Beate Dutschk*, Matthäus Pordzik und Michael Heizmann

Einsatz von Gaußprozessen und Weighted Least-Squares-Verfahren für die Fusion von konfokaler Mikroskopie und Weißlichtinterferometrie

Gaussian processes and weighted least squares methods for fusion of confocal microscopy and white light interferometry

DOI 10.1515/teme-2018-0034

Zusammenfassung: Für die steigenden Anforderungen der Zuverlässigkeit und Präzision von Messergebnissen für die Oberflächenqualität werden vermehrt mehrere Sensorensysteme bzw. Multisensor-Messsysteme eingesetzt. Durch Verwendung von Sensorsystemen unterschiedlicher Eigenschaften kann so mithilfe einer Fusion ein holistischeres Ergebnis erzielt werden. In diesem Beitrag werden zwei Möglichkeiten für die Fusion bei der Verwendung von konfokaler Mikroskopie und Weißlichtinterferometrie vorgestellt. Die Fusion wird einmal anhand von Gaußprozessen sowie mit einem Weighted Least-Squares-Verfahren durchgeführt. Die Gaußprozesse werden hierfür mit einem hierarchischen Ansatz und einer Bayes'schen Komitee-Maschine [20] umgesetzt. Das Weighted Least-Squares-Verfahren wird über implizite Oberflächen und mit einer gewichteten Kernel-Regression realisiert. Die verwendeten Sensoren sowie die Verfahren, die explizit für den Anwendungsfall adaptiert wurden, werden kurz vorgestellt. Auf die Ergebnisse anhand von Simulationen und realen Daten wird eingegangen. Verschiedene Metriken werden für die Bewertung der Resultate eingesetzt.

Schlüsselwörter: Gaußprozesse, Weighted Least-Squares-Verfahren, konfokale Mikroskopie, Weißlichtinterferometrie.

Abstract: For a growing demand in reliability and precision for measurement results for surface metrology, multiple sensor systems or multisensor systems are increasingly

used. By using sensor systems with differing characteristics, a more holistic result can be gained. In this contribution, two different methods for fusing data from confocal microscopy and white light interferometry are presented. The fusion itself is done by Gaussian processes and a weighted least squares method. For the Gaussian process, a hierarchical approach is used in combination with a Bayesian committee machine [20]. The weighted least squares method is realized with implicit surfaces and a kernel regression. In the following, the deployed sensors are shortly presented as well as the fusion methods, which are adapted for this use case. The results with simulated data as well as a real data set are discussed. Different metrics for the evaluation of the methods are presented.

Keywords: Gaussian processes, weighted least squares methods, confocal microscopy, white light interferometry.

1 Einführung

Die Möglichkeiten in der Fertigung von funktionalen Oberflächen wachsen stetig. Dadurch steigen auch die Anforderungen an Zuverlässigkeit und Präzision der Messungen dieser Oberflächen in der Qualitätskontrolle. Beispiele sind unter anderem immer kleinere Bauteile oder reduzierte Rauheiten von Oberflächen [6]. Eine Möglichkeit, eine erhöhte Qualität von Oberflächenmessungen und ein holistischeres Ergebnis zu erhalten, ist der Einsatz von mehreren Sensorsystemen beziehungsweise Multisensor-Messsystemen [23]. Für die Oberflächenmesstechnik kommen taktile und optische Messmethoden infrage. Letztere bieten den Vorteil, eine Probe zerstörungsfrei erfassen zu können. Optische Systeme, die mehrere Sensoren in einem Gerät vereinen, sind seit einiger Zeit kommerziell erhältlich (siehe z. B. [11, 12]). Auch Keck et al. beschreiben in [8] ein multisensorisches Messsystem. Ein weiterer An-

*Korrespondenzautor: Beate Dutschk, Institut für industrielle Informationstechnik, Karlsruher Institut für Technologie, Hertzstr. 16, 76187 Karlsruhe, E-Mail: beate.dutschk@kit.edu

Matthäus Pordzik, E-Mail: matthaeus.pordzik@outlook.de

Michael Heizmann, Institut für industrielle Informationstechnik, Karlsruher Institut für Technologie, Hertzstr. 16, 76187 Karlsruhe, E-Mail: michael.heizmann@kit.edu

satz mit nicht ausschließlich optischen Verfahren wird von Hagemeyer und Lehmann in [6] beschrieben.

Besonderes relevant ist die Fusion, wenn keine der verfügbaren Oberflächenmessprinzipien ein optimales Ergebnis liefern kann [14]. Die vorgestellten Multisensor-Systeme ermöglichen jedoch nur bedingt die Fusion der Messergebnisse. Eine mögliche Vorgehensweise für die Kombination von konfokaler Mikroskopie und Fokusvariation wird von Matilla et al. in [14] dargestellt. Die Fusion wird in drei Varianten entweder über die Topografie mit einer Maske für die verworfenen Informationen, den einzelnen Ebenen oder mit den einzelnen axialen Übertragungssignalen der Messwerte durchgeführt. Weitere Verfahren zur Fusion in der Oberflächenmesstechnik werden in [22] von Wang et al. dargestellt. Ein besonderer Fokus wird auf die Methoden mit Weighted Least-Squares-Verfahren und Gaußprozessen gelegt. Beispiele für die Fusion mittels Gaußprozessen finden sich unter anderem auch in [4].

In diesem Beitrag wird die Fusion für die konfokale Mikroskopie und Weißlichtinterferometrie anhand von hierarchischen Gaußprozessen mit einer robusten Bayes'schen Komitee-Maschine [20] durchgeführt. Außerdem wird ein Verfahren mit einem Weighted Least-Squares-Verfahren und impliziten Oberflächen aufgezeigt. Im Folgenden werden die Verfahren kurz skizziert und die verwendeten Messprinzipien vorgestellt. Anhand von simulierten Daten werden die Verfahren evaluiert. Mit Aufnahmen des optischen Oberflächenmesssystems DCM8 der Firma Leica werden reale Daten erhoben. Dieses Gerät kann sowohl konfokale als auch weißlichtinterferometrische Aufnahmen erfassen. Eine Bewertung der Ergebnisse erfolgt über geeignete Metriken.

2 Gaußprozesse

Gaußprozesse stellen nicht-parametrische statistische Verfahren dar, die zur Datenfusion verwendet werden können [21]. Ein Gaußprozess

$$f(\mathbf{x}) \sim \mathcal{GP}(\mu(\mathbf{x}), \mathbf{k}(\mathbf{x}, \mathbf{x}')) \quad (1)$$

wird über den Erwartungswert $\mu(\mathbf{x})$ und die Kovarianz oder auch Kernelfunktion $\mathbf{k}(\mathbf{x}, \mathbf{x}')$ definiert [18]. Die Kernelfunktion $\mathbf{k}(\mathbf{x}, \mathbf{x}')$ beschreibt die Beziehung zwischen den Werten der Zielfunktion $f(\mathbf{x})$ und den Eingangswerten $\mathbf{x}$ bzw. $\mathbf{x}'$. Sie kann entsprechend der vorliegenden Daten gewählt werden und ist abhängig von den Hyperparametern Θ , die den Parametern der Kernelfunktion entsprechen [18]. Beispiele für gängige Kernelfunktionen sind

der lineare Kernel, die radiale Basisfunktion, die Kernel der Matérn-Klasse oder auch periodische Kernel [18, 24].

Ein Trainingsdatensatz enthält N Eingangsvektoren $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^N$ mit $\mathbf{x}_i \in \mathbb{R}^d$ und dem dazugehörigen Ausgangsvektor $\mathbf{y} = \{y_i\}_{i=1}^N$ mit $y_i \in \mathbb{R}$ [18]. Dabei ist $y_i = f(\mathbf{x}_i) + \varepsilon_i$ mit mittelwertfreiem, normalverteiltem Rauschen $\varepsilon_i \sim N(0, \sigma^2)$. f soll aus den Trainingsdaten bestimmt werden. Das Training des Gaußprozesses erfolgt über die Optimierung der Hyperparameter Θ , die den Logarithmus der bedingten Wahrscheinlichkeit maximieren [18]:

$$\log p(\mathbf{y}|\mathbf{X}, \Theta) = \log[\mathcal{N}(\mathbf{y}, \mathbf{K} + \sigma^2 \mathbf{I})]. \quad (2)$$

$\mathbf{K}$ ist die $N \times N$ Kovarianzmatrix aus den Trainingsdaten. Für die Testdaten $\mathbf{X}_* = \{\mathbf{x}_{*,i}\}_{i=1}^M$ mit $\mathbf{x}_i \in \mathbb{R}^d$ soll eine Schätzung f_* erfolgen. Für die Trainings- und Testdaten kann folgende Beziehung angenommen werden:

$$\begin{pmatrix} y \\ f_* \end{pmatrix} \sim \mathcal{N}\left(0, \begin{pmatrix} \mathbf{K} + \sigma^2 \mathbf{I} & \mathbf{K}_* \\ \mathbf{K}_*^T & \mathbf{K}_{**} \end{pmatrix}\right). \quad (3)$$

$\mathbf{K}_*$ ist die $N \times M$ Kovarianzmatrix zwischen Trainings- und Testdaten und $\mathbf{K}_{**}$ ist die $M \times M$ Kovarianzmatrix der Testdaten. Die Bestimmung der A-Posteriori-Wahrscheinlichkeitsverteilung mithilfe des Bayes'schen Theorems liefert:

$$f_* | y, \mathbf{X}, \mathbf{X}_* \sim \mathcal{N}(\mathbf{K}_*^T (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} y, \mathbf{K}_{**} - \mathbf{K}_*^T (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{K}_*). \quad (4)$$

Aufgrund der hier benötigten Matrixinversion von $(\mathbf{K} + \sigma^2 \mathbf{I})^{-1}$ ist die Rechenkomplexität bei der Optimierung $\mathcal{O}(N^3)$. Deshalb wird ein dünnbesetzter Ansatz nach [19] verwendet, der die Rechenkomplexität reduziert. Dünnbesetzte Gaußprozesse fokussieren sich auf die Inferenz von wenigen Punkten, welche zu einer möglichst genauen A-Posteriori-Schätzung des gesamten Datensatzes führen. Dazu wird ein Pseudo-Input $\mathbf{X}_A$ bestimmt, der eine Menge an Stützstellen beschreibt, die zur Schätzung herangezogen werden [19]. Die Approximation der Randwahrscheinlichkeit ist nach [19]:

$$\log p(\mathbf{y}|\mathbf{X}_A, \Theta) = \log[\mathcal{N}(\mathbf{y}, \mathbf{Q}_{NN} + \sigma^2 \mathbf{I})]. \quad (5)$$

$\mathbf{Q}_{NN}$ ist hierbei mit $\mathbf{Q}_{NN} = \mathbf{K}_{NA} \mathbf{K}_{AA}^{-1} \mathbf{K}_{AN}$ eine Approximation der vollen Kovarianzmatrix $\mathbf{K}$ mit A Stützstellen [1]. Eine variationale Approximation sowie eine Optimierung der Stützstellen erfolgt mit dem Verfahren der variationalen freien Energie nach [19].

Die Verknüpfung mehrerer Gaußprozesse kann in einem hierarchischen Modell erfolgen. Dabei können Teilprozesse mit einem übergeordneten Prozess angeordnet werden [15].

Die Randwahrscheinlichkeit des übergeordneten Prozesses ergibt sich über die Multiplikation der Wahrscheinlichkeitsverteilungen der einzelnen Teilprozesse mit

$$P(f|\mathbf{X}, \Theta) \propto \prod_{i=1}^b P(f^{(i)}|\mathbf{X}^{(i)}, \Theta^{(i)}) \quad (6)$$

mit der Anzahl b der Teilprozesse in einer Schicht und den Hyperparametern $\Theta^{(i)}$.

Über die Bildung des Logarithmus kann die Randwahrscheinlichkeit bestimmt werden und die Optimierung des übergeordneten Prozesses kann über die Optimierung der Teilprozesse erfolgen. Der übergeordnete Prozess in einem hierarchischen Gaußprozess aus stochastisch unabhängigen Datensätzen ist somit äquivalent zum Produkt der Teilprozesse. Aufgrund normalverteilter Modelle ist das Fusionsresultat als gewichtete Summe der Schätzungen definierbar:

$$\mu_{\text{fuse}} = \sum_{i=1}^b \omega_i \mu_i \quad \text{und} \quad \sigma_{\text{fuse}}^2 = \sum_{i=1}^b \omega_i \sigma_i^2 \quad (7)$$

mit $\omega_i = \sigma_i^{-2} (\sum_{j=1}^b \sigma_j^{-2})^{-1}$ [15]. Für die Fusion von heterogenen Daten wird als Erweiterung eine robuste Bayes'sche Komitee-Maschine nach [20] verwendet, da die Daten hier aus unterschiedlichen Messgeräten stammen. Sie bietet den Vorteil, unterschiedliche Priors zu berücksichtigen und lokal überangepasste Datensätze nicht zu stark in die Gewichtung mit einzubeziehen. Bei jedem Teildatensatz $\mathcal{D}^{(k)}$ wird die A-Priori-Varianz miteinbezogen nach [5]:

$$P(f_*|\mathbf{X}_*, \mathcal{D}) = P(f_*|\mathbf{X}_*) \frac{\prod_{k=1}^b P_k^{\omega_k}(f_*|\mathbf{X}_*, \mathcal{D}^{(k)})}{\prod_{k=1}^b P_k^{\omega_k}(f_*|\mathbf{X}_*)}. \quad (8)$$

Die Gewichtung der Teilmodelle wird über die relative Entropieänderung

$$\omega_i = \frac{1}{2} (\log \sigma_{i,\text{prior}}^2 - \log \sigma_i^2) \quad (9)$$

definiert, um die absolute Verbesserung des Modells zu berücksichtigen [3].

Mit den vorgestellten Ansätzen zur Erweiterung der hierarchischen Gaußprozesse ergibt sich für den Erwartungswert von Gleichung (8)

$$\mu_{\text{fuse}}^* = (\sigma_{\text{fuse}}^*)^2 \sum_{i=1}^b \omega_i (\sigma_i^*)^{-2} \mu_i^* \quad (10)$$

sowie eine Varianz von

$$(\sigma_{\text{fuse}}^*)^{-2} = \sum_{i=1}^b \omega_i (\sigma_i^*)^{-2} + \sum_{i=1}^b \left(\frac{1}{b} - \omega_i \right) (\sigma_{i,\text{prior}})^{-2}. \quad (11)$$

3 Weighted Least-Squares-Verfahren

Über ein Weighted Least-Squares-Verfahren als Verallgemeinerung des herkömmlichen Least-Squares-Verfahrens können heterogen gestreute Daten mit unterschiedlichen Rauschprozessen fusioniert werden [22]. Dabei werden einzelne Least-Squares-Modelle in Abhängigkeit ihrer Unsicherheiten gewichtet addiert. Die Gewichtung $(\sigma_i)^{-2}$ wird durch einen optimalen unvoreingenommenen Schätzer nach dem Gauß-Markov-Theorem umgekehrt proportional zur Modellunsicherheit σ_i^2 bestimmt.

Für die Rekonstruktion der Oberflächen wird der Ansatz des robusten Moving-Least-Squares-Verfahrens nach [16] verwendet. Diese Methode verwendet eine lokale Kernel-Regression, bei der eine implizite Funktion $f(\mathbf{x}_i) : \mathbb{R}^d \rightarrow \mathbb{R}$ an den Testpunkten $\mathbf{x}_i \in \mathbb{R}^d$ approximiert wird. Auch hier gilt $y_i = f(\mathbf{x}_i) + \varepsilon$, mit ε als mittelwertfreie Zufallsvariable [16]. f soll aus den vorliegenden Trainingsdaten bestimmt werden. Es gilt die Annahme, dass die Werte y_i der Testpunkte $\mathbf{x}_i$ nahe der Oberfläche liegen, d. h. $f(\mathbf{x}_i) \approx 0$ mit $y_i = 0$ [16]. Für die vorliegenden Oberflächen werden die Normalen $\mathbf{n}_i$ zu den Testpunkten $\mathbf{x}_i$ nach [9] bestimmt. Eine Formulierung für $f(\mathbf{x})$ ergibt sich über eine Minimierung von [16]

$$\arg \min_{f(\mathbf{x})} \sum_i (f(\mathbf{x}) + (\mathbf{x}_i - \mathbf{x})^T \mathbf{n}_i)^2 \phi_i(\mathbf{x}). \quad (12)$$

Daraus erhält man gemäß [16]:

$$f(\mathbf{x}) = \frac{\sum_i \mathbf{n}_i(\mathbf{x})^T (\mathbf{x} - \mathbf{x}_i) \phi_i(\mathbf{x})}{\sum_i \phi_i(\mathbf{x})}. \quad (13)$$

$\phi_i(\mathbf{x}) = \phi(\|\mathbf{x} - \mathbf{x}_i\|)$ beschreibt eine symmetrische, radial abklingende Gewichtungsfunktion, die Testpunkten nahe $\mathbf{x}$ mehr Bedeutung zuordnet.

Um eine Robustheit gegenüber Ausreißern zu erreichen, wird ein M-Schätzer eingesetzt, der eine iterative Optimierung von $f(\mathbf{x})$ in Abhängigkeit von Residuen ermöglicht:

$$f_k(\mathbf{x}) = \arg \min_{f_k(\mathbf{x})} \sum_i \omega(r_i^{k-1}) (r_i^k)^2. \quad (14)$$

Dabei ist $k - 1$ der vorangegangene Iterationsschritt mit dem entsprechenden Residuum $r_i^{k-1} = f_{k-1}(\mathbf{x}) - y_i$. r_i^k bildet das aktuelle Residuum. Über die Residuen und die Gewichtungsfunktion ω werden die Gewichte $\omega(r_i^{k-1})$ definiert. Diese Gewichte werden herangezogen, um die iterative Minimierung des Weighted Least-Squares-Problems (siehe Gleichungen (12) und (13)) zu beeinflussen [16]. Dabei werden Ausreißer eine geringere Bedeutung durch ab-

klungende Funktionen zugeordnet und die implizite Funktion wird genauer angenähert.

Für die verwendeten Residuen der impliziten Funktion r_i^{k-1} und einem zusätzlichen Parameter aus der Differenz des Normalenvektors zum Gradienten $\nabla f_{k-1}(\mathbf{x}) - \mathbf{n}_i$ werden ebenfalls symmetrische, radial abfallende Gewichtungsfunktionen ϕ_R und ϕ_N verwendet.

Das robuste iterative Moving-Least-Squares-Verfahren (RIMLS) nach [16] wird wie folgt definiert:

$$f_k(\mathbf{x}) = \frac{\sum_i \mathbf{n}_i^T (\mathbf{x} - \mathbf{x}_i) \phi_i(\|\mathbf{x} - \mathbf{x}_i\|) \phi_R(r_{i,k-1})}{\sum_i \phi_i(\|\mathbf{x} - \mathbf{x}_i\|) \phi_R(r_{i,k-1})} \dots \frac{\phi_N(\|\nabla f_{k-1}(\mathbf{x}) - \mathbf{n}_i\|)}{\phi_N(\|\nabla f_{k-1}(\mathbf{x}) - \mathbf{n}_i\|)}. \quad (15)$$

Durch diese Minimierung wird die implizite Oberfläche angenähert.

Der Fusionsansatz des gewichteten Least-Squares-Verfahrens beruht auf einer Gewichtung der einzelnen Oberflächen in Abhängigkeit der Modellunsicherheit:

$$\sigma^2 = \frac{1}{N} \sum_{j=1}^N (f_k(\mathbf{x}) - \mathbf{n}_j^T (\mathbf{x} - \mathbf{x}_j))^2. \quad (16)$$

Die Fusion der impliziten Oberflächen kann über die Abhängigkeit des Gewichtungsfaktors aus $w_i = \frac{1}{\sigma_i^2}$ erfolgen:

$$f_k(\mathbf{x}) = \frac{\sum_i w_i f_{i,k}(\mathbf{x})}{\sum_i w_i}. \quad (17)$$

Hierbei ist i die Anzahl der verwendeten Modelle, was in diesem Fall der Anzahl der verwendeten Sensorsysteme entspricht.

4 Aufnahmeverfahren

Für die vorliegenden Untersuchungen wurden die konfokale Mikroskopie und die Weißlichtinterferometrie zugrunde gelegt. Diese zwei optischen Messprinzipien sind in der Oberflächenmesstechnik weit verbreitet und kommen neben der Fokusvariation häufig zum Einsatz [10]. Sie unterscheiden sich durch unterschiedliche physikalische Grundprinzipien, was zu unterschiedlichen Fähigkeiten bei der Erfassung von Oberflächen führt. Im Folgenden werden die einzelnen Verfahren kurz skizziert.

4.1 Konfokale Mikroskopie

Die konfokale Mikroskopie basiert auf dem Prinzip eines Lichtmikroskops mit weiteren Blenden im Strahlengang, die im Vergleich zur Lichtmikroskopie eine Tiefenselektivität erzeugen können [2]. Das konfokale Prinzip ist in

Abb. 1: Prinzip eines konfokalen Mikroskops nach [2].

Abbildung 1 schematisch dargestellt. Die Veränderung des Abstands zwischen Objektiv und Probe in z-Richtung erzeugt ein Signal, aus dem ein Höhenwert für eine Oberflächentopografie ermittelt werden kann [2].

4.2 Weißlichtinterferometrie

Die Weißlichtinterferometrie nutzt die Bildung von Interferenzen bei gleichen Weglängen von Referenz- und Messstrahl aus. In Abbildung 2 wird das Prinzip schematisch dargestellt. Über eine Veränderung des Abstands zwischen Objektiv und Probe wird die Interferenz zwischen Referenz- und Messstrahl variiert und das Intensitätsprofil kann erstellt werden [2]. Daraus kann z. B. über eine Hilbert-Transformation die Oberflächentopografie ermittelt werden. Hier wird ein Mirau-Interferometer verwendet, bei dem die Interferenz direkt im Mirau-Objektiv erfolgt.

Abb. 2: Prinzip eines Weißlichtinterferometers nach [2].

5 Ergebnisse

Im Folgenden werden die Ergebnisse anhand der vorgestellten Verfahren dargestellt. Es folgen Untersuchungen mit simulierten Daten und einem realen Datensatz. Die Ergebnisse werden bezüglich der Metriken RMSE, Korrelation

Abb. 3: Modellfunktionen für die Simulation.

ρ , SSIM und MS-SSIM bewertet:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^N (Z_{\text{ref},n} - Z_{\text{test},n})^2}, \quad (18)$$

$$\rho = \frac{\sum_{n=1}^N (Z_{\text{ref},n} - \mu_{\text{ref}})(Z_{\text{test},n} - \mu_{\text{test}})}{\sqrt{(\sum_{n=1}^N (Z_{\text{ref},n} - \mu_{\text{ref}})^2)(\sum_{n=1}^N (Z_{\text{test},n} - \mu_{\text{test}})^2)}}, \quad (19)$$

$$\text{SSIM} = \frac{(2\mu_{\text{ref}}\mu_{\text{test}} + C_1)(2\sigma_{\text{ref},\text{test}} + C_2)}{(\mu_{\text{ref}}^2 + \mu_{\text{test}}^2 + C_1)(\sigma_{\text{ref}}^2 + \sigma_{\text{test}}^2 + C_2)}, \quad (20)$$

$$\text{MS-SSIM} = l_M^\alpha \cdot \prod_{m=1}^M c_m^\beta \cdot s_m^\gamma, \quad (21)$$

$$l = \frac{2\mu_{\text{ref}}\mu_{\text{test}} + C_1}{\mu_{\text{ref}}^2 + \mu_{\text{test}}^2 + C_1}, \quad (22)$$

$$c = \frac{2\sigma_{\text{ref}}\sigma_{\text{test}} + C_2}{\sigma_{\text{ref}}^2 + \sigma_{\text{test}}^2 + C_2}, \quad (23)$$

$$s = \frac{\sigma_{\text{ref},\text{test}} + C_3}{\sigma_{\text{ref}}\sigma_{\text{test}} + C_3}. \quad (24)$$

Bei C_1 , C_2 und C_3 handelt es sich um Konstanten, die für die Regularisierung sorgen. α , β und γ sind Gewichteungen [17].

5.1 Evaluierung anhand simulierter Daten

Für die Evaluation der vorgestellten Verfahren werden Simulationen mit charakteristischen Rauschgrößen der Aufnahmeverfahren verwendet. In Abbildung 3 sind die verwendeten Modellfunktionen dargestellt. Die verwendeten

Abb. 4: Evaluierung der Fusion mittels des Weighted Least-Squares-Verfahrens anhand des synthetischen Datensatzes. Es werden die RMSE-, SSIM-, MS-SSIM- und Korrelations-Metriken der Einzeldatensätze und der Fusion dargestellt. 1#: Heaviside, 2#: Sinc, 3#: Peaks, 4#: Ornament.

ten Rauschgrößen sind angelehnt an Angaben aus der Literatur [7, 13]. Dabei werden unterschiedliche Auflösungen berücksichtigt. Die charakteristischen Eigenschaften der gewählten Modellfunktionen sind charakteristischen Oberflächentopografien nachempfunden. Während in [4, 24] niedrig- und hochaufgelöste Datensätze unterschieden werden, ist diese Unterscheidung im vorliegenden Fall von untergeordneter Bedeutung. Beide Datensätze werden mit entsprechendem Rauschen versehen.

Die Auswertung der einzelnen Metriken für die simulativ erstellten Datensätze ist in Abbildung 4 für das Weighted Least-Squares-Verfahren dargestellt. Die Untersuchungen zeigen, dass die Fusion mit dem Weighted Least-Squares-Verfahren die Rekonstruktion gegenüber den Rekonstruktionen der Einzeldatensätze tendenziell verbessert. Auch beim Vergleich mit den gewählten Metriken zeigt sich, dass in drei von vier Fällen eine Verbesserung erzielt wird.

Auch bei der Verwendung der Gaußprozesse für die Fusion der Daten zeigt sich in den meisten Fällen eine Verbesserung. Hier wurden jeweils mehrere Durchläufe mit unterschiedlichen Kernelfunktionen berechnet. In Abbildung 5 ist deshalb zusätzlich die Standardabweichung dargestellt. Es zeigt sich, dass das Ergebnis der Rekonstruktion von der Wahl des Kernel beeinflusst wird, was sich in einer erhöhten Standardabweichung widerspiegelt.

Abb. 5: Evaluierung der Fusion mittels verteilter Gaußprozesse am synthetischen Datensatz. Es werden die RMSE-, SSIM-, MS-SSIM- und Korrelations-Metriken der Einzeldatensätze und der Fusion dargestellt. 1# : Heaviside, 2#: Sinc, 3#: Peaks, 4#: Ornament

Bei geeigneter Wahl des Kernels kann die Fusion zu einer Verbesserung der vorgestellten Metriken führen. Die besten Ergebnisse werden mit radialen Basisfunktionen als Kernelfunktionen erzielt.

5.2 Untersuchung eines realen Datensatzes

Die vorgestellten Fusionsmethoden wurden auch mit einem realen Datensatz untersucht. Für die Aufnahme wurde ein Tiefeneinstellnormal der Firma Halle verwendet. Die Aufnahmen sind in Abbildung 6 ohne weitere Vorverarbeitungen dargestellt. Sowohl die konfokale als auch die weißlichtinterferometrische Aufnahme wurde mit dem Leica DCM 8 erzeugt. Beide Aufnahmen wurden mit einer 20-fachen Vergrößerung aufgenommen. Zusätzlich wurde auf Basis des Datenblatts des Tiefeneinstellnormals eine möglichst genaue Referenz zum Abgleich modelliert.

Die Ergebnisse in Abbildung 7 zeigen, dass Abweichungen der Messwerte vom Modell durch die Fusion mit dem Weighted Least-Squares-Verfahren verringert werden können. Auch unter Vorliegen von Ausreißern und in Kantenbereichen kann eine verbesserte Rekonstruktion der Topografie erzielt werden. Bei der Fusion mit Gaußprozessen in Abbildung 8 wird nur bei der MS-SSIM-Metrik

Abb. 6: Modell und Aufnahmen des Tiefeneinstellnormals.

Abb. 7: Evaluierung der Fusion basierend auf dem Weighted Least-Squares-Verfahren am Tiefeneinstellnormal. Es werden die RMSE-, SSIM-, MS-SSIM- und Korrelations-Metriken der Einzeldatensätze sowie der Fusion dargestellt.

Abb. 8: Evaluierung der Fusion basierend auf verteilten Gaußprozessen am Tiefeneinstellnormal. Es werden die RMSE-, SSIM-, MS-SSIM- und Korrelations-Metriken der Einzeldatensätze sowie der Fusion dargestellt.

eine Verbesserung erzielt. Eine allgemeine Verbesserung mit den gewählten Metriken ist nicht erkennbar.

6 Zusammenfassung

In diesem Beitrag wurden verschiedene Methoden zur Fusion von Daten für die multisensorielle Oberflächenmesstechnik dargestellt. Untersucht wurden Adaptionen des Weighted Least-Squares-Verfahrens und von hierarchischen Gaußprozessen für die Fusion von Daten aus Weißlichtinterferometrie und konfokaler Mikroskopie. Durch die vorgenommenen Adaptionen zeigen beide Verfahren das Potential für eine geeignete Fusion. Bei der Untersuchung mit synthetischen Datensätzen zeigt das Weighted Least-Squares-Verfahren in drei von vier Fällen bessere Ergebnisse. Mit beiden vorgestellten Verfahren können eine Fusion der entsprechenden Daten durchgeführt werden und Verbesserungen erzielt werden. Dabei zeigt sich, dass das Weighted Least-Squares-Verfahren leistungsfähiger ist. Im Vergleich zu den untersuchten hierarchischen Gaußprozessen hat es außerdem einen geringeren Rechenaufwand. Weitere Arbeiten zur optimierten Registrierung sowie weiteren Fusionsvarianten folgen.

Literatur

- [1] M. Bauer, M. van der Wilk und C. E. Rasmussen. Understanding probabilistic sparse Gaussian process approximations. In D. D. Lee, M. Sugiyama, U. V. Luxburg, I. Guyon und R. Garnett, editors, *Advances in Neural Information Processing Systems 29*, S. 1533–1541. Curran Associates, Inc, 2016.
- [2] J. Beyerer, F. Puente León und C. Frese. *Automatische Sichtprüfung: Grundlagen, Methoden und Praxis der Bildgewinnung und Bildauswertung*. Springer-Verlag, Berlin Heidelberg, 2. erweiterte und verbesserte Auflage, 2016.
- [3] Y. Cao und D. J. Fleet. Generalized product of experts for automatic and principled fusion of Gaussian process predictions. *CoRR*, abs/1410.7827, 2014.
- [4] B. M. Colosimo, M. Pacella und N. Senin. Multisensor data fusion via Gaussian process models for dimensional and geometric verification. *Precision Engineering*, 40:199–213, 2015.
- [5] M. Deisenroth und J. W. Ng. Distributed Gaussian processes. In F. Bach und D. Blei, editors, *Proceedings of the 32nd International Conference on Machine Learning*, Band 37 in *Proceedings of Machine Learning Research*, S. 1481–1490, Lille, France, 07–09 Jul 2015. PMLR.
- [6] S. Hagemeyer und P. Lehmann. Multisensor-Messsystem zur Messung von Mikro- und Nanotopographien. *tm – Technisches Messen*, 84(S1):2–12, 2017.
- [7] A. Hornberg, editor. *Handbook of machine and computer vision: The guide for developers and users*. Wiley-VCH, Weinheim, 2017.
- [8] A. Keck, M. Böhm, K. L. Knierim, O. Sawodny, M. Gronle, W. Lyda und W. Osten. Multisensorisches Messsystem zur dreidimensionalen Inspektion technischer Oberflächen. *tm – Technisches Messen*, 81(6):280–288, 2014.
- [9] K. Klasing, D. Althoff, D. Wollherr und M. Buss. Comparison of surface normal estimation methods for range sensing applications. In *2009 IEEE International Conference on Robotics and Automation*, S. 3206–3211, Mai 2009.
- [10] R. Leach, editor. *Optical Measurement of Surface Topography*. Springer-Verlag, Berlin Heidelberg, 2011.
- [11] Leica Microsystems GMS GmbH. LeicaDCM 8. URL <http://www.leica-microsystems.com/de/produkte/lichtmikroskope/industrie-materialanalyse/aufrechte-mikroskope/details/product/leica-dcm8/>. Abrufdatum: 04.04.2017.
- [12] Mahr GmbH. Marsurf CWM 100 - Mahr Fertigungsmesstechnik. URL <https://www.mahr.com/de/Leistungen/Fertigungsmesstechnik/Produkte/MarSurf---Optische-Messgeraete/MarSurf-CWM-100/>. Abrufdatum: 12.06.2018.
- [13] E. M. M. Manders, F. J. Verbeek und J. A. Aten. Measurement of co-localization of objects in dual-colour confocal images. *Journal of Microscopy*, 169(3):375–382, 1993.
- [14] A. Matilla, J. Mariné, J. Pérez, C. Cadevall und R. Artigas. Three-dimensional measurements with a novel technique combination of confocal and focus variation with a simultaneous scan. In C. Gorecki, A. K. Asundi und W. Osten, editors, *Optical Micro- and Nanometrology VI*. SPIE, 2016.
- [15] J. W. Ng und M. P. Deisenroth. Hierarchical mixture-of-experts model for large-scale Gaussian process regression. *ArXiv e-prints*, Dez. 2014.
- [16] A. C. Öztireli, G. Guennebaud und M. Gross. Feature preserving point set surfaces based on non-linear kernel regression. *Computer Graphics Forum*, 28(2):493–501, 2009.
- [17] S. K. Ramasamy und J. Raja. Performance evaluation of multi-scale data fusion methods for surface metrology domain. *Journal of Manufacturing Systems*, 32(4):514–522, 2013.
- [18] C. E. Rasmussen und C. K. I. Williams. *Gaussian processes for machine learning*. Adaptive computation and machine learning. MIT Press, Cambridge, Mass., 2006.
- [19] M. Titsias. Variational learning of inducing variables in sparse Gaussian processes. In D. van Dyk und M. Welling, editors, *Proceedings of the Twelfth International Conference on Artificial Intelligence and Statistics*, Band 5 in *Proceedings of Machine Learning Research*, S. 567–574, Clearwater Beach, Florida USA, 2009. PMLR.
- [20] V. Tresp. A Bayesian Committee Machine. *Neural Computation*, 12(11):2719–2741, 2000.
- [21] S. Vasudevan. Data fusion with Gaussian processes. *Robotics and Autonomous Systems*, 60(12):1528–1544, 2012.
- [22] J. Wang, R. K. Leach und X. Jiang. Review of the mathematical foundations of data fusion techniques in surface metrology. *Surface Topography: Metrology and Properties*, 3(2), 2015.
- [23] A. Weckenmann, X. Jiang, K.-D. Sommer, U. Neuschaefer-Rube, J. Seewig, L. Shaw und T. Estler. Multisensor data fusion in dimensional metrology. *CIRP Annals - Manufacturing Technology*, 58(2):701–721, 2009.
- [24] Y. Yin, M. J. Ren, L. Sun und L. Kong. Gaussian process based multi-scale modelling for precision measurement of complex surfaces. *CIRP Annals - Manufacturing Technology*, 65(1):487–490, 2016.