



## قطعه بندی تصاویر MRI با هدف تشخیص تومور مغزی

فاطمه السادات آبادیان زاده  
دانشکده مهندسی کامپیوتر  
دانشگاه علم و صنعت ایران  
f\_abadianzadeh@comp.iust.ac.ir

### چکیده

تشخیص زود هنگام و دقیق تومور مغزی، شانس زنده بودن افراد مبتلا به این عارضه را افزایش می دهد. توجه به ساخت و بهبود سیستم های CAD برای تشخیص این عارضه می تواند کمک شایانی به متخصصان این حوزه در این امر باشد. در این پروژه با استفاده از توانایی شبکه های عمیق در یادگیری و حل مسائل، به بررسی روش های بخش بندی تومور در تصاویر MRI مغز پرداختیم. معماری مورد استفاده در این پروژه معماری U-Net که از یک ساختار Encoder و Decoder تشکیل شده است، می باشد. تلاش شده است تا بررسی جامعی از نحوه تاثیر پارامترهای مختلف در آموزش بر میزان دقت شبکه در نسخه دو بعدی آن صورت گیرد. شش آزمایش مختلف با پارامترهای مختلف بر روی شبکه صورت گرفته و نتایج آنها با یکدیگر مقایسه شده است.

### ۱ مقدمه

سرطان به عنوان رشد غیرقابل کنترل و غیر طبیعی بدن سلولهای تعریف می شود. ظهور یک توده، رشد و تقسیم سلولی غیر طبیعی در بافت مغزی تومور مغزی است. در حالی که تومورهای مغزی بسیار رایج نیستند، آنها یکی از سرطان های کشنده بشمار ما آیند. گلیوما نوعی از تومورهای مغزی هستند که از سلولهای گلیال تشکیل شده اند. آنها رایجترین نوع تومورهای مغزی هستند که تحقیقات قطعه بندی تومور مغز در حال حاضر روی آن تمرکز دارد. تشخیص زودهنگام تومورهای مغزی نقش بسزایی در بالا بردن احتمال درمان و زنده ماندن بیماران دارد. تصاویر MRI اطلاعات ارزشمندی درباره شکل، اندازه، مکان و متابولیسم تومورهای مغز در اختیار قرار می دهد و به تشخیص آنها کمک می کنند. MRI یک تکنیک تصویرسازی در شرایط آزمایشگاهی است که از سیگنال های رادیویی برای تحریک بافت های هدف، به منظور تولید تصاویر داخلی تحت نفوذ یک میدان مغناطیسی بسیار قدرتمند استفاده می کند. تصاویر دنباله های مختلف MRI از طریق تغییر تحریک و زمان های تکرار در طول فرآیند تصویربرداری ایجاد می شوند. این شیوه های مختلف تصویربرداری MRI انواع مختلفی از تصاویر کنتراست بافت را تولید می کنند. در نتیجه اطلاعات با ارزش برای تشخیص و قطعه بندی تومور فراهم می کنند.

قبل از اعمال هرگونه درمان، جداسازی تومور به منظور حفظ سلامتی سایر بافتها ضروری است. تقسیم بندی تومور مغزی شامل تشخیص و جدا سازی بافت های توموری از سایر بافت ها است. در روال معمول بالینی، این فرآیند به صورت دستی انجام می پذیرد. از آنجا که تقسیم بندی دستی یک روش بسیار وقت گیر است، توسعه روش های تقسیم بندی خودکار، برای ارائه تقسیم بندی کارآمد، در سال های اخیر به یک موضوع تحقیقاتی مورد توجه تبدیل شده است. عملکرد خوب روش های یادگیری عمیق در قطعه بندی تصاویر، آنها را به عنوان راهکاری مناسب برای دستیابی به این هدف مطرح کرده است.

چالش BraTS به صورت سالانه از سال ۲۰۱۲ برگزار شده است و همواره بر روی ارزیابی روش های جدید و پیشرفته برای تعیین ناحیه تومورهای مغزی در اسکن تصاویر MRI متمرکز شده است. در این پژوهش برای ارزیابی سیستم، داده ها از چالش طبقه بندی تومور مغز BraTS ۲۰۱۵ و BraTS ۲۰۱۸ انتخاب شده اند. در مجموعه دادگان سال ۲۰۱۵ مجموعه آموزش شامل ۲۲۰ مورد تومور با درجه پیشرفت بالا (HGG) و ۵۴ مورد با درجه کم (LGG) است. مجموعه دادگان ۲۰۱۸ شامل ۲۱۰

تصویر HGG و ۷۵ تصویر LGG است. این تصاویر در ابعاد  $240 \times 240 \times 155$  ارائه شده اند و متناسب با هر تصویر و با همان ابعاد تصویر ناحیه بندی شده<sup>۱</sup> مربوط به ناحیه تومور نیز در اختیار قرار گرفته شده است.

در سالهای اخیر استفاده از شبکه های عمیق در زمینه کارهای مرتبط با پردازش تصویر منجر به پیشرفت قابل توجهی در نتایج به دست آمده شده است. شبکه u-net [۱] نوعی معماری برای قطعه بندی سریع و دقیق تصاویر و به طور خاص تصاویر حوزه پزشکی است. این شبکه بر اساس شبکه های convolutional fully طراحی شده اند و هدف از طراحی آن ها به وجود آورد بهبود در ساختار شبکه های connected fully به منظور کاهش میزان تصاویر لازم برای فرآیند آموزش است. نسخه های مختلفی از u-net با توجه به ساختار ورودی شبکه وجود دارد. از جمله از این نسخه ها می توان به U-Net ۲D و U-Net ۳D اشاره کرد که تصویر ورودی این شبکه ها به ترتیب دو بعدی و سه بعدی هستند.

## ۲ کارهای مرتبط / پیش زمینه

در [۲] از شبکه ای بر پایه U-Net نسخه دو بعدی استفاده شده است. در این پژوهش از داده های چالش BraTS۲۰۱۵ استفاده شده است. همچنین از تکنیکهای افزایش داده<sup>۲</sup> و معیار Dice برای Loss استفاده شده است و دقت ۸۶٪ برای تشخیص ناحیه کل تومور گزارش شده است. پژوهش [۳] نسخه U-Net ۳D با ابعاد ورودی  $128 \times 128 \times 128$  استفاده شده است. علاوه بر آن از Dropout = ۰,۲ استفاده شده است. برای activation از LeakyRelu استفاده شده و در هر لایه conv از regularization 1۲ با نرخ یادگیری  $10^{-5}$  در نظر گرفته شده است. استفاده از این معماری در پژوهش مذکور برای مجموعه دداگان BraTS۲۰۱۵ دقت ۸۵٪ برای ناحیه تومور کامل را نتیجه داده است. پژوهش [۴] از U-Net نسخه سه بعدی با BatchNormalization و از LeakyRelu به عنوان activation با نرخ  $10^{-2}$  در نظر گرفته شده است. همچنین از تابع Loss ترکیبی که حاصل جمع ساده Dice و Entropy Cross است. سپس پس پردازشی روی خروجی شبکه انجام داده شده است. در نهایت دقت ۹۱٪ برای تشخیصی ناحیه کل تومور گزارش شده است.

در پژوهش [۵] باز هم از نسخه سه بعدی شبکه U-Net استفاده شده است. تفاوت این پژوهش با پژوهش های پیشین در این است که ورودی این شبکه ابعاد بزرگتری نسبت به شبکه های پیشین دارد ( $160 \times 192 \times 128$ ). خروجی این شبکه به دو شاخه تقسیم می شود که یکی شامل هر سه ناحیه تومور است. از شاخه دوم در حین فرآیند آموزش به عنوان regularizer استفاده شده است. همچنین از ترکیب Entropy Cross Dice و KL-Divergence به صورت وزن دار برای محاسبه میزان Loss استفاده شده است. شبکه پیشنهادی برای regularization از نرم L۲ استفاده کرده است. دقت گزارش شده برای این شبکه ۹۰٪ است.

## ۳ مدل پیشنهاد شده

به دلیل محدودیت سخت افزاری و زمان، مدل پیشنهادی برای این پروژه بر پایه مدل U-Net ۲D است. ورودی شبکه تصاویر  $128 \times 128$  از برش های تصاویر MRI است و خروجی آن تصویر  $128 \times 128$  سیاه سفید، که مشخص کننده ناحیه تومور در تصویر ورودی است. شکل ۳ نخستین معماری استفاده شده را نمایش می دهد. همانطور که در شکل قابل مشاهده است، این معماری از دو مسیر Encoder و Decoder تشکیل شده است. در مسیر Encoder هر مرحله از دو لایه Conv تشکیل شده است. سپس خروجی این دولایه به ابعاد کوچکتری مقیاس شده و به مرحله بعد داده خواهد شد. در مسیر برگشت و Decoder نیز هر مرحله از دو لایه Conv تشکیل شده است. تفاوت در مقیاس کردن است. در مسیر برگشت تصاویر ورودی هر مرحله ابتدا به مقیاس بالاتر رفته و سپس به لایه Conv داده خواهد شد. هر کدام از مسیرهای رفت و برگشت شامل ۴ مرحله هستند. در معماری پیشنهادی در این بخش بعد از هر لایه Conv از BatchNormalization و Dropout استفاده شده است. Activation مورد استفاده در این شبکه Relu است و از Coefficient Dice برای محاسبه Loss شبکه استفاده شده است.


ساختار دیگری که از مدل U-Net در این پروژه استفاده شده است در شکل ۳ نمایش داده شده است. کلیات این معماری مانند معماری شکل ۳ است. با این تفاوت که در این پیکربندی از LeakyRelu برای Activation استفاده شده است. همچنین در هر لایه Conv از Regularization L۲ استفاده شده است و دیگر از BatchNormalization در این ساختار استفاده نشده است.

### ۱.۳ پیش پردازش


همانطور که گفته شد تصاویر داده شده به صورت تصاویر سه بعدی در اختیار قرار گرفته شده اند. به دلیل اینکه ما از نسخه دو بعدی شبکه استفاده خواهیم کرد ابتدا باید داده ها را به صورتی تبدیل کنیم که مناسب با ساختار ورودی شبکه باشد. بدین منظور ما هر تصویر سه بعدی با ۱۵۵ برش را به صورت ۱۵۵ تصویر دو بعدی مجزا در نظر می گیریم. از آنجا که همه ۱۵۵ برش شامل اطلاعات تصویر با معنی نیستند، تنها برش های ۶۰ تا ۱۳۰ مورد استفاده قرار گرفته اند. در مجموع با عملیات دو

<sup>۱</sup>Segmentation

<sup>۲</sup>Augmentation

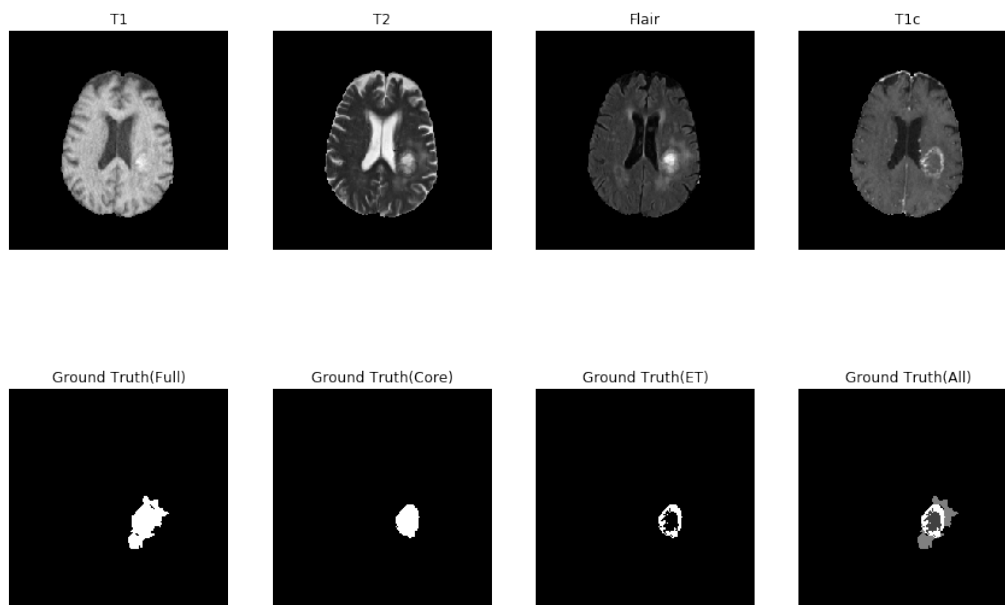


شکل ۱: شبکه پیشنهادی - معماری اول



شکل ۲: شبکه پیشنهادی - معماری دوم

بعدي ساي ۲۸۵\*۷۰ تصوير در اختيار داريم. اين تصاوير داراي ابعاد ۲۴۰\*۲۴۰ هستند كه آنها را به ۱۲۸\*۱۲۸ تغيير اندازه مي دهيم. شكل ۱.۳ تصوير يك برش از اين تصاوير را نشان مي دهد.



شكل ۳: يك برش از تصوير MRI و تصوير سگمنت شده كه بخش هاي مختلف تومور را نشان مي دهد.

پيش پردازش ديگري كه بر روي داده هاي انجام شده است نرمال سازي داده ها است. با توجه به مطالعات صورت گرفته به دو صورت اين كار صورت گرفته است. يكي نرمال سازي هر يك از برش هاي تصوير نسبت به ميانگين و انحراف معيار كل تصوير و ديگري نرمال سازي نسبت به ميانگين و انحراف معيار ناحيه مربوط به تصوير مغز در هر برش است. در واقع پيكسل هايي كه شامل تصوير مغز نيستند و مقدار آن ها صفر است صفر باقي مي مانند و در نرمال سازي تاثيري ندارند.

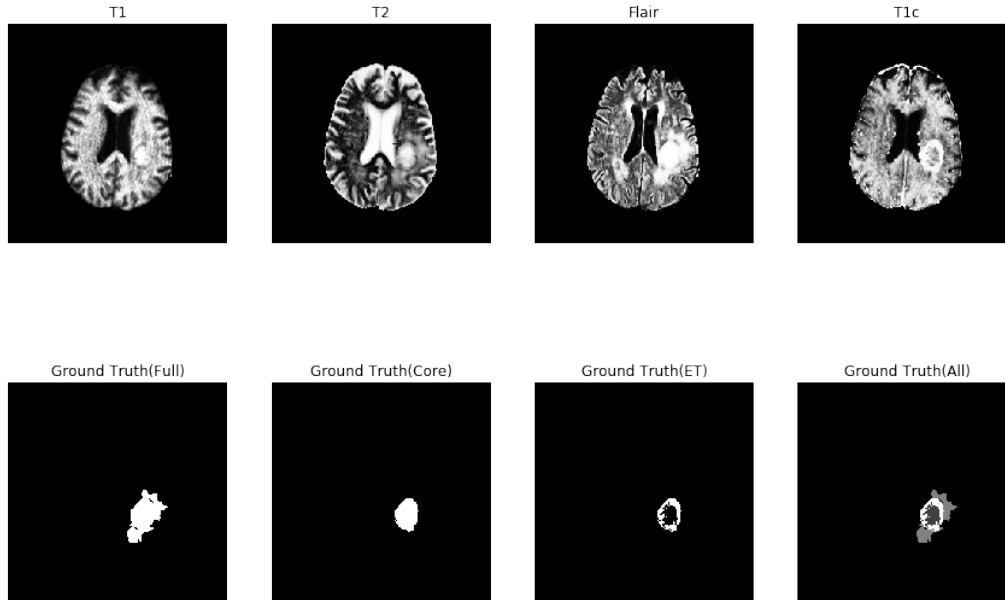
همانطور كه در شكل ۱.۳ قابل مشاهده است به دليل تفاوت كم رنگ ها در تصاوير مغزي پيش پردازش ديگري كه روي داده ها انجام شده است متعادل سازي هيستوگرام<sup>۳</sup> است. اين عمل منجر به تصوير با كيفيت بيشتري شده كه تفاوت بخش تومور با ساير بخش ها در اين تصاوير بيشتري قابل تشخيص است. از طرف ديگر تعداد داده هاي در اختيار براي آموزش شبكه كافي نيست. لذا بايد عمليات افزايش داده ها برروي داده هاي در اختيار صورت گيرد. به دو روش متفاوت در اين پروژه اقدام به افزايش داده هاي آموزش كرده ايم. در روش اول با استفاده از تغيير شكل هايي مانند چرخش، زوم، معكوس كردن افقي و عمودي و جابجايي اقدام به دو برابر كردن داده ها كرديم. همچنين از روش هاي پيشرفته تر ديگري نيز براي افزايش داده هاي آموزش استفاده شده است. در پژوهش [؟] از تغيير شكل الاستيك<sup>۴</sup> استفاده شده است. دليل اين كار به وجود آوردن تصاويري با شكل تومور متفاوت است. در شكل ۱.۳ نتيجه اعمال اين تغيير شكل نمايش داده شده است.

#### ۴ نتايج

شش آزمايش مجزا با استفاده از معماری ها ذکر شده در بخش قبل صورت گرفته است که در ادامه هر آزمايش، نتایج آن و جزئیات در نظر گرفته شده برای آن ذکر شده است.

<sup>۳</sup>Histogram Equalization

<sup>۴</sup>Elastic Deformation



شکل ۴: تصویر یک برش بعد از متعادل سازی هیستوگرام

#### ۱.۴ آزمایش اول

در این آزمایش از پیکربندی شکل ۳ استفاده شده است. در اینجا dropout در نظر گرفته نشده است. برای پیش پردازش از نرمال سازی ساده بر روی تمام تصویر استفاده شده است و متعادل سازی هیستوگرام اعمال نشده است. علاوه بر آن برای افزایش داده های آموزش فقط از روش های معمول استفاده شده و از تغییر شکل الاستیک استفاده نشده است. همچنین برای loss از شاخص Dice استفاده شده است. برای آموزش این شبکه از مجموعه دادگان BraTS۲۰۱۵ استفاده شده است. نحوه محاسبه معیار Dice بدین صورت است.

$$DSC = \frac{2TP}{(FP + 2TP + FN)} \quad (1)$$

در رابطه فوق TP=True Positive، FN=False Negative و FP=False Positive است.

#### ۲.۴ آزمایش دوم

در این آزمایش از پیکربندی شکل ۳ استفاده شده است. تفاوت این آزمایش با آزمایش اول استفاده از Dropout = ۰,۱ است. در شکل ۲.۴ فرآیند آموزش نشان داده شده است. برای آموزش این شبکه از مجموعه دادگان BraTS۲۰۱۸ استفاده شده است.


#### ۳.۴ آزمایش سوم

تغییرات این آزمایش نسبت به دو آزمایش قبل عبارت اند از استفاده از Dropout = ۰,۲ و نرمال سازی تصاویر فقط بر روی قسمت شامل تصویر مغز است. نتیج این آزمایش در ادامه آورده شده است.


#### ۴.۴ آزمایش چهارم

در این آزمایش از Dropout = ۰,۱ استفاده شده است. برای پیش پردازش داده ها علاوه بر موارد روش قبل از متعادل سازی هیستوگرام نیز استفاده شده است. همچنین برای افزایش داده های آموزش از تغییر شکل الاستیک در کنار موارد آزمایش قبل استفاده شده است.

Flair




T1c



Ground Truth(Full)




Ground Truth(Full)




شکل ۵: تصویر معکوس شده افقی


Flair



T1c





Ground Truth(Full)



Ground Truth(Full)




شکل ۶: نتیجه اعمال تغییر شکل الاستیک بر روی تصویر





شکل ۷: فرآیند آموزش آزمایش اول







شکل ۸: فرآیند آموزش آزمایش دوم



شکل ۹: فرآیند آموزش آزمایش سوم



شکل ۱۰: فرآیند آموزش آزمایش چهارم

#### ۵.۴ آزمایش پنجم

در این آزمایش از ترکیبی استفاده شده است. برای محاسبه Loss علاوه بر Dice، از معیارهای Entropy Cross و KL-Divergence استفاده شده است. مجموع این سه معیار به عنوان Loss در نظر گرفته شده است. نتایج به دست آمده از این تغییر بسیار ضعیف بود و قابل گزارش نیست. روابط ۲، ۳ نحوه محاسبه Entropy Cross و KL-Divergence را نشان می دهد.

$$(y \log(p) + (1 - y) \log(1p)) \quad (۲)$$

$$L_{KL} = \frac{1}{N} \sum \mu^2 + \sigma^2 + -\log \sigma^2 + 1 \quad (۳)$$

#### ۶.۴ آزمایش ششم

در این آزمایش از معماری که در شکل ۳ استفاده شده است. برای پیش پردازش از متعادل سازی هیستوگرام استفاده نشده است. همچنین از ترکیب Dice و Entropy Cross برای محاسبه Loss استفاده شده است.

### ۵ تحلیل


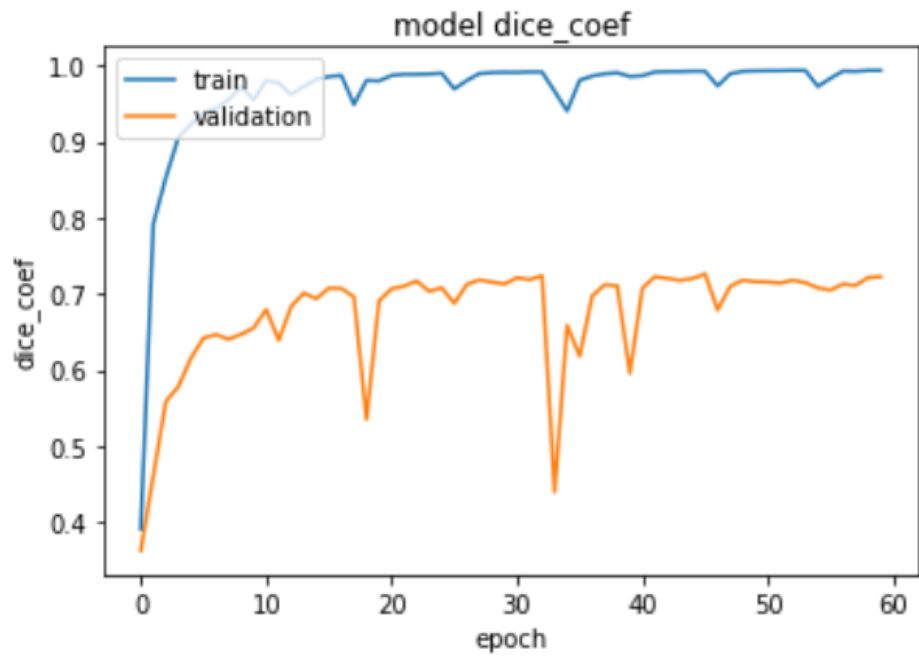
جدول ۵ مقایسه ای از بهترین دقت به دست آمده در روش های استفاده شده در آزمایشات مختلف را نشان می دهد. عبارات مخفف شده در جدول به شرح زیر است :

- BatchNormalization = BN
- Augmentation Simple = SA
- Coefficient Dice = DC
- Deformation Elastic = ED
- Dropout = D
- Entropy Cross = CE
- KL-Divergence = KL
- Relu Leaky = LRelu
- Equalization Histogram = HE

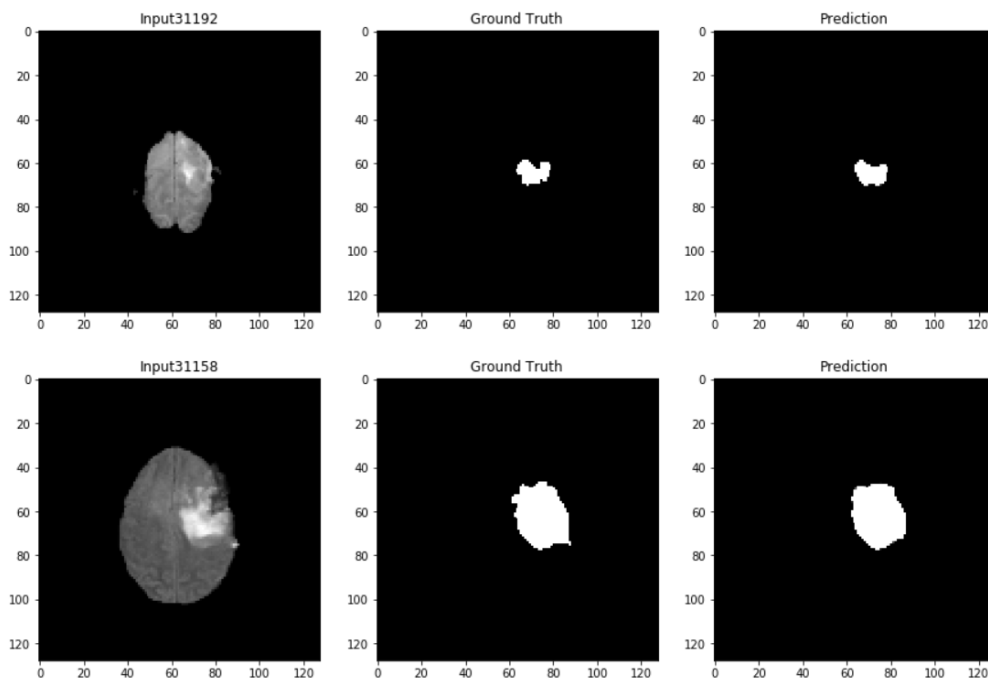
جدول ۱: مقایسه روش ها

Dice دقت	روش
۰,۷۷	Normalization 1 <sup>st</sup> + DC + SA + Relu + BN
۰,۸۱	Normalization 1 <sup>st</sup> + DC + SA-ED + Relu + BN
۰,۶۹	Normalization 2 <sup>st</sup> + DC + SA-ED + D + Relu + BN
۰,۸۲	Normalization 2 <sup>st</sup> + DC + SA + D + Relu + BN
۰,۴۵	HE + Normalization 2 <sup>st</sup> + DC-CE-KL + SA + D + Relu + BN
۰,۷۰	Normalization 2 <sup>st</sup> + DC-CE + SA + D + LRelu + L۲

شکل ۵ نمونه یک قطعه قطعه بندی تصویر مغز را نشان می دهد. به نظر میرسد که شبکه آموزش داده شده توانایی یادگیری مرزهای یا تغییرات ناگهانی و جزئیات ریز را ندارد. علاوه بر آن در مواردی در فرآیند آموزش مقدار دقت پرش دارد که باید این موارد نیز مورد بررسی قرار گیرد. ولی در کل این شبکه با کمی تغییر نسبت به معماری U-Net اولیه یعنی اضافه کردن Dropout، نرمال سازی و استفاده از BatchNormalization نتایج قابل قبولی (۰,۸۲) را ارائه داده است. به نظر می رسد هنوز هم داده آموزشی برای شبکه کم است و باید از داده های بیشتری استفاده کرد. چرا که از یکجایی به بع در آزمایشات صورت گرفته افزایش چشمگیری در میزان دقت روش نداریم.



شکل ۱۱: فرآیند آموزش آزمایش ششم



شکل ۱۲: نمونه قطعه بندی تصویر با استفاده از مدل پیشنهادی

## منابع

- [1] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597, 2015.
- [2] Hao Dong, Guang Yang, Fangde Liu, Yuanhan Mo, and Yike Guo. Automatic brain tumor detection and segmentation using u-net based fully convolutional networks. *CoRR*, abs/1705.03820, 2017.
- [3] Fabian Isensee, Philipp Kickingereder, Wolfgang Wick, Martin Bendszus, and Klaus H. Maier-Hein. Brain tumor segmentation and radiomics survival prediction: Contribution to the BRATS 2017 challenge. *CoRR*, abs/1802.10508, 2018.
- [4] Richard McKinley, Raphael Meier, and Roland Wiest. Ensembles of densely-connected cnns with label-uncertainty for brain tumor segmentation. In *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries - 4th International Workshop, BrainLes 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers, Part II*, pages 456–465, 2018.
- [5] Fabian Isensee, Philipp Kickingereder, Wolfgang Wick, Martin Bendszus, and Klaus H. Maier-Hein. No new-net. *CoRR*, abs/1809.10483, 2018.