

Neue Bildverarbeitungsalgorithmen für die automatische Fehlstellendetektion bei der shearografischen Bauteilüberprüfung

Alexander HANF^{1,2}, Christopher PETRY², Michael PROF. DR. SCHUTH²

¹ Mesolt Engineering GmbH, Trier

² Hochschule Trier, Technikum OGKB A113, Trier

Kontakt E-Mail: Alexander.Hanf@Mesolt.com

Kurzfassung. Bei der shearografischen Bauteilüberprüfung stellt die Automatisierung der Klassifikation in Gut- und Schlecht-Teile eine große Herausforderung dar. Auch wenn Defekte für geschultes Personal meist intuitiv gut erkennbar sind, hat es sich bisher als schwierig erwiesen, hierfür geeignete Algorithmen zu entwickeln. Die besten Ergebnisse wurden bisher mit Convolutional Neural Networks (CNNs) erzielt. Diese müssen jedoch für jeden Anwendungsfall neu trainiert werden.

In diesem Paper werden alternative Algorithmen präsentiert, die statt aufwändiger Trainingsphase lediglich eine einfache Parametrisierung benötigen. Die Klassifikation kann sowohl anhand von Shearogrammen, als auch von Demodulationen erfolgen. In der Validierung wurde eine Spezifität von 100% und eine Sensitivität zwischen 82,9% und 97,9% erreicht, abhängig von der Beschaffenheit, Sichtbarkeit und Orientierung der Fehlstellen.

1. Motivation

Neben der Wirtschaftlichkeit sorgt das durch den Klimawandel getriebene Bewusstsein für Nachhaltigkeit und Ressourceneffizienz, für einen erhöhten Innovationsdruck in der Materialtechnik. Besonders in Bereichen, in denen Gewicht und daraus resultierender Energieverbrauch wichtige Faktoren darstellen, wie etwa in der Luft- und Raumfahrt, zunehmend aber auch in der Automobilindustrie, sind Kompositbauteile unabdingbar geworden. Diese stellen, wegen der verschiedenen Materialien und komplexen Strukturen, in der Qualitätssicherung eine Herausforderung für viele Prüftechniken dar. Ein Prüfverfahren, das sich hierbei bewährt hat, ist die Shearografie. Diese findet unter anderem in der Qualitätskontrolle von Reifen, Flugzeugtragflächen und Windkraftanlagen Anwendung.

Shearografie ist ein optisches Lasermessverfahren, das lokale Unterschiede in Oberflächenverformungen im Sub-Mikrometerbereich ermittelt. In der Qualitätskontrolle wird diese hohe Messgenauigkeit genutzt, um Anomalien in der Verformung eines Prüfteils zu detektieren, die Hinweise auf Schwachstellen im Inneren liefern.

Eines der Hindernisse für eine stärkere Verbreitung der Shearografie ist die aufwändige Beurteilung der gewonnenen Informationen. Diese wird in der Regel von speziell geschultem Personal durchgeführt, was einerseits hohe Kosten verursacht und andererseits die Prüfgeschwindigkeit limitiert. Eine Automatisierung dieses Schrittes würde entsprechend, neben einer Steigerung der Effizienz, auch die Erschließung neuer



Anwendungsfelder ermöglichen. Im Folgenden werden neue Ansätze zur automatischen Fehlerdetektion anhand shearografischer Bilddaten präsentiert.

2. Shearografie

Shearografie ist ein berührungsfreies, bildgebendes Verfahren, mit dem sich lokale Unterschiede im Verformungsverhalten sichtbar machen lassen. Hierzu werden Prüfteile mit einer kohärenten Laserlichtquelle beleuchtet und durch spezielle Optiken fotografiert, siehe Fig. 1a). Das in das Messgerät einfallende Licht wird dabei so umgelenkt, dass es mit sich selbst interferiert und zwei sich überlagernde Bilder auf den Foto-Chip projiziert. Die Versatzrichtung der beiden Bilder wird als Shearrichtung bezeichnet, der Grad der Verschiebung als Shearbetrag, siehe Fig. 1b). Die auf diese Art aufgenommenen Bilder werden als Interferenzbilder bezeichnet.

Durch Subtraktion zweier Interferenzbilder eines Bauteils voneinander, entsteht ein s.g. Differenzphasenbild, auch *Shearogramm* genannt. Diese Differenzphasenbilder repräsentieren die Ableitung der Out-of-Plane Verformung entlang der Shearrichtung. In der Regel werden Differenzphasenbilder zunächst mit einem Mean-Filter gefiltert um Rauschen zu unterdrücken und die Interpretation zu erleichtern, siehe Fig. 1c).

In Fig. 2b) ist die erste Ableitung der Out-of-Plane Verformung entlang der Shearrichtung in blau geplottet.

Die der Berechnung zugrundeliegende Größe ist nicht die Distanz der Ausdehnung, sondern Unterschiede in der resultierenden Phasenverschiebung des Lichts. Entsprechend ist sie nur zwischen 0 und 2π definiert, sodass es bei der Quantisierung der Messergebnisse zu Phasensprüngen kommt. Dies ist mit der Anwendung einer *Modulo* 2π -Operation auf die Ableitung vergleichbar, und wird in Fig. 2b) in rot dargestellt. Diese Phasensprünge erschweren die Fehlerdetektion der Shearogramme, besonders für automatische Systeme.

Typisch für Defekte sind die s.g. *Schmetterlingsmuster*. Hierbei zeigen zwei benachbarte Gruppen konzentrischer Ringe, siehe Fig. 2c), wie sich durch die Verformung auf der Oberfläche des Bauteils eine Senke oder Erhebung gebildet hat. Anhand der Helligkeitsverläufe innerhalb der Ringe, von hell zu dunkel oder umgekehrt, lässt sich die Richtung der Steigung beurteilen. Die Positionierung der beiden Ringstrukturen, neben oder übereinander, ist dabei abhängig von der Shearrichtung.

Ein Ansatz, die Sichtbarkeit der Fehler zu verbessern, ist die s.g. Demodulation [1][2][3][4][5][6]. Hierbei wird versucht, die in Fig. 2b) dargestellte *Modulo* 2π -Operation umzukehren. Durch den bei einer *Modulo*-Operation unvermeidbaren Informationsverlust, ist hierbei nur eine näherungsweise Rekonstruktion möglich. Hierzu müssen alle Phasenübergänge, sowohl in, als auch orthogonal zur Shearrichtung integriert werden. Dieser Schritt ist entsprechend rechenaufwändig.

3. Stand der Forschung

Sämtliche bei der Recherche gefundenen Vorgehensweisen zur automatischen Fehlerdetektion in shearografischen Bilddaten beschreiben die Analyse von Shearogrammen. Ansätze, welche die Demodulation der Shearogramme zur Defektdetektion verwenden, konnten nicht gefunden werden.

Die meisten existierenden Verfahren arbeiten auf Basis Neuronaler Netze. So verwenden Rosin, Nyongesa und Otieno [7] zunächst Korrelationskoeffizienten zur Bestimmung von Symmetrie-Achsen, entlang derer das Shearogramm gesampled wird. Diese Samples werden anschließend von Backpropagation Networks klassifiziert. Die Sensitivität und Spezifität betragen jeweils 100%.

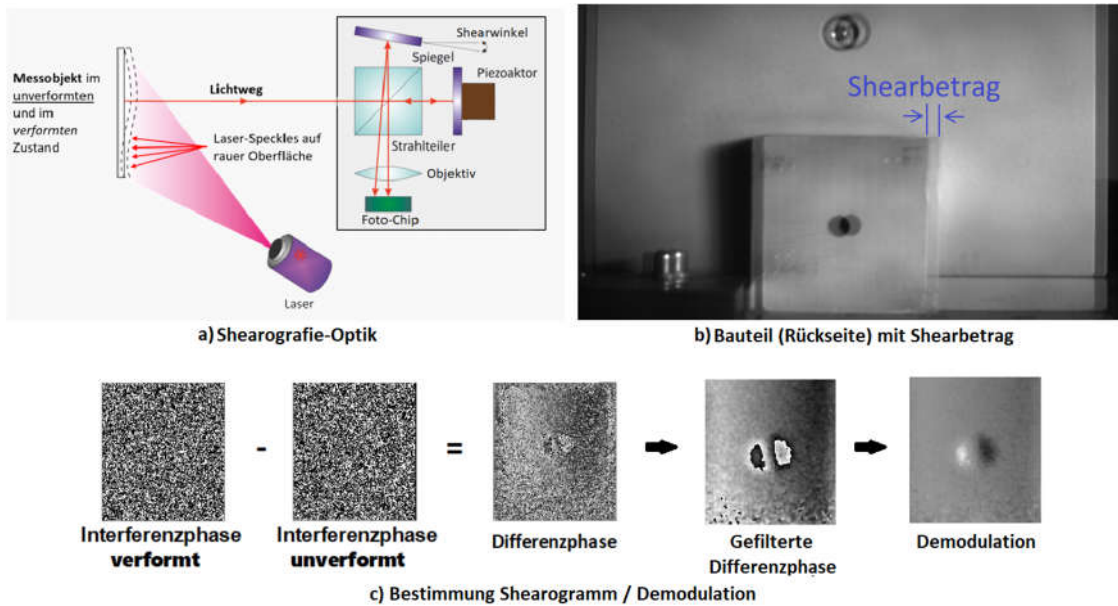


Fig. 1 Aufnahme eines Shearogramms

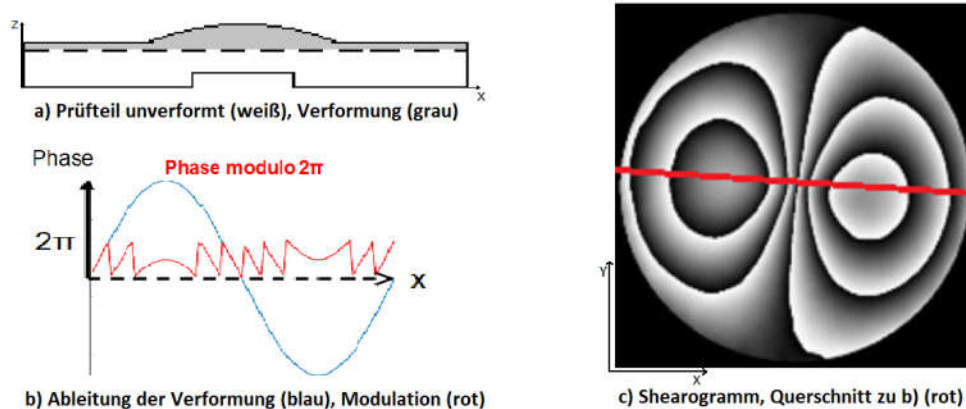


Fig. 2 Interpretation eines Shearogramms

Ye, Ma, Zhou, Arola und Zhang [8] verzichten bei ihrem Ansatz auf explizites Sampling und lassen die Shearogramme von *ZF Faster R-CNN* [9] bewerten. Die Qualität der Klassifikation wird als äquivalent zu einem menschlichen Prüfer bezeichnet.

Auch Chang, Srinivasan, Wang, Ganapathy, Vincent und Deepa [10] nutzen ein *Faster R-CNN*, welches sie zur Reduktion der False-Positive-Rate (FP-Rate) eines Convolutional-Neural-Networks einsetzen. Während zwar 90% der Shearogramme richtig klassifiziert werden konnten, wurde die FP-Rate durch Verwendung des zweiten Neuronalen Netzwerks lediglich um 2% von 20% auf 18% reduziert.

Lediglich Wang, Lin und Yang [11] sowie Vandenrijt und Georges [12] verzichten bei ihren Algorithmen auf die Verwendung von Neuronalen Netzen.

Wang, Lin und Yang detektieren Fehlstellen anhand von Regionen mit erhöhter Standardabweichung und erzielen eine 85% Übereinstimmung der von ihrem System gefundenen und von Menschen gefundenen Fehlstellen.

Bei Vandenrijt und Georges erfolgt die Auswahl der als fehlerhaft markierten Regionen basierend auf dem quadratischen Mittel (RMS) der Gradienten in X- und Y-Richtung. Die Ergebnisse werden als vielversprechend beschrieben.

Ein aussagekräftiger Vergleich der verschiedenen Ansätze und der hier vorgestellten Algorithmen ist leider nicht möglich, da, selbst bei vorhandenen Literaturangaben zur Performanz, keine standardisierten Testdatensätze existieren, die als einheitliche Grundlage zur Verifikation genutzt werden können.

4. Algorithmen

Im Folgenden werden 2 Algorithmen zur Fehlstellendetektion anhand von Shearogrammen bzw. deren Demodulation präsentiert.

Da dabei nur Graustufenbilder genutzt werden, sei ein Bild I im Folgenden durch seine Breite I_{width} , seine Höhe I_{height} , sowie durch die Menge der Grauwerte $I(x,y)$ mit $0 \leq I(x,y) \leq 255$, $0 \leq x < I_{width}$ und $0 \leq y < I_{height}$ definiert.

4.1 Fehlerdetektion anhand shearografischer Demodulationsbilder (MinMaxRoiMatching)

Zur Detektion der Fehlstellen in den Demodulationsbildern werden Bereiche gesucht, in denen es zunächst eine positive Steigung gibt (Anstieg auf die fehlertypische Auswölbung), gefolgt von einer entgegengesetzten negativen Steigung (Abstieg zurück auf die Prüfteiloberfläche). Zwischen diesen kann ein Sattelpunkt ohne nennenswerte Steigung liegen. Im Demodulationsbild zeigen sich diese Defekte durch benachbarte helle und dunkle *Regions of Interest (Roi)*, gegebenenfalls mit einem grauen Sattelpunkt zwischen ihnen.

Die Grundidee des hier vorgestellten Algorithmus ist es, benachbarte Regionen mit besonders hohen positiven und negativen Steigungen zu lokalisieren und zusammenzufassen. Im Folgenden wird der Algorithmus als *MinMaxRoiMatching* bezeichnet.

Zur Filterung globaler Verformungstrends wird aus dem Eingangsbild I_{in} zunächst mittels einer Detrend-Operation das Bild $I_{detrend}$ berechnet.

Anschließend werden, zur Detektion von betragsmäßig starken Steigungen, die zwei Masken M_{min} und M_{max} erstellt. Diese beinhalten alle Pixel, deren Grauwert kleiner bzw. größer der Parameter $minS$ bzw. $maxS$ sind. Anschließend wird auf jede der Masken eine morphologische Open-Operation angewendet.

Der nächste Schritt ist die Blob-Detection [16]. Als Ausgabe resultieren die beiden Listen *MinBlobs* und *MaxBlobs*. Diese können jeweils mehrere Blobs B beinhalten, jeweils definiert durch ihren Mittelpunkt $Blobs_M(B)$ sowie ihren Radius $Blobs_R(B)$. Blobs unter einer bestimmen Größe werden verworfen.

Der letzte Schritt ist das Blob-Matching. Hierbei wird für jeden Blob $B_1 \in MaxBlobs$ geprüft, ob ein Blob $B_2 \in MinBlobs$ existiert, sodass die Distanz zwischen $Blobs_M(B_1)$ und $Blobs_M(B_2)$, abzüglich der Radien $Blobs_R(B_1)$ und $Blobs_R(B_2)$, kleiner ist als der vorgegebene Distanzwert *MaxBlobDistanz*. Existieren Blob Paare, auf die diese Bedingung zutrifft, werden sie als Defekte markiert und das Bild als *Nicht-OK (NOK)* klassifiziert. Der schrittweise Ablauf ist in Fig. 3 a) – f) dargestellt.

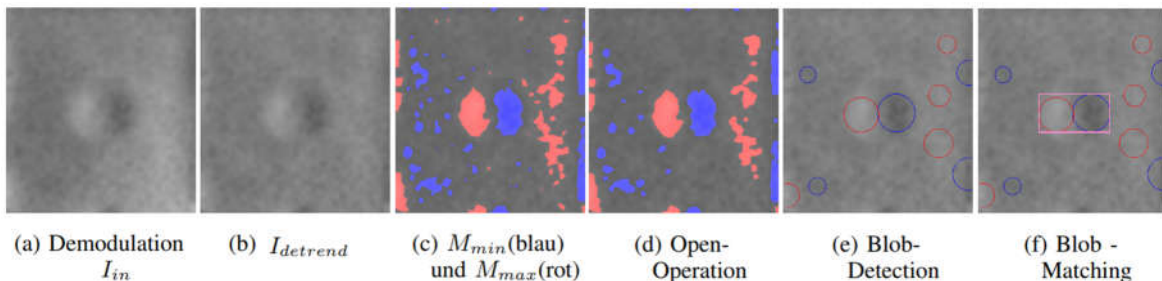


Fig 3 Ablauf MinMaxRoiMatching

4.2 Fehlerdetektion anhand von Differenzphasenbildern (GradShift)

Bei der Interpretation eines Differenzphasenbildes ist zu beachten, dass das Bild zwar die erste Ableitung der Verformung repräsentiert, die Helligkeitswerte der einzelnen Pixel jedoch nicht die Steigung am jeweiligen Punkt wiedergeben. Stattdessen sind die Helligkeitswerte der Pixel nur im Kontrast zu ihrer Umgebung aussagekräftig.

Zur Interpretation bietet es sich entsprechend an, zunächst die Gradienten zu bestimmen. Das so berechnete Gradientenbild beschreibt die zweite Ableitung der Verformung, wobei es dieselben Phasensprünge aufweist wie das zugrundeliegende Differenzphasenbild. Um diese zu bereinigen wird eine Technik eingesetzt, die im Folgenden als PhaseShift bezeichnet wird.

Wie bereits beschrieben liegt die Aussagekraft eines Differenzphasenbildes in den Helligkeitsverhältnissen benachbarter Pixel. Eine gleichmäßige Änderung dieser Werte verändert entsprechend nicht die zugrunde liegenden Informationen. Zwar ist es nach diesem Verschieben (Shift) nötig eine Modulo-Operation durchzuführen, um alle Helligkeitswerte wieder auf das Intervall 0-255 zu mappen, da diese Operation jedoch äquivalent zur impliziten Modulo 2π Operation bei der Berechnung der Shearogramme ist, entsteht hierbei kein zusätzlicher Informationsverlust. Im Folgenden beschreibt $PShift_s$ ein Phasenschieben um den Wert s , siehe Gleichung 1. Dabei gilt $I_{in} = PShift_0 = PShift_{256}$.

$$PShift_s(x, y) = modulo_{256}(I_{in}(x, y) + s),$$

$$\forall x < I_{width},$$

$$\forall y < I_{height}$$
(1)

Zur Berechnung eines von Phasensprüngen bereinigten Gradientenbildes für ein Eingabebild I_{in} werden zunächst $PShift_0 (=I_{in})$, $PShift_{85}$ und $PShift_{170}$, sowie die jeweiligen Gradientenbilder $Grad_{I_{in}}$, $Grad_{PShift_{85}}$ und $Grad_{PShift_{170}}$ bestimmt. Anschließend werden $Grad_{Min}$, $Grad_{Max}$ und $Grad_{Sum}$ berechnet, wobei $Grad_{Min}(x,y)$ und $Grad_{Max}(x,y)$ jeweils als Minimum bzw. Maximum von $Grad_{I_{in}}(x,y)$, $Grad_{PShift_{85}}(x,y)$ und $Grad_{PShift_{170}}(x,y)$ definiert sind und $G_{Sum}(x,y) = Grad_{I_{in}}(x,y) + Grad_{PShift_{85}}(x,y) + Grad_{PShift_{170}}(x,y)$ gilt.

Da der Gradient zwischen benachbarten Pixeln nur in maximal einem der drei phasenverschobenen Gradientenbilder durch einen Phasensprung verfälscht werden kann, lässt sich aus der Subtraktion von $Grad_{Min}$ und $Grad_{Max}$ von $Grad_{Sum}$ ein von Phasensprüngen bereinigtes Gradientenbild $Grad_{Diff}$ errechnen, siehe Fig. 4.




Fig 4 Bestimmung des von Phasensprüngen bereinigten Gradientenbildes

Zur Vorbereitung der Fehlerdetektion wird auf $Grad_{Dif}$ zunächst ein Mean-Filter angewendet. Die eigentliche Fehlerdetektion erfolgt wie beim *MinMaxRoiMatching*-Algorithmus durch Blob-Matching, siehe Fig. 5. Die Bestimmung der ROIs, die Open-Operation und die Blob-Detection erfolgen wie in Abschnitt 4.1 beschrieben. Lediglich beim

Blob-Matching ist zu beachten, dass statt zwei nun drei Blobs gematched werden müssen, da nicht mehr die 1. sondern die 2. Ableitung der Verformung betrachtet wird.

Hierzu wird folgende Regel formuliert: Drei verschiedene Blobs B_1 , B_2 , B_3 repräsentieren einen Defekt und sind genau dann zu matchen, wenn $B_1, B_2 \in \mathbf{MaxBlobs}$, $B_3 \in \mathbf{MinBlobs}$ und der Mittelpunkt von B_3 im von B_1 und B_2 aufgespannten Rechteck liegt. Außerdem darf die Distanz von B_1 und B_2 zu B_3 jeweils nicht größer als vom Parameter *Blob-Distanz* vorgegeben sein.




Fig 5 Detektion von Fehlstellen anhand des von Phasensprüngen bereinigten Gradientenbildes

5. Datensatz

Zur Validierung der hier präsentierten Algorithmen werden 50mm x 50mm x 10mm Platten aus Polyoxymethylen (POM) Kunststoff verwendet. Diese wurden zur Simulation von Fehlstellen mit Sacklochbohrungen und Nuten verschiedener Größe und Tiefe versehen, siehe Fig. 6a). Diese Art der Substitution ist in der Shearografie-Praxis üblich [13].

Die Aufnahme der Shearogramme sowie die Berechnung der Demodulationen erfolgt durch das *Technikum für Optische Messtechnik, Gerätebau, Konstruktion und Bauteiloptimierung (OGKB)* [14] der Hochschule Trier. Dabei werden die Platten einzeln mittels 750 W Quarzstrahler und eines shearographischen Messgeräts (Shearbetrag 3,5 mm in X-Richtung, Laserwellenlänge 532 nm) in einem Abstand von 365 mm angeregt bzw. erfasst.

Um sicherzustellen, dass für alle eingebrachten Defekte geeignete Shearogramme existieren, werden mehrere Prüfreiheiten durchgeführt. Diese unterscheiden sich in der Dauer der Anregung sowie den verwendeten Filtern. Insgesamt werden 129 Shearogramme bzw. Demodulationen berechnet, welche auf die entsprechenden Datensätze **Phase** und **Demod** verteilt werden. Für jeden der beiden Datensätze werden die Bilder in verschiedene Klassen eingeteilt. **Phaseok** und **Demodok** beinhalten alle Bilder der fehlerfreien OK-Prüfteile, alle anderen werden der Klasse **Phasenok** bzw. **Demodok** (NOK = Nicht-OK) zugewiesen.

Da nicht jeder Defekt in jeder Prüfreiheit gut oder auch nur teilweise sichtbar ist, werden die NOK-Aufnahmen zusätzlich auf die Unterklassen **Phasegv** (Good Visibility) **Phasebv** (Bad Visibility) und **Phasenv** (Not Visible) bzw. **Demodgv**, **Demodbv** und **Demodnv** verteilt. Die Beurteilung der Sichtbarkeit erfolgt in Anlehnung an DIN 54180-1:2015-0 [15] bzw. ASTM E258 [13].

Fig. 6 zeigt die Prüfteile und einige der Aufnahmen mit der jeweiligen Klassenzugehörigkeit, dabei beschreibt $phase_{l,g1}$ das Shearogramm des Prüfteils $g1$ aus der Messreihe 1.

6. Auswertung

Die Auflösung der untersuchten Shearogramme bzw. Demodulationen beträgt 494 ± 6 Pixel x 516 ± 21 Pixel, wobei in einem Vorverarbeitungsschritt zunächst von jedem Bild ein 20 Pixel breiter Rahmen abgeschnitten wird, um Randeinflüsse auszuschließen.

Da noch keine Versuche unternommen wurden die Implementierung der hier präsentierten Algorithmen, beispielsweise durch Parallelisierung, auf Performanz zu

optimieren, sind die angegebenen Zeiten als Worst-Case, nicht als kompetitiver Benchmark zu interpretieren. Die Berechnungen erfolgen auf einem handelsüblichen Windows 10 Heimcomputer.




Fig. 6 Prüfteile(links) und Beispiel-Shearogramme mit Klassenzugehörigkeit (rechts)

6.1 Resultate MinMaxRoiMatching

Die Evaluation wird mit verschiedenen Teilmengen des in Absatz 5 beschriebenen Datensatzes durchgeführt:

- **D1 = Demod_{OK} ∪ Demod_{GV}**
- **D2 = Demod_{OK} ∪ Demod_{GV} ∪ Demod_{BV}**

Im Durchschnitt dauert die Klassifizierung eines Bildes 0.33 Sekunden, die maximale Klassifikationsdauer beträgt 0.52 Sekunden.

D1	Richtig klassifiziert	Falsch klassifiziert
OK	34 (100%)	0 (0%)
NOK	47 (97,9%)	1 (2,1%)

Tabelle 1 Ergebnisse D1

D2	Richtig klassifiziert	Falsch klassifiziert
OK	34 (100%)	0 (0%)
NOK	63 (82,9%)	13 (17,1%)

Tabelle 2 Ergebnisse D2

Die Ergebnisse der Klassifikation sind in den Tabellen 1 und 2 dargestellt. Sie zeigen, dass die FN-Rate bei 0% liegen und dass für die gut sichtbaren Defekte eine Sensitivität von 97,91% erreicht wird. Lediglich bei einem Prüfbild wird ein vorhandener Defekt nicht erkannt. Ursache hierfür ist, dass es sich bei dem Defekt um eine in Shearrichtung orientierte Nut handelt. Dies hat zur Folge, dass zwar der Auf- und Abstieg der Verformung erkannt werden, diese jedoch zu weit auseinander liegen um, bei dem verwendeten *MaxBlobDistanz* Parametern, als zusammengehörig erkannt zu werden.

Von den Demodulationen mit schlecht sichtbaren Defekten konnten nur 57,14% richtig klassifiziert werden.

Insgesamt stellt der *MinMaxRoiMatching*-Algorithmus einen sehr vielversprechenden Ansatz zur Detektion von Defekten auf Basis der Demodulation dar. Die Abhängigkeit von Bildern mit gut sichtbaren Fehlstellen könnte durch die gute Spezifität relativiert werden, da durch die Konjunktion mehrerer Prüfdurchläufe mit unterschiedlichen

Aufnahmepara-metern eine sehr robuste Prüfung gewährleistet werden sollte. Dies gilt es in weiteren Untersuchungen zu verifizieren.

6.2 Resultate GradShift

Die Evaluation wird mit verschiedenen Teilmengen des in Absatz 5 beschriebenen Datensatzes durchgeführt:

- **P1 = PhaseOK \cup PhaseGV**
- **P2 = PhaseOK \cup PhaseGV \cup PhaseBV**

Im Durchschnitt dauert die Klassifizierung eines Bildes 0.59 Sekunden, die maximale Klassifikationsdauer beträgt 1.34 Sekunden. Die Ergebnisse sind in den Tabellen 4 und 5 dargestellt.

P1	Richtig klassifiziert	Falsch klassifiziert
OK	34 (100%)	0 (0%)
NOK	39 (97,5%)	1 (2,5%)

Tabella 3 Ergebnisse P1

P2	Richtig klassifiziert	Falsch klassifiziert
OK	34 (100%)	0 (0%)
NOK	63 (87,5%)	9 (12,5%)

Tabella 4 Ergebnisse P2

Wie schon beim MinMaxRoiMatching ist auch beim GradShift anzumerken, dass manche der False-Positives, 100% bei **P1** und 33% bei **P2**, auf Defekte mit einer Orientierung orthogonal zur Shearrichtung zurückzuführen sind. Wie in Fig.7c), d) dargestellt, zeigt sich diese Art von Defekten nicht durch das gesuchte Muster aus einem MaxBlob, einem MinBlob und einem MaxBlob in einer Reihe, sondern durch je zwei über Kreuz angeordnete Min- und MaxBlobs. Durch eine zusätzliche Abfrage beim BlobMatching, auf eben diese Konfiguration, sollte es bei Weiterentwicklungen des Algorithmus entsprechend nicht nur möglich sein, diese Art von Defekten zu finden, sondern darüber hinaus die beiden Defektarten voneinander zu unterscheiden.

Die im Vergleich zum *MinMaxRoiMatching* deutlich längere Klassifikationsdauer ist, neben der höheren Anzahl an zu matchenden Blobs, damit zu erklären, dass beim *MinMaxRoiMatching* bereits berechnete Demodulationen als Input verwendet werden, während beim Grad-Shift-Algorithmus zunächst das von Phasensprüngen bereinigte Gradientenbild bestimmt werden muss.

7. Fazit

Sowohl die Demodulation, als auch die hier verwendete Methode zur Berechnung eines von Phasensprüngen befreiten Gradientenbildes, haben sich als gute Basis zur automatischen Klassifikation von shearografischen Ergebnissen erwiesen.

Das in beiden Ansätzen verwendete BlobMatching kann die meisten Testbilder gut klassifizieren, besonders im Hinblick auf in Shearrichtung orientierte Defekte existiert jedoch noch Optimierungspotential, siehe Fig. 7. Eine Option wäre es, verschiedene Shearrichtungen zu kombinieren. Dies würde es auch erlauben die zulässige *MaxBlobDistanz* zu beschränken und so das Risiko für False-Positives zu verringern. Die so erzielten Verbesserungen wären jedoch gegen die aufwändigere Datenerhebung abzuwiegen

Des Weiteren sei anzumerken, dass die vom verwendeten Blob-Detektor gewählten Blobs nicht immer nachvollziehbar waren. Eine präzisere Detektion und Beschreibung der Blobs, beispielsweise durch Höhe und Breite statt des Radius, könnte weiteres Verbesserungspotential bieten.

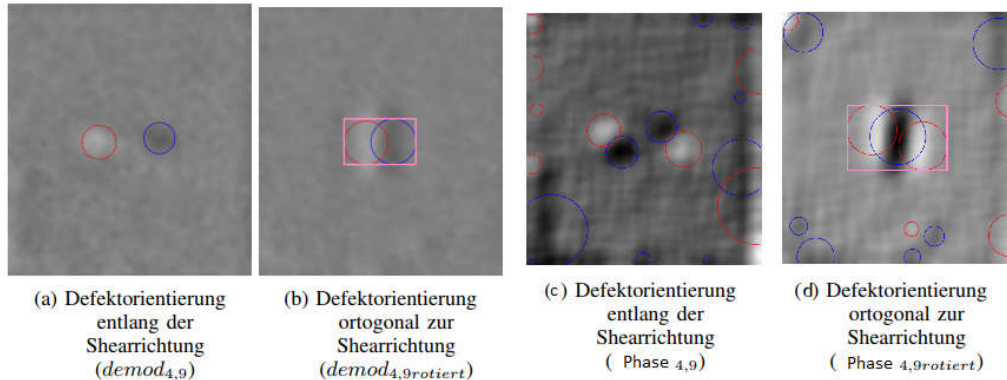


Fig 7 Auswirkung von räumlich orientieren Fehlstellen auf das Matching (rosa Quadrat) der Min- und Max-Blobs (blaue bzw. rote Kreise) in Abhängigkeit der Shearrichtung (Hier entlang der X-Achse)

8. Referenzen

- [1] D. C. Ghiglia and L. A. Romero, *Robust twodimensional weighted and unweighted phase unwrapping that uses fast transforms and iterative methods*, *J. Opt. Soc. Am. A*, vol. 11, no. 1, pp. 107–117, 1994. DOI: 10.1364/JOSAA.11.000107. Available: <http://josaa.osa.org/abstract.cfm?URI=josaa-11-1-107>
- [2] *2D Weighted Phase Unwrapping*, <https://de.mathworks.com/matlabcentral/fileexchange/60345-2d-weightedphase-unwrapping>, Accessed: 2020-09-18.
- [3] W. Buerakov, *Interferometrische Bauteilprüfung, Schadenserkenkung und Ermittlung der modalen Parameter mittels Belastung*, Shaker Verlag Aachen, M.S. thesis, Universität Saarbrücken, 2017.
- [4] H. Naumann, G. Schröder, and M. Löffler-Mang, *Handbuch Bauelemente der Optik, 7. Vollständig überarbeitete und erweiterte Auflage*. Hanser Verlag, München, 2014.
- [5] C. Ghiglia and D. Pritt, *Two-Dimensional Phase Unwrapping - Theory, Algorithms and Software*. John Wiley and Sons, Inc., 1998.
- [6] Jacquot and Fournier, *Interferometry in Speckle Light-Theory and Application*. Springer Verlag, 2000.
- [7] P. L. Rosin, H. Nyongesa, and A. W. Otieno, *Classification of delaminated composites using neuro-fuzzy image analysis*, 1999.
- [8] Y. Ye, K. Ma, H. Zhou, D. Arola, and D. Zhang, *An Automated Shearography System for Cylindrical Surface Inspection*, *Measurement*, vol. 135, Nov. 2018. DOI: 10.1016/j.measurement.2018.11.085.
- [9] M. D. Zeiler and R. Fergus, *Visualizing and Understanding Convolutional Networks*, <https://arxiv.org/abs/1311.2901>, 2013. eprint: 1311.2901.
- [10] C.-Y. Chang, K. Srinivasan, W.-C. Wang, G. Ganapathy, D. Vincent P M, and N. Deepa, *Quality Assessment of Tire Shearography Images via Ensemble Hybrid Faster Region-Based ConvNets*, *Electronics*, vol. 9, pp. 1–13, Dec. 2019. DOI: 10.3390/electronics9010045.
- [11] Y.-C. Wang, J.-C. Lin, and H.-Y. Yang, *Quantitative Post-Processing Module of Online Automatic Image Inspection for Inner Bubble Defects in a Tire*, *DEStech Transactions on Engineering and Technology Research*, May 2017. DOI: 10.12783/dtetr/imeia2016/9342.
- [12] Vandenrijt JF., Georges M. (2014) Automated Defect Detection Algorithm Applied to Shearography in Composites. In: Osten W. (eds) *Fringe 2013*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-36359-7_36
- [13] *Standard Practice for Shearography of Polymer Matrix Composites and Sandwich Core Materials in Aerospace Applications*, ASTM International, Standard, 2019.
- [14] Technikum für Optische Messtechnik, Gerätebau, Konstruktion und Bauteiloptimierung, <https://www.hochschule-trier.de/hauptcampus/technik/ogkb>, Accessed: 14.10.2020.
- [15] *Zerstörungsfreie Prüfung - Shearografie - Teil 1: Allgemeine Grundlagen*, Deutsches Institut für Normung e.V., Standard, 2015.
- [16] *OpenCV SimpleBlobDetector*, https://docs.opencv.org/3.4/d0/d7a/classcv_1_1SimpleBlobDetector.html Accessed: 14.10.2020.