

شبکه‌ی عصبی کانولوشن هیبریدی برای ایجاد طراحی درمان رادیوتراپی تعدیل شده با شدت بهینه برای تومورهای مغزی

آرش ابراهیمی^۱، ایرج عابدی^۲، آرن بنایی^۳، شایسته‌سادات ممهد^۴

مقاله پژوهشی

چکیده

مقدمه: رادیوتراپی با شدت مدوله شده (Intensity-Modulated Radiation Therapy) IMRT یکی از روش‌های اصلی درمان تومورهای مغزی است، اما طراحی آن پیچیده و وابسته به تجربه فیزیسیست است. هدف این مطالعه، توسعه و ارزیابی یک مدل شبکه‌ی عصبی کانولوشن هیبریدی (Hybrid CNN) برای پیش‌بینی طراحی خودکار پلن‌های IMRT با دقت بالا بود.

روش‌ها: داده‌های ۱۲۰ بیمار مبتلا به گلیوبلاستوما بین سال‌های ۱۴۰۰ تا ۱۴۰۳ استفاده شد. تصاویر CT و MRI کانتور شده و مقادیر هیستوگرام حجم همپوشانی (Overlap Volume Histogram) OVH برای ارگان‌ها به عنوان داده ورودی ارائه شد. سه رویکرد بررسی شد: استفاده از داده‌های OVH، داده‌های ساختارهای کانتور شده و ترکیب هر دو به عنوان ورودی جامع. مدل با استفاده از لایه‌های D1 و D-CNN3 و شبکه کاملاً متصل آموزش داده شد و عملکرد آن با شاخص‌های میانگین خطای مطلق (MAE) و خطای مربعی میانگین (MSE) ارزیابی شد.

یافته‌ها: مدل هیبریدی عملکرد برتری نسبت به مدل‌های منفرد داشت. میانگین فاصله MAE و MSE در مجموعه تست به ترتیب $2/85$ Gy و $7/55$ Gy بود. مقادیر پیش‌بینی شده دوز برای اندام‌های حساس با داده‌های واقعی همخوانی بالایی داشت ($P > 0/05$). ترکیب OVH و تصاویر کانتور شده موجب افزایش دقت مدل و توانایی ثبت روابط پیچیده میان ساختارهای آناتومیک و اهداف دوز-حجم شد.

نتیجه‌گیری: مدل هیبریدی CNN قادر است طراحی خودکار پلن‌های IMRT را با دقت بالا انجام دهد، کیفیت پلن‌ها را بهبود بخشد، وابستگی به تجربه فیزیسیست را کاهش دهد و قابلیت ادغام با سیستم‌های برنامه‌ریزی درمانی را داراست، و مسیر پرتودرمانی شخصی‌سازی شده و ایمن‌تر در بیماران مبتلا به تومور مغزی هموار می‌سازد.

واژگان کلیدی: رادیوتراپی با شدت مدوله‌شده؛ شبکه‌ی عصبی کانولوشن هیبریدی؛ طراحی درمان خودکار؛ تومور مغزی؛ هیستوگرام حجم همپوشانی

ارجاع: ابراهیمی آرش، عابدی ایرج، بنایی آرن، ممهد شایسته‌سادات. شبکه‌ی عصبی کانولوشن هیبریدی برای ایجاد طراحی درمان رادیوتراپی

تعدیل‌شده با شدت بهینه برای تومورهای مغزی. مجله دانشکده پزشکی اصفهان ۱۴۰۵؛ ۴۴ (۸۶۰): ۶۲۳-۶۳۱.

مقدمه

رادیوتراپی با شدت مدوله‌شده (Intensity-Modulated Radiation Therapy) IMRT یکی از روش‌های اصلی درمان تومورهای مغزی است که با تمرکز دوز پرتو بر ناحیه‌ی هدف، آسیب به بافت‌های سالم پیرامونی را به حداقل می‌رساند (۱، ۲). با این حال، طراحی درمان IMRT فرایندی پیچیده و زمان‌بر است که به تجربه و مهارت برنامه‌ریزان انسانی وابسته بوده و می‌تواند منجر به تفاوت‌های قابل

توجه در کیفیت درمان شود (۳).

طراحی درمان به طور سنتی بر پایه‌ی الگوریتم‌های محاسبه دوز و طراحی درمان دستی انجام می‌شود که دقت بالایی دارند اما به زمان محاسباتی زیاد نیازمند هستند (۴، ۵). در سال‌های اخیر، روش‌های یادگیری عمیق و شبکه‌های عصبی کانولوشن (Convolutional Neural Network) به عنوان ابزاری کارآمد برای خودکارسازی طراحی درمان مطرح شده‌اند، زیرا می‌توانند رابطه‌ی پیچیده میان ویژگی‌های

۱- گروه فیزیک، دانشکده‌ی علوم، دانشگاه اصفهان، اصفهان، ایران

۲- گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

۳- گروه علوم کامپیوتر، دانشگاه شهید بهشتی، تهران، ایران

۴- گروه مهندسی برق، دانشگاه آزاد نجف آباد، نجف آباد، ایران

نویسنده‌ی مسؤول: ایرج عابدی؛ گروه فیزیک پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

Email: Iraj_abedi@yahoo.com

بیمار و پارامترهای درمانی را استخراج کرده و پلن‌های درمانی با کیفیت نزدیک به طرح‌های کلینیکی معمول ایجاد کنند (۶، ۷).

در طراحی درمان خودکار، رویکردهای یادگیری عمیق عمدتاً بر تنظیم خودکار پرتوها و زوایای تابش به منظور دستیابی به پوشش هدف بهینه، بهینه‌سازی توزیع دوز بر اساس اهداف درمانی و محدودیت‌های اندام‌های حساس، و همچنین ادغام شبکه عصبی با الگوریتم‌های بهینه‌سازی کلاسیک تمرکز دارند تا بتوانند پلن‌های درمانی با کیفیت بالاتر و سازگاری بالینی بیشتر ایجاد نمایند (۸).

مطالعات قبلی نشان داده‌اند که ترکیب CNN با الگوریتم‌های بهینه‌سازی، امکان طراحی درمان خودکار IMRT را فراهم کرده و زمان طراحی درمان را کاهش می‌دهد، در حالی که کیفیت بالینی پلن‌ها حفظ می‌شود (۹، ۱۰). با این حال، بیشتر پژوهش‌ها بر مدل‌های منفرد یا داده‌های محدود تمرکز داشته و ارزیابی جامع بالینی طرح‌های پیشنهادی، به ویژه برای تومورهای مغزی، به طور کامل انجام نشده است (۱۱-۱۳).

در این مطالعه، سه رویکرد متمایز برای ارزیابی کارایی نسبی انواع داده‌های ورودی طراحی شد. در رویکرد نخست، از یک رویکرد سنتی مبتنی بر یادگیری ماشین استفاده شد و مدل تنها با مقادیر OVH استخراج‌شده از ارگان‌های حساس (Organ at Risks) تغذیه گردید. در رویکرد دوم، اندام‌های حساس و ساختارهای کانتور شده بافت هدف (Planning Target Volume) به عنوان ورودی مدل ادغام شدند. در نهایت، در رویکرد سوم، مقادیر OVH با ساختارهای کانتور شده OARs و PTV ترکیب شده و به عنوان یک ورودی جامع به مدل ارائه شد.

روش‌ها

این مطالعه از نوع توصیفی-مقطعی بود که با هدف بررسی طراحی درمان IMRT در بیماران مبتلا به گلیوبلاستوما انجام شد. داده‌های ۱۲۰ بیمار که بین سال‌های ۱۴۰۰ تا ۱۴۰۳ در بیمارستان میلاد، اصفهان، ایران تحت درمان قرار گرفتند، مورد استفاده قرار گرفت. حجم نمونه بر اساس دسترس‌پذیری داده‌های بالینی و معیارهای ورود و خروج بیماران تعیین شد. بیماران بر اساس راهنمای NCCN برای سرطان‌های سیستم عصبی مرکزی (Central Nervous System Cancers, Version 1.2023) در مرحله T1-3N0M0 طبقه‌بندی شدند (۱۴).

تصاویر سی‌تی‌اسکن با استفاده از سیستم زیمنس (Siemens Confidence, Germany) انجام شد. تصاویر MRI بدون کتراست با تصاویر CT هم‌تراز شدند تا اطلاعات آناتومیک دقیق برای طراحی درمان فراهم گردد. هدف درمان و لندام‌های در معرض خطر (OARs) شامل چشم‌ها، اعصاب بینایی، کیاسمای بینایی، ساقه مغز و مغز سالم توسط یک

انکولوژیست، مطابق با دستورالعمل ICRU 62 تعیین شد (۱۵). پلن‌های درمانی توسط سه فیزیسیست مجرب با استفاده از پرتوهای فوتونی ۶MV طراحی شد، به گونه‌ای که دوز کل ۶۰Gy در ۳۰ جلسه به بیمار تحویل داده شود.

ورودی و خروجی مدل

در این مطالعه، سه رویکرد مجزا برای پیش‌بینی طراحی درمان پرتودرمانی بررسی شد. در رویکرد نخست، مقادیر OVH مربوط به شش اندام در معرض خطر (OARs) به عنوان ورودی مدل استفاده گردید. در رویکرد دوم، ساختارهای کانتور شده OARها و حجم هدف (PTV) به عنوان ورودی ارائه شدند. نهایتاً، در رویکرد سوم، OVH و ساختارهای کانتور شده به صورت ترکیبی در یک مدل جامع مبتنی بر شبکه عصبی کانولوشن (CNN) به کار گرفته شد. هدف از آن، ارزیابی تأثیر انواع داده‌های ورودی بر دقت پیش‌بینی طراحی درمان بود. علاوه بر این، حداکثر دوز دریافت شده توسط چشم‌ها، عدسی‌ها و اعصاب بینایی به عنوان خروجی مدل تعیین شد تا اثر بالینی هر رویکرد بر اندام‌های حساس ارزیابی شود.


پردازش داده‌ها

پیش‌پردازش شامل تولید ماسک‌های دوبعدی برای هر اسلایس تصویر پزشکی و استخراج مختصات کانتور PTV و OARها انجام شد. ماسک‌های دودویی برای تفکیک بخش‌های موردنظر از تصویر اصلی استفاده شدند. سپس، ماسک سه‌بعدی (۶۴×۶۴×۶۴) از طریق برش و تغییر اندازه داده‌ها ایجاد شد. همچنین، نرمال‌سازی و مقیاس‌بندی شدت پیکسلی برای استانداردسازی داده‌ها اعمال شد. برای داده‌های OVH یک بردار (۵۱×۶) ذخیره شد که نشان‌دهنده OVH شش OAR با بازه فاصله‌ای از ۲- cm تا ۳ cm و گام ۱ mm بود.


معماری شبکه

سه مدل معماری برای تحلیل داده‌ها بررسی شد. در رویکرد اول، یک شبکه 1D CNN برای پردازش داده‌های OVH استفاده شد. خروجی CNN به شبکه دسته‌بندی‌کننده متصل شد تا مقدار دوز پیش‌بینی شود. لایه‌های کانولوشنی در CNN با استفاده از فیلترها ویژگی‌های ورودی را استخراج کردند. توابع فعال‌سازی مانند ReLU برای یادگیری الگوهای پیچیده به کار رفتند و از مشکل گرادیان صفر جلوگیری کردند. نقشه‌های ویژگی خروجی لایه‌های کانولوشنی بسته به ابعاد ورودی، تعداد فیلترها و نوع پدینگ تغییر کردند (شکل ۱).

در رویکرد دوم، با شکل ورودی ۶۴×۶۴×۶۴، لایه‌های کانولوشنال دوبعدی و لایه‌های ادغام حداکثر دوز بعدی را در معماری شبکه انتخاب کردیم. قبل از ارسال داده‌های خروجی از شبکه‌های عصبی کانولوشن (CNN) به طبقه‌بندی‌کننده، پیش‌بینی مقادیر دوز تولید می‌شود (شکل ۲).




شکل ۱. شبکه یک بعدی CNN و طبقه‌بندی‌کننده برای پیش‌بینی مقدار دوز: شکل تانسور ورودی (۱۱×۵۱). خروجی مدل شامل مقادیر حداکثر دوز OARهای مشخص گردید.



شکل ۲. پیش‌بینی مقدار دوز پیشرفته با استفاده از CNNهای ۲ بعدی و شبکه طبقه‌بندی‌کننده: شکل ورودی (۶۴×۶۴×۶۴).

- Max-Pooling Layer: برای کاهش ابعاد ویژگی‌ها، هر نقشه ویژگی را به بخش‌های غیرهمپوشانی تقسیم کرده و فقط مقدار بیشینه را حفظ می‌کند. در این مدل، اندازه این لایه ۲ در نظر گرفته شده است.
- Batch Normalization: جهت مقابله با تغییرات داخلی توزیع داده‌ها و بهبود همگرایی مدل، مقدار ویژگی‌ها را با میانگین صفر و واریانس یک تنظیم می‌کند.

در نهایت، رویکرد سوم یک طرح ترکیبی CNN معرفی گردید که شامل یک و دو لایه پیچشی است، همانطور که در شکل ۳ نشان داده شده است. هدف استفاده از داده‌های تصویر OVH و کانتور به ترتیب با یک و سه بعدی بود. اجزای اولیه مدل به کار رفته در این کار (شکل ۳) لایه‌های کانولوشن، لایه‌های حداکثر تجمع، لایه‌های نرمال‌سازی دسته‌ای، لایه‌های ادغام میانگین کلی، و لایه‌های حذفی هستند. مدل پیشنهادی شامل چندین لایه کلیدی برای پردازش داده‌ها است:



شکل ۳. معماری مدل نشان‌دهنده‌ی لایه‌های کانولوشنیک ۱ بعدی و ۳ بعدی به همراه یک FCN برای طبقه‌بندی نتایج. مدل ورودی شامل تصاویر کانتور و OVH بود. خروجی مدل شامل مقادیر حداکثر دوز OARهای مشخص شده بود.

n : تعداد نمونه‌ها یا داده‌های مورد بررسی (مثلاً تعداد وکسل‌ها در یک نقشه دوز).

D_k : مقدار واقعی دوز در وکسل k (دوز در پلن بالینی).

$\hat{D}_k$: مقدار پیش‌بینی شده یا مدل‌شده دوز در وکسل k .

برای مقایسه‌ی دوزهای پیش‌بینی‌شده و واقعی، آزمون تی زوجی انجام شد. فرض صفر (H_0) برابری میانگین‌ها را نشان می‌دهد، در حالی که فرض جایگزین (H_1) به تفاوت معنادار اشاره دارد. این تحلیل به بررسی دقت مدل در مقایسه با داده‌های واقعی کمک می‌کند.

یافته‌ها

جدول ۱ مقادیر MSE و MAE را برای هر یک از ده برابر در طول ارزیابی نشان می‌دهد و عملکرد سه مدل متمایز را ارائه می‌کند: مدل ۱ بعدی CNN (مدل OVH)، مدل ۳ بعدی CNN و مدل ترکیبی. علاوه بر این، جدول میانگین مقادیر MSE و MAE محاسبه شده در تمام تاه‌ها را ارائه می‌کند و یک نمای کلی مختصر از عملکرد کلی هر مدل برای کل مجموعه داده ارائه می‌دهد.

به دلیل عملکرد بهتر مدل ترکیبی، این مدل برای ارزیابی نهایی انتخاب شد. عملکرد آن در سطح بیمار با تجمیع مقادیر پیش‌بینی‌شده دوز حداکثری ارزیابی شد. مقادیر MSE و MAE در ۱۱ بیمار محاسبه و میانگین آن‌ها در جدول ۲ ارائه شده است.

- Global Average Pooling: در لایه نهایی CNN، میانگین هر نقشه ویژگی را محاسبه کرده و اطلاعات فضایی را به یک مقدار عددی فشرده می‌کند.
- Fully Connected Network (FCN): خروجی ترکیبی از 1D-CNN و 3D-CNN در یک شبکه کاملاً متصل (FCN) پردازش شده و از طریق سه لایه متراکم (Dense) با فعال‌سازی ReLU و یک لایه خروجی خطی به ۶ متغیر هدف متصل می‌شود. برای جلوگیری از بیش‌برازش، یک لایه Dropout با مقدار ۰/۵ اضافه شده است.

آموزش مدل شامل:

- استفاده از بهینه‌ساز Adam با نرخ یادگیری ۰/۰۰۱ و دسته‌های آموزشی با اندازه ۱۶.
 - تابع هزینه MSE برای یادگیری پایدار.
 - اعتبارسنجی ۱۰ برابری برای ارزیابی عملکرد مدل.
- ارزیابی مدل با استفاده از MSE و MAE انجام شد تا دقت پیش‌بینی در سطح بیمار بررسی شود. این روش به ارزیابی توانایی مدل در پیش‌بینی دوز توزیعی برای بیماران کمک می‌کند (روابط ۱ و ۲).

$$\text{رابطه ۱} - MSE = \frac{1}{n} \sum_{k=1}^n (D_k - \hat{D}_k)^2$$

$$\text{رابطه ۲} - MAE = \frac{1}{n} \sum_{k=1}^n |D_k - \hat{D}_k|$$

جدول ۱. خلاصه عملکرد مدل ۱ بعدی CNN (مدل OVH)، مدل سه بعدی CNN و مدل ترکیبی در اعتبارسنجی متقاطع ۱۰ برابر.

شماره	مدل CNN یک بعدی (مدل OVH)	مدل CNN سه بعدی	مدل CNN ترکیبی	
	MAE (گری)	MSE (گری)	MAE (گری)	MSE (گری)
۱	۱۰/۸۵	۲/۱۹	۱۰/۶۴	۲/۰۸
۲	۶/۵۰	۱/۴۹	۶/۳۵	۱/۳۸
۳	۷/۶۴	۱/۸۳	۷/۱۰	۱/۶۷
۴	۱۵/۷۶	۲/۴۸	۱۴/۵۳	۲/۲۹
۵	۷/۶۴	۱/۵۹	۷/۲۳	۱/۴۰
۶	۷/۹۸	۱/۷۶	۷/۶۸	۱/۴۹
۷	۱۰/۱۸	۱/۹۸	۷/۸۲	۱/۵۳
۸	۱۵/۰۰	۱/۹۶	۱۴/۸۳	۱/۹۷
۹	۷/۷۹	۱/۷۸	۷/۴۰	۱/۸۱
۱۰	۱۰/۸۸	۲/۱۳	۱۰/۸۴	۲/۰۸
میانگین	۱۰/۰۲	۱/۹۲	۹/۴۴	۱/۷۷

جدول ۲. مقایسه‌ی MSE و MAE مقادیر دوز پیش‌بینی شده


توسط مدل ترکیبی با مقادیر واقعی برای ۱۱ بیمار

تعداد بیمار	میانگین مربعات خطا (Gy)	میانگین خطای مطلق (Gy)
۱	۶/۵۶	۱/۶
۲	۵/۹۷	۱/۳۴
۳	۵/۲۴	۱/۵
۴	۹/۵۱	۲/۱۱
۵	۷/۰۱	۲/۱
۶	۵/۹۳	۱/۷
۷	۹/۷۳	۱/۶۳
۸	۱۲/۱۲	۲/۵
۹	۹/۰۷	۲/۲۳
۱۰	۴/۹۳	۱/۵۳
۱۱	۷/۰۳	۲/۱۶
میانگین	۷/۵۵	۱/۸۵

تحلیل مقایسه‌ای با Paired Samples T-Test برای ۱۱ بیمار، مقادیر پیش‌بینی شده مدل هیبریدی و مقادیر واقعی دوز را بررسی کرد. P‌های بالا (همگی < 0.05) برای OARها (چشم‌ها، عدسی‌ها و اعصاب بینایی) نشان‌دهنده‌ی تطابق معنادار پیش‌بینی‌های مدل با داده‌های واقعی است. این نتایج دقت مدل را در تخمین دوز واقعی برای ساختارهای آناتومیک مختلف تأیید می‌کند.

شکل ۴ توزیع هیستوگرام دوز-حجم (DVH) را برای دو مورد به طور تصادفی انتخاب شده از مجموعه آزمایش نشان می‌دهد و DVH‌های طرح‌های تولید شده با مدل ترکیبی (کمک DL) را با DVH‌های طرح‌های اصلی مقایسه می‌کند.

یک مقایسه‌ی آماری جامع بین برنامه‌های اولیه و برنامه‌های مبتنی بر یادگیری عمیق (DL) انجام شد تا معیارهای بالینی مرتبط ارزیابی شوند. این تحلیل، اثربخشی برنامه‌های مبتنی بر یادگیری ماشین را در محیط‌های بالینی واقعی بررسی می‌کند. جدول ۳ مقادیر دوز دو نمونه تصادفی (A و B) را نشان می‌دهد.



شکل ۴ توزیع DVH برای دو مورد از مجموعه آزمایشی، مقایسه DVH‌های طرح به کمک DL با طرح‌های اصلی.

جدول ۳. مقادیر دوز برای موارد A و B به طور تصادفی انتخاب شده از مجموعه آزمایش

مورد B		مورد A		پارامتر	اندام در معرض خطر (OAR)
طرح مبتنی بر DL	طرح اولیه	طرح مبتنی بر DL	طرح اولیه		
۶۶/۴۳	۶۴/۲۴	۶۵/۰۴	۶۳/۷۳	D2 (Gy)	PTV
۵۹/۹۴	۵۹/۰۴	۶۰/۶۱	۶۰/۱۲	D98 (Gy)	
۶۳/۶۷	۶۱/۷۸	۶۳/۴۳	۶۲/۲۵	Dmean (Gy)	
۶۷/۲۳	۶۴/۹۷	۶۵/۴۷	۶۴/۵۱	Dmax (Gy)	
۰/۱۱	۰/۰۹	۰/۰۷	۰/۰۶	HI	
۲/۴۰	۱۷/۸۰	۰/۹۷	۲/۱۰	D2 (Gy)	کیاسم نوری
۰/۸۵	۱/۴۴	۰/۴۳	۰/۷۸	D98 (Gy)	
۱/۴۹	۵/۰۹	۰/۶۴	۱/۲۸	Dmean (Gy)	
۲/۴۵	۱۸/۳۴	۱/۰	۲/۲	Dmax (Gy)	
۰/۷۸	۱/۳۴	۰/۴۳	۰/۷۳	Dmin (Gy)	
۴/۹۸	۳۱/۷۵	۰/۷۷	۴/۲۸	D2 (Gy)	چشم (چپ)
۰/۶۰	۰/۹۶	۰/۲۹	۰/۴۷	D98 (Gy)	
۱/۴۸	۷/۹	۰/۴۵	۱/۲۵	Dmean (Gy)	
۵/۱۷	۳۲/۹۱	۰/۸۱	۴/۶۲	Dmax (Gy)	
۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱	Dmin (Gy)	
۰/۷۲	۱/۳۴	۰/۴۱	۰/۵۹	D2 (Gy)	چشم (راست)
۰/۴۱	۰/۴۴	۰/۳۷	۰/۳۷	D98 (Gy)	
۰/۵۱	۰/۷	۰/۴۵	۰/۴۵	Dmean (Gy)	
۰/۸۱	۱/۵۵	۰/۶۵	۰/۶۵	Dmax (Gy)	
۰/۴۱	۰/۴۴	۰/۳۷	۰/۳۷	Dmin (Gy)	
۲/۰۳	۱۳/۴۹	۱/۶۹	۱/۶۹	D2 (Gy)	عصب بینایی (چپ)
۰/۹۶	۲/۱۱	۰/۷۰	۰/۷۰	D98 (Gy)	
۱/۴۴	۶/۴	۱/۱۶	۱/۱۶	Dmean (Gy)	
۲/۰۵	۱۳/۹۹	۱/۷۱	۱/۷۱	Dmax (Gy)	
۰/۹۴	۲/۰۹	۰/۶۹	۰/۶۹	Dmin (Gy)	
۱/۰۲	۳/۴۰	۰/۸۵	۰/۸۵	D2 (Gy)	عصب بینایی (راست)
۰/۵۸	۰/۶۴	۰/۴۷	۰/۴۷	D98 (Gy)	
۰/۷۶	۱/۲۴	۰/۶۵	۰/۶۵	Dmean (Gy)	
۱/۰۵	۳/۵۲	۰/۸۷	۰/۸۷	Dmax (Gy)	
۰/۵۸	۰/۶۴	۰/۴۷	۰/۴۷	Dmin (Gy)	
۱/۹۰	۷/۵۴	۱/۷۲	۱/۷۲	D2 (Gy)	ساقه مغز
۰/۲۷	۰/۳۰	۰/۱۹	۰/۱۹	D98 (Gy)	
۰/۸۵	۱/۵۶	۰/۷	۰/۷	Dmean (Gy)	
۱/۹۳	۸/۳۶	۱/۷۶	۱/۷۶	Dmax (Gy)	
۰/۲۲	۰/۲۸	۰/۱۵	۰/۱۵	Dmin (Gy)	
۰/۰۳		۰/۱۳		Paired Sample T-test	

*: D2 دوز ۲ درصد از حجم هدف (hot spot)، D98: دوز ۹۸ درصد از حجم هدف (حداقل دوز)، Dmean: میانگین دوز کل حجم، Dmax: حداکثر دوز دریافت شده، HI: شاخص یکنواختی دوز.

بحث

این مطالعه یک رویکرد نوآورانه مبتنی بر یادگیری عمیق ارائه می‌دهد که قادر است اهداف دوز-حجم بهینه را برای طراحی درمان بیماران مبتلا به تومور مغزی پیش‌بینی کند. مدل ارائه شده، یک شبکه عصبی کانولوشن هیبریدی است که خروجی‌های دو شبکه کانولوشن مجزا را با هم ترکیب می‌کند. این طراحی امکان بهره‌گیری همزمان از تصاویر کانتور شده CT و مقادیر OVH را فراهم ساخته و به تولید مدلی دقیق و جامع برای پیش‌بینی پلن منجر می‌شود. افزودن OVH به داده‌های ورودی، اطلاعات مکانی دقیق‌تری درباره نزدیکی OARها به حجم هدف ارائه می‌دهد و این ویژگی بهبود عملکرد مدل را در پیش‌بینی اهداف دوز-حجم تسهیل می‌کند.

نتایج مطالعه نشان داد، عملکرد کمی مدل هیبریدی نیز بسیار مطلوب بود. میانگین خطای مطلق و خطای مربعی میانگین در مجموعه آموزش به ترتیب $Gy\ 1/72$ و $Gy\ 8/22$ بود، و در مجموعه تست، به ترتیب $Gy\ 2/85$ و $Gy\ 7/55$ ثبت شد. این مقادیر نشان‌دهنده دقت و پایداری بالا در پیش‌بینی اهداف دوز-حجم است و نشان می‌دهد که مدل توانسته به طور قابل اعتماد توزیع دوز را برای اندام‌های حساس و حجم هدف تخمین بزند.


مطالعات متعددی به کاربرد یادگیری عمیق در طراحی خودکار برنامه‌های درمانی پرتودرمانی پرداخته‌اند. برای نمونه، مدل DeepDoseNet برای پیش‌بینی اهداف دوز-حجم در بیماران سر و گردن توسعه یافته بود و عملکرد آن در پیش‌بینی طرح درمان با MAE برابر $Gy\ 2.3$ و MSE برابر $Gy\ 3$ گزارش شد [16]. تفاوت اصلی مدل پیشنهادی ما با DeepDoseNet، ادغام مقادیر OVH با ساختارهای کانتور شده OARها و PTV در یک مدل هیبریدی است، که اطلاعات فضایی و حجم هدف را به شکل جامع در اختیار شبکه قرار می‌دهد. این ترکیب، توانایی مدل در ثبت روابط پیچیده میان ساختارهای آناتومیک و اهداف دوز-حجم و تولید طرح درمان خودکار با کیفیت بالاتر را افزایش می‌دهد.

مطالعات دیگری نیز نشان داده‌اند که استفاده از داده‌های ترکیبی شامل OVH و تصاویر کانتور شده می‌تواند دقت و کارایی مدل‌های پیش‌بینی طراحی درمان را بهبود بخشد (۱۷، ۱۸). بعنوان مثال، افزودن OVH به ورودی مدل، اطلاعات مهمی درباره نزدیکی اندام‌های حساس به هدف درمان ارائه می‌دهد و امکان طراحی طرح‌های درمانی بهینه‌تر را فراهم می‌کند. این یافته‌ها با نتایج مدل هیبریدی ما همسو است و نشان می‌دهد که استفاده از داده‌های چندمنظوره و مدل هیبریدی CNN می‌تواند به ایجاد پلن‌های درمانی خودکار و بالینی قابل اعتماد منجر شود.

از دیدگاه بالینی، مدل توسعه یافته قابلیت ادغام با سیستم‌های

برنامه‌ریزی درمانی (Treatment Planning System) را دارد و با طرح‌های اصلی بیماران تطابق مناسبی نشان می‌دهد. این ویژگی بیانگر پتانسیل بالینی مدل است و نشان می‌دهد که می‌توان از آن برای بهبود کیفیت و کارایی طراحی درمان IMRT در بیماران مبتلا به تومور مغزی استفاده کرد. همچنین، استفاده از این مدل می‌تواند وابستگی به تجربه طراحی‌کننده و تفاوت‌های فردی در طراحی درمان را کاهش دهد، که اهمیت بالینی قابل توجهی دارد.

علاوه بر این، نمودارهای ویولن ارائه شده در شکل ۵ تفاوت بین دوز واقعی و پیش‌بینی شده برای هر OAR را نشان می‌دهد و امکان ارزیابی دقیق‌تر توزیع دوز و عملکرد پیش‌بینی مدل را فراهم می‌کند. این تحلیل بصری کمک می‌کند تا کارایی مدل در شرایط بالینی واقعی به شکل جامع و شفاف ارزیابی شود.



شکل ۵ نمودار ویولن مقادیر دوز واقعی و پیش‌بینی شده تولید شده توسط مدل ترکیبی را برای بیماران مجموعه تست برای هر OAR مقایسه می‌کند.

در مجموع، نتایج این مطالعه نشان داد که ترکیب یادگیری عمیق و طراحی معماری نوآورانه می‌تواند به توسعه سیستم‌های خودکار و دقیق طراحی درمان منجر شود و مسیر را برای پزشکی شخصی‌سازی شده و ایمن‌تر در پرتودرمانی تومورهای مغزی هموار سازد.

نتیجه‌گیری

مدل شبکه‌ی عصبی کانولوشن هیبریدی ارائه شده با ترکیب تصاویر کانتور شده CT و مقادیر OVH قادر است طراحی خودکار پلن‌های درمانی IMRT برای بیماران مبتلا به تومور مغزی را با دقت بالا و قابلیت اعتماد مناسب انجام دهد. این رویکرد با ثبت روابط پیچیده میان ساختارهای آناتومیک و اهداف دوز-حجم، کیفیت پلن‌های درمانی را بهبود می‌بخشد، وابستگی به تجربه فیزیسیست را کاهش می‌دهد و قابلیت ادغام با سیستم‌های برنامه‌ریزی درمانی را داراست، که مسیر را برای پرتودرمانی شخصی‌سازی شده و ایمن‌تر هموار می‌کند.

تشکر و قدردانی

این مقاله منتج از طرح تحقیقاتی رشته‌ی فیزیک پزشکی با کد ۱۴۰۰۴۸۱ می‌باشد که در دانشگاه علوم پزشکی اصفهان به تصویب

رسیده و با حمایت مالی دانشگاه علوم پزشکی اصفهان به انجام رسیده است. بدین‌وسیله از زحمات معاونت محترم پژوهشی دانشگاه علوم پزشکی اصفهان تقدیر و تشکر می‌شود.

References

1. Takahashi S, Miyake K, Ogawa D, Anada M, Kinoshita T, Nishide T, et al. A prospective study of intensity-modulated radiation therapy using a standard radiation dose for high-grade glioma. *Cancer Diagn Progn* 2023; 3(4): 491-7.
2. Feng X, Zhang L, Li Y, Pan y, Zuo g, Yang r. A new deep learning model for predicting IMRT dose distribution in lung cancer. *Front Oncol* 2025; 15: 1587788.
3. Li X, Zhang Y, Zhao F, Yang F, Luo Y. Transformer-integrated hybrid convolutional neural network for dose prediction in nasopharyngeal carcinoma radiotherapy. *Journal of Imaging Informatics in Medicine* 2024; 38(3): 1531-51.
4. van de Sande D, Sharabiani M, Bluemink H, Kneepkens E, Bakx N, Hagelaar E, et al. Artificial intelligence-based treatment planning of radiotherapy for locally advanced breast cancer. *Phys Imaging Radiat Oncol* 2021; 20: 111-6.
5. Scaringi C, Minniti G, Paolini S. Technical advances in radiation therapy for brain tumors. *Anticancer Res* 2018; 38(11): 6041-7.
6. Kajikawa T, Kadoya N, Ito K, Takayama Y, Chiba T, Tomori S, et al. A convolutional neural network approach for IMRT dose distribution prediction in prostate cancer patients. *J Radiat Res* 2019; 60(5): 685-93.
7. Sheng Y, Li M, Liu Z, et al. Artificial intelligence applications in intensity modulated radiation therapy. *Med Phys* 2021; 48(3): 1-8.
8. Cai W, Ding S, Li Y, Zhou X, Dou W, Zhou L, et al. Automatic IMRT treatment planning through fluence prediction and plan fine-tuning for nasopharyngeal carcinoma. *Radiother Oncol* 2024; 19(1): 39.
9. Li J. Artificial intelligence-based treatment planning of radiotherapy for different anatomical sites. Durham, NC: Duke University; 2023.
10. Fuller CD, Choi M, Forthuber B, Wang SJ, Rajagiriyl N, Salter BJ, et al. Standard fractionation intensity modulated radiation therapy (IMRT) of primary and recurrent glioblastoma multiforme. *Radiat Oncol* 2007; 2: 26.
11. Wang Y, Piao Z, Gu H, Chen M, Zhang D, Zhu J. Deep learning-based prediction of radiation therapy dose distribution in head and neck cancers *Technol Cancer Res Treat* 2024; 23: 15330338241256594.
12. Tol JP, Dahele M, Delaney AR, Slotman BJ, Verbakel WF. Can knowledge-based DVH predictions be used for automated, individualized quality assurance of radiotherapy treatment plans? *Radiat Oncol* 2015; 10(1): 234.
13. Westermayer M, Sandu D, Laude C, Racadot S, Serre AA, Sarrut D, et al. Evaluation of a quasi-automatic treatment planning workflow for head-and-neck cancer in radiotherapy. *Phys Imaging Radiat Oncol* 2026; 39: 100983.
14. Nabors B, Portnow J, Hattangadi-Gluth J, Horbinski C. NCCN CNS tumor guidelines update for 2023. *Neuro Oncol* 2023; 25(12): 2114-6.
15. International Commission on Radiation Units and Measurements (ICRU). ICRU Report 62: Prescribing, Recording, and Reporting Photon Beam Therapy. Bethesda, MD: ICRU; 1999.
16. Soomro MH, Alves VG, Nourzadeh H, Siebers JV. DeepDoseNet: A deep learning model for 3D dose prediction in radiation therapy. *arXiv*. 2021. Available from: <https://arxiv.org/pdf/2111.00077>
17. Jihong C, Penggang B, Xiuchun Z, Kaiqiang C, Wenjuan C, Yitao D, et al. Automated Intensity Modulated Radiation Therapy Treatment Planning for Cervical Cancer Based on Convolution Neural Network. *Technol Cancer Res Treat* 2020; 19: 1533033820957002.
18. Wang CW, Khalil MA, Puspita Firdi N. A survey on deep learning for precision oncology. *Diagnostics (Basel)* 2022; 12(6): 1489..

Hybrid Convolutional Neural Network to Generate Optimal Intensity-Modulated Radiotherapy Treatment Planning for Brain Tumors

Arash Ebrahimi¹, Iraj Abedi², Arian Banaei³, Shayesteh Sadat Momahheh⁴

Original Article

Abstract

Background: Intensity-Modulated Radiation Therapy (IMRT) is one of the main treatments for brain tumors; however, treatment planning is complex and highly dependent on the physicist's experience. This study aimed to develop and evaluate a Hybrid Convolutional Neural Network (Hybrid CNN) model for accurate automated IMRT treatment planning prediction.

Methods: Data from 120 patients with glioblastoma treated between 2021 and 2024 were used. Contoured CT and MRI images along with Overlap Volume Histogram (OVH) values for organs-at-risk and target volumes were provided as model inputs. Three approaches were evaluated: using OVH data, contoured structures, and a combined input of both. The model was trained using 1D and 3D-CNN layers with a fully connected network, and its performance was assessed using Mean Absolute Error (MAE) and Mean Squared Error (MSE).

Findings: The hybrid model outperformed individual models. The mean MAE and MSE in the test set were 2.85 Gy and 7.55 Gy, respectively. Predicted doses for organs-at-risk showed high agreement with actual values ($P > 0.05$). Combining OVH and contoured images improved model accuracy and captured complex relationships between anatomical structures and dose-volume objectives.

Conclusion: The Hybrid CNN can perform automated IMRT treatment planning with high accuracy, improve plan quality, reduce dependence on physicist experience, and integrate with clinical treatment planning systems. This approach paves the way for safer and personalized radiotherapy in patients with brain tumors.

Keywords: Intensity-Modulated Radiotherapy, Hybrid Convolutional Neural Network, Automatic Treatment Planning, Brain Tumor, Overlap Volume Histogram

Citation: Ebrahimi A, Abedi I, Banaei A, Momahheh ShM. **Hybrid Convolutional Neural Network to Generate Optimal Intensity-Modulated Radiotherapy Treatment Planning for Brain Tumors.** J Isfahan Med Sch 2026; 44 (860): 623- 31.

1- Department of Physics, Faculty of Sciences, University of Isfahan, Isfahan, Iran

2- Department of Medical Physics, School of Medicine, Isfahan University of Medical Sciences, Isfahan, Iran

3- Department of Computer Science, Shahid Beheshti University, Tehran, Iran

4- Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran

Corresponding Author: Iraj Abedi, Department of Medical Physics, School of Medicine, Isfahan University of Medical Sciences, Isfahan, Iran; Email: Iraj_abedi@yahoo.com