

Optimale Geradenschätzung für Time-of-Flight Umfeldsensoren

Optimized Line Estimation for Time-of-Flight-Sensors of Surroundings

Jan Stellet, Karlsruher Institut für Technologie,
Christian Kutzera, Robert Weigel, Friedrich-Alexander-Universität Erlangen-Nürnberg

Zusammenfassung Dieser Artikel stellt einen verbesserten Algorithmus zur Geradenschätzung für Umfeldsensoren vor. Eine optimale Schätzung ist nur möglich, wenn die stochastischen Eigenschaften der Messfehler berücksichtigt werden. Lidar- und Ultraschallsensoren erfassen die radiale Entfernung r und den Azimutwinkel φ . Deshalb ist es sinnvoll, unkorrelierte Messfehler in Polarkoordinaten anzunehmen. Schätzverfahren, die die daraus folgende Korrelation in kartesischen Koordinaten nicht berücksichtigen, können daher einen systematischen Schätzfehler aufweisen. Zwei neuere Ansätze zur Maximum-Likelihood-Schätzung der Geradenparameter werden hier vorgestellt und es wird die Verbesserung

eines der Verfahren vorgeschlagen. ►►► **Summary** This paper presents an improved algorithm for estimating line segments in noisy range data. An estimator's performance depends on correctly taking the measurement errors into account. Most sensors measure range and angle independently and thus it is a sound assumption to model the measurement error by independent noise processes in radius r and azimuth angle φ . However, this leads to correlated errors in Cartesian coordinates. Simple estimators do not consider this and therefore yield poor results. Two more recent approaches based on Maximum-Likelihood-Estimation are discussed in this paper and an improved formulation is presented.

Schlagwörter Optimale Parameterschätzung, Least Squares, Maximum Likelihood, Time-of-Flight Umfeldsensoren ►►►
Keywords Optimized line estimation, least squares, Maximum Likelihood, time-of-flight sensors

1 Einleitung

Für Fahrerassistenzsysteme und intelligente Roboter spielt die Umgebungserkennung eine wesentliche Rolle. Häufig werden Laserscanner oder Ultraschallsensoren eingesetzt, die ein einzeliliges Tiefenbild erzeugen. Die Sensoren senden Licht- oder Ultraschallimpulse aus und können mithilfe einer Laufzeitmessung auf die Entfernung eines reflektierenden Objektes schließen. Wird die Winkelausrichtung des Senders schrittweise variiert und der Vorgang wiederholt, kann anhand aller Reflexionspunkte auf die Lage von Objekten im Sensorumfeld geschlossen werden. Eine Untersuchung des Umfeldes ist aber nur dann sinnvoll möglich, wenn aus den gemessenen Reflexionen ein geometrisches Abbild der Umgebung rekonstruiert wird. Ein einfaches und gängiges Prinzip ist dabei die Modellierung der Objektkanten

durch Geradensegmente. In einem ersten Schritt müssen die Messpunkte hierzu in Segmente gruppiert werden, ein Problem zu dem verschiedene Methoden entwickelt wurden [1]. Anschließend können mit Parameterschätzverfahren die Modellparameter für jedes Segment separat bestimmt werden.

Derartige Regressionsprobleme lassen sich auf unterschiedliche Weise lösen. Wichtig ist die Berücksichtigung der stochastischen Eigenschaften der gemessenen Daten. Eine besondere Schwierigkeit ergibt sich aufgrund der notwendigen Koordinatentransformation. Während die genannten Sensoren die radiale Entfernung r sowie die azimutale Winkellage φ messen, erfordert die explizite lineare Darstellung der Geradengleichung die Verwendung von kartesischen Koordinaten. Allerdings wird hierbei auch das Messrauschen transformiert, welches aufgrund

des physikalischen Sensormessprinzips in Polarkoordinaten auftritt. Somit ergeben sich neue stochastische Eigenschaften.

Unter diesen Voraussetzungen existieren mehrere Verfahren zur Geradenschätzung und drei Möglichkeiten werden hier zunächst vorgestellt. Dies ist zum einen der einfache Least-Squares-Schätzer, welcher das Messrauschen jedoch nur unzureichend einbezieht. Zwei neuere Ansätze nach dem Maximum-Likelihood-Prinzip berücksichtigen zwar das Messrauschen in der radialen Komponente, nehmen einen Fehler in der Winkelmessung jedoch entweder nicht an [3], oder verwenden Abschätzungen für kleine Winkelfehler [5]. Der in dieser Arbeit vorgeschlagene Schätzer stellt eine Erweiterung des letztgenannten Verfahrens um eine Korrektur der Linearisierungsfehler dar. Es wird dazu auf Erkenntnisse zur optimalen Koordinatentransformationen mit Hinblick auf die Objektverfolgung zurückgegriffen [4]. Mithilfe einer Simulation wird das Potenzial der Verbesserung verdeutlicht. Anschließend wird gezeigt, dass die Maximum-Likelihood-Schätzer für den Spezialfall eines exakt gemessenen Winkels identisch sind.

2 Stochastisches Sensormodell

2.1 Messfehler

In [3] wird ein stochastisches Modell für Lidarsensoren begründet. Die wesentliche Aussage ist die Annahme zweier unabhängiger weißer gaußscher Rauschprozesse mit konstanten Standardabweichungen σ_r und σ_φ . Da die Messfehler aus der Summe einer Vielzahl von Ursachen resultieren, ist die Annahme einer normalverteilten Fehleramplitude nach dem zentralen Grenzwertsatz gerechtfertigt. Des Weiteren soll die Möglichkeit der Kalibrierung angenommen werden, sodass von mittelwertfreien Rauschprozessen ausgegangen wird. Die Verbunddichtefunktion einer Messung ist daher mit den tatsächlichen Werten r_0 und φ_0 gegeben durch:

$$f(r, \varphi) = \frac{1}{2\pi\sigma_R\sigma_\Phi} \exp\left(-\frac{(r-r_0)^2}{2\sigma_R^2} - \frac{(\varphi-\varphi_0)^2}{2\sigma_\Phi^2}\right).$$

2.2 Koordinatentransformation

Sowohl die lineare Geraden- als auch Bewegungsdarstellung erfordern die Verwendung von kartesischen Koordinaten. Es muss daher die Auswirkung einer Transformation der Polarkoordinaten auf die stochastischen Eigenschaften untersucht werden. Die exakte Transformation zeigt zunächst, dass keine bivariate Normalverteilung vorliegt:

$$f(x, y) = \frac{1}{\sqrt{x^2 + y^2}} \frac{1}{2\pi\sigma_R\sigma_\Phi} \exp\left(-\frac{(\sqrt{x^2 + y^2} - r_0)^2}{2\sigma_R^2} - \frac{(\arctan(\frac{y}{x}) - \varphi_0)^2}{2\sigma_\Phi^2}\right).$$

Eine häufig verwendete Approximation entsteht durch Linearisieren der Transformationsgleichungen. Es ergibt sich dann eine Gaußdichtefunktion für die Verteilung der Zufallsvariable $\vec{x} = (x \ y)^T$

$$f(\vec{x}) = \frac{1}{2\pi\sqrt{|\mathbf{R}|}} \exp\left(-\frac{1}{2} (\vec{x} - \vec{\mu})^T \mathbf{R}^{-1} (\vec{x} - \vec{\mu})\right) \quad (1)$$

mit der Kovarianzmatrix

$$\mathbf{R} = \begin{pmatrix} r_{11} & r_{12} \\ r_{12} & r_{22} \end{pmatrix}$$

$$r_{11} = \sigma_R^2 \cos^2(\varphi_0) + \sigma_\Phi^2 r_0^2 \sin^2(\varphi_0)$$

$$r_{12} = (\sigma_R^2 - \sigma_\Phi^2 r_0^2) \cos(\varphi_0) \sin(\varphi_0)$$

$$r_{22} = \sigma_R^2 \sin^2(\varphi_0) + \sigma_\Phi^2 r_0^2 \cos^2(\varphi_0)$$

und dem Erwartungswert

$$\vec{\mu} = \begin{pmatrix} r_0 \cos(\varphi_0) \\ r_0 \sin(\varphi_0) \end{pmatrix}.$$

Diese Darstellung bringt zwei Probleme mit sich. Zum einen ist die linearisierte Kovarianzmatrix von den im Allgemeinen unbekanntem tatsächlichen Koordinaten abhängig. Insbesondere bedeutet dies, dass unterschiedliche Reflexionspunkte in kartesischen Koordinaten unterschiedliche stochastische Eigenschaften besitzen. Dieses Resultat ist unbefriedigend, da beide Einschränkungen in Polarkoordinaten nicht vorliegen. Des Weiteren suggeriert dieses durch Linearisierung erhaltene Ergebnis, dass die transformierten Messwerte durch mittelwertfreie Abweichungen gestört werden. Tatsächlich liegt jedoch ein Bias vor, welches mithilfe von multiplikativem Debiasing kompensiert werden kann [4]. Die erweiterten Transformationsvorschriften lauten folgendermaßen:

$$x(r, \varphi) = \exp\left(\frac{1}{2}\sigma_\Phi^2\right) \cdot r \cos(\varphi)$$

$$y(r, \varphi) = \exp\left(\frac{1}{2}\sigma_\Phi^2\right) \cdot r \sin(\varphi).$$




Bild 1 Geradendarstellung eines Punktes (r_0, φ_0) mit den Parametern R, α .

Es werden zwar die Abweichungen des Erwartungswertes korrigiert, die nach [4] erhaltene Kovarianzmatrix stellt jedoch nach wie vor lediglich eine Approximation dar. Die Ursache des Problems ist, dass alle Punkte an denen die Gaußsche Dichtefunktion denselben Funktionswert annimmt, durch eine Gleichung der Form

$$(\vec{x} - \vec{\mu})^T \mathbf{R}^{-1} (\vec{x} - \vec{\mu}) = \text{const.}$$

und damit einer Ellipse beschrieben werden. Die nichtlineare Koordinatentransformation führt zu einer Krümmung der Höhenlinien, die die Darstellung nach Gleichung (1) nicht fassen kann.

3 Optimale Parameterschätzung

3.1 Least-Squares-Schätzer

Die gemessenen Reflexionspunkte eines Objektes sollen zur Parametrierung eines Objektmodells dienen. Als einfaches Modell eignen sich für einzeiligen Sensoren eine Gerade, eine L-Form aus zwei Geradenstücken sowie ein allgemeiner Polygonzug. Der Kern des Problems ist in jedem Fall die optimale Anpassung der Geradengleichung an $k = 1 \dots n$ fehlerbehaftete Messwerte. Für die Geradendarstellung in expliziter linearer Form

$$y = \Theta_1 x + \Theta_2 + e_y \tag{2}$$

folgen die bekannten Schätzgleichungen des Least-Squares-Schätzers:

$$\hat{\Theta}_1 = \left[\sum_{k=1}^n (x_k - \bar{X})^2 \right]^{-1} \sum_{k=1}^n (x_k - \bar{X}) (y_k - \bar{Y}) \tag{3}$$

$$\hat{\Theta}_2 = \left[\sum_{k=1}^n (x_k - \bar{X})^2 \right]^{-1} \left[\bar{Y} \sum_{k=1}^n x_k^2 - \bar{X} \sum_{k=1}^n x_k y_k \right]. \tag{4}$$

Aufgrund der Koordinatentransformation resultieren aber korrelierte Messfehler in beiden Koordinaten und die Annahmen des einfachen Least-Squares-Schätzers sind nicht erfüllt. Der in [2] verwendete Least-Square-Schätzer basiert auf

$$y = \Theta_1 (x + e_x) + \Theta_2 + e_y \tag{5}$$

und berücksichtigt zwar das zusätzliche Messrauschen in der x -Koordinate, verwendet jedoch die linearisierte Kovarianzmatrix. Diese wird zudem als konstant für alle Reflexionspunkte angenommen. Insgesamt erfordert die Geradenschätzung in kartesischen Koordinaten somit Kompromisse.

3.2 Maximum-Likelihood-Schätzer

In [3] wird ein Maximum-Likelihood-Schätzer formuliert, welcher optimale Ergebnisse liefert, sofern die Winkelmessung mit $\sigma_\varphi^2 = 0$ exakt ist. Die exakten Koordinaten (r_0, φ_0) erfüllen die Geradengleichung und werden mit den Transformationsvorschriften eingesetzt:

$$r_0 \sin(\varphi_0) = \Theta_1 r_0 \cos(\varphi_0) + \Theta_2. \tag{6}$$

Umformen und Einsetzen der Fehlergleichung $r = r_0 + e_r$ führt auf

$$r = \frac{\Theta_2}{\sin(\varphi_0) - \Theta_1 \cos(\varphi_0)} + e_r.$$

Die Dichtefunktion einer Entfernungsmessung r lautet:

$$f(r) = \frac{1}{\sqrt{2\pi}\sigma_R} \exp\left(-\frac{1}{2\sigma_R^2} \left(r - \frac{\Theta_2}{\sin(\varphi_0) - \Theta_1 \cos(\varphi_0)}\right)^2\right).$$

Aufgrund der stochastischen Unabhängigkeit der einzelnen Messungen eines Objektes folgt die Likelihood-Funktion als Produkt der einzelnen Dichtefunktionen. Die gesuchten Schätzwerte der Parameter Θ_1, Θ_2 maximieren diese Likelihood-Funktion und als Lösung folgt:

$$\frac{1}{2\sigma_R^2} \sum_{k=1}^n \left(r_k - \frac{\Theta_2}{\sin(\varphi_0) - \Theta_1 \cos(\varphi_0)} \right)^2 \xrightarrow{\Theta_1, \Theta_2} \min. \tag{7}$$

In der Arbeit [5] wird ein weiterer Ansatz zur Maximum-Likelihood-Schätzung beschrieben, der auch einen Fehler e_φ in der Winkelmessung berücksichtigt. Zur Darstellung der Geraden dient, wie in Bild 1 verdeutlicht, ein nicht nichtlineares Modell in Polarkoordinaten. Der Parameter R beschreibt die Länge des von der Geraden in den Koordinatenursprung gefällten Lotes und der Parameter α den zugehörigen Winkel:

$$r(\varphi) = \frac{R}{\cos(\alpha - \varphi)}. \tag{8}$$

Der Abstand eines Messpunktes zu der durch die Parameter beschriebenen Geraden kann durch eine Projektion auf die Lotgerade bestimmt werden:

$$\delta = r \cos(\alpha - \varphi) - R = (r_0 + e_r) \cos(\alpha - \varphi_0 - e_\varphi) - R. \tag{9}$$

In [5] werden anschließend die Abschätzungen $\sin(e_\varphi) \approx e_\varphi, \cos(e_\varphi) \approx e_\varphi$ und $e_r e_\varphi \approx 0$ eingesetzt. Als Ergebnis ergibt sich die mittelwertfreie Zufallsvariable

$$\delta \approx e_r \cos(\alpha - \varphi_0) + e_\varphi r_0 \sin(\alpha - \varphi_0). \tag{10}$$




Bild 2 Projektion δ_k des Messfehlers auf die Lotgerade.

Die in [5] als Gewichtungsfaktor verwendete Varianz ist

$$\sigma_\delta^2 \approx \sigma_R^2 \cos^2(\alpha - \varphi_k) + \sigma_\Phi^2 r_k^2 \sin^2(\alpha - \varphi_k). \quad (11)$$

Daraus ergibt sich als Optimierungsziel die Minimierung der Summe aus den mit σ_δ^{-2} gewichteten quadratischen Abstände δ_k^2 :

$$\sum_{k=1}^n \frac{\delta_k^2}{2\sigma_{\delta,k}^2} \rightarrow \min. \quad (12)$$

Wie für die Koordinatentransformation in [4] beschrieben, führt die Linearisierung auch hier zu einer systematischen Abweichung. Da es sich bei den Differenzen δ_k im Allgemeinen um sehr kleine Werte handelt, fällt der Linearisierungsfehler relativ gesehen ungleich größer aus.

In dieser Arbeit wird daher ein neuer Ansatz zur Maximum-Likelihood-Schätzung vorgestellt, der [5] um ein Debiasing nach [4] ergänzt. Die Grundidee ist, dass die Koordinatentransformation von polar zur kartesisch eine Projektion auf die Koordinatenachsen darstellt, wie auch hier eine Projektion verwendet wird. Die um den Korrekturfaktor $\lambda^{-1} = \exp(\frac{1}{2}\sigma_\Phi^2)$ erweiterte Projektion führt zu einer neuen Bestimmungsgleichung des Abstandes:

$$\delta = \lambda^{-1} r \cos(\alpha - \varphi) - R. \quad (13)$$

Als Varianz ergibt sich dann

$$\sigma_\delta^2 \approx r^2 (\lambda^{-2} - 2) \cos^2(\alpha - \varphi) + \frac{1}{2} (r^2 + \sigma_R^2) \left(1 + e^{-2\sigma_\Phi^2} \cos(2\alpha - 2\varphi) \right). \quad (14)$$

Anhand dieser Beziehungen lässt sich als verbesserte Approximation eine mittelwertfreie Normalverteilung annehmen. Auch wenn die transformierte Dichte nicht durch eine Gaußdichtefunktion beschrieben werden kann, ist zumindestens der Erwartungswert korrigiert. Ausgehend von der Likelihood-Funktion aus $k = 1 \dots n$ unabhängigen Messungen ergibt sich daraus analog zu (12) als Lösung:

$$\sum_{k=1}^n \frac{\delta_k^2}{2\sigma_{\delta,k}^2} \rightarrow \min. \quad (15)$$

3.3 Beziehungen zwischen den ML-Schätzern

Der Maximum-Likelihood-Schätzer nach [3] geht wie beschrieben durch Einsetzen der Koordinatentransformation in die kartesische Geradengleichung hervor. Die Likelihood-Funktion entsteht daher ohne Linearisierungen ausschließlich aufgrund der Annahme $e_\varphi = 0$. Demgegenüber wird in [5] eine Projektion des durch die Fehler in Winkel und Entfernung resultierenden Gesamtfehlers senkrecht zur Geraden durchgeführt. Die Anwendung von vereinfachenden Abschätzungen für kleine Winkelfehler e_φ führt dann zur Likelihood-Dichte.

Die verbesserte Form bringt zusätzlich eine Korrektur des bei der Linearisierung entstehenden Mittelwertfehlers ein.

Interessanterweise sind die Formulierungen der drei Schätzer für den Fall $e_\varphi = 0$ identisch. Es kann daher gezeigt werden, dass der hier vorgeschlagene Ansatz die verallgemeinerte Form von [3] und [5] darstellt.

Die zur Herleitung in [5] verwendeten Linearisierungen sind aufgrund der Winkelfunktionen notwendig. Für eine exakte Winkelmessung sind die Abschätzungen $\sin(e_\varphi) = 0$, $\cos(e_\varphi) = 1$ und $e_r e_\varphi = 0$ allerdings exakt. Der Korrekturfaktor ist $\lambda^{-1} = 1$, sodass beide Formulierungen offenbar identisch sind.

Interessanter ist, dass dann auch (7) mit (12) übereinstimmt. Dies folgt durch Einsetzen der Transformationsvorschriften $\Theta_1 = -\frac{1}{\tan(\alpha)}$ und $\Theta_2 = \frac{R}{\sin(\alpha)}$ in (7):

$$\begin{aligned} & \frac{1}{2\sigma_R^2} \sum_{k=1}^n \left(r_k - \frac{\Theta_2}{\sin(\varphi_0) - \Theta_1 \cos(\varphi_0)} \right)^2 \\ &= \frac{1}{2\sigma_R^2} \sum_{k=1}^n \left(r_k - \frac{\frac{R}{\sin(\alpha)}}{\sin(\varphi_0) + \frac{1}{\tan(\alpha)} \cos(\varphi_0)} \right)^2 \\ &= \frac{1}{2\sigma_R^2} \sum_{k=1}^n \left(r_k - \frac{R}{\cos(\alpha - \varphi_0)} \right)^2 \\ &= \sum_{k=1}^n \frac{(r_k \cos(\alpha - \varphi_0) - R)^2}{2\sigma_R^2 \cos^2(\alpha - \varphi_0)} = \sum_{k=1}^n \frac{\delta_k^2}{2\sigma_{\delta,k}^2}. \end{aligned} \quad (16)$$

Bei einer unverfälschten Winkelmessung sind die Schätzer somit identisch und liefern dieselben Ergebnisse.

3.4 Ergebnisse des simulativen Vergleichs

Zur Untersuchung der verschiedenen Schätzer wurde eine Simulation durchgeführt. Die Schätzung des Winkels $\alpha = -45^\circ$ wurde anhand eines simulierten Szenarios mit 20 Reflexionspunkten verglichen. Jede Schätzung wurde 100 Mal wiederholt und die Mittelwerte sowie der Root mean square error (RMSE) des geschätzten Winkels bestimmt. Die Standardabweichung des simulierten mittelwertfreien Messfehlers in der Winkelkomponente wurde variiert ($\sigma_\varphi = 0 \dots 3,0^\circ$), der Entfernungsmessung war weißes Rauschen mit $\sigma_r = 0,7$ Meter überlagert.

Die Simulationsergebnisse zeigen, dass der Ansatz nach [3] in Folge des nicht berücksichtigten Winkelfehlers zu vergleichsweise starken systematischen Abweichungen neigt. Sowohl der Ansatz nach [5] als auch die hier vorgeschlagene erweiterte Form erreichen bessere Ergebnisse. Bemerkenswert ist, dass die zweite Formulierung des Schätzers ab einem Wert von $\sigma_\varphi \approx 1,5^\circ$ zu steigenden Fehlern führt, wohingegen die erweiterte Fassung bessere Resultate liefert. Dies ist somit auf die hinzugefügte Biaskorrektur zurückzuführen.

Der Schätzfehler ist im Allgemeinen situationsabhängig. Dies wird in [3] ausführlich begründet und gezeigt, dass der Least-Squares-Schätzer bei symmetrisch um




Bild 3 Simulationsergebnisse Mittelwert.




Bild 4 Simulationsergebnisse RMSE.

den Nullwinkel verteilten Reflexionspunkten asymptotisch erwartungstreu ist. Die Ergebnisse einer weiteren Simulation in Bild 5, in welcher der Parameter α variiert wurde, verdeutlichen dies exemplarisch.

3.5 Zusammenfassung

In dieser Arbeit wurde ein neuer Algorithmus zur Geradenschätzung bei verrauschten Messdaten von Umfeldsensoren erarbeitet. Das Verfahren stellt eine Ver-




Bild 5 Winkelabhängigkeit des RMSE.

besserung eines bestehenden Ansatzes um eine Korrektur von Linearisierungsfehlern dar, welche bei zunehmenden Fehlern in der Winkelmessung auftreten. Es wurde des Weiteren gezeigt, dass ein bekanntes drittes Verfahren als Spezialfall hieraus hervorgeht. Aus diesem Grund stellt der hier präsentierte Ansatz eine Verallgemeinerung dar und erzielt daher die besten Ergebnisse.

Literatur

- [1] C. Fernández, V. Moren, B. Curto, J.A. Vicente: *Clustering and line detection in laser range measurements*, In: Robotics and Autonomous Systems 58 (2010), S. 720–726.
- [2] N. Kämpchen: *Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems*, Universität Ulm, Diss., 2007.
- [3] A. Kapp, L. Gröll: *Optimal Estimation of Line Segments in Noisy Lidar Data*, In: Signal Processing 86 (2006), September, S. 2304–2317.
- [4] L. Mo, X. Song, Y. Zhou, Z. Sun, Y. Bar-Shalom: *Unbiased Converted Measurements for Tracking*, In: IEEE Transactions on Aerospace and Electronic Systems 34 (1998), Juli, S. 1023–1027.
- [5] S. T. Pfister, S. I. Roumeliotis, J. W. Burdick: *Weighted Line Fitting Algorithms for Mobile Robot Map Building and Efficient Data Representation*, In: Proceedings of the 2003 IEEE International Conference on Robotics and Automation. Taipei, Taiwan, September 2003, 1, S. 1304–1311.



Jan Stellet ist Student der Elektro- und Informationstechnik am Karlsruher Institut für Technologie. Im Rahmen seiner Bachelorarbeit befasste er sich mit dem Themenbereich „Umfeldsensoren und Fahrerassistenzsysteme“.

Adresse: Karlsruher Institut für Technologie, Kaiserstraße 12, 76131 Karlsruhe,
E-Mail: jan.stellet@student.kit.edu



Christian Kutzera ist Promotionsstudent am Lehrstuhl für Technische Elektronik an der Friedrich-Alexander-Universität Erlangen-Nürnberg. Im Rahmen seiner Forschungsarbeit war er als externer Mitarbeiter bei der Dr. Ing. h. c. F. Porsche AG im Themenbereich „Umfeldsensoren und Fahrerassistenzsysteme“ tätig.

Adresse: Friedrich-Alexander-Universität Erlangen-Nürnberg, Lehrstuhl für Technische Elektronik, Cauerstraße 9, 91058 Erlangen, Tel.: +49-9131-85-27195, Fax: +49-9131-302951,
E-Mail: kutzera@lte.e-technik.uni-erlangen.de



Prof. Dr.-Ing. Dr.-Ing. habil. Robert Weigel ist Professor für Technische Elektronik und seit 2002 Inhaber des Lehrstuhls für Technische Elektronik an der Universität Erlangen-Nürnberg. Zuvor war er an der TU München, der TU Wien, der Universität Linz und der Tongji Universität Shanghai als Professor tätig.

Adresse: Friedrich-Alexander-Universität Erlangen-Nürnberg, Lehrstuhl für Technische Elektronik, Cauerstraße 9, 91058 Erlangen, Tel.: +49-9131-85-27200, Fax: +49-9131-302951,
E-Mail: weigel@lte.e-technik.uni-erlangen.de

Manuskripteingang: 20. September 2010, zur Veröffentlichung angenommen: 6. April 2011



Moderne spezialisierte Aktoren: Funktionsweise und Einsatzmöglichkeiten



Hartmut Janocha
**Unkonventionelle
Aktoren**
Eine Einführung

2010
283 S. | Broschur
€ 49,80
ISBN 978-3-486-58915-3

Aktoren dienen der zielgerichteten Einstellung von Energieflüssen oder Massen- und Volumenströmen in Prozessen. Sie werden elektrisch angesteuert und verwenden im konventionellen Fall elektromagnetische Wirkungen. Darüber hinaus gibt es aber seit einiger Zeit eine Reihe von Werkstoffen, die aufgrund besonderer physikalischer Eigenschaften zur Verwendung als Aktoren geeignet und kommerziell nutzbar sind.

Dieser modernen und spezialisierten Form der Aktoren widmet sich dieses Buch, indem es jeweils die zugrunde liegenden physikalischen Phänomene und die Einsatzmöglichkeiten grundsätzlich und anhand von Beispielen aus der Praxis vorstellt.

Ein eigenständiges Werk für unkonventionelle Aktoren, die sehr interessante Einsatzmöglichkeiten zeigen.


Das Buch richtet sich an Studierende des Maschinenbaus, der Elektrotechnik, Mechatronik, Automatisierungstechnik und Fachkräfte aus Forschung und industrieller Entwicklung.

Oldenbourg

Bestellen Sie in Ihrer Fachbuchhandlung oder direkt bei uns:
Tel: 089/45051-248, Fax: 089/45051-333, verkauf@oldenbourg.de
www.oldenbourg-wissenschaftsverlag.de



Schulwissen Mathematik – komprimiert für Studienanfänger



Joachim Erven,
Matthias Erven,
Josef Hörwick
Vorkurs Mathematik
Ein kompakter Leitfaden
4., korrigierte und
erweiterte Auflage 2010
269 S. | Broschur
€ 19,80
ISBN 978-3-486-58986-3

Die kompakte und anschauliche Grundlage für Mathematik-Vorkurse an Fachhochschulen und Universitäten.

Der „Vorkurs Mathematik“ stellt alle wesentlichen Stoffgebiete der Mathematik knapp und anschaulich dar.

Es komprimiert das Schulwissen der Mathematik für Studienanfänger – und ist somit hervorragend zum Selbststudium geeignet.

Wichtige Bestandteile des Schulstoffs werden wiederholt und schrittweise zu einem Basiswissen in Analysis und linearer Algebra ausgebaut. Zahlreiche Beispiele und Übungsaufgaben ermöglichen dem Leser ein selbstständiges Erarbeiten der elementaren Gebiete der Mathematik sowie die Aneignung solider Rechenfertigkeiten.

Für die 4. Auflage wurde ein Abschnitt zur Kombinatorik ergänzt.

Das Buch richtet sich an Studienanfänger an Fachhochschulen und Universitäten mit Nebenfach Mathematik.

Oldenbourg

Bestellen Sie in Ihrer Fachbuchhandlung oder direkt bei uns:
Tel: 089/45051-248, Fax: 089/45051-333, verkauf@oldenbourg.de
www.oldenbourg-wissenschaftsverlag.de