ABSCHLUSSBERICHT: Fraunhofer-Center für Silizium-Photovoltaik (CSP)

VERBUNDVORHABEN: Optimierte Messtechnik für c-Si Solarzellprozesse durch kombinierte und vernetzte Messansätze sowie Machine Learning basierte Datenkonzepte (OptiLearn)

TEILVORHABEN: Inline-Messmethoden und Datenanalytik

FÖRDERKENNZEICHEN: 03EE1108A

LAUFZEIT DES VORHABENS UND BERICHTSZEITRAUM: 01.08.2021 – 31.12.2025

Berichtnummer: 032/2026

Gefördert durch:

Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

AUTOREN: Marko Turek, Manuel Meusel, Stephan Hensel

Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

Inhalt

TEIL I – Kurzbericht 3
Motivation und Gesamtziel des Vorhabens 3
Wissenschaftlich-technische Ziele, angestrebte Innovationen 3
Ablauf des Vorhabens und Arbeitsinhalte 3
Wissenschaftlich-technischer Stand, an den angeknüpft wurde 4
Wesentliche Ergebnisse 4

TEIL II – Eingehende Darstellung 5

1 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde 6
Bezug zu den förderpolitischen Zielen 6
Wissenschaftlich-technische Ziele, angestrebte Innovationen 6
Stand von Wissenschaft und Technik, an den angeknüpft wurde 7
Zusammenarbeit mit anderen Stellen 7

2 Erzielte Ergebnisse 9

3 Veröffentlichungen 25

TEIL I – Kurzbericht

Motivation und Gesamtziel des Vorhabens

Ein wesentlicher Ansatzpunkt für die fortschreitende Kostensenkung in Solarzell-produktionsprozessen ist die Steigerung der Overall-Equipment-Effectiveness OEE sowie verkürzter Entwicklungszyklen zur Einführung effizienzsteigernder technologischer PV-Innovationen. Die Steigerung der OEE-Kennzahl wird durch Qualitätssteigerungen im Produktionsprozess (d.h. Reduktion der Anzahl fehlerhafter Solarzellen), Erhöhung der Linienperformance (d.h. ein Betrieb im Prozessoptimum mit durchgängig hohen Zellwirkungsgraden) sowie Erhöhung der Verfügbarkeit der Linien (d.h. minimale Wartungs- und Ausfallzeiten) erreicht. Ein wesentlicher Beitrag zur Verkürzung von Entwicklungszyklen liegt in der systematischen Erfassung und korrelativen Auswertung von Messdaten aus der Produktion im Wechselspiel mit der Entwicklung.

Wissenschaftlich-technische Ziele, angestrebte Innovationen

Die geplanten Arbeiten mit starkem Fokus auf neuen Messverfahren und –applikationen sowie der Datenverarbeitung sollten die Industriepartner befähigen, im kostengetriebenen Photovoltaikmarkt auch zukünftig weiter ihre Zuliefererrolle wahrnehmen und wettbewerbsfähig bleiben zu können. Das Fraunhofer CSP hat im Projekt die folgenden drei wesentlichen Projektziele verfolgt:

1. Bereitstellung einer angepassten MK4-Linie sowie des MES und der Datenbanken für neue inline-Messmethoden und digital verknüpfter Messketten
2. Etablierung neuer Messabläufen in der MK4-Linie, die neue Messapplikationen beinhalten und mehrere Messvorgänge digital verknüpft
3. Bereitstellung von Algorithmen zur Auswertung großer Datenmengen mit Ziel der Anwendbarkeit in Produktionsumgebungen

Im Rahmen der Projekterweiterung „OptiLearn Next" sollten die vier zusätzlichen Ziele erreicht werden: Anpassung der MK4-Plattform auf neue Zellgrößen bis M10/G12; Erweiterung auf neue Zelltechnologien (vor allem busbarlose Zellen oder Rückkontakt-zellen); Ergänzung der Linie um ein zusätzliches Automatisierungsmodul; Aufbau automatisiertes, flexibles Zellsortiersystems.

Ablauf des Vorhabens und Arbeitsinhalte

Das Teilvorhaben am Fraunhofer CSP war in neun Arbeitspakete AP-1 – AP-9 sowie ein zusätzliches Arbeitspaket AP-Z im „OptiLearn Next" untergliedert: AP 1 Non-STC in-line Leistungsmessungen mittels LED Sonnensimulator; AP 2 Integration LBIC-Mess-methoden in den in-line LECO Prozess; AP 3 Aktive, zeitaufgelöste IR-Bildgebung; AP 4 Demonstration Messmethoden und Datenerzeugung (MK4-Plattform); AP 5 Datenbanksystem, Datenaufbereitung und MES; AP 6 Datenanalyse und KI zur Bildklassifizierung und Anomaliedetektion; AP 7 Machine Learning zur Klassifizierung spektraler non-STC-Messungen; AP 8 Erkennung Produktionsdrifts (Predictive Maintenance, Zeitreihenanalyse); AP 9 Erkennung Korrelationen und quantitativer Zusammenhänge in Messketten; sowie AP Z: Anpassung, Erweiterung der MK4-Messplattform auf zukünftige Zelltechnologien.
In allen APs erfolgten während des Projektes Arbeiten, die in den jeweiligen Zwischenberichten dokumentiert waren. Die folgenden Meilensteine waren dabei für das CSP definiert: Meilenstein MS-CSP1 (AP1.2, CSP, nach 9 Monaten): Vorversuche auf Labortool für ein non-STC Verfahren (z.B. LED-EQE, LED-REFL, LED-LowLight) abgeschlossen; Meilenstein MS-CSP2 (AP4.3, CSP, nach 15 Monaten): Erster Datensatz

zu non-STC-Messungen in MK4-Linie steht zur Auswertung bereit; Meilenstein MS-CSP3 (AP8.2, CSP, nach 24 Monaten): Algorithmen zur Dimensionsreduktion und Clusteranalyse für MK4 Daten stehen bereit. Im „OptiLearn Next“ wurde als wesentlicher Meilenstein wird die finale Festlegung der wesentlichen technischen Spezifikationen für die Erweiterungen der MK4-Linie festgelegt. Dieser Meilenstein sollte nach dem ersten Projektquartal vom „OptiLearn Next“ erreicht sein.

Wissenschaftlich-technischer Stand, an den angeknüpft wurde

Zu Projektbeginn war der Trend erkennbar, dass PV-Produktionsanlagen zunehmend mit Messtechnik, vor allem Bildgebung, und in-line-Sensorik ausgestattet wurden. Zum einen erfolgte für jede Solarzelle eine Strom-Spannungskennlinien-Messung (I-V-Messung), zum anderen wurde eine Prüfung der Zellen auf lokale Defekte mittels optischer Inspektion und Elektrolumineszenz durchgeführt. Daneben gab es zum Projektstart eine Vielzahl an Methoden, die grundsätzlich für den in-line Einsatz geeignet waren, wie z.B. schnelle EQE-Messungen. Eine umfassende und automatisierte Datenanalyse unter Einbeziehung der Korrelation verschiedener Datenquellen sowie datenintensiver neuer Messmethoden war erst im Anfangsstadium. Der Vorteil neuer Methoden und deren Korrelation blieb damit vielfach ungenutzt, auch weil hierfür die passenden Algorithmen und Datenstrukturen fehlten. Im Bereich der Datenauswertung fanden hinsichtlich der quantitativen Messungen weitgehend nur niedrigdimensionale Korrelationsanalysen statt. Für die bildgebenden Methoden wurden zunehmend Neuronale Netze zur Defekterkennung an EL-Bildern eingesetzt. Für den Laser Enhanced Contact Optimization Process (LECO) wurde vor Projektstart bereits nachgewiesen, dass damit eine deutliche Reduktion des Serienwiderstands durch einen verbesserten Metall-Halbleiter-Kontakt erreicht werden kann. Die Erweiterung des Prozesses auf eine Messung zur Erlangung komplementärer Informationen war noch Gegenstand der Forschung.

Wesentliche Ergebnisse

Im Projekt wurde in allen APs neue Ergebnisse erzielt, z.B.

- Umbau und Anpassungen der Lab-to-fab Plattform MK4 an neue Zellformate und neue Messmethoden sowie Entwicklung hoch-flexibler Zellsortierplatz
- Entwicklung inline-tauglicher non-STC Messverfahren mittels LED-Lichtquellen
- Integration und Evaluierung LECO-LBIC in inline-Umgebung
- Beschleunigte, damit in-line taugliche, IR-Bildgebung
- Kombination KI-basierter EL-Bildanalyse mit quantitativen I-V-Messungen
- Simulationstool zur Erzeugung von Trainings- und Testdatensätzen
- Algorithmen zur Erkennung von Drift und Anomalien in Produktionsdaten

Dabei wurden die ursprünglich geplanten Meilensteine jeweils erreicht.

TEIL II – Eingehende Darstellung

1 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Das Projekt ist als Anschlussprojekt an das Projekt „MK4.0" (FKZ 03EE1040) zu sehen, in dem eine industrienahe, automatisierte Testinsel inklusive eines LECO-Tools und LED-Sonnensimulators aufgebaut wurde.

Bezug zu den förderpolitischen Zielen

Das Verbundvorhaben orientierte sich an den Zielen des 7. Energieforschungsprogramms gemäß der Bekanntmachung des Bundesministeriums für Wirtschaft und Energie vom 1. Oktober 2018 „Innovationen für die Energiewende". Übergeordnetes Ziel der Bundesregierung war es, Technologien zu fördern, die dazu beitragen, den Ausbau der erneuerbaren Energien voranzutreiben und eine Reduktion der Treibhausgase zu erzielen. Daneben sollte die heimische Wirtschaft gestärkt werden, indem Beiträge zu deren Modernisierung geleistet werden, z.B. auf dem Gebiet der Digitalisierung. Das Projekt „OptiLearn" adressiert vorrangig den Schwerpunkt „Energieerzeugung – Photovoltaik" im Hinblick auf eine Weiterentwicklung der Produktionstechnologien (Abschnitt 3.5.1). Insbesondere sollte im Vorhaben ein Beitrag geleistet werden zur „weitergehenden Prozesskontrolle" und zu „umfassender Überwachungs-, Analyse- und Prognosetechnik im Zuge der Digitalisierung (Big-Data-Analyse) und Automatisierung, wie die sich selbst überwachende beziehungsweise steuernde Fabrik (Industrie 4.0)". Weiterhin sollten Aspekte der künstlichen Intelligenz und Digitalisierung in der Industrie, vor allem in der Produktion adressiert werden (Abschnitt 3.2.9 b), vorrangig zu „Innovationen bei der Mess-, Steuer- und Regelungstechnik" und „Verarbeitung großer Datenmengen und unscharfer Daten im industriellen Kontext".

Wissenschaftlich-technische Ziele, angestrebte Innovationen

Die geplanten Arbeiten mit starkem Fokus auf neuen Messverfahren und –applikationen sowie der Datenverarbeitung sollten die Industriepartner befähigen, im kostengetriebenen Photovoltaikmarkt auch zukünftig weiter ihre Zuliefererrolle wahrnehmen und wettbewerbsfähig bleiben zu können. Die Entwicklungen setzten dabei zunächst an aktuellen Zell- und Modultechnologien an. Es sollen zwei wesentliche wissenschaftlich-technische Ziele im Projekt erreicht werden:

- Erforschung neuer hochdurchsatztauglicher in-line Messmethoden (LECO-LBIC; LED-EQE, -REFL, -LowLight) und verknüpfter Messketten sowie methodenspezifischer, automatisierter und intelligenter Datenverarbeitung der dadurch stark anwachsenden Datenmenge, z.B. Machine Learning Algorithmen für automatisierte Anomalieerkennung;
- Erforschung von automatisierbaren, universellen Algorithmen und Datenbanklösungen für PV-Produktionsumgebungen mit Fokus auf frühzeitiger, automatisierter Erkennung von Korrelationen zwischen Zellperformance und Prozessparametern, Produktionsdrifts sowie Mustererkennung in Mess- und Bilddaten über neuronale Netze und Machine Learning Ansätze

Das Fraunhofer CSP hat dabei die folgenden drei wesentlichen Projektziele verfolgt:

4. Bereitstellung einer angepassten MK4-Linie sowie des MES und der Datenbanken für neue inline-Messmethoden und digital verknüpfter Messketten
5. Etablierung neuer Messabläufen in der MK4-Linie, die neue Messapplikationen beinhalten und mehrere Messvorgänge digital verknüpft

6. Bereitstellung von Algorithmen zur Auswertung großer Datenmengen mit Ziel der Anwendbarkeit in Produktionsumgebungen

Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Stand von Wissenschaft und Technik, an den angeknüpft wurde

Ein zentraler Ansatz, Kostensenkungspotentiale in der PV-Industrie zu realisieren, ist die Steigerung der Overall-Equipment-Efficency OEE von Produktionslinien. Dabei spielt die Messtechnik und die Datenanalytik eine wesentliche Rolle, die durch die Messgerätehersteller umfänglich abgedeckt werden muss. Dabei war der Trend erkennbar, dass PV Produktionsanlagen zunehmend mit Messtechnik, vor allem Bildgebung, und in-line-Sensorik ausgestattet werden.

Hinsichtlich der Inline-Bewertung von Solarzellen stellten zu Projektbeginn zwei Messmethoden die wesentliche Grundlage dar. Zum einen erfolgte für jede Solarzelle eine Strom-Spannungskennlinien-Messung (I-V-Messung) unter normierten Beleuchtungsbedingungen. Zum anderen wurde in einer großen Vielzahl von Produktionslinien eine Prüfung der Zellen auf lokale Defekte mittels optischer Inspektion und Elektrolumineszenz durchgeführt. In allen Fällen (I-V-Kennlinie, optische Inspektion, EL-Bild) erfolgte die Datenanalyse primär über regelbasierte Auswertungen.

Daneben gab es zum Projektstart eine Vielzahl an Methoden, die grundsätzlich für den in-line Einsatz geeignet sind bzw. deren Eignung als Proof-of-Concept nachgewiesen wurde. Dazu zählen non-STC-Messungen, wie z.B. eine schnelle EQE-Messung oder Messungen unter modifizierten Intensitäten mittels LED-Sonnensimulatoren, ortsaufgelöste Messungen, wie z.B. Infrarotbildgebung IR oder light beam induced current LBIC. Eine umfassende und automatisierte Datenanalyse unter Einbeziehung der Korrelation verschiedener Datenquellen sowie datenintensiver neuer Mess-methoden war jedoch erst im Anfangsstadium. Der Vorteil neuer Methoden und deren Korrelation blieb damit vielfach ungenutzt, auch weil hierfür die passenden Algorithmen und Datenstrukturen fehlten.

Insbesondere waren auch spektrale in-line Messmethoden, die eine Unterscheidung zwischen Vorder- bzw. Rückseite von Volumeneffekten ermöglicht, nicht Stand der Technik. Eine Realisierungsmöglichkeit war unter Laborbedingungen mittels LED-Sonnensimulatoren bereits als Proof-of-Concept nachgewiesen. Für den Laser Enhanced Contact Optimization Process (LECO) wurde vor Projektstart bereits vielfach nachgewiesen, dass damit eine deutliche Reduktion des Serienwiderstands durch einen verbesserten Metall-Halbleiter-Kontakt erreicht werden kann. Die Erweiterung des Prozesses auf eine Messung zur Erlangung komplementärer Informationen war noch Gegenstand der Forschung und nicht für den Einsatz in einer Produktionsumgebung verfügbar. Im Bereich der Datenauswertung fanden hinsichtlich der quantitativen Messungen weitgehend nur niedrigdimensionale Korrelationsanalysen statt. Für die bildgebenden Methoden wurden zunehmend Neuronale Netze zur Defekterkennung an EL-Bildern eingesetzt. Aus wissenschaftlichen Arbeiten war die selbstständige Anomaliedetektion als Machine-Learning Methode bekannt, allerdings noch nicht für bildgebende Verfahren in der PV entwickelt. Ein modulares, universelles Bilderkennungssystem, welches mit geringem Trainingsaufwand sowohl für EL, als auch IR und (LECO-)LBIC einsetzbar ist, existierte zum Projektstart noch nicht.

Zusammenarbeit mit anderen Stellen

Im Vorhaben erfolgte eine enge Zusammenarbeit mit den Projektpartnern in Verbund. Für die Entwicklung der non-STC Methoden mittels LED-Sonnensimulatoren gab es eine direkte und enge Kooperation mit WAVELABS. Insbesondere der Abgleich zwischen realisierbaren Messrezepten und der Hardware spielte dabei eine große Rolle.

Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Ebenso wurde die Relevanz und Anwendbarkeit von neuen Messansätzen intensiv diskutiert und floss in das Projekt ein. Mit der Kontron AIS gab es enge Wechselwirkung zum MES, welches auch für die MK4 als Modellsystem implementiert ist. Hierbei konnten vor allem Fragen zur sicheren Datenerfassung von verschiedenen Datenquellen zielgerichtet adressiert werden. CE Cells war der zentrale Partner für die Weiterentwicklung der LECO-LBIC Methoden. So konnte durch die enge Verknüpfung im Projekt ein Modell des Messprozesses entwickelt werden, welches die Gemeinsamkeiten bzw. Unterschiede zu anderen bildgebenden Messverfahren (z.B. EL) beschreiben kann. Die Zusammenarbeit mit XACTools bzw. DENKweit hat sich sehr positiv auf die Entwicklung und praxisnahe Anwendung von KI-basierten Bildanalyse-Tools ausgewirkt. Insbesondere die Frage zur Korrelation von EL-Bilder mit IV-Messdaten konnte so adressiert werden. Für den Bereich der IR-Bildgebung, vor allem zur zeitabhängigen Bildauswertung war die Kooperation mit InfraTec zielführend. Die untersuchten Messrezepte wurden in enger Abstimmung zur Kamera-Hardware und den vorhanden Software-Möglichkeiten durchgeführt.
Neben diesen konkreten Punkten zur Zusammenarbeit gab es vielfachen Austausch, z.B. auf den Projekttreffen, hinsichtlich Proben bzw. fachlichen Fragestellungen und deren industrieller Relevanz.

2 Erzielte Ergebnisse

Im Folgenden werden die wichtigsten Ergebnisse in den einzelnen Arbeitspaketen zusammengefasst:

AP 1 Non-STC in-line Leistungsmessungen mittels LED Sonnensimulator

Zunächst wurde eine technische Analyse und Abstimmung für die Implementierung von non-STC Messungen vorgenommen und bewertet, welche davon technisch realisierbar sind und einen Mehrwert in der inline-Anwendung bringen können. Anschließend wurden Messrezepte mit Fokus auf eine rapid-EQE sowie eine Voc-Decay Messung implementiert. Die erzeugten Datensätze für unterschiedliche Zellgruppen wurden zunächst statistisch hinsichtlich Verteilung und Korrelationen analysiert, s. Beispiel rapid-EQE in Abbildung 1.

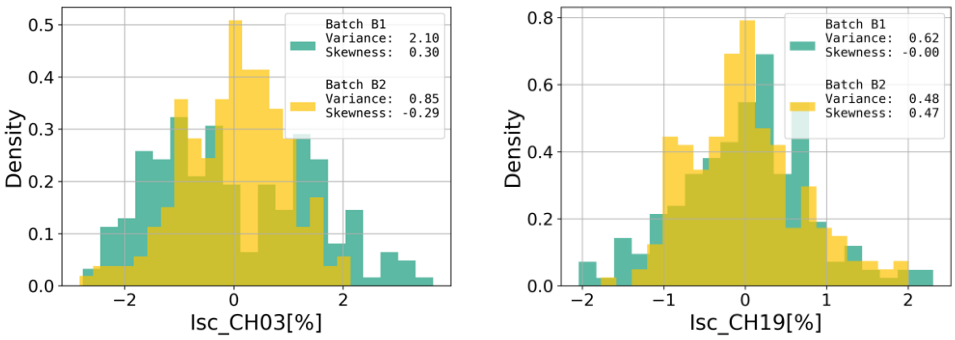

Abbildung 1: Verteilung der Ströme bei kurzen Wellenlängen (links) und bei langen Wellenlängen (rechts) für die Zellbatches B1 und B2.

Zur Validierung und Weiterentwicklung des rapid-EQE Verfahrens wurden weitere Testkampagnen mit größeren Stückzahlen an Zellen durchgeführt und dabei die rapid-EQE Daten zwischen 370nm und 1010nm erfasst. Parallel wurden EQE-Messungen an ausgewählten Zellen auf Labor-Tools durchgeführt, um die Relevanz der rapid-EQE Messungen zu untermauern, s. Abbildung 2. Dabei konnte gezeigt werden, dass sich die Unterschiede in der rapid-EQE Messung auf Unterschiede in der Zell-EQE zurückführen lassen.

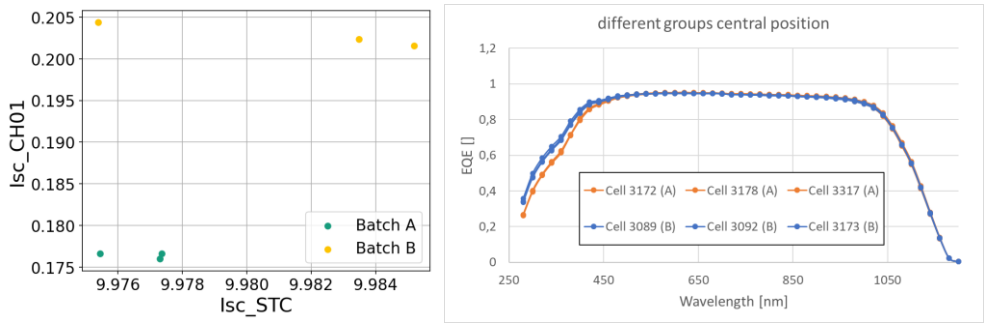

Abbildung 2: (links) Auswahl von jeweils drei repräsentativen Zellen: B1a mit niedriger und B1b mit hoher 370nm EQE. (rechts) Messdaten der kompletten offline EQE zeigen einen klaren Unterschied im Bereich zwischen 270nm und 440nm.

Ebenso wurden produktionsrelevante Analysemethoden implementiert, die Drifts in den Daten mit hoher Sensitivität erkennbar machen. Dabei hat sich herausgestellt, dass z.B. eine Drift in den langwelligen rapid-EQE Messungen auf den Messvorgang selbst, jedoch nicht auf die Zellqualität zurückführbar ist. Auf dieser Grundlage wurde eine

Driftkorrektur in die Datenanalyse integriert, um Schwankungsbreiten in den Verteilungen korrekt zu quantifizieren. Auf diese Weise konnte für zwei exemplarische Zellgruppen nachgewiesen werden, dass Schwankungen in den STC-Werten des Isc nicht nachweisbar sind, jedoch gut in einzelnen rapid-EQE Messungen, s. Abbildung 3.

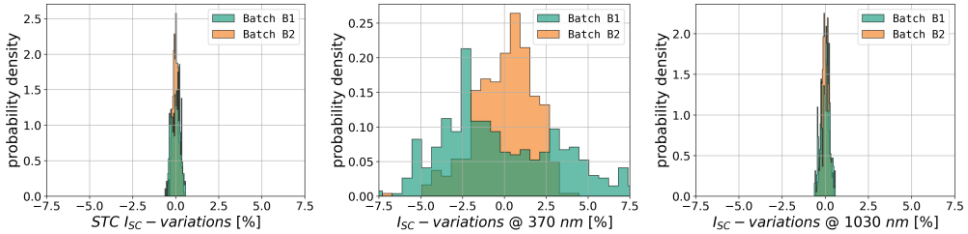

Abbildung 3: (links) Verteilung der Isc-Stromwerte für Zellbatch B1 und B2, (mitte) Verteilung der Schnell-EQE-Werte für 370nm Wellenlänge, (rechts) Verteilung der Schnell-EQE-Werte für 1030nm Wellenlänge.

Auf Grundlage dieser Ergebnisse wurde die rapid-EQE Methode als sehr wertvoll bewertet, da sie kleine Unterschiede in verschiedenen Zellgruppen identifizieren kann. Deshalb wurde in einem weiteren Versuch das Augenmerk auf die Quantifizierung der Wiederholstabilität der Methode gelegt. Dadurch wurde nachgewiesen, dass die Methode messtechnisch stabil genug ist, um Unterschiede zwischen einzelnen Zellen der untersuchten Zellgruppe nachzuweisen. Analoge Betrachtungen wurden hinsichtlich der Voc-Decay und rapid-REFL Methoden durchgeführt, allerdings in reduzierter Tiefe, da die Aussagekraft im Vergleich zur rapid-EQE Methode im Projekt als niedriger eingestuft wurde.

AP 2 Integration LBIC-Messmethoden in den in-line LECO Prozess

Zum Projektstart erfolgt ein Austausch mit CE Cells hinsichtlich technischer Realisierungsoptionen eines Messverfahrens basierend auf der LECO-Einheit unter Einbeziehung der Spezifikationen der bekannten Labor-LBIC-Verfahren. Darauf basierend hat CE Cells die Umsetzung einer entsprechenden Lösung geplant, wobei die Qualität der Datenerfassung im Kontext der zu erreichenden Messgeschwindigkeit zentraler Forschungsgegenstand war. Zunächst wurde dann ein LECO-LBIC Demoaufbau bei CE Cells realisiert und erste Datensätze mit Referenzdaten aus den Labormessgeräten am CSP verglichen. Parallel wurde dazu ein Python-basiertes Simulationstool am CSP entwickelt, um den Einfluss der LECO-LBIC Parameter, z.B. der Spannung, besser bewerten zu können. Nach den ersten proof-of-concept Versuchen wurden spezielle Testzellen mit unterschiedlichen Fehlerbildern präpariert, s. Abbildung 4. Die Messsignale der unterschiedlichen Defekte wurden im Detail quantitativ hinsichtlich ihrer Kontrastverhältnisse analysiert. Dabei wurde nachgewiesen, dass das Modell diese Kontrastverhältnisse in Abhängigkeit von den Messparametern gut reproduzieren kann.

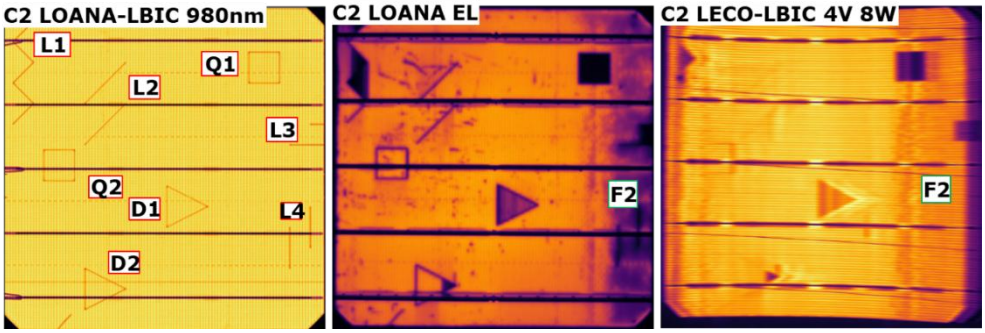

Abbildung 4: (links) Zelle mit präparierten Liniendefekten (L1-L4) und Flächendefekten (D1, D2, Q1, Q2) sowie bereits vorhandenen Bereichen reduzierter Qualität (F2): konventionelle offline LBIC-Messung, (mitte) konventionelle EL-Messung, (rechts) LECO-LBIC Verfahren mit Potential zur inline-Anwendung.

Im Anschluss an diese vielversprechenden Vorversuche wurde eine Messeinheit von CE Cells für die MK4-Plattform entwickelt und integriert, s. Abbildung 5.

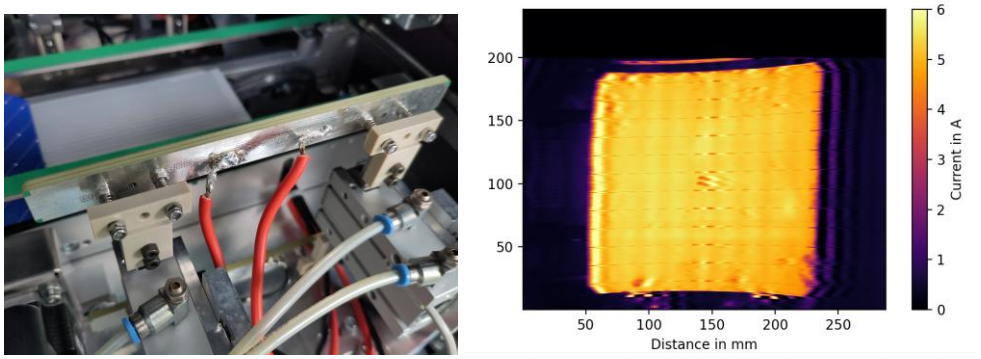

Abbildung 5: (links) Optimierte Kontaktierung der LECO-LBIC Messeinheit in der MK4-Linie. (rechts) Messergebnis der integrierten LECO-LBIC Messeinheit.

Dabei wurden sukzessive relevante Integrationsprobleme behoben und Optimierung, z.B. an der Kontaktierung, vorgenommen. Ebenso wurde die Messdatenqualität verbessert. Dabei hat sich jedoch auch herausgestellt, dass insbesondere bei den hohen Geschwindigkeiten eine Überschwingverhalten der Messelektronik auftritt, welches zu Bildartefakten führt. Es wurden im Projekt Lösungsansätze – sowohl softwareseitig als auch hardwareseitig – konzipiert und teilweise auch praktisch getestet, allerdings konnte das Überschwingverhalten im Projekt nicht komplett durch CE Cells behoben werden. Trotzdem stellt das Projektergebnis einen vielversprechenden Ansatz dar, um LBIC-artige Informationen in direkte Kombination mit der LECO-Prozessierung zu realisieren.
Eine statistische Analyse über die Stabilität in der Quantität der LECO-LBIC Bildgebung wurde mit den etablierten bildgebenden Methoden der Elektrolumineszenz (EL) und Photolumineszenz (PL) verglichen. Dabei wurde ein Zellbatch von etwa 150 Zellen 4-mal gemessen. Für jede bildgebende Methode wurde eine Region (ROI) ausgewertet, die den Großteil der Solarzelle umfasst und davon der Mittelwert als Maß für die mittlere Helligkeit der Solarzelle ermittelt. Weiterhin wurden zwei verschiedene Normierungsarten verglichen. Zum einen wurde auf alle Messdaten normiert und zum anderen auf die Messdaten derselben Zelle, wodurch der Einfluss der Zellparameter auf das Ergebnis minimiert wird.

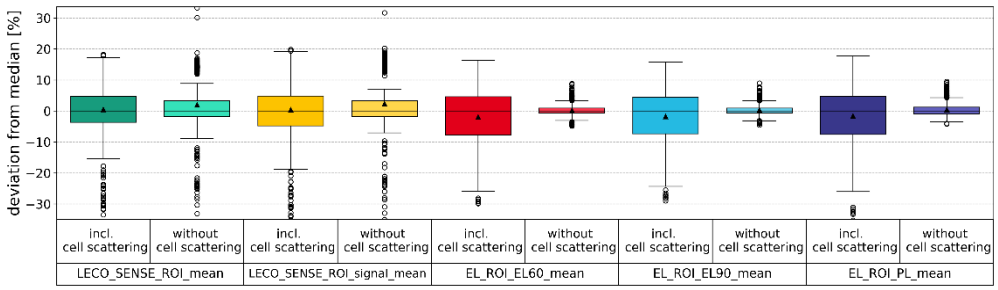

Abbildung 6: Statistischer Boxplot-Vergleich verschiedener Bildgebender Methoden hinsichtlich der Wiederholstabilität. Die Wiederholstabilitätsanalyse der LECO-LBIC Bildgebung (in der Abbildung als „LECO SENSE" bezeichnet) zeigt nur kleinere Unterschiede zur Wiederholstabilität der EL- und PL-Bildgebung.

Dabei zeigt die LECO-LBIC-Bildgebung eine etwas geringere Empfindlichkeit gegenüber Zellunterschiede (Vergleich Boxbreite „incl. cell scattering") im Gegenzug aber eine etwas höhere Ungenauigkeit im Vergleich zu EL und PL-Bildern, wenn die Zellunterschiede mittels zellgenauer Normierung nicht berücksichtigt werden (Vergleich Boxbreite „without cell scattering". Im untersuchten Zellbatch übersteigen die Zellunterschiede die Messschwankungen, sodass die quantitativen Messwerte der LECO-LBIC Methode für weitere Auswertungen (z.B. Korrelationsanalyse) verwendet werden können.

AP 3 Aktive, zeitaufgelöste IR-Bildgebung

Zunächst wurde ein Probensatz Solarzellen mit spezifischen Defekten sowie Referenzzellen präpariert. Dafür wurde ein Verfahren entwickelt, um reproduzierbar lokale, strominduzierte Defekte, die als Wärmequellen aktiv werden, zu erzeugen. Ebenso wurde ein IR-Messplatz weiterentwickelt, um auch zeitaufgelöste Messungen durchführen und Solarzellen kontaktieren zu können. Mit diesen Proben und dem Testsetup wurden erste Temperatur-Zeit-Datensätze erfasst, s. Beispiel in Abbildung 7. Dabei wurde die Qualität des Messsystems quantifiziert, in dem die Messunsicherheit bestimmt wurde. Es zeigte sich, das lokale Temperaturmessungen mit ca. +/- 40mK erfasst werden können.

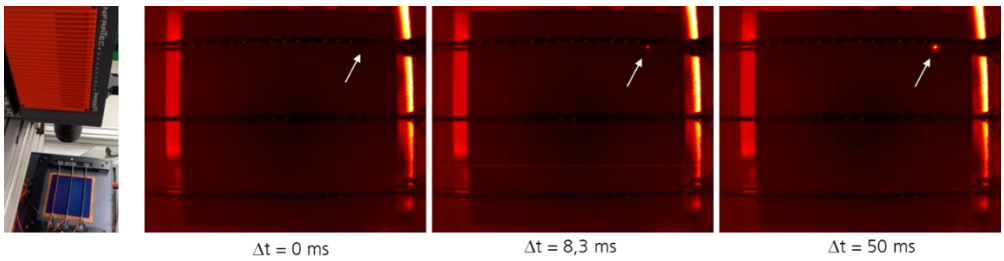

Abbildung 7: (links) Foto der Messkonfiguration aus Perspektive der IR-Kamera. (3 Bilder rechts) Sequenz von 3 aus der gesamten Bildserie ausgewählten Bildern zu unterschiedlichen Zeitpunkten nach Bestromung der Zelle. Der Wärmepunkt ist mit einem Pfeil markiert.

Insbesondere der zeitliche Verlauf ist bei schnellen Messungen relevant, da dieser das thermische Einschwingverhalten bzw. in längeren Zeiten die maximale Temperatur widerspiegelt, s. Abbildung 8.

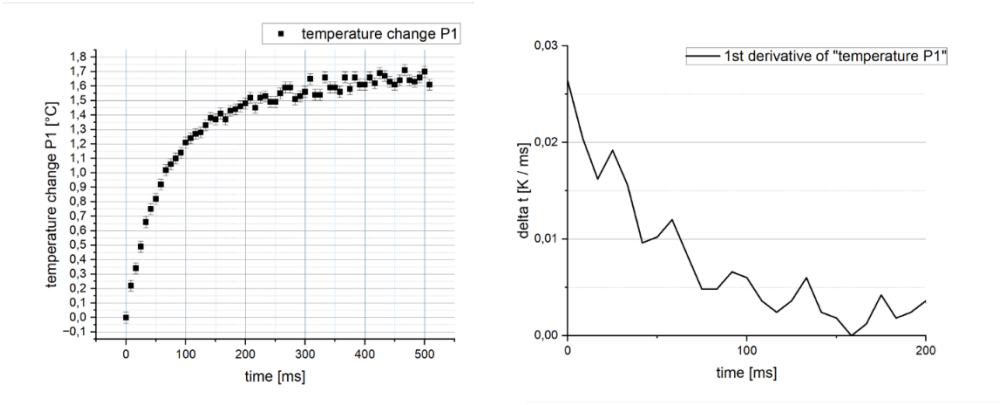

Abbildung 8: (links) Aus den Messdaten bestimmte Temperaturerhöhung gegenüber der Ausgangstemperatur aufgetragen gegen die Zeit. (rechts) Zeitabhängige Temperaturerhöhung durch Ableitung der Temperatur nach der Zeit.

Mit dem dadurch validierten Verfahren wurden verschiedene Solarzelltypen vermessen. Zu Datenanalyse wurde ein Model für die zeitliche Erwärmung implementiert, das es ermöglicht, die wesentlichen Parameter der Ausgangs- bzw. Umgebungstemperatur, der finalen Gleichgewichtstemperatur sowie der Zeitkonstanten zu bestimmten.
Basierend auf diesem Ansatz wurde anschließend erforscht, welche Reduzierung der Messpunkte zur Beschleunigung der Messungen noch möglich ist, ohne die drei wesentlichen Parameter signifikant zu verändern. Damit ist es z.B. möglich, eine Messung bereits deutlich vor Erreichen der finalen Gleichgewichtstemperatur zu beenden und trotzdem diese Temperatur aus den Messdaten zu gewinnen.
In einem letzten Schritt wurde der Aufbau und das Messverfahren schließlich erweitert, um auch in einem erweiterten Spannungsbereich bis 1kV Messungen durchführen zu können. Das ist im Kontext der Hochspannungsisolation der Verkapselung von PV-Modulen relevant. Die Einsatzbereitschaft dieses erweiterten Aufbaus wurde mittels definierter, technischer Widerstände geprüft und nachgewiesen.

AP 4 Demonstration Messmethoden und Datenerzeugung (MK4-Plattform)
Zu Projektbeginn wurde die MK4-Testplattform umgebaut und erweitert, so dass flexibel Zellformate bis M6 durch die Linie transportiert werden können.

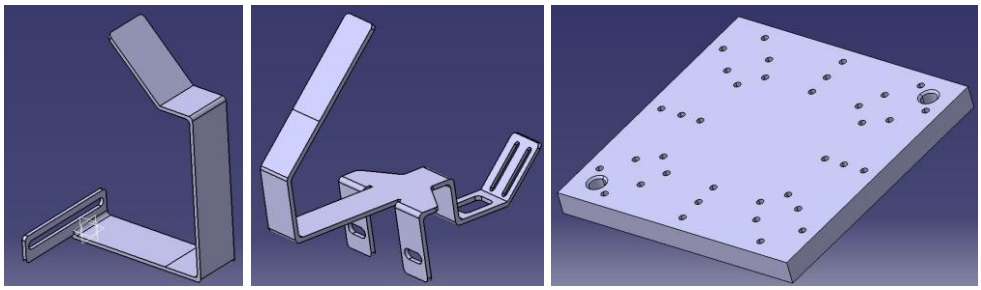

Abbildung 9: Konstruktionszeichnungen verschiedener neuer Bauelemente (links, mitte: Reflektorhalter; rechts: Basisplatte Zellbox) zur Anpassung der MK4-Plattform an M6-Zellformate.

Es wurde weiterhin ein Bar-Code Reader implementiert, der ein individuelles Zell-Tracking erlaubt. Für die Datenanalyse wurde ein Web-basiertes Dash-Board entwickelt, in dem sich per Remote-Zugriff die Daten eines Experimentes visualisieren lassen. Für alle diese Erweiterungen wurden Test-Runs durchgeführt, um die stabile Funktion der MK4-Plattform in der Erweiterung sicherstellen zu können. Dabei hat sich gezeigt, dass

z.B. weitere Optimierungen bzgl. des Kontaktrahmens, s. Abbildung 10, oder der Beleuchtung für den Bar-Code-Reader nötig sind. Ebenfalls waren dafür Anpassungen am MES notwendig, um die Bar-Code-Daten korrekt allen Messdaten zuzuordnen.

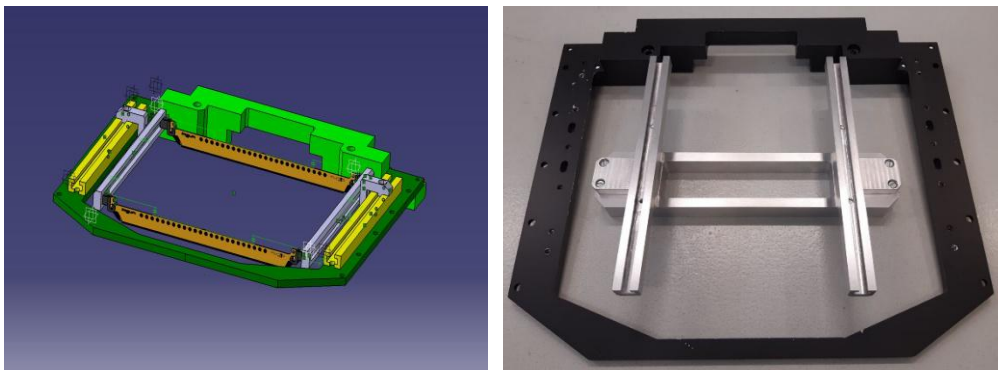

Abbildung 10: (links) Konstruktion des neuen Rahmens, (rechts) gefertigter neuer Rahmen zur Aufnahme der Kontaktleisten.

Nach der Umsetzung der Erweiterungen wurden jeweils die Experimente zur Erstellung von Datensätzen für die statistische Bewertung des Markierungsprozesses, des LECO-Prozesses und der Kontaktiergenauigkeit wurden durchgeführt.

AP 5 Datenbanksystem, Datenaufbereitung und MES

Im Rahmen des Projektes wurden zusätzliche Datenquellen in das MES eingebunden. Dafür wurden zunächst mit Projektpartner Kontron AIS die Schnittstellen definiert, vor allem, um ein Zellindividuelles Tracking basierend auf den Bar-Code-Informationen auch bei Wiederholungsexperimenten zu ermöglichen. Zusammen mit Kontron AIS wurden ein Python-Backend installiert und getestet. Das CSP hat dabei Kontron bei der Identifikation von Fehlern basierend auf realen Messkampagnen unterstützt. Schließlich wurde systematisch analysiert, welche Messparameter in der Testplattform noch vorliegen, jedoch noch nicht vom MES erfasst werden. Ebenso wurden freie, dynamische Parameter eingeführt, die bei späteren Erweiterungen genutzt werden können, ohne die interne Struktur des MES selbst nochmals anpassen zu müssen. Dadurch wird eine höhere Flexibilität für zukünftige Weiterentwicklungen erzielt.

AP 6 Datenanalyse und KI zur Bildklassifizierung und Anomaliedetektion

Als Demo-Case wurde ein Test-Run durchgeführt, bei dem die Kontaktierung der Solarzellen beabsichtigt Schwankungen aufwies, die sich bei einigen Zellen in zu niedrigen Füllfaktoren widerspiegelt. Die Motivation für diesen Versuch lag darin, ob sich messtechnisch bedingte Schwankungen von echten Qualitätsproblemen der Solarzellen unterscheiden lassen. Hierfür hat sich ergeben, dass vor allem eine quantitative und KI-basierte Bildanalyse wertvolle Informationen liefern kann. Dazu wurde der komplette Bilddatensatz zunächst manuell durch den Operator klassifiziert, s. Abbildung 11.

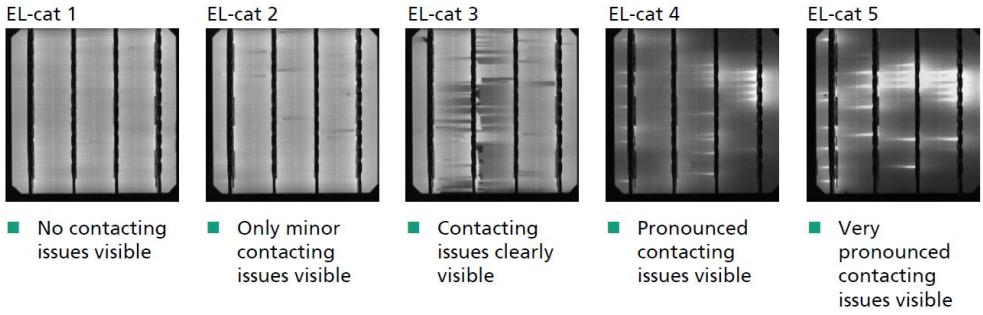

Abbildung 11: Beispiele für die manuelle Klassifizierung aller Zellen in fünf EL-Kategorien.

Das diese Klassifizierung sinnvoll ist, hat sich an statistischen Auswertungen bezüglich der einzelnen Füllfaktorverteilungen in den jeweiligen Klassen gezeigt, wo ein direkter Zusammenhang sowohl zwischen den Medianwerten als auch den Streubreiten sichtbar ist, s. Abbildung 12.

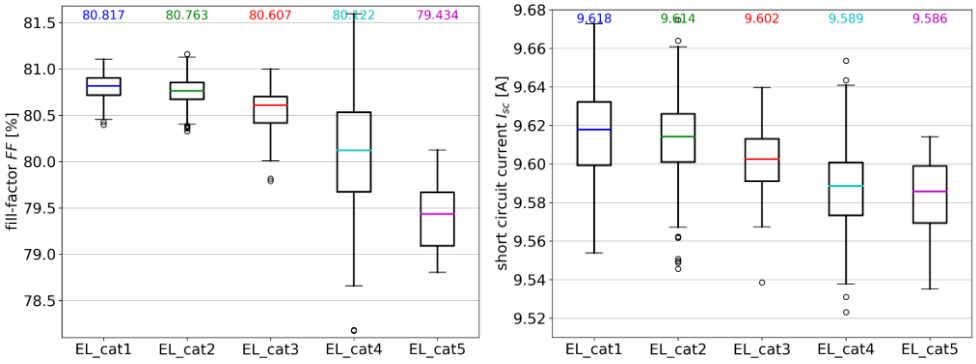

Abbildung 12: (links) Boxplots der Füllfaktorverteilung jeder einzelnen EL-Kategorie zeigen einen deutlichen Zusammenhang zwischen dem quantitativen Füllfaktormesswert und der subjektiven EL-Kategorie, (rechts) Boxplots der Kurzschlussstromwerte zeigen einen leichten Trend zu niedrigeren Strömen bei schlechter kontaktierten Zellen.

Damit bildet der Datensatz eine geeignete Grundlage zum Training eine KI-basierten Modells, welche eine automatisierte Klassifizierung erlaubt. Bei der Analyse der confusion-matrix zur Bewertung des Modells hat sich gezeigt, dass die EL-Kategorie 1 sehr gut vom Netz erkannt wird (viele „*true positives*"), jedoch viele Zellen der Kategorie 2 (minimale Auffälligkeiten im EL) ebenfalls noch der Kategorie 1 zugeordnet werden (viele „*false negatives*"). Ebenso gibt es große Überschneidungen zwischen Kategorie 4 („große Kontaktierprobleme") und 5 („sehr große Kontaktierprobleme"). Insgesamt konnte das KI-Modell jedoch sehr gut die unkritischen Kategorien 1 und 2 von den kritischen Kategorien 4 und 5 unterscheiden. Die statistische Analyse der Füllfaktorwerte basierend auf den KI-vorhergesagten Kategorien führte zu analogen Ergebnissen wie bei den manuell definierten Kategorien, so dass die Aussagekraft bei einer automatisierten Erkennung erhalten bleibt.
Zur weiteren Validierung dieses Ansatzes wurde anschließend der Einfluss des Trainingsdatensatzes untersucht, wobei eine einfache, zufällig ausgewählte Datenbasis zum Training sehr stabile Vorhersageergebnisse liefert und anderen Varianten überlegen war. Zugleich gibt es aber auch bei einer zufälligen Auswahl von Trainingsdaten Unterschiede in der Vorhersage, die bei praktischen Anwendungen zu berücksichtigen bzw. zu testen ist, s. Abbildung 13.

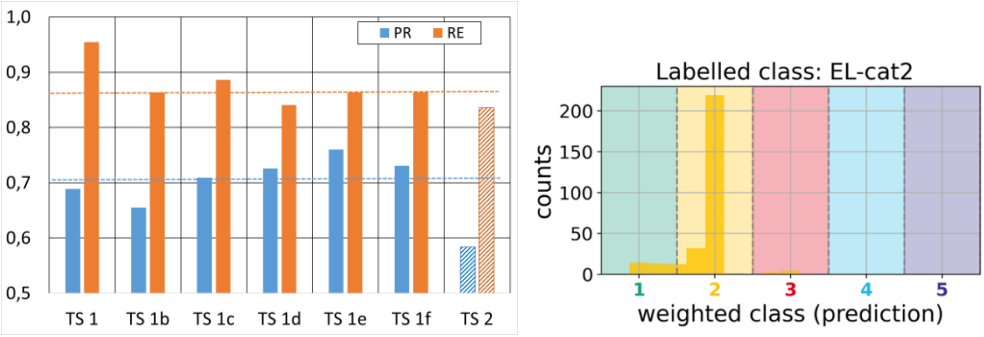

Abbildung 13: (links) Vergleich der precision (PR) und recall (RE) Performancewerte eines antrainierten KI-Modells basierend auf unterschiedlichen, zufällig ausgewählten (TS1, TS1b .. TS1f) im Vergleich zu einem Trainingsdatensatz TS2, der die Daten basierend auf einer chronologischen Reihenfolge enthält. (rechts) Die gewichteten EL-cat Vorhersagen für die Klasse EL-cat2 zeigen dass ein gewisser Anteil der Zellen eine signifikante Wahrscheinlichkeit für eine Zuordnung zu EL-cat1 vorhergesagt wird, wohingegen keine Vermischung mit EL-cat3 zu finden ist.

AP 7 Machine Learning zur Klassifizierung spektraler non-STC-Messungen

Zunächst wurde in AP7 die Python-Bibliotheken zur Datenvorbehandlung, d.h. Datenimport und Erzeugung strukturierter Datensätze sowie einfacher statistischer Auswertungen, weiterentwickelt. Diese Bibliotheken sollen als universelle Datenanalytik-Toolbox bei allen zukünftigen Experimenten sowie externen Daten für eine effiziente Datenauswertung zum Einsatz kommen. Ebenso wurde ein Dokumentationssystem für die Softwarebibliothek implementiert, damit eine Weiterentwicklung der umfangreichen Programme intern und ggf. auch extern möglich ist. Diese Python-Bibliothek bildet die Grundlage für die Anwendung von machine learning Konzepten auf die Messdaten.
Neben den Basisfunktionen wurde eine Trendanalyse basierend auf dem STL-LOESS (locally estimated scatterplot smoothing) Ansatz sowie eine Dimensionsreduktion hochdimensionaler Produktionsdaten mittels PCA implementiert. Ebenso wurde die Visualisierung mittels Zeitreihendiagrammen, Korrelationsmatrizen und Klassenbasierten Scatterplots ergänzt und getestet. Diese universelle Toolbox zur Erzeugung strukturierter Daten sowie deren Analyse und Visualisierung kam in AP1, AP6 und AP8 zum Einsatz.
Damit wurde der Basis-Workflow zur Datenanalyse in Python-Bibliotheken bzw. Skripten komplett abgebildet. Es können die Rohdaten aus einem MK4-Experiment eingelesen und nach Nutzervorgabe strukturiert bzw. als strukturierte Datensätze gespeichert werden. Aus Basis der strukturierten und ggf. skalierten Daten lassen sich umfangreiche Statistik- und Korrelationsuntersuchungen durchführen sowie erweiterte Algorithmen, z.B. zur Anomalieerkennung, ausführen. Die ersten entsprechenden Algorithmen, z.B. zur Erkennung von Trends oder Ausreißern, wurden implementiert.

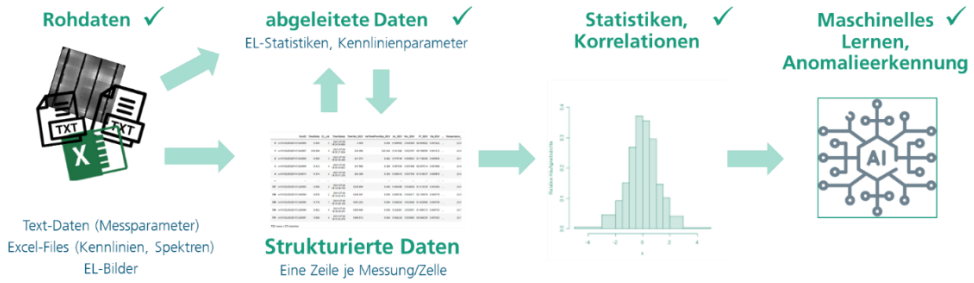

Abbildung 14: Schema des Workflows zur Datenanalyse: Datenerfassung, Erzeugung strukturierter Daten, Analyse von statistischen Verteilungen und Korrelationen sowie Anwendung von maschinellem Lernen.

Im AP7 wurde eine Python-Bibliothek zur Simulation von Solarzellen erweitert, so dass damit statistische Eigenschaften von Produktionsdatensätzen nachgestellt werden können. Dabei wird ausgehend von den Parametern des 2-Dioden-Modells eine Kennlinie simuliert und daraus die Kennlinienparameter Isc, Voc und FF bestimmt. Dies wurde exemplarisch an einem realen Datensatz aus der Solarzellproduktion (ca. 50.000 Zellen) getestet und gezeigt, dass sehr ähnliche Parameterverteilungen für Isc, Voc, und FF mittels des Simulationstools erzielt werden können. Basierend auf diesem numerischen Modellsystem wurden erste algorithmische Ansätze zu Erkennung von Korrelationen, Drifts oder Ausreißern untersucht. Für AP9 wurde das Modell erweitert, so dass auch optische Defekte modellhaft berücksichtig werden können, um Strategien zur Erkennung von Korrelationen zwischen optischen Defekten und Solarzellleistungs-parametern zu entwickeln.

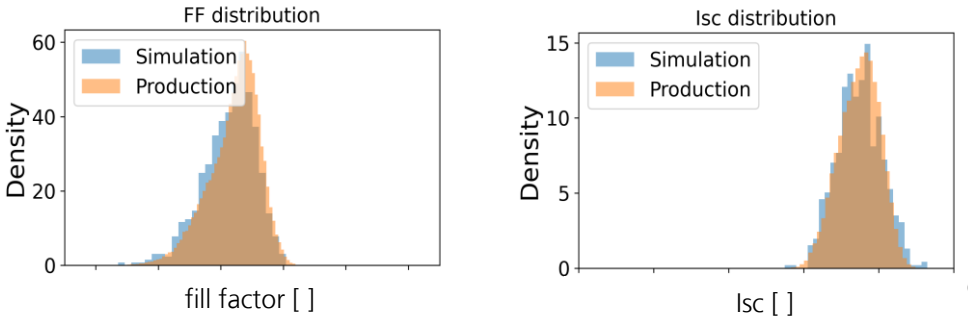

Abbildung 15: Verteilungen von Zellparametern eines Produktionsdatensatzes im Vergleich zu simulierten Daten.

Ebenso wurden Tools zur vereinfachten grafischen Darstellung entwickelt, z.B. zur vergleichenden Analyse von I-V-Messungen und deren Kennwerten, s. Abbildung 16.

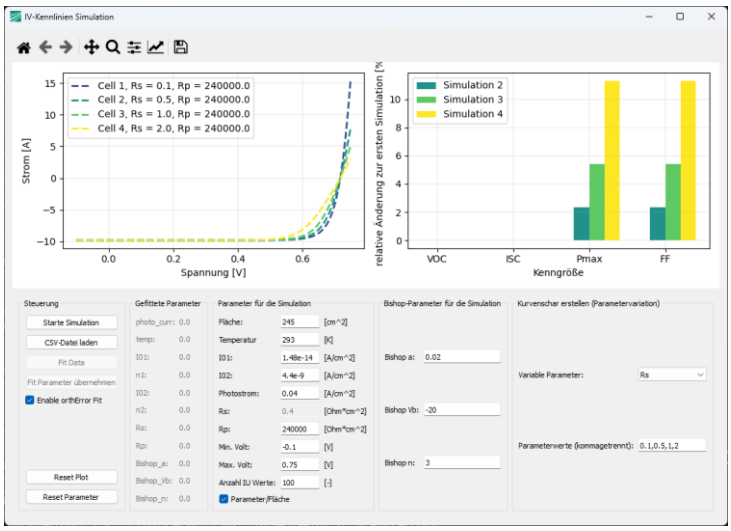

Abbildung 16: Graphical User Interface (GUI) mit interaktiven Graphen als Schnittstelle zur Simulationsbibliothek für I-V-Kennwerte von Solarzellen.

Alle im AP7 entwickelten Software-Tools und Algorithmen kamen umfangreich in den andere APs zum Einsatz.

AP 8 Erkennung Produktionsdrifts (Predictive Maintenance, Zeitreihenanalyse)

Als erstes wurden im Projekt erste Konzepte zur Trend- und Anomalieerkennung in Zeitreihen erarbeitet, welche in einem nächsten Schritt implementiert wurden. Dazu zählen die saisonal-trend Zerlegung (mittels LOESS locally estimated scatterplot smoothing), Zeitabhängiges clustering oder Abweichungen von forecasting Modellen (z.B. ARIMA Autoregressive Integrated Moving Average Model).
Die implementierte Drift-/Trenderkennung wurde auf die non-STC Testdatensätzen aus AP1 angewendet, s. Abbildung 17. Dabei wurde beobachtet, dass die Trendanteile der Zeitreihe zumeist kleiner sind als die periodischen Anteile oder die verbleibenden zufälligen Streuungen. Das deutet daraufhin, dass kein übergelagerter Trend in den Messdaten vorliegt.

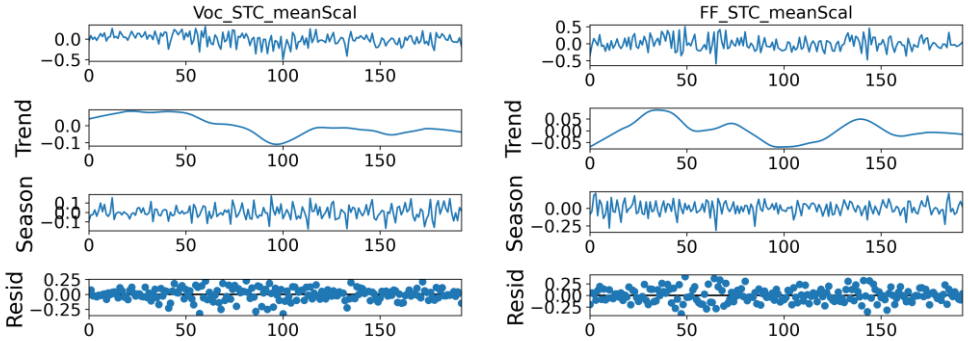

Abbildung 17: Trenderkennung durch Zerlegung der Zeitreihe in einen Trendanteil, periodischen Anteil und verbleibenden Zufallsanteil für die Spannung V_{oc} (links) bzw. den Füllfaktor FF (rechts).

Weiterhin wurde der Isolation Forrest Algorithmus implementiert und auf einen Produktionsdatensatz angewendet, um Ausreißer zu identifizieren. Diese Ansätze werden in den kommenden Monaten weiter verfeinert und getestet.

Basierend auf dem neuen Datensatz aus AP1 wurde die Trenderkennung an STC- und non-STC-Daten weiterentwickelt und getestet. Dabei wurde z.B. beobachtet, dass die STC-Parameter, wie Strom Isc und Spannung Voc, keine wesentlichen Trends über die Dauer des Versuches zeigen, s. Abbildung 17 (oben). Ebenso kann man beobachten, dass die kurzwellige rapid-EQE (gemessen über LED-Kanal CH01) einen ähnlichen Trend und Korrelation mit dem Isc aufweist. Allerdings findet man auch, dass die 760nm rapid-EQE (LED-Kanal CH12) einen deutlichen Trend innerhalb der ersten 150 Zellen zeigt. Da dieser Trend sich nicht in den STC-Stromdaten widerspiegelt, ist anzunehmen, dass es hierbei um einen Messeffekt handelt, z.B. die Erwärmung der Lichtquelle. Diese wird durch den Regelkreis bei den STC-Messungen kompensiert, allerdings nicht bei den implementierten non-STC Messungen.
Ebenso wurde die Trenderkennung angewendet, um eine Ausreißererkennung zu optimieren. In Abbildung 18 ist links die Ausreißererkennung ohne Trendbereinigung gezeigt und rechts mit Trendbereinigung. Es lässt sich gut erkennen, dass ein zuverlässige Ausreißererkennung über den gesamten Messzeitraum nur mittels Trend-bereinigung erreichen lässt. Das bedeutet, dass eine zuverlässige Trenderkennung grundlegend für eine Vielzahl weiterer Datenanalysen ist und die entsprechenden Algorithmen weiterentwickelt werden müssen.

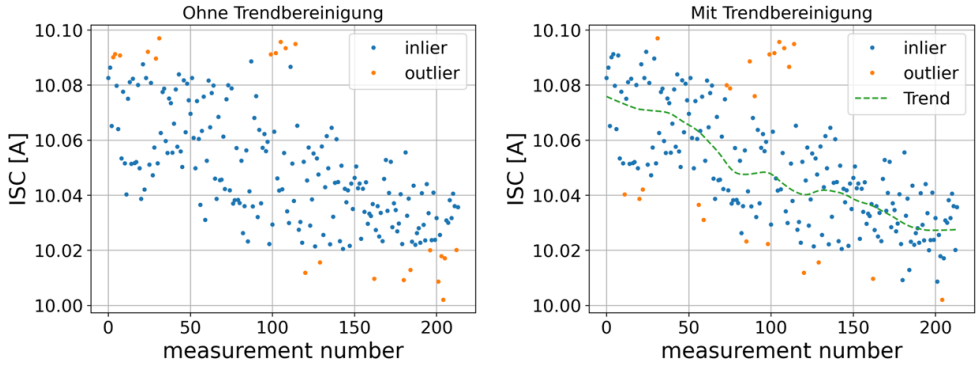

Abbildung 18: Ausreißererkennung (links) ohne Trendbereinigung und (rechts) mit Trendbereinigung.

Die Auswirkung dieser Trendbereinigung auf die statistischen Daten ist substanziell, s. Abbildung 19. So reduziert sich die Trendbereinigte Schwankungsbreite von B1 deutlich und die Unterscheidung zu B2 ist klarer erkennbar.

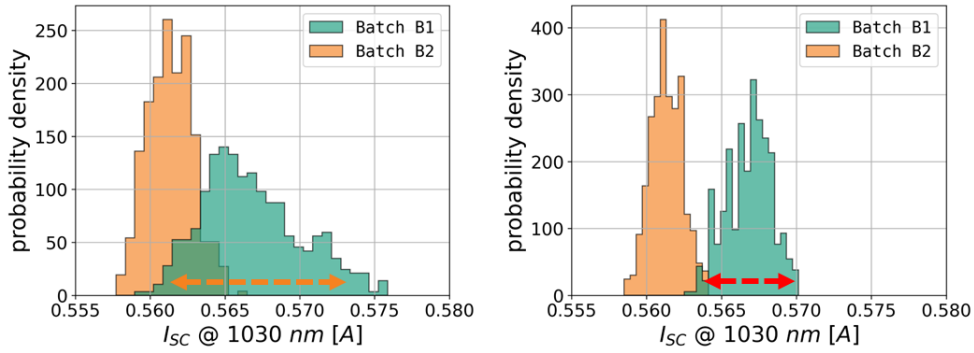

Abbildung 19: (links) Verteilung der Messwerte von batch B1 ohne Trendkorrektur weisen hohe Schwankungsbreite auf, (rechts) Durch die numerische Trendkorrektur der Rohdaten werden die realistischen Schwankungsbreiten der Daten erfasst.

AP 9 Erkennung Korrelationen, quantitativer Zusammenhänge in Messketten

- Korrelation von Prozess- mit Performanceparametern am Beispiel des LECO Prozesses;
- Übertragung und Evaluierung der Anwendbarkeit der Algorithmen

Der Schwerpunkt der Arbeiten zur Messmethoden übergreifenden Korrelation lag zunächst auf dem Datensatz der EL-Bilder mit zugeordneten I-V-Kennwerten. Dazu wurden auch in AP6 erste Untersuchungen, z.B. zum Zusammenhang zwischen den EL-cat Klassen und den FF-Werten oder den Isc-Werten durchgeführt. In diesem AP9 wurde zunächst untersucht, ob ein automatisiertes Training eines KI-Modells zur Erkennung der EL-cat umgesetzt werden kann, wobei der Trainingssatz nicht durch einen Operator gelabelt werden muss, sondern basierend auf den FF-Werten direkt. Dazu wurden zwei Trainingsdatensätze erzeugt, wobei einmal Klassen basierend auf equidistanten Füllfaktorintervallen und einmal basierend auf fünf gleichgroßen Untergruppen aller Zellen definiert wurden, s. Abbildung 20.

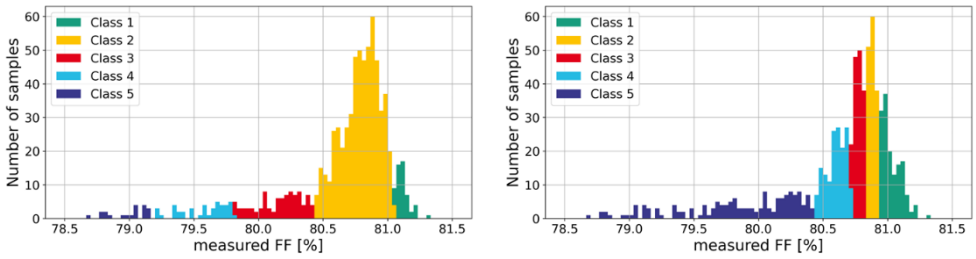

Abbildung 20: (links) Definition von fünf Klassen basierend auf FF-Intervallen oder (rechts) basierend auf fünf Untergruppen mit jeweils identischer Anzahl von Zellen.

Basierend auf dem Simulationsmodell aus AP7 wurden Datensätze für einen speziellen Anwendungsfall erzeugt. Dabei wurden neben den normalen Prozessvariationen in der Solarzellfertigung, die sich in den Parametern des 2-Dioden-Modells widerspiegeln, auch zusätzlich optische Defekte simuliert. Es wurden dabei zwei Datensätze erzeugt, die identische Verteilungen ihrer Performanceparameter aufweisen, wobei in einem Fall jedoch die optischen Defekte keine Auswirkung auf die Zellperformance habe und im anderen den Serienwiderstand beeinflussen.

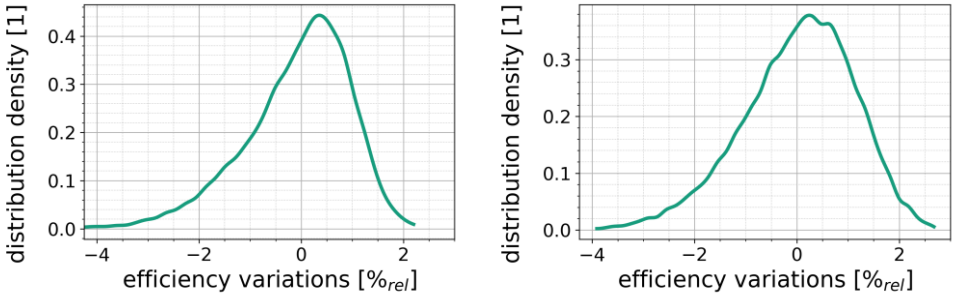

Abbildung 21: Asymmetrische Gauss-Verteilung der Wirkungsgrade des Produktionsdatensatzes (links) und des Simulationsmodells (rechts).

Mit diesen Datensätzen werden unterschiedliche numerische Testverfahren evaluiert, um zuverlässig bewerten zu können, welche quantitativen Zusammenhänge es zwischen unterschiedlichen Datenquellen geben kann. So können z.B. Verteilungen von Untergruppen von Zellen (z.B. Untergruppe „mit optischen Defekten“ und Untergruppe „ohne optische Defekte“) analysiert werden – dabei lassen sich mit höherer Sensitivität Rückschlüsse ziehen, ob die Defekte einen Einfluss auf die Performance haben. In der Simulation, welche den Produktionsdatensatz wiedergibt, s. Abbildung 21 und Abbildung 22, erkennt man die Unterschiede deutlich.

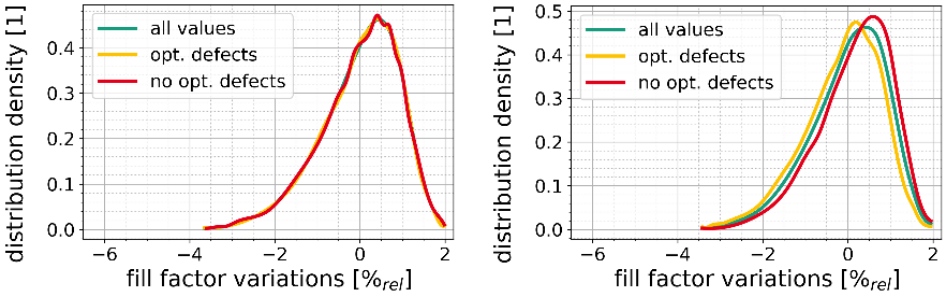

Abbildung 22: Simulierte Füllfaktorverteilungen (links) im Fall, dass die optisch erkennbaren Defekte keinen Einfluss auf die Performance haben, und (rechts) für den Fall, dass sie einen Einfluss haben. Die gesamte Verteilung (grün) ist zusätzlich einzeln für Zellen mit optischen Defekten (gelb) und ohne optische Defekte (rot) dargestellt.

Wendet man diese Verfahren auf die realen Daten an, ergibt sich, dass im untersuchten Fall die optischen Defekte keinen Einfluss auf die Performance haben, s. Abbildung 23. Das Verteilungsdiagramm folgt eher dem links in Abbildung 22 dargestellten Fall als dem rechts dargestellte.

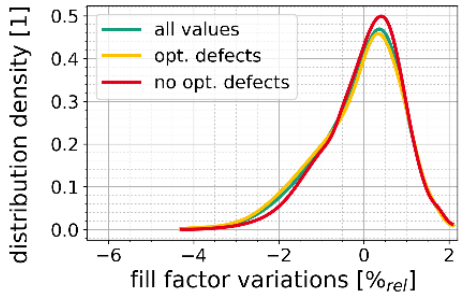

Abbildung 23: Verteilung der Füllfaktorwerte für den gesamten Datensatz sowie für die Untergruppen „ohne optische Defekte“ und „mit optischen Defekten“.

Anhand des Versuches, bei dem etwa 150 TOPCon-Zellen wiederholt gemessen wurden, konnten Korrelationsanalysen erstellt werden. Damit wurde beispielhaft die Korrelation von LECO-LBIC Daten und EL/PL-Daten mit IV-Parametern untersucht. Für LECO-LBIC wurden die Rohdaten der analysierten Region mit den Signaldaten (Abzug des Hintergrundes) sowie die Maximaldaten aus dem Prozess (ohne LECO-LBIC Bildgebung) verglichen. Hier zeigt sich ein grundlegend ähnliches verhalten, wobei die Signaldaten des ROI die stärksten Korrelationen zeigen. Insgesamt zeigt sich eine leichte positive Korrelation mit dem Füllfaktor FF und daraus resultierend auch mit der Zell-Leistung P_{MPP}. Hier zeigt sich auch ein großer Unterschied zur Bildgebung mittels EL und PL. Hier ist eine starke Korrelation zwischen Intensität und V_{OC} zu sehen, die sich dann auch auf die Zell-Leistung P_{MPP} auswirkt.
Es konnte anhand der Korrelationsanalyse mit den IV-Parametern der Solarzellen gezeigt werden, dass Unterschiede zu den anderen etablierten bildgebenden Verfahren wie PL und EL existieren und somit LECO-LBIC einen zusätzlichen Informationsgewinn bieten kann.

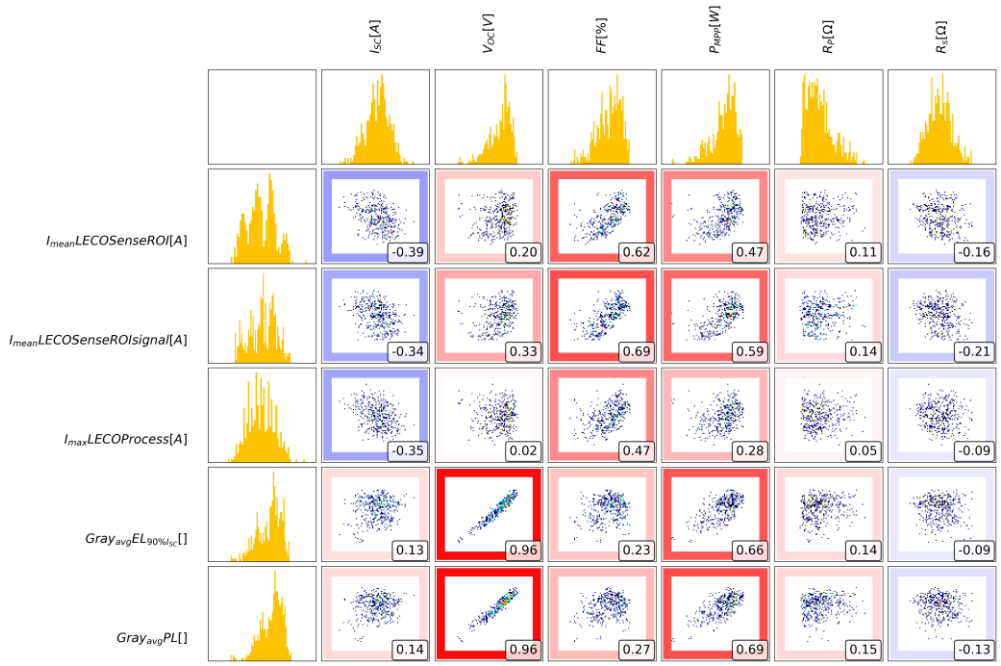

Abbildung 24: Korrelationsmatrix zwischen Parametern aus der Bildgebung (LECO LBIC – in der Abbildung als „LECO Sense" bezeichnet, EL und PL) und IV-Parameter aus dem Sonnensimulator (I_{SC}, V_{OC}, FF, P_{MPP} R_P und R_S). Die Koeffizienten der linearen Korrelation der einzelnen Parameter sind in jedem Streudiagramm unten rechts dargestellt und als Rand farblich markiert.

AP Z: Anpassung und Erweiterung der MK4-Messplattform (Projektaufstockung „OptiLearn Next")

- Erweiterung der Automatisierung und Kontaktierung auf neue Zellformate/-layouts
- Erweiterung der Messmöglichkeiten / -module in der Messplattform
- Aufbau einer Zellsortiereinheit

In einem ersten Schritt wurden in diesem zusätzlichen Projektteil „OptiLearn Next" verschiedene Anpassungen am Transportweg innerhalb der MK4 Plattform vorgenommen, z.B. Ausrichtschienen, Modifikationen am Kontaktierrahmen sowie an den Transportbändern. Im Ergebnis können jetzt Zellgrößen bis M12 (Halb- und Vollzelle) in üblichen Busbar-Designs in der MK4-Linie vermessen werden.

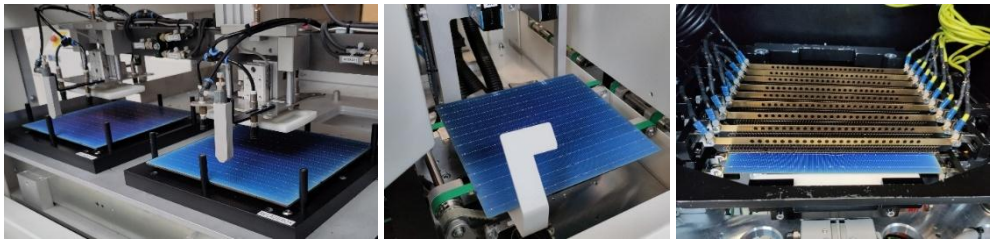

Abbildung 25: Erweiterung und Anpassung der MK4-Linie auf neue Zellformate bis G12: (links) Angepasste Beladeboxen, (mitte) modifizierte Winkel- und Führungselemente, (rechts) neuer Messrahmen und Kontaktleisten.

Es wurden nach dem Umbau noch Optimierungen am Umbau vorgenommen und Test-Runs, z.B. mit M10 Vollzellen, durchgeführt. Dabei wurde u.a. die Wiederholbarkeit der Messungen statistisch bewertet, exemplarisch dargestellt in Abbildung 26 für die

Leerlaufspannung. Dabei zeigte sich, dass ein zuverlässiger Zelltransport nach den Umbauten möglich und die Wiederholstabilität der Messungen gegeben ist. Als eine besondere Herausforderung hat sich dabei die genaue Positionierung der Zellen in der Kontaktiereinheit herausgestellt, die durch eine Anpassung der Führungsschienen erreicht wurde. Ebenso wurde festgestellt, dass die Erkennung des QR-Codes zur Zell-individuellen Analyse stark abhängig von der getesteten Zellart ist. Hier wurden ebenfalls noch Optimierungen bzgl. der Positionierung des Codes sowie der Beleuchtung und der QR-Kamera vorgenommen.

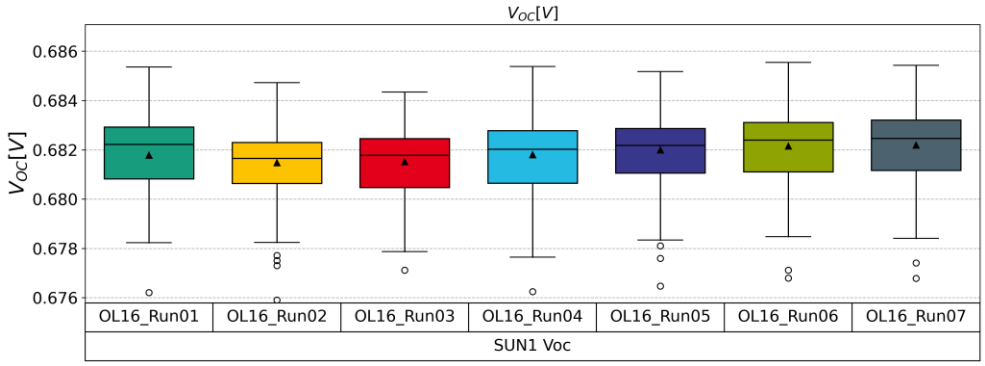

Abbildung 26: Statistische Analyse der I-V-Messungen in sieben Wiederholungsruns für ein Zellbatch von ca. 100 Zellen.

Außerdem wurde im Rahmen des Projektes die Integration eines zusätzlichen Moduls in die MK4-Plattform vorgenommen. Dafür wurden die technischen Details ausgearbeitet und sowohl hinsichtlich der Hardware- als auch der Softwareanforderungen abgestimmt. Bestandteil dieser Arbeiten waren neben der mechanischen Integration des Moduls auch die Integration einer Kamera, als Beispiel für ein mögliches Messgerät. Darüber hinaus wurden auch die Anpassung und Optimierung der Automatisierung und der Datenflüsse durchgeführt. Die Automatisierungsablauf wurde dahingehend optimiert, dass ein flexibler Einsatz verschiedener Messgeräte möglich wird. Zum einen kann die Positionierung in Bewegungsrichtung entweder mittels Anschlags oder auch zeitgesteuert über die Bandgeschwindigkeit angepasst werden. Kolbenbewegungen für eine Kontaktierung der Solarzellen sind in diesem Ablauf bereits implementiert und ermöglichen auf diese Weise eine Integration von Messverfahren, die einen elektrischen Kontakt der Solarzellen benötigen. Zum anderen gibt es einen Ablauf, bei dem sich die Solarzelle während des Messvorganges konstant bewegt, wodurch eine Integration von scannenden Messverfahren (z.B. Zeilenkamera) möglich wird.
Es wurde ein Protokoll zur Gerätekommunikation entwickelt, welches für beide Anwendungsfälle anwendbar ist. Auf diese Weise kann ohne weitere Anpassung an der Modulautomatisierung eine Vielzahl an verschiedenen Messgeräten in das neue Modul integriert werden. Der Steuerungsablauf und die Gerätekommunikation wurden anhand der installierten Kamera ausführlich zum einen für dieses Modul getestet zum anderen aber auch im Zusammenspiel mit dem schon bestehenden Teil der Linie.

Entgegen der ursprünglichen Planung wurde für die technische Umsetzung eines Zellsortierplatzes nicht auf einen externen Zulieferer für das Gesamtsystem zurückgegriffen, da die benötigte Flexibilität des Aufbaus in dem Fall nicht erreicht werden konnte. Es wurden CSP-intern das Gesamtkonzept entwickelt sowie die Einzelkomponenten (2-Achs-Greifer, Vakuumsauger, Kamera zur QR-Erkennung usw.) spezifiziert und ausgewählt. Die Zellsortiereinheit wurde aufgebaut und getestet, siehe Abbildung 27. Die Firmware der Steuerung wurde dabei zweigeteilt aufgebaut. Der erste Teil befindet sich direkt in der Steuereinheit des 2-Achs-Systems und ermöglicht die Bewegung und QR-Erkennung und bietet eine Art API. Der zweite Teil kann via

TCP-IP-Kommunikation mit der Steuereinheit kommunizieren (API) und dient der Übermittlung der Steuerbefehle des Nutzers an die Steuereinheit. Auf diese Weise ist es möglich Messdaten, beispielsweise aus dem MES, an den Zellsortierplatz zu übergeben, ohne auf die eigentliche Steuereinheit zugreifen zu müssen. Dabei wird von der Firmware auf der Steuereinheit der Barcode der Zelle übermittelt und die Nutzersoftware kann dann auf Grundlage dieses Barcodes entscheiden in welche Box die Zelle sortiert werden soll.

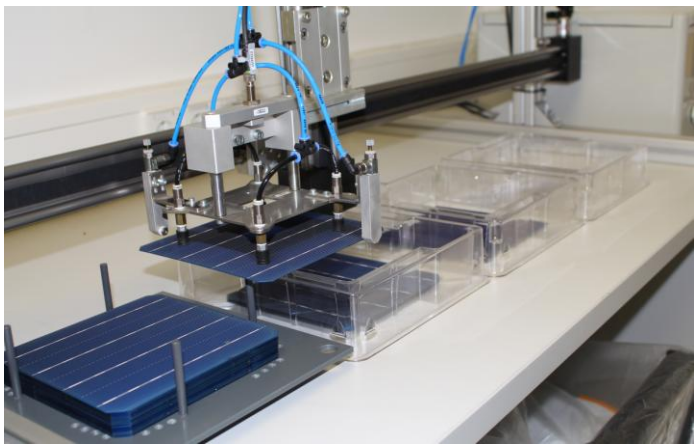

Abbildung 27: Automatisierter Sortierplatz mit Vakuumgreifer, 2-Achs-Einheit (inklusive Controller zur Ansteuerung) und Kameraschnittstelle zur Erkennung der Bar-Codes auf den Zellen.

3 Veröffentlichungen

Beiträge zu Workshops, Konferenzen und Veröffentlichungen im Projekt:

- **Posterbeitrag SiliconPV 2022**: E. Krassowski, S. Großer, M. Turek: "Statistical Data Analysis Revealing the Improvement Potential of Laser-Enhanced Contact Optimization (LECO) of Solar Cells".
- **Posterbeitrag SiliconPV 2022**: M. Turek, D. Hevisov: "Improved Lab-to-Fab Solar Cell Performance Assessment by Statistical Data Analysis in an Automated, High-Throughput Metrology Line".
- **Veröffentlichung**: Marko Turek, David Hevisov, Christian Hagendorf: "Improved lab-to-fab solar cell performance assessment by statistical data analysis in an automated, high-throughput metrology line." *AIP Conf. Proc.* 27 June 2023; 2826 (1): 030014. https://doi.org/10.1063/5.0141831
- **Veröffentlichung**: Eve Krassowski, David Hevisov, Stephan Großer, Marko Turek: "Investigation of impact of cell-properties on LECO effectiveness using off-spec PERC-cells of different manufacturers on MK4 platform" AIP Conf. Proc. 15 November 2022; 2709 (1): 020009. https://doi.org/10.1063/5.0126349
- **Vortrag SiliconPV 2023**: M. Turek, M. Meusel: "Automated Classification of EL-Images Using Artificial Neural Networks in Correlation to Solar Cell Performance Parameters"
- **Veröffentlichung**: Marko Turek, Manuel Meusel: "Automated classification of electroluminescence images using artificial neural networks in correlation to solar cell performance parameters" Solar Energy Materials and Solar Cells 260, 2023; 112483. https://doi.org/10.1016/j.solmat.2023.112483.
- **Poster SiliconPV 2024**: Marko Turek, Yuriy Tymyrivskyy, Stephan Hensel, Manuel Meusel: "Inline measurement of light beam induced current (LBIC) under high-injection and reverse bias conditions". https://doi.org/10.52825/siliconpv.v2i.1284
- **Poster EU-PVSEC 2024**: Stephan Großer, Matthias Schak, Stefan Eiternick, Bengt Jaeckel, Marko Turek: „Assessment of critical Laminate Temperature increase by fast IR-based analysis of hot spots on solar cells"
- **Vortrag EU-PVSEC 2024**: M. Meusel, A. Starke and M. Turek: "Identification of Performance-relevant Optically Detected Defects by Correlative Data Analysis in Solar Cell Production"
- **Poster EU-PVSEC 2025**: Hedayatullah Karimy, Manuel Meusel, Marko Turek: "Applicability of Non-Contact Quantum Efficiency Measurements to Various Solar Cell Architectures"