

# Anwenderpreis der DGZfP 2023

## Semi-Automatische Void-Analyse mittels Computed Laminography (CL) und Deep Learning für MXI-Systeme in der traditionellen SMT-Produktion und im Semiconductor-Bereich

Peter Koch

2080 Camel Ln., Walnut Creek, CA, 94596, USA

Kontakt E-Mail: [ptkch66@gmail.com](mailto:ptkch66@gmail.com)

### Einleitung & Marktüberblick

Comet Yxlon International GmbH ist ein Hersteller von Röntgensystemen zur Prüfung von industriellen Bauteilen. Comet Yxlon bedient heute Kunden der

- Elektronikindustrie
- Automobilindustrie und
- Aerospace

Strategisch richtet sich Comet Yxlon verstärkt anhand der Marktanforderungen aus dem Electronics Markt aus.

Der Electronics Markt lässt sich grundsätzlich in folgende zwei „Submärkte“ unterscheiden:

1. Semi-Markt (= Semiconductor; dazu zählen z. B. ganze Wafer, „scheiben“, IC Packages)
2. SMT-Markt (= Surface-mounted technology; wie z. B. Mainboards, 5G Chips, Grafikkarten)

Generell unterliegt der Electronics-Markt dem Trend der Miniaturisierung – sprich die Bauteile werden immer kleiner bzw. die Bauteilstrukturen werden immer komplexer. Die „Chips“ entwickeln sich grundsätzlich von „flachen“ Architekturen zu 3D-Architekturen, um mehr Rechenleistung pro Fläche generieren zu können. Diese Architekturen können zerstörungsfrei mit Röntgen geprüft werden. Die nachfolgende Abbildung zeigt eindrücklich wie sich die Transistorgrößen im Semi-Bereich seit 2016 von 16 nm auf 4 nm verkleinert haben.

Die einzelnen Chip-Architekturen sind durch sehr kleine Lötunkte (= Balls oder Bumps) miteinander verbunden. Diese haben heute Größen von z. B. 70 µm (C4 Bumps), 25 µm – 5 µm (µ-Bumps).



Vorstandsmitglied Dr. Dirk Treppmann (re.) überreicht auf der DGZfP-Jahrestagung in Friedrichshafen den Anwenderpreis der DGZfP 2023 an Peter Koch.

### Der Autor

**Peter Koch** ist Diplom-Ingenieur (Werkstoffwissenschaften) und ist seit 2005 in der Röntgeninspektion im Bereich Elektronik und Semiconductor tätig – speziell in der Fehleranalyse von Boards, Bauelementen und Halbleiter-Produkten mit 2D-, Tomosynthese- und CT-Techniken. In Zusammenarbeit mit namhaften Firmen entwickelte er die vorhandene Software weiter, um Sie im PCB- und Semiconductor-Markt für Applikationen in Bezug auf Rekonstruktion und Visualisierung anwenden zu können. Zudem veröffentlichte er Papers und Artikel in Fachzeitschriften. Aktuell ist er für die Firma Werth Messtechnik GmbH in den USA tätig.

## TSMC Advanced Technology Roadmap



Abbildung 1: Entwicklung der Chipgröße (N4 = 4 Nanometer)




Abbildung 2: Beispielhaft CoWoS-Architektur von TSMC (= IC Package)




Abbildung 3: Fehlerbilder von bumps

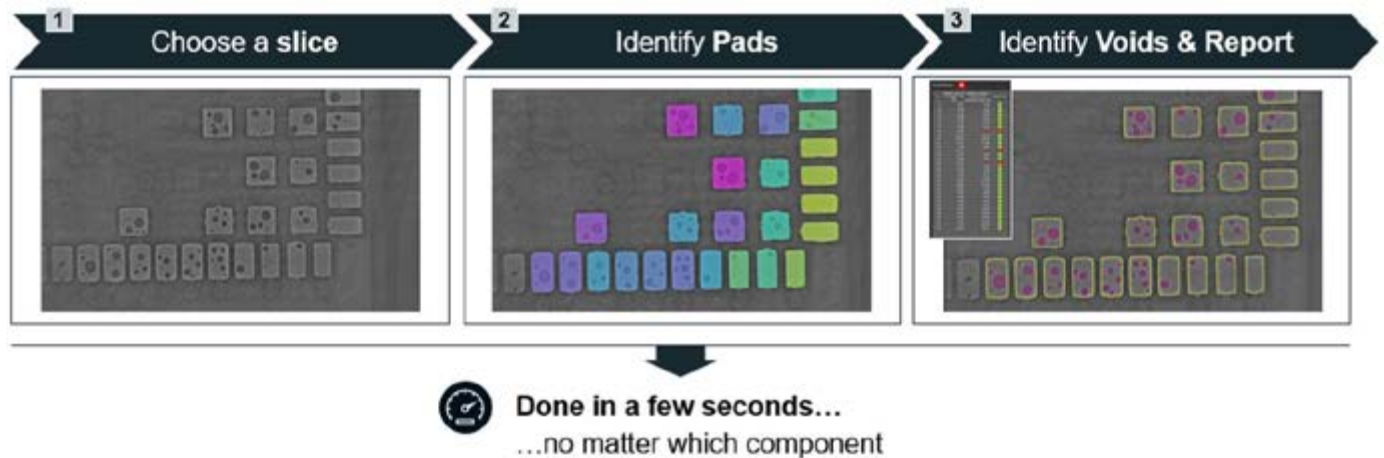


Abbildung 4: Workflow-Ablauf Void-Inspect

Grundsätzlich werden dies Chip-Architekturen immer komplexer und auch die „Lötunkte“ immer kleiner. Dadurch müssen immer kleinere Fehler detektiert werden. Heutige Röntgenlösungen bei Auflösungen um 600 nm kommen hier an ihre Grenzen.

Grob vereinfacht geht es sowohl im SMT- als auch im Semi-Bereich um die Prüfung von „Bumps“ von Größen zwischen 400 µm (BGA) bis 5 µm (Micro-Bumps). Hier ergeben sich eine Reihe von Fehlerbildern, die in Abbildung 3 dargestellt sind.

Comet Yxlon hat für die Void-Analyse eine Level 2 „assisted“ und damit semi-automatische Inspektionslösung geschaffen.

### 1 Mehrwert von Void-Inspect CL

Die Inspektionslösungen werden in vier Stufen unterschieden:

1. **Manuell (Visualisierung)**
2. **Guided workflows (Review Lösung)**  
(Der/die Nutzende folgt einem klaren Prüfablauf, dem er/sie folgen muss. Algorithmen unterstützen nur leicht)
3. **Assisted (Review Lösung)**  
(Der/die Nutzende hat einen klaren Prüfablauf, dem er/sie folgen muss. Algorithmen machen die Hauptarbeit bei der Segmentierung und Klassifizierung, können aber nicht in 100% der Fälle zu einem richtigen Ergebnis führen)
4. **Automated**  
(Typische ADR – Keine Nutzerinteraktion notwendig)

Der VoidInspect CL ist ein „Assisted Workflow“ und folgt damit einem standardisierten Prüfablauf.

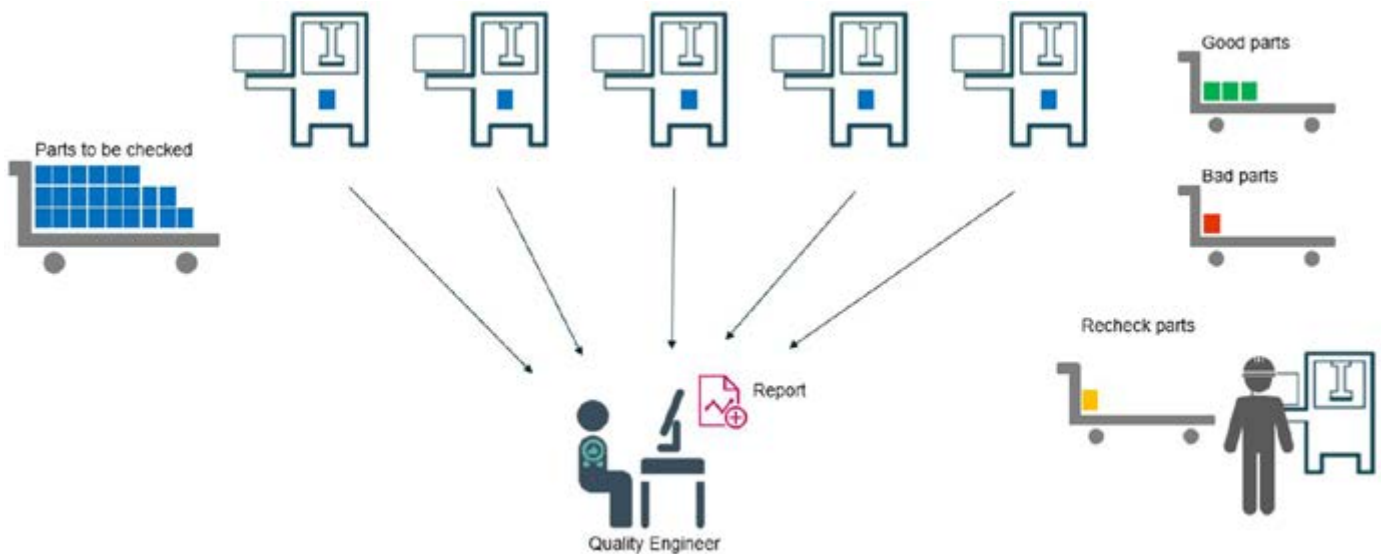


Abbildung 5: Multi-System Use Case

Diese Lösung bietet folgende Vorteile:

1. **Das Ergebnis ist wiederholbar:**  
Das bedeutet, dass verschiedene Prüfende zu demselben Ergebnis kommen, da sie denselben Prüfablauf verfolgen. Anlernzeiten werden durch den Workflow stark reduziert.
2. **Das Ergebnis ist verlässlich:**  
Das bedeutet, dass die Segmentierungs- und Klassifizierungsergebnisse auf Algorithmen ermittelt werden und nicht dem „Fingerspitzengefühl“ der Prüfenden unterliegen.
3. **Das Ergebnis ist kosteneffizient:**  
Die Lösung ermöglicht 3x schnellere Ergebnisse als bisherige vorhandene Lösungen am Markt. Diese Geschwindigkeitszuwächse ermöglichen „Multi-System“ Use Cases in denen mehrere Systeme „Bildraten“ erzeugen und an einer Review-Station Prüfentscheidungen getroffen werden.

## 2 VoidInspect CL Work-flow

### 2.1 Übersicht

In der Vergangenheit waren Offline-Röntgenprüfsysteme (MXI – Manual X-Ray Inspection) aufgrund der hochwertigen Bildkette vorwiegend für die gründliche Fehleranalyse geeignet, während bei In-line-Systemen (AXI – Automated X-Ray Inspection) der Schwerpunkt auf der Geschwindigkeit und der Fehlersuche liegt. Mittels neuer Algorithmen und neuer Funktionalitäten in der Prüfprogrammierung können aber auch Offline-Röntgenprüfsysteme an Inspektionsgeschwindigkeit gewinnen, können also die hervorragende Bildqualität für die Fehleranalyse mit einer erhöhten Inspektionsgeschwindigkeit ergänzen.

Gleichzeitig setzt die steigende Komplexität von Elektronikkomponenten der zweidimensionalen Radioskopie jedoch Grenzen, besonders dann, wenn Leiterplatten doppelseitig bestückt sind. Dann sind Untersuchungen mittels Computed Laminography (CL) unumgänglich.

In diesem Anwenderbericht soll nicht speziell auf den neuen Algorithmus von YXLON zur Void-Analyse (VoidInspect CL) eingegangen, sondern aufgezeigt werden, wie die Qualitätssicherung mit CL und den verschiedenen Algorithmen erweitert werden kann – im gesamten Feld der Aufbau- und Verbindungstechnik (AVT), in der SMT-Fer-

tigung (Surface Mounted Technology), sowie im Halbleiterbereich mit C4 (Controlled Collapse Chip Connection) und  $\mu$ -Bumps,  $\mu$ -Vias und weiteren Verbindungstechniken.

Durch neue Algorithmen in der Void-Analyse und durch zusätzliche Möglichkeiten Laminographie-Abläufe in Prüfprogramme zu integrieren, lässt sich hochwertige Bildqualität mit einer höheren Inspektionsgeschwindigkeit kombinieren. Auch mit sehr wenigen Projektionen können 3D-Volumen mittels Laminographie erstellt werden, die eine hochwertige Void-Analyse ermöglichen.

Die Laminographie hat im Gegensatz zur konventionellen Computed Tomography (CT) den Vorteil auch im hier beschriebenen Anwendungsbereich wirklich zerstörungsfrei zu sein. Konventionelle CT erfordert hier eine geringe Probengröße, um ein Volumen mit der erforderlichen hohen Ortsauflösung zu erstellen. Im SMT-Bereich muss dafür die Leiterplatte zerstört werden, da man den zu untersuchenden Bereich heraustrennen muss. Laminographie ist auch in dieser Situation zerstörungsfrei und kann auf der gesamten Inspektionsfläche des MXI-Systems hochwertige Volumendaten erzeugen.

Bauteile, bei denen eine Void-Analyse notwendig ist, um deren Funktion sicherzustellen, sind z.B. BGA (Ball Grid Array), LGA (Land Grid Array), IGBT (Insulated-Gate Bipolar Transistor), BTC (Bottom Terminated Components), sowie QFN (Quad Flat No Leads). Gerade beim BGA bietet CL die Möglichkeit, Voids separat an den oberen und unteren Verbindungsflächen zu messen, wo sie besonders kritisch sind, weil sie hier direkten Einfluss z. B. auf die thermische Stabilität des gesamten BGAs haben. Verbindungsflächen sind hierbei z.B. Anbindungen des Bauteils an die Leiterplatte. Indem das virtuelle 3D-Volumen in einzelne Schnittebenen aufgeteilt wird, kann das sogenannte Voiding an den Verbindungsflächen (Interfaces) exakt ausgewertet werden. Als Voids werden Luftpinschlüsse bezeichnet, die beim Reflow-Prozess entstehen. Im Reflow-Prozess wird das Lot aufgeschmolzen und das Flussmittel im Lot wird aktiviert, um die Bauteile mit der Leiterplatte zu verbinden. Besonders durch das Flussmittel entstehen während dieses Aufheizens Luftpinschlüsse (Voids) im Lot.



## 2.2 VoidInspect CL für Semiconductor Anwendungen

Eine große Rolle spielt Laminographie mit VoidInspect CL auch immer mehr im Semiconductor-Bereich. Die Verbindungstechnik ist zwar prinzipiell vergleichbar mit der Situation bei SMT, ist aber sehr viel komplexer und diffiziler. Die Strukturen bei Bumps liegen bei einem Durchmesser von durchschnittlich  $50\mu\text{m}$ , werden sich aber in den nächsten Jahren eher in Richtung  $5\mu\text{m}$  bewegen. Dazu muss man unterscheiden zwischen Advanced Packaging und Wafer Level Packaging (WLP). WLP kann derzeit noch mit 2D-Auswertungen auskommen, es wird aber zunehmend auch für WLP nach Computed Laminography für Bumps, TSVs und Copper Pillars verlangt. Für Advanced Packaging gibt es zu CL wahrscheinlich keine Alternative, wie „Abbildung 2: Beispielhaft CoWoS-Architektur von TSMC (= IC Package)“ verdeutlicht.

Interessant bzw. erforderlich für eine Röntgeninspektion sind die BGAs, C4-Bumps,  $\mu$ -Bumps und TSVs. Für eine Void Calculation kommen speziell BGAs, sowie die C4- und  $\mu$ -Bumps in Frage.

Im Folgenden soll anhand verschiedener 2D-Aufnahmen verdeutlicht werden, warum man gerade beim Advanced Packaging um CL keinen Bogen machen darf.




Abbildung 6: SMT-Board mit einem BGA und C4-Bumps (Durchmesser:  $60\mu\text{m}$ ). Das BGA ist leicht auswertbar, die C4-Bumps sind nicht auswertbar.




Abbildung 7: Advanced Packaging – in 2D ist es unmöglich einen fehlerhaften Bump unter Tausenden zu finden. Der fehlerhafte Bump ist mit einem roten Pfeil markiert.

Durch die visuelle Darstellung bei CL ist ein fehlerhafter Bump leichter erkennbar – in Abbildung 8 rot markiert:




Abbildung 8: Schichtbilddarstellung eines fehlerhaften Bumps.

Dasselbe gilt für non-wet Bumps, Bump Shift oder unterbrochene  $\mu$ -Vias:




Abbildung 9: Visualisierung von offenen Bumps im Vordergrund, erkennbar durch die unterschiedliche Form. rot markiert: offener Bump, grün markiert: gelöteter Bump




Abbildung 10: Drei Schnittebenen (x, y, z) im Volumen und Darstellung der offenen Bumps mit Visualisierung (rot markiert: offene Bumps, grün markiert: gelöteter Bump)

### Advanced Packaging: Bump-Shift:




Abbildung 11: Visualisierung des gesamten Bauteils, Vias, C4-Bumps, BGA




Abbildung 12: Bump-Shift (mit einem grünen Pfeil markiert)

Advanced Packaging: Unterbrechung bei  $\mu$ -Vias:




Abbildung 13 (oben): Draufsicht Schnittebene: Verbindung der  $\mu$ -Vias fehlt  
 Abbildung 14 (unten): Zwei unterbrochene  $\mu$ -Vias in der Seitenansicht

Genauso wie bei Bauteilen in der SMT, kann auch im Semiconductor-Bereich das Laminographie-Volumen mit dem VoidInspect CL Workflow verwendet werden, um die Voids z. B. in C4-Bumps beim Advanced Packaging zu detektieren. Die Vorgehensweise ist dieselbe wie in der SMT.




Abbildung 15: Advanced Packaging: BGA auf der Unterseite, C4-Bumps (60  $\mu$ m) auf der Oberseite, im Substrat Vias




Abbildung 16: Advanced Packing: Schichtdarstellung der C4-Bumps mit Voiding – im Bild links oben als schwarze Punkte in den weißen Bumps

erkennbar




Abbildung 17: Advanced Packaging: Auswertung einer Rol mit C4-Bumps (60  $\mu$ m) – Void Calculation

Auch wenn für den Semiconductor-Bereich andere Anforderungen hinsichtlich der Bildkette (Nanofokus-Röhre, Detektor) gelten, ist der VoidInspect Workflow auch hier mit einer sehr guten Wiederholgenauigkeit anwendbar. Ein Maßstab kann vorher schon die Visualisierung des Laminographie-Volumens sein. Grundsätzlich gilt: Was man im Volumen nicht oder nur schlecht sehen kann, ist nicht auswertbar oder die Ergebnisse sind sehr fehlerbehaftet.

2.3 VoidInspect CL für SMT

Neben BGAs sind insbesondere LGAs gut geeignet, eine Void-Analyse mittels CL durchzuführen. LGAs sind generell von anderen Bauteilen überlagert und eine 2D-Bewertung dadurch praktisch unmöglich.




Abbildung 18: 2D-Ansicht eines Prüfobjekts (LGA)



Visualisierung (VIS) des rekonstruierten Laminographie-Volumens mit der FF CT Software (YXLON):




Abbildung 19: Aufsicht eines Prüfobjekts (LGA)



Abbildung 20: Schrägsicht eines Prüfobjekts (LGA)




Abbildung 21: Seitensicht eines Prüfobjekts (LGA)

Das LGA wird überdeckt von den verschiedensten Bauteilen, die eine 2D-Auswertung unmöglich machen (Abbildungen 21 und 22). In der Seitensicht sieht man sehr deutlich, wie komplex dieses Prüfobjekt ist.

Diese Abbildung wird als Beispiel einer doppelseitig bestückten Leiterplatte gezeigt (LTE-Modul). Überdeckt von anderen Bauteilen wie BGAs, Kondensatoren, C4-Bumps usw. befindet sich das LGA in diesem LTE-Modul. Eine 2D-Void-Analyse ist hier ausgeschlossen. Eine Bewertung der Voids kann nur mittels Computed Laminography durchgeführt werden, indem man im rekonstruierten Volumen den VoidInspect CL Workflow auf die korrekt ausgewählte Schicht auf Höhe der Verbindung des LGAs zur Leiterplatte anwendet.




Abbildung 22: Auswahl der Schicht für die Void-Messung (links) und Visualisierung der Voids (rechts)




Abbildung 23: Visualisierung von Voids (Detail)

Je besser die Voids in einem Volumen visualisiert werden können, desto höher ist die erreichbare Genauigkeit der Auswertung (Abbildung 23). Bei der Visualisierung (VIS) wurde das Lot als Material transparent dargestellt. Die Voids erscheinen als Material hellgrau in den rechteckigen dunkelgrauen Bereichen (Abbildung 23).

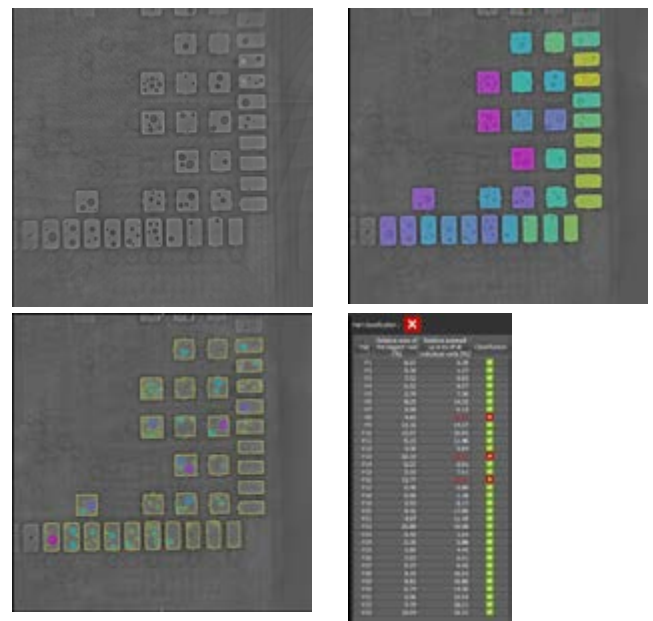


Abbildung 24: VoidInspect CL – 3 Schritte bis zum Ergebnis: Schichtauswahl – Pad-Erkennung – Auswertung

Tabelle 1: Auflistung berücksichtigter Datensätze nach Verbindungsart

	LGA	DPAK	IGBT Central	IGBT Die Attach	BGA	QFN	Pads	LED
<b>Volumen</b>	22	20	20	21	41	21	20	22
<b>Reports</b>	460	430	237	155	498	262	242	260
<b>Total Volumen</b>	<b>Total 187</b>							
<b>Reports</b>	<b>2524</b>							

Ziel ist es, die Auswertungen auch durch einen ungeschulten Operator durchführen lassen zu können: Mit einer Minimalanzahl von Schritten ohne Interaktion des Operators, aber mit der bestmöglichen Qualität. Dabei wird der Operator vom VoidInspect CL Workflow (Abbildung 24) unterstützt.

Für den Einsatz in der Serienprüfung oder zur Fehleranalyse muss ein Void-Algorithmus immer ein wiederholbares Ergebnis liefern. Der Algorithmus wurde deshalb an einer Vielzahl gebräuchlicher Bauteile getestet und dabei sowohl die Abweichung von Akquisition zu Akquisition berechnet als auch die Abweichung für nur ein Volumen, bei dem die Analyse mit VoidInspect CL insgesamt zwanzigmal durchgeführt wurde.

In der Auswertung wurden folgende Bauteilarten berücksichtigt: BGA, QFN, Pads einzelner Komponenten und das Central Pad (Thermal Pad), LED, DPAK und bei einem High-Power-Modul (IGBT) sowohl der sogenannte Die Attach als auch die Base Plate.

Es wurden von den Bauteilen insgesamt 187 Volumeneinheiten und davon 2524 Auswertungen (Reports) erstellt, in denen die Voids entsprechend der Bauteilnummer oder Verbindungsform aufgelistet werden, die für die Bestimmung der Wiederholgenauigkeit der Auswertung herangezogen wurden (Tabelle 1). Gemessen wurde dabei

sowohl der jeweils größte Single Void in % der Fläche einer Region of Interest (RoI) als auch die Total Voids in % dieser Fläche.

Für die Auswertung der Abweichung wurden drei repräsentative Pads des LGA` s ausgewählt (Abbildung 25).

Ergebnis ist im konkreten Fall eine Abweichung von 0 % bei Auswertung eines einzelnen Volumens (Tabelle 2). Eine Wiederholgenauigkeit in diesem Volumen mit der eingesetzten Rekonstruktion und dem AuswertungsAlgorithmus ist also hier exakt gegeben.

P8 und P13 haben eine große Anzahl von kleinen Voids (Abbildung 26). Da die Auswertung eines Volumens eine Abweichung von 0% ergab, ist davon auszugehen, dass die Abweichung zwischen Akquisitionen durch minimale Grauwertunterschiede in den Projektionen – und damit im rekonstruierten Volumen – verursacht wurde, da es das Ziel des Workflows ist, immer mit denselben Einstellungen wie z.B. der Grauwertschwelle (Threshold) auszuwerten, was im vorliegenden Fall auch so umgesetzt wurde.

Bei Auswertung des LGAs (Tabelle 2, Tabelle 3) zeigt sich, dass das größte Single Void immer noch eine Abweichung von unter 0.3% hat und die Abweichung der Total Voids in einem Pad max. 1% beträgt. Dies lässt sich durch die Menge an kleinen Voids erklären, die sich in einem Pad befinden (Abbildung 25 & 26).




Abbildung 25: Für die Analyse ausgewertete Bereiche (Rols – Regions of Interest)




Abbildung 26: Detailansicht der ausgewerteten Rols

Tabelle 2: Abweichung der Messung für 1 Volumen bei 10 Wiederholungen (LGA)

LGA #10	P6 Single	P8 Total	P13 Single	P13 Total	P16 Single	P16 Total
1	4,72	26,16	10,28	26,45	11,93	25,42
2	4,72	26,16	10,28	26,45	11,93	25,42
3	4,72	26,16	10,28	26,45	11,93	25,42
4	4,72	26,16	10,28	26,45	11,93	25,42
5	4,72	26,16	10,28	26,45	11,93	25,42
6	4,72	26,16	10,28	26,45	11,93	25,42
7	4,72	26,16	10,28	26,45	11,93	25,42
8	4,72	26,16	10,28	26,45	11,93	25,42
9	4,72	26,16	10,28	26,45	11,93	25,42
10	4,72	26,16	10,28	26,45	11,93	25,42
<b>Average</b>	<b>4,72</b>	<b>26,16</b>	<b>10,28</b>	<b>26,45</b>	<b>11,93</b>	<b>25,42</b>
<b>Min</b>	4,72	26,16	10,28	26,45	11,93	25,42
<b>Max</b>	4,72	26,16	10,28	26,45	11,93	25,42
<b>Deviation</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>

Tabelle 3: Messung der Abweichung beim Vergleich von 20 Volumen bei Verwendung von 10 Reports je Volumen (LGA)

LGA						
Laminography #	P 8 Single	P8 Total	P 13 Single	P 13 Total	P 16 Single	P16 Total
1	4,69	25,45	10,3	26,29	11,97	25,42
2	4,73	25,69	10,28	25,97	11,8	25,02
3	4,72	25,82	10,18	25,8	12,08	25,62
4	4,68	26,13	10,24	26,13	11,93	25,32
5	4,67	26,25	10,21	26,23	11,98	25,58
6	4,69	26,29	10,21	26,19	11,98	25,45
7	4,69	26,25	10,29	26,41	11,92	25,44
8	4,69	26,22	10,26	26,25	11,96	25,35
9	4,67	25,95	10,25	26,18	11,92	25,3
10	4,72	26,16	10,28	26,45	11,93	25,42
11	4,69	25,98	10,28	26,29	11,97	25,48
12	4,72	26,22	10,26	26,43	12,03	25,61
13	4,71	26,26	10,31	26,55	12,01	25,6
14	4,69	26,26	10,31	26,61	12,04	25,68
15	4,71	26,27	10,29	26,7	12,02	25,59
16	4,7	26,34	10,18	26,26	12,07	25,73
17	4,69	26,45	10,14	26,34	12,08	25,76
18	4,69	26,39	10,16	26,25	12,09	25,76
19	4,69	26,41	10,18	26,32	12,07	25,71
20	4,74	26,35	10,23	26,3	12,03	25,68
<b>Average</b>	<b>4,699</b>	<b>26,157</b>	<b>10,242</b>	<b>26,2975</b>	<b>11,994</b>	<b>25,526</b>
<b>Min</b>	4,67	25,45	10,16	25,8	11,8	25,02
<b>Max</b>	4,73	26,45	10,31	26,7	12,09	25,76
<b>Deviation</b>	<b>0,06%</b>	<b>1%</b>	<b>0,15%</b>	<b>0,90%</b>	<b>0,29%</b>	<b>0,74%</b>

Die Abweichung bei der Auswertung wird immer kleiner, je größer die auszuwertende Fläche ist. Als Beispiel dafür dient die Auswertung von 6 DPAKS (Abbildung 27) und die Auswertung der Base Plate eines IGBT (High Power Module). Auf einer Base Plate befinden

sich dabei 8 Dies (Abbildung 28). Mit Laminographie und dem VoidInspect CL Workflow wird das Voiding an der Base Plate und den 8 Dies bestimmt (Abbildung 29).






Abbildung 27: Visualisierung von 6 DPAKs (links) und Schichtdarstellung (rechts)  
links: VIS der 6 DPAKs von einem CL-Volumen  
rechts: Schicht für die Auswertung mittels VoidInspect CL und VIS der Voids in einem DPAK.




Abbildung 29: Voiding in der Base Plate des IGBT (Screenshot des VoidInspect CL Workflow)

Für die Visualisierung der Voids wurde das Lot transparent dargestellt und die Voids als Material. Die Voids sind hier die grau-weißen Blasen über dem schwarzen Untergrund.




Abbildung 28: IGBT, High Power Module

Tabelle 4: Auswertung der Abweichung für 1 Volumen, 20 Reports – Abweichung 0% (DPAK)

Laminography #	DPAK 1		DPAK 2		DPAK 3		DPAK 4		DPAK 5		DPAK 6	
	%	%	%	%	%	%	%	%	%	%	%	%
1	5,61	21,77	2,56	19,36	4,93	20,75	3,17	20,11	1,96	17,95	6,45	20,37
2	5,64	21,99	2,57	19,31	4,94	20,89	3,19	20,26	1,97	18,18	6,45	20,52
3	5,60	21,62	2,55	19,22	4,93	20,62	3,19	20,15	1,96	17,88	6,43	20,35
4	5,63	21,75	2,57	19,32	4,95	20,86	3,18	20,24	1,96	18,08	6,45	20,48
5	5,63	21,83	2,56	19,32	4,95	20,65	3,17	20,11	1,99	18,42	6,43	20,51
6	5,64	22,33	2,56	19,5	4,97	21,13	3,15	20,37	1,98	18,68	6,43	20,74
7	5,63	22,1	2,57	19,44	4,96	20,97	3,18	20,3	1,98	18,51	6,42	20,53
8	5,64	21,86	2,57	19,42	4,95	20,87	3,19	20,27	1,99	18,2	6,45	20,42
9	5,64	21,88	2,57	19,29	4,93	20,71	3,18	20,1	1,97	18,2	6,45	20,49
10	5,67	22,12	2,57	19,49	4,96	20,98	3,2	20,3	1,97	18,41	6,48	20,6
11	5,65	22,15	2,56	19,38	4,95	20,96	3,16	20,26	1,99	18,58	6,43	20,56
12	5,65	21,74	2,56	19,17	4,96	20,6	3,18	20,06	1,98	18,09	6,46	20,39
13	5,62	21,77	2,57	19,2	4,95	20,68	3,18	20,16	1,96	17,97	6,46	20,29
14	5,68	22,06	2,56	19,31	4,97	20,95	3,18	20,2	1,99	18,33	6,47	20,53
15	5,66	21,95	2,57	19,54	4,95	20,98	3,19	20,48	1,97	18,24	6,47	20,76
16	5,65	22,12	2,57	19,71	4,95	20,64	3,18	20,64	1,97	18,4	6,47	20,83
17	5,60	21,74	2,56	19,37	4,93	20,77	3,17	20,39	1,96	18	6,62	20,59
18	5,63	21,99	2,55	19,5	4,94	21	3,16	20,29	1,98	18,33	6,44	20,66
19	5,63	21,88	2,55	19,47	4,94	20,97	3,16	20,25	1,96	18,35	6,44	20,68
20	5,64	22,15	2,54	19,62	4,96	21	3,17	20,46	1,99	18,58	6,42	20,77
<b>Average</b>	<b>5,637</b>	<b>21,94</b>	<b>2,562</b>	<b>19,397</b>	<b>4,9485</b>	<b>20,849</b>	<b>3,1765</b>	<b>20,27</b>	<b>1,974</b>	<b>18,269</b>	<b>6,456</b>	<b>20,5535</b>
<b>Max</b>	5,68	22,15	2,57	19,71	4,97	21,13	3,19	20,64	1,99	18,68	6,48	20,77
<b>Min</b>	5,6	21,62	2,54	19,17	4,93	20,62	3,15	20,11	1,96	17,95	6,42	20,29
<b>Deviation</b>	<b>0,08</b>	<b>0,53</b>	<b>0,03</b>	<b>0,54</b>	<b>0,04</b>	<b>0,51</b>	<b>0,04</b>	<b>0,53</b>	<b>0,03</b>	<b>0,73</b>	<b>0,06</b>	<b>0,48</b>

Tabelle 5: Abweichung von 20 Volumen mit 400 Reports – maximale Abweichung 0,73 % (DPAK)

Laminography #	DPAK 1		DPAK 2		DPAK 3		DPAK 4		DPAK 5		DPAK 6	
	%	%	%	%	%	%	%	%	%	%	%	%
1	5,61	21,77	2,56	19,36	4,93	20,75	3,17	20,11	1,96	17,95	6,45	20,37
2	5,64	21,99	2,57	19,31	4,94	20,89	3,19	20,26	1,97	18,18	6,45	20,52
3	5,60	21,62	2,55	19,22	4,93	20,62	3,19	20,15	1,96	17,88	6,43	20,35
4	5,63	21,75	2,57	19,32	4,95	20,86	3,18	20,24	1,96	18,08	6,45	20,48
5	5,63	21,83	2,56	19,32	4,95	20,65	3,17	20,11	1,99	18,42	6,43	20,51
6	5,64	22,33	2,56	19,5	4,97	21,13	3,15	20,37	1,98	18,68	6,43	20,74
7	5,63	22,1	2,57	19,44	4,96	20,97	3,18	20,3	1,98	18,51	6,42	20,53
8	5,64	21,86	2,57	19,42	4,95	20,87	3,19	20,27	1,99	18,2	6,45	20,42
9	5,64	21,88	2,57	19,29	4,93	20,71	3,18	20,1	1,97	18,2	6,45	20,49
10	5,67	22,12	2,57	19,49	4,96	20,98	3,2	20,3	1,97	18,41	6,48	20,6
11	5,65	22,15	2,56	19,38	4,95	20,96	3,16	20,26	1,99	18,58	6,43	20,56
12	5,65	21,74	2,56	19,17	4,96	20,6	3,18	20,06	1,98	18,09	6,46	20,39
13	5,62	21,77	2,57	19,2	4,95	20,68	3,18	20,16	1,96	17,97	6,46	20,29
14	5,68	22,06	2,56	19,31	4,97	20,95	3,18	20,2	1,99	18,33	6,47	20,53
15	5,66	21,95	2,57	19,54	4,95	20,98	3,19	20,48	1,97	18,24	6,47	20,76
16	5,65	22,12	2,57	19,71	4,95	20,64	3,18	20,64	1,97	18,4	6,47	20,83
17	5,60	21,74	2,56	19,37	4,93	20,77	3,17	20,39	1,96	18	6,62	20,59
18	5,63	21,99	2,55	19,5	4,94	21	3,16	20,29	1,98	18,33	6,44	20,66
19	5,63	21,88	2,55	19,47	4,94	20,97	3,16	20,25	1,96	18,35	6,44	20,68
20	5,64	22,15	2,54	19,62	4,96	21	3,17	20,46	1,99	18,58	6,42	20,77
<b>Average</b>	<b>5,637</b>	<b>21,94</b>	<b>2,562</b>	<b>19,397</b>	<b>4,9485</b>	<b>20,849</b>	<b>3,1765</b>	<b>20,27</b>	<b>1,974</b>	<b>18,269</b>	<b>6,456</b>	<b>20,5535</b>
<b>Max</b>	5,68	22,15	2,57	19,71	4,97	21,13	3,19	20,64	1,99	18,68	6,48	20,77
<b>Min</b>	5,6	21,62	2,54	19,17	4,93	20,62	3,15	20,11	1,96	17,95	6,42	20,29
<b>Deviation</b>	<b>0,08</b>	<b>0,53</b>	<b>0,03</b>	<b>0,54</b>	<b>0,04</b>	<b>0,51</b>	<b>0,04</b>	<b>0,53</b>	<b>0,03</b>	<b>0,73</b>	<b>0,06</b>	<b>0,48</b>

Eine max. Abweichung von 0,73 % bei 400 Auswertungen (Tabelle 5) liegt durchaus noch in einem sehr akzeptablen Bereich, wenn man die kleine Fläche berücksichtigt. Bei einer größeren Fläche wie der Base Plate von einem IGBT ergibt sich eine maximale Abweichung von 0,01 % für den größten einzelnen Void und von 0,05 % in der Gesamtsumme der Voids an der Base Plate (Tabelle 7).

Zusammenfassend lässt sich feststellen: Je größer die Fläche ist, die auf Voiding untersucht wird, desto besser ist die Wiederholgenauigkeit des VoidInspect CL Workflows.

Für die Auswertungen wurde dabei der Schwellwert für die Detektion des Voidings nicht geändert. Änderungen der Detektion der Voids beruhen, wie vorher schon beschrieben, auf Unterschieden in den Grauwerten bei der Aufnahme der Projektionen und der Rekonstruktion. Kleinere Voids werden dadurch unterschiedlich erkannt und ausgewertet. Bei einer großen Fläche spielen diese Abweichungen in der Erkennbarkeit der Voids nur eine minimale Rolle.

Tabelle 6: Auswertung eines Volumens: Deviation 0 % (IGBT)

Laminography #20	Single %	Total %
1	0,27	0,7
2	0,27	0,7
3	0,27	0,7
4	0,27	0,7
5	0,27	0,7
6	0,27	0,7
7	0,27	0,7
8	0,27	0,7
9	0,27	0,7
10	0,27	0,7
<b>Deviation</b>	<b>0%</b>	<b>0%</b>

Tabelle 7: Auswertung 20 Volumen, jeweils 10 Reports, max. Abweichung (IGBT)

Laminography #	IGBT Base Plate		All Volumes	
	Single %	Total %	Single %	Total %
1	0,27	0,73	0,27	0,73
2	0,27	0,69	0,27	0,69
3	0,27	0,68	0,27	0,68
4	0,27	0,7	0,27	0,7
5	0,27	0,71	0,27	0,71
6	0,27	0,73	0,27	0,73
7	0,28	0,73	0,28	0,73
8	0,28	0,72	0,28	0,72
9	0,28	0,72	0,28	0,72
10	0,28	0,73	0,28	0,73
11	0,27	0,71	0,27	0,71
12	0,27	0,69	0,27	0,69
13	0,27	0,72	0,27	0,72
14	0,27	0,72	0,27	0,72
15	0,27	0,7	0,27	0,7
16	0,28	0,7	0,28	0,7
17	0,27	0,68	0,27	0,68
18	0,27	0,7	0,27	0,7
19	0,27	0,71	0,27	0,71
20	0,27	0,7	0,27	0,7
<b>Average</b>	<b>0,2725</b>	<b>0,7085</b>	<b>0,2725</b>	<b>0,7085</b>
<b>MAX</b>	0,27	0,68	0,27	0,68
<b>MIN</b>	0,28	0,73	0,28	0,73
<b>Deviation</b>	<b>0,01%</b>	<b>0,05%</b>	<b>0,01%</b>	<b>0,05%</b>

### 2.4 VoidInspect mit Deep Learning

Neben der einfachen Void Calculation kann man auch bei einem MXI-System die Zeit der Bildaufnahme für die Erstellung des Volumens minimieren. Dies geschieht beispielsweise durch Deep Learning, im vorliegenden Fall mit dem Produkt Dragonfly der Firma ORS (Object Research Systems, Kanada). ORS gehört seit 2019 zur Comet AG, zu der auch die YXLON International GmbH gehört.

Dabei kann die Anzahl der Projektionen drastisch reduziert werden, indem die Projektionen mit einem geeigneten Algorithmus qualitativ verbessert werden. Die Zeitersparnis in Folge der Verwendung von Deep Learning durch Verringerung der Anzahl der Projektionen und dadurch einer schnelleren Rekonstruktion kann bis zu 80 % betragen. Dies wird anhand einer Void Calculation bei

LEDs vorgestellt. Ausgewertet wurden sechs LEDs für eine traditionelle Void Calculation via CL und VoidInspect CL.




Abbildung 30: Schicht mit 2 LEDs in einem Laminographie-Volumen für die Void-Auswertung

Tabelle 8: Auswertung LED #20, 10 Reports

LED #20	P1 Single	P1 Total	P3 Single	P3 Total	P4 Single	P4 Total	P6 Single	P6 Total
1	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
2	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
3	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
4	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
5	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
6	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
7	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
8	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
9	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
10	8,46	10,11	2,88	3,38	9,28	11,74	1,41	
<b>Average</b>	<b>8,46%</b>	<b>10,11</b>	<b>2,88%</b>	<b>3,38%</b>	<b>9,28%</b>	<b>11,74%</b>	<b>1,41%</b>	
<b>Deviation</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>	<b>0%</b>	

Tabelle 9: Auswertung von 20 LEDs, jeweils 10 Reports

LED all								
Volumes #	P1 Single	P1 Total	P3 Single	P3 Total	P4 Single	P4 Total	P6 Single	P6 Total
1	8,55	10,19	2,89	3,39	9,38	11,84	1,45	4,3
2	8,55	10,21	2,91	3,41	9,41	11,88	1,45	4,32
3	8,67	10,26	2,87	3,37	9,38	11,82	1,4	4,15
4	8,59	10,18	2,89	3,35	9,34	11,78	1,42	4,22
5	8,56	10,2	2,94	3,45	9,42	11,88	1,43	4,28
6	8,65	10,25	2,87	3,34	9,34	11,78	1,42	4,21
7	8,56	10,22	2,9	3,41	9,41	11,87	1,42	4,29
8	8,54	10,22	2,89	3,4	9,4	11,87	1,44	4,28
9	8,5	10,16	2,88	3,38	9,35	11,85	1,42	4,25
10	8,55	10,21	2,9	3,39	9,39	11,87	1,44	4,31
11	8,53	10,2	2,9	3,43	9,37	11,89	1,43	4,32
12	8,52	10,18	2,92	3,43	9,35	11,82	1,4	4,26
13	8,49	10,14	2,88	3,37	9,35	11,82	1,43	4,26
14	8,49	10,13	2,9	3,41	9,38	11,83	1,42	4,21
15	8,47	10,1	2,87	3,35	9,33	11,79	1,4	4,22
16	8,54	10,18	2,92	3,45	9,37	11,84	1,45	4,33
17	8,57	10,23	2,92	3,44	9,42	11,96	1,45	4,34
18	8,49	10,13	2,89	3,39	9,32	11,76	1,41	4,24
19	8,48	10,11	2,9	3,39	9,36	11,83	1,42	4,24
20	8,46	10,11	2,88	3,38	9,28	11,74	1,41	4,23
<b>Average</b>	<b>8,538</b>	<b>10,1805</b>	<b>2,896</b>	<b>3,3965</b>	<b>9,3675</b>	<b>11,836</b>	<b>1,4255</b>	<b>4,263</b>
<b>Min</b>	<b>8,47%</b>	<b>10,10%</b>	<b>2,87%</b>	<b>3,35%</b>	<b>9,28%</b>	<b>11,74%</b>	<b>1,40%</b>	<b>4,15%</b>
<b>Max</b>	<b>8,67%</b>	<b>10,26%</b>	<b>2,94%</b>	<b>3,49%</b>	<b>9,42%</b>	<b>11,96%</b>	<b>1,45%</b>	<b>4,34%</b>
<b>Deviation</b>	<b>0,20%</b>	<b>0,16%</b>	<b>0,07%</b>	<b>0,13%</b>	<b>0,14%</b>	<b>0,22%</b>	<b>0,05%</b>	<b>0,19%</b>



Betrachtet man die Reports eines Volumens, erhält man wie erwartet eine Abweichung von 0% für die Single und Total Voids (Tabelle 8). Bei Auswertung aller Reports für alle Volumen beträgt die Abweichung.

Obwohl VoidInspect CL mit Laminographie-Volumen sehr gute Ergebnisse mit minimalen Abweichungen liefert, ist es doch zu zeitintensiv, um eine Alternative zu einem AXI-System darzustellen. Qualitätsmäßig liegt ein MXI-System im Vergleich weit vorne, was aber fehlt ist die Geschwindigkeit eines AXI-Systems. Ein MXI-System wird dabei zwar nie den Durchsatz eines AXI-Systems erreichen, hat aber viele Vorteile gerade bei der Fehleranalyse. Doch auch beim Durchsatz eines MXI-Systems bestehen Möglichkeiten, diesen zu verbessern – beispielsweise, wie hier vorgestellt, mit Deep Learning.

Es wurden von einer LED jeweils Volumen mit 10, 30 und 200 Projektionen erstellt. Die Volumen mit 200 Projektionen dienen dabei als Referenz. Ziel war es, Volumen mit 10 oder 30 Projektionen im Hinblick auf die Auswertbarkeit mittels Deep Learning auf die Datenqualität der Rekonstruktionen aus 200 Projektionen zu bringen.

Deep Learning teilt sich auf in eine Trainingsphase, in der ein Modell erstellt wird und eine Anwendungsphase. Mit dem trainierten Modell werden die auszuwertenden Volumen korrigiert bzw. die Datenqualität verbessert, um einen Qualitätsverlust bei der Void-Analyse zu vermeiden.

Im ersten Schritt wurden Scan-Daten von 25 LEDs erzeugt:

- Quick Scan ( $n_{exp} = 10$  bzw. 30)
- Standard Scan ( $n_{exp} = 200$ )
- Bei jedem Standard-Scan wurden die Voids manuell segmentiert.

Anschließend wurde auf Grundlage der Daten aus dem Standard-Scan ein KI-Modell darauf trainiert, die Segmentierung auf Daten aus dem Quick Scan durchzuführen:

- 20 LEDs wurden für das Training verwendet.
- Auf 5 LEDs wurde das KI-Modell angewendet.

Abbildung 31 zeigt einen Vergleich der Schichtbilder mit einer unterschiedlichen Anzahl an Projektionen.



Abbildung 31: Schnittbilder aus Rekonstruktionen mit 200 Projektionen, 30 Projektionen und 10 Projektionen (von links nach rechts)




Abbildung 32: Vergleich der Schichtbilder – Trainingsphase mit 10 Projektionen

In Abbildung 32 ist das Ergebnis für Daten aus 10 Projektionen dargestellt, mit den folgenden Bezeichnungen:

$N_{exp} = 200$ : Referenzvolumen mit 200 Projektionen

$N_{exp} = 10$ : rekonstruiertes Volumen mit 10 Projektionen

$Dice_{Void} = 0,82$  – Koeffizient der erkannten Voids im Vergleich zur Referenz mit 200 Projektionen

Das rekonstruierte Volumen mit 10 Projektionen weist zu viele Tomosynthese-Artefakte auf, die gerade die kleinen Voids überlagern und unauswertbar machen. Der erreichte Koeffizient  $Dice_{Void}$  entspricht mit durchschnittlich etwas über 0,8 nicht den Anforderungen.




Abbildung 33: Vergleich der Schichtbilder – Trainingsphase mit 30 Projektionen

Im aus 30 Projektionen rekonstruierten Volumen sind sehr viel weniger Tomosynthese-Artefakte vorhanden (Abbildung 33). Kleinere Voids sind auch in diesem Volumen schon ersichtlich. Eine Void Calculation mit diesem Volumen würde aber zu einer sehr viel geringeren Wiederholgenauigkeit als benötigt führen. Die Verbesserung mit Deep Learning ergibt hier einen  $Dice_{Void}$ -Koeffizienten von durchschnittlich 0,98, d.h. das mittels Deep Learning verbesserte Volumen entspricht ziemlich genau einem aus 200 Projektionen erstellten Volumen. Das nahezu identische Ergebnis lässt sich dabei mit 85% weniger Projektionen und einer um ca. 50% verkürzten Rekonstruktionszeit erzielen, was insgesamt zu einem um ca. 80% verringerten Zeitaufwand führt.

**Zusammenfassend lässt sich für das gewählte Beispiel feststellen:**

*Volumen mit 10 Projektionen:*

Die automatische Segmentierung von Voids in Volumen aus 10 Projektionen ist möglich, erzeugt aber keine hinreichend reproduzierbaren Ergebnisse. Bei Voids, die schon sehr schlecht visuell erkennbar sind, ergeben sich zu viele Fehler im Vergleich zu Volumen mit 200 Projektionen. Der Koeffizient  $Dice_{Void}$  liegt durchschnittlich bei etwas über 0,8 und damit deutlich zu niedrig.

*Volumen mit 30 Projektionen:*

Die automatische Segmentierung von Volumen aus 30 Projektionen ist sehr viel besser im Vergleich zu Volumen aus 10 Projektionen und liefert vergleichbare Ergebnisse zu Volumen aus 200 Projektionen. Mit 85% weniger Projektionen und einer um ca. 50% verkürzten Rekonstruktionszeit kommt man mit einem 80% verringerten Zeitaufwand zu einem nahezu identischen Ergebnis. Der Koeffizient  $Dice_{Void}$  liegt durchschnittlich bei 0,98.

Im Allgemeinen gilt: je mehr Iterationen (epoch) für das Training des KI-Modells genutzt werden, desto mehr nähert sich der Koeffizient  $Dice_{Void}$  dem Wert 1 (ideal) an, wie in Abbildung 34 ersichtlich wird. Es kann aber auch vorkommen, dass ein Volumen „übertrainiert“ wird und der Koeffizient  $Dice_{Void}$  abfällt. In diesem Fall wurde jeweils mit dem Modell gearbeitet, das den höchsten  $Dice_{Void}$ -Koeffizienten aufwies.

**3 Zusammenfassung**

Bisher war die Void-Messung an komplexen Leiterplatten sehr zeitaufwändig und nur eingeschränkt möglich. Entweder konnten nur die Bereiche des Bauteils in 2D ausgewertet werden, die nicht von anderen Bauteilen überdeckt sind.

Auswertungen mit MXI-Systemen waren aufwändig, nicht userfreundlich organisiert und basierten ebenso auf Algorithmen, die für 2D-Messungen ausgelegt sind.

Mit dem neuen VoidInspect CL Workflow, bietet sich nun die Möglichkeit halbautomatisiert Voids in den verschiedensten Bauteilen in CL-Volumen in einer hohen Qualität zu bestimmen und dabei die Wiederholbarkeit, Verlässlichkeit des Ergebnisses und Kosteneffizienz zu steigern.

Auch für den Semiconductor-Bereich, der naturgemäß sehr viel höhere Ansprüche hat (bis hin zu Microbumps (Faktor 80 kleiner als BGAs), ist der Workflow geeignet. Der Workflow bietet über Deep Learning ebenfalls die Möglichkeit Scan- und Auswertzeiten erheblich zu verkürzen – ohne Verschlechterung der Wiederholgenauigkeit.

Somit haben Kund\*innen die Möglichkeit bei sehr komplexen Prüfungen, schnell und teilautomatisiert eine Prüfentscheidung zu erhalten. Das ist vor allem ein Vorteil bei sehr komplexen Prüfungen, bei denen eine voll „ADR“ heute noch nicht zum Einsatz kommen kann.

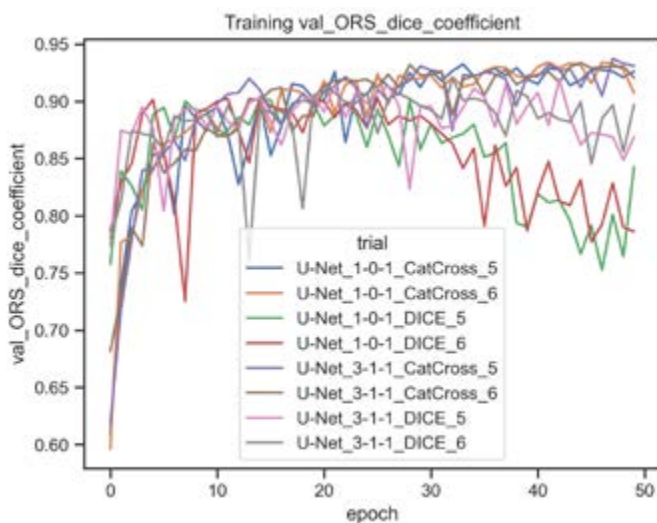


Abbildung 34: Trainingsfortschritt der Modelle