


Künstliche Intelligenz: Reduzierung von Prüfzeiten und manueller Arbeit im Qualitätsmanagement

Die neuartige Auto-Labeling-Methode von *FLAIR* und *CCI*

CSOT (China Star Optoelectronics Technology), auch *Shenzhen Huaxing Photoelectric Technology* genannt, ist der führende LED-Lieferant der *TCL Group* und der zweitgrößte Produzent von LCD-Displays weltweit. Das Unternehmen nutzt Künstliche Intelligenz (KI) zur Automatisierung von Fehlerprüfungsprozessen, um seinen Wettbewerbsvorteil zu erhalten und auszubauen. Das Labeln (dt. Beschriftung/ Etikettierung) von Datensätzen für das Training mit aktuellen KI-basierten Methoden ist jedoch zeit- und arbeitsintensiv und erfordert insgesamt bis zu 1500 Stunden Trainingszeit für eine typische Produktionsfabrik mit mehreren Produktionslinien. Um dieser Herausforderung zu begegnen, entwickelt das *Hong Kong Industrial Artificial Intelligence and Robotics Centre (FLAIR)* – gemeinsam initiiert vom *RWTH Aachen Campus* und dem *Hong Kong Productivity Council* – neue KI-basierte Segmentierungs- und Klassifizierungstechniken. Mit diesen Ansätzen wird das Data-Labeling von 20 Sekunden auf weniger als eine Sekunde reduziert. So werden mehr als 1400 Arbeitsstunden pro Fabrik eingespart, was großes Potenzial für Qualitätsverbesserungen im Produktionsmanagement und geschätzte Einsparungen von mehr als 84.000 Euro bedeutet. >



Artificial Intelligence Helps Quality Managers to Reduce Inspection Time and Manual Labor

Novel Auto Labeling Method From *FLAIR* and *CCI*

CSOT (China Star Optoelectronics Technology), also called *Shenzhen Huaxing Photoelectric Technology*, is the leading LED supplier of the *TCL Group* and the second largest producer of LCD displays worldwide. They use Artificial Intelligence (AI) to automate defect inspection processes to maintain their competitive edge. However, the labeling of datasets for training using current AI based methods is time-consuming and labor-intensive, requiring up to 1,500 hours training time in total for one typical manufacturing factory containing multiple production lines. To address this challenge, the *Hong Kong Industrial Artificial Intelligence and Robotics Centre (FLAIR)* – jointly initiated by *RWTH Aachen Campus* and *Hong Kong Productivity Council* – develops new AI based segmentation and classification techniques. With this approach, image labeling is reduced from 20 seconds to less than 1 second and more than 1,400 working hours can be saved per factory, providing great potential quality improvement for production management and estimated savings of more than EUR 84,000. >

Künstliche Intelligenz kann die Produktqualität in der LCD-Herstellung verbessern. Der Einsatz fortschrittlicher Techniken der Künstlichen Intelligenz in realen Produktionslinien wird jedoch erschwert. Im wettbewerbsintensiven Umfeld der LCD-Herstellung für Smartphones, Monitore usw. müssen hohe Qualitätsstandards eingehalten werden. Diese Prozesse erfordern Präzision im Mikrometerbereich und sind sehr anfällig für Defekte, die z. B. durch Fremdkörper oder Fotolackreste verursacht werden. Daher ist die Verringerung der Ausschussrate von entscheidender Bedeutung, um den Ertrag im wettbewerbsintensiven Marktumfeld zu steigern. Der Einsatz von KI-basierten Fehlerprüfsystemen erlaubt, die Genauigkeit und Robustheit der Fehlererkennung zu verbessern, die Prüfzeit und -kosten zu reduzieren und letztendlich die allgemeine Produktqualität und Kundenzufriedenheit zu erhöhen. Trotz ihrer Vorteile hat sich die Technologie jedoch noch nicht vollständig in realen Produktionslinien durchgesetzt.

Einer der Hauptgründe für den begrenzten Einsatz von KI-Technologie in der Qualitätskontrolle ist die Tatsache, dass KI immer noch manuelle Arbeit für die Vorbereitung der Datensätze erfordert. Das Rückgrat der KI-basierten Bilderkennungsalgorithmen sind unüberwachte Lernmethoden wie *Convolutional Neural Networks (CNNs)*. Um CNNs auf die Produktionslinie anzuwenden, müssen sie auf Fehlerbilddaten trainiert werden. Dafür werden Fehlerbilddaten von der Produktionslinie gesammelt. Für gängige KI-Anwendungen werden 10 000 bis 30 000 Fehlerbilder für das Training benötigt. Die Bilddaten müssen für das Training vorbereitet werden, indem jedes Bild mit den Informationen versehen wird, die das KI-Modell zum Erlernen der Muster benötigt. Die KI-Fehlerprüfung für komplexe Anwendungsfälle erfordert Klassenlabels und Fehlermaskenlabels, die beide manuell ermittelt werden. Auf der einen Seite ordnen die Klassen-Labels jedes Bild einer bestimmten Fehlerklasse zu, z. B. aufgrund seiner Herkunft oder der betroffenen Materialien. Ein:e Expert:in ordnet also gemäß

Artificial intelligence can improve product quality in LCD manufacturing. However, their adoption of artificial intelligence techniques in real production lines is still hindered. In the competitive environment of LCD manufacturing for smartphones and monitors etc., high quality standards must be met. These processes require precision at the micrometer level and are very susceptible to defects caused, for example, by foreign particles or photoresist residue. Therefore, reducing product scrap rates is critical to enhance yield in the competitive market landscape. By using AI-based defect inspection systems, managers have the potential to improve defect detection accuracy and robustness, reduce inspection time and costs, and ultimately enhance overall product quality and customer satisfaction. However, despite its benefits, the technology still has not been fully adopted in real production lines.

One of the primary contributing factors to the limited use of AI-technology in quality control is, that AI requires manual labor for the preparation of the datasets. The backbone of AI-based image recognition algorithms are unsupervised learning methods such as *Convolutional Neural Networks (CNNs)*. To apply CNNs to the production line, CNNs need to be trained on defect image data. Therefore, defect image data is collected from the production line. Common AI applications require 10,000 – 30,000 defect images for training. The image data needs to be prepared for the training by labeling each image with information that is required for the AI model to learn the patterns. AI defect inspection for complex use cases requires class labels and defect mask labels that are both obtained manually. On the one side, class labels allocate each image to a certain defect class based on e. g. its origin or affected materials. A domain expert, therefore, assigns each defect image to a defect class according to a defect catalog that has been elaborated before. On the other side, the defect mask label represents



Figure 1 and 2:
Quality inspection is crucial in LCD manufacturing

It all began with an exceptional strategic collaboration between FLAIR, the Center Connected Industry (CCI), FIR, and our valued industry partner TCL.

Frankie Liu,
Head of Computer Vision, FLAIR



einem zuvor erstellten Fehlerkatalog jedes Fehlerbild einer Fehlerklasse zu. Auf der anderen Seite stellt das Fehlermasken-Label die Position des Fehlers auf dem Bild dar. Um die Defektmaske zu labeln, markiert der oder die Expert:in jedes Pixel des Defekts im Bild. Dieser Vorgang kann im Durchschnitt etwa 20 Sekunden dauern und ist damit zwanzigmal länger als die Markierung der Klassifikationslabels¹. Diese 20 Sekunden für etwa 15 000 beschriftete Bilder und 18 verschiedene Produkttypen ergeben eine geschätzte Vorbereitungszeit fürs Labeln von 1 500 Stunden für eine typische Fabrik. Da TCL acht Fabriken in China betreibt, beträgt das Einsparpotenzial 12 000 Stunden. Dies ist zeitaufwendig, da eine große Anzahl von Bildern benötigt wird und nur von geschultem Personal durchgeführt werden kann. Die Abhängigkeit von Fehlermasken-Label schränkt die Skalierbarkeit von KI-basierten, visuellen Inspektionsmethoden ein und erschwert deren Einsatz in großen Produktionslinien. Infolgedessen verlassen sich viele Fertigungsunternehmen nach wie vor auf herkömmliche visuelle Inspektionsmethoden, die zwar weniger genau, weniger robust und anfälliger für menschliche Fehler, aber einfacher zu implementieren sind.

Revolutionierung der Qualitätskontrolle: KI-Fortschritte für automatisierte Inspektion und Labeling

Die Idee, die Hürden für den Einsatz von KI in der Qualitätskontrolle zu beseitigen, führt zu der Frage, wie CNNs weiterentwickelt werden können, um den manuellen Labeling-Aufwand zu verringern. Ziel ist es, neue KI-basierte Algorithmen für die automatisierte Qualitätsprüfung zu entwickeln, die die Genauigkeitsanforderungen der Industrie erfüllen, ohne dass eine manuelle Kennzeichnung von Fehlermasken erforderlich ist. Ein Projektteam des *Hong Kong Industrial*

the location of the defect on the image. To label the defect mask, the domain expert marks each pixel of the defect in the image. This can take around 20 seconds in average and therefore 20 times longer than the classification label¹. Those 20 seconds for around 15,000 labeled images and 18 different product types result in 1,500 hours of estimated training time for one typical factory. As TCL has eight factories in China, the potential savings are 12,000 hours. This is time-consuming as vast number of images are needed and can only be done by trained personnel. Hence, the dependency on defect mask labels limits the scalability of AI-based visual inspection methods, making it difficult to apply them in large-scale production lines. As a result, many manufacturing companies still rely on traditional visual inspection methods, which are less accurate, less robust and more prone to human errors but are easier to implement.

Revolutionizing Quality Control: Advancements in AI for Automated Inspection and Labeling

The idea to resolve the hurdles for the use of AI in quality control, leads to the question of how CNNs can be advanced to reduce manual labeling effort. The goal is to develop new AI-based algorithms for automated quality inspection, that meets the accuracy requirements of the industry without the need for manual defect mask labeling. A project team of *Hong Kong Industrial Artificial Intelligence and Robotics Centre (FLAIR)* addresses this challenge. FLAIR develops AI-technologies for the manufacturing industry in *Guangdong-Hong Kong-Macau Greater Bay Area (GBA)*. FLAIR is integrated alongside a total of 28 labs within 'InnoHK', Hong Kong's flagship initiative to promote collaboration with global research institutes.² FLAIR collaborates on the one side with institutes and centers from

¹ s. BEARMAN ET AL. 2016, S. 554

¹ BEARMAN ET AL. 2016, p. 554



Through our collective teamwork, we have achieved remarkable strides in the development of cutting-edge AI algorithms for automated quality inspection in LCD production.

Benny Drescher,
CTO, FLAIR

Artificial Intelligence and Robotics Centre (FLAIR) nimmt sich dieser Herausforderung an. FLAIR entwickelt KI-Technologien für die verarbeitende Industrie in Guangdong-Hong Kong-Macau Greater Bay Area (GBA). FLAIR ist zusammen mit insgesamt 28 Laboren in die Leitinitiative InnoHK von Hongkong zur Förderung der Zusammenarbeit mit globalen Forschungsinstituten integriert.² FLAIR arbeitet zum einen mit Instituten und Zentren auf dem RWTH Aachen Campus zusammen, etwa dem Center Connected Industry (CCI) und dem FIR e. V. an der RWTH Aachen. Auf der anderen Seite kooperiert FLAIR mit Industriepartnern wie TCL, um langfristige Innovationen zu etablieren.

Das Projektteam erzielte wichtige Fortschritte in der KI-Technologie, insbesondere beim unüberwachten Lernen (*unsupervised learning*), die es ermöglichen, die manuelle Arbeit zu reduzieren. Die Expert:innen entwickelten KI-Technologien, die den Lablingprozess automatisieren können, sodass Produktionsunternehmen KI-basierte Qualitätsprüfungssysteme einfacher und schneller einführen können³. Insbesondere werden eine CAM-basierte Fehlersegmentierung und eine *feature-based ROI-cropping defect classification* mit einer Auto-Labling-Architektur vorgeschlagen, bei der die das zeitaufwendige Labling von Fehlern auf Pixelebene stark reduziert werden kann. Darüber hinaus kann auch der Aufwand des Qualitätskontrollpersonals für die Trainieren der KI-Modelle verringert werden, was besonders in der High-Mix-Produktion mit einer hohen Anzahl von Umstellungen und Produktionsprozessanpassungen wichtig ist. Insgesamt können mehr als 11 000 Stunden von den geschätzten 12 000 Stunden Labling-Zeit eingespart werden.

Das Projekt hat nun seine Endphase erreicht, denn der letzte Schritt besteht in der Validierung vor Ort mit dem Partner TCL. Die Validierung folgt einem strukturierten Ansatz. Zunächst halfen wir TCL, einen vorteilhaften Anwendungsfall zu identifizieren, führten technologische Schulungen durch und

RWTH Aachen Campus, such as the Center Connected Industry (CCI) and the Institute for Industrial Management FIR. On the other side, FLAIR collaborates with industrial partners such as TCL to establish long-term innovation.

The Project team made major advancements in AI technology, particularly in unsupervised learning, that make it possible to reduce manual labor. The experts developed AI technologies that can automate the labeling process, making it easier and faster for production companies to implement AI-based quality inspection systems³. In particular, CAM-based defect segmentation and feature-based ROI-cropping defect classification are proposed with auto-labeling architecture, where time-consuming pixel-level labeling of defects can be greatly reduced. Furthermore, the efforts of quality control personnel for model training can be also reduced which is especially important in high-mix production with a high number of changeovers and production process adjustments. In total more than 11.000 hours from the estimated 12.000 hours of training time can be saved.

The project has now reached its final stages as the remaining step is the on-site validation with the Partner TCL. The validation follows a structured approach. First, we helped TCL to identify a beneficial use case, had technological trainings and are tailoring the technology to their production environment to save more than 95 percents labeling effort. Together we will evaluate the results and assess further options for strategic implementation.

The exact steps include:

Kick Off: The first step was to define personalized use case for TCL, set expectations and requirements for the validation study. Here strategic and operational benefits were identified with interdisciplinary experts.

² s. WITTSTAMM ET AL. 2022, S. 28

³ LIU ET AL. 2022, S. 506 – 513

² WITTSTAMM ET AL. 2022, p. 28

³ LIU ET AL. 2022, pp. 506 – 513

passten die Technologie an ihre Produktionsumgebung an, um mehr als 95 Prozent des Labeling-Aufwands zu sparen. Gemeinsam werden wir die Ergebnisse auswerten und weitere Optionen für die strategische Umsetzung prüfen.

Die genauen Schritte umfassen:

Kick-off: Der erste Schritt bestand darin, den personalisierten Anwendungsfall für TCL zu definieren, Erwartungen und Anforderungen für die Validierungsstudie festzulegen. Hier wurden mit interdisziplinären Expert:innen strategische und operative Vorteile identifiziert.

Schulung & Trends zum Thema Computer Vision: TCL erhielt ein spezielles Training zur KI-basierten visuellen Fehlerinspektion und wurde über die neuesten Trends in diesem Bereich sowie über die neuartigen Lösungen auf dem RWTH Aachen Campus informiert.

Validierungsstudie: Die Validierungsstudie von TCL wurde erfolgreich abgeschlossen. Ziel war es, das KI-basierte visuelle Qualitätsprüfungssystem zu validieren. TCL stellte daher die erforderlichen Bilddatensätze und erweiterte technische Unterstützung zur Verfügung. Das Inspektionssystem wurde mit sehr wenigen gelabelten Bildern erfolgreich trainiert und validiert. Bei der Fehlersegmentierung wurde eine Erfassungsrate von 65 Prozent und eine Einschlussrate von 60 Prozent erreicht, was auf eine hohe Erkennungsgenauigkeit der Fehler hindeutet; die erkannten Masken können direkt als Label für die nicht gelabelten Bilder verwendet werden. Bei der Klassifizierung von Defekten wurde eine Klassifizierungsgenauigkeit von 80 Prozent erreicht, wobei nur die Klassenlabel zum Trainieren des Modells verwendet wurden. Insgesamt können etwa 80 Stunden manueller Labeling-Aufwand für das Training eines typischen KI-Modells für jeden Produktions-

Training & Trends Regarding Computer Vision: TCL received a dedicated training on AI based visual defect inspection and be briefed on the latest trends in the field as well as on the novel solutions from the RWTH Aachen Campus.

Validation Study: TCL's validation study is completed successfully. The aim was to validate the AI-based visual quality inspection system, therefore TCL provided the necessary imaging datasets and enhanced technical support. With very limited labeled images, the inspection system has been successfully trained and validated. For defect segmentation task, 65 percent coverage rate and 60 percent inclusion rate have been achieved which shows high detection accuracy of the defects, and the detected masks can be directly used as labels for the unlabelled images. For defect classification task, 80 percent classification accuracy has been achieved where only class labels are used to train the model. Overall, around 80 hours manual labeling effort can be saved for training a typical AI model for each production process, which potentially save TCL more than 11,000 hours for all its factories in China.

After the validation study, the aim is to assess the effectiveness and benefits of the AI-based visual quality inspection system by industry experts in the production line.

Let's Continue the Success Story: Expanding AI-Technology through Collaborative Partnerships

This successful story should now be continued with additional industrial partners. After successfully implementing the new AI-based quality inspection system in the manufacturing context, it is not only required to further develop the working models, but to repeatedly validate them in

FLAIR strives to transform technological advances into innovative, practical solutions for enterprises to achieve new industrialisation. By expanding the network of partners in validation and further cooperation, we look forward to helping more industries and enhancing the I&T ecosystem together.

*Edmond Lai,
CEO, FLAIR*





FLAIR Auto-Labeling system will enhance productivity and release labor from the unpleasant manual labeling task. The FLAIR solution will be of great benefit to the industry, solving the time-consuming manual processes in the production environments for defect labeling. The solution has the potential to be applied into a wide variety of industries and will enhance vision systems performance as well as contribute to the occupational health and safety for employee's vision protection. We thank the FLAIR team for the development conducted together with TCL.

*Dr. Dahai Yu,
General Manager, AI Director of TCL Corporate Research*

prozess eingespart werden, wodurch TCL potenziell mehr als 11.000 Stunden für alle seine Fabriken in China einsparen kann.

Nach der Validierungsstudie sollen die Wirksamkeit und die Vorteile des KI-basierten visuellen Qualitätsprüfungssysteme von Branchenexpert:innen in der Produktionslinie bewertet werden.

Setzen wir die Erfolgsgeschichte fort: Ausweitung der KI-Technologie durch Kooperationspartnerschaften

Nach der erfolgreichen Implementierung des neuen KI-basierten Qualitätsprüfungssysteme im Fertigungskontext ist es nicht nur erforderlich, die KI-Modelle weiterzuentwickeln, sondern sie auch wiederholt in realen Industrieumgebungen zu validieren. Um dies zu ermöglichen, arbeitet FLAIR an der Kommerzialisierung der Technologie und ermöglicht den Transfer in die Industrie. Der gegenwärtige Zeitpunkt bietet eine günstige Gelegenheit, weitere Kooperationen zu initiieren. Durch die Automatisierung des Labelingprozesses durch unüberwachtes Lernen hat das Projekt die Grenzen des manuellen Labelings überwunden und es Produktionsunternehmen erleichtert, KI-basierte Qualitätsprüfungssysteme einzuführen. TCL war neugierig und wurde zu einem frühen Anwender. Jetzt hat das Projekt das System erfolgreich offline validiert und arbeitet derzeit an der Online-Validierung und den technischen Anpassungen für die Implementierung in die Produktionslinie des Unternehmens.

*Liu · Drescher · Yu ·
Wittstamm · Becerra*

real-world industrial environments. To facilitate this, FLAIR is working on commercializing the technology and enable transfer to the industry. The current moment presents a favorable opportunity to initiate additional collaborations.

By automating the labeling process through unsupervised learning, the project has overcome the limitations of manual labeling and made it easier for production companies to implement AI-based quality inspection systems. TCL was curious and became an early adopter. Now the project has successfully validated the system offline and is currently working towards online validation and technical adjustments for implementation in their production line.

*Liu · Drescher · Yu ·
Wittstamm · Becerra*

Literatur:

BEARMAN, A.; RUSSAKOVSKY, O.; FERRARI, V.; FEI-FEI, L.: What's the point: Semantic segmentation with point supervision. In: Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part VII. Springer, Cham [u. a.] 2016, S. 554

LIU, C.; VAASSEN, S.; MANOJ, L.; ZHAN, X. Q.; XU, C.; RUDRA AJAY, S.; LU, Z. Y.; WITTSTAMM, M.; JAIN, S.; ZHANG, C.; DRESCHER, B.: Automatic Labeling in Image Segmentation and Classification for TFT-LCD Manufacturing, In: 2022 IEEE International Conference on Mechatronics and Automation (ICMA), Guilin, Guangxi, China, 2022, S. 506 – 513. DOI: 10.1109/icma54519.2022.9856233

WITTSTAMM, M.; DRESCHER, B.; ENGLÄNDER, J.: RWTH Aachen Campus erforscht Technologien der Künstlichen Intelligenz in der Fertigungsindustrie Hongkongs. In: UdZ – The Data-driven Enterprise 2 (2011) 3, S. 29 – 33.