

# Materialidentifikation von schwarzen Kunststoffen mittels aktiver Thermographie

Kevin SCHMITZ<sup>1</sup>, Nina SHPAKOVA<sup>1</sup>, Andreas KELLER<sup>1</sup>, Udo NETZELMANN<sup>1</sup>  
<sup>1</sup> Fraunhofer Institut für zerstörungsfreie Prüfverfahren IZFP, Saarbrücken, Deutschland,  
kevin.schmitz@izfp.fraunhofer.de

**Kurzfassung.** Nachhaltigkeit ist eines der wichtigsten Ziele der heutigen Gesellschaft, mit erheblichem Einfluss auf wirtschaftliche und politische Entscheidungen. Eine wichtige Initiative in dem europäischen Green Deal, der eine Strategie für Nachhaltigkeit darstellt, ist der Aktionsplan für die Kreislaufwirtschaft (CEAP). Ziel ist es, den ökologischen Fußabdruck der EU zu reduzieren und die Verwendung von Recyclingmaterialien in den nächsten zehn Jahren zu verdoppeln. Konkrete Maßnahmen wurden in verschiedenen Bereichen wie Elektronik, Verpackungen, Kunststoffe und Textilien eingeleitet.

Ein wichtiges Segment einer Kreislaufwirtschaft ist die Sortierung und das Recycling von Materialien. Um die Qualität des Recyclings zu steigern, sind Verbesserungen in der Abfallsammlung und -sortierung erforderlich. Die derzeit auf dem Markt erhältlichen Sensorsysteme für die Sortierung von Kunststoffen in der Abfallwirtschaft basieren hauptsächlich auf Nah-Infrarot (NIR) und Kurzwellen-Infrarot (SWIR). Die Sortierung schwarzer Kunststoffe, einschließlich solcher aus dem Automobilssektor, bleibt für diese Systeme jedoch eine Herausforderung.

Im vorliegenden Beitrag werden die Ergebnisse des Fraunhofer-Leitprojektes Waste4Future vorgestellt, in dem ein aktives Thermographie-System entwickelt wurde, um verschiedene Kunststoffmaterialien zu unterscheiden. Dieses System wurde erfolgreich verwendet, um schwarze Kunststoffe auf einem Förderband zu klassifizieren. Die Analyse der Abkühlungskurven der Proben ermöglichte aufgrund unterschiedlicher Erwärmungs- und Abkühlungscharakteristika die Unterscheidung der Materialien. Mit der Verwendung maschineller Lernalgorithmen konnte ein pixelweiser f1-Score von über 98,2 % unter Verwendung von drei ganzen Proben je Material als Testdaten erzielt werden.

Die Erkenntnisse aus der aktiven Thermographie eröffnen vielversprechende Möglichkeiten für die Integration in die aktuelle Sensorik zur Sortierung schwarzer Kunststoffe, ein wichtiger Schritt in Richtung einer nachhaltigeren Kreislaufwirtschaft.

**Keywords:** Maschinelles Lernen, Recycling, Sortierung schwarze Kunststoffe, Thermographie, Kreislaufwirtschaft



## 1. Einleitung

In der heutigen Zeit spielen die Abschwächung des Klimawandels, die Schonung natürlicher Ressourcen sowie die Thematik der Nachhaltigkeit eine immer größere Rolle in allen Bereichen des Lebens und der Technik. Im Rahmen dieser Herausforderungen hat die EU den sog. „European Green Deal“ auf den Weg gebracht, in dessen Rahmen ein Aktionsplan für die Kreislaufwirtschaft (CEAP) [1] aufgestellt wurde. Durch dieses Strukturprogramm soll die Nutzung von Rezyklaten innerhalb von 10 Jahren verdoppelt werden, mit dem Ziel der Reduktion des ökologischen Fußabdrucks der gesamten EU. Dabei ist die Materialgruppe der Polymere aufgrund ihrer Allgegenwärtigkeit von hohem Interesse.

Zur Erreichung der Ziele des European Green Deal müssen im Rahmen der Kreislaufwirtschaft die in den Bereichen Sortierung und Recycling von Materialien vorhandenen Potentiale ausgeschöpft werden. Hierzu zählen Verbesserungen in der Abfallsammlung und -sortierung, welche eine Qualitätssteigerung des Rezyklats ermöglichen. Nach derzeitigem Stand der Technik stellen Nahinfrarot (NIR) und Kurzwelleninfrarot (SWIR) den Standard in der Polymersortierung dar [2]. Mittels dieser Technologien ist eine schnelle und präzise Bestimmung der meisten geläufigen Polymere möglich. Die Sortierung schwarzer Kunststoffe, unter anderem aus dem Automobilsektor, stellt jedoch weiterhin eine große Herausforderung dar [3, 4].

Um eine Unterscheidung verschiedener Kunststoffmaterialien mit mehr als nur dem Stand der Technik zu ermöglichen, wurde im Rahmen des Fraunhofer Leitprojekts »Waste4Future« [5] ein aktives thermographisches System entwickelt.

Teile dieser Arbeit wurden bereits in der „Sensorbased Sorting and Control 2024“ veröffentlicht [6] und für diese Konferenz angepasst und erweitert, um unterschiedliche Aspekte hervorzuheben.

## 2. Thermographie

Die Infrarotthermographie misst im Spektralbereich von etwa 2 - 15  $\mu\text{m}$  Wellenlänge die thermischen Emissionen infraroter Strahlung. Diese sind abhängig vom Planckschen Strahlungsgesetz. Dabei ist neben der Temperatur der betrachteten Objekte vor allem die Emissivität wichtig. Die Reflektivität hingegen spielt im Gegensatz zur NIR-Spektroskopie nur eine untergeordnete Rolle. Schwarze Polymere absorbieren sichtbares und nahinfrarotes Licht sehr gut und wandeln es energieeffizient in Wärme und somit thermische Strahlung um. Diese Eigenschaft macht man sich mit der aktiven Thermographie zunutze, bei der ein kurzzeitiger Aufheizimpuls eine Probe über ihre anfängliche Temperatur hinaus erwärmt. Dies kann beispielsweise durch eine starke Lichtquelle oder einen IR-Heizstrahler erfolgen. Der Wärmeeintrag findet dabei an der Oberfläche des Materials statt und steigert die Emission infraroter Strahlung von der Oberfläche weg, zudem resultiert daraus ein Wärmefluss ins Volumen. Dieser Wärmefluss ist materialspezifisch abhängig von thermischer Leitfähigkeit, Dichte und spezifischer Wärmekapazität. Weiterhin ist zu beachten, dass die meisten Polymere im Infraroten semitransparent sind, d.h. die emittierte Wärmestrahlung stammt sowohl von der Oberfläche als auch aus dem Volumen. Die meisten Informationen können jedoch bei einer nur oberflächlichen Erwärmung der Probenkörper gewonnen werden [7], weshalb die Aufnahme der Messdaten kurz nach dem optischen Aufheizen erfolgt, bevor sich die Probenkörper im Volumen erwärmen. Daher muss die Zeitabhängigkeit der thermischen Infrarotstrahlung immer mit beachtet werden.

Indem die Effekte der thermischen Diffusion, optischen Absorption sowie die Emission thermischer Strahlung kombiniert betrachtet werden, sollte eine Unterscheidung verschiedener Polymere möglich sein.

### 3. Versuchsaufbau

Ein durchdachter Versuchsaufbau ist von entscheidender Bedeutung für neue Messverfahren. Er ermöglicht präzise und stabile Messungen, indem er die systematische Kontrolle von Variablen und die Minimierung von Störfaktoren erlaubt. Ein solcher Ansatz fördert die Reproduzierbarkeit und ermöglicht die Identifizierung der tatsächlichen kausalen Abhängigkeiten der zu messenden Effekte auf die Messdaten. Durch die Aufrechterhaltung fester Positionen und Bandgeschwindigkeiten werden einheitliche Rahmenbedingungen für die Messungen sichergestellt. Um die materialabhängigen Effekte unterschiedlicher Kunststoffe erfassen zu können, wurde die Infrarot-Kamera FLIR A35 gewählt, da ihre Spezifikationen für den gewählten Versuchsaufbau passend waren. Ein Überblick der technischen Daten der FLIR A35 Kamera ist in Tabelle 1 dargestellt.

<b>Kameratyp</b>	Focal Plane Array, ungekühltes VOX-Mikrobolometer
<b>Bildfrequenz</b>	60 fps
<b>Auflösung</b>	320 x 256 px
<b>Spektrale Auflösung</b>	7.5-13 $\mu\text{m}$
<b>Abstand Kamera - Probe</b>	62 cm
<b>Thermische Empfindlichkeit (NEDT)</b>	50 mK
<b>Sichtfeld</b>	48 ° x 39 °

Tabelle 1: Kamera Spezifikationen

Ein Förderband transportiert die Proben mit konstanter Geschwindigkeit zur Infrarot-Heizung, um sie aktiv zu erwärmen. Anschließend werden die Proben durch den Aufnahmebereich der Kamera bewegt, wobei aus der aufgenommenen Videosequenz Kühlkurven für die einzelnen Pixel erstellt werden. Eine schematische Darstellung der Messanordnung ist in Abbildung 1 zu sehen.

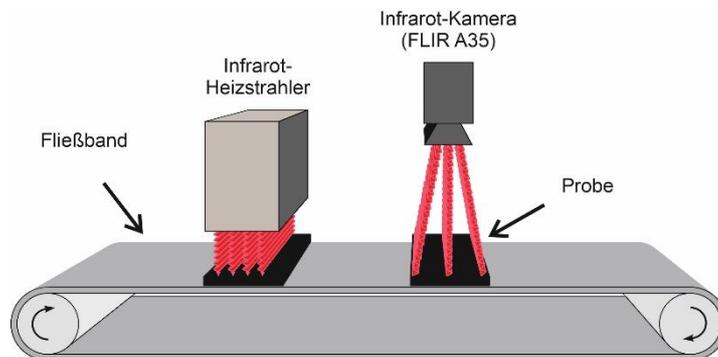


Abbildung 1: Schematischer Messaufbau [6]

Nachdem das Setup definiert wurde, ist es entscheidend, die dominanten Einflüsse zu identifizieren und klassifizieren, die den gesamten Messvorgang beeinflussen. Eine Liste von Einflüssen einschließlich ihrer Kategorisierung ist in Abbildung 2 dargestellt. Die Einflussfaktoren sind in drei verschiedenen Farben dargestellt. Grün kennzeichnet die relevanten Informationen, die als gewünschte Einflüsse kategorisiert sind, welche das Ziel der Messung sind. Blau gekennzeichnet sind Einflüsse, die als Parameter klassifiziert wurden. Das bedeutet, dass sie aktiv durch den Messaufbau kontrolliert werden können. In Rot sind Störeinflüsse gekennzeichnet, die entweder nicht vorhersehbar, nicht messbar oder veränderlich sind. In realen Anwendungen spielen Faktoren wie die Probengeometrie, Umgebungstemperaturen und Verschmutzungen eine bedeutende Rolle, können jedoch nicht aktiv kontrolliert werden. Bei der Analyse der Daten kann es immer wieder

vorkommen, dass unbekannte Einflüsse existieren, die eine zeitliche Korrelation aufweisen können. Um diese Einflüsse zu minimieren, sollten Proben nicht in einer bestimmten, sondern in einer randomisierten Reihenfolge gemessen werden. Ansonsten können Faktoren wie die Eigenerwärmung von Sensoren oder Änderungen in den Randbedingungen im Laufe der Zeit die Daten beeinflussen. Zusätzlich wirken inhärenten Ungenauigkeiten in Sensoren, was gemeinhin als Sensorstreuung bekannt ist, ebenfalls auf die Datenqualität ein.

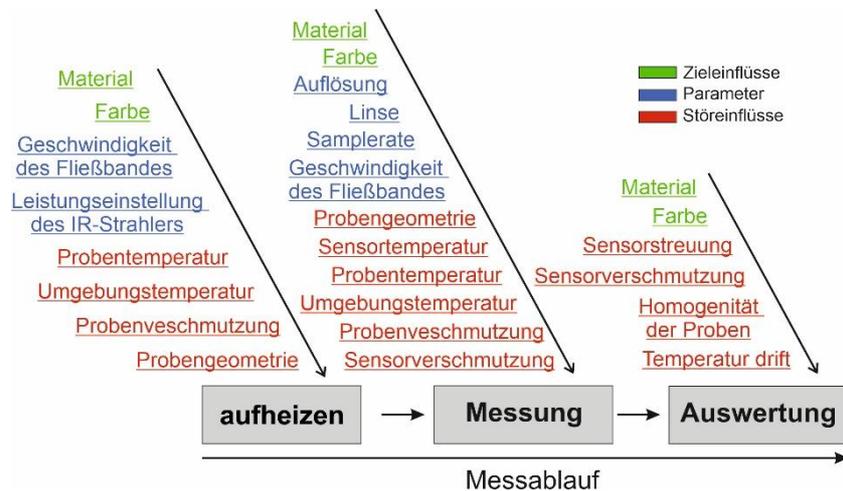


Abbildung 2: Kategorisierte Einflüsse auf die verschiedenen Prozessschritte

In der Anfangsphase sollten die Parameter optimiert und für den restlichen Versuchsablauf konstant gehalten werden. Dadurch werden alle blau markierten Einflüsse auf den weiteren Versuchsablauf eliminiert. Um die gewünschten Einflüsse (Materialien) zu verstärken und gleichzeitig mögliche Einflüsse durch beispielsweise Probengeometrien zu verringern, muss die Auswahl der Proben überlegt getroffen werden, um eine umfassende Darstellung der gewünschten Einflüsse zu gewährleisten. Die drei in dieser Arbeit untersuchten Polymere sind aufgrund der Zugabe von Ruß schwarz und zu 30 % mit Glasfaser gefüllt. Die Proben bestehen aus einem Polyamid 66 (PA66-GF) (TECHNYL A216 V30 Black 21N von DOMO Chemicals, Leuna, Deutschland), einem Polyamid 6 (PA6-GF) (DOMAMID 6G30 BK, ebenfalls von DOMO Chemicals) und einem Polypropylen (PP-GF) (Scofin 53 G13-9 von der Ravago Group, Arendonk, Belgien). Alle Polymere wurden im Fraunhofer-Institut für Betriebsfestigkeit und Systemzuverlässigkeit LBF spritzgegossen. Die thermische Leitfähigkeit  $\lambda$  der drei in diesem Projekt verwendeten Plastikmaterialien ist in Tabelle 2: Thermische Leitfähigkeiten der drei untersuchten Materialien abgebildet (entnommen von der Webseite matweb.de) [8].

Material	Thermische Leitfähigkeit $\lambda$ [W/mK]
PA66-GF	0.24-0.25
PA6-GF	0.25
PP-GF	0.27-0.33

Tabelle 2: Thermische Leitfähigkeiten der drei untersuchten Materialien

Ein weiterer Einfluss ist die Umgebungstemperatur auf die Kamera. Um diesen Einfluss zu bestimmen wurde die Kamera in einem Klimaschrank betrieben und auf einen schwarzen Strahler gerichtet, der eine konstante Temperatur von 20°C gehalten hat. Die Temperatur des Klimaschranks wurde schrittweise um 2,5°C von 17.5°C auf 27.5°C erhöht. In diesem Versuch konnte eine lineare Abhängigkeit der Intensitätswerte von der Umgebungstemperatur nachgewiesen werden. Um besagte Temperaturabhängigkeit zu

kompensieren, erfolgt die zyklische Messung der Umgebungstemperatur mit Hilfe eines Temperatursensors (DHT22). Die gemessenen Intensitätswerte können durch die Anwendung folgender Korrekturformel

$$I_{korr} = I_{mess} - (\theta - \theta_{ref}) * 10.9286 \frac{1}{K}$$

mit:

$$\begin{aligned} I_{korr} &= \text{korrigierter Intensitätswert} \\ I_{mess} &= \text{gemessener Intensitätswert} \\ \theta_{ref} &= \text{Referenztemperatur (hier } 20^{\circ}\text{C)} \\ \theta &= \text{gemessene Temperatur} \end{aligned}$$

unter Berücksichtigung der vom DHT22 gemessenen Temperatur korrigiert werden. Auf diese Weise wurde der Einfluss der Umgebungstemperatur auf die Kamera kompensiert. Um potenzielle zeitliche Abhängigkeiten zu minimieren, wird eine zufällige Probenreihenfolge gewählt. Dieser Ansatz zielt darauf ab, Abhängigkeiten in den Daten zu eliminieren und trägt somit zu einer robusten und unbeeinflussten Analyse bei. Durch diese Vorgehensweise konnten unerwünschte Einflüsse in erheblichem Maße reduziert werden.

#### 4. Datenauswertung

Die Datenauswertung ist entscheidend, um die Beziehung zwischen Messdaten und Materialeigenschaften zu verstehen. Sie beginnt mit der Vorverarbeitung, die das Ziel hat, den gewünschten Effekt zu verstärken und Störfaktoren zu reduzieren. Nach dieser Phase kommen verschiedene Methoden des maschinellen Lernens zum Einsatz, um Muster zu erkennen und Daten den entsprechenden Materialien zuzuordnen.

Der erste Schritt der Vorverarbeitung ist die präzise Erfassung der Probenbewegung. Das Förderband transportiert die Proben gleichmäßig, während die Kamera Bilder mit konstanter Rate aufnimmt, was die exakte Bestimmung der Pixelverschiebung – die Distanz, die eine Probe zwischen zwei Aufnahmen zurücklegt – erlaubt. Sobald Proben aus dem Sichtfeld rücken, wird für jeden Probenpixel eine Kühlkurve erstellt. Die zeitliche Auflösung der Abkühlkurven ist abhängig von der Bandgeschwindigkeit und der Bildrate. Da Pixelverschiebungen oft keine ganzen Zahlen sind, kommt lineare Interpolation zum Einsatz, um die Genauigkeit beim Erstellen der Kühlkurven zu verbessern.

Die gesamte Abkühlkurve wird durch ein Polynom approximiert, wobei synthetische Daten entstehen, die das thermische Verhalten wiedergeben und Störungen reduzieren, wie von Shepard et al. [9] vorgeschlagen. Diese Datenverarbeitung erhöht die Effizienz und verringert den Speicherbedarf, was besonders für die schnelle Sortierung von Kunststoffen wichtig ist. Auch Artefakte wie Kamerareflexionen, die die Messergebnisse verfälschen können, werden so reduziert. Die schnelle Fourier-Transformation (FFT) wird auf die Kühlkurven angewandt, um Materialien anhand ihrer thermischen Reaktion zu differenzieren, wie von Maldague & Marinetti [10] vorgeschlagen.

Verschiedene Merkmale wurden im Hinblick auf ihre Relevanz für das maschinelle Lernmodell bewertet. Zusätzlich zu den FFT-bezogenen Merkmalen hat sich die Berechnung der relativen Temperaturabfälle als nützlich erwiesen. Hierbei wurden verschiedene Zielbilder in Bezug auf das Anfangsbild gesetzt. Ein Beispiel für verschiedene Materialien in Abbildung 3 dargestellt. Die folgenden Merkmale wurden als am bedeutendsten identifiziert und als Eingabe für das maschinelle Lernmodell ausgewählt:

- FFT-Amplitude (erste 10 Frequenzbins nach DC)
- FFT-Phase (erste 10 Frequenzbins nach DC)
- relativer Temperaturabfall für Zielbilder 10, 20, 50, 80 und 90
- zwei Polynomkoeffizienten (Polynom erster Ordnung im logarithmischen Bereich)

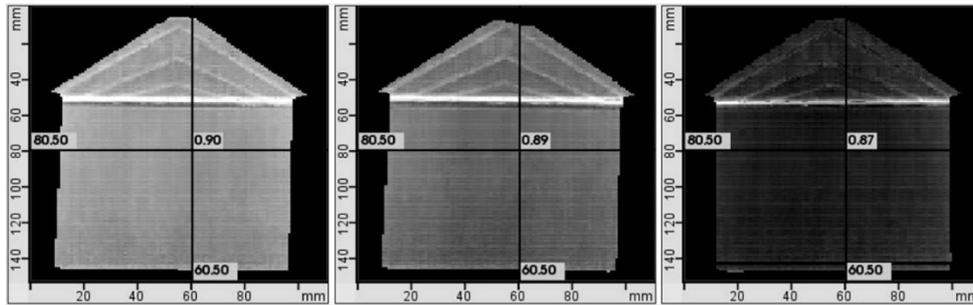


Abbildung 3: Relativer Temperaturabfall für PA66-GF, PA6-GF und PP-GF Proben, Zielbild 80 [6]

Um ein maschinelles Lernmodell zu erstellen, welches in der Lage ist, zwischen den drei zu untersuchenden schwarzen Materialien zu unterscheiden, wird der Datensatz in Trainings- und Validierungsdaten aufgeteilt. Der Validierungsdatensatz beinhaltet drei vollständige Proben, die für jedes Material ausgewählt wurden. Als Klassifikationsmodell wurde mit der Python Bibliothek Scikit-learn (Version 1.2.2) [11] eine Pipeline erstellt, die eine Standardskalierung und anschließend eine lineare Diskriminanzanalyse (LDA) [12] enthält. Diese überwachte Methode der multivariaten Statistik hat gegenüber „Blackbox“ Ansätzen wie eines neuronalen Netzes den großen Vorteil, dass jede Klassifikationsentscheidung nachvollziehbar und vollständig erklärbar ist. Insbesondere wenn bisher keine eindeutigen Beweise dafür vorliegen, dass ein neues Verfahren die Aufgabe erfolgreich bewältigen kann, ist es ratsam, erklärbare Methoden zu verwenden.

## 5. Ergebnis

Bei Anwendung der Pipeline auf den Datensatz wird eine Projektion der 27 Merkmale auf zwei neue kanonische Variablen erstellt, wodurch die Trennung zwischen den Klassen maximiert wird. Durch die Darstellung in einer Konfusionsmatrix aus den Vorhersageergebnissen des Modells kann erkannt werden, welche und wie viele Klassifizierungen fehlerhaft waren. Wie in Abbildung 4 links zu sehen ist, führte die pixelweise Klassifizierung bereits zu einem guten Ergebnis, da keine Fehlklassifikationen für Polypropylen vorlagen und nur wenige zwischen beiden Polyamid Materialien auftraten. Da eine pixelweise Sortierung nicht praktikabel ist, wird im nächsten Schritt eine Objekterkennung für einzelne Proben durchgeführt und eine Mehrheitsentscheidung für jede Probe getroffen. Die Abbildung 4 zeigt rechts, dass mit diesem Ansatz eine fehlerfreie Klassifikation der drei Materialien durchgeführt werden konnte.

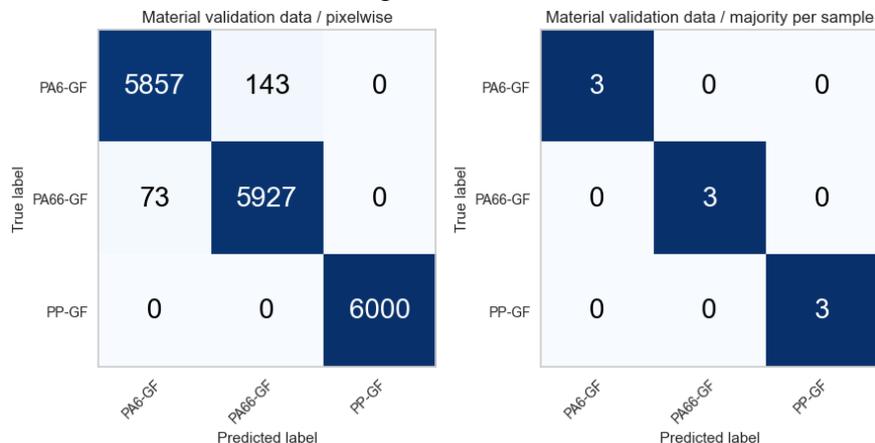


Abbildung 4: Konfusionsmatrizen: links: pixelweise, rechts Mehrheitsentscheid pro Objekt

Für die Klassifizierung ist es immer noch wichtig, die pixelweisen Vorhersagen als Grundlage zur Verbesserung des Modells und zur Bewertung der Ergebnisse zu betrachten. Um die Genauigkeit der vorhergesagten Ergebnisse zu messen, wird häufig der F1-Score verwendet, der „precision“ und „recall“ kombiniert [13] und somit eine umfassende Aussage über das Klassifikationsergebnis darstellt. In der Abbildung 5 wird die Darstellung der pixelweisen Ergebnisse in diesen drei häufig verwendeten Bewertungskriterien gezeigt. Es konnte ein F1-Score von mindestens 0,982 erreicht werden. Herausforderungen in Bezug auf die Vorhersagegenauigkeit sind nur zwischen den Materialien PA6-GF und PA66-GF zu beobachten, die sehr ähnliche physikalische und chemische Eigenschaften aufweisen. Die Unterscheidung zwischen PA6-GF/PA66-GF und PP-GF kann jedoch fehlerfrei mit einem F1-Score von 100% durchgeführt werden.

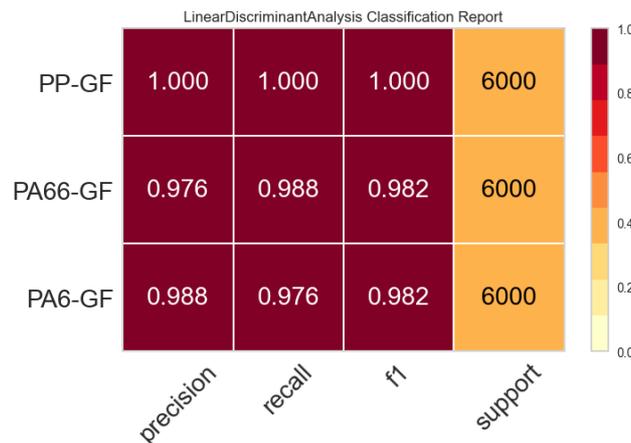


Abbildung 5: Pixelweiser F1-Score der Ergebnisse der Validierungsdaten

## 6. Zusammenfassung und Ausblick

In dieser Arbeit wurden schwarze Kunststoffmaterialien (PA6-GF, PA66-GF, PP-GF) mittels aktiver Thermographie klassifizieren. Es wurde ein Setup entwickelt, das stabile und präzise Messungen ermöglicht. Alle Einflussfaktoren wurden identifiziert, klassifiziert und teilweise kompensiert mit dem Ziel, unbekannte und unerwünschte Einflüsse zu reduzieren. Durch iterative Verbesserungen wurden Vorverarbeitungstechniken und Merkmalsextraktionen entwickelt, die die wichtigsten Informationen konzentrieren. Ein maschineller Lernalgorithmus wurde trainiert, welcher alle Validierungsproben korrekt klassifizieren konnte. Dadurch konnte gezeigt werden, dass die Nutzung dieser Technologie eine Verbesserung gegenüber dem aktuellen Stand der Technik ermöglicht.

Die nächsten Schritte umfassen die Verwendung dieser Laboreinrichtung und des gewonnenen Wissens, um sukzessive weitere reale Einflussfaktoren hinzuzufügen, die zuvor ausgeschlossen wurden (z.B.: unterschiedliche Probengeometrien). Die Kamera kann durch ein Exemplar mit schnellerer Bildrate ersetzt werden, um die Bandgeschwindigkeit zu erhöhen. Eine Kamera mit höherer Auflösung kann auch die Qualität und Präzision der Analyse verbessern. Um Selbstreflexionseffekte der Kamera zu reduzieren, kann die Kamera unter einem Winkel statt vertikal angebracht werden. Hierbei müssen die Daten anschließend mit einer Transformationsmatrix entzerrt werden. Ebenso findet die Fusion der aktiven Thermographie im Projekt »Waste4Future« [5] in einen Demonstrator einschließlich anderer Modalitäten statt, um einen multimodalen Sortierer für Kunststoffmaterialien zu schaffen. Wie in dieser Arbeit gezeigt wurde, ist der Ansatz der aktiven Thermographie in der Lage, die Genauigkeit der Klassifizierung von schwarzen Kunststoffen zu erhöhen.

## Referenzen

- [1] EC: *Circular Economy action plan*. URL [https://environment.ec.europa.eu/strategy/circular-economy-action-plan\\_en](https://environment.ec.europa.eu/strategy/circular-economy-action-plan_en) – Überprüfungsdatum 2023-11-23
- [2] CHEN, Xiaozheng ; KROELL, Nils ; FEIL, Alexander ; PRETZ, Thomas: *Determination of the composition of multilayer plastic packaging with NIR spectroscopy*. In: *Detritus* 13 (2020), S. 62–66
- [3] ROZENSTEIN, Offer ; PUCKRIN, Eldon ; ADAMOWSKI, Jan: *Development of a new approach based on midwave infrared spectroscopy for post-consumer black plastic waste sorting in the recycling industry*. In: *Waste management* 68 (2017), S. 38–44. URL <https://www.sciencedirect.com/science/article/pii/S0956053X17305160>
- [4] MASOUMI, Hamed ; SAFAVI, Seyed Mohsen ; KHANI, Zahra: *Identification and classification of plastic resins using near infrared reflectance*. In: *International Journal of Mechanical Sciences* 6 (2012), S. 213–220
- [5] W4F: *Waste 4 Future*. URL <https://www.waste4future.fraunhofer.de>
- [6] SCHMITZ, Kevin ; SHPAKOVA, Nina ; KELLER, Andreas ; NETZELMANN, Udo: *Classification of black plastic using active thermography*, Bd. 10. In: Lehrstuhl für Anthropogene Stoffkreisläufe und Lehr- und Forschungsgebiet Aufbereitung mineralischer Rohstoffe (Hrsg.): *Sensor-Based Sorting & Control* : Shaker, 2024, S. 195–215
- [7] JONES ROGER W. ; MCCLELLAND JOHN F.: *Transient infrared emission spectroscopy*. In: *Analytical chemistry* 61 (1989), Nr. 7, S. 650–656
- [8] MATWEB. URL <https://www.matweb.com/index.aspx> – Überprüfungsdatum 2023-11-23
- [9] SHEPARD, S. M. ; AHMED, T. ; RUBADEUX, B. A. ; WANG, D. ; LHOTA, J. R.: *Synthetic processing of pulsed thermographic data for inspection of turbine components*. In: *Insight: Non-Destructive Testing and Condition Monitoring* 43 (2001), S. 587–589
- [10] MALDAGUE, Xavier. ; MARINETTI, Sergio: *Pulse phase infrared thermography*. In: *Journal of Applied Physics* (1996), Nr. 79, S. 2694–2698
- [11] PEDREGOSA, F. ; VAROQUAUX, G. ; GRAMFORT, A. ; MICHEL, V. ; THIRION, B. ; GRISEL, O. ; BLONDEL, M. ; PRETTENHOFER, P. ; WEISS, R. ; DUBOURG, V. ; VANDERPLAS, J. ; PASSOS, A. ; COURNAPEAU, D. ; BRUCHER, M. ; PERROT, M. ; DUCHESNAY, E.: *Scikit-learn: Machine Learning in Python*. In: *Journal of Machine Learning Research* 12 (2011), S. 2825–2830
- [12] FISHER, R. A.: *The use of multiple measurements in taxonomic problems*. In: *Annals of Eugenics* 7 (1936), Nr. 2, S. 179–188
- [13] FAWCETT, Tom: *An introduction to ROC analysis*. In: *Pattern Recognition Letters* 27 (2006), Nr. 8, S. 861–874. URL <https://www.sciencedirect.com/science/article/pii/S016786550500303X> – Überprüfungsdatum 2023-11-23