

Fortschritte für die quantitative ZfP mit aktiver Thermografie durch neue Rekonstruktionsmethoden

David MÜLLER¹, Udo NETZELMANN², Sergey LUGIN², Bernd VALESKE^{1,2}

¹ htw saar, Saarbrücken

² Fraunhofer IZFP, Saarbrücken

Kontakt E-Mail: david.mueller@izfp-extern.fraunhofer.de

Kurzfassung. Die Rekonstruktion der Lage und Größe von inneren Fehlern und Strukturen in Werkstoffen aus zeitaufgelösten Thermografiedaten der Oberfläche ist eine Aufgabe, die im Vergleich zu anderen zerstörungsfreien Prüfverfahren bisher nur ansatzweise gelungen ist. Im höherdimensionalen Fall beschränken sich Rekonstruktionsversuche meist auf die gleichzeitige Bestimmung von Tiefenlage und Durchmesser von Flachbodenbohrungen bei bekannten Materialeigenschaften.

In dieser Arbeit wird ein neuer Ansatz für eine verbesserte Rekonstruktion von unbekannten Fehlern vorgestellt. Durch Einführung der „self-referencing relative contrast“ Methode, kann auf das erste *a-priori* Wissen des Referenzbereiches verzichtet werden. Weiterhin wurde ein einfaches neuronales Netzwerk zur Material Klassifizierung trainiert und erprobt. Ein wesentlicher Vorteil der Verfahren besteht darin, dass eine Reduzierung der zur Rekonstruktion benötigten *a-priori* Parameter durch die ergänzende Verwendung der angewandten Rekonstruktionsmethoden erreicht wird. Im Experiment wird die Blitzthermografie eingesetzt. Anwendungsperspektiven ergeben sich in der Rekonstruktion von unbekannten Fehlerarten vom Typ Risse, Korrosion und Pore/Lunker in zu prüfenden Bauteilen.

Einführung

Bei der Impulsthermografie handelt es sich um eine aktive thermografische Prüftechnik, die die schnelle Untersuchung von unbekannten Bauteilen ermöglicht. Mit herkömmlichen Blitzlampen wird mit einem kurzen Energieimpuls die Oberfläche des zu prüfenden Objektes angeregt. Die erzeugte thermische Energie breitet sich im Volumen aus, wechselwirkt mit verdeckten Fehlern und wird zum Teil reflektiert. Mittels einer Infrarotkamera lässt sich die Oberflächentemperaturverteilung des Bauteils digital abbilden. Die Erwärmung ermöglicht es, vorhandene Inhomogenitäten zu detektieren. Die damit verbundenen aufgenommenen thermischen Kontraste zeigen im Infrarotbild die im Bauteil vorhandenen Fehler und lassen in ihrer zeitlichen Entwicklung auch Rückschlüsse auf die Fehlertiefe und Fehlergeometrie zu. Die quantitative Rekonstruktion der Größe und Lage von inneren Fehlern und Strukturen in Werkstoffen aus den gemessenen zeitaufgelösten Thermografiedaten der Oberfläche ist bisher nur ansatzweise gelungen. Zerstörungsfreie Prüfverfahren wie der 3D-Ultraschall oder die 3D-Tomografie liefern im Gegensatz zu Verfahren der Thermografie sehr gute Rekonstruktionsergebnisse. Ursache für die bisher unzureichenden Rekonstruktionsversuche

ist das schlecht gestellte Inversionsproblem bei Diffusionsvorgängen. Aus mathematischer Sicht ist ein Problem $T = f(x)$ gut gestellt, wenn:

- für das Problem eine Lösung existiert
- diese Lösung eindeutig bestimmbar ist
- diese Lösung stetig von den Eingangsdaten abhängt

Ist eine der genannten Bedingungen nicht erfüllt, so wird das Problem als schlecht gestellt bezeichnet [1]. Das inverse Problem besteht also darin, aus den gemessenen zeitaufgelösten Thermografiedaten das entsprechend eindeutige Tiefenprofil zu rekonstruieren. Fehler erscheinen im Temperaturprofil durch Diffusionsvorgänge meist größer, als sie in Wirklichkeit sind.




Abb. 1. a) Darstellung eines planaren Fehlers mit flächiger Anregung und Energiestreuung, der eingebrachten Energie am Fehler. b) Wie durch das Temperaturlinienprofil verdeutlicht, verursachen Fehler eine inhomogene Temperaturverteilung an der Bauteiloberfläche und können nur unzureichend rekonstruiert werden.

Basierend auf der Theorie der eindimensionalen Wärmeleitung werden zum Rückschluss auf die Defektgeometrie direkte Methoden (Vorwärtsrechnung) verwendet. Diffusionsvorgänge, gestützt durch laterale Wärme Flüsse, können in direkten Verfahren nicht ohne weiteres berücksichtigt werden. Zudem ist das Wissen an *a priori* Informationen unabdinglich. Als *a priori* Wissen wird oft die Kenntnis über einen defektfreien Referenzbereich des zu prüfenden Bauteils sowie Informationen über die Materialzusammensetzung und Geometrie vorausgesetzt. Veröffentlichte inverse Verfahren sind meist durch Finite-Element Verfahren gestützt, welche weitere *a priori* Daten wie die Materialdicke und Informationen über die thermische Anregung benötigen [2,3]. Im Folgenden Abschnitt wird zunächst ein Überblick über die in der Literatur beschriebenen Verfahren gegeben.

1. Quantitative Rekonstruktionsmethoden in der aktiven Thermografie

Eindimensional betrachtet, lässt sich die thermische Reaktion eines Bauteils, verursacht durch einen kurzzeitigen Delta-Impuls, wie es praktisch durch die Blitzthermografie umgesetzt wird, wie folgt beschreiben:

$$T(z, t) = \frac{I_0}{\sqrt{\pi \rho c_p \kappa t}} e^{\left(-\frac{z^2}{4\alpha t}\right)} \quad (1)$$

T entspricht der Temperaturänderung des Bauteils zum Zeitpunkt t und ρ , c_p , κ sind die Dichte, spezifische Wärmekapazität und Wärmeleitfähigkeit des Festkörpers. $\alpha = \frac{\kappa}{\rho c_p}$ beschreibt die thermische Diffusivität des Körpers und I_0 den in die Oberfläche eingebrachten Energieimpuls. Die Bauteildicke oder die Tiefe eines vorhandenen Defektes wird mittels der Raumkoordinate z beschrieben [4,5]. Entwickelte Rekonstruktionsmethoden

haben gemeinsam, dass *a priori* Wissen die Grundlage jeder Rekonstruktion bildet. Als erstes *a priori* Wissen wird oftmals vorausgesetzt, dass die thermische Diffusivität α bekannt ist. Gleichzeitig wird auch die Kenntnis über einen defektfreien Referenzbereich benötigt. Als charakteristisches Merkmal weist die defektfreie Referenzzone eines homogenen Materials eine \sqrt{t} Zeitabhängigkeit der Oberflächentemperatur auf. An einer defektfreien Referenzzone mit der Temperatur T_0 gilt:

$$T_0(z = 0, t) = \frac{I_0}{\sqrt{\pi \rho c_p \kappa t}} \quad (2)$$

Sind die in einem Bauteil vorhandenen Fehler gegenüber der gesamt zu analysierenden Fläche des Bauteils klein, kann der defektfreie Bereich auch zeitaufgelöst aus dem Mittelwert aller Pixel berechnet werden. Alternativ kann als defektfreies Referenzgebiet auch der kühlsste Bereich des Thermogramms ausgewählt werden [6]. Dies lässt sich automatisiert rechnerisch bestimmen. Bei Betrachtung eines Defekts unterhalb der Bauteiloberfläche, müssen Reflektionen berücksichtigt werden. Der Defekt reflektiert und streut ankommende thermische Energie zurück zur Oberfläche. Unter Berücksichtigung von n Reflektionen lässt sich Gleichung 1 erweitern auf:

$$T(z, t) = \frac{I_0}{\sqrt{\pi \rho c_p \kappa t}} \cdot \left[1 + 2 \sum_{n=1}^{\infty} R^n e^{\left(-\frac{n^2 z^2}{\alpha t}\right)} \right] \quad (3)$$

$R = \frac{e_1 - e_2}{e_1 + e_2}$ ist der thermische Reflektionskoeffizient zwischen dem Bauteilmedium mit der Effusivität $e_1 = \sqrt{\rho_1 c_{p,1} \kappa_1}$ und des Defektmediums mit der Effusivität e_2 . n gibt die Anzahl der berücksichtigten Reflektionen an [4,5].

1.1 Rekonstruktion im Zeitbereich mit absolutem Kontrast

Zur quantitativen Defekttiefenrekonstruktion wurde erstmals von D.P. Almond et al. vorgeschlagen, den Zeitpunkt, zu dem der maximale thermische Kontrast zwischen einem defekten und einem vorher gewählten Referenzpunkt auftritt, bekannt als Peak Contrast, zu betrachten [5]. Der absolute Kontrast entspricht einer Temperatur $T(t)$ bezogen auf einen Referenzbereich $T_0(t)$. Er wird wie folgt berechnet:

$$K_A(t) = T(t) - T_0(t) \quad (4)$$

Veranschaulicht in Abb. 2 ist der absolute Kontrast. Der Zeitpunkt zum Maximum der Kurve wird als Peak Time und der Zeitpunkt der stärksten Steigung als Peak Slope Time bezeichnet.




Abb. 2. Eine typische absolute Kontrastkurve als Funktion der Zeit. Der Zeitpunkt zum Maximum der Kurve wird als Peak Time und der Zeitpunkt der stärksten Steigung als Peak Slope Time bezeichnet. Abbildung 2 in Anlehnung an [7].

Abbildung 2 legt nahe, dass grundsätzlich ein einfacher Zusammenhang zwischen dem maximalen absoluten Kontrast zum Zeitpunkt t_P Peak Time und der Defekttiefe z existieren könnte. Jedoch liefert dieser Parameter aufgrund der dreidimensionalen Wärmeverteilung nur bedingt eine quantitative Tiefeninformation. Durch das sehr späte Auftreten des maximalen Kontrastes, haben diffusionsbedingte laterale Wärmeströme bereits einen sehr großen Einfluss auf das Rekonstruktionsergebnis. Ein früherer Zeitpunkt, früh genug, um die beeinflussenden Auswirkungen der lateralen Wärmediffusion weitgehend zu unterdrücken, ist der Moment, in dem die thermische Kontrastkurve ihre maximale Steigung aufweist. Dieser Zeitpunkt wird als t_{PST} Peak Slope Time gekennzeichnet. Der Zeitpunkt der maximalen Steigung des Signals lässt sich durch die zweite zeitliche Ableitung des Temperatursignals ermitteln [8]. Ohne Berücksichtigung von multiplen Reflexionen kann anschließend die Defekttiefe angenähert werden:

$$z = \sqrt{2 \cdot \alpha \cdot t_{PST}} \quad (5)$$

1.2 Rekonstruktion im Zeitbereich mit relativem Kontrast

In einer weiteren Arbeit von D. Balageas et al. [9], wird angegeben, dass für eine verbesserte Rekonstruktion, vorzugsweise der Zeitpunkt betrachtet werden sollte, in welcher der relative thermische Kontrast eines zu analysierenden 1D-Signals aus dem Signalrauschen aufsteigt. Angenommen, die Referenztemperatur über einen fehlerfreien Referenzbereich ist gleich der Temperatur $T_0(t)$ der Probe an der Vorderseite und unter Berücksichtigung des relativen Temperaturanstiegs, kann der relative Kontrast $K_R(t)$ definiert werden durch:

$$K_R(t) = \frac{T(t) - T_0(t)}{T_0(t)} \quad (6)$$

Es ist anzunehmen, dass zu frühen Zeitpunkten laterale Diffusionsprozesse die thermischen Daten noch nicht übermäßig beeinflussen konnten und somit ein engerer Zusammenhang zwischen dem frühen Zeitereignis mit der lokalen Fehlertiefe besteht:

$$z = \sqrt{\alpha \cdot t_{K_r} \cdot \ln\left(\frac{200}{K_r(t_{K_r})}\right)} \quad (7)$$

Der Kontrastzeitpunkt, kurz nachdem das Signal aus dem thermischen Grundrauschen aufsteigt, wird mit t_{K_r} beschrieben und befindet sich auf zeitlicher Achse unmittelbar vor dem Zeitpunkt t_{PST} . Balageas et al. führen zusätzlich einen nicht weiter beschriebenen, d.h. gegebenenfalls experimentell ermittelten Korrekturfaktor ein [9].

Um eine verbesserte Rückrechnung auf die Rückwandgeometrie zu ermöglichen, wurde die Echo-Defect-Shape-Methode (EDS) mit iterativen Inversionsverfahren von S. Lugin et al. [2] in 2-D Version eingeführt und später von R. Richter [3] für 3-D Problemstellungen aufgegriffen und verbessert. Zur Herleitung der EDS wird die analytische 1D-Lösung für die Wärmeleitung für eine Probe mit semi-unendlicher Dicke berechnet. Hierzu wird angenommen, dass die zu analysierende Seite des Bauteils einer kurzzeitigen Delta-Impulsanregung ausgesetzt worden ist. In Bezug auf eine defektfreie Referenzfläche T_0 kann die Defekttiefe angenähert werden durch:

$$z = \sqrt{-\alpha \cdot t_{K_r} \cdot \ln(K_r(t_{K_r}))} \quad (8)$$

Exakt wie bei D. Balageas et al. wird wieder ein Schwellwert des Kontrasts THR (Threshold) eingeführt. Dieser dimensionslose Schwellwert wird oberhalb des Grundrauschens des Signals angesetzt, zu einer Zeit t_{THR} , wo der Fehlerkontrast noch weitgehend unbeeinflusst von lateralen Wärmequellen ist:

$$z = \sqrt{-\alpha \cdot t_{THR} \cdot \ln(THR)} \quad (9)$$

Der Schwellwert ist sowohl abhängig von der verwendeten Infrarotkamera als auch von Oberflächenreflektion und Emission des Probekörpers. Die 1D-Signale der Defekte müssen diesen Schwellwert für eine erfolgreiche Rekonstruktion überschreiten. Es ist möglich, dass das Grundrauschen experimenteller Daten bestimmte Referenzbereiche beeinflussen kann, sodass es abhängig vom Bauteil Abweichungen bei einer Probe geben kann. Um anschließend quantitative Informationen über die Fehlerüberdeckung zu erhalten und um laterale Diffusionsprozesse herauszurechnen, wird eine iterative Inversionsmethode angewendet. Hierzu wird im ersten Schritt die Defekttiefe mit festgelegtem relativem Kontrastschwellwert aus den Messdaten berechnet. Anschließend wird aus dem berechneten Defekttiefenprofil ein Finite-Element Methoden (FEM) Modell erstellt und der thermische Prozess simuliert. Aus jenem Simulationsergebnis wird nochmals das Defekttiefenprofil berechnet und anschließend mit dem Tiefenprofil der Messung verglichen. Bei guter Übereinstimmung wird das Ergebnis als Endergebnis übernommen. Bei schlechter Übereinstimmung wird die Geometrie angepasst und nochmals mittels FEM simuliert. Dies geschieht solange, bis ein Abbruchkriterium erreicht wird, was z.B. über den mittleren absoluten Fehler realisiert wird. Der vollständige Ablaufplan für den Inversionsprozess ist in Abbildung 3 gezeigt.

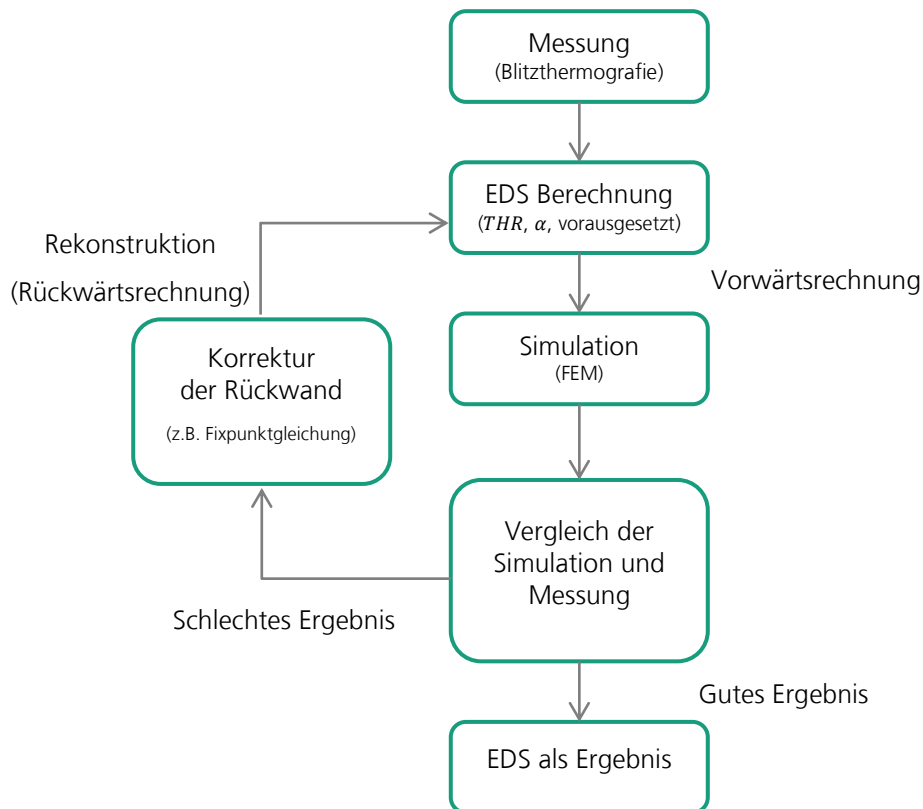


Abb. 3. Ablaufplan für den Inversionsprozess nach der Echo-Defect-Shape-Methode (EDS).
Abbildung in Anlehnung an [2,3].

Die Korrektur der Geometrie erfolgt über eine Fixpunktgleichung [2] oder wie von R. Richter gezeigt, über eine Rekonstruktion nach der Levenberg-Marquardt Methode [3]. Einschränkungen bestehen bei der iterativen Echo-Defect-Shape-Methode in der unzureichenden Rekonstruktion von Defekten mit komplexen Geometrien, wie z.B. nicht Oberflächen parallelen Fehlern, sowie hoher Rechenzeiten durch iterative FEM-Simulationen. Zusätzlich wird ein *a priori* Wissen vorausgesetzt, welches sowohl Materialdaten wie die thermische Diffusivität α , die Dicke der Probe, die Kenntnis über die fehlerfreie Zone der Probe sowie für die FEM gestützten Simulation die Anregungsleistung und Anregungszeiten umfasst [2,3].

1.3 Quantitative Defekttiefenrekonstruktion im Frequenzbereich

Ein weiterer Rekonstruktionsansatz bietet die Analyse des Temperaturverlaufes im Frequenzbereich. Mittels Pulsphasentransformationen werden die Daten in den Frequenzraum transformiert [4,6]. Aus dem komplexwertigen Transformationsergebnis können die zeitaufgelösten Thermografiedaten in eine Amplituden-Sequenz und in eine Phasen-Sequenz aufgeteilt werden. Die Phase ist von besonderem Interesse für die aktive Thermografie. Im Gegensatz zu den Rohdaten, ist die Phase weniger stark durch Umgebungsreflexionen, Emissionsgradschwankungen oder ungleichmäßige Erwärmung beeinflusst [10]. Der Phasenkontrast ($\Delta\varphi$) kann aus den Phasenprofilen berechnet werden. Hierzu wird ein absoluter Phasenkontrast $\Delta\varphi$ gebildet, indem an jeder Stelle des Bildes die Phase eines defektfreien Referenzbereichs abgezogen wird:

$$\Delta\varphi = \varphi_D - \varphi_{DF} \quad (10)$$

φ_D ist die Phase des Thermogramms und φ_{DF} ist die Phase des defektfreien Referenzbereiches. In Phasenkontrastbildern mit absoluten Kontrast Phasen $\Delta\varphi > 0$ und den Frequenzen $f_0 < f \leq f_b$ sind Gebiete, die Defekte enthalten, sichtbar. Hierbei ist die *Blind Frequency* f_b eben die Frequenz, für die ein Fehlerkontrast gerade noch sichtbar ist und bei der der absolute Phasenkontrast die Nullkontrastlinie durchschreitet. f_b ist korrelierbar mit der Defekttiefe. Fehler die näher zur Probeoberfläche liegen, haben eine größere Blindfrequenz, als Fehler die tiefer in der Probe liegen.




Abb. 4. Absolute Phasenkontrast mit *Blind Frequency* f_b

Zur Tiefeninversion kann die Gleichung zur Berechnung der thermischen Diffusionslänge herangezogen werden:

$$\mu = \sqrt{\frac{\alpha}{\pi \cdot f}} \quad (11)$$

Mit Einführung einer Korrekturkonstante C_1 kann nun die Defekttiefe ermittelt werden:

$$z = C_1 \cdot \sqrt{\frac{\alpha}{\pi \cdot f_b}} \quad (12)$$

C_1 ist konventionell materialabhängig. Experimentell ermittelt, liegen typische Werte zwischen 1.5 und 3 [6]. Immer vorhandenes Messrauschen sowie laterale Wärmeeinflüsse erschweren auch hier die Bestimmung des zur Rekonstruktion relevanten Parameters f_b zusätzlich.

1.4 Rekonstruktion unter Verwendung einer Punktbildverwaschungsfunktion

Mit Kenntnis einer Thermogramm-spezifischen Punktbildverwaschungsfunktion ist es möglich Diffusionsvorgänge herauszurechnen. Im mathematischen Sinne spricht man hier von Entfaltung (Dekonvolution). Ein vorhandener Defekt wird hierzu als planarer Energiestreuer modelliert. Die allgemeine Wärmeleitungsgleichung kann durch die Greensche Funktion in Verwendung mit Born-Approximation erster Ordnung und unter Ignorierung multipler Reflexionen gelöst werden [2]. Das Ergebnis an der Oberfläche für ein Bauteil mit einem Energiestreuer in Tiefe z ist gegeben durch:

$$\Delta T = T(r, t) - T_0(r, t)$$

$$= - \frac{1}{2\pi\sqrt{\pi\alpha t}} \frac{\partial}{\partial z} \left[\frac{\exp\left(-\frac{[\sqrt{x^2 + y^2 + z^2} + z]^2}{4\alpha t}\right)}{\sqrt{x^2 + y^2 + z^2}} * f(x', y') \right] \quad (13)$$

$$\text{mit} \quad T_0(r, t) = \frac{1}{\sqrt{\pi\alpha t}} \exp\left(-\frac{z^2}{4\alpha t}\right) \quad (14)$$

Im mathematischen Sinne handelt es sich um eine zweidimensionale Faltung zwischen der Punktbildverwaschungsfunktion und der Defektgeometrie $f(x, y)$. Die Funktion $f(x, y)$ stellt eine Schwellwertfunktion dar, die den Energiestreuerräumlich beschreibt. Zur Verbesserung des Signal-Rausch-Verhältnisses wird meist ein Wiener-Filter, um bei der Entfaltung den Einfluss von Rauschen zu minimieren, nach der Transformation in den Fourierraum angewandt. Für praktische Zwecke ist die beschriebene Funktion auf den Spezialfall von planare Defekte beschränkt. Zusätzlich wird zur Anwendung neben bereits erwähnten *a priori* Wissen, die Kenntnis über die lokale Defekttiefe vorausgesetzt [11].

Es ist zusätzlich wichtig darauf hinzuweisen, dass Rekonstruktionsergebnisse durch ungleichmäßige Verteilung der Anregungsenergie auf der Oberfläche des zu prüfenden Materials sowie durch einen eventuell vorhandenen ungleichmäßigen Oberflächenemissionsgrad und abhängig von der Oberflächenbeschaffenheit (Geometrie, Rauheit, Sauberkeit) immer beeinflusst werden können [12].

2. Erweiterte Rekonstruktionsmethoden

In diesem Abschnitt wird eine erweiterte Rekonstruktionsmethode zur automatischen Klassifizierung von Defekten und Bestimmung ihrer zweidimensionalen geometrischen Parameter erläutert. Durch Adaption der EDS-Methode, gestützt durch die in diesem Abschnitt eingeführte „self-referencing relative contrast“ Methode, werden Defekte einer Musterprobeplatte ohne Kenntnis des Referenzbereiches rekonstruiert. Die vorgestellte Rekonstruktionsmethode ist nicht wie die ursprüngliche EDS-Methode simulationsgestützt, um eine vereinfachte Modellvorstellung und die simulationsbedingte Vereinfachung physikalischer Abläufe zu vermeiden. Im konkreten Sinne handelt es sich um eine Vorwärtsrechnung. Experimentell erzeugte Daten sind für eine Rekonstruktion eine große Herausforderung, da immer vorhandene Umgebungseinflüsse eine Messung beeinflussen. Des Weiteren wird eine Methode zum Einsatz eines neuronalen Netzwerkes aufgezeigt, um Defekte ohne die direkte Kenntnis von Materialparametern zu rekonstruieren.

2.1 Rekonstruktion mit der „self-referencing relative contrast“ Methode

Für den experimentellen Test des Rekonstruktionsverfahrens wurde eine 5 mm dicke graue Hart-PVC Platte mit unterschiedlich tief eingesenkten Buchstaben in Form von eckigen Rückwandnuten angefertigt. Die Zeichnung der Probe, mit den Angaben über die Defekttiefen, ist in Abbildung 5 gezeigt. Jede der Rückwandnuten hat eine Breite von 5 mm. Zur Verbesserung der Oberflächenemissivität wurde eine dünne Schicht schwarzer Lack aufgetragen. Die thermische Diffusivität der Probeplatte wurde für die Rekonstruktion zu $\alpha_{PVC} = 0,07 \cdot 10^{-6} \frac{m^2}{s}$ angenommen.




Abb. 5. IZFP PVC-Probeplatte mit unterschiedlich tief eingesenkten Buchstaben in Form von Rückwandnuten. Die Probeplatte hat eine Dicke von 5 mm. Jede der Nuten ist 5 mm breit.

Mittels eines Ringblitzes mit einer Leistung von 3,5 kJ wurde die Probeplatte thermisch durch einen kurzen Lichtimpuls angeregt. Die Datenaufnahme erfolgte mit einer 14-bit Thermosensorik QWIP 384 Dualband Kamera, mit einer Auflösung von 384 x 288 Pixel. Die Temperaturempfindlichkeit (Noise Equivalent Temperature Difference: NETD) der Kamera ist im mittleren Infrarot Bereich (4,4 – 5,2 μm) kleiner 25 mK. Die Aufnahmedauer der Sequenz betrug 20 s bei einer Abtastrate von 146 Hz. Um Inhomogenitäten die durch ungleichmäßige Lichtanregung verursacht wurden auszugleichen, wurden die Zeitmomente vor der thermischen Anregung abgeschnitten und das gesamte Signal durch den Mittelwert dieser dividiert. Zur Bad-Pixel-Reduktion wurde die gesamte Sequenz zusätzlich mit einem 3x3 Median Filter geglättet. Immer im Signal enthaltenes Grundrauschen wurde durch die TSR-Methode nach Shepard et al. weitgehend eliminiert [13]. Dazu werden die experimentellen Daten durch ein logarithmisches Polynom angefitet:

$$T(t) = \exp[a_0 + a_1[\ln(t)]] + a_2[\ln(t)]^2 \dots + a_n[\ln(t)]^n \quad (15)$$

Ein Polynom 7ten-Grades hat sich in diesem Schritt als besonders geeignet herausgestellt. Im Sinne der automatischen Fehlerdetektion, wurde ein “Automatic Segmentation” Algorithmus verwendet, welcher die Positionen von maximalen Fehlerkontrasten automatisch markiert [4]. Nachdem ein sogenannter Hot Spot, welcher den stärksten lokalen Temperaturkontrast darstellt, gefunden wurde, evaluiert der Algorithmus, ob sich in einem festgelegten Abstand „*minimum distance*“ (MND) ein größerer Hot Spot befindet. Konnte kein größerer Hot Spot gefunden werden, wird der bereits gefundene Wert als Hot Spot abgespeichert. Wird jedoch ein größerer Hot Spot als der bereits gefundene entdeckt, wird eben dieser als neuer Hot Spot festgelegt. Abbildung 6 zeigt schematisch die Detektion von zwei Hot Spots mit Abstand MND.




Abb. 6. Prinzip des “Automatic Segmentation Algorithmus”. Abbildung 6 in Anlehnung an [1].

Für eine erfolgreiche Anwendung des Algorithmus müssen vorher Bad-Pixel entfernt werden, andernfalls könnten diese als Hot Spots fehlklassifiziert werden. Weiterhin muss vorher festgelegt werden, wie viele Hot Spots maximal enthalten sind [4].




Abb. 7. Probeplatte mit unterschiedlich tief eingesenkten Buchstaben in Form von Rückwandnuten. Links: Zweidimensionales Defektbild bei $t \approx 14$ s mit den gefundenen Defekthotspots: 1-9. Mitte: Dreidimensionale Darstellung, zur Verdeutlichung des Diffusioneffektes. Rechts: Linienplot bei $y = 150$, entlang der x-Achse, laterale Wärmefflüsse haben die Defektgeometrie deutlich beeinflusst.

Abbildung 7 zeigt das bereits durch den Medianfilter geglättete und durch die TSR-Methode entrauschte Thermogramm zum Zeitpunkt $t \approx 14$ s. Im Linienplot, gezeichnet bei $y = 150$, entlang der x-Achse, ist zusehen, dass laterale Wärmefflüsse bereits das Profil der Defektgeometrie verzerrt haben. Weiterhin ist ersichtlich, dass das gesamte dreidimensionale Thermogramm gekrümmt erscheint. Diese Inhomogenität ist durch bei experimentellen Messungen nie zu vermeidende ungleichmäßige thermische Anregung zu begründen. Es ist unrealistisch, eine komplett homogen ausgeleuchtete Messung durchzuführen. Die inhomogene Energieverteilung kann nachträglich rechnerisch korrigiert werden. Omar et al. führten hierzu die *Self-Referencing Thermography* ein [14]. Das Grundprinzip der selbstreferenzierenden Technik besteht darin, das Thermogrammbild in kleine *local neighborhoods* zu unterteilen und vom gesamten Thermogramm abzuziehen. Die von Omar et al. vorgestellte Gleichung zur Berechnung eines *self-referencing absolute contrast* ($K_{A,Omar}(t) = T(i,j,t) - T_{avg(i,j)}(t)$), wurde in dieser Arbeit zur Berechnung des *self-referencing relative contrast* erweitert:

$$K_{R,SR}(t) = \frac{T(i,j,t) - T_{avg(i,j)}(t)}{T_{avg(i,j)}(t)} \quad (16)$$

Dabei ist $T(i, j, t)$ die Temperatur eines Pixels an der entsprechenden i, j -Koordinate und $T_{avg(i,j)}(t)$ die Durchschnittstemperatur. $T_{avg(i,j)}(t)$ entspricht einer pixelabhängigen dynamischen Referenzzone. Definiert wird diese Referenzzone aus den jeweils um ein Pixel (i, j) umliegenden Pixel im definierten Kernel der Größe $[m, n]$. Die Größe der „local neighborhood“ wurde in dieser Arbeit mit einem Kernel von 20x20 Pixel gewählt. Mit diesem Schritt erübrigt sich das *a priori* Wissen über eine defektfreie Referenzfläche.




Abb. 8. Self-referencing relative contrast für die detektierten Defekthotspots in Abb.7. Links: $K_{R,SR}(t)$ über die komplette Zeitdauer. Rechts: $K_{R,SR}(t)$ für die ersten Zeitmomente bis 1 s. Das anfänglich beschriebene Grundrauschen ist bis etwa 0,5 s zu sehen. Mittels der Kurvenschar kann der Rekonstruktions-Schwellwert mit $THR = 0,025$ über dem Rauschen festgelegt werden.

Abbildung 8 zeigt die *self-referencing relative contrast* -Kurven $K_{R,SR}(t)$ für die ermittelten Defektpunkte. Links dargestellt sind die Kurven über die komplette aufgenommene Sequenz. Rechts ist ein Ausschnitt der Sequenz bis zur ersten Sekunde gezeigt. Deutlich zu sehen ist das um die Nullachse schwingende Grundrauschen. Für die Rekonstruktion wurde daher ein Rekonstruktions-Threshold über dem ermittelten Grundrauschen von $THR = 0,025$ festgelegt. Mittels des detektierten Rekonstruktions-Threshold THR kann anschließend für jeden Pixel (i, j) der Zeitpunkt t_{THR} ermittelt werden, bei dem gilt: $K_{R,SR}(t) \cong THR$. Durch diesen Schritt wird die vormals dreidimensionale Thermogrammsequenz auf ein zweidimensionales Thermogramm, welches aus den individuellen pixelspezifischen Zeitpunkten t_{THR} besteht, reduziert (Abbildung 9).




Abb. 9. Gezeigt ist das Thermogramm, welches aus den individuellen pixelspezifischen Zeitpunkten t_{THR} besteht. Im Linienplot, gekennzeichnet mit Rot, sind die durch Diffusionsvorgänge beeinflussten Geometrieplateaus der einzelnen Buchstaben. An den Kanten verursachte Überschätzungen der Geometrie sind mit Grün gekennzeichnet. Des Weiteren ist, wie im mittleren Bild zu sehen, ein rekonstruktionsbedingtes Rauschen enthalten.

Eine anschließende gradientenbasierte Kantendetektion mit Sobel-Operator, ermöglicht eine deutlichere Unterscheidung zwischen wahren Defektkanten und diffusionsbedingter Fehlerüberschätzung. Mit Kenntnis der Fehlerpositionen, wurde zur Minimierung der Diffusionseinflüsse, für jeden Fehler, um den Bereich des jeweiligen Defektmittelpunktes, ein defektspezifischer Schwellwert berechnet. Dazu wird im Gradientenmagnitudenbild die gewichtete Summe der umliegenden 3x3 Nachbarpixel Pixel berücksichtigt. Ein gesamtes Binärbild, bestehend aus der Superposition der einzelnen fehlerspezifischen Schwellwertbilder, visualisiert das neue Fehlerbild (Abbildung 10).

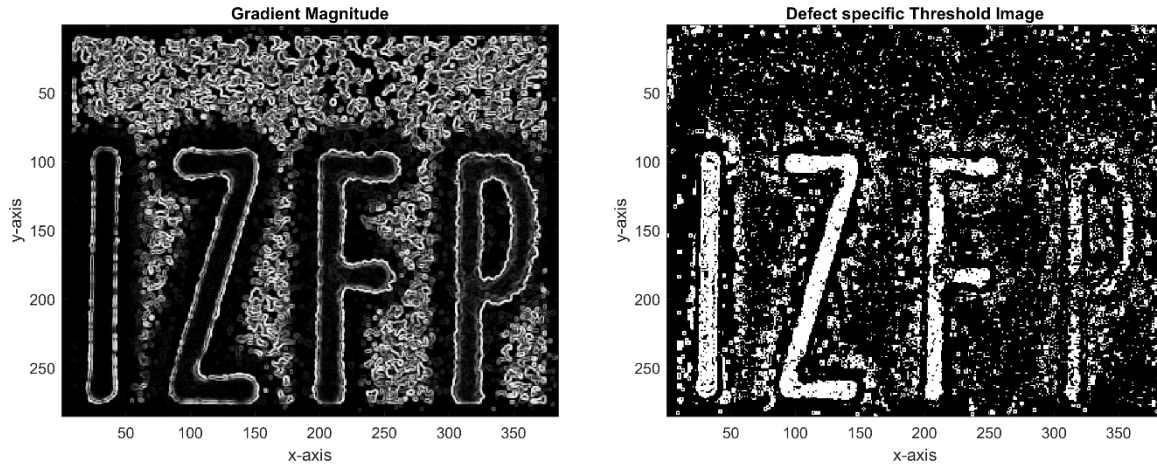


Abb. 10. Links: gradientenbasierte Kantendetektion mit Sobel-Operator. Die Kanten der einzelnen Fehler sind deutlich hervorgehoben. Rechts: Das gesamte Schwellwertbild, bestehend aus der Superposition der einzelnen fehlerspezifischen Schwellwertbilder.

Mit Gleichung 9 erfolgt abschließend die Umrechnung der Zeitmomente t_{THR} in die Defekttiefen.




Abb. 11. Das Rekonstruktionsergebnis: Diffusionsbedingte Geometrieüberschätzungen wurden durch die gradientenbasierte Kantendetektion mit Sobel-Operator und anschließender Schwellwertberechnung herausgerechnet. Die Zeitmomente t_{THR} wurden mittels Gleichung 9 in Defekttiefen umgerechnet. Das noch in Abbildung 9 zusehende Rauschen wurde herausgerechnet. Das Liniendiagramm zeigt deutlich die ursprünglichen Geometrieprofile.

Abbildung 11 zeigt das Rekonstruktionsergebnis. Diffusionsbedingte Geometrieüberschätzungen wurden durch die gradientenbasierte Kantendetektion mit Sobel-Operator und anschließender Schwellwertberechnung herausgerechnet. Das Liniendiagramm zeigt deutlich die rekonstruierten Geometrien. Die berechneten Defekttiefen entsprechen mit einer durchschnittlichen Abweichung von 0,1 mm der Originalgeometrie. Für den am tiefsten liegenden Buchstaben „P“ sind aufgrund des zeitlich späteren Auftretens der Defektkontraste

und durch stärkere laterale Wärmeeinflüsse, die Abweichungen zur Originalgeometrie am größten.

2.2 Rekonstruktion mit einem einfachen neuronalen Netzwerk

Nachdem gezeigt wurde, dass eine Defekttiefen-Rekonstruktion mittels der „self-referencing relative contrast“ Methode möglich ist und dass auf ein Kenntnis der defektfreien Referenzzone als erstes *a priori* Wissen verzichtet werden kann, wird nachfolgend eine Möglichkeit gezeigt, um zusätzlich das Kenntnis über die Materialparameter zu umgehen. Dazu wird ein neuronales Netzwerk mit vier verschiedenen Materialien trainiert, um anschließend eine unbekannte Probe klassifizieren zu können. Der relative Kontrast lässt sich mit der Berücksichtigung von multiplen Reflexionen zwischen Oberfläche und verborgenen Fehler wie folgt berechnen:

$$K_R(t) = \frac{T(t) - T_0(t)}{T_0(t)} = \frac{\frac{I_0}{\sqrt{\pi \rho c_p \kappa t}} \cdot \left[1 + 2 \sum_{n=1}^{\infty} R^n e^{\left(-\frac{n^2 z^2}{at}\right)} \right] - \frac{I_0}{\sqrt{\pi \rho c_p \kappa t}}}{\frac{I_0}{\sqrt{\pi \rho c_p \kappa t}}} \quad (17)$$

$$= 2 \sum_{n=1}^{\infty} R^n e^{\left(-\frac{n^2 z^2}{at}\right)}$$

Ohne die Berücksichtigung von Folgereflexionen (nur $n = 1$) und Totalreflexion am Fehler ($R = 1$) reduziert sich die Gleichung auf:

$$K_R(t) = \frac{T(t) - T_0(t)}{T_0(t)} = e^{\left(-\frac{z^2}{at}\right)} \quad (18)$$

$K_R(t)$ kann für n unterschiedliche Materialien, mit n unterschiedliche α -Werten, über ein festgelegtes Zeitintervall $t_0 < t \leq t_{end}$ und Defekttiefenintervall $z_0 < z \leq z_{max}$ berechnet werden. Dadurch ergibt sich für jedes Material eine Kurvenschar von relativen Kontrastkurven, mit denen ein neuronales Netzwerk trainiert werden kann. Nachfolgend sind im Zeitintervall $0 < t \leq 10 \text{ s}$ und im defekttiefen Intervall $0 < z \leq 1,5 \text{ mm}$ die theoretischen relativen Kontrastkurven für die Materialien PVC ($\alpha_{PVC} = 0,07 \cdot 10^{-6} \frac{\text{m}^2}{\text{s}}$) und rostfreien Stahl ($\alpha_{Stahl} = 7,2 \cdot 10^{-6} \frac{\text{m}^2}{\text{s}}$) zur Visualisierung gezeigt. Zusätzlich wurde der Schnittpunkt $K_R(t) \cong THR$ mit dem schon bekannten Schwellwert von $THR = 0,025$ für jede Kurve gesucht und anschließend die entsprechenden Zeitmomente t_{THR} über die Defekttiefe im Intervall $0 < z \leq 1,5 \text{ mm}$ aufgetragen (Abbildung 12).

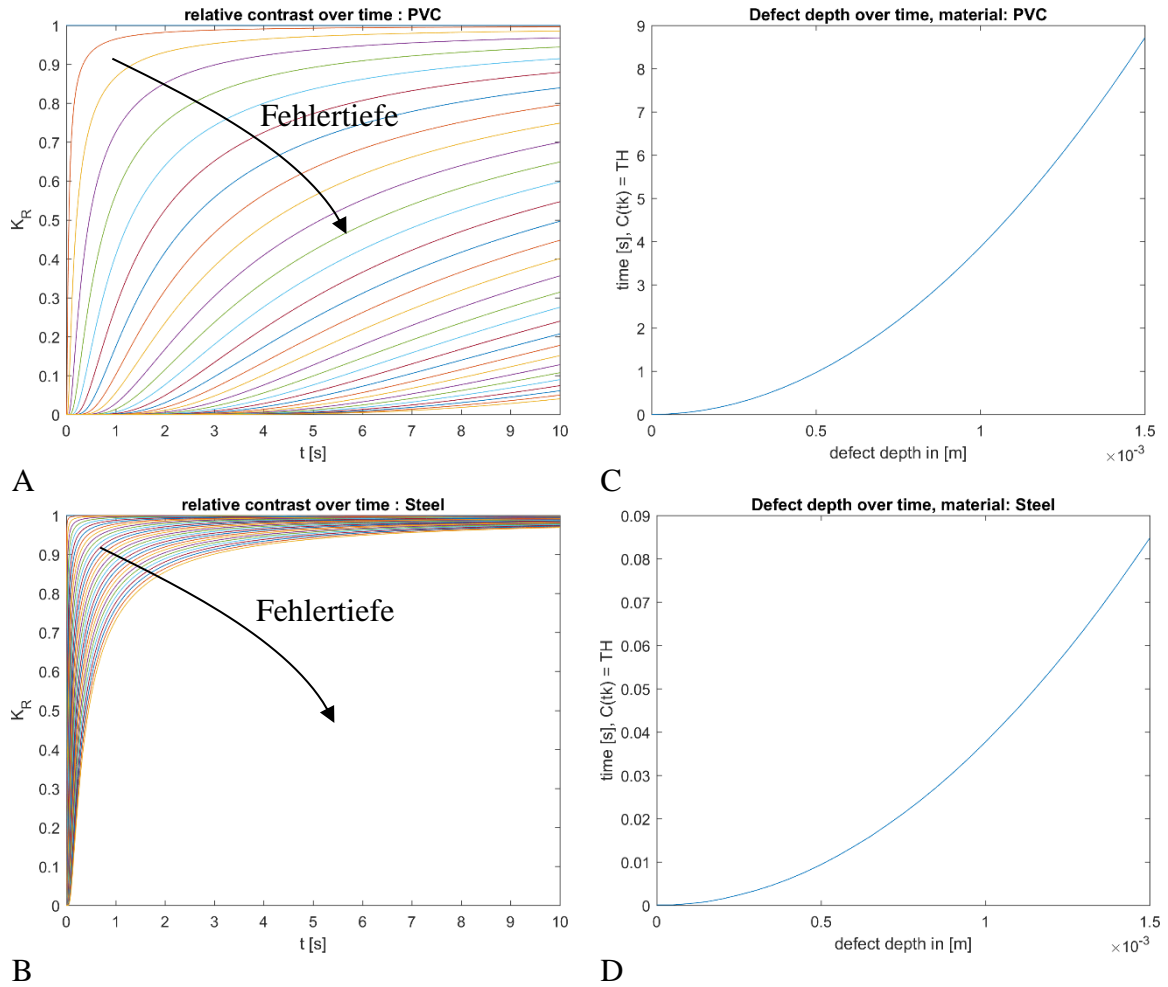


Abb. 12. Relative Kontrastkurven für die Materialien PVC (A) und Stainless Steel (B). Bild C-D zeigen für die einzelnen Materialien die Kurven t_{THR} aufgetragen über die Defekttiefe im Intervall $0 < z \leq 1,5 \text{ mm}$.

Die gezeigten t_{THR} Kurven aus Abbildung 12 können nun einem einfachen neuronalen Netzwerk trainiert werden. Zusätzlich wurden dem Netzwerk noch die in Abbildung 12 nicht gezeigten Materialien Aluminium und Luft trainiert. Das trainierte Netzwerk dient dazu, berechnete Zeitmomente, wie sie z.B. in Abbildung 9 gezeigt sind, anhand der gelernten Kurven einem Material richtig zuzuordnen. Für das Training des neuronalen Netzwerks wurden die Materialien in vier Klassifizierungsintervalle unterteilt (Tabelle 1).

Tabelle 1. Dem neuronalen Netzwerk trainierte Materialien mit entsprechenden Klassifizierungsintervallen.

| Material | Klassifizierungsintervall |
|--|----------------------------|
| $\alpha_{Luft} = 22,3 \cdot 10^{-6} \frac{m^2}{s}$ | ≤ 10 |
| $\alpha_{PVC} = 0,07 \cdot 10^{-6} \frac{m^2}{s}$ | $> 10 \text{ \& } \leq 20$ |
| $\alpha_{Alu} = 96,8 \cdot 10^{-6} \frac{m^2}{s}$ | $> 20 \text{ \& } \leq 30$ |
| $\alpha_{Stahl} = 7,2 \cdot 10^{-6} \frac{m^2}{s}$ | > 30 |

Der Trainingsdatensatz wird nach dem Zufallsprinzip in Trainings- (80%), Validierungs- (10%) und Testdaten (10%) aufgeteilt. Der Hidden Layer wurde auf eine Größe von 20 Neuronen festgelegt. Das neuronale Netzwerk wird solange trainiert und

getestet, bis der mittlere quadratische Fehler auf ein Minimum reduziert wurde. Die Algorithmen für diese Verfahren stammen von der MATLAB Neural Network Toolbox 2016b genutzt. Jeder Bildpixel, welcher einem Zeitpunkt t_{THR} entspricht, wurde nach Tabelle 1 durch das neuronale Netz einer Materialgruppe zugeordnet.




Abb. 13. a.) Klassifizierung Ergebnis des neuronalen Netzwerks. 53,3 % der Pixel wurden richtig als PVC (13b. graue Farbwerte) klassifiziert. Vorhandenes Rauschen wurde als Aluminium und Stahl fehlklassifiziert (13b. weiße Farbwerte).

Abbildung 13 zeigt das Klassifikationsergebnis des neuronalen Netzwerks. Jeder Bildpixel (i, j) , welcher einem Zeitpunkt t_{THR} entspricht, wurde einem Klassifizierungsintervall zugeordnet. Der Datensatz der IZFP-Probeplatte konnte zu 53,3 % dem Material PVC richtig zugeordnet werden (graue Farbwerte in Abb. 13 b.). Pixel, die bereits durch die Schwellwertberechnung herausgerechnet wurden, wurden in der prozentualen Berechnung nicht betrachtet (schwarze Farbwerte in Abb. 13b).

3. Anwendungsgebiete

Anwendungsperspektiven ergeben sich in der Rekonstruktion von unbekannten Fehlerarten vom Typ Risse, Korrosion und Pore/Lunker in zu prüfenden Bauteilen. Unternehmen können sich zukünftig auf die Verwendung eines schnelllernenden Rekonstruktionsverfahrens berufen, das durch seine Automatisierbarkeit hohes Potenzial für eine verbesserte Fehlercharakterisierung zulässt.

4. Zusammenfassung

Der aktuelle Stand der Technik sowie zwei neue Ansätze für die quantitative ZFP mit aktiver Thermografie durch neue und erweiterte Rekonstruktionsmethoden wurden vorgestellt. Hierzu wurde ein neuer Ansatz zur Detektion von Fehlern durch die „self-referencing relative contrast“ Methode experimentell untersucht. Des Weiteren wurde eine Methode vorgestellt, um eine unbekannte Probe mit Hilfe eines neuronalen Netzes einem Material zuzuordnen. Zusammenfassend stellen beide Verfahren einen Fortschritt für die Rekonstruktion von Bauteilen mit unbekannten Materialparametern und unbekannten Defekttiefen dar.

Danksagung

Wir bedanken uns für die Förderung eines Teils der Arbeit durch den Europäischen Fonds für regionale Entwicklung (EFRE). Das Projekt wird unter der Projektbezeichnung „Monitoring von sicherheitskritischen Leichtbaukomponenten“ geführt.



EUROPÄISCHE UNION

Europäischer Fonds für
regionale Entwicklung

Referenzen

- [1] A. K. Louis, Inverse und schlecht gestellte Probleme. Stuttgart, B. G. Teubner 1989
- [2] S. Lugin and U. Netzelmann, A defect shape reconstruction algorithm for pulsed thermography. NDT&E International, 40:220-228, 2007
- [3] R. Richter, Numerisches Verfahren für die aktive Thermografie zur Untersuchung von Rückwandgeometrien, Dissertation, TU Braunschweig, 2013
- [4] K X. Maldague, Theory and Practice of Infrared Technology for Non-Destructive Testing. John Wiley & Sons, 2001.S. 171-186
- [5] S.K. Lau, D.P. Almond and J.M. Milne, A quantitative analysis of pulsed video thermography. NDT E Int. 1991, 24, 195–202
- [6] K C. Ibarra-Castanedo, Quantitative subsurface defect evaluation by pulsed phase thermography: Depth retrieval with the phase. PhD thesis, Université Laval, Québec, 2005.
- [7] X. Han, L.D. Favro, P.K. Kuo and R.L. Thomas, Early-time pulse-echo thermal wave imaging. Department of Physics and Institute for Manufacturing Research Wayne State University, Detroit
- [8] Z. Zeng, J. Zhou, N. Tao, L. Feng, C. Zhang, Absolute peak slope time based thickness measurement using pulsed thermography. Infrared Physics & Technology. 55. 200–204. 10.1016/j.infrared.2012.01.005.
- [9] D. Balageas, J.C. Krapez, L. Legrandjacques, F. Lepoutre and H. Petry, Industrial applications of infrared thermography. CP463, Photoacoustic and Photothermal Phenomena: 10th International Conference edited by F.Scudieri and M. Betrolotti (357-361) Roma (Italy), August 23 -27, 1998.
- [10] G. Busse, and A. Rosencwaig, “Subsurface Imaging with Photoacoustics,” Appl. Phys. Lett., 36(10):815-816(1980).
- [11] R. L. Thomas, L. D. Favro, D. J. Crowther, and P. K. Kuo, Inversion of thermal wave infrared images. In Proceedings of the Eurotherm Seminar n°27, Quantitative infrared thermography QIRT 92, D. Balageas, G.Busse and G.M. Carlomagno (Ed.), 1992.
- [12] H.G. Walther, Surface roughness influence on photothermal radiometry, Applied Surface Science 193 (1–4) (2002) 156–166.
- [13] S. Shepard, A. Taymur and B.A. Rubadeux, D.Wang, J.R. Lhota, (2001). Synthetic processing of pulsed thermographic data for inspection of turbine components. Insight: Non-Destructive Testing and Condition Monitoring. 43. 587-589.
- [14] M. Omar, M.I. Hassan, K. Saito, and R. Alloo, IR self-referencing thermography for detection. Infrared Physics & Technology, 46:283289, 2005.