

Preisträgervortrag Österreichischer Kongress für Zahnmedizin 2022

„Automatisierte Herdbefundung in DVT Datensätzen mit Hilfe von künstlicher Intelligenz“

DDr. Barbara Kirnbauer

Kirnbauer B, Hadzic A, Jakse N, Bischof H, Stern D. Automatic Detection of Periapical Osteolytic Lesions on CBCT Using Deep CNNs. J Endod 2022; Epub ahead of print, <https://doi.org/10.1016/j.joen.2022.07.013>

Das Röntgen ist ein Werkzeug, das aus dem zahnmedizinischen Alltag nicht wegzudenken ist. In erster Linie werden dabei 2D-Techniken wie intraorale Kleinbildröntgen oder Panoramaröntgen eingesetzt. Darüber hinaus kommt seit mehr als zwanzig Jahren die Digitale Volumentomographie (DVT, englisch: CBCT, cone beam computed tomography) als 3dimensionales bildgebendes Verfahren zum Einsatz. Der Schwerpunkt liegt dabei auf der Hartgewebeabbildung mit Visualisierung von Zähnen und knöchernen Strukturen der Kiefer und des Schädels. (1) Die Indikationen für eine Überweisung zum DVT sind vielfältig. Dementsprechend steigt die Zahl der durchgeführten Untersuchungen, wobei jeder Datensatz, gemäß gesetzlicher Vorgaben, einer genauen Befunderhebung mit anschließender schriftlicher Dokumentation unterzogen werden muss. Die Auflistung sämtlicher Haupt- und Nebenfunde inklusive ihrer Interpretation bedeutet einen erheblichen ärztlichen Zeitaufwand. (1,2) Zu den häufigsten pathologischen Veränderungen in der Zahnmedizin zählen osteolytische Kieferläsionen im Bereich der Wurzelspitzen als Folge einer bakteriellen, zahnassozierten Infektion. Potentiell kann jede der bis zu 30 Wurzeln pro Kiefer betroffen sein. Diese Pathologien, die als apikale Parodontitiden bezeichnet werden, treten als radioluzente Bereiche auf, die im Durchmesser von einer einfachen Verbreiterung des Parodontalspalttes bis zu mehreren Millimetern variieren können. Ihre Form ist meist kugelig bis ellipsoid, wobei sie vollständig knochenringt sind oder die angrenzenden anatomischen Strukturen überschreiten können. Die Identifizierung ist insofern wichtig, um Schmerzen und Komplikationen wie Abszessbildung bis hin zum Zahnverlust zu verhindern und die Mund- und Allgemeingesundheit des Patienten zu erhalten oder wieder herzustellen. (3) Abgesehen davon ist aus rechtlichen Gründen die Beschreibung und Dokumentation jedes einzelnen pathologischen Befundes innerhalb eines Datensatzes vom zuständigen Zahnarzt/Zahnärztin ausnahmslos durchzuführen. Bei einer steigenden Anzahl an DVT-Untersuchung nimmt der Befundungsaufwand insgesamt deutlich zu. Die Entwicklung einer automatisierten, computergestützte Befunderhebung auf Basis von Deep learning (DL) von DVT Datensätzen, wie bereits aus anderen medizinischen Disziplinen bekannt, kann eine wesentliche Arbeitserleichterung für den Zahnarzt,

sowie eine Verbesserung im Sinne einer Qualitätssteigerung und Erhöhung der Patientensicherheit darstellen. (4)

Maschinelles Lernen (ML) ist ein Teilgebiet der künstlichen Intelligenz, das statistische Methoden anwendet, um Muster in Daten zu finden. Deep Learning ist ein Ansatz, der in ML verwendet wird, um Abstraktionen in Daten mithilfe künstlicher neuronaler Netzwerke (KNNs) effizient zu modellieren. Convolutional Neural Networks (CNNs) sind eine Art von deep KNNs, die speziell darauf ausgelegt sind, räumliche Strukturen in Bildern zu erkennen. Das Kennzeichen eines CNN ist eine Faltungsschicht, welche aus mehreren unabhängigen Kernen besteht. Ein Kern ist eine Menge von Neuronen, die Faltungsoperationen auf die Ausgabe der vorigen Schicht anwendet. CNN- Architekturen können sich in der Anzahl der Schichten und in der Anzahl und Größe der Faltungskerne, die in jeder Schicht verwendet werden, unterscheiden. Der gebräuchlichste Ansatz, um die optimalen Parameter für Faltungskerne von CNN-Modellen zu finden, ist überwachtes Lernen. Die Aufgabe dieser Methode besteht darin, mit erlernten Optimalparametern ein Modell zu erstellen, welches zu einer gegebenen Eingabe die korrekte Ausgabe möglichst gut vorhersagt. Deswegen besteht das Trainingsset nicht nur aus Eingabebildern, sondern auch aus den dazugehörigen (gewünschten) Ausgabewerten.(5)

Im Rahmen einer Forschungskoooperation der Meduni Graz und der TU Graz erfolgte die Entwicklung eines Algorithmus zur automatisierten Befundung von periapikalen osteolytischen Läsionen (PALen) anhand von 144 DVT Datensätzen. Dieser entwickelte Algorithmus befähigt ein Software zum selbständigen Lernen und zur Detektion von PALen innerhalb zuvor nicht gescreenter DVT-Datensätze anhand zweier hintereinandergeschalteter deep CNNs (Abbildung 1).

Die Besonderheit besteht darin, dass hierbei ein vollautomatisierter Workflow verwirklicht werden konnte und mit Hilfe der beiden hintereinander verwendeten Netzwerke zuerst die Zahnerkennung im Datensatz und danach erst die Detektion der PALs unter Erhalt der detaillierten Auflösung durchgeführt wurde. Die Ergebnisse des präsentierten Projektes zeigen nun eine Sensitivität von 97.1% und eine Spezifität von 88% bezüglich Läsionserkennung. (6) Verglichen mit Angaben aus der Literatur (7,8) übertrifft der entwickelte Algorithmus die bisher publizierten Methoden im Bereich der PAL-

Erkennung deutlich und kann somit als Basis für weitere Entwicklungen bis hin zum Einsatz im klinischen Alltag gesehen werden.

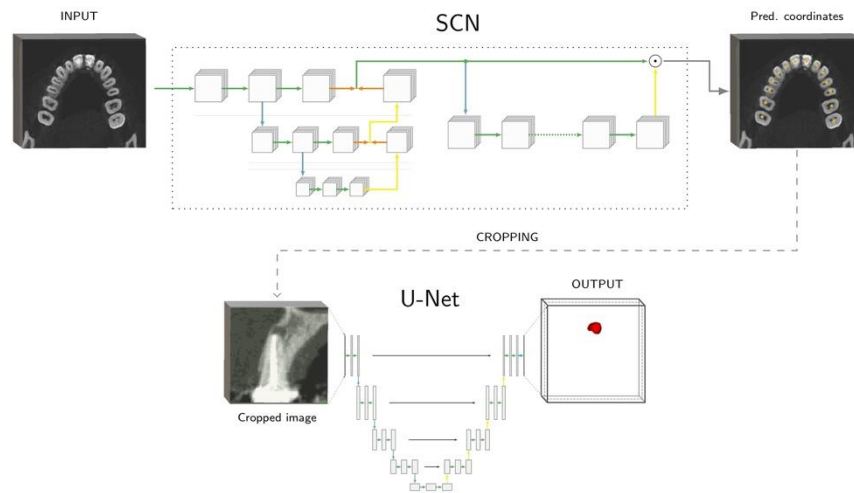


Abbildung 1: Schematische Darstellung der beiden hintereinandergeschalteten Netzwerke (SCN und U-Net) erstens zur Zahnerkennung und zweitens zur Läsionserkennung unter Erhalt der hohen Auflösungskapazität der DVT-Datensätze.

- (1) Jacobs R, Salmon B, Codari M, Hassan B, Bornstein MM. Cone beam computed tomography in implant dentistry: recommendations for clinical use. *BMC Oral Health* 2018 May 15;18(1):88-018.
- (2) SEDENTEXCT. 2018; Available at: <http://www.sedentext.eu>. Accessed 05/18, 2019.
- (3) Aberg F, Helenius-Hietala J, Meurman J, Isoniemi H. Association between dental infections and the clinical course of chronic liver disease. *Hepatol Res* 2014 March 01;44(3):349-353.
- (4) Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, et al. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol* 2019 May 01;48(4):20180051.
- (5) Hung K, Yeung AWK, Tanaka R, Bornstein MM. Current Applications, Opportunities, and Limitations of AI for 3D Imaging in Dental Research and Practice. *Int J Environ Res Public Health* 2020 June 19;17(12):4424. doi: 10.3390/ijerph17124424.
- (6) Kirnbauer B, Hadzic A, Jakse N, et al. Automatic Detection of Periapical Osteolytic Lesions on CBCT Using Deep CNNs. *J Endod* 2022; Epub ahead of print, <https://doi.org/10.1016/j.joen.2022.07.013>
- (7) Orhan K, Bayrakdar IS, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *Int Endod J* 2020 May 01;53(5):680-689.
- (8) Setzer FC, Shi KJ, Zhang Z, Yan H, Yoon H, Mupparapu M, et al. Artificial Intelligence for the Computer-aided Detection of Periapical Lesions in Cone-beam Computed Tomographic Images. *Journal of Endodontics* Invalid date Invalid date;46(7):987-993.