



MRO

MAGYAR
RADIOLÓGIA
ONLINE

A MAGYAR RADIOLÓGUSOK TÁRSASÁGÁNAK FOLYÓIRATA

Hungarian Radiology

Journal of the Society of Hungarian Radiologists

13. évfolyam • 2022. 2.

Budai et al.:

Radiomikai elemzés – ami igazán lényeges, az a szemnek sokszor láthatatlan

Magyar Radiológia Online 2022; 13(2): 3.



**EGYSZERŰBB
KEZELHETŐSÉG**

**TÖBB
TÖRŐDÉS**



Bayer Hungária Kft.,
1117 Budapest, Dombóvári út 26.
Tel.: 1-487-4100, Fax: 1-487-4220
bayer.co.hu

Clear Direction. ➤ From Diagnosis to Care.

medrad® Centargo
CT Injection System

BUDAI Bettina Katalin
TÁNCZIK Zsófia
KÖRMENDY Borbála
ZSOMBOR Zita
PALOTÁS Lőrinc
STOLLMAYER Róbert
RÓNASZÉKI
Aladár Dávid
MAUROVICH HORVAT
Pál
KAPOSI Novák Pál

Semmelweis Egyetem, Orvosi
Képalkotó Klinika, Radiológia
Tanszék, Budapest / Department of
Radiology, Medical Imaging Centre,
Semmelweis University, Budapest

Radiomikai elemzés – ami igazán lényeges, az a szemnek sokszor láthatatlan

METODIKAI KÖZLEMÉNY

A radiológiai képalkotással nyert orvosi képek kiértékelése ma elsősorban kvalitatív módon történik, így a diagnózisalkotás pontossága a leletező szakorvos szakmai tapasztalatától jelentős mértékben függhet. A radiológiai diagnosztikában jelenleg használatos leíró jellegű képi paraméterek segítik egy adott lézió kategorizálását, ugyanakkor jelentős szubjektív komponenssel bírnak, így megbízhatóságuk változó lehet. A digitalizáció korában ma már lehetőség nyílik a modern képalkotó eljárások során készült felvételek számítógépes képelemzésére, ami életre hívta a radiológia egy új tudományterületének, az úgynevezett radiomikának a megjelenését. A radiomikai képelemzés, szemben a hagyományos képi diagnosztikai leírással, objektív és reprodukálható módon, különböző matematikai egyenletek segítségével nagyszámú kvantitatív képi paraméter (radiomikai paraméter) meghatározására képes. A radiomikai paraméterekből számszerű természetüknél fogva könnyedén képezhető adatbázis, amelyen statisztikai elemzések végezhetők. Korábbi kutatások már bizonyították, hogy a radiomikai elemzés során kimutatható lehet olyan, az emberi szemmel kevésbé érzékelhető eloszlási mintázat is, ami az adott lézióra vonatkozó diagnosztikus információt hordoz, és amelyet ugyanakkor a hagyományos kiértékelés során a szakorvosok nem tudnak reprodukálhatóan megítélni. A radiomikai elemzés alapvető célja tehát, hogy adott patológiás elváltozás diagnosztizálása elősegítésének érdekében a radiológiai felvételek számítógépes, automatizált képelemzése során olyan matematikai algoritmusok kerüljenek kidolgozásra, amelyek számszerűen, objektíven és reprodukálható módon képesek karakterizálni az adott léziót, aminek segítségével a radiológiai diagnosztika pontosítható, felgyorsítható. Ez az új típusú számítógépes képelemzési módszer gépi tanulási algoritmusokkal kombinálva megnyitja az utat a mesterséges intelligencia alapú, automatizált diagnosztikus eljárások irányába. A jelen metodikai közlemény célja megismertetni az olvasóval a radiomikai képelemzés munkafolyamatát, és betekintést adni a kvantitatív textúraelemzés elméleti hátterébe.

Kulcsszavak: radiomika, CT, MR, radiológiai-patológiai korreláció, vizuális diagnózis, számítógép-vezérelt diagnózis

Radiomics analysis – what is essential is invisible to the eye

Assessment of radiological images is mainly qualitative nowadays, therefore the diagnostic accuracy highly depends on the radiologists' expertise. Descriptive parameters that are broadly used in traditional radiology help to categorize lesions, however, they have a subjective component,



LEVELEZŐ SZERZŐ / CORRESPONDING ADDRESS

Budai Bettina Katalin

Semmelweis Egyetem, Orvosi
Képkalkotó Klinika, Radiológia
Tanszék

1083 Budapest, Üllői út 78/a

E-mail:

budai.bettina@med.semmelweis-univ.hu

which makes their diagnostic reliability variable. In the digital era, we have the opportunity to use computer programs to assist medical image processing and analysis, which allowed a new field of radiology called radiomics to appear. Unlike traditional radiology, using radiomics, large numbers of quantitative features can be objectively and reproducibly extracted from medical images using standardized mathematical algorithms. A database can be easily formed from the radiomic features, which enables us to run statistical analyses. Previous publications have proven that radiomics has the potential to uncover hidden information, disease characteristics that are difficult to identify by the human eye. The aim of radiomics is to use computer-based automated image processing and develop mathematical algorithms, which help to characterize the pathological lesion and make diagnostics faster and more accurate. Feature analysis combined with machine learning algorithms allows artificial intelligence-based automated diagnostic methods to arise. This methodical study aims to introduce the reader to the workflow of radiomics analysis and allows one to understand the theoretical background of qualitative texture analysis.

Keywords: radiomics, CT, MR, radiological-pathological correlation, visual diagnosis, computer-aided diagnosis

Biomarkernek nevezhetünk minden olyan mérhető tulajdonságot, amely információt hordoz egy adott biológiai folyamat lefolyásáról.¹ Ha egy szöveti tulajdonság kimutatása az orvosi képkalkotó eljárások során készített felvételek segítségével történik, úgynevezett képkalkotó biomarkerről beszélünk. A képkalkotó biomarkerek között megkülönböztethetünk kvalitatív markereket, amelyekkel a vizsgált szövetek szubjektív módon jellemezhetők és kategorizálhatók, illetve kvantitatív markereket, amelyek számszerű módon megmérhetők, s így a vizsgált szövetek objektív jellemzését teszik lehetővé.²

Az orvosi képkalkotó vizsgálatok során keletkező radiológiai felvételek kiértékelése ma elsősorban szubjektív módon, kvalitatívan történik. A radiológiai diagnosztikában jelenleg használatos diagnosztikus klasszifikációs rendszerek egy része is (pl.: Li-RADS, PI-RADS) a leíró jellegű szemantikus képi paraméterek (pl.: nekrozis, spikuláció, tumorszél elmosódottsága) és a hisztopatológiai morfológia szoros korrelációján alapulnak.^{3,4} A szemantikus paraméterek ugyanakkor jelentős szubjektív komponenssel bírnak, így megítélésük függ a leletező orvos szakmai tapasztalatától, ezért megbízhatóságuk változó lehet. A szubjektív alapokon nyugvó kvalitatív kiértékelés további hátránya, hogy azt az

emberi szem felbontóképessége szintén korlátozza, így a képekben raktározott információ jelentős része elvész a kiértékelés során.⁵

A modern képkalkotó eljárások digitalizált volta azonban lehetővé teszi a felvételek számítógépes tárolását, feldolgozását és képelemzését, ami életre hívta a radiológián belül egy új tudományterület, az úgynevezett radiomika megjelenését.^{1,6} A radiomikai képelemzés, szemben a hagyományos képi diagnosztikai leírással, különböző matematikai algoritmusok segítségével nagyszámú kvantitatív képi paraméter meghatározására képes, amelyek reprodukálhatók, és adatbázist képezve statisztikailag elemezhetők.²

A radiomikai elemzés során tehát az orvosi képkalkotó vizsgálatok eredményeül kapott felvételeken kijelölt területekből (ROI) vagy térfogatokból (VOI) matematikai egyenletek alapján nyerünk ki jól definiált, számszerű, kvantitatív képi jellemzőket, amelyekre radiomikai paraméterként hivatkozik a szakirodalom.⁷ A radiomika tárgykörében megjelent korábbi publikációk jelentős különbségeket mutatnak mind a képi utómunkálatok, mind a statisztikai kiértékelés, mind pedig a radiomikai elemzésre használt szoftverek tekintetében, így azok eredményeinek reprodukálhatósága változó. A radiomikai elemzések lépéseinek és az

egyes radiomikai paraméterek definícióinak egy-
ségeztésére 2016-ban alakult meg az Image Bio-
marker Standardization Initiative (IBSI) független
nemzetközi összefogás. Az IBSI munkásságának fő
célja az algoritmusok diverzitásának csökkentése,
a radiomikai elemzést végző különböző szoftverek
validálása, s így a radiomikai kutatások reprodu-
kálhatóságának növelése.

Amennyiben a ROI/VOI-ból kivont radiomikai pa-
raméterekhez orvosi kimeneteket kapcsolunk,
azok felhasználhatóak lehetnek biomarkerekként.
A radiomikai kutatások céljai a radiomikai para-
méterek és különböző klinikai végpontok (pl.: tu-
mortípus meghatározása, túlélés becslése, terápia
hatásosságának prediktálása) közötti összefü-
gések feltárása, valamint a diagnosztikus értékű
képi biomarkerek azonosítása. A genomika tudo-
mányterületének rohamos fejlődése és ezen két
forrongó terület találkozásával a genetikai jellem-
zők prediktálását célzó radiomikai kutatások meg-
jelenése életre hívta a radiogenomika területét is.⁸
Amellett, hogy a radiomika az orvosi képek kiérté-
kelésének automatizálásával gyorsíthatja és ponto-
síthatja a non-invazív diagnózisalkotást, a klinikai
betegadatok mellett radiomikai és radiogenomikai
adatokat is számba vevő klinikai döntéstámoga-
tó eszközök létrehozása a magas rizikójú betegek
azonosításán és a terápiás döntéshozatal segítségén
keresztül előrelendítheti a személyre szabott medi-
cina fejlődését is.⁹

Célkitűzés

A jelen metodikai közlemény célja megismertetni
a radiomika iránt érdeklődő olvasóval a radiomi-
kai analízis és a kvantitatív textúraelemzés elmé-
leti hátterét és munkafolyamatát. Végül a teljesség
igénye nélkül különböző radiomikai tanulmányok
rövid bemutatásával illusztráljuk a hasi képalkotás
területén elért legjelentősebb nemzetközi eredmé-
nyeket.

Módszerek

A radiomika definíció szerint a radiológiai vizsgá-
latok képi információinak kvantitatív kinyerése,
analízise és megjelenítése.⁹ Az orvosi képalko-
tó vizsgálatok során keletkező felvételek radiomi-
kai kiértékelése egy többlépcsős, összetett feladat,

amelyet az alábbi főbb lépésekre lehet osztani: or-
vosi képalkotás, szegmentálás, képi paraméterek
kinyerése, exploratív analízis és végül a predikciós
modellépítés (1. ábra).


Orvosi képalkotás, utómunkálatok

Az orvosi képek elkészítését követően azokon to-
vábbi utómunkálatok elvégzése szükséges. Az MRI-
felvételek esetében figyelemmel kell lenni arra,
hogy a CT-vel ellentétben, ahol a különböző szöve-
tek jól meghatározott, rájuk jellemző denzitástar-
tományon belüli denzitáértékekkel rendelkeznek,
az MRI esetén az egyes szöveteknek nincsen rájuk
jellemző, fix voxel-jelintenzitás tartománya, ezért
a radiomikai elemzést megelőzően szükséges az
MRI-felvételek jelintenzitás-tartományának stan-
dardizálása.¹⁰

Az MRI-felvételek esetében a Rice-féle (Rician)
eloszlású zaj jelenléte miatt kiemelt fontosságú
a zajszűrő alkalmazása,¹¹ hiszen a radiomikai para-
méterek – főleg a textúraparaméterek – érzékenyek
a jel-zaj arányra.¹² A CT-képeken leggyakrab-
ban a fémmimplantátumok vagy pacemakerek ál-
tal létrehozott műtermékek tesznek szükségessé
zajszűrést.¹³ Különböző műtermék-redukciós algo-
ritmusok (pl.: ortopédiai fém műtermék redukció)
azonban ma már a szuboptimális technikával ké-
szült CT-felvételeken is lehetővé teszik a hatékony
képelemzést.¹⁴

Szegmentálás

A radiomikai paraméterek eloszlását egy kije-
lölt vizsgálati területen vagy térfogaton belül ha-
tározzuk meg. A ROI-k/VOI-k kijelölését a vizsgált
képanyagon szegmentálásnak nevezzük, amely
nemzetközi szakirodalom alapján leggyakrabban
szabadkézzel történik.¹⁵ A VOI általában a lézió teljes
háromdimenziós térfogata, míg a ROI leggyakrab-
ban a lézió legnagyobb átmérőjű axialis szeleté-
nek területe. A munkafolyamat automatizálásának
és gyorsításának érdekében az elmúlt években
megnövekedett az igény a mesterséges intelligen-
cián alapuló szegmentációs módszerek fejlesztésé-
re.¹⁶ A legszélesebb körben elterjedt konvolúciós
neurális hálókat megfelelő nagyságú tanító adat-
halmaz esetén saját képanyagunkon is taníthatjuk
az elemezni kívánt elváltozások felismerésére.¹⁷



1. ábra. A radiomikai elemzés főbb lépései

Miután a képalkotó diagnosztikai vizsgálat során leképeztük az adott testtáját (A), rekonstruáljuk a felvételeket, majd szükség esetén különböző utómunkákat végzünk rajtuk. Ezt követően a felvételeken kijelöljük az általunk vizsgálni kívánt elváltozást (B), amit szegmentálásnak nevezünk. Majd matematikai algoritmusok segítségével a kijelölt területekből számszerű jellemzőket, úgynevezett radiomikai paramétereket vonunk ki (C). Az így nyert adatokat szelektáljuk, kiszűrjük a redundáns, diagnosztikus információt nem hordozó paramétereket (D). Végül a relevánsnak tartott radiomikai paramétereket használjuk fel statisztikai elemzésre, illetve gépi tanulási algoritmusokon alapuló predikciós modellépítésre (E).

A szegmentálás eredményeül kapott ROI-kat úgynevezett bináris maszk formájában mentjük el, a radiomikai paramétereket ezeken a maszkolt régiókban belül számoljuk.¹⁸


Radiomikai képelemzés

Konvencionális radiomikai paraméterek kinyerése

A konvencionális radiomikai paramétereket három fő csoportra oszthatjuk. Az első csoport a voxelintenzitás-hisztogram eloszlásából számított elsőrendű statisztikai paraméterek. A második csoportba a geometriai paraméterek tartoznak, amelyek számszerűen jellemzik a kijelölt lézió alakjára vonatkozó információkat. A harmadik nagy csoportot a másodrendű textúraparaméterek képviselik, amelyek a különböző intenzitásértékekkel rendelkező voxelek egymáshoz viszonyított

térbeli eloszlási mintázatát számszerűsítik.² A textúraparaméterek főbb családjai a gray-level co-occurrence matrix (GLCM), a gray-level run-length matrix (GLRLM), a gray-level size zone matrix (GLSZM), a gray-level dependence matrix (GLDM) és a neighboring gray tone difference matrix (NGTDM) alapú textúraparaméterek. A különböző radiomikai jellemzők nevezéktanát, definícióit és matematikai képleteit az IBSI nemzetközi szervezet egységesítette.²

Az IBSI 2020. évi referencia-kézikönyvében a radiomikai paraméterek reprodukálhatóságát és robosztusságát növelendő ajánlja a voxel-szűrkeértékek és a voxelméret standardizálását is a radiomikai elemzés során. A voxel-szűrkeértékek diszkrétizációjára a fix hisztogram oszlopszélesség és a fix hisztogram oszlopszám módszerét egyaránt elfogadhatónak tartják, amennyiben azt egységesen alkalmazzák a kutatás során minden felvételre, azonban az MRI-felvételek esetén a fix



2. ábra. Elsőrendű statisztikai paraméterek kiszámítása a radiomikai elemzés során

A corticomedullaris fázisú axialis CT-felvételen kijelöljük a vesetumor elemezni kívánt területeit (ROI) vagy a teljes tumortérfogatot (VOI) (A és C). Az elsőrendű statisztikai paraméterek a voxelek denzitásértékeinek eloszlását jellemzik egy adott kijelölt területen belül, ilyenek például a hisztogramcsúcsosság (kurtózis) (B), illetve a hisztogramferdeség (skewness) (D).

oszlopszám módszerét ajánlják. A voxelméret standardizálására a voxelek izotropikus interpolációját ajánlják.⁷

A radiomikai módszerek mindennapi, rutin klinikai gyakorlatban történő alkalmazásához nélkülözhetetlen a képalkotó vizsgálati technika és a képalkotó paraméterek standardizálása.¹⁹ A robosztus, reprodukálható képi biomarkerek azonosításának érdekében elengedhetetlen annak meghatározása, hogy az eltérő konfigurációjú készülékekkel,²⁰ illetve eltérő vizsgálati beállítással²¹ milyen mértékben változnak a képi paraméterek, valamint szintén kiemelt jelentőségű a radiomikai paraméterek vizsgálok közötti reprodukálhatóságának elemzése.²²

Neurális háló alapú képi paraméterek kinyerése

A konvolúciós neurális hálók majd később a mélytanulás megjelenése utat nyitott egy újfajta radiomikai elemzési módszernek is, az úgynevezett mély neurális háló alapú kvantitatív paraméterek kinyerésének. A radiomikai elemzés során a mély neurális hálókat egyrészt felhasználhatjuk mint klasszifikáló algoritmusokat, azonban az utóbbi években megjelentek olyan publikációk is, amelyek a mély neurális hálókat kvantitatív képi jellemzők generálására használják, aminek során az előre betanított neurális hálók különböző rétegeiből vonnak ki vektorizálás útján számszerű jellemzőket.^{23,24} Ezek a kvantitatív paraméterek ezt követően a hagyományos radiomikai paraméterekhez hasonlóan szintén felhasználhatók különböző predikciós modellek építésére, azonban a jelen metodikai közleményben ezen technika ismertetésére nem térünk ki részletesen.

A következőkben bemutatjuk a konvencionális radiomikai elemzés során használt főbb radiomikai paramétercsaládokat és kiszámításuk elméletét néhány egyszerűsített példán keresztül.

Elsőrendű statisztikai paraméterek

Az intenzitásalapú elsőrendű statisztikai paraméterek az egyes voxelek szürkescálán vett értékeinek eloszlását számszerűsítik egy adott kijelölt területen belül.² Ilyen paraméterek többek között a voxelek szürkeértékeinek átlaga, szórása,

mediánja, interkvartilis tartománya, minimuma, maximuma és különböző percentilis értéke a kijelölt ROI-n/VOI-n belül; de ide tartoznak például a szürkeértékek hisztogrameloszlásából számított ún. hisztogramcsúcsosság (kurtózis), illetve hisztogramferdeség is (2. ábra). Az elsőrendű statisztikai paraméterek IBSI által egységesített definícióit és képleteit a 2020. évben aktualizált referenciakézikönyvben olvashatjuk.⁷

Geometriai paraméterek

A geometriai jellemzők a ROI/VOI alakjára és méretére vonatkozó információkat számszerűsítik.² A geometriai paraméterek IBSI által egységesített definícióit és képleteit szintén megtaláljuk a 2020. évben aktualizált referenciakézikönyvben.⁷ Ide tartoznak többek között olyan egyszerűen mérhető jellemzők, mint a kijelölt terület maximális kétdimenziós átmérője vagy a kijelölt lézió térfogata, de találunk közöttük komplexebb számításokat igénylő radiomikai paramétereket is, mint a felszín területe, a gömbölyűség vagy az elongáltság.

Textúraparaméterek

Míg az elsőrendű statisztikák csak a pixelek egyedi jellemzőit értékelik és figyelmen kívül hagyják a pixelek elhelyezkedését és egymáshoz való viszonyát, addig a textúraelemzésre használt másod-, illetve magasabb rendű paraméterek az egyes pixelek/voxelek egymáshoz való viszonyát, az adott kijelölt terület heterogenitását vizsgálják a két-, illetve háromdimenziós térben.

Szürkeérték együttes előfordulási mátrix (GLCM)


A szürkeérték együttes előfordulási mátrix (gray-level co-occurrence matrix – GLCM) alapú textúraparaméterek a legelső és egyben legszélesebb körben használt textúraparaméter-család, amelyet Haralick és mtsai alkottak meg 1973-ban.²⁵ A GLCM egy kétdimenziós ROI vagy egy háromdimenziós VOI esetén jellemzi az adott i és j szürkeértékekkel rendelkező pixelek/voxelek együttes előfordulását egy adott θ szögű tengely mentén, egy adott δ távolságon belül.

A GLCM-alapú textúraparaméterek számolása során a leggyakrabban a közvetlenül egymás mellett ($\delta=1$ távolságra) elhelyezkedő pixelpárok/voxelpárok szürkeértékeinek együttes előfordulási gyakoriságát írjuk le. Két dimenzió esetén egy pixel közvetlen szomszédjainak száma 8, a tengelyek száma 4, míg három dimenzió esetén az egymással közvetlen szomszédtságban lévő voxelek száma 26, a tengelyek száma pedig 13.² Fontos megjegyezni, hogy a radiomikai elemzéshez használt szoftverek egymástól eltérő módon, eltérő sorrendű matematikai műveletekkel vonhatják össze az egyes irányvektorok mentén számolt GLCM-értékeket. Az egyik legközkedveltebb programcsomag, a pyRadiomics¹⁸ esetén például a textúraelemzés során az egyes textúraparaméterek szimmetrikus módon (a pozitív és a negatív irányvektort is figyelembe véve) kerülnek kiszámolásra minden egyes θ szögű tengelyre létrehozott GLCM alapján külön-külön, amely textúraparaméter-értékek ezt követően átlagolódnak. A GLCM-alapú textúraparaméterek IBSI által egységesített definícióit és képleteit a 2020. évben aktualizált referencia-kézikönyvben olvashatjuk.⁷

A szimmetrikus GLCM felépülését egy egyszerűsített példán keresztül a 3. ábra mutatja be. Az egyes textúraparamétereket (pl.: „GLCM – Inverse difference moment“) az így keletkező GLCM-mátrixból számoljuk ki, meghatározott matematikai egyenleteknek megfelelően.


Gray-level run-length matrix (GLRLM)

Az úgynevezett „gray-level run-length matrix“ (GLRLM) alapú textúraparamétereket Galloway és mtsai alkották meg 1975-ben.²⁶ A GLRLM az adott θ szögű tengely mentén elhelyezkedő, azonos i szürkeértékkel rendelkező, egymással kapcsolódó pixelek futáshosszát (j) számszerűsíti. Vagyis megadja, hogy az adott értékkel rendelkező pixelből adott tengely mentén hány darab helyezkedik el egymás mellett, és ezen értékek gyakoriságát fejezi ki az adott kijelölt területen belül.² A GLRLM-alapú textúraparaméterek IBSI által egységesített definícióit és képleteit a 2020. évben aktualizált referencia-kézikönyvben olvashatjuk.⁷ A mátrix felépülését egy egyszerűsített példán keresztül a 4. ábra mutatja be. Az egyes textúraparamétereket (pl.: „GLRLM – Short runs emphasis“) az így keletkező GLRLM-mátrixból számoljuk ki, meghatározott matematikai egyenleteknek megfelelően. Fontos itt is megjegyezni, hogy a radiomikai elemzéshez használt szoftverek egymástól eltérő módon, eltérő sorrendű matematikai műveletekkel vonhatják össze az egyes tengelyek mentén számolt GLRLM-értékeket. Az egyik legközkedveltebb programcsomag, a pyRadiomics¹⁸ esetén például a textúraelemzés során az egyes textúraparaméterek minden egyes θ szögű tengelyre létrehozott GLRLM alapján külön-külön kiszámolásra



3. ábra. A szürkeérték együttes előfordulási mátrix (gray-level co-occurrence matrix – GLCM) kiszámolása a textúraelemzés során (px: pixel; ROI: vizsgált terület)

Egy $N_g \times N_g = 5 \times 5$ méretű szimmetrikus $P(i,j|\delta,\theta)$ GLCM felépülése $\theta=0^\circ$ szögű tengely és $\delta=1$ távolság esetén, ahol i , illetve j jelölik a kijelölt terület (ROI) egyes pixeleinek denzitásértékeit. A jelen példa esetén egy vesetumort tartalmazó axialis CT-szeleten belül egy 5x5 pixel nagyságú ROI-t határoztunk meg, ahol az egyes pixelek denzitásértékei az egyszerűség kedvéért 1 és 5 közé eső pozitív egész számok ($N_g=5$). A mátrix felépülésekor minden lépésnél azonosítjuk az adott i értékű pixeleket, és meghatározzuk, hogy ezeknek a központi pixeleknél adott θ irány mentén adott δ távolságra lévő szomszédos pixelpárjai hányszor vesznek fel j értéket. Más szavakkal, a ROI-n belül hányszor fordul elő, hogy adott i értékű pixel mellett adott j értékű pixel áll.



4. ábra. Az ún. „gray-level run-length matrix” (GLRLM) kiszámolása a textúraelemzés során (px: pixel; ROI: vizsgált terület)


A példában egy vesetumort tartalmazó axialis CT-szeleten belül egy 5x5 pixel nagyságú ROI-t határoztunk meg, ahol az egyes pixelek denzitásértékei az egyszerűség kedvéért 1 és 5 közé eső pozitív egész számok ($N_g=5$). A kétdimenziós kijelölt területen belül ezek után definiáltuk a textúraelemzés során $\theta=90^\circ$ szögű tengelyt. Az $N_g \times N_g=5 \times 3$ nagyságú GLRLM felépítésekor i jelöli az egyes pixelekhez rendelt denzitásértékeket, j pedig a futáshosszokat. Minden lépésnél kijelölünk egy adott i denzitásértékű pixelt és számszerűsítjük, hogy ennek a pixelnek hány olyan szintén i értékű szomszédja van, amelyek folytatólagosan érintkeznek egymással θ irány mentén.

kerülnek, amely textúraparaméter-értékek ezt követően átlagolódnak.

Gray-level size zone matrix (GLSZM)

Az úgynevezett „gray-level size zone matrix” (GLSZM) alapú textúraparamétereket Thibault és mtsai írták le először 2014-ben.²⁷ A GLSZM – hasonlóan a GLRLM-hez – szintén az azonos szűrkeértékekkel rendelkező, egymással kapcsolódó

pixelek számát határozza meg. Fontos különbség, hogy a GLRLM-mel ellentétben a GLSZM tengely megjelölése nélkül adja meg az azonos szűrkeértékkel rendelkező, egymással vagy éllel, vagy sarokkal érintkező pixelek számát az adott ROI-n belül.² A GLSZM-alapú textúraparaméterek IBSI által egységesített definícióit és képleteit a 2020. évben aktualizált referencia-kézikönyvben olvashatjuk.⁷ A mátrix felépülését egy egyszerűsített példán keresztül a 5. ábra mutatja



5. ábra. Az ún. „gray-level size zone matrix” (GLSZM) kiszámolása a textúraelemzés során (px: pixel; ROI: vizsgált terület)

A példában egy vesetumort tartalmazó axialis CT-szeleten belül egy 5x5 pixel nagyságú ROI-t határoztunk meg, ahol az egyes pixelek denzitásértékei az egyszerűség kedvéért 1 és 5 közé eső pozitív egész számok ($N_g=5$), az egymással érintkező azonos denzitású pixelek maximális száma pedig négy ($N_z=4$). Az $N_g \times N_z=5 \times 4$ nagyságú GLSZM felépítésekor i jelöli az egyes pixelekhez rendelt denzitásértékeket, j pedig az összefüggő területek nagyságát. Minden lépésnél számszerűsítjük, hogy hány olyan i értékű szomszédos pixel van, amelyek folytatólagosan az élüknél vagy a sarkuknál fogva érintkeznek egymással.

be. Az egyes textúraparamétereket (pl.: „GLSZM – High gray-level zone emphasis”) az így keletkező GLSZM-mátrixból számoljuk ki, meghatározott matematikai egyenleteknek megfelelően.


Neighboring gray-level dependence matrix (NGLDM)

Az úgynevezett „neighboring gray-level dependence matrix” (NGLDM) alapú textúraparamétereket *Sun* és *Wee* határozták meg 1983. évi publikációjukban.²⁸ Az NGLDM-alapú textúraparaméterek IBSI által egységesített definícióit és képleteit a 2020. évben aktualizált referencia-kézikönyvben olvashatjuk.⁷ Az NGLDM felépülését egy egyszerűsített példán keresztül a 6. ábra mutatja be. Ebben az esetben az NGLDM felépülése során egyszerűen megfogalmazva azt számszerűsítjük, hogy a ROI-n belül hányszor fordul elő, hogy az adott i intenzitásértékű központi pixel közvetlen szomszédjai között nulla/egy/kettő/három stb. azonos i intenzitásértékű pixel található. Az egyes textúraparamétereket (pl.: „NGLDM – Low dependence low gray-level emphasis”) az így keletkező NGLDM-mátrixból számoljuk ki, meghatározott matematikai egyenleteknek megfelelően.

Predikciós modellépítés gépi tanulási algoritmusokkal

A radiomikai paraméterek kiértékeléséhez, a nagyszámú változók közötti összefüggések feltérképezéséhez az utóbbi időben egyre gyakrabban hívunk segítségül különböző matematikai modelleken alapuló gépi tanulási algoritmusokat.^{29,30,31} A gépi tanulási algoritmusok két nagy csoportba oszthatók, a klasszikus algoritmusok mellett (pl.: k -legközelebbi szomszéd algoritmus, szupport vektor gép algoritmus [SVM], véletlen erdő [RF] algoritmus) az utóbbi évtizedben megjelentek különböző neurális háló algoritmusok, valamint a területen mérföldkövet jelentő úgynevezett mélytanulás módszere.³²

A gépi tanulás a mesterséges intelligencia egyik területe, ami olyan rendszerekkel foglalkozik, amelyek tapasztalatokból tudást generálnak, tehát „tanulni” képesek. Ez azt jelenti, hogy a rendszer példaadatok, minták alapján képes önállóan vagy emberi segítséggel mintázatokat felismerni, valamint szabályokat meghatározni, amelyek alapján képes olyan általánosításra, ami – a tanulási szakasz végeztével – lehetővé teszi, hogy ismeretlen adatokra vonatkozólag is helyes döntéseket tudjon



6. ábra. Az ún. „neighboring gray-level dependence matrix” (NGLDM) kiszámolása a textúraelemzés során (px: pixel; ROI: vizsgált terület)


A példában egy vesetumort tartalmazó axialis CT-szeleten belül egy 5x5 pixel nagyságú ROI-t határoztunk meg, ahol az egyes pixelek denzitásértékei az egyszerűség kedvéért 1 és 5 közé eső pozitív egész számok ($N_g=5$), a központi pixeltől „függő” szomszédos pixelek száma pedig 0–2 között változik ($N_d=3$). Az $N_g \times N_d = 5 \times 3$ nagyságú $P(i,j)$ NGLDM felépítésekor i jelöli az egyes pixelekhez rendelt denzitásértékeket, j pedig a központi pixel szomszédságában lévő, attól az $|i-m| \leq \alpha$ kritérium alapján „függő” pixelek számát jelöli. A δ értékét leggyakrabban 1-nek választjuk, ebben az esetben csak a központi pixellel közvetlenül érintkező szomszédos pixeleket vesszük figyelembe a textúraelemzés során. Az α értékét pedig leggyakrabban 0-nak választjuk, mely esetben az $|i-m| \leq \alpha$ kritérium megfelel az $i=m$ kritériumnak. Vagyis ebben az esetben azt számszerűsítjük, hogy a ROI-n belül hányszor fordul elő, hogy az adott i denzitásértékű központi pixel $\delta=1$ egységnyi távolságú szomszédságában (közvetlen szomszéd) nulla/egy/kettő/három stb. azonos $m=i$ denzitás értékű pixel található.

hozni.³³ A gépi tanulásnak három fő típusa létezik: a felügyelet nélküli, a felügyelt és a megerősített tanulás. A felügyelet nélküli tanulás esetén előre fel nem címkézett, strukturálatlan adatokkal áll szemben a rendszer, viszont rendelkezik olyan algoritmussal, amely képes felismerni az adatok tulajdonságait, amely tulajdonságok alapján képes őket rendszerezni, kategorizálni. Ezzel szemben a felügyelt tanulás lényege, hogy az algoritmus felcímkézett adatokon tanul, majd később olyan adatokat is képes lesz az adott címkéknek megfelelően csoportosítani, amelyeket még nem látott. A felügyelet nélküli gépi tanulási módszerek közül a radiomikai kutatások során leggyakrabban a főkomponens-elemzést és a hierarchikus klaszterelemzést használjuk.

Főkomponens-elemzés (PCA)

A főkomponens-elemzés (PCA) egy széleskörben elterjedt dimenziócsökkentő módszer, ami

a magasabb dimenziós beviteli adatokat alacsony dimenziós adatokká alakítja. A módszer jól használható az adathalmaz legmeghatározóbb eloszlási mintázatának megjelenítésére, a legfontosabb paraméterek kiválasztására, valamint korlátozottan alkalmas zajcsökkentésre is. Előnye, hogy csökkenti a feldolgozási és számítási időt, miközben a dimenziók csökkentésével megkönnyíti az adatok ábrázolását és az összefüggések értelmezését. A multidimenziós beviteli adatok két-dimenziójú kimenetté alakításához kiválasztja az első dimenziót, ami mentén az adatpontok a legnagyobb varianciát mutatják, és így meghatározza az első főkomponenst. Ezt követően kiválasztja az első főkomponensre azt a merőleges második dimenziót, ami mentén a lehető legnagyobb varianciával rendelkeznek az adatpontok, és ezt a második dimenziót definiálja mint második főkomponenst.³⁴ A főkomponens-elemzés lényegét a 7. ábra mutatja be egy hipotetikus adathalmazon keresztül.



7. ábra. Főkomponens-elemzés a radiomikai paramétereken

Főkomponens-elemzés során a radiomikai paramétereket mint multidimenziós beviteli adatokat kezeljük, ahol az egyes radiomikai paraméterek egy-egy dimenziót jelentenek (x_1 és x_2), az egyes esetek adatpontjait pedig a radiomikai paraméterek által meghatározott multidimenziós térben vesszük fel (A). A multidimenziós tér két-dimenziójú kimenetté alakításához az algoritmus először kiválasztja azt a tengelyt, ami mentén az adatpontok a legnagyobb varianciát mutatják, ezt mint első főkomponenst definiálja, majd következő lépésként kiválasztja az első főkomponensre azt a merőleges második tengelyt, ami mentén a lehető legnagyobb varianciával rendelkeznek az adatpontok, és ezt a második tengelyt definiálja mint második főkomponenst (A). A B ábrán látható a főkomponens eredménye, az x tengelyen elhelyezkedő első főkomponens jelen esetben az adathalmaz teljes varianciájának 29,3%-át őrzi, míg az erre merőleges második főkomponens az y tengelyen a variancia 19,1%-áért felelős. A kék négyzetekkel és a piros körökkel jelzett két hipotetikus csoport esetei a főkomponens-elemzés során jól elkülönülnek egymástól. (Az ábra csak illusztráció.)

Hierarchikus klaszterelemzés

A hierarchikus klaszterelemzésnek két fő formáját: a felosztót és az összevonót különböztetjük meg. A hierarchikus klaszterelemzés eredményeinek ábrázolására elterjedt módszer a dendrogram, illetve az úgynevezett hőtérkép készítése.


Az összevonó módszer lényege, hogy a kiindulási multidimenzionális rendszer minden egyes adatpontját különálló klasztereknek definiálja, és az adatpontok egymáshoz viszonyított hasonlósága alapján addig párosítja, csoportosítja az adatokat, míg végül két fő klaszter alakul ki, amelyek az utolsó lépésben szintén összevonódnak. Az adatpontok hasonlóságának jellemzésére különböző módszerek állnak rendelkezésre. A klaszterek közötti távolság definiálása történhet többek között euklidészi vagy manhattani távolság számításával, a kapcsolási kritérium meghatározása pedig alapulhat a klaszterek két egymáshoz legközelebb

elhelyezkedő pontjának távolságán (egyszerű kapcsolás), a két legtávolabbi pont távolságán (teljes kapcsolás) vagy a klaszterek adatpontjai közötti átlagos távolságon (csoportátlag).³⁵

Felügyelt gépi tanulási módszerek

A felügyelt gépi tanulási módszerek közül a legelterjedtebb algoritmusok az úgynevezett legkisebb abszolút értékű szűkítés és szelekciós operátor (LASSO), az SVM és a döntési fák csoportjába tartozó RF algoritmus.

A LASSO egy lineáris gépi tanulási modell, amelyet regressziós feladat esetén használunk. Népszerűségét annak köszönheti, hogy a lineáris regresszióval ellentétben – ahol minden, a modellhez hozzáadott független változót számításba veszünk a modell építésekor – a LASSO képes a lineáris modellhez adott független változók közül a modellillesztés során kiszűrni a redundáns



8. ábra. A szupport vektor gép algoritmus működésének bemutatása

A szupport vektor gép (SVM) egy gépi tanulási algoritmus, amely a lineárisan szeparálható és a lineárisan nem elkülöníthető multidimenziós adathalmazokon egyaránt alkalmazható. A jelen ábra egy bináris modellt illusztrál, ezen bináris modell esetén előre meghatározzuk a tanítóhalmaz adatpontjainak két csoportját, amelyeket az SVM a tanulási fázist követően egy, az adatpontoktól leoptimalisabb távolságra lévő úgynevezett hipersíkkal különít el egymástól (A). A hipersíkhöz legközelebb eső, annak helyzetét meghatározó adatpontokat szupport vektornak nevezzük. Az algoritmus lineárisan elkülöníthető adathalmazok esetén automatikusan azt a leoptimalisabb hipersíkot szerkeszti meg, amely a legszélesebb margóval rendelkezik, tehát amitől a szupport vektorok a lehető legnagyobb távolságra vannak. A jelen példa esetén a hipersíktól jobbra eső eseteket az algoritmus a piros körök csoportjába osztja, míg a hipersíktól balra eső eseteket a kék négyzetek csoportjába sorolja. A hipotetikus példa alapján a tanító adathalmaz esetén két esetben történt téves klasszifikáció. Ezt követően a modell predikciós teljesítményét a tesztadathalmazon határozzuk meg. A jelen példa esetben a tesztadathalmazon validálva a modellt, összesen öt esetben történt téves klasszifikáció (B). (Az ábra csak illusztráció.)

változókat, ezzel egyszerűsítve a modellt.³⁶ Ezen előnyös tulajdonsága miatt gyakran használjuk a radiomikai elemzések során – mint szűrő – a radiomikai paraméterek számának redukálására is.

Az SVM algoritmust 1992-ben mutatták be *Boser* és *mtsai*.³⁷ A módszer a mai napig az egyik leghatékonyabb gépi tanulási algoritmus, ami mind a lineárisan szeparálható, mind pedig a lineárisan nem elkülöníthető multidimenzionális adathalmazok esetén is alkalmazható. Az SVM algoritmuson alapuló klasszifikációs modellek esetén a felhasználó előre meghatározza a tanító adathalmaz adatpontjainak két vagy több csoportját, amelyeket az SVM a tanulási fázist követően egy, az adatpontoktól legoptimálisabb távolságra lévő úgynevezett hipersíkkal különít el egymástól. Ha a tréninghalmaz két csoportjának adatpontjai lineárisan nem elkülöníthetők egymástól, lehetőség van adatpontok új, magasabb dimenziójú koordináta-rendszerbe történő transzformálására, ami már lehetővé teszi a két csoport adatpontjainak lineáris szeparálását. Erre a módszerre a szakirodalom úgynevezett „kernel-trükk”-ként hivatkozik.^{38,39} A szupport vektor gép algoritmus működését a 8. ábra mutatja be.

Az RF modell a döntési fák módszerén alapuló gépi tanulási algoritmus, amely a függő és független változók között nem feltételez lineáris kapcsolatot. Az algoritmus kiválóan alkalmazható klasszifikációs feladatokra olyan adathalmaz esetén, ahol a csoportok lineárisan nem elkülöníthetők egymástól. A modell több különböző döntési fát is tartalmaz; működése során a modell bemenete a benne található döntési fák bemenete lesz, amelyek külön-külön adnak egy-egy eredményt, majd az egyes döntési fák eredményei közül többségi döntés segítségével kapjuk meg a végső kimenetet.⁴⁰

Az SVM és az RF algoritmust a neurális hálókhoz hasonlóan az úgynevezett fekete doboz technikák között tartjuk számon, ami a módszerek azon tulajdonságára utal, hogy az algoritmus matematikai komplexitásából adódóan annak döntési mechanizmusa nem minden részletében áttekinthető. Ellentétben például a fehér doboz technikák közé sorolható lineáris regresszió modellel, amely döntéshozatalának logikája jól leírható és könnyen áttekinthető.⁴¹ A fekete doboz modellek működésének megértését tehát korlátozza a komplexitásuk, ami ezáltal azok klinikai alkalmazását is korlátozhatja.^{42,43} Azonban a fekete doboz technikák

a gyakorlatban mégis jobb predikciós teljesítményt mutatnak, mint a fehér doboz módszerek,⁴¹ ezért az utóbbi években a mesterséges intelligencia algoritmusok gyakorlati alkalmazásának megjelenésével megnőtt a jelentősége a fekete doboz technikák értelmezését támogató módszerek kidolgozásával foglalkozó, úgynevezett magyarázható mesterséges intelligencia tudományterületének.⁴⁴

Klinikai alkalmazások a hasi képképzésben

A radiomikai elemzés hasznosságát több korábbi kutatás bizonyította már mind ultrahang-, mind PET-, MRI-, valamint CT-vizsgálatok esetén; egyaránt jól használható módszernek tűnik benignus³⁰ és malignus elváltozások detektálására.⁴⁵ A CT-textúraelemzés onkológiai alkalmazása, a tumor-textúraanalízis ígéretesnek tűnik mind a terápiás válasz, mind a túlélés megítélésére több különböző szervrendszer malignus tumora – többek között a nyelöcsőrák,⁴⁶ a nem kissejtes tüdőrák,⁴⁷ a colorectalis carcinoma,^{48,49} a vastagbélrák májáttétei,⁵⁰ a hepatocelluláris carcinoma,⁵¹ a pancreas-adenocarcinoma⁵² és a vesesejtes veserák⁵³ – esetén is.


Az onkológiai alkalmazások közül *Wang* és *mtsai* a világossejtes veserák és a nem világossejtes veserák altípusok elkülönítésére tanított különböző gépi tanulási algoritmusokat kortikomedulláris fázisú CT-felvételekből kivont radiomikai paraméterek segítségével. A 2021-ben megjelent tanulmányban az SVM, az RF és a logisztikus regresszió algoritmuson alapuló gépi tanulási modellek diagnosztikus teljesítményét vevő működési karakterisztika görbe elemzéssel (ROC) értékelték. Mindhárom modell kiváló diagnosztikus teljesítményt, 0,84, 0,94 és 0,91 görbe alatti terület (AUC) értéket ért el a tesztadathalmazon validálva a világossejtes veserák klasszifikálásának tekintetében, amely teljesítmény még a tapasztalt radiológus diagnosztikus pontosságát is meghaladta (AUC=0,69).⁵⁴ Így a tanulmány meggyőzően igazolta, hogy a radiomikai elemzés objektív módon képes a vesetumorkok csoportosítására, meghaladva még a radiológus szakorvos diagnosztikus teljesítményét is, s így jól alkalmazható eszköz lehet a klinikai gyakorlatban.

A pancreas-adenocarcinoma szövettani grádusainak CT-textúraelemzésen alapuló, non-invazív

elkülönítésére *Chang* és mtsai végeztek multicentrikus retrospektív vizsgálatot.⁵⁵ A pankreatogén fázisú preoperatív CT-felvételekből kivont radiomikai paraméterekkel LASSO regressziós modellt építettek, amivel az alacsony (I/II) és magas (III/IV) grádusú adenocarcinómákat különítették el egymástól. A modell AUC=0,91 értékkel tudta elkülöníteni a magas grádusú tumorokat a belső validálás során, és független klinika betegein validálva is elfogadható teljesítményt mutatott (AUC=0,77). A tanulmány megmutatta, hogy a CT-felvételek radiomikai elemzése, feszegetve a radiológia szakterület határait, képes lehet egy nem radiológiai tumortulajdonság, a szövettani tumorgrádus non-invazív megítélésére is.

A nem onkológiai alkalmazások közül a májfibrosis non-invazív, CT-alapú diagnosztikájára és stádiummeghatározására *Budai* és mtsai építettek háromdimenziós CT-textúraelemzés során kapott

radiomikai paraméterekből SVM és RF algoritmusú predikciós modelleket.³⁰ A májparenchymán végzett textúraelemzés voxelszintű rekonstrukciójának eredményeit az egyes radiomikai paraméterek esetében a 9. ábra illusztrálja. A teszhalmazon validálva a modelleket, az RF modell AUC=0,88–0,90; míg az SVM modell AUC=0,76–0,90 diagnosztikus teljesítménnyel volt képes elkülöníteni egymástól a kezdetleges (F0-1-2) és az előrehaladott (F4-3) stádiumú májfibrosissal diagnosztizált betegek májszegmentumait. A kutatócsoport eredményei megmutatták, hogy a radiomikai paraméterek robusztusak a különböző CT-berendezésekkel és vizsgálati protokollokkal szemben, valamint hogy a radiomikai elemzés gépi tanulási algoritmusokkal kombinálva sikeresen alkalmazható non-invazív diagnosztikai módszer lehet a magas rizikójú betegek rutin portális vénás CT-felvételek alapján történő azonosítására.



9 ábra. A májparenchyma radiomikai elemzésének eredményéül kapott textúraparaméterek voxelszintű rekonstrukciója hőképp formájában

A szürkeérték együttes előfordulási mátrix alapú textúraparaméterek, úgymint a Haralick-féle korreláció (A), az entrópia (B), az inercia (C) és az energia (D) voxelszintű rekonstrukciója hőképp formájában. A rekonstruált textúratérképeket a portális vénás fázisú axialis CT-felvételekre vetítettük.

Megbeszélés

A radiomika egy új tudományterületet képvisel a radiológián belül. Bár számos kutatás bizonyította már ígéretességét különböző szervrendszerek jó- és rosszindulatú elváltozásainak diagnosztikájában. Az eredmények robusztusságát azonban csökkenti, hogy a legtöbb publikáció kis esetszámú és mindössze egyetlen intézet beteganyagának feldolgozásával készült; nagy esetszámú és multicentrikus kutatási eredmények még nem állnak rendelkezésre.

A radiomikai kutatások minőségének meghatározására 2017-ben *Lambin* és mtsai létrehozták a „Radiomics Quality Score”-t (RQS). A RQS egy 16 db kritériumon alapuló score-rendszer, amelyben a maximálisan elérhető 36 pont jelzi a legjobb minőséget. A kritériumok a reprodukálhatóságra helyezik a hangsúlyt, de többek között magukban foglalják az adatok publikus, nyílt hozzáférésű, ingyenes elérhetőségét is.⁹ Figyelemreméltó, hogy *Sanduleanu* és mtsai 2018-ban publikált szisztematikus irodalmi áttekintő tanulmánya eredményeként a vizsgált 41db radiomikai tanulmányból – négy különböző vizsgáló által függetlenül értékelve – csak 1–4 kutatás ért el $\geq 50\%$ RQS-értéket.⁵⁶ 2021-es évi szisztematikus irodalmi áttekintő cikkükben hasonló eredményeket közöltek *Bhandari* és mtsai is, akik a vesetumorkok radiomikai elemzését célzó korábbi publikációk minőségét értékelték. A vizsgált 13 cikk elemzése során a medián RQS-érték 12/36-volt, a legmagasabb érték pedig mindössze 15/36 volt.⁵⁷

A radiomika területén mérföldkövet jelentett az IBSI munkássága nyomán megjelent referencia-kézikönyv 2016-ban, amely a radiomikai paraméterek definícióit és matematikai egyenleteit egységesítette.² Az egyre nagyobb népszerűségnek örvendő képelemzési technika maga után vonta

a radiomikai elemzésre képes szoftverek számának növekedését is, ezért a szervezet 2020-ban publikált tanulmányában az egyes radiomikai paramétereket a különböző szoftverek között is validálta.⁷

Azonban a publikált radiomikai kutatások esetén a használt módszerek jelentős különbségeket mutatnak, hiszen a radiomikai elemzés során kapott adatbázisok kiértékelése a statisztikai módszerek hatalmas tárházának alkalmazására ad lehetőséget. A tudományterület legfőbb limitációja, hogy a munkafolyamatra és a statisztikai metodikára még a mai napig nincsen egységesen elfogadott nemzetközi protokoll. A jelenleg elérhető ajánlások^{58,59} csak a munkafolyamat főbb lépéseit definiálják és a főbb buktatókra hívják föl a figyelmet, azonban a felvételeken végzendő utómunkálatok, a paraméterszelekció és a modellépítés metodikája részleteinek tekintetében nem tartalmaznak határozott állásfoglalást. A publikált radiomikai tanulmányok limitációira való tekintettel meg kell állapítani, hogy jelenleg a radiomikai elemzés metodikája még nem elég kiforrott ahhoz, hogy az a mindennapi klinikai gyakorlatban rutinszerűen alkalmazható legyen. Multicentrikus kutatások során validálva a radiomikai kutatások eredményeit azonban a radiomika a jövőben ígéretes új típusú, non-invazív diagnosztikai eszköz lehet a radiológus szakorvos kezében, amely automatizált képelemzéssel pontosíthatja és gyorsíthatja a képalkotó diagnosztikát.

Köszönetnyilvánítás

A kézirat az Innovációs és Technológiai Minisztérium ÚNKP-21-3-1-SE kódszámú Új Nemzeti Kiválóság Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs alaphól finanszírozott szakmai támogatásával készült (BBK).

IRODALOMJEGYZÉK

1. Gillies RJ, Kinahan PE, Hricak H: Radiomics: Images Are More than Pictures, They Are Data. *Radiology* 2016; 278(2): 563-577. DOI: 10.1148/radiol.2015151169
2. Zwanenburg A, Leger S, Vallières M, Löck S: Image biomarker standardisation initiative. *arXiv preprint arXiv:1612.07003*. 2016. DOI: <https://doi.org/10.48550/arXiv.1612.07003>
3. Chernyak V, Fowler KJ, Kamaya A, Kiar A, Elsayes KM, et al.: Liver Imaging Reporting and Data System (LI-RADS) Version 2018: Imaging of Hepatocellular Carcinoma in At-Risk Patients. *Radiology* 2018; 289(3): 816-830. DOI: 10.1148/radiol.2018181494
4. Turkbey B, Rosenkrantz AB, Haider MA, Padhani AR, Villeirs G, et al.: Prostate Imaging Reporting and Data System Version 2.1: 2019 Update of Prostate Imaging Reporting and Data System Version 2. *Eur Urol* 2019; 76(3): 340-352. DOI: 10.1016/j.eururo.2019.02.033

5. Varghese BA, Cen SY, Hwang DH, Duddalwar VA: Texture Analysis of Imaging: What Radiologists Need to Know. *AJR Am J Roentgenol* 2019; 212(3): 520-528. DOI: 10.2214/ajr.18.20624
6. Lambin P, Rios-Velazquez E, Leijenaar R, Carvalho S, van Stiphout RG, et al.: Radiomics: extracting more information from medical images using advanced feature analysis. *Eur J Cancer* 2012; 48(4): 441-446. DOI: 10.1016/j.ejca.2011.11.036
7. Zwanenburg A, Vallières M, Abdalah MA, Aerts HJWL, Andrearczyk V, et al.: The Image Biomarker Standardization Initiative: Standardized Quantitative Radiomics for High-Throughput Image-based Phenotyping. *Radiology* 2020; 295(2): 328-338. DOI: 10.1148/radiol.2020191145
8. Shui L, Ren H, Yang X, Li J, Chen Z, et al.: The Era of Radiogenomics in Precision Medicine: An Emerging Approach to Support Diagnosis, Treatment Decisions, and Prognostication in Oncology. *Front Oncol* 2020; 10: 570465. DOI: 10.3389/fonc.2020.570465
9. Lambin P, Leijenaar RTH, Deist TM, Peerlings J, de Jong EEC, et al.: Radiomics: the bridge between medical imaging and personalized medicine. *Nat Rev Clin Oncol* 2017; 14(12): 749-762. DOI: 10.1038/nrclinonc.2017.141
10. Carré A, Klausner G, Edjlali M, Lerousseau M, Briend-Diop J, et al.: Standardization of brain MR images across machines and protocols: bridging the gap for MRI-based radiomics. *Sci Rep* 2020; 10(1): 12340. DOI: 10.1038/s41598-020-69298-z
11. Gudbjartsson H, Patz S: The Rician distribution of noisy MRI data. *Magn Reson Med* 1995; 34(6): 910-914. DOI: 10.1002/mrm.1910340618
12. Roy S, Whitehead TD, Quirk JD, Salter A, Ademuyiwa FO, et al.: Optimal co-clinical radiomics: Sensitivity of radiomic features to tumour volume, image noise and resolution in co-clinical T1-weighted and T2-weighted magnetic resonance imaging. *eBioMedicine* 2020; 59. DOI: 10.1016/j.ebiom.2020.102963
13. Gjestebj L, Man BD, Jin Y, Paganetti H, Verburg J, et al.: Metal Artifact Reduction in CT: Where Are We After Four Decades? *IEEE Access* 2016; 4: 5826-5849. DOI: 10.1109/ACCESS.2016.2608621
14. Kaposi PN, Youn T, Tóth A, Frank VG, Shariati S, et al.: Orthopaedic metallic artefact reduction algorithm facilitates CT evaluation of the urinary tract after hip prosthesis. *Clin Radiol* 2020; 75(1): 78.e17-78.e24. DOI: 10.1016/j.crad.2019.08.027
15. Kocak B, Durmaz ES, Erdim C, Ates E, Kaya OK, et al.: Radiomics of Renal Masses: Systematic Review of Reproducibility and Validation Strategies. *AJR Am J Roentgenol* 2020; 214(1): 129-136. DOI: 10.2214/AJR.19.21709
16. Soffer S, Ben-Cohen A, Shimon O, Amitai MM, Greenspan H, et al.: Convolutional Neural Networks for Radiologic Images: A Radiologist's Guide. *Radiology* 2019; 290(3): 590-606. DOI: 10.1148/radiol.2018180547
17. Budai B, Borsos P, Magyar P, Bérczi V, Kaposi NP: ECR 2020 Book of Abstracts. S 8-4. Convolutional neural network-based volumetric segmentation of the liver compared with semi-automatic and manual methods. *Insights Imaging* 2020; 11(Suppl 1): 34. DOI: 10.1186/s13244-020-00851-0
18. van Griethuysen JJM, Fedorov A, Parmar C, Hosny A, Aucoin N, et al.: Computational Radiomics System to Decode the Radiographic Phenotype. *Cancer Res* 2017; 77(21): e104-e107. DOI: 10.1158/0008-5472.Can-17-0339
19. Rizzo S, Botta F, Raimondi S, Origgi D, Fanciullo C, et al.: Radiomics: the facts and the challenges of image analysis. *Eur Radiol Exp* 2018; 2(1): 36. DOI: 10.1186/s41747-018-0068-z
20. Jha AK, Mithun S, Jaiswar V, Sherkhane UB, Purandare NC, et al.: Repeatability and reproducibility study of radiomic features on a phantom and human cohort. *Sci Rep* 2021; 11(1): 2055. DOI: 10.1038/s41598-021-81526-8
21. Meyer M, Ronald J, Vernuccio F, Nelson RC, Ramirez-Giraldo JC, et al.: Reproducibility of CT Radiomic Features within the Same Patient: Influence of Radiation Dose and CT Reconstruction Settings. *Radiology* 2019; 293(3): 583-591. DOI: 10.1148/radiol.2019190928
22. Haarburger C, Müller-Franzes G, Weninger L, Kuhl C, Truhn D, et al.: Radiomics feature reproducibility under inter-rater variability in segmentations of CT images. *Sci Rep* 2020; 10(1): 12688. DOI: 10.1038/s41598-020-69534-6
23. Zhang Y, Lobo-Mueller EM, Karanicolas P, Gallinger S, Haider MA, et al.: Improving prognostic performance in resectable pancreatic ductal adenocarcinoma using radiomics and deep learning features fusion in CT images. *Sci Rep* 2021; 11(1): 1378. DOI: 10.1038/s41598-021-80998-y
24. Wei J, Cheng J, Gu D, Chai F, Hong N, et al.: Deep learning-based radiomics predicts response to chemotherapy in colorectal liver metastases. *Med Phys* 2021; 48(1): 513-522. DOI: 10.1002/mp.14563
25. Haralick RM, Shanmugam K, Dinstein I: Textural Features for Image Classification. *IEEE Trans Syst, Man, Cybern* 1973; SMC-3(6): 610-621. DOI: 10.1109/TSMC.1973.4309314
26. Galloway MM: Texture analysis using gray-level run lengths. *Comp Graph Image Process* 1975; 4(2): 172-179. DOI: 10.1016/S0146-664X(75)80008-6
27. Thibault G, Angulo J, Meyer F: Advanced statistical matrices for texture characterization: application to cell classification. *IEEE Trans Biomed Eng* 2014; 61(3): 630-637. DOI: 10.1109/tbme.2013.2284600
28. Sun C, Wee WG: Neighboring gray-level dependence matrix for texture classification. *Comp Graph Image Process* 1983; 23(3): 341-352. DOI: 10.1016/0734-189X(83)90032-4
29. Budai BK, Frank V, Shariati S, Fejér B, Tóth A, et al.: CT Texture Analysis of Abdominal Lesions – Part I.: Liver lesions. *Imaging* 2021. DOI: 10.1556/1647.2021.00007
30. Budai BK, Toth A, Borsos P, Frank VG, Shariati S, et al.: Three-dimensional CT texture analysis of anatomic liver segments can differentiate between low-grade and high-grade fibrosis. *BMC Med Imaging* 2020; 20(1): 108. DOI: 10.1186/s12880-020-00508-w
31. Kaposi PN, Budai B, Frank V, Shariati S, Folhoffer A, et al.: CT texture analysis in liver fibrosis shows a strong correlation with portal phase enhancement and can predict cirrhosis in decision tree model. *Insights Imaging* 2019; 10(Suppl. 1): B-1589. DOI: 10.1186/s13244-019-0713-y
32. Vial A, Stirling D, Field M, Ros M, Ritz C, et al.: The role of deep learning and radiomic feature extraction in cancer-specific predictive modelling: a review. *Transl Cancer Res* 2018; 7(3): 803-816. DOI: 10.21037/tcr.2018.05.02
33. Erickson BJ, Korfiatis P, Akkus Z, Kline TL: Machine Learning for Medical Imaging. *Radiographics* 2017; 37(2): 505-515. DOI: 10.1148/rg.2017160130

34. Tan P-N, Steinbach M, Kumar V: Introduction to data mining. Appendix B. Dimensionality Reduction. International ed. ed. Boston, Mass., Pearson Addison Wesley, 2006. pp. 701-704.
35. Tan P-N, Steinbach M, Kumar V: Introduction to data mining. Chapter 8. Cluster Analysis: Basic Concepts and Algorithms. International ed. ed. Boston, Mass., Pearson Addison Wesley, 2006. pp. 515-26.
36. Aggarwal CC: Data Classification: Algorithms and Applications. Chapter 2. Feature Selection for Classification: A Review. Yorktown Heights, New York, USA, CRC Press, 2015. pp. 47-48.
37. Boser B, Guyon I, Vapnik V: A training algorithm for optimal margin classifiers. Proceedings of the Fifth Annual Workshop on Computational Learning Theory, Pittsburgh, 1992.
38. Mohri M, Rostamizadeh A, Talwalkar A: Foundations of Machine Learning. Support Vector Machines. MIT Press, 2012. pp. 63-87.
39. Tan P-N, Steinbach M, Kumar V: Introduction to data mining. Chapter 6. Classification: Alternative Techniques. International ed. ed. Boston, Mass., Pearson Addison Wesley, 2006. pp. 256-70.
40. Joshi AV: Machine Learning and Artificial Intelligence. Part II Machine Learning. Switzerland, Springer Nature, 2020. pp. 53-63.
41. Pintelas E, Livieris IE, Pintelas P: A Grey-Box Ensemble Model Exploiting Black-Box Accuracy and White-Box Intrinsic Interpretability. Algorithms 2020; 13(1). DOI: 10.3390/a13010017
42. Price WN: Big data and black-box medical algorithms. Sci Transl Med 2018; 10(471). DOI: 10.1126/scitranslmed.aao5333
43. Poon AIF, Sung JY: Opening the black box of AI-Medicine. J Gastroenterol Hepatol 2021; 36(3): 581-584. DOI: 10.1111/jgh.15384
44. Zhang Y, Weng Y, Lund J: Applications of Explainable Artificial Intelligence in Diagnosis and Surgery. Diagnostics 2022; 12(2). DOI: 10.3390/diagnostics12020237
45. Lubner MG, Smith AD, Sandrasegaran K, Sahani DV, Pickhardt PJ: CT Texture Analysis: Definitions, Applications, Biologic Correlates, and Challenges. Radiographics 2017; 37(5): 1483-1503. DOI: 10.1148/rg.2017170056
46. Ganeshan B, Skogen K, Pressney I, Coutroubis D, Miles K: Tumour heterogeneity in oesophageal cancer assessed by CT texture analysis: preliminary evidence of an association with tumour metabolism, stage, and survival. Clin Radiol 2012; 67(2): 157-164. DOI: 10.1016/j.crad.2011.08.012
47. Ganeshan B, Panayiotou E, Burnand K, Dizdarevic S, Miles K: Tumour heterogeneity in non-small cell lung carcinoma assessed by CT texture analysis: a potential marker of survival. Eur Radiol 2012; 22(4): 796-802. DOI: 10.1007/s00330-011-2319-8
48. Miles KA, Ganeshan B, Griffiths MR, Young RC, Chatwin CR: Colorectal cancer: texture analysis of portal phase hepatic CT images as a potential marker of survival. Radiology 2009; 250(2): 444-452. DOI: 10.1148/radiol.2502071879
49. Ng F, Ganeshan B, Kozarski R, Miles KA, Goh V: Assessment of primary colorectal cancer heterogeneity by using whole-tumor texture analysis: contrast-enhanced CT texture as a biomarker of 5-year survival. Radiology 2013; 266(1): 177-184. DOI: 10.1148/radiol.12120254
50. Beckers RCJ, Lambregts DMJ, Schnerr RS, Maas M, Rao SX, et al.: Whole liver CT texture analysis to predict the development of colorectal liver metastases – A multicentre study. Eur J Radiol 2017; 92: 64-71. DOI: 10.1016/j.ejrad.2017.04.019
51. Brenet Defour L, Mule S, Tenenhaus A, Piardi T, Sommacale D, et al.: Hepatocellular carcinoma: CT texture analysis as a predictor of survival after surgical resection. Eur Radiol 2018. DOI: 10.1007/s00330-018-5679-5
52. Yun G, Kim YH, Lee YJ, Kim B, Hwang JH, et al.: Tumor heterogeneity of pancreas head cancer assessed by CT texture analysis: association with survival outcomes after curative resection. Sci Rep 2018; 8(1): 7226. DOI: 10.1038/s41598-018-25627-x
53. Lubner MG, Stabo N, Abel EJ, Del Rio AM, Pickhardt PJ: CT Textural Analysis of Large Primary Renal Cell Carcinomas: Pretreatment Tumor Heterogeneity Correlates With Histologic Findings and Clinical Outcomes. AJR Am J Roentgenol 2016; 207(1): 96-105. DOI: 10.2214/AJR.15.15451
54. Wang P, Pei X, Yin X-P, Ren J-L, Wang Y, et al.: Radiomics models based on enhanced computed tomography to distinguish clear cell from non-clear cell renal cell carcinomas. Sci Rep 2021; 11(1): 13729. DOI: 10.1038/s41598-021-93069-z
55. Chang N, Cui L, Luo Y, Chang Z, Yu B, et al.: Development and multicenter validation of a CT-based radiomics signature for discriminating histological grades of pancreatic ductal adenocarcinoma. Quant Imaging Med Surg 2020; 10(3): 692-702. DOI: 10.21037/qims.2020.02.21
56. Sanduleanu S, Woodruff HC, de Jong EEC, van Timmeren JE, Jochems A, et al.: Tracking tumor biology with radiomics: A systematic review utilizing a radiomics quality score. Radiother Oncol 2018; 127(3): 349-360. DOI: 10.1016/j.radonc.2018.03.033
57. Bhandari A, Ibrahim M, Sharma C, Liong R, Gustafson S, et al.: CT-based radiomics for differentiating renal tumours: a systematic review. Abdom Radiol (NY) 2021; 46(5): 2052-2063. DOI: 10.1007/s00261-020-02832-9
58. Shur JD, Doran SJ, Kumar S, ap Dafydd D, Downey K, et al.: Radiomics in Oncology: A Practical Guide. Radiographics 2021; 41(6): 1717-1732. DOI: 10.1148/rg.2021210037
59. van Timmeren JE, Cester D, Tanadini-Lang S, Alkadhi H, Baessler B: Radiomics in medical imaging-“how-to” guide and critical reflection. Insights Imaging 2020; 11(1): 91. DOI: 10.1186/s13244-020-00887-2

XXI. SZÁZADI RADIOLOGIA A KÓRHÁZAKNAK

MEDIX DR
csontsűrűségmérő



EOS EDGE és SterEOS
innovatív képalkotó rendszer
és 3D munkaállomás



Nagy sebességű, digitális
radiológiai teljes-test szkennerek




Compact DR Plus
mobil körtermi
berendezések



APOLLO
röntgenátvilágító



MOVIPLAN
felvételi
röntgen-
berendezések



MELODY
mammográfiás
berendezések

