



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

DOKTORI (PHD) ÉRTEKEZÉS
TÉZISFÜZET

GYÖRFI ÁGNES

Agytumor automatikus felismerése és
szegmentálása

Témavezetők:

Prof. Dr. Kovács Levente

Prof. Dr. Szilágyi László

**ALKALMAZOTT INFORMATIKAI ÉS
ALKALMAZOTT MATEMATIKAI
DOKTORI ISKOLA**

Budapest, 2024. november 21.

Tartalomjegyzék

1. Előszó	2
2. A kutatás háttere	5
3. Javasolt megoldások	7
4. Új tudományos eredmények	13
4.1. I. tétiscsoport – MRI adatok előfeldolgozásával kapcsolatos eredmények	13
4.2. II. tétiscsoport – Képpontok osztályozásával kapcsolatos eredmények	15
4.3. III. tétiscsoport – A szegmentálás kimenetének utófeldolgozásával kapcsolatos eredmények	16
5. Az eredmények hasznosítási lehetősége	17
Irodalomjegyzék	18
A tétispontokhoz kapcsolódó tudományos közlemények	20
További tudományos közlemények	24

Előszó

Az agy és a központi idegrendszer rákos megbetegedései évente több mint kétszázezer halálesetet okoznak világszerte [Patel et al., 2019]. Ezek jelentős része megelőzhető lenne korai diagnózissal. Az orvosi képalkotó berendezések által előállított képi adatok jelentős mennyisége miatt egyre nyilvánvalóbbá vált az olyan automatizált eljárások iránti igény, amelyek hatékonyan, gyorsan és megbízhatóan előszűrik a képeket, és az orvosok figyelmébe ajánlják a szerintük rendellenesnek vélt eseteket.

Az agytumороk automatikus felismerése és szegmentálása MRI adatokban már több mint három évtizede foglalkoztatja a kutatókat [Gordillo et al., 2013]. A 2012 óta évente megrendezett Brain Tumor Segmentation Challenges (BraTS) fokozta az érdeklődést e terület iránt azáltal, hogy standardizált tanítási és tesztelési adatokat, valamint egységes értékelési keretet tett elérhetővé mindenki számára [Menze et al., 2015, Bakas et al., 2017].

Az agytumороk korai felismerése és pontos szegmentálása létfontosságú a betegek hatékony kezelése és a túlélési esélyek javítása szempontjából. Az olyan tényezők, mint a tumor típusa, a tumor foka és a korai felismerés jelentős szerepet játszanak. Az Egészségügyi Világszervezet az agytumороkat különböző fokozatokba sorolja, amelyek mindegyike saját prognózissal és kezelési megközelítéssel rendelkezik.

Az orvosi képalkotó eszközök által előállított MRI felvételek mennyisége folyamatosan növekszik, miközben a képek elemzéséhez szükséges szakemberi kapacitás korlátozott. Ezért sürgető igény mutatkozik olyan automatizált szegmentálási módszerek kifejlesztésére, amelyek csökkentett számítási követelmények mellett is kiváló minőségű

eredményeket nyújtanak.


A kutatás során az volt a fő célom, hogy olyan megoldást javasoljak az agytumороk szegmentálására, amely csökkentett számítási követelmények mellett kiváló minőségű eredményeket nyújt. Célom volt továbbá annak vizsgálata, hogy az előfeldolgozási módszerek miként járulhatnak hozzá a szegmentáció hatékonyságának növeléséhez, valamint az osztályozók teljesítményének és működésének elemzése különböző megközelítések alkalmazásával. Ezen túlmenően a kutatás során arra is törekedtem, hogy feltárjam az utófeldolgozási eljárások szerepét és lehetőségeit a szegmentációs eredmények finomítása és pontosságának javítása érdekében.

Ehhez egy együttes tanulást [Gordillo et al., 2013] alkalmazó osztályozást valósítottam meg, melyet számos olyan képfeldolgozási módszer segít, melyeket a fokális elváltozásokat valószínűleg tartalmazó MRI felvételek feldolgozására terveztem. Emellett egy U-Net alapú [Ronneberger et al., 2015] szegmentációs megközelítést is javaslok azzal a céllal, hogy a gépi tanulás legmodernebb technológiáinak felhasználásával tovább javítsam az eredmények minőségét.

Az első téziscsoport az MRI adatok előfeldolgozásának fontos kérdéseivel foglalkozik. Megvizsgálja és javaslatot tesz a legmegfelelőbb hisztogram egységesítési módszerre, a jó minőségű agyi MRI szegmentáláshoz, külön vizsgálva a fokális elváltozásokat tartalmazó és nem tartalmazó felvételek esetét. Javasol egy jellemzőgenerálási és kiválasztási sémát a szegmentáláshoz szükséges jellemzők számának csökkentésére a minőség romlása nélkül. Megvizsgálja a spektrális felbontás hatását a szegmentálás pontosságára, és javaslatot tesz az MRI adatok hatékony tárolására. Végül bemutat egy atlasz alapú [Yang et al., 2019], [Cabezas et al., 2011] adatjavító technikát, amelyel pontosabbá sikerült tenni a tumороk térbeli szegmentálását.

A második téziscsoport az együttes tanulást és a mély tanulást [Pereira et al., 2016], [Fernando and Tsokos, 2023], [Yu et al., 2021] hasonlítja össze agytumorok szegmentálása során, megállapítva a mély tanulási módszerek jobb teljesítményét. A tanulmány elemzi a különböző osztályozók pontosságát és hatékonyságát, bemutatva a mély tanulás figyelemre méltó képességeit az orvosi képeken belüli komplex minták és térbeli kapcsolatok megragadásában. A hagyományos, ember által tervezett jellemzők alapján működő megközelítésektől eltérően a mély tanulási módszerek nagyfokú alkalmazkodóképességet és skálázhatóságot mutattak. A szegmentálási pontosság jelentős javulása kiemelte a mély tanulási módszereket, mint az agytumorok elemzésének hatékonyságát és megbízhatóságát növelő ígéretes utat.

A harmadik téziscsoport új utófeldolgozási módszert kínál mindkét szegmentáló eljáráshoz. Egyrészt bevezet egy kétlépcsős utófeldolgozási módszert az együttes tanulást alkalmazó szegmentáló rendszerbe, másrészt javasolja egy második U-Net konvolúciós neurális háló [Ronneberger et al., 2015] alkalmazását azzal a céllal, hogy finomítsa és javítsa az agytumor szegmentációs pontosságát. Ez a finomított szegmentációs kimenet értékes alapként szolgál a későbbi elemzésekhez és klinikai alkalmazásokhoz, biztosítva a pontos információk megszerzését a diagnózis és a kezelés tervezéséhez. A klasszikus gépi tanulás és a mély tanulás módszereit integráló megközelítések bizonyították hatékonyságukat az agytumorok szegmentálási minőségének javításában, ami végső soron mind a klinikusok, mind pedig a neuroképalkotás területén dolgozó kutatók számára jelentős előnyökkel jár.



1. ábra. A kutatás kezdőpontjának tekinthető agytumor szegmentáló eljárás egyszerűsített folyamatábrája.

A kutatás háttere

A Sapientia Egyetem kutatócsoportja, amelyhez 2017-ben csatlakoztam, kidolgozott egy agytumor szegmentáló eljárást, amelyet doktori kutatómunkám alapjának, kiinduló pontjának lehet tekinteni. A kezdeti eljárás részletei a [Szilágyi et al., 2018], [Szilágyi et al., 2015a], [Szilágyi et al., 2015b], [Kapás et al., 2016], [Kapás et al., 2018] dolgozatokban vannak leírva. Az eljárás egyszerűsített folyamatábrája az **1.** ábrán látható.

A szegmentálás a képpontok osztályozása során valósul meg, ahol az osztályozást egy együttes tanulást alkalmazó rendszer, egy bináris döntési fákból álló erdő végzi el. Az osztályozást megelőzően az MRI adatokat előfeldolgozási lépéseknek vetjük alá, melynek célja a nyers MRI adatok előkészítése az osztályozásra. Az *előfeldolgozás* szükséges és lehetséges lépései, a végrehajtás sorrendjében:

1. Különböző MRI felvételek képpontjainak az intenzitás értékei nem azonos skálán helyezkednek el, így azonos szövettípusok más-más felvételekben egymástól különböző módon néznek ki. Ezért az előfeldolgozás során hisztogram egységesítést végzünk el, melynek során mindegyik adatcsatornán külön-külön egymáshoz igazítjuk az intenzitás értékek hisztogramját. Ezt a lépést

a kezdeti eljárás egy kontextusfüggő lineáris transzformációval valósította meg.

2. A rendelkezésünkre álló multispektrális MRI adatok között nem minden képpont rendelkezik mért intenzitásértékkel mindegyik adatcsatornán; egyes helyeken a nullás érték jelzi a hiányzó adatot. A hiányzó adatok pótlására elsődlegesen az adott képpont közvetlen térbeli szomszédjának tekinthető 26 képpont intenzitás értékeinek átlagát használjuk, vagy ha ez nem áll rendelkezésre, akkor az adott felvételen a teljes adatcsatorna átlagos intenzitás értékét.
3. A klasszikus gépi tanulást alkalmazó módszerek jobban működnek sok dimenziós adattérben. Ugyanakkor elmondhatjuk, hogy egy-egy képpont vagy az általa reprezentált egy köbmilliméternyi agyszövet minden lehetséges részlete nem található meg a négy mért adatban, amit a T1, T2, T1c és FLAIR adatcsatornák nyújtanak számunkra. Ezért a kezdeti eljárásunk 100 további jellemzőt generált, így összesen 104 elemből álló jellemzővektorokat használtunk a tanításhoz és teszteléshez.

A *szegmentálás* a képpontok osztályozásával történik, felügyelt gépi tanulási technikák segítségével. A kezdeti szegmentációs keretrendszer bináris döntési fák (BDT) együttesét alkalmazta az osztályozás elvégzésére. Egy korlátlan mélységű BDT a kétirányú döntések bármely hierarchiáját leírhatja [Akers, 1978]. Továbbá, egy BDT tökéletesen meg tudja tanulni bármely tanulási adathalmaz osztályozását, ha nincs ellentmondás az adatokban. A kezdeti szegmentáló eljárás döntési fái azonos mennyiségű, véletlenszerűen kiválasztott képpont jellemzővektoraiból tanulták meg szétválasztani a pozitív és negatív képpontokat.

A *utófeldolgozás* egy utólagos újracímkézési műveletet jelent, amely a kezdeti szegmentációs eljárásban egy tanulást nem igénylő egyszerű morfológiai kritérium szerint valósult meg. Az utófeldolgozási lépés bemeneti adatai a BDT együttes által a tesztadat összes képpontjához rendelt címkékből áll. Minden egyes képpont esetében megállapítottuk egy előre meghatározott térbeli szomszédságon belül a pozitívként megjelölt szomszédok számát és az összes szomszédok számát. Egy képpont végső besorolása akkor és csak akkor lett tumor, ha a pozitív szomszédok aránya meghaladta az empirikusan megállapított küszöbértéket ($1/3$).

Javasolt megoldások

A doktori tanulmányaim ideje alatt publikált dolgozatok nagy többsége az előző fejezetben ismertetett kezdeti agytumor szegmentáló eljárás működését optimalizálta. Minden dolgozat a feldolgozás egy-egy lépésére koncentrált. Mindegyik ilyen dolgozatban szerepel a teljes szegmentáló eljárás, melynek a fókuszban levő feldolgozó egységét alternatív megoldásokkal próbálom helyettesíteni és megállapítom a legjobban teljesítő verziót.

A [\[GyA4\]](#) dolgozat a szegmentálást legjobban támogató hisztogram egységesítő módszert állapítja meg, összehasonlítva a szakirodalomban leggyakrabban alkalmazott lineáris transzformációt Nyúl László szakaszonként lineáris transzformációjával [\[Nyúl et al., 2000\]](#), mindkettőnek figyelembe véve a lehetséges paramétereit. Fokális elváltozást tartalmazó és nem tartalmazó MRI felvételeken elvégzett tesztek alapján megállapítottam, hogy a legjobban a szakaszonként lineáris transzformáció teljesít, és javaslatokat tettem az algoritmus megfelelő paraméterezésére.

A [GyA1] dolgozatban bevezettem egy jellemző kiválasztási eljárást, amely a szegmentáló eljárás számításiigényét és memóriaigényét hivatott csökkenteni az eredmény minőségének jelentős csökkenése nélkül. A javasolt módszer iteratív módon hajtja végre a teljes tanítási és tesztelési ciklust egyre kisebb jellemző halmaz használatával. Minden iteráció során eltávolítom a legkevesebbet használt és a legrosszabb döntések meghozásában részt vevő jellemzőket. Az eredeti jellemző halmazt egy nyolcadára sikerült lecsökkenteni, míg a végső szegmentálási eredményt jellemző átlagos Dice score csökkenése 0,3% alatt maradt.

A [GyA5] dolgozatban az MRI adatok spektrális felbontásának (színmélységének) hatását vizsgáltam a szegmentálás minőségére. A hisztogram egységesítés során lehetőségem volt kigenerálni kigenerálni tetszőleges bitszámú jellemzőket. Megvizsgáltam, hogy fokális elváltozást tartalmazó és nem tartalmazó MRI felvételek szegmentálási pontossága hogyan változik a 2-10 bites színmélység tartományban. A vizsgálat eredménye azt mutatja, hogy a klasszikus gépi tanulási módszerek hat bites színmélység használata esetén képesek a maximális elérhető szegmentálási pontossággal teljesíteni, a további bitek igencsak redundánsak. E megfigyelés alapján csökkenteni lehet a jellemzők tárolására használt memória területet anélkül, hogy romlana a szegmentálási pontosság. A [GyA2] dolgozat a [GyA5] korai verziója, kevesebb tesztesettel, de hasonló eredményekkel.

A [GyA3] dolgozatban egy multi-atlaszos megoldást javasoltam az MRI adatok minőségének feljavítása céljából. Egy adott tanuláshoz használandó teljes MRI térfogatokat előbb egy merev regisztrációval egymáshoz illesztettem, majd csak a normális szövettípus-hoz tartozó képpontok figyelembe vételével megállapítottam, hogy lokálisan mennyi a normál képpontok intenzitásértékeinek átlaga és

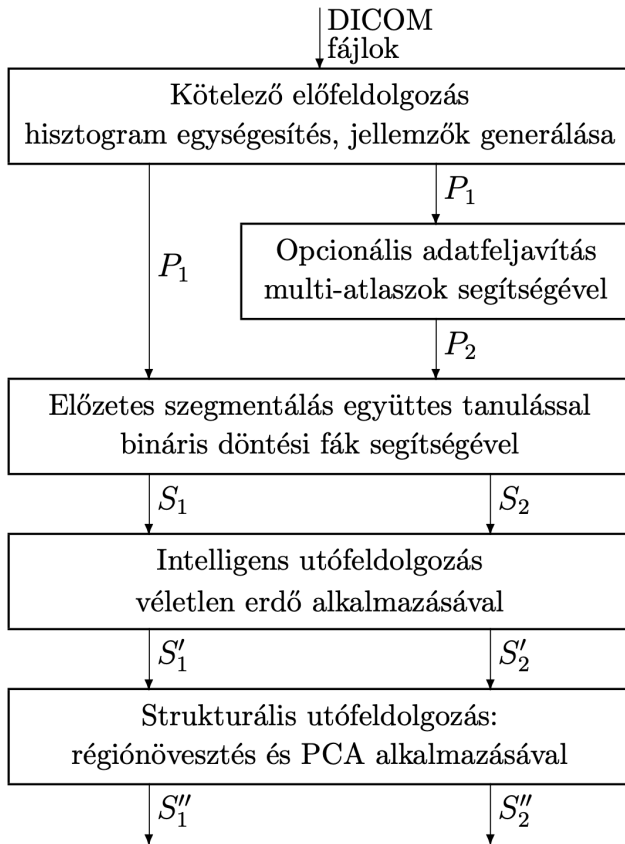
négyzetes szórása, adatcsatornánként külön-külön. Ezek után a tanulási- és tesztadatok minden képpontjának intenzitásértékét átírtam annak megfelelően, hogy a lokális szórás hányszorosával tér el a lokális átlagértéktől, és milyen irányban. Az így módosított adatokat használtam tanításra és tesztelésre. Az atlasz méretének függvényében 0,5-1% körüli javulást értem el a szegmentálás minőségét jellemző átlagos Dice score mutatóknál.

A [GyA10] és [GyA7] dolgozatokban a szegmentálást végző döntési fa együttes helyett javasoltam egyéb gépi tanulási eljárásokat. LGG és HGG tumort tartalmazó MRI felvételek esetében egyaránt a véletlen erdővel értem el a legjobb szegmentálási pontosságot.

A [GyA12] dolgozatban a morfológiai utófeldolgozás helyett javasoltam egy intelligens algoritmust, amely morfológiai jellemzők alapján újraértékeli mindegyik képpont elsődlegesen megállapított címkéjét a környezetében található címkék alapján. A javasolt algoritmus egy véletlen erdőt alkalmaz a döntéshozáshoz, melyet morfológiai jellemzők alapján tanítottam. Az eredetileg használt egyszerű morfológiai kritériummal szemben akár 1%-os javulás is elérhető a végső szegmentálás pontosságában.

A [GyA11] dolgozatban bevezettem egy strukturális utófeldolgozási műveletet. Az elsődleges szegmentálás kimenetében előbb egy térbeli régiónövesztéssel megkeresem az összefüggő, pozitívnak nevezett részeket. A nagyon kis méretű pozitív régiókat elvetem, a többieknek pedig főkomponens-analízissel megkeresem a három fő tengelyét és az azoknak megfelelő méretet. Empirikusan megállapított kritériumként a nagyon lapos (harmadik releváns dimenzió szerint kis méretű) pozitív régiókat átcímkezem negatívnak, a többieket véglegesen pozitívnak tekintem.

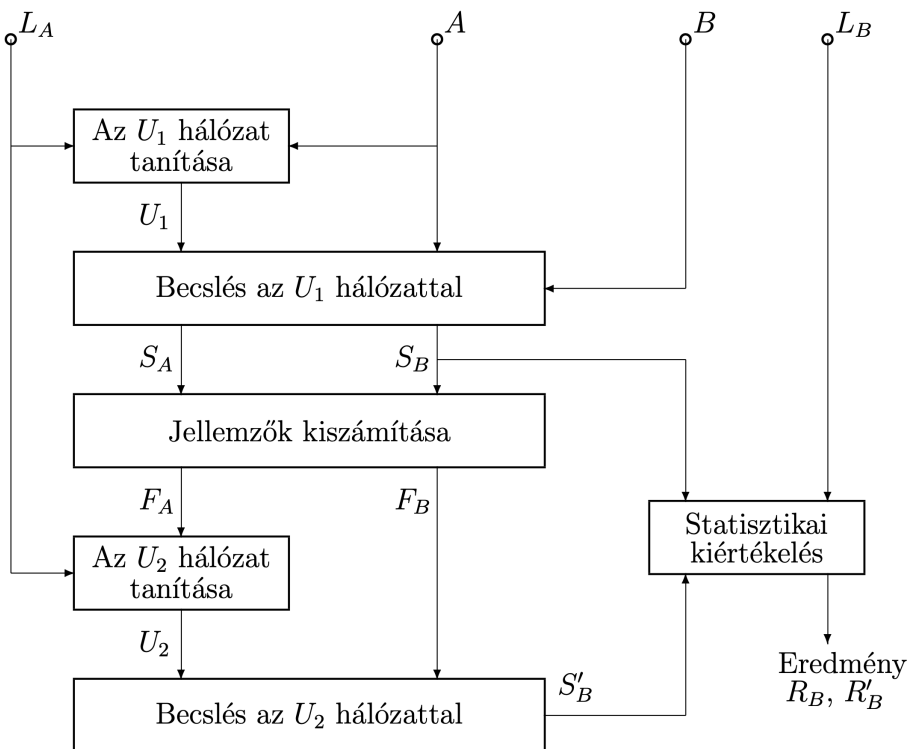
A [GyA6] dolgozat egyszerre alkalmazza az összes korábban meg-



2. ábra. A bemeneti DICOM fájlokat kétféle előfeldolgozott adattá alakítjuk (P_1 és P_2). Az együttes tanulást alkalmazó szegmentáló algoritmus kétféle eredményéből (S_1 és S_2) a kétlépéses utófeldolgozás alakítja ki a végleges eredményt (S''_1 és S''_2).

nevezett változtatást a kezdeti eljárásra, és elvégez egy részletes kiértékelés sorozatot többféle adathalmazon. A módosított eljárás folyamatábrája a [2](#) ábrán látható. A módosított eljárás szegmentálás pontosságában és hatékonyságában is versenyképes a szakirodalomban fellelhető, legjobban teljesítő módszerekkel.

Doktori tanulmányaim későbbi fázisában megvalósítottam egy U-Net architektúra segítségével működő agytumor szegmentáló eljárást [\[Ronneberger et al., 2015\]](#). A [\[GyA8\]](#) dolgozatban bevezettem egy U-Net kaszkád rendszert, amelyben két azonos típusú és méretű U-Net hálózat végzi az osztályozást és utófeldolgozást. A javasolt eljárás folyamatábrája a [3](#) ábrán található. Az első U-Net egy elsődleges szegmentálást végez térbeli adatokon, térbeli konvolúciót alkalmazva. Bemenetként megkapja egyszerre egy multi-spektrális MRI felvétel négy adatcsatornáját és a kimeneten megadja minden képpontnak a pozitív régiókhöz való tartozásának becsült valószínűségét. A kimenetből kiszámítok négy morfológiai jellemzőt a [\[GyA12\]](#) dolgozatban leírtakhoz hasonlóan, és ezeknek a térbeli eloszlását adom meg bemenetként a második U-Net hálózatnak, amely elvégzi az utófeldolgozást és a kimeneten megadja minden képpontnak a végső becsült besorolását. Az elért szegmentálási pontosság átlagosan 1%-kal felülmúlja a korábbi megoldásom eredményeit. A [\[GyA9\]](#) dolgozatban egy adaptív lokális hisztogram kiegyenlítő algoritmust (CL-HE) vettem be előfeldolgozásként az U-Net kaszkád előtt, amivel tovább javult a szegmentálási pontosság.



3. ábra. A javasolt kétlépéses szegmentáló módszer folyamatábrája: az U_1 hálózat egy előzetes szegmentálást készít, míg az U_2 hálózat megvalósítja az utófeldolgozást az előzetes szegmentálásból kinyert jellemzők alapján. A és B a tanításra, illetve tesztelésre használt adatok halmaza, míg L_A és L_B az ezekhez rendelkező alapigazságot jelképezi.

Új tudományos eredmények

I. téziscsoport – MRI adatok előfeldolgozásával kapcsolatos eredmények

1.1 tézis

Megvizsgáltam az agyi MRI adatok hisztogramjának egységesítését végző leggyakrabban alkalmazott módszereket azzal a céllal, hogy megállapítsam, melyik algoritmus és annak milyen beállításai szolgálják leginkább az MRI adatok helyes szegmentálását fokális elváltozások jelenlétében és hiányában egyaránt. Új javaslatokat fogalmaztam meg, az eredetileg Nyúl és mtsai [Nyúl et al., 2000] által publikált, legjobban teljesítő algoritmus használatával kapcsolatosan, melynek segítségével 0,5-3,0% javulást lehet elérni a szegmentálást jellemző Dice score értékekben, a korábban publikált felhasználási módozatokhoz viszonyítva.

A téziszhez kapcsolódó saját publikáció: [GyA4].

1.2 tézis

Bevezettem egy jellemző generálási és kiválasztási algoritmust az agydaganatok hatékony szegmentálásának támogatására multispektrális MRI felvételekből. Az algoritmus célja egy optimális méretű jellemzővektor létrehozása, amely lehetővé teszi a klasszikus gépi tanuláson alapuló módszerek számára a kiváló minőségű szegmentálás elérését. A javasolt módszer jelentősen csökkenti a szükséges jellemzők számát, és ennek következtében a tanítás és tesztelés számítási terhét anélkül, hogy a szegmentálás minősége romlana.

A tézishoz kapcsolódó saját publikáció: [\[GyA1\]](#).

1.3 tézis

A hisztogram egységesítési tanulmány folyamatoként megvizsgáltam az előfeldolgozott adatok tárolásakor használt spektrális felbontás hatását az elérhető szegmentálási minőségre. A fokális elváltozásokat tartalmazó és nem tartalmazó MRI adatokon végzett értékelés azt mutatta, hogy a 6 bites spektrális felbontás elegendő a klasszikus gépi tanuláson alapuló osztályozók számára az általuk elérhető legjobb szegmentációs minőség eléréséhez. Ezzel jelentősen csökkenthetjük az adatfeldolgozáshoz szükséges tárhelyet, figyelembe véve, hogy az MRI készülékek 16 bites felbontású adatokat állítanak elő.

A tézishoz kapcsolódó saját publikációk: [\[GyA2\]](#), [\[GyA5\]](#).

1.4 tézis

Javasoltam egy atlaszok alapján működő adatminőség javítási technikát, amely a tanítási adathalmazból származó, egészséges szövetekhez tartozó képpontok statisztikai elemzésére támaszkodik. Minden atlasz egy térbeli térképe egy adott jellemző helyi átlagértékeinek és szórásainak. Mind a tanítási, mind a tesztadatok intenzitás értékeit átalakítjuk az atlasz segítségével mielőtt az osztályozásra kerülne sor, annak függvényében, hogy hány szórásnyival térnek el az átlagértéktől és milyen irányban. A javasolt módszer a HGG és LGG adatok esetében is 1% körüli javulást eredményezett az átlagos Dice Score értékekben.

A tézishez kapcsolódó saját publikációk: [GyA3](#), [GyA6](#).

II. téziscsoport – Képpontok osztályozásával kapcsolatos eredmények

2. tézis

Alapos elemzésnek vetettem alá számos klasszikus gépi tanuláson, illetve mély tanuláson alapuló osztályozó eljárást, hogy meghatározzam a teljesítményüket az agytumor szegmentálási feladat és a felhasznált adathalmaz esetében. Az eredmények azt mutatták, hogy a mély tanulási módszerek pontosabban működnek, és a kijelölt feladat és adathalmaz kontextusában kiváló teljesítményt nyújtanak.

A tézishez kapcsolódó saját publikációk: [GyA7](#), [GyA8](#), [GyA9](#), [GyA10](#).

III. téziscsoport – A szegmentálás kimenetének utófeldolgozásával kapcsolatos eredmények

3.1 tézis

Kétlépcsős utófeldolgozást javasoltam a klasszikus gépi tanuláson alapuló szegmentálási módszerekhez. Az első lépést egy véletlen erdő valósítja meg, amely a kezdeti döntésből ki nyert morfológiai jellemzők alapján módosítja a képpontok besorolását. A második szakasz a térbeli régiönövesztésre és főkomponens-analízisre támaszkodva megállapítja az összefüggő elváltozások méretét és alakját, és az azonosított struktúrák alapján végleges döntést hoz. A javasolt módszer 0,5-1,0%-kal, illetve 0,5-0,8%-kal javította a HGG és LGG adatok végső szegmentálási eredményét a korábban használt morfológiai kritériumhoz képest.

A tézishoz kapcsolódó saját publikációk: [\[GyA11\]](#), [\[GyA12\]](#).

3.2 tézis

Újszerű megközelítést dolgoztam ki az U-Net neurális hálózattal szegmentált agyi tumorok utófeldolgozására egy második, azonos architektúrájú U-Net segítségével. Ez a módszer növeli az általános szegmentálási pontosságot, és finomítja a kezdeti szegmentálási folyamatból kapott eredményeket.

A tézishoz kapcsolódó saját publikációk: [\[GyA8\]](#), [\[GyA9\]](#).

Az eredmények hasznosítási lehetősége

A kutatás eredményei számos területen kínálnak hasznosítási lehetőséget az orvosi gyakorlat és a tudományos kutatás számára. A kifejlesztett szegmentáló módszerek hozzájárulhatnak az agytumороk gyorsabb és pontosabb diagnosztizálásához, csökkentve az orvosok terhelését és javítva a betegek ellátásának minőségét. Az automatikus szegmentálás segítségével nyomon követhető a tumor méretének és alakjának változása a kezelés során, ami fontos információt nyújt a terápia hatékonyságáról. Emellett a kutatás során kifejlesztett új módszerek és algoritmusok alkalmazhatók más orvosi képalkotó adatok feldolgozásában is, hozzájárulva a gépi tanulás és a mély tanulás módszereinek további fejlődéséhez, ezáltal támogatva a kutatási és fejlesztési tevékenységeket. Továbbá, a kifejlesztett eljárások és az elért eredmények felhasználhatók az orvosi képalkotás és a gépi tanulás területén folyó oktatásban is, segítve a hallgatók gyakorlati tudásának bővítését és a korszerű technológiák elsajátítását.

Hivatkozások

- [Akers, 1978] Akers, S. B. (1978). Binary decision diagrams. *IEEE Trans. Computers*, C-27(6):509–516.
- [Bakas et al., 2017] Bakas, S., Akbari, H., Sotiras, A., and et al. (2017). Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features. *Scientific Data*, 4:170117.
- [Cabezas et al., 2011] Cabezas, M., Oliver, A., Lladó, X., Freixenet, J., and Bach Cuadra, M. (2011). A review of atlas-based segmentation for magnetic resonance brain images. *Computer Methods and Programs in Biomedicine*, 104(3):e158–e177.
- [Fernando and Tsokos, 2023] Fernando, K. R. M. and Tsokos, C. P. (2023). Deep and statistical learning in biomedical imaging: State of the art in 3D MRI brain tumor segmentation. *Information Fusion*, 92:450–465.
- [Gordillo et al., 2013] Gordillo, N., Montseny, E., and Sobrevilla, P. (2013). State of the art survey on MRI brain tumor segmentation. *Magn. Reson. Imaging*, 31:1426–1438.
- [Kapás et al., 2018] Kapás, Z., Lefkovits, L., Iclănzan, D., Györfi, Á., Iantovics, B. L., Lefkovits, S., Szilágyi, S. M., and Szilágyi, L. (2018). Automatic Brain Tumor Segmentation in Multispectral MRI Volumes Using a Random Forest Approach. In *Image and Video Technology*, pages 137–149. Springer International Publishing.

- [Kapás et al., 2016] Kapás, Z., Lefkovits, L., and Szilágyi, L. (2016). Automatic Detection and Segmentation of Brain Tumor Using Random Forest Approach. In *Modeling Decisions for Artificial Intelligence*, pages 301–312. Springer International Publishing.
- [Menze et al., 2015] Menze, B. H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., and et al. (2015). The multimodal brain tumor image segmentation benchmark (BRATS). *IEEE Trans. Med. Imag.*, 34:1993–2024.
- [Nyúl et al., 2000] Nyúl, L. G., Udupa, J. K., and Zhang, X. (2000). New variants of a method of MRI scale standardization. *IEEE Trans. Med. Imag.*, 19:143–150.
- [Patel et al., 2019] Patel, A. P., Fisher, J. L., Nichols, E., Abd-Allah, F., Abdella, J., Abdelalim, A., and et al. (2019). Global, regional, and national burden of brain and other CNS cancer, 1990-2016: a systematic analysis for the Global Burden of Disease Study 2016. *Lancet Neurol.*, 18:376–393.
- [Pereira et al., 2016] Pereira, S., Pinto, A., Alves, V., and Silva, C. A. (2016). Deep Convolutional Neural Networks for the Segmentation of Gliomas in Multi-sequence MRI. In *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, pages 131–143.
- [Ronneberger et al., 2015] Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, pages 234–241. Springer International Publishing.

- [Szilágyi et al., 2018] Szilágyi, L., Iclănzan, D., Kapás, Z., Szabó, Z., Györfi, Á., and Lefkovits, L. (2018). Low and high grade glioma segmentation in multispectral brain MRI data. *Acta Universitatis Sapientiae – Informatica*, 10(1):110–132.
- [Szilágyi et al., 2015a] Szilágyi, L., Lefkovits, L., and Benyó, B. (2015a). Automatic brain tumor segmentation in multispectral MRI volumes using a fuzzy c -means cascade algorithm. In *12th International Conference on Fuzzy Systems and Knowledge Discovery*, pages 285–291.
- [Szilágyi et al., 2015b] Szilágyi, L., Lefkovits, L., Iantovics, B., Iclănzan, D., and Benyó, B. (2015b). Automatic Brain Tumor Segmentation in Multispectral MRI Volumetric Records. In *Neural Information Processing*, pages 174–181. Springer International Publishing.
- [Yang et al., 2019] Yang, Y. Y., Jia, W. J., and Yang, Y. N. (2019). Multi-atlas segmentation and correction model with level set formulation for 3D brain MR images. *Pattern Recognition*, 90:450–463.
- [Yu et al., 2021] Yu, H., Yang, L. T., Zhang, Q., Armstrong, D., and Jamal Deen, M. (2021). Convolutional neural networks for medical image analysis: State-of-the-art, comparisons, improvement and perspectives. *Neurocomputing*, 444:92–110.

A tézispontokhoz kapcsolódó tudományos közlemények

- [GyA1] Á. Györfi, L. Kovács, and L. Szilágyi. A Feature Ranking and Selection Algorithm for Brain Tumor Segmentation in Multi-Spectral Magnetic Resonance Image Data. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 804–807, 2019. [doi:10.1109/EMBC.2019.8857794](https://doi.org/10.1109/EMBC.2019.8857794).
- [GyA2] Á. Györfi, T. Fülöp, L. Kovács, and L. Szilágyi. The Effect of Spectral Resolution Upon the Accuracy of Brain Tumor Segmentation from Multi-Spectral MRI Data. In *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, pages 325–328, 2020. [doi:10.1109/SAMI48414.2020.9108770](https://doi.org/10.1109/SAMI48414.2020.9108770).
- [GyA3] T. Fülöp, Á. Györfi, B. Surányi, L. Kovács, and L. Szilágyi. Brain tumor segmentation from MRI data using ensemble learning and multi-atlas. In *18th IEEE World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, pages 111–116, 2020. [doi:10.1109/SAMI48414.2020.9108752](https://doi.org/10.1109/SAMI48414.2020.9108752).
- [GyA4] A. Köble, Á. Györfi, S. Csaholczi, B. Surányi, L. Dénes-Fazakas, L. Kovács, and L. Szilágyi. Identifying the most suitable histogram normalization technique for machine learning based segmentation of multispectral brain MRI data. In *Proc. IEEE AFRICON*, pages 71–76, 2021. [doi:10.1109/AFRICON51333.2021.9570990](https://doi.org/10.1109/AFRICON51333.2021.9570990).

- [GyA5] Á. Györfi, Sz. Csaholczi, I. M. Pisak-Lukáts, L. Dénes-Fazakas, A. Köble, O. Shvets, Gy. Eigner, L. Kovács, and L. Szilágyi. Effect of spectral resolution on the segmentation quality of magnetic resonance imaging data. In *2022 IEEE 26th International Conference on Intelligent Engineering Systems (INES)*, pages 53–58, 2022. [doi:10.1109/INES56734.2022.9922634](https://doi.org/10.1109/INES56734.2022.9922634).
- [GyA6] Á. Györfi, L. Szilágyi, and L. Kovács. A Fully Automatic Procedure for Brain Tumor Segmentation from Multi-Spectral MRI Records Using Ensemble Learning and Atlas-Based Data Enhancement. *Applied Sciences*, 11(2):564, 2021. [doi:10.3390/app11020564](https://doi.org/10.3390/app11020564).
- [GyA7] Á. Györfi, L. Kovács, and L. Szilágyi. Brain Tumor Detection and Segmentation from Magnetic Resonance Image Data Using Ensemble Learning Methods. In *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, pages 909–914, 2019. [doi:10.1109/SMC.2019.8914463](https://doi.org/10.1109/SMC.2019.8914463).
- [GyA8] Á. Györfi, L. Kovács, and L. Szilágyi. A two-stage U-net approach to brain tumor segmentation from multi-spectral MRI records. *Acta Universitatis Sapientiae – Informatica*, 14(2):223–247, 2022. [doi:10.2478/ausi-2022-0014](https://doi.org/10.2478/ausi-2022-0014).
- [GyA9] Á. Györfi, L. Kovács, and L. Szilágyi. Brain Tumor Segmentation from Multi-Spectral MRI Records Using a U-net Cascade Architecture. In *2023 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, volume paper no. 623, pages 1317–1322, 2023. [doi:10.1109/SMC53992.2023.10394168](https://doi.org/10.1109/SMC53992.2023.10394168).

- [GyA10] Á. Györfi, L. Kovács, and L. Szilágyi. Brain Tumour Segmentation from Multispectral MR Image Data Using Ensemble Learning Methods. In I. Nyström, Y. Hernández Heredia, and V. Milián Núñez, editors, *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications (CIARP)*, pages 326–335. Springer International Publishing, 2019. [doi:10.1007/978-3-030-33904-3_30](https://doi.org/10.1007/978-3-030-33904-3_30).
- [GyA11] Á. Györfi, Sz. Csaholczi, T. Fülöp, L. Kovács, and L. Szilágyi. Brain Tumor Segmentation from Multi-Spectral Magnetic Resonance Image Data Using an Ensemble Learning Approach. In *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 1699–1704, 2020. [doi:10.1109/SMC42975.2020.9282987](https://doi.org/10.1109/SMC42975.2020.9282987).
- [GyA12] T. Fülöp, Á. Györfi, Sz. Csaholczi, L. Kovács, and L. Szilágyi. Brain Tumor Segmentation from Multi-Spectral MRI Data Using Cascaded Ensemble Learning. In *2020 IEEE 15th International Conference of System of Systems Engineering (SoSE)*, pages 531–536, 2020. [doi:10.1109/SoSE50414.2020.9130550](https://doi.org/10.1109/SoSE50414.2020.9130550).

További tudományos közlemények

- [N1] Z. Kapás, L. Lefkovits, D. Iclănzan, Á. Györfi, B. L. Iantovics, Sz. Lefkovits, S. M. Szilágyi, and L. Szilágyi. Automatic brain tumor segmentation in multispectral mri volumes using a random forest approach. In P. Manoranjan, C. Hitoshi, and Q.M. Huang, editors, *Image and Video Technology*, pages 137–149. Springer International Publishing, 2018. [doi:10.1007/978-3-319-75786-5_12](https://doi.org/10.1007/978-3-319-75786-5_12).
- [N2] Zs. Szabó, Z. Kapás, L. Lefkovits, Á. Györfi, S. M. Szilágyi, and L. Szilágyi. Automatic segmentation of low-grade brain tumor using a random forest classifier and gabor features. In *14th International Conference on Neural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, pages 1106–1113. IEEE, 2018.
- [N3] L. Szilágyi, D. Iclănzan, Z. Kapás, Zs. Szabó, Á. Györfi, and L. Lefkovits. Low and high grade glioma segmentation in multispectral brain MRI data. *Acta Universitatis Sapientiae – Informatica*, 10(1):110–132, 2018. [doi:10.2478/ausi-2018-0007](https://doi.org/10.2478/ausi-2018-0007).
- [N4] Á. Györfi, Z. Karetka-Mezei, D. Iclănzan, L. Kovács, and L. Szilágyi. A Study on Histogram Normalization for Brain Tumour Segmentation from Multispectral MR Image Data. In I. Nyström, Y. Hernández Heredia, and V. Milián Núñez, editors, *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications (CIARP)*, pages 375–384, 2019. [doi:10.1007/978-3-030-33904-3_35](https://doi.org/10.1007/978-3-030-33904-3_35).