

مقاله اصلی

تولید مجموعه داده ساختگی برای تصاویر توموگرافی انسجام نوری دارای ناهنجاری تخریب ماکولای وابسته به سن

تاریخ دریافت: ۱۴۰۰/۱۲/۲۸ - تاریخ پذیرش: ۱۴۰۱/۰۱/۲۲

خلاصه

مقدمه

توموگرافی انسجام نوری نقش مهمی در چشم پزشکی دارد و آنالیز خودکار این تصاویر از اهمیت زیادی برخوردار است، نیاز به برجسب گذاری و بخش بندی دستی این دادگان توسط چشم پزشک و مشکل دیتای محدود یک چالش در زمینه تصاویر پزشکی است و به تعداد زیادی از آنها برای آموزش الگوریتم‌های مبتنی بر یادگیری عمیق و نیز ارزیابی عملکرد الگوریتم‌های پردازش تصویر نیاز است.

روش کار

داده‌های این طرح شامل مجموعه داده OCT در حضور ناهنجاری شبکیه در بیماری تخریب ماکولای وابسته به سن، اخذ شده از دستگاه AREDS2 Ancillary در دانشگاه دوک می‌باشد. برای آموزش الگوریتم از هفتاد B اسکن که به طور تصادفی از مجموعه فوق انتخاب می‌شوند، استفاده می‌گردد. مدل شکل فعال برای تولید مرزهای مصنوعی بکار رفته است و تصاویر جدید مشابه شکل‌های مجموعه آموزش تولید می‌شوند.

نتایج

با در نظر گرفتن ویژگی‌های آناتومیکی تصاویر موجود مانند تعداد و ضخامت لایه‌ها و همچنین روشنایی مربوط به آن‌ها، دادگانی با مشابهت بالا در حضور ناهنجاری تولید می‌گردند. برای ارزیابی نتایج داده‌های ساختگی توسط چشم پزشک مورد بررسی قرار گرفت.

نتیجه گیری

مدل پیشنهادی با استفاده از ویژگی‌های مهمی مانند مرز لایه‌های اصلی شبکیه و بافت تخریب شده در اثر بیماری، برای پر کردن خلا موجود در تولید داده‌های مصنوعی OCT در حضور ناهنجاری طراحی شده و میتواند به عنوان مجموعه داده برای آموزش الگوریتم‌های مبتنی بر یادگیری عمیق و همچنین ارزیابی عملکرد الگوریتم‌های بخش بندی مورد استفاده قرار گیرد.

کلمات کلیدی

توموگرافی انسجام نوری، تخریب ماکولا وابسته به سن، داده مصنوعی، مدل شکل فعال

پی نوشت: این مطالعه فاقد تضاد منافع می‌باشد.

هاجر دانش^۱

کیوان معقولی^۱

علیرضا دهقانی^۲

راحله کافیه^{۳*}

^۱گروه مهندسی پزشکی، واحد علوم و تحقیقات، دانشگاه آزاد

اسلامی، تهران، ایران

^۲مرکز تحقیقات چشم اصفهان، گروه چشم پزشکی، دانشگاه علوم

پزشکی اصفهان، اصفهان، ایران

^۳دانشکده فناوری‌های نوین پزشکی، مرکز تحقیقات پردازش

تصاویر و سیگنال‌های پزشکی، دانشگاه علوم پزشکی اصفهان،

اصفهان، ایران. دستیار پژوهشی، دانشگاه نیوکاسل، انگلستان

Email: rkafieh@gmail.com

مقدمه

ناهنجاری، توسط چنین مجموعه‌های داده آنلاین آموزش ببینند، حتی در صورت برچسب گذارب توسط پزشکان، تفاوت در پارامترهای خاص دستگاه، اندازه، وضوح، نویز و غیره، بر عملکرد آن‌ها در مجموعه داده‌های موجود تأثیر می‌گذارد. بنابراین افزایش داده‌ها با استفاده از روش ساخت داده‌های مصنوعی، یک روش مناسب است که در آن تصاویر جدید با ظاهری کاملاً مشابه مجموعه کوچک مرجع تولید می‌شوند.

همچنین از آنجایی که برای ارزیابی عملکرد الگوریتم‌های مختلفی که برای بخش بندی لایه‌های شبکیه در حال معرفی هستند نیاز به مجموعه داده دارای برچسب به عنوان مرجع مقایسه وجود دارد، داده‌های تولید شده می‌تواند به عنوان معیاری برای بررسی عملکرد الگوریتم‌های پردازش تصویر نیز مورد استفاده قرار گیرد. بر اساس دانسته‌های ما، تا کنون روش‌های زیادی برای رسیدن به یک تصویر ساختگی فاقد نویز از بافت شبکیه به عنوان مبنایی واقعی برای تست کارایی ابزار پردازش تصویر یا مدل نویز OCT معرفی نشده است؛ و تعدادی از مقالات برای ارزیابی الگوریتم‌های پردازش تصویر پیشنهادی خود از تصاویر ساختگی استفاده نمودند؛ از طرفی این راهکارها بهینه نمی‌باشند چرا که این عکس‌های ساختگی ویژگی‌های تصاویر پزشکی واقعی را توصیف نمی‌کنند.

همچنین روش‌های فعلی برای تولید تصاویر مصنوعی که ویژگی‌های تصاویر واقعی OCT را با وجود پاتولوژی نشان دهند، به طور موفق عمل نکرده اند. آن‌ها نمی‌توانند به درستی داده‌های OCT را شبیه سازی نمایند زیرا تمایل به صاف نمودن داده ها، باعث از دست دادن اطلاعات بافت و حتی اطلاعات پاتولوژی می‌شود چرا که به طور نمونه کیست‌ها به سادگی با این روش‌ها صاف شده و از بین می‌روند.

توموگرافی انسجام نوری Optical Coherence Tomography (OCT) یک روش تصویربرداری غیرتهاجمی است که با استفاده از بازتابش نور مادون قرمز، یک تصویر مقطعی و سه بعدی از بافت شبکیه را فراهم می‌کند. داده‌های OCT از تعدادی تصاویر مقطعی به نام B اسکن تشکیل شده است. هر B اسکن مجموعه ای از ستون‌های تصویری به نام A اسکن را تشکیل می‌دهد که در جهت موازی با انتشار نور در بافت قرار دارد. بافت داخل شبکیه یک ساختار چند لایه است که نور را به سیگنال‌های عصبی برای استفاده در مغز تبدیل می‌کند (۱، ۲). تقسیم بندی دقیق لایه‌های بافت داخل شبکیه در تصاویر توموگرافی انسجام نوری برای تعیین کمی تغییرات مورفولوژیکی در بافت شبکیه و تشخیص بیماری‌های چشمی مانند تخریب ماکولای وابسته به سن Age-Related Macular Degeneration (AMD) و ادم ماکولای دیابتی Diabetic Macular Edema (DME) کاربرد دارد (۳-۷).

امروزه، الگوریتم‌های مبتنی بر یادگیری عمیق به طور گسترده برای تجزیه و تحلیل تصاویر OCT مورد استفاده قرار می‌گیرند و مقالات جدیدتر بر دادگان دارای ناهنجاری‌ها تمرکز دارند (۸-۱۴). برای آموزش چنین الگوریتم‌هایی نیاز به تعداد زیادی داده‌های دارای برچسب (بخش بندی مرزها) می‌باشد و برچسب گذاری داده‌ها توسط چشم پزشک کاری وقت گیر و پرهزینه می‌باشد. بنابراین، داده‌های ساختگی و روش‌های افزایش تعداد داده برای انواع داده‌های پزشکی توسعه یافته است. اگر چه تعداد زیادی از داده‌های OCT به صورت آنلاین در دسترس است، اما این داده‌ها عموماً بدون برچسب بوده به دادگان نرمال اختصاص دارند. بنابراین، اگر الگوریتم‌های مختص دادگاه دارای

مدل آماری برای تولید تصاویر مصنوعی استفاده شد. در (۱۸) دو لایه شبکه (ILM, RPE) برای حجم زیادی از داده‌ها استخراج می‌شود. مشخصات ضخامت برای فاصله بین این دو منطقه محاسبه می‌شود و یک مدل ریاضی از نقشه ضخامت ساخته می‌شود. اکثر روش‌های قبلی از اطلاعات پنهان موجود در داده‌ها استفاده نمی‌کنند و بر روی فرمول‌های محض ریاضی متمرکز شده‌اند تا منحنی‌های OCT را شکل دهند. در (۱۹)، داده‌های مصنوعی با استفاده از داده‌های اصلی دو بعدی ساخته شد. از روش ASM دو بعدی برای ایجاد مرزها استفاده شد. این الگوریتم فقط قادر به پردازش داده‌های سالم بود.

در مطالعات قبلی، تعداد داده‌های تولید شده محدود است و مجموعه داده‌های دارای برجسب آزادانه در دسترس نیستند. الگوریتم ما مجموعه‌ای محدود از OCT‌های دارای برجسب را دریافت می‌کند و تقریباً تعداد نامحدودی از داده‌های مصنوعی را با تغییر پارامترها ارائه می‌دهد. اکثر روش‌های فوق دارای محدودیت‌هایی هستند و بزرگترین محدودیت آن‌ها تمرکز بر روی دادگان سالم می‌باشد که روش‌های پیشنهادی را در حضور ناهنجاری غیر قابل استفاده می‌نمایند.

در این تحقیق، از مدل شکل فعال برای تولید تصاویر ساختگی AMD به عنوان یکی از پیچیده‌ترین بیماری‌ها استفاده می‌شود تا نقایص موجود در روش‌های قبلی را برطرف نموده و یک مجموعه داده جدید ارائه شود. همچنین به جای استفاده از مراحل پیچیده کار قبلی (۱۹) برای تولید داده، ما یک روش جدید ایجاد بافت تصویر را که برای OCT‌های غیر نرمال قابل استفاده است پیشنهاد کردیم. علاوه بر این، تلفیق اطلاعات در تصاویر مصنوعی تولید شده توسط این مدل ما را قادر می‌سازد تا ویژگی‌های تصویر مرجع را شبیه سازی کرده و تأثیرات مختلف شرایط تصویربرداری را نیز در نظر بگیریم.

در تحقیقات انجام شده تفکیک لایه‌های شبکه بر اساس برجسب زنی دستی صورت گرفته که روندی خسته کننده و وقت گیر است و از دقت کافی برخوردار نمی‌باشد. در این تحقیق از روش اتوماتیک برای تفکیک و بخش بندی لایه‌ها استفاده می‌گردد. در این تحقیق، برای ایجاد یک مدل مصنوعی داده‌های OCT شبکه از داده‌های تصاویر واقعی استفاده می‌شود و هر یک از اسکن‌های چشم به منظور استخراج پارامترهای لازم، پردازش می‌شود تا تصاویری مشابه تصاویر اصلی ساخته شود و تصاویر تولید شده ویژگی‌های تصاویر اصلی را دارا می‌باشند. همچنین عملکرد تصویربرداری و ساختار آناتومیک می‌تواند در چشم‌های سالم و چشم‌های پاتولوژیک به دلیل بسیاری از عوامل، از جمله برخی از موارد مرتبط با شرایط آسیب شناسی تحت مطالعه، متفاوت باشد؛ این مدل می‌تواند یک تست انعطاف پذیر ارائه دهد که به راحتی برای این شرایط متفاوت سازگار باشد.


به طور کلی مقالات ارائه شده در مورد ساخت تصاویر OCT شامل ۵ مقاله زیر است:

Serranho از یک مدل ریاضی برای تولید تصاویر OCT مصنوعی استفاده کرد (۱۵). در این مقاله از ۱۰ داده چشم سالم انسان با تقسیم بندی دستی استفاده شده است، سه لایه شبکه استخراج می‌شود (ILM, RPE, OSL) و ۴ ناحیه ایجاد شده در تصاویر با استفاده از توابع ریاضی مدل سازی می‌شود. سپس نویز لکه به تصاویر اضافه می‌شود. شهریان (۱۶) روش سرانهو را با تقسیم ناحیه شبکه به بلوک‌های کوچک و تابع پایه ساده به داده‌ها بهبود بخشید. آنها داده‌های مصنوعی را در حضور کیست‌ها تولید کردند. در این مقالات رگ‌های خونی استخراج نشده است. در (۱۷) تصاویر مصنوعی با استفاده از ویژگی آماری ۱۴ تصویر چشم واقعی از حیوانات مختلف تولید شد. تقسیم بندی اولیه به صورت دستی برای ۷ لایه شبکه انجام شد و از یک

روش کار

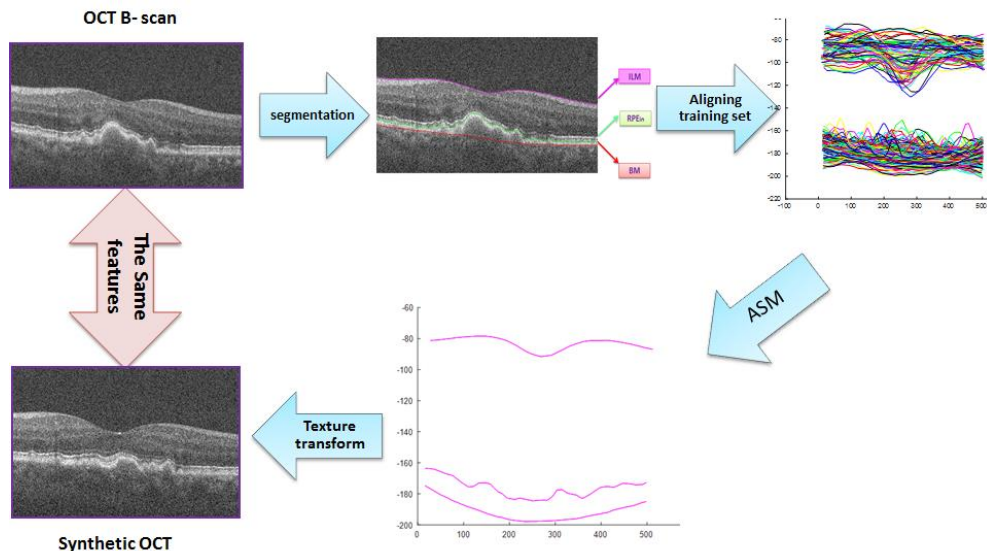
تخریب ماکولا وابسته به سن و یا تخریب لکه زرد یک بیماری چشمی شایع و یکی از علل اصلی از دست دادن بینایی در افراد بالای ۵۰ سال می باشد. در این بیماری به مرور زمان ماکولا یا همان قسمت مرکزی شبکیه چشم دچار آسیب شده و در نتیجه فرد دچار اختلالات بینایی خواهد شد. این بیماری موجب آسیب لکه زرد می شود. لکه زرد نقطه کوچکی نزدیک مرکز شبکیه می باشد که برای دید مرکزی واضح و دقیق لازم است. آسیب ماکولا در قسمت مرکزی شبکیه و از بین رفتن دید مرکزی باعث می شود تا فرد در انجام کارهای ساده روزانه از قبیل دیدن چهره ها، رانندگی، خواندن، نوشتن و... دچار اختلال شود. وجود ناهنجاری هایی مانند AMD اثر مستقیمی بر صافی مرزهای شبکیه دارد، در این بیماری، رسوبات (drusen) در لایه اپیتلیوم رنگدانه شبکیه Retinal Pigment Epithelium (RPE) منجر به بی نظمی و تورم در مرز داخلی RPE می شود. شکل ۱ نمونه ای از تصاویر AMD را به همراه سه مرز اصلی

شبکیه (ILM, RPE, BM) و بی نظمی ایجاد شده در RPE نشان می دهد.



شکل ۱. نمونه ای از B اسکن شبکیه با بیماری AMD

برای آموزش مدل پیشنهادی، مجموعه داده OCT با بیماری AMD، ارایه شده در دانشگاه دوک انتخاب شده است (۲۰). این داده ها از دستگاه AREDS2 Ancillary اخذ شده اند و در آن ها سه مرز ILM, RPE و BM تفکیک شده است. برای آموزش الگوریتم از هفتاد B اسکن که به طور تصادفی از مجموعه فوق انتخاب می شوند استفاده می گردد و از هر مرز ۵۱ نقطه برای مدل سازی انتخاب می گردند. فلوگراف روش پیشنهادی در شکل (۲) نشان داده شده است.



شکل ۲. فلوگراف روش پیشنهادی

۲-۱- مدل توزیع نقطه ای

مدل شکل فعال (ASM) Active Shape Model بصورت کلاسیک برای بخش بندی تصاویر بکار می‌رود ولی تئوری این روش در این تحقیق برای تولید مرزهای مصنوعی بکار رفته است (۲۱، ۲۲). برای توصیف تغییر شکل در مجموعه داده‌های آموزشی، از یک مدل توزیع نقطه ای استفاده شده و اشکال جدید مشابه شکل‌های مجموعه آموزش با استفاده از مدل شکل فعال تولید می‌شوند. مکان نقاط اصلی هر مرز در تصویر با تجزیه و تحلیل موقعیت هندسی نقاط مشابه و ساخت مدل توزیع نقطه تعیین می‌شود. این مدل شامل یک شکل متوسط از مکان نقاط مشخص شده در مرحله آموزش و تعدادی پارامتر برای کنترل اصلی ترین تغییرات در آنها است. تغییر در مختصات این نقاط تغییرات شکل مجموعه داده‌های آموزشی را توصیف می‌کند (۱۹). ابتدا ماتریس نقاط مهم تصاویر آموزش به صورت زیر ساخته می‌شود:

(۱)

$$x_i = (x^1, y^1, \dots, x^n, y^n)^T$$

۲-۲- روش بهینه برای انطباق تصاویر گروه آموزش

برای به حداکثر رساندن ویژگی‌های مشترک بین مرزها و کاهش غیرخطی بودن در توزیع، تصاویر در ابتدا بر اساس مرزها هم تراز می‌شوند. این روش بر اساس مطالعه آماری نقاط علامت گذاری شده بر روی شکل‌های گروه آموزش صورت می‌گیرد. برای اینکه بتوان نقاط مشابه از شکل‌های مختلف را با هم مقایسه نمود، باید آنها را بر اساس یک سری از محورها منطبق نماییم. این کار با تغییر دادن اندازه، مقدار چرخش و تغییر مکان شکل‌های گروه آموزش انجام می‌شود، به نحوی که مرزهای تصاویر تا حد امکان به هم نزدیک شوند. هدف این بهینه سازی، حداقل کردن مجموع وزن

دار مربعات فواصل بین نقاط مشابه در شکل‌های مختلف است. این روش، یک روش بهبود یافته پراک روسترز به حساب می‌آید (۲۳). الگوریتم زیر برای منطبق کردن N تصویر مختلف بکار می‌رود:

همه تصاویر را با تغییر دادن اندازه، مقدار چرخش و تغییر مکان با تصویر اول منطبق کن.

روند زیر را تکرار کن:


- شکل متوسط را از تمام شکل‌های منطبق شده محاسبه کن.

- اندازه، چرخش و تغییر مکان شکل متوسط را نرمالایز کن.

- همه شکل‌ها را با این متوسط جدید منطبق کن.

تا زمانی که الگوریتم همگرا شود، روند فوق را تکرار کن.

شکل ۳ سه لایه تصاویر OCT با بیماری AMD را قبل و بعد از تراز بندی نشان می‌دهد.



شکل ۳. اثرات هم تراز بر روی مرزها، الف) مرزهای اولیه، ب) مرزها بعد از هم تراز

۳-۲- مدل شکل فعال

بهترین زیرفضاهای متناسب با مدل توزیع نقطه ای انطباق یافته، توسط روش تحلیل مولفه اساسی منجر به دستیابی به مجموعه ای با ابعاد $q=1, 2, \dots, m-1$ می‌گردد. برای یک مجموعه داده خاص، ساختارهای نهفته ای وجود دارد که از نظر دور هستند و نیز افزونگی هایی وجود دارند که می‌توانند با حفظ بیشتر اطلاعات، و نه همه اطلاعات مربوط به داده ها، حذف شوند. پس از حذف

۴-۲- تولید تصاویر ساختگی

پس از ساخت مرزهای مصنوعی با استفاده از به روش فوق، از آنجایی که تصاویر بیمار دارای بافت مشخصی نیستند و محل رگ‌ها و روشنایی لایه‌های مختلف در آن‌ها طبق الگوی مشخصی نیست و روش پیشنهادی در (۱۹) برای آن‌ها قابل استفاده نمی‌باشد. روش جدید پیشنهاد شده در این تحقیق، برای ساخت بافت در تصویر دارای ناهنجاری ارائه شده است. در این روش ویژگی‌های لایه‌ها شامل مشخصات بافت، تغییرات شدت و رگ‌های خونی از داده‌های مشابه OCT (داده مرجع) در مجموعه آموزش به داده‌های مصنوعی منتقل می‌شوند. به این منظور، داده‌ها به صورت ستونی انتخاب شده، با تغییر در اندازه، به ستون جدید منتقل می‌شوند. برای یافتن تصویر مرجع، شباهت داده‌های ساخته شده به داده‌های آموزش بر اساس شکل مرز اول تعیین می‌شود (۱۹). به این منظور، پس از تراز نمودن تصاویر، یک منحنی درجه ۳ بر یک سوم وسط مرز اول در تصاویر آموزش و تصاویر ساختگی فیت می‌گردد و با مقایسه اختلاف پارامترهای منحنی در تصاویر ایجاد شده و تصاویر اصلی شبیه‌ترین تصویر به تصویر ساخته شده مشخص می‌گردد.

نتایج

برای نشان دادن این واقعیت که تغییرات b_i ، نمونه‌های مختلفی از تصاویر مصنوعی AMD را ایجاد می‌کند، سه نمونه از تصاویر ساختگی تولید شده که شبیه یک تصویر مرجع هستند و با پارامترهای مختلف b_i تولید شده اند در شکل ۴ برای دو مورد از تصاویر مرجع نشان داده شده است.

این افزونگی ها، می‌توانیم داده‌ها را تقریباً به طور کامل در یک فضای q بعدی نشان دهیم (۲۴). پس از تجزیه و تحلیل مولفه اصلی بر روی بردارهای شکل تراز شده S ماتریس کوواریانس با استفاده از رابطه زیر محاسبه می‌شود:

$$S = \frac{1}{N} \sum_{i=1}^N (\bar{x} - x_i)(\bar{x} - x_i)^T$$

(۲)

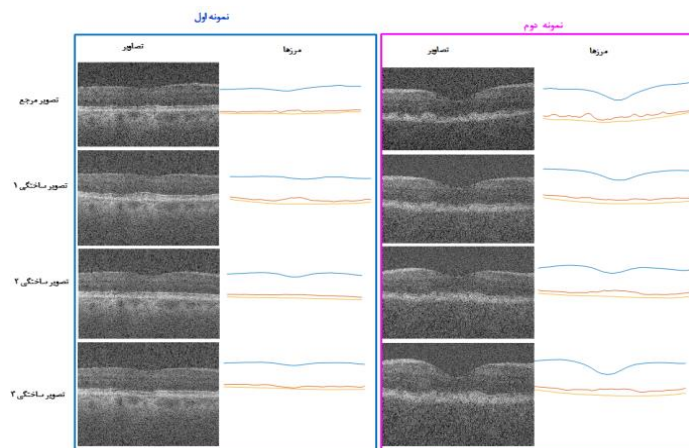
\bar{x} شکل متوسط تصاویر تراز شده می‌باشد. بردارهای ویژه (p_i) و مقادیر ویژه (σ_i) ماتریس کوواریانس محاسبه می‌شوند، تا خصوصیات آماری شکل بدست آید. هر شکل موجود در مجموعه را می‌توان با استفاده از معادله زیر تخمین زد:

$$X \cong \bar{x} + P * b \quad (۳)$$

که در آن $b = (b_1, b_2, \dots, b_i)^T, i = (1, \dots, t)$ بردارهای ویژه ماتریس همبستگی مربوط به t بزرگترین مقادیر ویژه است. معادله ۳ هسته اصلی مدل ترکیبی پیشنهادی است و به ما امکان می‌دهد با تغییر مقادیر بردار b ، تصاویر جدید ایجاد کنیم. این پارامترها دارای استقلال خطی هستند، اگرچه ممکن است به صورت غیر خطی به هم وابسته شوند. محدودیت مقادیر این پارامترها نیز با مطالعه توزیع آن‌ها در تصاویر آموزشی تعیین می‌شود. در ضمن، می‌توان برای اطمینان از تغییر پارامترها در محدوده مجاز، محدوده مشخصی را برای مقادیر تعیین کرد. با توجه به داده‌های آموزش، محدودیت را می‌توان به شرح زیر تعریف کرد (۲۵):

$$-3\sqrt{\sigma_i} \leq b_i \leq +3\sqrt{\sigma_i} \quad (۴)$$


با تغییر t پارامتر اول، می‌توان نمونه‌های مشابهی از اشکال آموزش ایجاد کرد. هر یک از این پارامترها یکی از حالت‌های تغییر را نشان می‌دهند و نوع خاصی از تغییرات را مدل می‌کنند.



شکل ۴. نمونه هایی از تصاویر AMD ساختگی به دست آمده از یک تصویر مرجع. تصویر مرجع در ردیف ۱ و تصاویر ساختگی در ردیف های ۲ تا ۴ نشان داده شده اند. مرزهای مربوطه در ستون های سمت راستی نشان داده شده است.

اما شبیه آن هستند. این به ما امکان ایجاد تعداد زیادی تصویر می دهد که منجر به افزایش داده های قابل توجهی از مجموعه داده واقعی شده و می تواند در آموزش الگوریتم های مبتنی بر یادگیری عمیق استفاده شود.

همچنین در شکل ۵، عملکرد روش پیشنهادی برای تصاویر مرجع مختلف نمایش داده شده است. همانطور که در شکل ۴ و ۵ نشان داده شد، مرزها و ویژگی های تصاویر مصنوعی دقیقاً با تصویر مرجع مطابقت ندارند




شکل ۵. داده های ساختگی با استفاده از تصاویر مرجع مختلف، الف: مرزهای ساختگی، ب: تصاویر ساختگی

بحث

هر ترکیب متفاوت از b_1 یک داده OCT جدید تولید کند. همانطور که مشاهده می شود زمانی که b_2 بزرگتر از $2\sqrt{\sigma_2}$ است شکل مرز اول دارای بالا زدگی می شود و داده های مطلوبی تولید نمی شود. همچنین این محدودیت برای b_2 کوچکتر از $-3\sqrt{\sigma_2}$ برقرار است. لذا می توان محدودیت های بیشتری را بر روی برخی b_1 ها اعمال نمود.

مقادیر b_1 می تواند شکل ظاهری داده ی مرزها را تغییر داده و منجر به تولید مجموعه داده های جدید شود. شکل ۶ این تاثیر را با جزئیات بیشتر به طور نمونه برای سه پارامتر اول نشان می دهد. هر ردیف با تغییر مقدار یکی از b_1 ها (مطابق معادله ۳) ایجاد می شود (b_1 در ردیف اول، b_2 در ردیف دوم، ...). مقدار $3\sqrt{\sigma_1}$ در معادله ۴ برای اطمینان از عدم تولید داده های دور طراحی شده است. انتظار می رود



شکل ۶. اثرات تغییر سه پارامتر اول مدل

آن‌ها با روش پیشنهادی مورد بحث قرار می‌گیرد. برای ارائه مقایسه بصری با برخی از روش‌های قبلی، در شکل ۷ نمونه‌های داده‌های مصنوعی از کارهای قبلی در مقایسه با روش پیشنهادی نشان داده شده است. این شکل ویژگی‌هایی مانند نسخه بدون نویز، و تولید تصاویر متعدد را نشان می‌دهد. Serranho (۱۵) و Montuoro (۱۸) قادر به تولید OCT‌های دو بعدی و داده‌های بدون نویز هستند. با این حال، هر دوی آنها شامل اطلاعات مهمی از داده‌های واقعی نیستند. به عنوان مثال، روش Serranho حضور رنگ‌ها را نادیده می‌گیرد. در مطالعات قبلی، تعداد داده‌های تولید شده محدود است و مجموعه داده‌های تولید شده دارای برچسب نیستند. علاوه بر این، هر دو روش مکان مرزها را از تصویر اصلی حفظ می‌کنند و مرزهای جدیدی ساخته نمی‌شوند. الگوریتم پیشنهادی مجموعه محدودی از OCT‌های دارای برچسب را دریافت می‌کند و تقریباً تعداد نامحدودی داده مصنوعی دارای برچسب را با تغییر پارامترها فراهم می‌کند. از طرف دیگر، روش‌های قبلی فقط برای OCT نرمال ایجاد شده اند و موارد پیچیده همراه با ناهنجاری را نادیده گرفته اند. در این


برای ارزیابی نتایج تعداد ۲۰ داده واقعی و ۲۰ داده ساختگی توسط چشم پزشک مورد بررسی قرار گرفت. با توجه به ویژگی‌های تصاویر به نسبت واقعی بودن آن‌ها امتیازهایی با استفاده از مقایسه ۰ تا ۵ (۵ کاملاً واقعی، ۰ کاملاً دور از واقعیت) به تصاویر اختصاص داده شد. میانگین و انحراف معیار امتیازها برای تصاویر ساختگی برابر 1.14 ± 3.05 و برای تصاویر واقعی برابر 1.18 ± 4.02 می‌باشد. که نشان دهنده کیفیت و دقت تصاویر ساخته شده با وجود بیماری و بی‌نظمی‌های موجود در تصاویر است.

نتیجه گیری

مدل پیشنهادی با استفاده از ویژگی‌های مهمی مانند مرز لایه‌های اصلی شبکیه و بافت تخریب شده در اثر بیماری، برای پر کردن خلا موجود در تولید داده‌های مصنوعی OCT در حضور ناهنجاری طراحی شده است. از آنجایی که کدها یا مجموعه داده‌های روش‌های قبلی به صورت آنلاین موجود نیستند. بنابراین، بسته به تصاویر ارائه شده در مقالات منتشر شده، روش‌ها را به صورت بصری با هم مقایسه و شباهت‌ها و تفاوت‌های

استفاده می‌شود، که در مرحله آموزش به تعداد زیادی داده دارای برچسب نیاز دارد. مقدار کم داده‌های برچسب دار در صورت وجود ناهنجاری‌ها محدودیت اصلی در روش‌های یادگیری عمیق است و با تولید داده‌های مصنوعی با روش پیشنهادی می‌توان این مشکل را حل کرد. ویژگی دیگر روش پیشنهادی تولید داده‌های دارای برچسب است که آن را به عنوان کاندیدایی ایده آل برای اندازه گیری عملکرد الگوریتم‌های بخش بندی معرفی می‌کند.

تحقیق، روش پیشنهادی برای کار با موارد دارای بیماری AMD، به عنوان یکی از پیچیده ترین و مخرب ترین بیماری‌های شبکیه، شرح داده شده است. با ارایه روش جدید ایجاد بافت تصویر به جای استفاده از مراحل پیچیده کارهای قبلی (۱۹) ما یک روش ساده انتقال بافت را در این مقاله پیشنهاد نمودیم که برای OCT‌های غیرنرمال قابل استفاده است. در این روش اطلاعات بافتی داده‌ها با توجه به داده‌های مرجع حفظ می‌شوند. امروزه از الگوریتم‌های یادگیری عمیق برای پردازش تصویر OCT در صورت وجود ناهنجاری



شکل ۷. مقایسه روش‌های موجود با روش پیشنهادی.

نمایش پایدار نباشند. ما می‌توانیم اطمینان حاصل کنیم که روش پیشنهادی یک تقویت واقعی در مورد مرزهای تولید شده است و هر الگوریتم یادگیری ماشینی با تاکید بر مرزها می‌تواند از داده‌های تقویت شده به درستی استفاده کند. رگ‌ها، همانطور که قبلاً توضیح داده شد،

روش پیشنهادی از محدودیت‌هایی نیز رنج می‌برد. همانطور که در بالا مورد بحث قرار گرفت، روش پیشنهادی می‌تواند اطلاعات مهمی را در مورد محل مرزها، رگ‌ها و بافت حفظ کند. با این حال، هر یک از پارامترهای ذکر شده ممکن است در همه موارد یک

ممکن است با نمونه گیری پراکنده ما نادیده گرفته شود و به درستی مدل سازی نشود. بنابراین، بخش بندی بسیار دقیق مرزها و ناهنجاری ها توسط یک متخصص بسیار مهم است. در نتیجه، روش پیشنهادی شکاف در روش های مصنوعی OCT قبلی را با پرداختن به مسائل پیچیده مانند وجود ناهنجاری ها پر می کند. علیرغم محدودیت های غیرقابل انکار، نشان داده شده است که این روش قادر به مدل سازی مرزها و بافت داده های OCT است و یک روش تقویت قابل قبول برای روش های آینده است که به تعداد زیادی از داده های OCT برچسب دار نیاز دارند.

به لحاظ بصری ارزیابی می شوند که شباهت قابل قبولی با داده های اصلی دارند، با این حال، تطابق بسیار دقیق را نمی توان تضمین کرد. از آنجایی که بسیاری از مقالات با استفاده از تحلیل بافت اطلاعات را استخراج می کنند، روش پیشنهادی برای داده های غیرنرمال می تواند اطلاعات بافت کامل را با به دست آوردن بافت از مشابه ترین تصویر در داده های آموزشی استخراج نماید. یک محدودیت دیگر، پیچیدگی و بار محاسباتی بالا در زمانی که تعداد نقاط زیادی برای مدل سازی مرزها استفاده می شوند می باشد. روش پیشنهادی بر محل دقیق نقاط در مرحله آموزش متکی است و اگر تعداد کمی از نقاط شاخص به درستی انتخاب نشوند، محل ناهنجاری

References

1. J.M.Schmitt, "Optical coherence tomography (OCT): a review," *IEEE Journal of Selected Topics in Quantum Electronics* 5(4): , doi: :10.1109/2944.796348.
2. D. Huang, E. A. Swanson, C. P. Lin, J. S. Schuman, W. G. Stinson, W. Chang, M. R. Hee, T. Flotte *et al.*, "Optical coherence tomography," Massachusetts Institute of Technology, Whitaker College of Health Sciences and Technology, 1993 .
3. J. A. Sousa, A. Paiva, A. Silva, J. D. Almeida, G. Braz Junior, J. O. Diniz, W. K. Figueredo, and M. Gattass, "Automatic segmentation of retinal layers in OCT images with intermediate age-related macular degeneration using U-Net and DexiNed," *Plos one*, vol. 16, no. 5, p. e0251591, 2021, doi: 10.1371/journal.pone.0251591.
4. D. Mahapatra, B. Bozorgtabar, and L. Shao, "Pathological retinal region segmentation from oct images using geometric relation based augmentation," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020, pp. 9611-9620 .
5. Z. Chen, D. Li, H. Shen, Y. Mo, H. Wei, and P. Ouyang, "Automated retinal layer segmentation in OCT images of age-related macular degeneration," *IET Image Processing*, vol. 13, no. 11, pp. 1824-1834, 2019, doi: 10.1049/iet-ipr.2018.5304.
6. A. Shirokanev, N. Ilyasova, N. Demin, and E. Zamyckij, "Extracting a DME area based on graph-based image segmentation and collation of OCT retinal images," in *Journal of Physics: Conference Series*, 2021, vol. 1780, no. 1: IOP Publishing, p. 012031 .
7. N. Ilyasova, A. Shirokanev, N. Demin, and R. Paringer, "Graph-Based Segmentation for Diabetic Macular Edema Selection in OCT Images," in *2019 5th International Conference on Frontiers of Signal Processing (ICFSP)*, 2019: IEEE, pp. 77-81 .
8. Z. Mishra, A. Ganegoda, J. Selicha, Z. Wang, S. R. Sadda, and Z. Hu, "Automated Retinal Layer Segmentation Using Graph-based Algorithm Incorporating Deep-learning-derived Information," *Scientific Reports*, vol. 10, no. 1, pp. 1-8, 2020, doi: 10.1038/s41598-020-66355-5.
9. Y. He, A. Carass, Y. Liu, B. M. Jedynek, S .D. Solomon, S. Saidha, P. A. Calabresi, and J. L. Prince, "Deep learning based topology guaranteed surface and MME segmentation of multiple sclerosis subjects from retinal OCT," *Biomedical optics express*, vol. 10, no. 10, pp. 5042-5058, 2019, doi: 10.1364/BOE.10.005042.
10. D. Lu, M. Heisler, S. Lee, G. W. Ding, E. Navajas, M. V. Sarunic, and M. F. Beg, "Deep-learning based multiclass retinal fluid segmentation and detection in optical coherence tomography images using a fully convolutional neural network," *Medical image analysis*, vol. 54, pp. 100-110, 2019, doi: 10.1016/j.media.2019.02.011.

11. Z. Wang, Y. Zhong, M. Yao, Y. Ma, W. Zhang, C. Li, Z. Tao, Q. Jiang *et al.*, "Automated segmentation of macular edema for the diagnosis of ocular disease using deep learning method," *Scientific Reports*, vol. 11, no. 1, pp. 1-12, 2021, doi: 10.1038/s41598-021-92458-8.
12. K. Alsaih, M. Z. Yusoff, T. B. Tang, I. Faye, and F. Mériaudeau, "Deep learning architectures analysis for age-related macular degeneration segmentation on optical coherence tomography scans," *Computer methods and programs in biomedicine*, vol. 195, p. 105566, 2020, doi: 10.1016/j.cmpb.2020.105566.
13. M. Pekala, N. Joshi, T. A. Liu, N. M. Bressler, D. C. DeBuc, and P. Burlina, "Deep learning based retinal OCT segmentation," *Computers in biology and medicine*, vol. 114, p. 103445, 2019, doi: 10.1016/j.compbiomed.2019.103445.
14. J. Kugelman, D. Alonso-Caneiro, Y. Chen, S. Arunachalam, D. Huang, N. Vallis, M. J. Collins, and F. K. Chen, "Retinal boundary segmentation in stargardt disease optical coherence tomography images using automated deep learning," *Translational vision science & technology*, vol. 9, no. 11, pp. 12-12, 2020, doi: 10.1167/tvst.9.11.12.
15. P. Serranho, C. Maduro, T. Santos, J. Cunha-Vaz, and R. Bernardes, "Synthetic oct data for image processing performance testing," in *2011 18th IEEE International Conference on Image Processing*, 2011: IEEE, pp. 401-404.
16. E. S. Varnousfaderani, W.-D. Vogl, J. Wu, B. S. Gerendas, C. Simader, G. Langs, S. M. Waldstein, and U. Schmidt-Erfurth, "Improve synthetic retinal OCT images with present of pathologies and textural information," in *Medical Imaging 2016: Image Processing*, 2016, vol. 9784: International Society for Optics and Photonics, p. 97843V.
17. P. Kulkarni, D. Lozano, G. Zouridakis, and M. Twa, "A statistical model of retinal optical coherence tomography image data," in *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2011: IEEE, pp. 6127-6130.
18. A. Montuoro, S. M. Waldstein, B. Gerendas, G. Langs, C. Simader, and U. Schmidt-Erfurth, "Statistical retinal OCT appearance models," *Investigative ophthalmology & visual science*, vol. 55, no. 13, pp. 4808-4808, 2014.
19. H. Danesh, K. Maghooli, A. Dehghani, and R. Kafieh, "Automatic production of synthetic labelled OCT images using an active shape model," *IET Image Processing*, vol. 14, no. 15, pp. 3812-3818, 2020, doi: 10.1049/iet-ipr.2020.0075.
20. S. J. Chiu, J. A. Izatt, R. V. O'Connell, K. P. Winter, C. A. Toth, and S. Farsiu, "Validated automatic segmentation of AMD pathology including drusen and geographic atrophy in SD-OCT images," *Investigative ophthalmology & visual science*, vol. 53, no. 1, pp. 53-61, 2012.
21. B. E. Cootes, T. Graham, J. , "An introduction to active shape models," *Image processing and analysis*, vol. 223-48., 2000.
22. T. F. Cootes, C. J. Taylor, D. H. Cooper, and J. Graham, "Active shape models-their training and application," *Computer vision and image understanding*, vol. 61, no. 1, pp. 38-59, 1995.
23. J. C. Gower, "Generalized procrustes analysis," *Psychometrika*, vol. 40, no. 1, pp. 33-51, 1975.
24. R. Reris and J. P. Brooks, "Principal component analysis and optimization: A tutorial," 2015.
25. G. Hamarneh, R. Abu-Gharbieh, T. Gustavsson, and R. Abu-gharbieh, "Active shape models-part i: Modeling shape and gray level variations," 1998.

Original Article

Production of Synthetic Dataset for Optical Coherence Tomography Images with Age-Related Macular Edema

Received: 19/03/2022 - Accepted: 16/04/2022

Hajar Danesh¹
Keivan Maghooli¹
Alireza Dehghani²
Raheleh Kafieh^{3*}

¹ Department of Biomedical Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

² Isfahan Eye Research Center, Department of Ophthalmology, Isfahan University of Medical Sciences, Isfahan, Iran

³ School of Advanced Technologies in Medicine, Medical Image and Signal Processing Research Center, Isfahan University of Medical Sciences, Isfahan, Iran. Research Associate, Newcastle University, UK

Email: rkafieh@gmail.com

Abstract

Introduction: Today, retinal optical coherence tomography (OCT) plays an important role in ophthalmology and automated analysis of OCT images is very important. The need for labeled data and manual segmentation of these data by the ophthalmologist and limited labeled data are challenges in the field of medical imaging and a large number of labeled data is needed to train deep learning algorithms as well as to evaluate the performance of image processing algorithms.

Materials and Methods: The data of this project include OCT dataset in the presence of retinal abnormality in age-related macular degeneration disease, obtained from AREDS2 Ancillary device at Duke University. Seventy B scans that are randomly selected from the above set are used to train the algorithm. The active shape model is used to generate synthetic boundaries, and new images are produced similar to the shapes in the training set.

Results: Considering the anatomical features of the existing images such as the number and thickness of the layers as well as the brightness related to them, data with high similarity are produced in the presence of anomalies. Synthetic data were reviewed by an ophthalmologist to evaluate the results.

Conclusion: The proposed model is designed to fill the gap in the production of OCT Synthetic data in the presence of anomalies, using important features such as the boundary of the main layers of the retina and disease-damaged tissue, and can be used as a data set for training deep learning-based algorithms as well as performance of segmentation algorithms.

Key words: Optical coherence tomography, synthetic data, age related macular degeneration, active shape model.

Acknowledgement: There is no conflict of interest.