

# Mesterséges intelligencia alkalmazása fogászati cone-beam számítógépes tomográfias felvételek automatikus szegmentációjára

Hegyi Alexandra<sup>1</sup> ■ Somodi Kristóf dr.<sup>1</sup> ■ Pintér Csaba dr.<sup>2, 3</sup>  
Molnár Bálint dr.<sup>1, 3</sup> ■ Windisch Péter dr.<sup>1, 3</sup> ■ García-Mato, David dr.<sup>3</sup>  
Diaz-Pinto, Andres dr.<sup>4</sup> ■ Palkovics Dániel dr.<sup>1, 3</sup>

<sup>1</sup>Semmelweis Egyetem, Fogorvostudományi Kar, Parodontológiai Klinika, Budapest

<sup>2</sup>Empresa de Base Tecnológica Internacional de Canarias, S. L. (EBATINCA),  
Las Palmas de Gran Canaria, Spanyolország

<sup>3</sup>Dent.AI Medical Imaging, Budapest

<sup>4</sup>School of Biomedical Engineering & Imaging Sciences, King's College London, London, Anglia

**Bevezetés:** A 'cone-beam' (kúpsugaras) számítógépes tomográfias (CBCT) felvételek szegmentációja során a síkbeli képekből álló adatokat három dimenzióban (3D) rekonstruáljuk. A szájszövetben és a parodontológiában a digitális adatfeldolgozás lehetővé teszi a műtéti beavatkozások 3D tervezését. A leggyakrabban alkalmazott határérték-alapú szegmentáció gyors, de pontatlan, míg a félautomatikus módszerek megfelelő pontosságúak, de rendkívül időigényesek. Az utóbbi években a mesterséges intelligencián alapuló technológiák elterjedésével azonban mostanra lehetőség van a CBCT-felvételek automatikus szegmentációjára.

**Célkitűzés:** A klinikai gyakorlatból vett CBCT-felvételeken betanított mélytanulási szegmentációs modell bemutatása és hatékonyságának vizsgálata.

**Módszer:** A vizsgálat három fő fázisa volt: a tanuló adatbázis felállítása, a mélytanulási modell betanítása és ezen architektúra pontosságának tesztelése. A tanuló adatbázis felállításához 70, részlegesen fogatlan páciens CBCT-felvételeit alkalmaztuk. A SegResNet hálózati architektúrára épülő szegmentációs modellt a MONAI rendszer segítségével fejlesztettük ki. A mélytanulási modell pontosságának ellenőrzéséhez 15 CBCT-felvételt használtunk. Ezeket a felvételeket a mélytanulási modell segítségével, valamint félautomatikus szegmentációval is feldolgoztuk, és összehasonlítottuk a két szegmentáció eredményét.

**Eredmények:** A mélytanulási szegmentáció és a félautomatikus szegmentáció közötti hasonlóság a Jaccard-index szerint átlagosan  $0,91 \pm 0,02$ , a Dice hasonlósági együttható átlagos értéke  $0,95 \pm 0,01$ , míg a két modell közötti átlagos Hausdorff- (95%) távolság  $0,67 \text{ mm} \pm 0,22 \text{ mm}$  volt. A mélytanulási architektúra által szegmentált és a félautomatikus szegmentációval létrehozott 3D modellek térfogata nem mutatott statisztikailag szignifikáns különbséget ( $p = 0,31$ ).

**Megbeszélés:** A vizsgálatunkban használt mélytanulási modell az irodalomban található mesterségesintelligencia-rendszerekhez hasonló pontossággal végezte el a CBCT-felvételek szegmentációját, és mivel a CBCT-felvételek a rutin klinikai gyakorlatból származtak, a mélytanulási modell relatíve nagy megbízhatósággal szegmentálta a parodontális csonttopográfiát és az alveolaris gerincdefektusokat.

**Következtetés:** A mélytanulási modell nagy pontossággal szegmentálta az alsó állcsontot dentális CBCT-felvételeken. Ezek alapján megállapítható, hogy a mélytanulási szegmentációval előállított 3D modell alkalmas lehet rekonstruktív szájszöveti és parodontális sebészeti beavatkozások digitális tervezésére.

Orv Hetil. 2024; 165(32): 1242–1251.

**Kulcsszavak:** cone-beam számítógépes tomográfia, számítógépes 3D leképezés, mesterséges intelligencia, mélytanulás, konvolúciós neurális háló, mandibula

## Automatic segmentation of dental cone-beam computed tomography scans using a deep learning framework

**Introduction:** The goal of segmentation is to reconstruct cone-beam computed tomography (CBCT) images in three dimensions (3D). In oral surgery and periodontology, digital data processing enables 3D planning of surgical interventions. Commonly used threshold-based segmentation is fast but inaccurate, whereas semi-automatic methods are sufficiently accurate but time-consuming. Recently, with artificial intelligence-based technologies, automatic segmentation of CBCT images has become feasible.

**Objective:** To present a deep learning segmentation model trained on CBCT images derived from clinical practice and to evaluate its efficiency.

**Method:** The study consisted of three phases: establishing the training dataset, training the deep learning model and testing its accuracy. CBCT images of 70, partially edentulous patients were used to establish the training dataset. The deep learning model, based on the SegResNet architecture, was developed within the MONAI framework. To verify the accuracy of the deep learning model, 15 CBCT scans were used processed using the deep learning-based segmentation and semi-automatic segmentation, and the results were compared.

**Results:** The similarity between the two methods, based on intersection over union, was on average  $0.91 \pm 0.02$ . The average Dice similarity coefficient was  $0.95 \pm 0.01$ , and the average Hausdorff (95%) distance was  $0.67 \text{ mm} \pm 0.22 \text{ mm}$ . There was no statistically significant difference in the volume of the 3D models segmented by the deep learning architecture compared to those created by semi-automatic segmentation ( $p = 0.31$ ).

**Discussion:** The deep learning model used in our study performed segmentation of CBCT images with accuracy comparable to other artificial intelligence-based systems reported in the literature. Since the CBCT images were sourced from routine clinical practice, the deep learning model segmented periodontal bone topography and alveolar ridge defects with relatively high reliability.

**Conclusion:** The deep learning model accurately segmented the mandible in dental CBCT scans. Therefore, the deep learning-based 3D models could be suitable for digital planning of reconstructive oral and periodontal surgical interventions.

**Keywords:** cone-beam computed tomography, computer-generated 3D imaging, artificial intelligence, deep learning, convolutional neural networks, mandible

Hegy A, Somodi K, Pintér Cs, Molnár B, Windisch P, García-Mato D, Diaz-Pinto A, Palkovics D. [Automatic segmentation of dental cone-beam computed tomography scans using a deep learning framework]. *Orv Hetil.* 2024; 165(32): 1242–1251.

(Beérkezett: 2024. május 23.; elfogadva: 2024. június 10.)

### Rövidítések

3D = háromdimenziós; CBCT = (cone-beam computed tomography) kúpsugaras számítógépes tomográfia; CNN = (convolutional neural network) konvolúciós neuralis háló; CT = (computed tomography) számítógépes tomográfia; DSC = (Dice similarity coefficient) Dice hasonlósági együttható; FN = (false negative) álnegatív; FP = (false positive) álpozitív; HD95 (Hausdorff distance 95%) a Hausdorff-távolság 95%-os percentilise; IoU = (intersection over union) Jaccard-index; ReLU = (rectified linear unit) rektifikált lineáris egység; SE RKEB = Semmelweis Egyetem, Regionális Kutatásetikai Bizottság; TN = (true negative) valódi negatív; TP = (true positive) valódi pozitív

A digitális technológia fejlődése jelentős hatással van az orvostudományra, folyamatosan formálja a beavatkozások menetét és a klinikai döntéshozatalt. A fogorvoslásban és a szájsebészetben ez a technológiai fejlődés lehetővé tette a hatékonyabb diagnózis felállítását és a személyre szabott kezelési módokat. A számítógépes technológiák számos formája – digitális képfeldolgozás,

3D modellezés, additív előállítás, mesterséges intelligencia – hozzájárulhat a fogorvosi műtéti beavatkozások kiszámíthatóbb elvégzéséhez, csökkentve az intraoperatív és a posztoperatív szövődmények előfordulását.

*Barr, Feigenbaum és Cohen* szerint a mesterséges intelligencia a számítástechnika azon része, amely az emberi viselkedéssel és intelligenciával azonosított tulajdonságokat – például nyelvértés, tanulás, következtetés, problémamegoldás – mutató, intelligens számítógépes rendszer tervezésével foglalkozik [1]. A mesterséges intelligencia alkalmazása számos területen azt célozza, hogy könnyebbé tegye az emberi munkát, és segítse a döntéshozatal folyamatát. Felhasználása mind az általános medicinában, mind pedig a fogorvoslás területén egyre inkább a mindennapi rutin betegellátás részét képezi [2–4]. A fogorvoslás területén a különböző gépi tanulási (machine learning) és mélytanulási (deep learning) módszereket a leggyakrabban a radiológiai kép-analízisben és képfeldolgozásban alkalmazzák [5, 6]. Ezenfelül mesterséges intelligencián alapuló technológiákat használnak a (i) klinikai döntéstámogatás, (ii) predik-

ció, (iii) klinikai képanalízis, (iv) természetes nyelvfeldolgozás/nagy nyelvi modellek, (v) robotasszisztált beavatkozások [7] esetében.

A volumetrikus képalkotó modalitások szegmentációjának célja, hogy az alapvetően síkbeli képekből álló adathalmazokon (például számítógépes tomográfia [CT], kúpsugaras számítógépes tomográfia [cone-beam computed tomography: CBCT]) a releváns anatómiai struktúrákat három dimenzióban (3D) rekonstruálja [8]. A szájszéjszövetben, a parodontológiában, az implantológiában és az arc- és állcsontsebészetben a digitális preoperatív adatfeldolgozás lehetővé teszi a műtéti beavatkozások 3D tervezését és az irányított sebészeti beavatkozások elvégzését. Szegmentáció céljából korábban határérték-alapú és félautomatikus eljárásokat alkalmaztunk [9–11]. A határérték-alapú szegmentáció egyszerű, de pontatlan 3D képrekonstrukciót eredményez, míg a félautomatikus szegmentációs módszer nagy pontosságú, de rendkívül időigényes [8]. A mesterséges intelligencián alapuló technológiák fejlődésével azonban lehetőség nyílt automatikus mélytanulás-alapú szegmentációra, melynek előnye, hogy képes megfelelő pontosságú modellek előállítására amellet, hogy nagymértékben csökkenti az adatfeldolgozás időtartamát.

A mesterséges intelligencián alapuló szegmentációs modellek fejlesztéséhez szükség van egy tanuló adatbázisra, mely előre feldolgozott CBCT-felvételeket tartalmaz. A feldolgozott képeken való tanulási ciklusokat követően a mesterségesintelligencia-modell a nem annotált képek szegmentációját is képes elvégezni. A megbízható eredmény eléréséhez fontos a tanuló adatbázis elemei közötti kis variabilitás, melynek elérésére a legtöbbször az adatbázisba beválogatott CBCT csak teljesen megtartott fogazatú páciensek CBCT-felvételeit tartalmazza. *Verhelst és mtsai* [12] kétfázisú 3D U-Net-alapú architektúrát használó konvolúciós hálózatot (convolutional neural network: CNN) alkalmaztak a mandibula automatikus szegmentációjára. Tanulmányuk eredménye azt mutatta, hogy az általuk használt CNN lehetővé teszi nagy felbontású CBCT-felvételek szegmentációját, és a segítségével automatikusan létrehozható az alsó állcsont 3D felszíni modellje.

A páciensek fogazati állapota, az állcsontok alakja, a meglévő fogak száma, a patológiás elváltozások morfológiája, valamint fogászati implantátumok/fogpótlások megléte miatt a CBCT-felvételek között nagy fokú a variabilitás. Ez alapvető nehézséget okoz a fogak és az alveolaris csont szegmentációja és a mélytanulási szegmentációs modell kifejlesztése során. Ezért a legtöbb kifejlesztett szegmentációs modell csak teljesen megtartott fogazatú páciensek CBCT-felvételeit tartalmazó adatbázison lett betanítva, ezáltal is növelve az adatbázis homogenitását [12–14]. Ám a megtartott fogazatú páciensek CBCT-felvételein tanított mesterségesintelligencia-modellek nem biztos, hogy megbízhatóan alkalmazhatók a különböző patológiás elváltozások felismerésében és rekonstrukciójában. Ezzel szemben a heterogén adatbázi-

sokon tanított mesterségesintelligencia-modellek képek lehetnek különböző patológiás elváltozások (például alveolaris gerincdefektusok, parodontalis intraossealis defektusok) felismerésére, ehhez azonban nagy méretű tanuló adatbázisra vagy a jelenlegi módszereknél hatékonyabban működő mélytanulási architektúra alkalmazására van szükség.

Ezért ennek a vizsgálatnak az a célja, hogy bemutasson egy, a klinikai gyakorlatból vett CBCT-felvételeken betanított mélytanulási modellt, valamint megvizsgálja ennek hatékonyságát részlegesen fogatlan páciensek CBCT-felvételeinek automatikus szegmentációjában.

## Módszer

### *A vizsgálat felépítése*

A vizsgálat három fő fázisból állt: (i) a tanuló adatbázis felállítása, (ii) a mélytanulási architektúra betanítása, (iii) a mélytanulási architektúra pontosságának tesztelése. A jelen mélytanulási architektúra kifejlesztéséhez 70 (57 tanításra, 13 validációra), részlegesen fogatlan, alveolaris gerinc-rekonstrukció/parodontalis regeneratív beavatkozás előtt álló páciens CBCT-felvételeit alkalmaztunk. A kiválasztott és feldolgozott adatokat többszintű mélytanulási keretrendszer felállításához használtuk. Az automatikus szegmentációs modell tesztelése során a tanuló adatbázistól független CBCT-felvételeket mind a mélytanulási modell, mind pedig a félautomatikus szegmentáció segítségével feldolgoztuk. Ennek célja a mélytanulási szegmentáció hatékonyságának meghatározása. A mélytanulási modell egyidejűleg szegmentálta az alsó állcsontot, a fogakat és az infraalveolaris ideget, a jelen vizsgálatban azonban csak a mandibula szegmentációjának pontosságát vizsgáltuk.

A vizsgálat a 2008. évi helsinki orvostikai iránymutatásoknak megfelelően zajlott, és vizsgálati protokollját a Semmelweis Egyetem Regionális, Intézményi Tudományos és Kutatás-Értékelési Bizottsága jóváhagyta (etikai engedélyszám: SE RKEB 138/2023). A vizsgálatot a *Schwendicke és mtsai* által közzétett „Artificial intelligence in dental research: checklist for authors, reviewers and readers” [15] szakmai iránymutatása alapján végeztük.

### *Beválasztási kritériumok, a CBCT-felvételek paraméterei*

A tanuló adatbázis felállításához a Semmelweis Egyetem Parodontológiai Klinikáján kezelt páciensek CBCT-felvételeit használtuk fel. A CBCT-felvételeket a rutinszerű klinikai gyakorlatból szereztük be, a tanulmány céljából külön CBCT-felvételek nem készültek.

A tanuló adatbázisba beválogattuk azokat a CBCT-felvételeket, amelyekre tömések, koronák, hidak, gyökérkezelt fogak vagy esetleges korábbi rekonstrukív műtétek során beültetett titánszegek láthatók. Kizártuk

azonban a teljesen fogatlan páciensek CBCT-felvételeit, illetve a fogászati implantátumokat és a teljes állcsontra kiterjedő, rögzített fémrestaurátumokat (körhíd) tartalmazó felvételeket. A mélytanulási modell tanításához kizárólag a teljes alsó és felső állcsontot tartalmazó, dentális CBCT-felvételeket használtuk fel. Teljes koponya-CBCT-felvételeket, fej-nyaki konvencionális CT-felvételeket, kis térfogatú, részleges állcsontot leképező CBCT-felvételeket nem alkalmaztunk a mélytanulási modell tanításához. A beválogatott páciensek CBCT-felvételeinek további feldolgozásához a CBCT-adatokat anonimizáltuk.

A tanuló adatbázisba bevásárolt felvételek az alábbi paraméterekkel rendelkeztek:

- I-CAT FLX® (KaVo Dental GmbH, Bieberach an der Riß, Németország), 300 µm voxelméret, 120 kV feszültség, 36 mA áramerősség;
- Planmeca Viso® (Planmeca, Helsinki, Finnország), 150 µm voxelméret, 100 kV feszültség, 12 mA áramerősség.

A tanításhoz alkalmazott CBCT-felvételeket 200 µm voxelmérettel újramintáztuk, minthogy a 200 µm-es felbontás még megbízhatóan alkalmazható műtéti tervezésre [16].

### A tanuló adatbázis felállítása

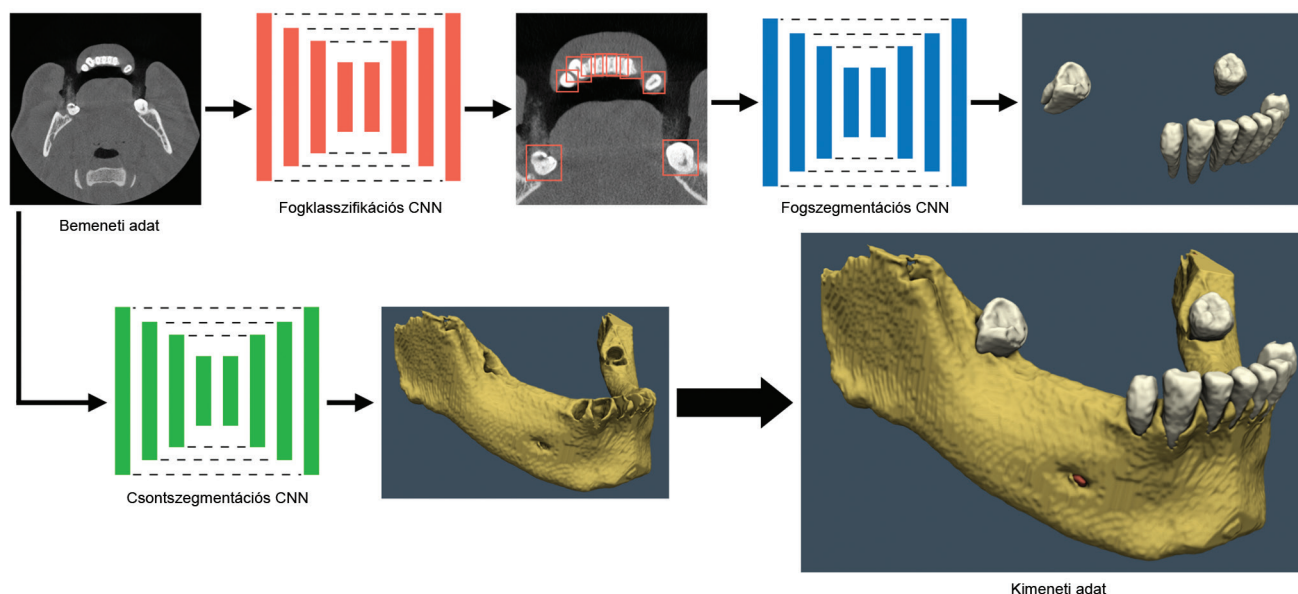
A tanításhoz alkalmazott CBCT-felvételeket a 3D Slicer (www.slicer.org) [17] nyílt forráskódú radiológiai képfeldolgozó szoftverbe importáltuk, és egy korábban már leírt félautomatikus módszerrel szegmentáltuk [8]. Az adatbázis felállításához szükséges CBCT-felvételek szegmentációját minden esetben maxillofacialis radiológiában jártas szakember végezte (PD), mely szegmentáció

pontosságát egy második szakértő ellenőrizte. Szegmentáláshoz a 3D Slicer „Segment Editor” moduljában található eszközöket alkalmaztuk [18]. A mandibula szegmentálásához a „Grow from seeds” régiónöveléses eszközt alkalmaztuk, a fogakat pedig vízfelöntéses algoritmussal („Watershed”) szegmentáltuk. Az infraalveolaris ideg szegmentálásához a „Draw tube” eszközt alkalmaztuk. A szegmentáció után a fogak, az alveolaris csont és az idegek „labelmap”-jeit egységes terminológiával és színkódolással láttuk el.

### Mélytanulási architektúra – SegResNet

Vizsgálatunkban többszintű mélytanulási keretrendszert alkalmaztunk a CBCT-adatok automatikus szegmentálásához. A mélytanulási modell két különböző fázisból áll: az első fázisban a fogak klasszifikációja és szegmentációja, a második fázisban pedig a mandibula és az infraalveolaris idegek automatikus szegmentálása történt. A szegmentációs modellt a MONAI rendszer (<https://github.com/Project-MONAI/MONAI>) segítségével fejlesztettük [19], és a 2018-ban Myronenko által leírt SegResNet (Segmented Residual Network) hálózati architektúrát vettük alapul [20]. Ez a hálózat egy 'encoder-decoder' alapú CNN, amelynek aszimmetrikusan nagyobb 'encoder' része van a képi jellemzők kinyeréséhez és egy kisebb 'decoder' része a kívánt anatómiai struktúrák szegmentációs maszkjának létrehozásához.

Az 'encoder' rész ResNet [21] rétegeket használ, ahol minden réteg két konvolúcióból, két normalizációból és két rektifikált lineáris egységből (rectified linear unit: ReLU) áll. Az általános CNN módszereknek megfelelően a képméret rétegenként folyamatosan csökken. Az egyes rétegekben a méretcsökkentő (down-sampling)



1. ábra

Kétfázisú SegResNet architektúrájú mélytanulási modell felépítése. A kétfázisú mélytanulási modell három SegResNet architektúrájú konvolúciós neurális hálót (CNN-t) alkalmaz. Az első fázisban két külön CNN végzi a fogak klasszifikációját és szegmentációját. A második fázisban történik az alveolaris csont és az infraalveolaris idegek szegmentációja egy harmadik SegResNet architektúrájú CNN segítségével

blokkok száma 1, 2, 2, 2 és 4. Az 'encoder' részben  $3 \times 3 \times 3$ -as méretű konvolúciós kernellel és 32 kezdeti szűrővel rendelkező rétegek vannak. A 'decoder' részben minden rétegben először felskálázódás történik, amely a jellemzők számának felére csökkentését és a térbeli dimenziók megduplázását jelenti. Ezt egy 'encoder' kimenet hozzáadása követi az egyenértékű térbeli szinteken. A 'decoder' végén a képméret megegyezik az eredeti képmérettel, a jellemzők száma pedig megegyezik a kezdeti bemeneti jellemzők számával. A SegResNet mélytanulási modell sematikus architektúráját az 1. ábra mutatja.

### Tesztelés

A mélytanulási modell pontosságának ellenőrzéséhez 15 CBCT-felvételt használtunk, melyek nem képezték részét az eredeti tanuló adatbázisnak. Ezeket a felvételeket a mélytanulási modell segítségével, valamint félautomatikus szegmentációval is feldolgoztuk, a mélytanulási szegmentáció eredményeit a félautomatikus szegmentációhoz hasonlítottuk. A CBCT-adatok automatikus feldolgozására a Dent.AI 3D Guide (Dent.AI Medical Imaging, Budapest) szoftver „Anatomic Modeler” modulját alkalmaztuk. A félautomatikus szegmentációt – a tanuló adatbázis felállításához hasonlóan – a 3D Slicer szoftverben végeztük.

### Vizsgálati metrikák

A mélytanulási modell predikcióinak és a félautomatikus szegmentációk közötti különbségeinek kiszámításához négy paramétert alkalmaztunk:

- valódi pozitív (true positive: TP): a helyesen szegmentált voxelek;
- valódi negatív (true negative: TN): a helyesen nem szegmentált voxelek;
- álpozitív (false positive: FP): a helytelenül szegmentált voxelek;
- álnegatív (false negative: FN): a helytelenül kihagyott voxelek.

Ezek alapján az alábbi változókat alkalmaztuk a mélytanulási szegmentáció pontosságának meghatározására:

1. Volumen ( $\text{cm}^3$ ): a mélytanulási architektúra által generált 3D mandibulamodell térfogata és a referencia, a félautomatikus szegmentációval létrehozott mandibulamodell térfogata közötti különbség.

2. Jaccard-index (intersection over union: IoU): a mélytanulási szegmentáció és a félautomatikus szegmentáció között átfedő voxelek számának és a két szegmentáció uniójának arányát fejezi ki. Az IoU értéke 0 és 1 között van, 1-es értéke tökéletes átfedést jelent a két szegmentáció között:

$$\text{IoU} = \text{TP} / (\text{TP} + \text{FP} + \text{FN})$$

3. Dice hasonlósági együttható (Dice similarity coefficient: DSC): ez az arány is a két szegmentáció között átfedő voxelek és a két szegmentáció voxelei uniójának arányát fejezi ki. A DSC értéke is 0 és 1 között változhat, ahol a 0 azt jelenti, hogy nincs átfedés, míg az 1 azt jelenti, hogy teljes átfedés van a két terület között:

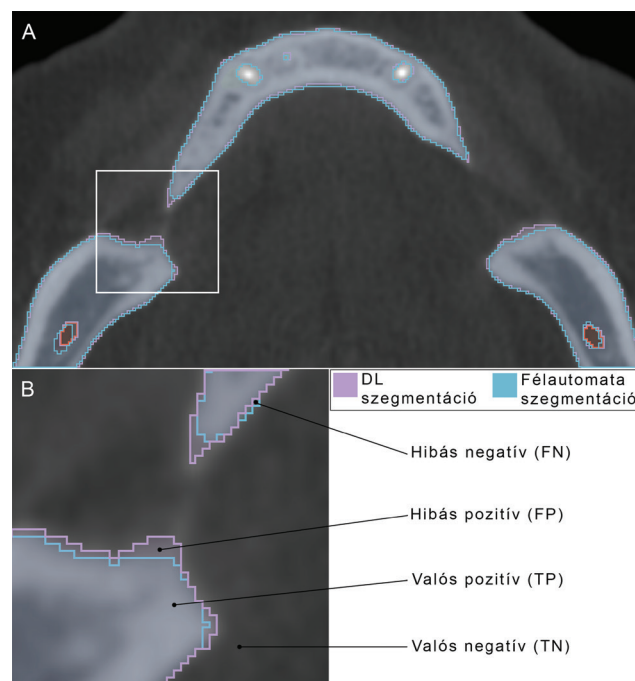
$$\text{DSC} = (2 \times \text{TP}) / (2 \times \text{TP} + \text{FP} + \text{FN}) = (2 \times \text{IoU}) / (1 + \text{IoU})$$

4. A Hausdorff-távolság 95%-os percentilise (Hausdorff distance 95%: HD95): a prediktált modell és a valós szegmentáció közötti maximális távolság 95%-os percentilise. A HD-érték 0 mm esetén teljes átfedést jelent.

Az automatikus mélytanulási szegmentáció és a félautomatikus szegmentáció eredményeit a 2. és 3. ábra mutatja.

### Statisztikai kiértékelés

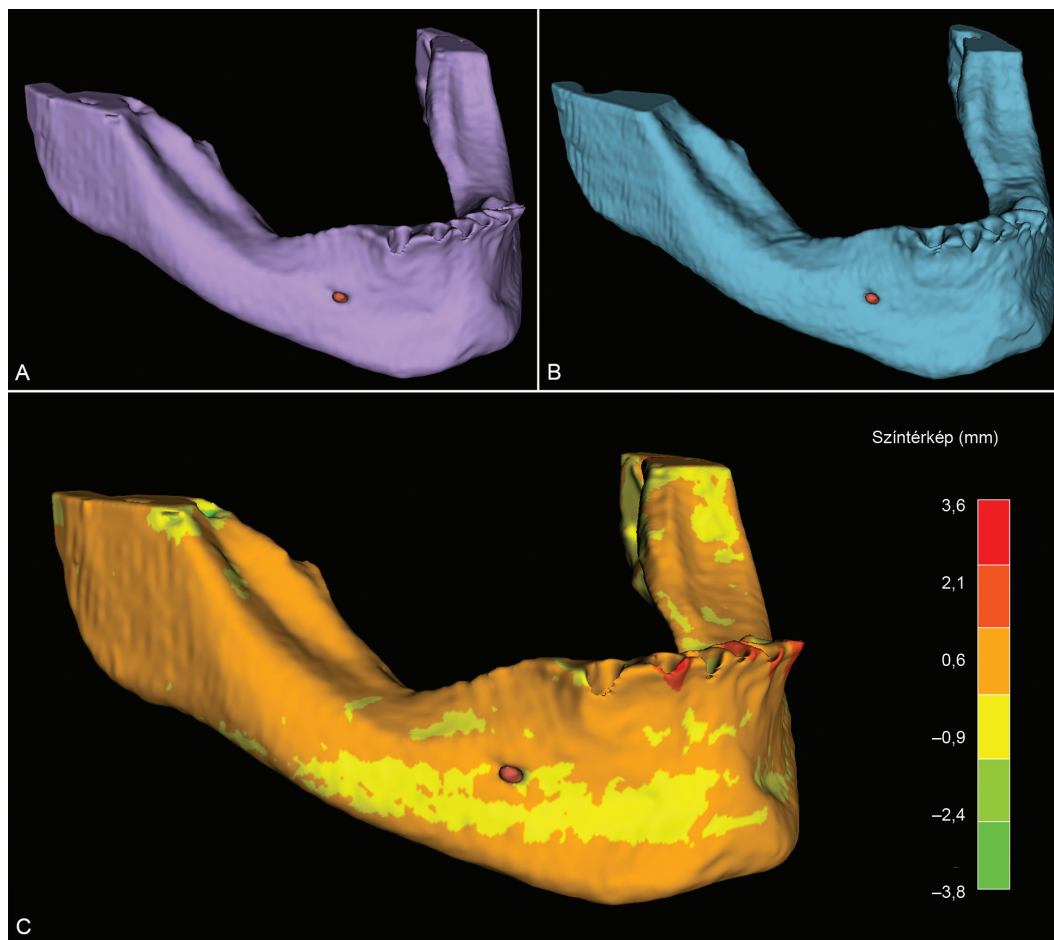
Valamennyi változó esetében leíró statisztikákat készítettünk, az adatokat átlagok  $\pm$  szórások formájában fejeztük ki. A félautomatikus és a mélytanulási szegmentáció



2. ábra

A mélytanulási modell predikcióinak és a félautomatikus szegmentációk közötti átfedéseknek/különbségeknek a kiszámításához alkalmazott paraméterek. A) A mélytanulási és a félautomatikus szegmentáció síkbeli reprezentációja (labelmap) (lila: a mélytanulási szegmentáció reprezentációja, kék: a félautomatikus szegmentáció reprezentációja). B) A szegmentációk közötti átfedések/különbségek kiszámításához alkalmazott paraméterek. A valós pozitív voxeleken átfedés van a két szegmentáció 'labelmap'-je között, a valós negatív voxeleken pedig egy szegmentáció 'labelmap'-je sem látható. A hibás pozitív voxeleken csak a mélytanulási szegmentáció 'labelmap'-je található meg, míg a hibás negatív voxeleken csak a félautomatikus szegmentáció 'labelmap'-je látható

DL = mélytanulási



3. ábra

Mélytanulós és félautomatikus szegmentációval létrehozott 3D modellek összehasonlítása. A) A mandibula és az infraalveoláris idegek mélytanulós szegmentációval automatikusan létrehozott 3D modellje. B) A mandibula és az infraalveoláris idegek félautomatikus szegmentációval létrehozott 3D modellje. C) Színtérképes 3D modell, mely a mélytanulós és a félautomatikus szegmentáció közötti pozitív és negatív eltéréseket mutatja

3D = háromdimenziós

eredményeként kapott 3D modellek térfogata közti különbséget inferenciális statisztikai módszerekkel elemeztük,  $\alpha = 0,05$  szignifikanciaszinttel. A térfogati értékek normalitását a Shapiro–Wilk-tesztel vizsgáltuk, ennek során az adatok normális eloszlást mutattak. Az egyes módszerek által szegmentált modellek közötti különbséget páros  $t$ -próba segítségével értékeltük ki. A két módszer által szegmentált modellek térfogata közötti korrelációt Pearson-féle korrelációs teszttel vizsgáltuk. A statisztikai elemzést a STATA Statistical Software: Release 18. szoftvercsomaggal (StataCorp LLC College Station, TX, USA) végeztük el.

## Eredmények

A többi változóval ellentétben a mélytanulós szegmentáció és a félautomatikus szegmentáció által létrehozott 3D modellek térfogata közötti különbség esetén lehetett inferenciális statisztikai elemzést végezni. Az átlagos térfogat a mélytanulási architektúra által szegmentált 3D modelleknél  $28,11 \text{ cm}^3 \pm 6,28 \text{ cm}^3$ , ezzel szemben a fél-

automatikus szegmentáció eredményeként létrehozott 3D modelleknél  $28,26 \text{ cm}^3 \pm 6,37 \text{ cm}^3$  volt. A két modell térfogata közötti különbség statisztikailag nem bizonyult szignifikánsnak ( $p = 0,31$ ). A két szegmentációs

1. táblázat | Mélytanulós és félautomatikus szegmentációval létrehozott 3D modellek térfogatának összehasonlítása

	DL-térfogat ( $\text{cm}^3$ ) <sup>1</sup>	FA-térfogat ( $\text{cm}^3$ ) <sup>2</sup>
Átlag	28,11	28,26
Szórás	6,28	6,37
Minimum	19,23	20,23
Maximum	41,07	41,89
Medián	27,85	27,70
Szignifikancia (p-érték) <sup>3</sup>	0,31	
PCC <sup>4</sup>	0,99 (p = 0,0000)	


<sup>1</sup>DL (mélytanulós) szegmentációval létrehozott 3D modellek térfogata

<sup>2</sup>Félautomatikus (FA) szegmentációval létrehozott 3D modellek térfogata

<sup>3</sup>Páros  $t$ -próbaival számított szignifikancia ( $\alpha = 0,05$ )

<sup>4</sup>Pearson-féle korrelációs koefficiens

## 3D modellek térfogatainak összehasonlítása



4. ábra | A tesztelés során szegmentált 15 alsó állcsont mélytanulós és félautomatikus szegmentációval létrehozott 3D modelleik térfogatai közti különbség  
3D = háromdimenziós; DL = mélytanulós; FA = félautomatikus

módszer által előállított 3D modellek térfogata között erős, statisztikailag szignifikáns korreláció volt megfigyelhető. A Pearson-féle korrelációs koefficiens értéke 0,99 volt ( $p = 0,0000$ ). A térfogati adatokat az 1. táblázat és a 4. ábrán látható oszlopdiagram mutatja.

A SegResNet architektúrát alkalmazó mélytanulási modell a tesztelési adatbázisba beválogatott 15 CBCT-felvételen a mandibulát a referencia félautomatikus szegmentációhoz képest viszonylag nagy pontossággal szegmentálta. A mélytanulós szegmentáció és a félautomatikus szegmentáció közötti hasonlóság átlagosan  $0,91 \pm 0,02$ -es IoU-értéket mutatott, azaz megállapítható, hogy a mélytanulási architektúra átlagosan 91%-os pontossággal szegmentálta a mandibulát a dentális CBCT-felvételeken.

A Jaccard-indexhez hasonlóan a DSC is a mélytanulós szegmentáció, valamint a félautomatikus szegmentáció közötti átfedést mutatta, melynek átlagos értéke  $0,95 \pm 0,01$  volt.

A Hausdorff-távolsághoz képest a HD95 robusztusabban fejezi ki a két modell közötti maximális távolságot, mert kevésbé érzékeny a kiugró értékekre (outliers).

2. táblázat | Az automatikus mélytanulós szegmentáció pontossága a referencia félautomatikus szegmentációhoz képest

	IoU <sup>1</sup>	DSC <sup>2</sup>	HD95 <sup>3</sup> (mm)
Átlag	0,91	0,95	0,67
Szórás	0,02	0,01	0,22
Minimum	0,87	0,93	0,45
Maximum	0,94	0,97	1,18
Medián	0,92	0,96	0,56

<sup>1</sup>Jaccard-index

<sup>2</sup>Dice hasonlósági együttható

<sup>3</sup>A Hausdorff-távolság 95%-os percentilise


A két modell közötti átlagos HD95-érték  $0,67 \text{ mm} \pm 0,22 \text{ mm}$  volt. Az adatokat a 2. táblázat és az 5. ábrán látható hegedűábra (violin plot) szemlélteti.

## Megbeszélés

Jelen vizsgálatunkban dentális CBCT-felvételek feldolgozására kifejlesztett mesterségesintelligencia-alapú szegmentációs keretrendszer pontosságát vizsgáltuk. A MONAI rendszerben fejlesztett SegResNet [20] architektúrájú mélytanulási modell segítségével szegmentáltuk az alsó állcsontot.

A SegResNet architektúrát eredetileg agydagatok automatikus szegmentációjához dolgozták ki, a jelen vizsgálat alapján azonban megállapítható, hogy alkalmas dentális CBCT-felvételek szegmentációjára is, ami a páciensek fogzatában megtalálható nagy fokú variancia miatt sokkal nagyobb kihívást jelent egy megfelelően működő mélytanulási keretrendszer fejlesztésére, mint egyéb szervek esetén [2, 22–25]. A páciensek fogzata számos egyedi elemet tartalmaz, nemcsak a fogak és az állcsontok méret- és alakbéli változatossága, hanem a különböző fogpótlások és implantátumok megléte vagy hiánya is fokozza az egyes felvételek közötti nagy fokú variabilitást. Továbbá a különböző fémrestaurátumok és implantátumok által generált műtermékek nagyban befolyásolják a képminőséget [26].

A Schwendicke és mtsai [15] által közölt szakmai iránymutatások alapján a mélytanulós szegmentáció eredményét egy referencia félautomatikus szegmentáció eredményével vetettük össze. A vizsgálatban alkalmazott mélytanulási modellt 70 CBCT-felvételekből álló adatbázison tanítottuk be. Mivel a tanuló adatbázis méretét illetően nincs egységes álláspont, az adatbázis méretét addig növeltük, amíg az automatikus szegmentáció eredménye



5. ábra | A Jaccard-index (IoU), a Dice hasonlósági együttható (DSC) és a Hausdorff-távolság (HD95) adatainak eloszlását mutató hegedűábrák (violin plot).  
A) Az IoU eloszlása. B) A DSC eloszlása. C) A Hausdorff-távolság 95%-os percentilisének eloszlása

klínikailag elfogadhatónak nem bizonyult. Az irodalomban található hasonló közleményekben a tanuló adatbázis mérete 80–130 CBCT-felvétel között változik [6, 12, 27]. A vizsgálatunkban használt tanuló adatbázis kevesebb CBCT-t tartalmazott, mint az irodalomban található hasonló publikációk, azonban hasonló pontossággal volt képes a mandibula szegmentációjára. A *Verhelst és mtsai* [12] által közölt cikkben az automatikus szegmentálást a referencia félautomatikus szegmentációval összehasonlítva az IoU értéke átlagosan  $0,95 \pm 0,01$ , a DSC átlagos értéke pedig  $0,97 \pm 0,01$  volt. A jelen vizsgálatban alkalmazott mélytanulási modell 91%-os átfedéssel szegmentálta az alsó állcsontot, mely érték nem különbözik jelentősen a fent említett cikkben elért 95%-os eredménytől. *Verhelst és mtsai* [12] 3D U-Net- [28] alapú architektúrát alkalmaztak, mely az egyik leggyakrabban használt konvolúciós neurális háló a 3D képfeldolgozásban. A mélytanulási architektúra eltérése mellett a megtartott fogak számát és a patológiás folyamatokat tekintve relatíve homogénebb tanuló adatbázist alkalmaztak. Ezzel szemben a jelen vizsgálatban a CBCT-felvételek a rutin klinikai gyakorlatból származtak, melyek heterogenitása lehetővé tette a mesterséges intelligencia számára a parodontális csont topográfiájának és az alveolaris gerincdefektusoknak a felismerését.

A tanuló adatbázis ilyen jellegű felállítását a *Schwendicke és mtsai* által megfogalmazott [15] szakmai iránymutatás alapján végeztük, hasonlóan a *Cui és mtsai* által közölt [29] publikációhoz, mely vizsgálatban közel 5000 darab CBCT-felvételből álló, relatíve heterogén adatbázison tanítottak egy többfázisú mesterségesintelligencia-modellt fogak és alveolaris csont automatikus szegmentációja céljából [29]. A rutin klinikai gyakorlatból származó CBCT-felvételek közötti nagy variancia miatt volt szükség a nagy méretű adatbázis felállítására annak érdekében, hogy a modell megbízhatóan működjék. A vizsgálatunkban alkalmazott adatbázis mérete a nagy megbízhatóság ellenére relatíve kicsi, ezért a modell robusztusságának növelése érdekében az adatbázis

további bővítésére és az architektúra további tanítására van szükség.

A teszteléshez alkalmazott 15 CBCT-felvétel automatikus szegmentációja alapján azonban megállapíthatjuk, hogy a modell kellő pontossággal szegmentálta az alveolaris gerincdefektusokat, ezáltal a modellek alkalmasak lehetnek különböző rekonstruktív szájszabási és parodontális sebészeti beavatkozások tervezésére. Korábbi vizsgálatunkban [10, 30, 31] félautomatikus szegmentációval előállított 3D modellek segítségével végeztük el regeneratív parodontális sebészeti, illetve alveolaris gerincaugmentációs beavatkozások digitális tervezését [32]. A 3D modellek alapján egyedileg gyártott műtéti segédeszközöket alkalmaztunk a rekonstruktív műtétek egyes lépéseinek navigált kivitelezéséhez [33, 34], mely egyéb faktorok mellett [35, 36] nagyban befolyásolhatja a beavatkozások sikerességét. A vizsgálatban alkalmazott félautomatikus szegmentációs módszer egyik hátránya a modellalkotáshoz szükséges idő, mely bizonyos esetekben akár több órát igénybe vehet [37]. A jelen vizsgálatban nem mértük ugyan a mélytanulási és a félautomatikus szegmentáció közötti időkülönbséget, de tapasztalataink alapján kb. 40–50-szeres időkülönbséget állapítottunk meg a két módszer között. A CBCT-felvételek feldolgozásához szükséges idő lerövidítése a jelen vizsgálatban alkalmazott mélytanulási modell segítségével kivitelezhető. Mivel a félautomatikus és a mélytanulási szegmentáció eredménye között nem volt statisztikailag szignifikáns különbség, megállapítható, hogy a mélytanulási szegmentációval létrehozott 3D modell alkalmas lehet gerincaugmentációs műtétek tervezésére.

Az alkalmazott SegResNet architektúrát a PyTorch-alapú, nyílt forráskódú MONAI keretrendszeren belül fejlesztettük ki. Más rendszerekhez képest (például TensorFlow), a PyTorch a rugalmasságának köszönhetően különösen hatékonyan alkalmazható kutatásban és prototípusok előállításában. Míg eredetileg kutatási célú felhasználásra fejlesztették, a PyTorch rendszer jelentős fejlődésen ment keresztül, így a nagyobb léptékű projektek megvalósításához is lehetőséget biztosít.



A jelen vizsgálatban alkalmazott mélytanulási modell legnagyobb hátránya a már említett, relatíve kis elemszámú adatbázis, amely heterogenitása ellenére nem biztosít kellő robusztusságot. Ezt mutatja, hogy a jelen vizsgálatból kizártuk az implantátumokat és a teljes fogívre kiterjedő fémrestaurátumokat (körhidat) viselő páciensek CBCT-felvételeit. Ennek oka, hogy a kiterjedt fém műtermékek miatt ezeket a felvételeket a jelenlegi tanuló adatbázis elemszáma mellett a mélytanulási keretrendszer nem tudta megfelelően feldolgozni. Az adatbázis méretbeli korlátai mellett a vizsgálat további hátránya, hogy csak az alsó állcsont szegmentációját értékeltük, míg a fogakat és a felső állcsont szegmentációját nem vizsgáltuk. A felállított keretrendszer azonban alkalmas mind a fogak, mind pedig a maxilla szegmentációjára.

## Következtetés

A vizsgálat eredményeiből megállapítható, hogy a SegResNet architektúrájú mélytanulási modell nagy pontossággal szegmentálta az alsó állcsontot dentális CBCT-felvételeken. A tanításhoz alkalmazott, relatíve heterogén adatbázis pedig lehetővé tette a különböző alveolaris gerincdefektusok szegmentációját is. Ezek alapján megállapítható, hogy a mélytanulós szegmentációval előállított 3D modell alkalmas lehet rekonstruktív szájsebészeti és parodontális sebészeti beavatkozások digitális tervezésére. A relatíve nagy pontosság ellenére azonban a modell megbízható működése céljából szükség van a tanuló adatbázis bővítésére és a modell újratanítására.

*Anyagi támogatás:* A jelen munka nem részesült anyagi támogatásban.

*Szerzői munkamegosztás:* H. A.: A mélytanulós szegmentáció felügyelete, a félautomatikus szegmentáció elvégzése, a szöveg megírása. S. K.: A szegmentáció pontosságának kiértékelése, a szöveg megírása. P. Cs.: A mesterségesintelligencia-modell fejlesztése, a szöveg szakmai véleményezése. M. B.: A szöveg szakmai véleményezése. W. P.: A szöveg szakmai véleményezése, a kutatás támogatója. D. G.-M., A. D.-P.: A mesterségesintelligencia-modell fejlesztése, a szöveg szakmai véleményezése. P. D.: A tanuló adatbázis felállítása, a 3D modellek pontosságának kiértékelése, statisztikai kiértékelés, a szöveg megírása. A közlemény végleges változatát valamennyi szerző elolvasta és jóváhagyta.

*Érdeklőségek:* A szerzőknek nincsenek érdeklőségeik.

## Irodalom

- [1] Barr A, Feigenbaum EA, Cohen PR. The handbook of artificial intelligence. HeurisTech Press, Stanford, California, 1981.
- [2] Wasserthal J, Breit HC, Meyer MT, et al. TotalSegmentator: robust segmentation of 104 anatomic structures in CT images. Radiol Artif Intell. 2023; 5: e230024.
- [3] Mangano FG, Admakin O, Lerner H, et al. Artificial intelligence and augmented reality for guided implant surgery planning: a proof of concept. J Dent. 2023; 133: 104485.
- [4] Schwendicke F, Golla T, Dreher M, et al. Convolutional neural networks for dental image diagnostics: a scoping review. J Dent. 2019; 91: 103226.
- [5] Elgarba BM, Fontenele RC, Tarce M, et al. Artificial intelligence serving pre-surgical digital implant planning: a scoping review. J Dent. 2024; 143: 104862.
- [6] Mureşanu S, Almăşan O, Hedeşiu M, et al. Artificial intelligence models for clinical usage in dentistry with a focus on dentomaxillofacial CBCT: a systematic review. Oral Radiol. 2023; 39: 18–40.
- [7] Schwendicke F, Samek W, Krois J. Artificial intelligence in dentistry: chances and challenges. J Dent Res. 2020; 99: 769–774.
- [8] Palkovics D, Sólyom E, Molnár B, et al. Digital hybrid model preparation for virtual planning of reconstructive dentoalveolar surgical procedures. J Vis Exp. 2021; 174. Doi: 10.3791/62743.
- [9] Molnár B, Würsching T, Sólyom E, et al. Alveolar cleft reconstruction utilizing a particulate autogenous tooth graft and a novel split-thickness papilla curtain flap – a retrospective study. J Craniomaxillofac Surg. 2024; 52: 77–84.
- [10] Palkovics D, Mangano FG, Nagy K, et al. Digital three-dimensional visualization of intrabony periodontal defects for regenerative surgical treatment planning. BMC Oral Health 2020; 20: 351.
- [11] Palkovics D, Molnár B, Pinter C, et al. Utilizing a novel radiographic image segmentation method for the assessment of periodontal healing following regenerative surgical treatment. Quintessence Int. 2022; 53: 492–501.
- [12] Verhelst PJ, Smolders A, Beznik T, et al. Layered deep learning for automatic mandibular segmentation in cone-beam computed tomography. J Dent. 2021; 114: 103786.
- [13] Preda F, Morgan N, Van Gerven A, et al. Deep convolutional neural network-based automated segmentation of the maxillofacial complex from cone-beam computed tomography: a validation study. J Dent. 2022; 124: 104238.
- [14] Ezhov M, Gusarev M, Golitsyna M, et al. Clinically applicable artificial intelligence system for dental diagnosis with CBCT. Sci Rep. 2021; 11: 15006.
- [15] Schwendicke F, Singh T, Lee JH, et al. Artificial intelligence in dental research: checklist for authors, reviewers, readers. J Dent. 2021; 107: 103610.
- [16] Jacobs R, Salmon B, Codari M, et al. Cone beam computed tomography in implant dentistry: recommendations for clinical use. BMC Oral Health 2018; 18: 88.
- [17] Fedorov A, Beichel R, Kalpathy-Cramer J, et al. 3D Slicer as an image computing platform for the quantitative imaging network. Magn Reson Imaging. 2012; 30: 1323–1341.
- [18] Pinter C, Lasso A, Fichtinger G. Polymorph segmentation representation for medical image computing. Comput Methods Programs Biomed. 2019; 171: 19–26.
- [19] Diaz-Pinto A, Mehta P, Alle S, et al. DeepEdit: deep editable learning for interactive segmentation of 3D medical images. 2023. Available from: <https://doi.org/10.48550/arXiv.2305.10655> [accessed: June 8, 2024].

- [20] Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization. In: Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. 4th International Workshop, BrainLes 2018, held in conjunction with MICCAI 2018, Granada, September 16, 2018, revised selected papers, Part II. Conference proceedings. Springer Nature, Cham, 2019; pp. 311–320.
- [21] Khan FM, Baccour E, Erbad A, et al. Adaptive ResNet architecture for distributed inference in resource-constrained IoT systems. Accepted in the International Wireless Communications and Mobile Computing (IWCMC) Conference, IEEE Communications Society, Marrakesh, 2023; 1543–1549. Doi: arXiv:2307.11499.
- [22] Ma J, He Y, Li F, et al. Segment anything in medical images. Nat Commun. 2024; 15: 654.
- [23] Barabás JJ, Hartyánszky I, Kocher A, et al. A 3D printed exoskeleton facilitates HeartMate III inflow cannula position. Interact Cardiovasc Thorac Surg. 2019; 29: 644–646.
- [24] Barabás JJ, Ghimesy ÁK, Rényi-Vámos F, et al. Innovation in medicine: opportunities of 3D modeling and printing for perioperative care of cardio and thoracic surgical patients. Experiences in Hungary. [Innovációs lehetőségek a medicinában: 3D tervezési és 3D nyomtatási lehetőségek a felnőtt szív- és mellkasbészeti betegellátásban. Magyarországi tapasztalatok.] Orv Hetil. 2019; 160: 1967–1975. [Hungarian]
- [25] Barabás JJ, Palkovics D, Bognár V, et al. The role of 3D technology in the support of mechanical circulation therapy. [A 3D technológia szerepe a műszívterápiában.] Orv Hetil. 2023; 164: 1026–1033. [Hungarian]
- [26] Fontenele RC, Machado AH, De Oliveira Reis L, et al. Influence of metal artefact reduction tool on the detection of vertical root fractures involving teeth with intracanal materials in cone beam computed tomography images: a systematic review and meta-analysis. Int Endod J. 2021; 54: 1769–1781.
- [27] Gerhardt MD, Fontenele RC, Leite AF, et al. Automated detection and labelling of teeth and small edentulous regions on cone-beam computed tomography using convolutional neural networks. J Dent. 2022; 122: 104139.
- [28] Çiçek Ö, Abdulkadir A, Lienkamp SS, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation. In: Ourselin S, Joskowicz L, Mert R, et al. (eds.) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016: 19th International Conference, Athens, October 17–21, 2016. Proceedings, Part II. Springer Nature, Cham, 2016, 424–432.
- [29] Cui Z, Fang Y, Mei L, et al. A fully automatic AI system for tooth and alveolar bone segmentation from cone-beam CT images. Nat Commun. 2022; 13: 2096.
- [30] Bolya-Orosz F, Palkovics D, Gergely Z, et al. 3D driven hard tissue augmentation based on reverse planning reconstruction of an advanced, horizonto-vertical alveolar ridge defect: a case report. J Dentistry 2022; 121: 104021.
- [31] Palkovics D, Sólyom E, Pintér C, et al. Virtual planning and volumetric evaluation of wound healing following regenerative surgical treatment of intrabony periodontal defects. J Dentistry 2022; 121: 104017.
- [32] Marton R, Martin A, Lemperger Sz, et al. Treating tissue defects following tooth removal. Three case reports. [Fogeltávolítást követően visszamaradt szöveti defektus ellátása. Három eset ismertetése.] Orv Hetil. 2017; 158: 1228–1234. [Hungarian]
- [33] Molnár B, Jung AK, Papp Z, et al. Comparative analysis of lateral maxillary sinus augmentation with a xenogenic bone substitute material in combination with piezosurgical preparation and bony wall repositioning or rotary instrumentation and membrane coverage: a prospective randomized clinical and histological study. Clin Oral Investig. 2022; 26: 5261–5272.
- [34] Orban K, Varga E Jr, Windisch P, et al. Accuracy of half-guided implant placement with machine-driven or manual insertion: a prospective, randomized clinical study. Clin Oral Investig. 2022; 26: 1035–1043.
- [35] Joób-Fancsaly Á, Karacs A, Pető G, et al. Effects of a nano-structured surface layer on titanium implants for osteoblast proliferation activity. Acta Polytechn Hung. 2016; 13: 7–25.
- [36] Körmöczi K, Komlós G, Papócsi P, et al. The early loading of different surface-modified implants: a randomized clinical trial. BMC Oral Health 2021; 21: 207.
- [37] Schenk A, Prause G, Peitgen HO. Efficient semiautomatic segmentation of 3d objects in medical images. In: Delp SL, DiGoia AM, Jaramaz B. (eds.) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2000. Third International Conference, Pittsburgh, PA, October 11–14, 2000. Proceedings. Springer Nature, Cham, 2000, 186–195.

(Palkovics Dániel dr.)

Budapest, Szentkirályi u. 47., 4. em., 1088  
e-mail: palkovics.dani-el@semmelweis.hu)