


# Fundamental neue Rekonstruktionstechnologie – KI und Deep Learning in der CT

Die Ansprüche steigen und die Radiologie wird komplexer – immer mehr ist in immer kürzerer Zeit zu bewältigen. Die richtige und sichere Diagnose ist und bleibt der Schlüssel für die weitere Behandlung der Patienten. Dabei profitieren RadiologInnen von neuester Technologie, die sie in der Klinik unterstützt.

Auf den folgenden Seiten lesen Sie Berichte namhafter Anwender der neuesten Rekonstruktionstechnologie „AiCE“ (Advanced intelligent Clear Image Quality Engine) von Canon Medical, die heute bereits zur Verfügung steht. Damit sind wir im Zeitalter der künstlichen Intelligenz nicht nur angekommen, wir machen sie nutzbar – zum Vorteil für RadiologInnen und PatientInnen.



Advanced Intelligent Clear Engine



### Technischer Hintergrund

Das Selbstlernen der Software und Deep Learning, das Lernen mittels eines neuronalen Netzwerkes, sind Teilbereiche der künstlichen Intelligenz und Megathemen der Radiologie. Canon Medical hat kürzlich die neue „AiCE“-Technologie vorgestellt, die auf diesen Megathemen basiert und die CT-Bildrekonstruktion der Zukunft schon heute anwendet. Neue Canon CTs können bereits heute von dieser Technologie profitieren.

**Die neue KI-Technologie „AiCE“ bietet eine fundamental neue Bildrekonstruktion mit überragender Bildqualität, einer bis dahin nicht erreichten Detailschärfe und einem natürlichen Bildkontrast – schon ab einer Schichtdicke von 0,5 mm.**

Dabei reduziert AiCE das Rauschen bei gleichzeitigem Erhalt der Textur und des natürlichen Bildeindrucks. AiCE lässt somit Ihre Patienten von einer bis dato nicht erreichten Dosisreduktion und Sie als Radiologen von einer gesteigerten Sicherheit bei der Diagnostik von Dünnschichtbildern profitieren.

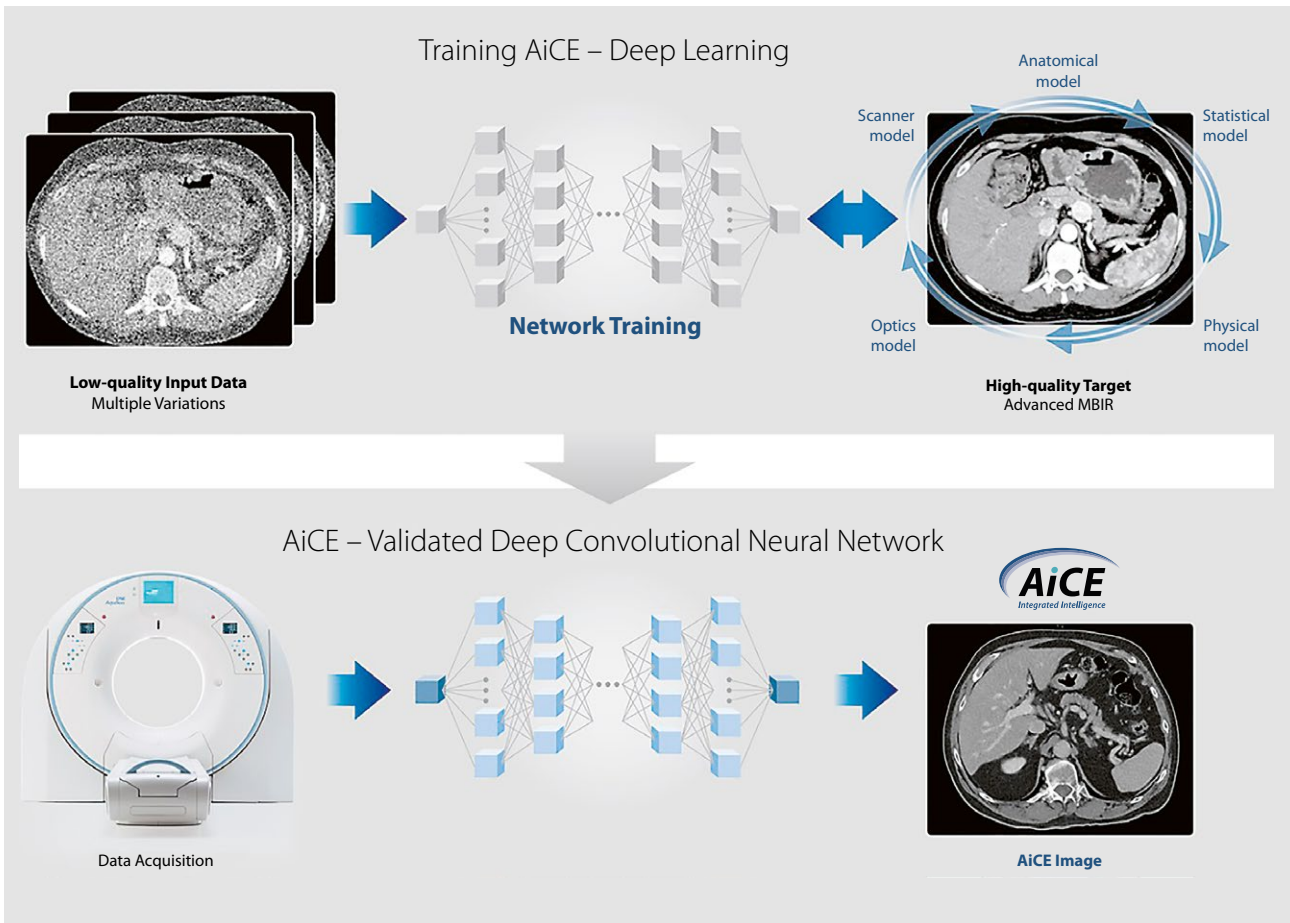
**AiCE basiert auf den Megathemen der Softwareentwicklung und setzt in der radiologischen Diagnostik neue Maßstäbe. Die Megathemen sind: Big Data: das Einspeisen von sehr großen Datenmengen in Form tausender Datensätze, Deep Learning: das Lernen mittels eines neuronalen Netzwerkes, und künstliche Intelligenz: das Selbstlernen der Software.**

Während die Rekonstruktion mittels der neuesten modellbasierten iterativen Rekonstruktion noch ein sehr rechenaufwändiger Prozess war, der mehr Zeit in Anspruch nahm und daher überwiegend selektiv eingesetzt wurde, arbeitet die neue AiCE-Rekonstruktion von Canon Medical annähernd so schnell wie die bekannte iterative Rekonstruktion und ist damit in der klinischen Routine einsetzbar.


Damit RadiologInnen in ihrer Umgebung – im Rahmen ihrer klinischen Routine – mit AiCE arbeiten können, wurden zwei Schritte vorbereitet. Im Canon Medical Systems Werk wurde

in Schritt I das neuronale Netzwerk mittels einer besonderen Hochleistungshardware aufgesetzt; es wurde ein sog. „Neural Network Training“ mit Tausenden von validierten Datensätzen durchgeführt. Dieses im Werk trainierte neuronale Netzwerk wird in Schritt II beim Kunden auf einer eigenen Hochleistungshardware installiert. Die beim Radiologen vor Ort gescannten Daten werden mittels AiCE rekonstruiert und stehen der Befundung in beeindruckender Geschwindigkeit unmittelbar zur Verfügung.

Der Trainingsprozess des neuronalen Netzwerkes ist rechnerisch sehr aufwändig: Der Massendatenspeicher „Big Data“ wurde mit zwei Arten von Datenmengen gespeist: mit einer Vielzahl hochqualitativer Datensätze, die zuvor mittels modellbasierter Iteration in den Rohdaten mit überproportional häufigen Iterationen und deutlich erhöhter Rechenleistung rekonstruiert wurden, und mit einer Vielzahl von Ultra-Low-Dose-Datensätzen, wie sie in der täglichen Routine bei Niedrigdosisuntersuchungen vorkommen.



Eine Software mit einem „Deep Convolution Neural Network“ wurde angelemt, Organstrukturen voxelgenau im menschlichen Körper zu erkennen – das neuronale Netzwerk weiß nach dem Trainingsprozess, welche Zusammenhänge zwischen Low-Dose-Datensätzen und hochqualitativen Datensätzen bestehen – dieses Wissen dient der Rekonstruktion von Low-Dose-Datensätzen zu einem perfekten diagnostischen Bild.



AiCE-Deep-Learning-Rekonstruktion für verschiedene Körperregionen.

### Lernprozess AiCE

Für den Trainingsprozess wurden reale Patientendaten bzw. Schichtbilder unterschiedlicher Körperregionen, die mit unterschiedlichen Bildqualitäten und Rekonstruktionskernels rekonstruiert wurden, in einer Datenbank zusammengestellt.

Aus den rekonstruierten Schichtbildern werden „Patches“ (Fragmente) besonderer Strukturen ausgeschnitten und als mathematische Matrizen verarbeitet. Diese Matrizen werden anhand der HU-Werte in den Schichtbildern parametrisiert. Mathematische Operationen der Patches werden auf Pixelebene mittels Faltung (Convolution) durchgeführt, bei ausreichender Wiederholung von Faltungen (Convolutionen) spricht man von einem Deep Convolutional Neural Network.

Die Matrizen werden zu künstlichen Neuronen verschaltet, die über mehrere Eingänge und einen Ausgang verfügen; der Ausgang reagiert auf die Gewichtungen der Eingänge der Neuronen.

Die Neuronen sind in mehreren „Layern“ (Schichten) organisiert, die Signale werden durch die Layer „propagiert“. Vom Eingangslayer über mehrere Zwischenlayer bis zum Ausgangslayer sind immer die Ausgänge der einzelnen Neuronen mit neuen Eingängen der nächsten Neuronen verbunden. Jedes Neuron in einem neuronalen Netzwerk berechnet einen Ausgabewert, indem eine bestimmte Funktion auf die Eingabewerte angewendet wird, die von dem vorherigen Layer stammen. Die Funktion, die auf die Eingabewerte angewendet wird, bestimmt die Gewichtungen. Das Lernen in einem neuronalen Netzwerk schreitet voran, indem iterative Anpassungen an den Gewichtungen vorgenommen werden.

Nach der Propagation findet eine Prüfung des neuronalen Netzes statt, die sog. Backpropagation. Dafür wird die Ausgabe des neuronalen Netzes mit dem erwarteten bzw. bekannten Ergebnis verglichen und eine Abweichung ermittelt. Die Abweichung wird

nun vom Ausgabebayer zum Eingabebayer zurückgegeben (Backpropagation).

Um die Abweichungen zu reduzieren, werden die Gewichtungen der Neuronen angepasst, mit jeder Anpassung wird das neuronale Netz optimiert. //

### Literatur

Boedecker K. AiCE Deep Learning Reconstruction: Bringing the power of Ultra-High Resolution CT to routine imaging. 2019

Akagi M, Nakamura Y, Higaki T et al: Deep learning reconstruction improves image quality of abdominal ultra-high-resolution CT. *Eur Radiol* 2019; 29: 6163–6171

Nakamura Y, Higaki T, Tatsugami F et al: Deep Learning-based CT Image Reconstruction: Initial Evaluation Targeting Hypovascular Hepatic Metastases. *Radiology: Artificial Intelligence* 2019; 1: e180011

Higaki T, Nakamura Y, Zhou J et al: Deep Learning Reconstruction at CT: Phantom Study of the Image Characteristics. *Academic Radiology* 2020; 27: 82–87

Narita K, Nakamura Y, Higaki T et al: Deep learning reconstruction of drip-infusion cholangiography acquired with ultra-high-resolution computed tomography. *Abdom Radiol* 2020.

