



MARKUS RAUHUT
ABTEILUNGSLEITER



MATHEMATISCHE MODELLE UND BILDANALYSE-ALGORITHMEN FÜR DIE INDUSTRIE

Die Abteilung entwickelt mathematische Modelle und Bildanalysealgorithmen und setzt diese um in industrietaugliche Software, vorwiegend in der Produktion. Die Anwendungsgebiete umfassen insbesondere anspruchsvolle Oberflächenprüfungen und Analyse von Mikrostrukturen. Auch die Beratung nimmt einen immer größeren Stellenwert ein, zum Beispiel zu Hardware bei der Konzeption von Bildverarbeitungssystemen oder zur Integration zusätzlicher Komponenten in ein bereits bestehendes System, aber auch unabhängige Beratung im Bereich optische Qualitätskontrolle oder bei der Entwicklung von Algorithmen.

In den letzten Jahren war unser Schwerpunkt vor allem im Bereich Machine Learning in der Bildverarbeitung für Produktion und Industrie. Methoden wie das »Deep Learning« erfordern eine hohe Anzahl annotierter Daten, zum Beispiel von den in einer Produktionsanlage zu findenden Defekten. Nun sind aber in einer gut funktionierenden Produktion viele Bilder von fehlerfreien Produkten vorhanden, aber nur wenige von Produkten mit Defekten. Wir wählen hier den Weg der Datenaugmentierung – d.h. auf Basis der echten Fehlerdaten werden künstliche Fehlerdatenbanken erzeugt.

Eine andere Lösung besteht darin, die Defekte mathematisch zu beschreiben und die Software bzw. den Algorithmus das zugrundeliegende Modell automatisch lernen zu lassen. Schwierig ist es auch, die Prüfschärfe von einem auf Machine Learning basierenden Inspektionssystem während der Produktion zu ändern, um z.B. bestimmte Qualitätsniveaus einzustellen. Wir setzen deshalb häufig Hybride aus den »klassischen« parametrisierbaren Verfahren (Filter, Morphologie, Kantendetektoren) und Machine Learning ein.

Kontakt

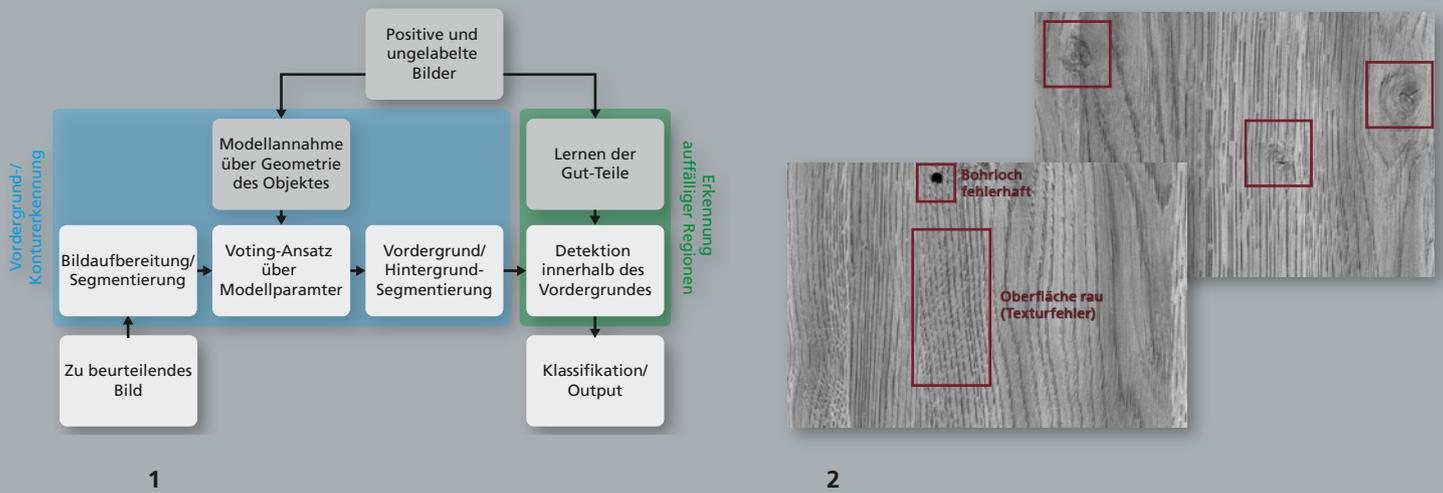
markus.rauhut@itwm.fraunhofer.de

www.itwm.fraunhofer.de/bv

SCHWERPUNKTE

- Oberflächen- und Materialcharakterisierung
 - Qualitätssicherung und Optimierung
 - Industrial Image Learning
 - Virtuelle Bildverarbeitung
-





MACHINE LEARNING FÜR DIE PRODUKTION

1 Schrittweises Vorgehen bei der Qualitätskontrolle in der Oberflächeninspektion ungelabelter Bilder (hybrider Ansatz)

2 Für die Holzinspektion ist ein Machine-Learning-Verfahren unabdingbar: Hier müssen nicht nur Defekte gefunden, sondern auch einzelne Dekore erkannt und überprüft werden.

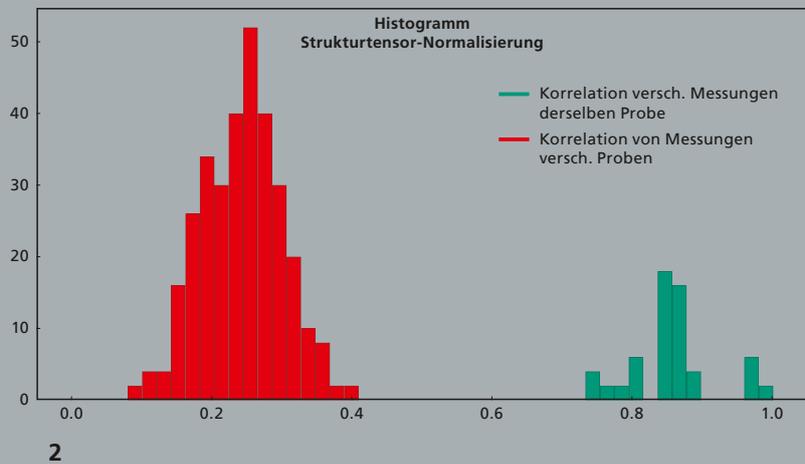
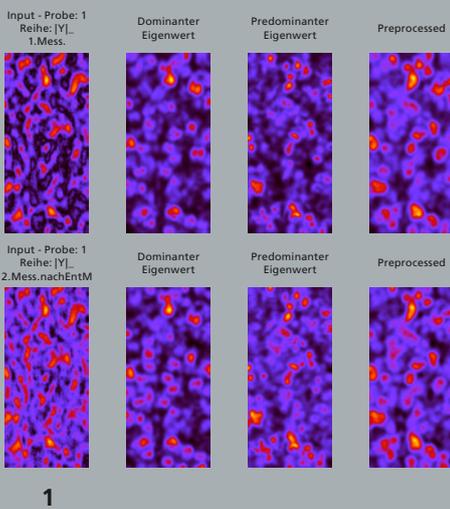
Industrielle Bildverarbeitung wird zur Qualitätskontrolle in vielen Produktionsumgebungen eingesetzt. Methoden des Machine Learning spielen bei der automatisierten Fehlererkennung schon lange eine Rolle; heutzutage tragen sie auch dazu bei, den anpassungsintensiven Teil der Bildverarbeitung zu automatisieren.

In der klassischen industriellen Bildverarbeitung versucht man zunächst, die Bildaufnahme optimal auf Fehler und Produkt abzustimmen, um die Fehlerdetektion zu vereinfachen. Mittels Bildverarbeitung wird zunächst das Bild verschiedentlich mathematisch transformiert, um potenzielle Fehlerregionen hervorzuheben und anschließend zu segmentieren. Im Anschluss daran werden diese Fehlerregionen zur Beurteilung des Gesamtobjektes genutzt.

Hybride Lösung für Fehlerdetektion und Einteilung in Qualitätsklassen

Das finale Ziel ist meist die Sortierung der Teile in verschiedene Qualitätsklassen und die Lokalisierung der entsprechenden Indikatoren/Defekte. Während die Beurteilung der potenziellen Fehlerregionen fast immer mittels Machine Learning erfolgt, werden für die Extraktion der Regionen selbst klassische Bildverarbeitungsverfahren angewendet – wie etwa Glättung durch verschiedene Filter, Segmentieren, Kantendetektion, morphologische Operationen. Mit Erstarren des Machine Learning, speziell des Deep Learning, wächst der Wunsch, diesen anpassungsintensiven Teil der industriellen Bildverarbeitung stärker zu automatisieren. Vollständig automatisierte Systeme erfordern eine große Anzahl annotierter Daten. Da aber meist im laufenden Betrieb gearbeitet wird, ist es nicht möglich, gezielt Fehlerklassenbeispiele zu produzieren; auch ist das manuelle Annotieren zeitaufwändig und teuer. Zudem gibt es selten auftretende Fehlerklassen mit nur sehr wenigen Repräsentanten. Insgesamt existieren wesentlich mehr Gut- als Schlecht-Beispiele. Die Spezifikation von Defekten und deren Klassifikation ändert sich im Laufe eines Projektes; das führt zur aufwändigen Anpassungen.

Wir setzen deshalb parametrierbare Methoden der Bildverarbeitung ein und kombinieren diese mit modernen Lernverfahren. Modellannahmen werden dabei zur Einbringung von Vorwissen für die Segmentierung genutzt, maschinelles Lernen zur Detektion auffälliger Regionen. Eine andere Lösung ist es, die Defekte mathematisch zu beschreiben und dann dieses Modell zu lernen. So können Defekte durch bestimmte Features beschrieben werden (z. B. die Form/das Aussehen durch morphologische Merkmale) und dann mit passenden Filtern genau diese Defekte aus den Bildern extrahiert werden. In der Praxis bedeutet dies u. a., dass zu jedem Feature entsprechende Filter implementiert werden.



BAUTEILE ANHAND INTRINSISCHER MERKMALE IDENTIFIZIEREN UND RÜCKVERFOLGEN

Ein Bauteil mit seinen individuellen Merkmalen zu jedem Zeitpunkt der Verarbeitung zu identifizieren und zurückverfolgen, das ist Voraussetzung für viele prozessbeeinflussende Entscheidungen in der Produktion. Im Projekt INSITU nutzen wir dafür ein neues Verfahren, welches sich die Kenntnis von Merkmalen im Bauteilinneren zunutze macht.

Die Optimierung von Qualität, Produktivität und Kosten hängt davon ab, ob ein Produkt jederzeit eindeutig identifizierbar und lokalisierbar ist, damit der Produktionsvorgang automatisiert werden kann. Bisher genutzte Objektkennzeichnungen – wie beispielsweise Etiketten, Barcodes, IC-Chips oder andere Identifikations-Tags – sind nur bedingt geeignet, da sie nicht dauerhaft und unbeschädigt auf dem Prüfobjekt verbleiben.

Wir nutzen im Projekt INSITU ein Verfahren der zerstörungsfreien Prüfung, um das Bauteil anhand von Merkmalen aus dem Bauteilinneren zu identifizieren. Solche sensorischen Verfahren werden oft für die Qualitätsprüfung eingesetzt. Durch große Versuchsreihen konnten wir feststellen, dass bestimmte Werkstoffeigenschaften eine eindeutige Identifikation ermöglichen. Die Kombination mehrerer Verfahren ermöglicht die Bauteilidentifikation für verschiedene metallische Werkstoffe und verschiedene Bauteiltypen. Die gewonnenen Identifikationsdaten werden in einem Merkmalsraum gespeichert und stellen das Bauteil als eindeutiges Individuum dar.

Maschinelles Lernen der Werkstoffeigenschaften

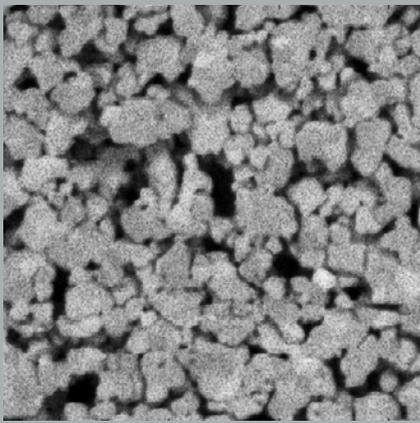
Die Erfassung charakteristischer Informationen aus dem Bauteilinneren wurde algorithmisch mit Technologien des maschinellen Lernens verknüpft, um die für die eindeutige Identifikation des Bauteils relevanten Informationen zu ermitteln: Durch die verwendeten Sensoren erhält man eine Art Bild aus dem Inneren des jeweiligen Bauteils. Maschinelles Lernen erfordert aber auch eine umfangreiche Annotation von Trainingsdaten. Für jeden Datensatz werden darum inhaltsbeschreibende Attribute erzeugt und diese Datenbank für das Training eines speziellen neuronalen Netzes verwendet. Der Deep-Learning-Algorithmus kann anhand der abstrakten Merkmale in den Werkstoffdaten eine eindeutige Identifikation vornehmen. So lässt sich nach jedem Arbeitsschritt in der Produktion der Vorgänger eines Werkstoffs feststellen.

In Kooperation mit Fraunhofer IZFP und Fraunhofer IWU entwickeln wir ein industrietaugliches Sensorsystem für die Bauteilidentifikation bei der Blechumformung, inklusive eines cloudbasierten Datenmanagementsystems zur Verwaltung und Rückverfolgung produktbezogener Daten.

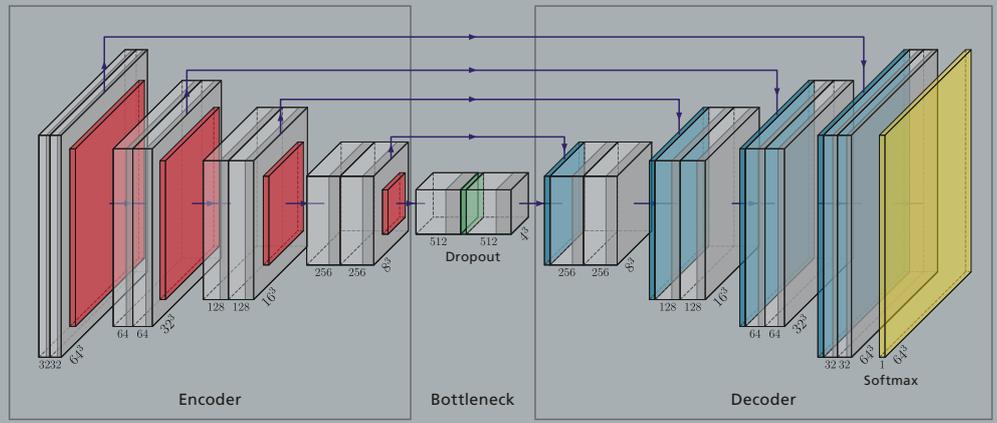
1 Optisch aufbereitet sehen die einzelnen Proben wie in dieser Abbildung aus. Durch eine Aufbereitung der Daten mittels Strukturtensor wurde die Erkennungsrate massiv verbessert.

2 Im Histogramm ist gut zu sehen, wie das System verschiedene Messungen der gleichen Probe (grün) zu einem Cluster zusammenfasst. Gleiches gilt für Messungen verschiedener Proben (rot).





1



2

DEEP LEARNING FÜR DIE 3D-REKONSTRUKTION HOCHPORÖSER STRUKTUREN AUS FIB-REM-BILDSTAPELN

1 REM-Bild einer nanoporösen Zirkondioxid-Probe

2 Skizze der genutzten U-Net3D-Architektur; die grauen Kästchen stellen Convolutional Layer dar, denen einer Batch-Normalisation folgt und mit ReLU aktiviert werden.

rot: Max-Pooling-Layer;
blau: entsprechende Up-Sampling-Layer;
gelb: Convolutional Layer mit Soft-Max-Aktivierung

Moderne Werkstoffe wie Gasdiffusionsschichten für Brennstoffzellen, Elektroden für Lithium-Ionen-Batterien, Filtermedien oder keramische Werkstoffe mit aktiven Komponenten haben komplexe, multiskalige Strukturen, die das makroskopische Materialverhalten hochgradig beeinflussen. 3D-Bilder der Strukturen ermöglichen ein tieferes Verständnis, wie Struktur und Eigenschaften zusammenhängen. Mit neuen Deep-Learning-Methoden tragen wir zu diesem Verständnis bei.

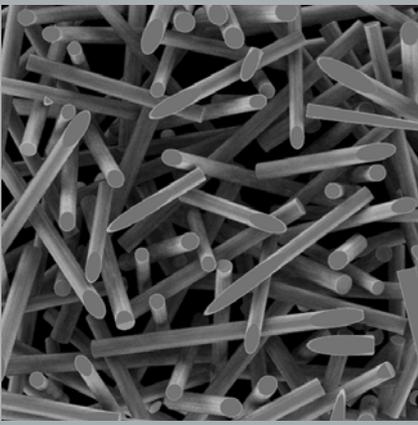
Auf der Nanoskala können Strukturen im Bereich 5–100 nm durch die FIB-REM-Serienschnitttechnik dreidimensional abgebildet werden. Mithilfe eines fokussierten Ionenstrahls (Focussed Ion Beam, FIB) wird die zu untersuchende Struktur präzise geschnitten und die Schnittfläche anschließend mit dem Rasterelektronenmikroskop (REM) abgebildet. Die Oberfläche wird weiter abgetragen, die Schnittfläche wieder abgebildet. Mehrere Hundert Schnittbilder ergeben einen Volumendatensatz.

Durchscheinartefakte erschweren die Rekonstruktion

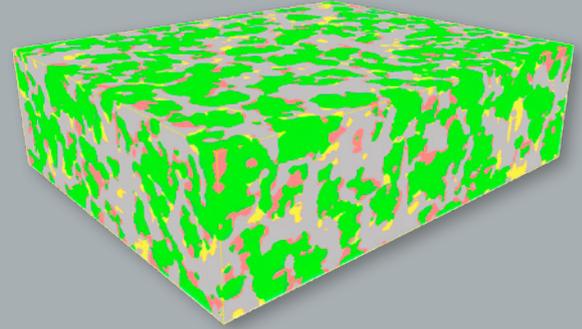
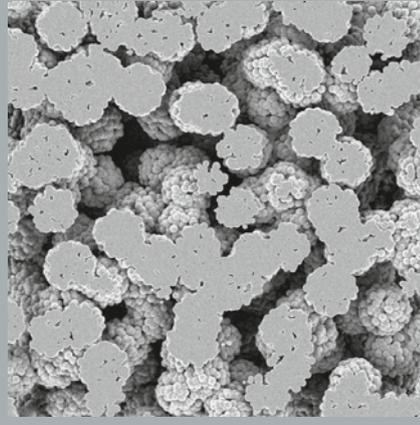
Bei hoher Porosität entspricht die aus den 2D-Schnitten rekonstruierte 3D-Struktur jedoch nicht der realen Struktur, da die einzelnen REM-Bilder nicht nur die tatsächlichen Schnittflächen zeigen. Die hohe Tiefenschärfe des REM lässt durch die Poren auch Strukturbereiche dahinter sichtbar werden und genauso hell erscheinen wie die aktuelle Schnittfläche. Diesen Effekt, dass feste Strukturen durch die Poren aus tieferen Schichten sichtbar sind, nennt man Durchscheinartefakt. Die Rekonstruktion der 3D-Struktur und deren quantitative Analyse sind deshalb für poröse Strukturen eine Herausforderung. Mehrere Rekonstruktionsverfahren sind u. a. am ITWM entwickelt worden. Sie sind jedoch nach wie vor maßgeschneidert für bestimmte Strukturen und Kontrastverhältnisse, nicht leicht zu parametrisieren und anfällig bei typischen Abbildungsartefakten wie Streifen durch das Schneiden oder Aufladung im Fall nichtleitender Materialien.

Deep Learning als Lösungsansatz für komplexe 3D-Segmentierungsaufgaben

Machine Learning wird immer öfter für die Lösung komplexer Segmentierungsaufgaben, auch in 3D-Bildern, eingesetzt. Convolutional Neural Networks (CNN) benötigen allerdings für die Trainingsphase viele korrekt segmentierte (hier rekonstruierte) Bilder. Gerade in unserem Fall ist aber die Bildgewinnung teuer. Außerdem ist es schwierig, interaktiv korrekt zu segmentieren, weil auch der Mensch Mühe hat, durchscheinendes von echtem Material zu unterscheiden.



3



4

Wir haben deshalb ein CNN (U-Net3D) mit ausschließlich synthetisch erzeugten FIB-REM-Bildern trainiert. U-Net3D besteht aus zwei Pfaden, wobei der erste – der Encoder – einem klassischen CNN ähnelt und alle Convolutional Layer mit Rectified Linear Unit (ReLU) aktiviert werden. Dieser Encoder wird zur Erfassung des Bildkontextes verwendet, indem mehrere Convolutional Layer gefolgt von einer Batch-Normalisation und abwechselnd mit Pooling-Layer zur Down-Sampling der Feature-Map ausgeführt werden (siehe Abbildung 2). Die ReLU-Layer lassen den Eingabewert unangetastet, wenn er positiv ist, und geben ansonsten Null zurück. Pooling-Layer werden eingeführt, um die Größe jeder Feature Map durch Down-Sampling mithilfe nichtlinearer Funktionen zu reduzieren. Batch-Normalisation-Layer skalieren die Werte der Feature Map so, dass sie im statistischen Sinne vergleichbar und standardisiert sind.

Rekonstruktion der Segmentierung aus der Feature-Map

Sobald die dünnste Schicht – der Flaschenhals des Netzwerks – passiert ist, expandiert der symmetrische zweite Pfad die Feature Maps wieder. Im Bottleneck wird ein Dropout-Layer mit einer Wahrscheinlichkeit von 0,5 als indirekte Augmentierung verwendet. Der expandierende Pfad ermöglicht die präzise Lokalisierung in den ursprünglichen Bilddimensionen, indem Up-Sampling-Layer anstatt Pooling-Layer verwendet werden und der Output mit dem entsprechenden Layer im Encoder verknüpft wird. Schließlich wird ein zusätzlicher Convolutional Layer mit Soft-Max-Aktivierung angewendet, um Wahrscheinlichkeiten der Klassenzugehörigkeit zu erhalten. Abbildung 2 enthält eine Skizze unserer Architektur einschließlich der Anzahl der Layer.

Training mit synthetisch erzeugten Bildern

Wir erzeugen also eine Geometrie, z. B. aus überlappenden Kugeln. Dieses Kugelsystem wird direkt diskretisiert. Das so entstandene 3D-Bild ist sofort als Grundwahrheit verfügbar. Zum anderen wird ein Stapel von REM-Bildern physikalisch korrekt simuliert. Abbildung 3 zeigt zwei Beispiele für synthetische REM-Bilddaten von Realisierungen stochastischer Geometriemodelle. Mit diesen Daten trainiert das CNN zu entscheiden, welche Pixel tatsächlich zum Vordergrund gehören, also zum Material. Wir haben dann diesem ausschließlich auf synthetischen Daten trainierten CNN FIB-REM-Stapel realer Strukturen vorgelegt. Zwei reale Datensätze hat es genauso gut wie die besten maßgeschneiderten klassischen Methoden segmentiert. In Abbildung 4 ist das Rekonstruktionsergebnis des trainierten Modells für die nanoporöse Zirkonoxid-Probe abgebildet.

Das nächste Entwicklungsziel besteht darin, das CNN anhand synthetischer FIB-REM-Bilder vieler verschiedener Strukturen zu trainieren. Dieses CNN könnte dann auch neue, unbekannte Strukturen korrekt segmentieren.

3 Beispiele für synthetische REM-Bilddaten von Realisierungen stochastischer Geometriemodelle; links zufällige Packung von Zylindern und rechts Cox-Boolesches-Modell von Kugeln

4 Rekonstruktionsergebnis des trainierten Modells für die nanoporöse Zirkonoxid-Probe; grün: korrekt segmentierte Vordergrundpixel (True Positiv); gelb: falsch als Vordergrund klassifizierte Pixel (False Positiv); rot: falsch als Hintergrund klassifizierte Pixel (False Negativ)





BV FÖRDERT STEM-GAMES



Gelerntes Wissen in Teamarbeit an realistischen Szenarien anwenden und komplexe Probleme lösen? Miteinander arbeiten und voneinander lernen? Sich nicht nur geistig, sondern auch körperlich auspowern und den Teamspirit stärken? Das ist die Intension der STEM-Games, die Anfang Mai 2019 in Porec, Kroatien, stattfanden. Auch die Abteilung Bildverarbeitung war als Partner dieses internationalen Recruiting Events sowohl in der Jury als auch mit Mentoren vertreten. In dem Wettbewerb für Studierende aus den MINT-Bereichen (Mathematik, Ingenieurwesen, Naturwissenschaft, Technik) bewältigen die Teams in vier Arenen komplexe Aufgabenstellungen. Neben dem wissenschaftlichen Wettbewerb treten sie auch in neun verschiedenen sportlichen Disziplinen gegeneinander an.

BV AUF DER CONTROL



Auf der Fachmesse Control stellte die Abteilung ihr Oberflächen-Inspektionssystem mit Roboter-gestützter Bahnplanung vor; es hat mehrere Schnittstellen für die Bildaufnahme, untersucht das Bauteil und leistet den Abgleich mit dem CAD-Modell sowie die Visualisierung dieses CAD-Modells. Darüber hinaus beinhaltet es die Algorithmen zur automatischen Berechnung von Scanpfaden. Die Visualisierung des CAD-Modells wird je nach Scanpfad des Roboters und Drehung der Rotationseinheit sukzessive modifiziert, sodass die bereits geprüften Bauteilregionen sichtbar gekennzeichnet werden. Dies erleichtert besonders die Prüfung von Bauteilen mit komplexen Geometrien.

ZUSAMMENARBEIT MIT OIKON

Im Oktober unterzeichneten das Fraunhofer ITWM und Oikon, ein führendes Institut auf dem Gebiet der angewandten Ökologie in Kroatien und Osteuropa, ein Memorandum of Understanding; damit besiegeln die ihre nachhaltige Zusammenarbeit: Vor allem im Bereich Bildverarbeitung sowie Raum- und Umweltanalyse kombinieren sie ihre jeweilige Expertise, um gemeinsam Projekte durchzuführen.