statistisch im Versuchsraum verteilt.

Für Polynommodelle werden in der Regel D-optimale Versuchspläne verwendet. Hierbei wird die Determinante der Informationsmatrix maximiert $\det(\underline{X}^T \underline{X}) \equiv \max$. Bei diesen sogenannten D-optimalen Versuchsplänen sind nur wenige Messpunkte erforderlich, allerdings ist der Versuchsplan von der Ordnung des Modellansatzes abhängig. Nachteilig ist die Häufung der Messpunkte an den Begrenzungen des Versuchsraums. Diese Begrenzungspunkte sind oftmals nur ungenau messbar, da zum Beispiel an den Laufgrenzen des Motors starke Schwankungen auftreten.




Abbildung 5: Versuchsplan Verbrennungsmotor

Werden neuronale Netze oder Gauss-Prozesse zur Modellbildung verwendet, empfiehlt sich die Nutzung von Space-Filling-Designs. Hierbei werden die Messpunkte über alle Eingangsgrößen möglichst gleichmäßig im Versuchsraum verteilt. Space-Filling-Designs bieten einen guten Kompromiss zwischen der Anzahl der benötigten Messungen und der Modell-Genauigkeit. Es ist kein Vorwissen über das verwendete Modell erforderlich, allerdings ist die Nutzung für Polynommodelle nicht optimal.

Die Herausforderung bei der Erstellung des Versuchsplans ist häufig die sinnvolle Eingrenzung des Versuchsraums. Selbstverständlich bieten moderne Werkzeuge vielfältige Möglichkeiten, den Versuchsraum zu gestalten (siehe Abbildung 5, erstellt mit ETAS-ASCMO [4]). Allerdings ergeben sich bei der modernen Motorapplikation verschiedene Parameterkombinationen, die nicht sinnvoll, beziehungsweise nicht fahrbar sind. Für diese Fälle wurden verschiedene Online-Verfahren entwickelt, die direkt am Prüfstand den fahrbaren Bereich ermitteln (siehe zum Beispiel [8]).

4 Messung

Unter Messung verstehen wir zunächst die klassische Messung am Prüfstand oder im Fahrzeug. Dabei werden gemäß des erstellten Versuchsplans die Eingangsgrößen eingestellt und die Ausgangsgrößen gemessen. Je höher die Präzision der Messergebnisse ist, desto verlässlicher werden später auch die Ergebnisse der Optimierung sein. Um bei größeren Messreihen den Einfluss von Messdrifts und sich ändernden Umgebungsbedingungen auszuschließen, wird regelmäßig der gleiche Referenzpunkt angefahren. Eine spätere Auswertung dieser Referenzpunkte ermöglicht dann Aussagen über die Messqualität.

Alternativ zu der klassischen Messung können hier auch Simulationsergebnisse genutzt werden. Ein typisches Beispiel ist die Simulation der Betriebsstrategie von Hybrid-Fahrzeugen. Hierbei werden verschiedene Eingangsgrößen wie die Batteriegröße, die Leistung, das Moment des Elektromotors und verschiedene Betriebsparameter variiert, um Aussagen über die Kraftstoffersparnis und Zusatzkosten zu erhalten [10].

5 Modellbildung

5.1 Methode der kleinsten Fehlerquadrate

Die Methode der kleinsten Fehlerquadrate ist das mathematische Standardverfahren, um für eine Reihe von Messdaten die unbekannt Parameter einer vorgegebenen Funktion zu be-

stimmen. Das Vorgehen lässt sich wie folgt beschreiben:

I. Festlegung des Funktionstyps, welcher der Ausgleichsrechnung zugrunde gelegt werden soll. Für n-dimensionale Optimierungsprobleme mit den Eingangsgrößen $u_1 \dots u_n$ werden typischerweise Polynome der 2. Ordnung zur Approximierung der Messwerte y_i eingesetzt:

$$\hat{y}_i = \beta_0 + \sum_{i=1}^n \beta_{1,i} u_i + \sum_{i=1}^n \beta_{2,i} u_i^2 + \sum_{i=1}^n \sum_{j=i+1}^n \beta_{2,ij} u_i u_j$$

Der modellierte Wert wird mit \hat{y}_i bezeichnet, der Parameter β_0 beschreibt einen konstanten Faktor, die Parameter $\beta_{1,i}$ und $\beta_{2,i}$ kennzeichnen die Terme der 1. und 2. Ordnung und mit $\beta_{2,ij}$ sind die gemischten Terme bezeichnet.

II. Fehlerquadrate: Mit dem ausgewählten Funktionstyp wird die Summe der Abstandsquadrate

$$S = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \equiv \min$$

gebildet, die von den k-unbekannten Parametern β abhängt.

III. Aufstellen des Gleichungssystems: Die Bestimmung der Parameter erfolgt, indem nach allen k unbekanntem Parametern β_k differenziert wird:

$$\frac{dS}{d\beta_k} = \frac{d(\sum_{i=1}^n (y_i - \hat{y}_i)^2)}{d\beta_k} = -2 \sum_{i=1}^n (y_i - \hat{y}_i) \frac{d\hat{y}_i}{d\beta_k} \equiv 0$$

IV. Lösung des Gleichungssystems: Aus diesen Bedingungen folgt ein Gleichungssystem, mit welchem die Parameter β_k bestimmt werden können.

Im einfachen Fall folgt ein lineares Gleichungssystem, welches zum Beispiel mit Hilfe eines Gauß-Verfahrens aufgelöst werden kann. Bei nichtlinearen Problemstellungen muss das Gleichungssystem iterativ mit Hilfe eines Newton-Raphson-Verfahrens oder eines Konjugierte-Gradienten-Verfahrens gelöst werden.

Ein typischer Anwendungsfall aus der Applikation von Motorsteuerungen sind sogenannte virtuelle Sensoren. Wird zum Beispiel anstelle eines Temperatursensors die Temperatur als Kennfeld mit den Eingangsgrößen u_1 und u_2 modelliert, so folgt $T = f(u_1, u_2)$. Zunächst wird jeder Stützstelle im Kennfeld der Wert β_{kl} zugewiesen, wobei die Laufvariablen k und l die Stützstellen in u_1 - und u_2 -Richtung kennzeichnen. Dann wird zu jedem Messwert y_i der entsprechende Modellwert \hat{y}_i berechnet, wobei sich \hat{y}_i aus einer linearen Interpolation der vier umliegenden Stützstellen ergibt (siehe Abbildung 6)

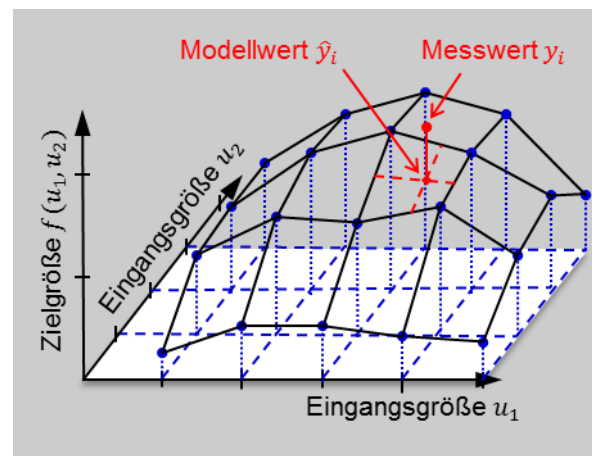


Abbildung 6: Virtueller Sensor für zwei Eingangsgrößen

Aus der Summe der Abstandsquadrate

$$S = \sum_{i=1}^n [y_i - \hat{y}_i]^2 \equiv \min$$

können nun die einzelnen Parameter β_{kl} bestimmt werden, vorausgesetzt, es liegen ausreichend viele Messpunkte vor. Bei realen Messungen kann es jedoch vorkommen, dass nicht alle Stützstellen auswertbar sind oder dass unplausible Schwankungen auftreten. Daher ist zusätzlich zur Summe der Abstandsquadrate noch eine „Glattheit“ der Kennfelder zu superponieren:

$$S = \sum_{k=2}^{k_m-1} \sum_{l=2}^{l_m-1} g_{u1} \left[\frac{\partial^2 \beta_{kl}}{\partial u_1^2} \right]^2 + g_{u2} \left[\frac{\partial^2 \beta_{kl}}{\partial u_2^2} \right]^2 \equiv \min$$

Dabei bestimmen die Faktoren g_{u1} und g_{u2} die Gewichtung der „Glattheit“ und k_m, l_m bezeichnen die Anzahl der Stützstellen. Weitere Bedin-

gungen zu den Randwerten können zusätzlich superponiert werden.

Da in modernen Motorsteuerungssystemen nahezu alle Verstellwerte in Form vom Kennfeldern, Kennlinien und Festwerten abgelegt sind, kommt der Kennfeldoptimierung eine besondere Bedeutung zu. Selbstverständlich werden hierbei nicht nur einfache Kennfelder mit nur zwei Eingangsgrößen betrachtet. Haben die Reglerstrukturen mehrere Eingangsgrößen, ist die Modellfunktion entsprechend zu erweitern.

Die Methode der kleinsten Fehlerquadrate ist robust und vielseitig einsetzbar und somit das Standardverfahren bei der Modellbildung. Allerdings muss der Funktionsansatz festgelegt werden, und stark nichtlineare Effekte können in der Regel schlecht modelliert werden.

5.2 Neuronale Netze

Zu der Klasse der nicht parametrischen Modelle gehören neuronale Netze, die den menschlichen Nervenzellen nachempfunden sind. Ein wichtiger Vertreter sind die radiale Basisfunktionen-Netze (RBF-Netze). Diese lassen sich als Aktivierungsfunktionen einer Schicht mit Neuronen auffassen. Die Neuronen sind radialsymmetrisch zum Zentrum μ_i der Basisfunktion, an dieser Stelle hat die Funktion ihren Maximalwert. Jedes Neuron besitzt nur ein sehr lokales Verhalten. Im Bereich um das Zentrum liefert es eine große Aktivierung, mit zunehmendem Abstand vom Zentrum fällt die Aktivierung typischerweise monoton gegen Null. Eine direkte Berechnung der Gewichte ist möglich, daher sind die RBF-Netze schnell trainierbar und sicher konvergierend. Für die Approximation mit Gauß-Funktionen mit j Neuronen gilt:

$$z = \sum_j w_j \cdot \exp(-\beta_j \cdot (u - \mu_j)^2)$$

In Abbildung 7 ist ein einfaches RBF-Netzwerk dargestellt. Die Eingabeschicht mit linearer Aktivierung $|u - \mu_i|$ ist als Eingangsneuronen gekennzeichnet. Es folgt das sogenannte Hidden Layer mit RBF-Neuronen. Dabei sind Zentrum und Breite der RBF-Neuronen adaptierbar. Aus

jedem Neuron folgt ein trainierbares Gewicht $w_1 \dots w_n$, dessen Summe in der Ausgabeschicht ausgegeben wird.

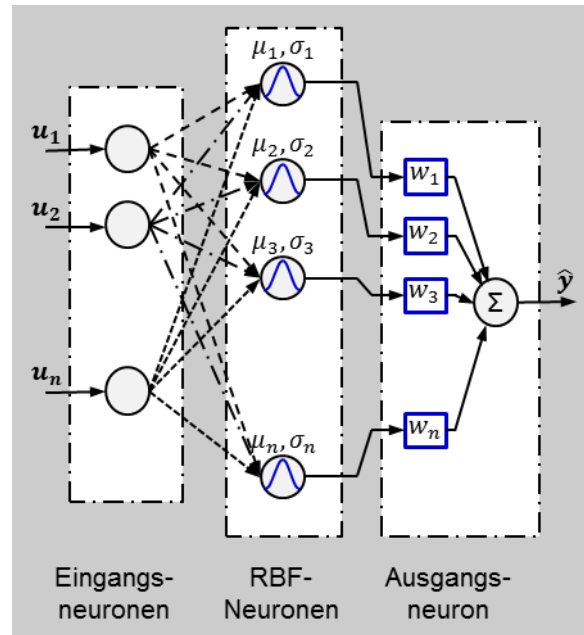


Abbildung 7: Einfaches RBF-Netzwerk

In Abbildung 8 ist ein Beispiel eines RBF-Netzwerkes dargestellt. Im oberen Diagramm wurde bei äquidistanten Stützstellen mit konstanten Faktoren $\beta_i = 4$ nach den Gewichten w_i optimiert.




Abbildung 8: Ungewichtetes RBF-Netz

Neuronale Netze erlauben es, komplexe Zusammenhänge abzubilden. Allerdings sind in der Regel viele Trainingsdaten erforderlich, die Anforderung an Rechenleistung ist im Allgemeinen hoch, und ein umfangreiches Expertenwissen ist erforderlich. Da einzelne Neuronen nur einen kleinen Wirkungsbereich bezogen auf die Ein-

gangsgröße u haben, eignen sich neuronale Netze für adaptive Modelle, wie sie zum Beispiel bei der Gemischvorsteuerung in Kraftfahrzeugen zum Einsatz kommen [11].

5.3 Gauß-Prozesse

Ein moderner Ansatz ist die Verwendung statistischer Lernverfahren auf Basis von Gauß-Prozessen. Unter einem Gauß-Prozess versteht man eine verallgemeinerte mehrdimensionale Gauß-Verteilung über unendlich viele Zufallsvariablen, von denen jede endliche Untermenge Gauß-verteilt ist [5,6].

Eine typische Aufgabenstellung, für welche Gauß-Prozesse genutzt werden können, ist in Abbildung 9 dargestellt. Die Messwerte y_i an den Stützstellen x_i seien bekannt und an der Stelle $x^* = 4,5$ wird der beste Schätzwert y^* gesucht, wobei eine multivariante Gauss-Verteilung zugrunde gelegt wird.




Abbildung 9: Schätzwert an der Stelle $x = 4,5$

Für die bekannten Messwerte y_i an den Stützstellen x_i kann geschrieben werden:

$$\begin{bmatrix} y_1 \\ y_2 \\ \dots \end{bmatrix} \sim N \left(\begin{bmatrix} 0 \\ 0 \\ \dots \end{bmatrix}, \begin{bmatrix} K_{11} & K_{12} & \dots \\ K_{21} & K_{22} & \dots \\ \dots & \dots & \dots \end{bmatrix} \right),$$

wobei sich die Kovarianzmatrix K wie folgt berechnet:

$$K_{ij} = \sigma_f^2 \exp \left[\frac{-(x_i - x_j)^2}{2 l^2} \right] + \sigma_n^2 \delta(x_i, x_j).$$

σ_f beschreibt die maximal zulässige Kovarianz und σ_n das Rauschen. Der Parameter l bestimmt

den Einflussbereich der einzelnen Terme. Die Kovarianzmatrix K beschreibt also den Zusammenhang zwischen den Eingangsgrößen x_i und x_j . Eine wesentliche Grundannahme ist, dass der gesuchte Funktionswert y^* von den benachbarten, bekannten Messwerten besonders stark abhängig ist und der Einfluss abnimmt, je weiter eine Messstelle entfernt ist. Mit dieser Annahme und der Kovarianz K^* zwischen den bekannten Stützstellen x_i und der gesuchten Stützstelle x^* folgt:

$$\begin{bmatrix} \vec{y} \\ y^* \end{bmatrix} \sim N \left(0, \begin{bmatrix} K & K^{*T} \\ K^* & K^{**} \end{bmatrix} \right)$$

und für den Funktionswert y^* sowie für seine Varianz folgt:

$$y^* = K^* K^{-1} \vec{y}$$

$$var(y^*) = K^{**} - K^* K^{-1} K^{*T}$$

In Abbildung 10 sind die Lösungen für $l = \{0,5; 1; 2\}$ dargestellt, wobei exakte Messwerte ($\sigma_n = 0$) vorausgesetzt wurden. Es ist ersichtlich, dass das Resultat der Regression von der optimalen Wahl der Parameter l , σ_f und σ_n abhängig ist.

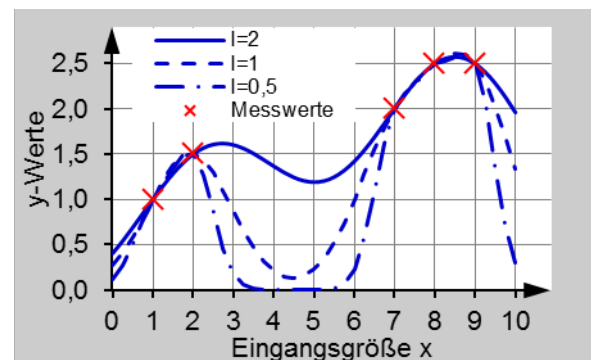


Abbildung 10: Lösungsfunktionen in Abhängigkeit der Einflussbreite l

Um aus allen möglichen Lösungen die statistisch wahrscheinlichste Lösung zu bestimmen, wird die Wahrscheinlichkeit $p(y|x, l, \sigma_f, \sigma_n)$ maximiert. Diese Optimierungsaufgabe lässt sich folgendermaßen schreiben:

$$\log p(y|x, l, \sigma_f, \sigma_n) = -\frac{1}{2}y^TK^{-1}y - \frac{1}{2}\log|K| - \frac{n}{2}\log(2\pi) \equiv \max$$

Hierbei entspricht der erste Term dem Fehler auf die Trainingsdaten und der zweite Term entspricht einer „Bestrafungsfunktion“ für die Komplexität der Modelle.

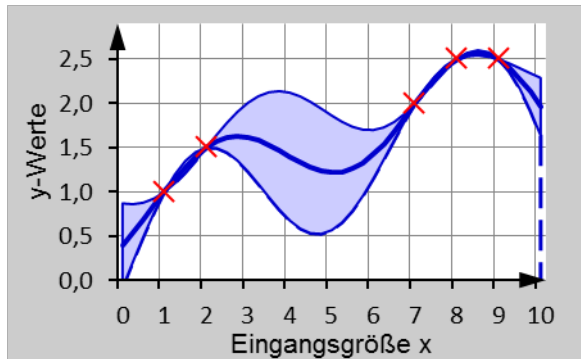


Abbildung 11: Lösungsfunktion und Varianz

In Abbildung 11 sind die wahrscheinlichsten Lösung sowie die Varianz dargestellt. Da der Messfehler gleich Null angesetzt wurde, stimmen die Messwerte und die Lösungsfunktion an den Messstellen exakt überein. Wird Messrauschen berücksichtigt, so nähert sich die Lösungsfunktion immer mehr einer Ausgleichsgerade an. Auch ist zu erkennen, dass die Unsicherheit in der Nähe der Stützstellen sehr gering ist, und zunimmt, je weiter der gesuchte Punkt von den bekannten Stützstellen entfernt ist: Dies ist eine Grundprämisse des gewählten Ansatzes.

Gauß-Prozesse sind für unbekannte und komplexe Verläufe besonders geeignet, da keine Funktion vorgegeben werden muss, und komplexe Verläufe werden auch in mehreren Dimensionen gut abgebildet. Die mathematisch exakte Formulierung benötigt mehr Rechenzeit als vergleichbare Polynommodelle. Auch ist die Nachvollziehbarkeit der Lösung nicht so anschaulich wie bei Polynommodellen.

6 Bewertung der Modellqualität

Die Bewertung der Modellqualität ist eine der zentralen Aufgaben bei der statistischen Versuchsplanung. Nur wenn alle relevanten Ein-

gangsgrößen berücksichtigt sind, die Messpunkte richtig gewählt wurden und eine hohe Messgenauigkeit vorliegt, sind weitergehende Schritte sinnvoll.

Prinzipiell besteht der Modellfehler aus zwei Anteilen:

$$e\{(y - \hat{y})^2\} = e\{(y - E(\hat{y}))^2\} + e\{(\hat{y} - E(\hat{y}))^2\}$$

Modellfehler Biasfehler Varianzfehler

Der Modellfehler bezeichnet die Abweichungen zwischen dem Messwert y und dem modellierten Wert \hat{y} . Der Biasfehler kennzeichnet den systematischen Fehler zwischen den Messungen und dem Modellausgang. Der Varianzfehler beschreibt den Fehler aufgrund von Messrauschen.

In Abbildung 12 sind Modell-, Bias- und Varianzfehler als Funktion der Modellkomplexität dargestellt. Bei einer Unteranpassung kann die Modellstruktur die Prozessstruktur nicht ausreichend genau abbilden. Bei einer Überanpassung wird die Messungenauigkeit der einzelnen Messungen im Modell abgebildet und besonders bei Polynomen höherer Ordnung können sehr große Fehler auftreten.

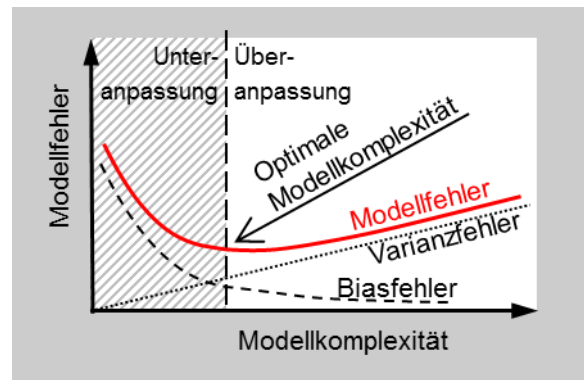


Abbildung 12: Modell-, Bias- und Varianzfehler

Zur Überprüfung der Modellqualität und der Modellstruktur sind folgende Punkte wichtig:

- Der RMSE (Root Mean Square Error) liefert die erste wichtige Aussage zur erreichten Modellqualität.
- Die Kreuzvalidierung (leave-one-out-Methode) ermöglicht eine Aussage zu Modellgüte und Struktur.

- Das Bestimmtheitsmaß R^2 kennzeichnet die Aussagefähigkeit des Modells.
- Mit Hilfe von sogenannten Probability-Plots können Messausreißer erkannt und entfernt werden.
- Hinweise auf mögliche Veränderungen der Messbedingungen geben Wiederholmessungen und die Auswertung der Modellfehler als Funktion der Messreihenfolge.
- Der Modellfehler als Funktion jeder Eingangsgröße kann einen Hinweis auf systematische Fehler geben.

An dieser Stelle sei nochmal erwähnt, dass, solange die Modellgenauigkeit und das Bestimmtheitsmaß nicht ausreichend sind, eine sinnvolle Auswertung der Messergebnisse nicht möglich ist.

7 Optimierung

7.1 Optimierung einer Zielgröße

Eine typische Aufgabenstellung bei der Optimierung komplexer Systeme ist die Fragestellung, wie groß beziehungsweise klein der maximal erreichbare Wert der Ausgangsfunktion werden kann und bei welchen Eingangsgrößen dieser Wert erreicht wird.

Ein typisches Beispiel ist in Abbildung 13 anhand eines direkteinstritzenden Benzinmotors mit strahlgeführten Brennvorgängen dargestellt. Für

den Betriebspunkt $n = 2000 \text{ min}^{-1}$ und einen effektiven Mitteldruck $p_{me} = 2 \text{ bar}$ sind auf der x-Achse die Eingangsgrößen Einspritzzeitpunkt, Zündzeitpunkt, Kraftstoffdruck, Abgasrückführrate, Position der Auslassnockenwelle, Position der Einlassnockenwelle und Stellung der Ladungsbewegungsclappe dargestellt. Auf der y-Achse sind als Ausgangsgrößen der Kraftstoffverbrauch sowie die Stickoxide dargestellt. Bei den aktuellen Werten der Eingangsgrößen, die mit gestrichelten Linien gekennzeichnet sind, wird ein Kraftstoffverbrauch von $2,6 \text{ kg/h}$ erreicht. Aus den Kurvenverläufen ist ersichtlich, dass für einen früheren Einspritzzeitpunkt der Kraftstoffverbrauch weiter minimiert werden kann. Sobald der Einspritzzeitpunkt auf 35° gestellt wird, ändern sich die Kurvenverläufe (Abhängigkeiten) und im vorliegenden Fall wird der Einfluss der Abgasrückführung geringer. Es ist also das Optimum einer Zielfunktion $f(\underline{u})$ in Abhängigkeit der Eingangsgrößen \underline{u} zu ermitteln. Hierfür steht zum Beispiel das konjugierte Gradienten-Verfahren zur Verfügung.

Das vorliegende Beispiel wurde mit ETAS-ASC MO [4] ausgewertet. Es sei noch angemerkt, dass sich im vorliegenden Betriebspunkt unter gleichzeitiger Variation aller Eingangsgrößen ein optimaler Kraftstoffverbrauch von $2,18 \text{ kg/h}$ ergibt. Die Modellbildung erfolgte auf Basis von 800 Messpunkten mit einem Gauß-




Abbildung 13: Intersection-Plot für einen direkteinstritzenden Benzinmotor mit strahlgeführten Brennvorgängen

Prozess-Modell. Die erforderliche Messzeit am Prüfstand liegt bei ungefähr einer Woche, wogegen eine vollständige Rasterung über alle Eingangsgrößen deutlich mehr als 100 Jahre Messaufwand benötigen würde.

7.2 Multikriterielle Optimierung

Bei der Optimierung mehrerer Zielgrößen kommt es häufig zu Zielkonflikten. Dies bedeutet, dass sich bei weiterer Optimierung einer Zielgröße die Ergebnisse der anderen Zielgrößen verschlechtern. In Abbildung 13 ist dieser Zielkonflikt bezüglich des Kraftstoffverbrauchs und der Stickoxidemissionen zu erkennen.

Abbildung 14 zeigt für den gegebenen Betriebspunkt eine Pareto-Darstellung, wobei Pareto-optimal bedeutet, dass eine Zielgröße nicht weiter verbessert werden kann, ohne dass sich gleichzeitig die anderen Zielgrößen verschlechtern. Die grün markierten Punkte sind bezüglich des Kraftstoffverbrauchs optimal, die blauen Punkte zeigen geringe Stickoxidemissionen und die mit rot gekennzeichneten Punkte bieten einen guten Kompromiss für beide Größen.




Abbildung 14: Pareto-Darstellung

Das Suchproblem wird näherungsweise durch vereinfachende Algorithmen, die den Prinzipien der natürlichen Evolution nachempfunden sind, gelöst. Abbildung 15 zeigt das Vorgehen der evolutionären Algorithmen.

Der hier dargestellte Suchalgorithmus kann auch in mehrdimensionalen Räumen eingesetzt werden. Typischerweise sind neben Verbrauch und

Stickoxiden noch die Partikelmasse, die Geräuschentwicklung, die Laufunruhe und weitere Größen zu betrachten.

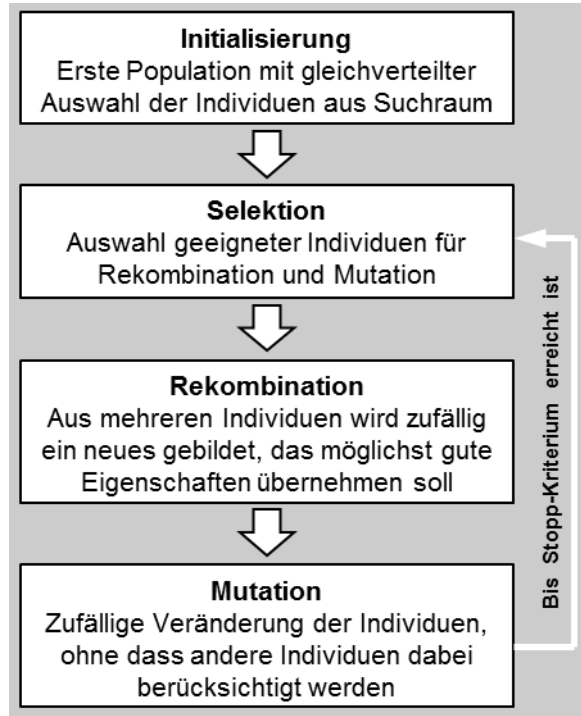


Abbildung 15: Evolutionärer Algorithmus

7.3 Optimierung mit Nebenbedingungen

Eine weitere wichtige Aufgabenstellung bei der Optimierung komplexer Systeme ist die Minimierung einer Zielgröße unter Einhaltung mehrerer Nebenbedingungen. Diese Art der Aufgabenstellungen soll anhand der Typprüfung eines Dieselmotors für mittelschwere Lastkraftwagen mit Euro V Zulassung erläutert werden [9]. Bei dieser Typprüfung werden Gesamtverbrauch und Emissionen aus den Einzelwerten an bestimmten Lastpunkten mit Hilfe gewichteter Summen bestimmt.

In Abbildung 16 sind die Lastpunkte des European Stationary Cycle (ESC-Test) sowie deren Gewichtung w_i dargestellt, die einzelnen Messpunkte sind mit Rauten gekennzeichnet. Zielsetzung der Optimierung ist zunächst die Minimierung des Verbrauchs:

$$KV = \sum_{i=1}^{i_{max}} w_i \cdot kv_i(\underline{u}) \equiv \min$$

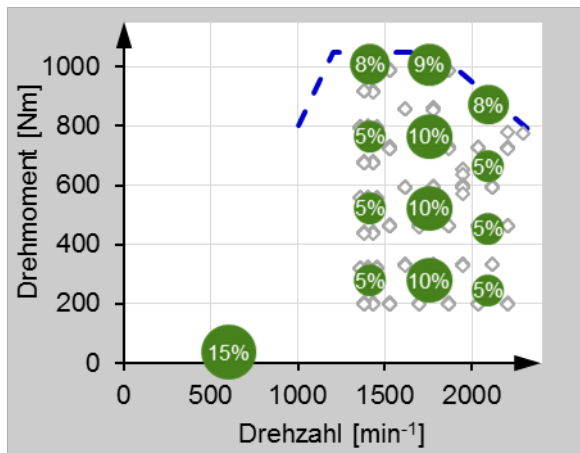


Abbildung 16: European Stationary Cycle

Die acht Eingangsgrößen \underline{u} sind die Menge und der Zeitpunkt von Pilot-, Haupt- und Nacheinspritzung sowie der Lade- und Kraftstoffdruck. Werden die aktuellen Werte dieser Eingangsgrößen \underline{u} an jedem Lastpunkt i so eingestellt, dass in jedem Punkt der Verbrauch optimal ist, so ergibt sich ein resultierender Gesamtverbrauch $KV = 218 \text{ g/kWh}$. Allerdings sind zusätzlich die Emissionsgrenzwerte zu berücksichtigen. Im vorliegenden Fall gilt für Stickoxid- und Partikelemissionen die globale Nebenbedingung:

$$NOx = \sum_{i=1}^{i_{max}} w_i \cdot NOx_i(\underline{u}) < 2 \text{ g/kWh}$$

$$PM = \sum_{i=1}^{i_{max}} w_i \cdot PM_i(\underline{u}) < 0,02 \text{ g/kWh}$$

Weiterhin sind lokale Nebenbedingungen, wie zum Beispiel maximale Geräuschentwicklung oder maximale Laufunruhe, zu berücksichtigen:

$$NVH_i(\underline{u}) < 80 \text{ dB}$$

In Abbildung 17 sind verschiedene Verbrauchs- und Emissionsergebnisse in Abhängigkeit vom Optimierungskriterium dargestellt. Im vorliegenden Fall wird der Kraftstoffverbrauch (KV) durch die Einhaltung der Emissionsgrenzwerte (NOx, Ruß) nur geringfügig verschlechtert, dies ist aber nicht immer so. Der zusätzliche Verbrauch durch Einhaltung der Emissionen kann je nach Applikation auch deutlich über 10% betragen.

Die Optimierung erfolgt im Wesentlichen mit den gleichen Verfahren wie in 7.1, wobei die Nebenbedingungen zu einer zusätzlichen Komplexität führen.

	KV*	NOx*	Ruß*
Neutral-Bedatung	240	5,41	0,036
Optimierung nach Verbrauch	218	4,03	0,021
Optimierung nach Verbrauch und Stickoxiden	220	1,76	0,032
Optimierung nach Verbrauch, Stickoxiden und Ruß	222	1,83	0,016
*) alle Werte in [g/kWh]			

Abbildung 17: Verbrauch und Emissionen in Abhängigkeit vom Optimierungskriterium

8 Verifikation

Da die Optimierung am Modell erfolgt und jedes Modell nur eine vereinfachte Abbildung des realen Systemverhaltens ist, sind die Ergebnisse zu verifizieren. Für qualitativ hochwertige Modelle werden die Verifikationsmessungen in der Regel die Optimierungsergebnisse bestätigen. Ist die Übereinstimmung nicht ausreichend, kann mit den neuen Messwerten eine verbesserte Modellbildung erfolgen.

Zusammenfassung

Die Optimierung von komplexen Systemen mit Hilfe der statistischen Versuchsplanung hat sich bei der Anpassung moderner Motorsteuersysteme als Standard etabliert und ist für die Minimierung des Kraftstoffverbrauchs und zur Einhaltung heutiger Emissionsgrenzwerte alternativlos [7].

Für die Modellbildung stehen verschiedene Verfahren zur Verfügung, wobei besonders die Gauß-Prozesse auch die Möglichkeit bieten, komplexe Modelle mit hoher Genauigkeit abzubilden.

Die vorgestellte Methodik eignet sich für ein breites Anwendungsgebiet im Bereich der Produkt- und Prozessoptimierung sowie bei der Erstellung von Verhaltensmodellen. Dabei kommen die Vorteile der statistischen Versuchsplanung besonders bei komplexen Systemen zum Tragen.

Literatur

- [1] Fischer, M., Röpke, K., (2000). *Effiziente Applikation von Motorsteuerungsfunktionen für Ottomotoren*. MTZ, 61.
- [2] Stuhler, H., Kruse, T., Stuber, A., Gschweidl, K., Piock, W., Pfluegl, H., Lick, P., (2002). *Automated Model-Based GDI Engine Calibration Adaptive Online DoE Approach*. SAE 2002-01-0708.
- [3] Stuhler, H., Kruse, T., (2003) *Parametrierung von Motorsteuerungen*. Isermann, R., (editor), *Modellgestützte Steuerung, Regelung und Diagnose von Verbrennungsmotoren*, Kapitel 3, pp. 23–38. Springer Verlag.
- [4] ETAS (2014). *ASCMO Produktinformationen*. <http://www.etas.com/de/products/ascmo.php> (abgerufen am 20.07.2014).
- [5] M. Ebdon (2008). *Gaussian Processes for Regression: A Quick Introduction*.
- [6] Rasmussen, C., Williams, C. (2006): *Gaussian Processes for Machine Learning*. MIT Press.
- [7] Klar, H., et al. (2013). *Neue Verfahren zur effizienten modellbasierten Motorapplikation*. 5. Internationales Symposium für Entwicklungsmethodik, Wiesbaden.
- [8] Sung, A., Klöpfer, F., Mitterer, A., Wachtmeister, G., Zell, A. (2007) *Modellbasierte Online-Optimierung in der Simulation und am Motorenprüfstand*. MTZ 01/2007.
- [9] Huber, T., Wirbeleit, F., Hartlief, H., Dehn, J. (2010). *Tools und Methoden in der Entwicklung und Applikation von Verbrennungsmotoren zur Erfüllung der zukünftigen Abgasgesetzgebung*, HeavyDuty Konferenz Mannheim.
- [10] Huber, T., (2010). *Modellgestützte Hybrid Systementwicklung – Modellierung und Optimierung*. Hrsg. Isermann, R., *Elektronisches Management motorischer Fahrzeugantriebe*. Springer Verlag.
- [11] Deflorian, M., (2011). *Versuchsplanung und Methoden zur Identifikation zeitkontinuierlicher Zustandsraummodelle am Beispiel des Verbrennungsmotors*. Dissertation TU München.

IMPRESSUM

Schriftenreihe INSIGHTS
Themenreihe Industrial Management INSIGHTS

Herausgeber:

Fakultät Technik der
Dualen Hochschule Baden-Württemberg Stuttgart
Postfach 10 05 63, 70004 Stuttgart

Prof. Dr. Dirk M. Reichardt, Dekan der Fakultät Technik
Jägerstraße 56, 70174 Stuttgart

E-Mail: dirk.reichardt@dhbw-stuttgart.de
Tel.: 0711/1849-610
Fax: 0711/1849-719

www.dhbw-stuttgart.de/technik/insights

Satz und Gestaltung: Inna Avrutina
Lektorat: Andrea Pöss, Inna Avrutina

Bildnachweis: vege - fotolia.com

ISSN 2193-9098

© Prof. Dr.-Ing. Harald Stuhler, Dr.-Ing. Thomas Kruse, 2014

Alle Rechte vorbehalten. Der Inhalt dieser Publikation unterliegt dem deutschen Urheberrecht. Die Vervielfältigung, Bearbeitung, Verbreitung und jede Art der Verwertung außerhalb der Grenzen des Urheberrechtes bedürfen der schriftlichen Zustimmung der Autoren und des Herausgebers.

Der Inhalt der Publikation wurde mit größter Sorgfalt erstellt. Für die Richtigkeit, Vollständigkeit und Aktualität des Inhalts übernimmt der Herausgeber keine Gewähr.

ISSN 2193-9098

www.dhbw-stuttgart.de/technik/insights