

Invariante Merkmale zur Klassifikation von Defekten aus Beleuchtungsserien

Ana Pérez Grassi, Fernando Puente León, Technische Universität München

Manuskripteingang: 22. April 2008; zur Veröffentlichung angenommen: 02. Juni 2008

Manche Oberflächen können nur zuverlässig inspiziert werden, wenn man sie mit variabler Beleuchtung beobachtet. Die automatische Umsetzung dieses Ansatzes erfordert die Erfassung und Verarbeitung von Bildserien. Jedes Bild der Serie bildet den gleichen Oberflächenausschnitt jeweils unter einem anderen Beleuchtungswinkel ab. Eine Methode wird vorgestellt, um aus solchen Bildserien rotations- und translationsinvariante Merkmale zu extrahieren. Im vorliegenden Fall werden die Invarianten durch Fuzzy-Histogramme repräsentiert. Zur Klassifikation wird eine SVM (*Support Vector Machine*) eingesetzt. Die Robustheit des Ansatzes wird am Beispiel der Klassifikation von Lackdefekten demonstriert.

Schlagwörter: Bildserie, invariante Merkmale, invariante Histogramme, Lackdefekte, Holzoberflächen

Invariant Features for Classification of Defects Based on Illumination Series

Some surfaces can only be inspected reliably, if they are observed under variable illumination. An automated inspection based on this principle requires taking and processing series of images in which each image shows the same surface's section with an illumination from a different angle. This paper presents a method to extract translation and rotation invariant features from such series of images. In our case, the invariant features are represented by fuzzy histograms and classified by an SVM (*support vector machine*). The robust performance of the method is demonstrated by the detection and classification of varnish defects.

Keywords: Image series, invariant features, invariant histograms, varnish defects, wood surfaces

1 Einleitung

Topografische Defekte auf bestimmten Oberflächentypen, etwa auf metallischen oder lackierten Oberflächen, können nur zuverlässig erkannt werden, wenn diese Oberflächen aus verschiedenen Richtungen beleuchtet werden [3]. Deswegen erfordert ihre automatische Inspektion die Aufnahme von Bildserien, wobei jedes

Bild der Serie unter einem anderen Beleuchtungswinkel aufgenommen wird. Die gleichzeitige Verarbeitung der gesamten Bildserie erweist sich als vorteilhaft gegenüber der getrennten Verarbeitung der Einzelbilder. Grund dafür ist, dass die relevante Information nicht nur in den Einzelbildern der Serie enthalten ist, sondern auch in den Beziehungen unter ihnen. Daher sollten die verschiedenen Dimensionen der Bildserie – Ort und Be-

leuchtungswinkel – gleichzeitig betrachtet werden, um die Extraktion der invarianten Merkmale vorzunehmen.

Der hier vorgestellte Ansatz basiert auf den Erkenntnissen von Ojala et al. [2] und Schael [5]. In diesen Arbeiten werden invariante Merkmale aus Einzelbildern errechnet, um Texturen und Defekte zu klassifizieren. Im vorliegenden Aufsatz schlagen wir eine Erweiterung dieser Methoden auf Bildserien vor. Zu diesem Zweck wird eine Kernfunktion definiert, welche die Information einer lokalen 3D-Nachbarschaft verarbeitet. Um den Verlust an Information zu minimieren, werden die Invarianten nicht durch Integration generiert, sondern vielmehr mit Hilfe von Histogrammen dargestellt. Histogramme erhalten die invarianten Eigenschaften der Merkmale und erhöhen dabei die Diskriminanz unter den Klassen [7].

Die Leistungsfähigkeit des vorgestellten Ansatzes wird anhand der Detektion und Klassifikation von Lackdefekten auf Holzoberflächen demonstriert. Solche Defekte sind zum Teil visuell kaum wahrnehmbar. Ferner kann – insbesondere bei transparentem Lack – die Maserung des Substrats die Defekte auf der Lackschicht maskieren. Die korrekte Erkennung von Lackdefekten stellt daher eine große Herausforderung an die automatische Sichtprüfung dar, weshalb diese Aufgabe von der Holzindustrie immer noch überwiegend manuell-visuell bewältigt werden muss.

Der restliche Aufsatz ist folgendermaßen gegliedert: Abschnitt 2 stellt das Konzept der invarianten Merkmale vor. Im Abschnitt 3 wird die Methode zur Extraktion invarianter Merkmale aus Bildserien beschrieben. Schließlich präsentiert Abschnitt 4 experimentelle Ergebnisse am Beispiel der Detektion und Klassifikation von Lackdefekten.

2 Extraktion invarianter Merkmale durch Integration

Die Aufgabe der Mustererkennung besteht darin, Aussagen über die in Mustern enthaltenen Objekte zu gewinnen. Muster, die sich durch induzierte Transformationen ineinander überführen lassen, haben im Hinblick auf die späteren Aussagen über die Objekte den gleichen Informationsgehalt – man bezeichnet solche Muster als äquivalent. Wenn ein Merkmal konstant für alle äquivalenten Muster bleibt, wird dieses als invariant bezeichnet [6].

Im Folgenden sei $g(\mathbf{x})$ mit $\mathbf{x} = (x, y)^T \in \mathbb{R}^2$ ein Grauwertbild und $\mathbf{m} = (m^1, \dots, m^L)^T$ ein L -dimensionaler Merkmalsvektor mit m^l als dessen l -tes Element. Man kann ein invariantes Merkmal m^l gegenüber einer bestimmten Transformationsgruppe $\mathcal{T}$ konstruieren, indem man eine beliebige lokale Kernfunktion

$f_l := f_l(\mathbf{s}_l)$ vom transformierten Bild über die ganze Transformationsgruppe integriert [6], wobei $\mathbf{s}_l$ der Parametervektor der Kernfunktion ist:

$$m^l = \int_{\mathcal{T}} f_l(t\{g(\mathbf{x})\}) dt = \int_{\mathcal{P}} f_l(t(\mathbf{p})\{g(\mathbf{x})\}) d\mathbf{p}. \quad (1)$$

Gleichung (1) ist als Haar-Integral bekannt, und $t(\mathbf{p}) \in \mathcal{T}$ bezeichnet eine Transformation, die durch den Parametervektor $\mathbf{p} \in \mathcal{P}$ parametrisiert wird. $\mathcal{P}$ bezeichnet dabei den Parameterraum.

In dieser Arbeit werden Invarianten bezüglich der zweidimensionalen euklidischen Bewegung extrahiert. Die 2D-euklidische Bewegung ist eine finite und kompakte Transformationsgruppe, was die Konvergenz des Haar-Integrals garantiert [6]. Diese Gruppe besteht aus Translation und Rotation im $\mathbb{R}^2$. Der Parametervektor ist $\mathbf{p} = (\tau_x, \tau_y, \varphi)^T$, wobei τ_x , τ_y und φ entsprechend die Translation und die Rotation charakterisieren. Gleichung (1) kann für die betrachtete 2D-euklidische Gruppe wie folgt umgeschrieben werden:

$$m^l = \int_{\mathcal{P}} f_l(t(\tau_x, \tau_y, \varphi)\{g(\mathbf{x})\}) d\tau_x d\tau_y d\varphi. \quad (2)$$

Wegen der diskreten Natur eines digitalen Bildes müssen alle Variablen diskretisiert werden:

$$g_{mn} := g(\mathbf{x}),$$

$$\mathbf{p}_{ijk} := (i\Delta x, j\Delta y, k\Delta\varphi)^T,$$

$$t_{ijk} := t(\mathbf{p}_{ijk}),$$

$$\mathbf{x} = (m\Delta x, n\Delta y)^T,$$

$$0 \leq m \leq M-1, \quad 0 \leq n \leq N-1,$$

$$0 \leq i \leq M-1, \quad 0 \leq j \leq N-1,$$

$$0 \leq k \leq K-1, \quad K = \frac{2\pi}{\Delta\varphi}.$$

Mittels Ersetzens des Integrals durch die Gesamtsumme kann Gl. (2) ebenfalls im Diskreten ausgedrückt werden:

$$m^l = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \sum_{k=0}^{K-1} f_l(t_{ijk}\{g_{mn}\}). \quad (3)$$

3 Invariante Merkmale für Bildserien

Im vorliegenden Fall ist das Eingangssignal eine Bildserie, die durch systematische Variation des Beleuchtungsazimuts $\omega \in [0, 2\pi)$ erzeugt wird [1]. Die Lichtquelle

wird um die Oberfläche herum rotiert, wobei die Einzelbilder in $\Delta\omega$ -Schritten aufgenommen werden (siehe Bild 1). Somit entstehen nach einer Umdrehung der Beleuchtung $B = \frac{2\pi}{\Delta\omega}$ Bilder, die jeweils mit dem Azimut der Beleuchtung indiziert werden (siehe Bild 2):

$$g_{mnb} := g(\mathbf{x}, \omega_b) \quad \text{mit} \quad \omega_b = b\Delta\omega \quad \text{und} \quad 0 \leq b \leq B-1.$$

Um Bildserien zu berücksichtigen, wird in Gl. (3) g_{mn} durch g_{mnb} ersetzt:

$$m^l = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \sum_{k=0}^{B-1} f_l(t_{ijk}\{g_{mnb}\}). \quad (4)$$

Die transformierte Bildserie $t_{ijk}\{g_{mnb}\}$ kann wie folgt ausgedrückt werden:

$$t_{ijk}\{g_{mnb}\} =: \tilde{g}_{m'n'b'}.$$

Der 2D-Vektor $(m', n')^T$ resultiert aus der Translation und Rotation des Vektors $(m, n)^T$:

$$\begin{pmatrix} m' \\ n' \end{pmatrix} = \begin{pmatrix} \cos(k\Delta\varphi) & \sin(k\Delta\varphi) \\ -\sin(k\Delta\varphi) & \cos(k\Delta\varphi) \end{pmatrix} \begin{pmatrix} m \\ n \end{pmatrix} - \begin{pmatrix} i \\ j \end{pmatrix}. \quad (5)$$

Ferner ist b' das Ergebnis einer zyklischen Translation der Intensitätswerte in der dritten Dimension, was jedoch mit der Rotationstransformation zusammenhängt: Wenn das auf der Bildserie abgebildete Objekt eine 2D-Rotation um den Winkel $k\Delta\varphi$ erfährt, kommt es zu

einer Änderung sowohl in den 2D-Koordinaten des abgebildeten Objekts als auch in seinen Intensitätswerten. Die Intensitätswerte würden sich allerdings nach einer derartigen 2D-Rotation nicht ändern, wenn sich die Lichtquelle zusammen mit dem Objekt drehen würde. Letzteres ist zu einer Translation in der dritten Dimension um einen Abstand $k\Delta\varphi$ äquivalent:

$$b' = (b + k) \bmod B. \quad (6)$$

Bild 3 zeigt zwei Bildserien vom gleichen Objekt, wobei das Objekt auf der zweiten Bildserie um 270° rotiert wurde. Die Form des Objekts wurde so gewählt, dass der Effekt der Beleuchtungsrichtung zusammen mit der Rotation über die Intensitätswerte betont wird. Ein Kreis, eine Raute, ein Dreieck und ein Pentagon wurden entsprechend benutzt, um vier Punkte um das Objekt herum zu markieren. In der ersten Bildserie werden diese Punkte so gezeigt, dass deren Position in Bezug auf die Lage der Beleuchtungsquelle immer unverändert bleibt. Um die gleichen Punkte auf der zweiten Bildserie zu lokalisieren, müssen sie nicht nur um 270° rotiert, sondern auch um 270° zyklisch entlang der dritten Dimension verschoben werden. Dadurch bleibt die Position jedes Punktes in Bezug auf das Objekt und die Beleuchtungsquelle erhalten. Entsprechend Gl. (6) können invariante Merkmale bezüglich Rotation aus einer Beleuchtungsserie nur für eine Auflösung des Rotationswinkels der Transformation $\Delta\varphi = \Delta\omega$ extrahiert werden.




Bild 1: Aufnahmeconfiguration für Bildserien mit konstantem Elevationswinkel ϑ .

Figure 1: Configuration for capturing series of images with a constant elevation angle ϑ .




Bild 2: Bildserie eines Kraters mit $B = 4$ ($\Delta\omega = 90^\circ$).

Figure 2: Image series of a crater with $B = 4$ ($\Delta\omega = 90^\circ$).




Bild 3: Rotation eines Objekts in einer Beleuchtungsserie ($\Delta\omega = \Delta\varphi = 90^\circ$, $k = 3$).

Figure 3: Object rotation in an illumination series ($\Delta\omega = \Delta\varphi = 90^\circ$, $k = 3$).

3.1 Kernfunktion

Bei der Auslegung der Kernfunktion wurden zwei Aspekte berücksichtigt:

- Die Information über topografische Defekte schlägt sich zum Teil in den Intensitätsänderungen entlang der dritten Dimension der Bildserie nieder. Daher sollte die Kernfunktion diese Änderungen auf jeden Fall berücksichtigen.
- Die lateralgeometrische Anordnung der Bildintensitäten enthält ebenfalls wichtige Informationen über die im Bild enthaltenen Defekte. Die Kernfunktion sollte daher diese Information ebenfalls auswerten.

Die vorgeschlagene Kernfunktion ist eine vektorielle Funktion $\mathbf{f}_l := \mathbf{f}_l(\mathbf{s}_l)$ mit $\mathbf{s}_l = (r_{1,l}, r_{2,l}, \alpha_l, \beta_l, a_l, \Delta\theta_l)$. Die Kernfunktion des transformierten Bildes kann wie folgt ausgedrückt werden:

$$\mathbf{f}_l(t_{ijk}\{g_{mnb}\}) = \mathbf{f}_l(\tilde{g}_{m'n'b'}) =: \mathbf{f}_{lijk}.$$

Das q -te Element f_{lijk}^q der Kernfunktion des transformierten Bildes $\mathbf{f}_{lijk} = (f_{lijk}^1, \dots, f_{lijk}^{Q_l})$ ist wie folgt definiert:

$$f_{lijk}^q = \frac{1}{B} |\tilde{g}_{u_l^q} - \tilde{g}_{v_l^q}|, \quad (7)$$

$$\mathbf{u}_l^q = \left(\begin{bmatrix} r_{1,l} \cos(\alpha_l + q\Delta\theta_l) \\ -r_{1,l} \sin(\alpha_l + q\Delta\theta_l) \end{bmatrix}; 0 \right)^T, \quad (8)$$

$$\mathbf{v}_l^q = \left(\begin{bmatrix} r_{2,l} \cos(\beta_l + q\Delta\theta_l) \\ -r_{2,l} \sin(\beta_l + q\Delta\theta_l) \end{bmatrix}; a_l \right)^T$$

mit $1 \leq q \leq Q_l$ und $Q_l = \frac{2\pi}{\Delta\theta_l}$.

Nach Gl. (7) werden hierzu zwei kreisförmige 2D-Nachbarschaften – eine im Bild ω_0 und eine im Bild $a_l\Delta\omega$ – definiert. Die 2D-Nachbarschaften mit den Radien $r_{(1,l)}$ und $r_{(2,l)}$ werden mit einer Auflösung $\Delta\theta_l$ abgetastet, was Q_l Intensitätswerte pro Nachbarschaft




Bild 4: Kernfunktion f_l für eine Bildserie mit $B = 4$ ($\Delta\omega = 90^\circ$) mit den Parametern: $a = 2$, $r_1 = 0,5 r_2$, $\alpha = 45^\circ$, $\beta = 90^\circ$ und $\Delta\theta = 180^\circ$ ($Q = 2$). Dabei stellen m' und n' das lokale Zentrum der Koordinaten dar. Die Linien zwischen den Punkten symbolisieren den Betrag der Differenz.

Figure 4: Kernel function f_l for an image series with $B = 4$ ($\Delta\omega = 90^\circ$) with the parameters: $a = 2$, $r_1 = 0,5 r_2$, $\alpha = 45^\circ$, $\beta = 90^\circ$, and $\Delta\theta = 180^\circ$ ($Q = 2$). The local center of coordinates is indicated by m' and n' . The lines between the points represent the absolute value of the difference.

ergibt. Die Anfangspunkte für die Abtastung werden durch α_l und β_l definiert. Die von der Abtastung jeder 2D-Nachbarschaft resultierenden Punkte $\mathbf{u}_l^q$ und $\mathbf{v}_l^q$ werden mit dem Index q gekennzeichnet. Um die Information entlang der dritten Dimension zu sammeln, werden die Intensitätswerte mit dem gleichen Index q jeder 2D-Nachbarschaft subtrahiert. Der resultierende Betrag der Differenz wird in f_{lij}^q gespeichert. Bild 4 illustriert die Kernfunktion und ihre Parameter, wobei der Einfachheit halber der Index l unterdrückt wurde.

Die definierte Kernfunktion liefert einen Vektor $\mathbf{m}^l = (m^{l1}, \dots, m^{lQ_l})^T$ zurück, dessen q -tes Element m^{lq} durch Gl. (4) definiert ist:

$$m^{lq} = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \sum_{k=0}^{K-1} f_{lij}^q. \quad (9)$$

Damit hat der Merkmalsvektor $\mathbf{m}$ die Dimension $\sum_{l=1}^L Q_l$.

3.2 Invarianten gegen 2D-Rotation

Durch die Bildung der Summe über k in Gl. (9) kann ein Q_l -dimensionaler rotationsinvarianter Merkmalsvek-

tor $\tilde{\mathbf{m}}_{ij}^l$ errechnet werden, dessen q -tes Element $\tilde{m}_{ij}^{lq}$ wie folgt definiert ist:

$$\tilde{m}_{ij}^{lq} = \sum_{k=0}^{K-1} f_{lijk}^q. \quad (10)$$

Wie in Gl. (6) zu erkennen ist, verursacht die 2D-Rotationstransformation in einer Bildserie nicht nur eine Rotation der Intensitätswerte um $\Delta\varphi$, sondern auch eine Translation entlang der dritten Dimension. Diese Translation erlaubt es, die relative Position jedes Pixels während der Rotation bezüglich der Beleuchtungsquelle festzuhalten, was eine Betrachtung der Koordinatenänderung des Objekts unabhängig von der Intensitätsänderung ermöglicht. Die Berechnung von $\tilde{m}_{ij}^{lq}$ wird entsprechend in den Bildern 5a und 5b schematisiert.

3.3 Invarianten gegenüber Translation: Fuzzy-Histogramme

Der rotations- und translationsinvariante Vektor $\mathbf{m}^l$ kann durch die Summe über i und j in Gl. (9) erzeugt werden, wobei sein q -tes Element wie folgt geschrieben werden kann:

$$m^{lq} = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \tilde{m}_{ij}^{lq}. \quad (11)$$

Alternativ können jedoch Histogramme erstellt werden. Histogramme sind ebenfalls invariant gegenüber Translationen, haben jedoch bessere Diskriminanzeigenschaften als durch Integration generierte Merkmale [7]. Zur Erstellung von Histogrammen werden Q_l Matrizen $\mathbf{H}^{lq}$ der Größe $M \times N$ gebildet, deren Elemente h_{ij}^{lq} wie folgt definiert werden:

$$h_{ij}^{lq} := \tilde{m}_{ij}^{lq}.$$

Von jeder Matrix $\mathbf{H}^{lq}$ wird ein Fuzzy-Histogramm $\mathcal{H}_c^{lq}$ mit C Einträgen erstellt, wobei $1 \leq c \leq C$ gilt [7].

Obwohl bei einer typischen Kameradynamik von 8 Bit jedes Kernfunktionselement f_{lij}^q Werte zwischen 0 und $255/B$ annehmen kann, ist die Dynamik von f_{lij}^q in der Praxis viel niedriger. Dies bedeutet, dass schon kleine Änderungen an f_{lij}^q viel Information über die Oberfläche enthalten können. Diese Information könnte durch die Bildung von Histogrammen verloren gehen, wenn die Anzahl der Histogrammeinträge C nicht ausreichend groß gewählt wird. Der Informationsverlust aufgrund unzureichender Histogrammeinträge beeinträchtigt die Diskriminanzeigenschaften der Merkmale. Ein großes C verursacht andererseits Histogramme mit




Bild 5: Gewinnung der Rotationsinvariante $\tilde{m}_{ij}^{lq}$ für die in Bild 4 gezeigten Kernfunktionselemente f_{ijk}^1 (a) und f_{ijk}^2 (b). Die Linien zwischen den Punkten repräsentieren die Ergebnisse jeder Iteration der Gesamtsumme über k gemäß Gl. (10). $\Delta\varphi = \Delta\omega = 90^\circ$ ($K = 4$).

Figure 5: Extraction of rotation invariant features $\tilde{m}_{ij}^{lq}$ for the kernel function elements f_{ijk}^1 (a) and f_{ijk}^2 (b) illustrated in Figure 4. The lines between the points represent the results of each iteration over k in the summation of Eq. (10). $\Delta\varphi = \Delta\omega = 90^\circ$ ($K = 4$).

vielen leeren Einträgen, was auch einen negativen Einfluss auf die Diskriminanz ausübt. Als Lösungsansatz für dieses Problem bietet sich eine neue Kernfunktion $\tilde{f}_l$ an, die eine logarithmierte Version der Kernfunktion f_l darstellt. Das q -te Element $\tilde{f}_{lij}^q$ der neuen Kernfunktion des transformierten Bildes wird folgendermaßen definiert:

$$\tilde{f}_{lij}^q = \frac{1}{B} \log_2 \left| \tilde{g}_{u_i^q} - \tilde{g}_{v_j^q} + 1 \right|.$$

Der Logarithmus erhöht den Abstand zwischen den Differenzen in der Berechnung der Kernfunktion von Gl. (7), was eine breitere Verteilung der Werte auf die Histogrammeinträge verursacht.

Normalerweise verraten hohe Werte der Matrixelemente h_{ij}^{lq} , dass das Pixel (i, j) der Bildserie Teile eines Defekts abbildet. Hohe Werte von h_{ij}^{lq} sind in den Histogrammeinträgen durch hohe c -Werte repräsentiert. Die Menge von Pixeln in der Bildserie, die zu einem Defekt gehören, ist jedoch viel niedriger als die Menge von Pixeln, die eine intakte Oberfläche abbilden. Dies verursacht, dass die Histogrammeinträge mit hohen c -Werten viel kleiner sind als diejenigen Einträge mit niedrigen c -Werten. Anders ausgedrückt werden hohe Werte von h_{ij}^{lq} wenig Einfluss auf die Klassifikation haben. Um den Einfluss der Histogrammeinträge mit hohen c -Werten während der Klassifikation zu verstärken, wird jeder

Histogrammeintrag mit einer Exponentialfunktion gewichtet:

$$\tilde{\mathcal{H}}_c^{lq} = D^c \mathcal{H}_c^{lq} \quad \text{mit} \quad D \in \mathbb{N}.$$

Die Q_l resultierenden Fuzzy-Histogramme $\tilde{\mathcal{H}}_c^{lq}$ werden in einer Matrix $\tilde{\mathbf{H}}^l$ der Größe $Q_l \times C$ zusammengefasst, welche das vorgeschlagene invariante Merkmal $\mathbf{m}^l$ bezüglich Rotation und Translation darstellt, und deren q, c -tes Element $\tilde{h}_{qc}^l$ wie folgt definiert ist:

$$\tilde{h}_{qc}^l := \tilde{\mathcal{H}}_c^{lq}. \quad (12)$$

Bild 6 vergleicht die Merkmale $\tilde{\mathbf{H}}^l$ von einer Oberfläche mit und ohne Defekt. In der Bildung der Merkmale der ersten Spalte wurde die Kernfunktion f_l und $D = 1$ angewendet. Die Merkmale der zweiten Spalte wurden durch $\tilde{f}_l$ und $D = 1$ berechnet. Schließlich zeigt die dritte Spalte die Wirkung von D auf die Merkmale: Die Merkmale der intakten Oberfläche mit $D = 1$ und $D = 10$ unterscheiden sich nur in ihren Elementen $\tilde{h}_{qc=2}^l$. Andererseits ändern sich bei defektbehafteten Oberflächen die Werte von $\tilde{h}_{qc}^l$ für $c \in \{2, 3, 4\}$, wobei speziell für $c = 4$ die Werte von $\tilde{h}_{qc}^l$ erst für den Fall $D = 10$ einen wesentlichen Einfluss auf die Klassifikation ausüben. Der größere Unterschied zwischen den Merkmalen beider Klassen, der mit jeder Modifikation erreicht wird, verbessert die Trennbarkeit und dadurch die spätere Klassifikation.




Bild 6: Matrix $\tilde{\mathbf{H}}_l$ mit $C = 5$ und $Q_l = 8$ ($\Delta\theta = 45^\circ$) für simulierte Oberflächen mit und ohne Defekt. Die drei Spalten vergleichen die Merkmale für die verschiedenen Möglichkeiten: Kernfunktion $\mathbf{f}_l$ und $D = 1$ (nicht gewichtete Histogramme), Kernfunktion $\tilde{\mathbf{f}}_l$ (mit Logarithmierung) und $D = 1$ und Kernfunktion $\tilde{\mathbf{f}}_l$ und $D = 10$ (gewichtete Histogramme).

Figure 6: Fuzzy histograms $\tilde{\mathbf{H}}_l$ with $C = 5$ and $Q_l = 8$ ($\Delta\theta = 45^\circ$) for simulated surfaces with and without defect. The three columns compare the features obtained with kernel function $\mathbf{f}_l$ and $D = 1$ (not weighted histogram), kernel function $\tilde{\mathbf{f}}_l$ (with logarithm) and $D = 1$ and kernel function $\tilde{\mathbf{f}}_l$ and $D = 10$ (weighted histogram).

4 Ergebnisse

Die vorgestellte Methode wurde auf die Detektion und Klassifikation von Lackdefekten auf Holzoberflächen angewandt. Alle Muster weisen transparenten Lack auf, wodurch die Holztextur im Hintergrund immer sichtbar ist. Lackdefekte sind nur teilweise und unter bestimmten Beleuchtungsbedingungen sichtbar. Außerdem stellt die darunter liegende Holztextur ein Hintergrundrauschen dar, das die Defekte maskieren kann. Wegen dieser Eigenschaften ist die Inspektion lackierter Holzoberflächen mit einer hohen Komplexität verbunden [4].

Eine Oberfläche kann Teile mit Defekten und ohne Defekte aufweisen. Deswegen wurde der Merkmalsvektor $\mathbf{m}$ lokal für kleinere 3D-Fenster der Größe $M' \times N' \times B$ berechnet, in die jede Bildserie aufgeteilt wurde. Die Fenster wurden aus der Bildserie mit einer örtlichen Überlappung von 50% extrahiert. Drei verschiedene Fenstergrößen $M' \times N' \times B$ wurden getestet: $64 \times 64 \times 8$, $32 \times 32 \times 8$ und $16 \times 16 \times 8$, wobei die mittlere Größe $32 \times 32 \times 8$ bei der betrachteten Auflösung die besten Ergebnisse lieferte.

Für jedes Fenster wurde ein Merkmalsvektor $\mathbf{m}$ berechnet, der durch die Auswahl von L verschiedenen Kernfunktionen $\tilde{\mathbf{f}}_l$ generiert wurde. Dementsprechend besteht der Merkmalsvektor $\mathbf{m}$ aus L Elementen $\mathbf{m}^l$, wobei jedes Element $\mathbf{m}^l$ eine Matrix $\tilde{\mathbf{H}}^l$ aus Fuzzy-Histogrammen darstellt. Als Referenz zur Selektion geeigneter Kernfunktionen dienten Messungen der Kolmogorov-Smirnow-Distanz zwischen den Merkmalen. Dabei wurden Kernfunktionen ausgewählt, welche die Kolmogorov-Smirnow-Distanz zwischen Merkmalen verschiedener Klassen maximieren und zwischen Merkmalen gleicher Klassen minimieren.

Während der Trainingsphase ordnete ein Experte jedem Fenster der Größe $M' \times N' \times B$ eine Klasse zu. Die Klasse jedes Fensters zusammen mit ihrem berechneten Merkmalsvektor $\mathbf{m}$ wurden zum Training des SVM-Klassifikators benutzt. Während der Testphase wurden sowohl die gleiche Konfiguration der Fenster als auch die gleiche Kernfunktionsliste benutzt.

Eine repräsentative Auswahl der Klassifikationsergebnisse ist in Bild 7 dargestellt. Die präsentierten Ergebnisse wurden von Bildserien mit $B = 8$ und ei-




Bild 7: Ergebnisse: (links) Einzelbild der Beleuchtungsserie; (rechts) Klassifikationsergebnis.

Figure 7: Results: (left) image of the series; (right) classification result.

ner Liste aus $L = 10$ Kernfunktionen gewonnen. Danach wurde jedes Fenster der Größe $32 \times 32 \times 8$ durch $10 \times Q_I$ Fuzzy-Histogramme charakterisiert. Fünf verschiedene Klassen wurden definiert: kein Defekt, Luftblasen, Ampullen, Krater und Risse. Zum Trainieren des Klassifikators wurden 20 Bildserien herangezogen, die

verschiedene Lackdefekte auf verschiedenen Holztypen enthalten. Zum Testen des Klassifikators wurde eine disjunkte Menge an Bildserien verwendet. Die Ergebnisse zeigen, dass die vorgeschlagenen Merkmale in der Lage sind, die Defekte nicht nur zuverlässig zu detektieren, sondern auch korrekt zu klassifizieren.

5 Zusammenfassung

Es wurde eine Methode präsentiert, um invariante Merkmale bezüglich Rotation und Translation aus Bildserien zu extrahieren, wobei die Bildserien durch systematische Änderung des Beleuchtungsazimuts generiert wurden. Die Rotation verursacht in solchen Bildserien nicht nur eine Verschiebung der 2D-Koordinaten entsprechend dem Rotationswinkel $k\Delta\varphi$, sondern auch eine Translation in der Beleuchtungsdimension um $k\Delta\varphi$.

Eine Gruppe von vektoriellen Kernfunktionen wurde definiert, um die ganze relevante Information in den inspeziierten Oberflächen zu sammeln. Zur höheren Diskriminanz zwischen den Klassen wurden zwei Methoden kombiniert: Zum einen wurden Invarianten bezüglich Rotation durch Integration berechnet. Darüber hinaus wurden Invarianten gegenüber Translation durch die Bildung von Fuzzy-Histogrammen extrahiert.

Die vorgestellte Methode wurde am Beispiel der Detektion und Klassifikation von Lackdefekten auf Holzoberflächen demonstriert. Zur Klassifikation wurde eine *Support Vector Machine* herangezogen. Die Ergebnisse zeigen auf, dass Lackdefekte durch die generierten Merkmale sehr zuverlässig erkannt und unterschieden werden können.

Literatur

- [1] Lindner, C. und Puente León, F.: *Segmentierung strukturierter Oberflächen mittels variabler Beleuchtung*. Technisches Messen, 73(4):200–207, 2006.
- [2] Ojala, T.; Pietikäinen, M. und Mäenpää, T.: *Multiresolution gray-scale and rotation invariant texture classification with local binary patterns*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 24(7):971–987, 2002.
- [3] Puente León, F.: *Enhanced imaging by fusion of illumination series*. In: Löffeld, O. (Hrsg.): *Sensors, Sensor Systems, and Sensor Data Processing*, Band 3100 der Reihe *Proceedings of SPIE*, Seiten 297–308. SPIE, 1997.
- [4] Pérez Grassi, A.; Abián Pérez, M. Á.; Puente León, F. und Pérez Campos, R. M.: *Detection of circular defects on varnished or painted surfaces by image fusion*. In: *Proceedings of the IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems*, Seiten 255–260, Heidelberg, 3–6 September 2006.
- [5] Schael, M.: *Methoden zur Konstruktion invarianter Merkmale für die Texturanalyse*. Doktorarbeit, Universität Freiburg, 2005.
- [6] Schulz-Mirbach, H.: *Anwendung von Invarianzprinzipien zur Merkmalgewinnung in der Mustererkennung*, Band 372 der Reihe *Fortschritt-Berichte VDI, Reihe 10*. VDI Verlag, Düsseldorf, 1995.
- [7] Siggelkow, S. und Burkhardt, H.: *Invariant feature histograms for texture classification*. In: *Proceedings of the 1998 Joint Conference on Information Sciences (JCIS'98)*, Research Triangle Park, North Carolina, 1998.



Ing. Ana Pérez Grassi ist wissenschaftliche Mitarbeiterin am Fachgebiet Verteilte Messsysteme der Technischen Universität München.

Hauptarbeitsgebiete: Automatische Sichtprüfung, Bildverarbeitung und Mustererkennung.

Adresse: Fachgebiet Verteilte

Messsysteme, Technische Universität München, Theresienstr. 90/N5, 80333 München, E-Mail: a.perez@tum.de



Prof. Dr.-Ing. Fernando Puente León leitet das Fachgebiet Verteilte Messsysteme an der Technischen Universität München.

Hauptarbeitsgebiete: Mess- und Automatisierungstechnik, Signalverarbeitung, automatische Sichtprüfung und Bildverarbeitung, Mustererkennung, Informationsfusion und Datenübertragung.

Adresse: Fachgebiet Verteilte Messsysteme, Technische Universität München, Theresienstr. 90/N5, 80333 München, E-Mail: f.puente@tum.de