

شبکه‌های عصبی در تحلیل اطلاعات فازی از تصاویر شبکه چشم

حامد فهیمی، جلال چاچی* و احمد کاظمی فرد

دانشگاه شهید چمران اهواز، دانشکده علوم ریاضی و کامپیوتر، گروه علوم کامپیوتر
دانشگاه شهید چمران اهواز، دانشکده علوم ریاضی و کامپیوتر، گروه آمار
دانشگاه شهید چمران اهواز، دانشکده علوم ریاضی و کامپیوتر، گروه ریاضی

تاریخ دریافت: ۱۴۰۰/۸/۲۵

تاریخ پذیرش: ۱۴۰۰/۱۲/۱۲

چکیده


در این مقاله به تحلیل اطلاعات نادقیق از تصاویر شبکه چشم انسان در قالب یک کیت قابل نصب بر گوشی‌های هوشمند پرداخته شده است. در این خصوص این منظور در چارچوب یادگیری عمیق و بر اساس اطلاعات نادقیق حاصل از تصاویر لایه‌های شبکه به آموزش یک شبکه انتها-به-انتها به منظور تحلیل و قطعه‌بندی لایه‌های شبکه مبادرت شده است. نتیجه این مطالعه به معرفی یک کیت قابل نصب بر گوشی‌های هوشمند ختم می‌شود که با استفاده از آن به راحتی و به آسانی می‌توان بر بینایی کاربران نظارت داشت.

۱ مقدمه

روش توموگرافی همدوس نوری OCT^۱ یک فناوری بدیع برای قطعه‌بندی تصویر با دقت بالاست که از نور به جای تصویربرداری ماوراءصوت استفاده می‌کند. از این روش به خصوص در اسکن چشم برای اندازه‌گیری ضخامت شبکه استفاده می‌شود که این امر بیش


^۱Optical Coherence Tomography (OCT)

عبارات و کلمات کلیدی: شبکه، شبکه‌های عصبی، اطلاعات فازی، یادگیری عمیق، تصمیم‌گیری چند شاخصه.



شکل ۱: نمونه سخت افزار اسکن چشم قابل نصب بر گوشی‌های هوشمند به همراه عکس گرفته شده از چشم

از چند دقیقه زمانبر نیست. امروزه همچنین سخت افزارهای کاربردی و مناسبی برای پرینت قطعات سه بعدی وجود دارد که به راحتی و با هزینه‌ای مناسب می‌توان آن‌ها را تولید نمود. شکل ۱ نمایی از این سخت‌افزار که بر روی یک گوشی هوشمند نصب شده است را نشان می‌دهد. این سخت‌افزارها این امکان را فراهم می‌سازند که پس از نصب بر گوشی‌های هوشمند، تصاویری با کیفیت بسیار بالا از چشم تهیه کنند. در این راستا برخی مطالعات در خصوص سیستم‌های OCT سیار برای اندازه‌گیری سریع لایه‌های چشم صورت پذیرفته است [۷]، به‌ویژه از آن منظر که قطعه‌بندی تصاویر OCT شبکیه به لایه‌های شبکیه تشکیل دهنده آن، یکی از مراحل مهم در تحلیل خودکار تصاویر OCT است. شکل ۲ نمونه تصویر OCT به همراه قطعه‌بندی ۷ لایه اصلی شبکیه که به ترتیب از بالا به پایین نام‌های اختصاری ILM ، $IPL - NFL$ ، INL ، OPL ، $ISM - ONL$ ، ISE و $RPE - OS$ دارند را نشان می‌دهد. نواحی بالا و پایین شبکیه به ترتیب RaR و RbR نامگذاری شده‌اند. به طور کلی روش‌های قطعه‌بندی ارائه شده در تحقیقات را می‌توان بر اساس الگوریتم مورد استفاده به دو گروه تقسیم کرد. گروه اول روش‌های سنتی قطعه‌بندی هستند که مدلی را برای توصیف ساختار تصاویر ورودی جستجو می‌کنند. این مدل سپس به عنوان قیودی در قطعه‌بندی استفاده می‌شود، مانند $A - Scan$ [۲۱]، کانتور فعال [۹]، روش‌های مبتنی بر گراف [۷]، و روش‌های



شکل ۲: نمونه اسکن OCT از شبکیه (سمت چپ) به همراه قطعه‌بندی لایه‌های شبکیه (سمت راست)

هوشمند [۲۲]. دسته دیگری از روش‌های قطعه‌بندی سعی می‌کنند تا با تقلید ادراک انسان نمایانگرترین ویژگی‌ها را بر مبنای گزاره‌های زبانی^۲ و اطلاعات فازی از هر لایه شبکیه یا مرزهای آن استخراج کنند. بسیاری از این رویکردها در محیط فازی و با استفاده از اطلاعات مبهم/فازی/نادقیق به تحلیل اطلاعات می‌پردازند. به عنوان نمونه دودو و همکاران [۶] بر انعطاف‌پذیری پردازش تصاویر فازی به منظور انتقال اطلاعات پیشین از تصاویر OCT به الگوریتم قطعه‌بندی تاکید می‌کنند. دودو و همکاران [۵] روشی بر مبنای هیستوگرام‌های فازی به منظور بهینه‌سازی جریان پیشینه متوالی در قطعه‌بندی چهار لایه از شبکیه را ارائه دادند. سلطان‌زاده و رضایی [۲۰] یک رویکرد کاملاً خودکار را برای تخمین کران‌های حفره‌ای در قطعه‌بندی‌های شبکیه با استفاده از سیستم‌های فازی معرفی نمودند. دسته دیگری از رویکردهای معرفی شده مبتنی بر روش‌هایی هستند که از آنها برای تعیین مرزهای لایه‌ها مانند روش‌های طبقه‌بندی کننده مبتنی بر ماشین بردار پشتیبان و/یا شبکه‌های عصبی استفاده می‌شود [۱۵]. یادگیری عمیق^۳ و یکی از انواع پرکاربرد و متداول آن یعنی شبکه‌های عصبی کانولوشنی^۴ در سال‌های اخیر مورد علاقه محققین در زمینه‌های مختلف بوده است [۱۴]. روش ارائه شده در [۱۳] ساختارهای طبقه‌بندی معروف را به ساختار شبکه تمام کانولوشنی تبدیل و سپس در مرحله آموزش آن را برای مسأله قطعه‌بندی تنظیم می‌کند. علاوه بر این برای بهبود جزئیات قطعه‌بندی، مفهوم اتصالات پرشی^۵ برای ترکیب اطلاعات کلی از لایه‌های

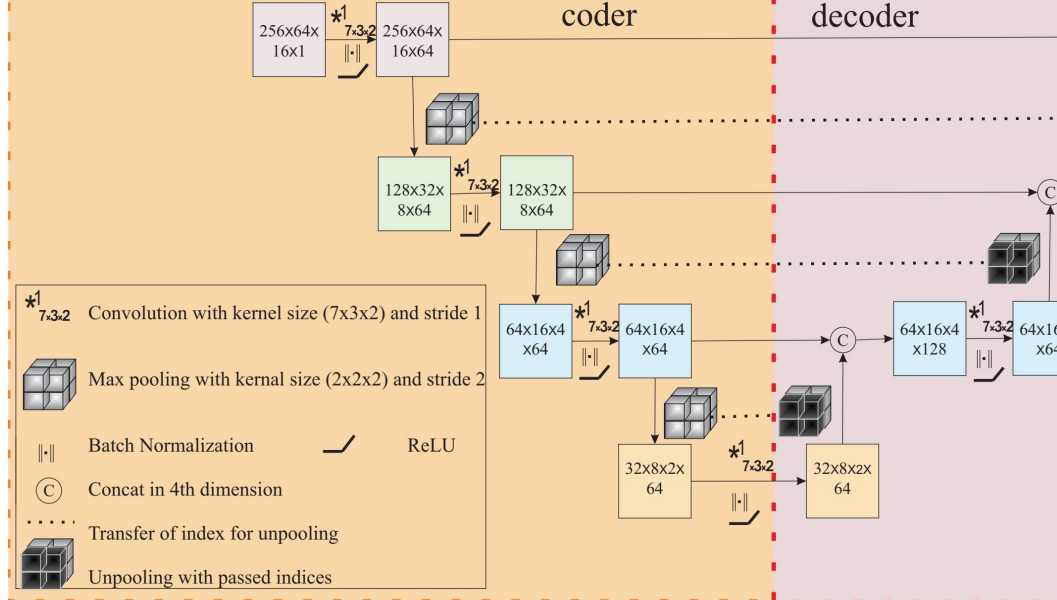
^۲Linguistic-Terms

^۳Deep-learning

^۴Convolutional-Neural-Network-(CNN)

^۵Skip-Connections

عمیق‌تر با اطلاعات جزئی از لایه‌های کم-عمق استفاده می‌شود. معرفی و به کارگیری ساختارهای مبتنی بر کدکننده-کدگشا، شامل DeconvNet با لایه‌های افزایش ابعاد دهنده^۶ به جای درونیابی، یکپارچگی مکانی قطعه‌بندی را بهبود می‌دهد [۱۶]. استفاده از شبکه U-Net که در آن اتصالات پرشی در ساختار کدکننده-کدگشا به کار گرفته می‌شود، کارایی آموزش را در حالت داده آموزش کم و محدود می‌کند [۱۷]. در کاربرد قطعه‌بندی خودکار لایه‌های شبکه‌ی، در پژوهش [۷] پیش‌بینی‌های احتمالی شبکه CNN با یک روش جستجوی گراف ترکیب شده است و پس از آن یک چارچوب شبکه CNN انتها-به-انتها که مبتنی بر روش‌های قطعه‌بندی عمیق در [۱۳] است، برای کاربرد قطعه‌بندی لایه‌های شبکه‌ی در تصاویر دوبعدی ارائه می‌شود. با این حال بیشتر روش‌های قطعه‌بندی نام برده شده براساس تصاویر دو بعدی OCT هستند و تاثیر استفاده از تصاویر حجمی سه بعدی، کمتر مورد توجه قرار گرفته است. قطعه‌بندی تصاویر سه بعدی تنها در سال‌های اخیر به ندرت و معمولاً در روش‌های مبتنی بر گراف سه بعدی مورد توجه بوده است [۱۹]. در برخی از این روش‌ها هر گره از گراف متناظر با یک بخش مکعبی از داده‌های سه بعدی در نظر گرفته می‌شود. مثلاً روش ارائه شده در [۱۲] مساله قطعه‌بندی سه بعدی را به یافتن مجموعه بسته با هزینه کمینه در گراف هندسی با یال‌های وزن داده شده متناظر تبدیل می‌کند. گراف موردنظر از اطلاعات لبه‌های تصویر و قیدهای تعاملی ساخته می‌شود. تعمیم این روش برای تصاویر حوزه طیفی که از نرم‌افزار قطعه‌بندی لایه‌های شبکه‌ی OCTExplorer استفاده می‌کند در [۸] بیان شده است. این نرم‌افزار از همبستگی میان اسکن‌های مجاور برای قطعه‌بندی استفاده می‌کند. به‌ویژه یک ساختار سه بعدی انتها-به-انتهای کانولوشن برای قطعه‌بندی لایه‌های چشمی OCT در [۱۱] ارائه شده است. حاصل پژوهش حاضر، ابداع یک کیت شخصی برای گوشی‌های هوشمند است که در آن از طریق قطعه‌بندی لایه‌های شبکه‌ی چشمی بیمار، بینایی وی تحت نظارت قرار می‌گیرد. نتایج مشاهدات مبتنی بر داده‌های واقعی نشان می‌دهد که دقت و عملکرد نتایج حاصل از آن به میانگین قضاوت‌های گروهی از چشم پزشکان متخصص بسیار نزدیک است. در ادامه و در بخش ۲ ساختار شبکه عمیق ارائه شده، اجزای آن و همچنین جزئیات مرحله آموزش شرح داده می‌شود. بخش ۳ مراحل عملیاتی و تجاری‌سازی این



شکل ۳: ساختار شبکه عمیق ارائه شده برای قطعه‌بندی لایه‌های OCT

طرح به‌طور خلاصه بیان می‌کند. در بخش ۴ با معرفی اجمالی رویکرد این پژوهش در تحلیل داده‌ها در چارچوب تصمیم‌گیری‌های چندشاخصه به مقایسه نتایج حاصل از رهیافت معرفی شده و قضاوت‌های گروهی از پزشکان متخصص پرداخته شده است. نهایتاً بخش ۵ به نتیجه‌گیریهای این پژوهش اختصاص دارد.

۲ شبکه عمیق طراحی شده برای قطعه‌بندی تصاویر

ساختار شبکه ارائه شده در شکل ۳ را که نشانگر شبکه مورد بحث در این مقاله است در نظر می‌گیریم. این شبکه از یک بخش کدکننده که کاهش دهنده ابعاد تصویر است و به دنبال آن یک بخش کدگشا که افزایش دهنده ابعاد تصویر است تشکیل شده است. اتصالات پرشی ویژگی‌های میانی را از کدکننده به بخش متناظر در کدگشا از طریق لایه ادغام‌کننده^۷ منتقل می‌کند. در انتها نیز یک لایه طبقه‌بندی کننده قرار دارد. هر یک از بلوک‌های تشکیل دهنده در ادامه شرح داده می‌شود.

^۷Concatenation-Layer

۱.۲ بخش کدکننده

این بخش از چهار لایه اصلی که به دنبال هم قرار گرفته‌اند تشکیل شده است. این لایه‌ها به ترتیب عبارتند از لایه کانولوشن، لایه نرمال‌کننده دسته داده^۸، تابع فعال‌کننده غیر خطی (نوع واحد خطی یکسوکننده^۹) و لایه تجمیع‌کننده^{۱۰}. فیلترهای کانولوشن برای تمام بلوک‌های کدکننده مکعب‌هایی با ابعاد $2 \times 3 \times 7$ تعریف می‌شوند. ابعاد فیلترها به گونه‌ای انتخاب می‌شوند که ویژگی‌ها در آخرین بلوک کدکننده تمام بخش‌های شبکه چشم را دربرگیرد. مرزهای ورودی فیلترها با صفر پر می‌شوند^{۱۱} تا قبل و بعد از لایه کانولوشن دارای ابعاد یکسانی باشند. یک لایه نرمال‌سازی دسته داده پس از لایه کانولوشن برای جبران شیفت متغیرها و جلوگیری از بیش-برازش در هنگام آموزش منظور می‌شود. لایه ReLU واردکننده اثر غیرخطی در شبکه است. پس از آن لایه max-pooling ابعاد ویژگی‌ها را به نصف کاهش می‌دهد. اندیس‌های متناظر با مقادیر حذف نشده در این عملگر ذخیره و در بخش جداساز^{۱۲} متناظر در بخش کدگشا برای افزایش ابعاد استفاده می‌شوند که سبب حفظ یکپارچگی مکانی می‌گردد.

۲.۲ بخش کدگشا

این بخش از پنج لایه اصلی به نام‌های لایه جداساز، لایه ادغام، لایه کانولوشن، لایه نرمال‌کننده دسته داده و لایه تابع فعال‌سازی ReLU تشکیل شده است. لایه جداساز، ابعاد و ویژگی‌های خروجی بلوک قبلی در کدگشا با استفاده از اندیس‌های لایه تجمیع‌کننده از بلوک متناظر در کدکننده را به دو برابر افزایش داده و در مکان‌های دیگر صفر قرار می‌دهد. چنین حرکتی سبب می‌شود که برخلاف استفاده از درون‌یابی برای افزایش ابعاد، اطلاعات مکانی نیز به خوبی حفظ شوند. این موضوع برای قطعه‌بندی دقیق لایه‌های نزدیک به fovea که شامل بخش‌های بسیار ظریفی از ساختمان چشم بوده و تاثیر بسیار زیادی بر بینایی دارند، بسیار مهم است زیرا اغلب ضخامتی برابر چند پیکسل دارند و

Batch-Normalization^۸
 Rectified-Linear-Unit-ReLU^۹
 Pooling^{۱۰}
 Zero-Padding^{۱۱}
 Unpooling^{۱۲}

درون‌یابی خطی می‌تواند به مرزبندی‌های نادرستی منجر شده و تخمین غیر قابل اطمینانی از ضخامت لایه‌ها را نتیجه دهد. پس از آن، اتصالات پرشی وجود دارند که ویژگی‌های خروجی را از بلوک کدکننده متناظر منتقل می‌کنند و این ویژگی‌ها توسط لایه ادغام‌کننده در کنار خروجی لایه جداساز قرار داده می‌شوند. مزیت چنین اتصالات پرشی از دو جهت است:

۱. اتصالات با اضافه کردن اطلاعات ویژگی‌ها از بخش کدکننده وضوح بالاتری را نتیجه می‌دهند.

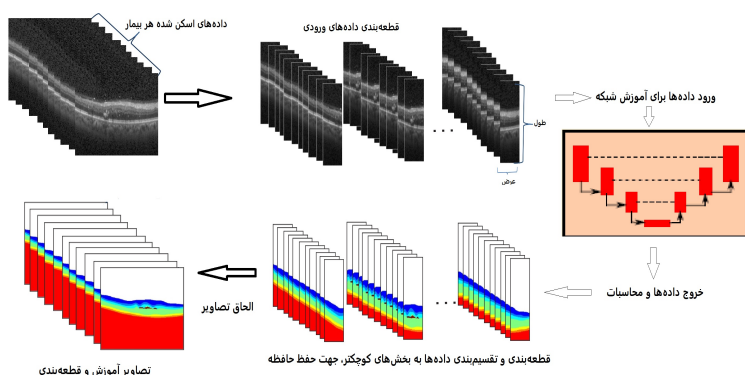
۲. این اتصالات جریان‌گردایان را به بخش کدکننده در طول آموزش منتقل می‌کنند که سبب کاهش خطر محوشدگی‌گردایان می‌شود (به ویژه زمانی که تعداد لایه‌های مدل افزایش می‌یابد). سپس به دنبال آن لایه کانولوشن، لایه نرمال‌کننده دسته داده و تابع ReLU قرار دارند که در واقع ویژگی‌های افزایش ابعاد داده شده را چگال/مترکم می‌کنند.

۳.۲ بخش طبقه‌بندی‌کننده

آخرین بلوک کدگشا شامل یک لایه کانولوشن با فیلتر با بعد یک (برای کاهش کانال‌های ویژگی‌ها بدون تغییر ابعاد مکانی) به منظور نگاشت ۶۴ کانال ویژگی به ۱۰ کانال ویژگی متناسب با ۱۰ کلاس می‌باشد. در پایان لایه softmax وجود دارد که احتمال تعلق داشتن هر پیکسل را به هر یک از ۱۰ کلاس موجود، تخمین می‌زند.

۴.۲ آموزش شبکه

آموزش شبکه با تصاویر و با اندازه کامل محدود به حافظه RAM در GPU است. اما از طرفی استفاده از دسته داده‌های با حجم کم اغلب‌گردایان‌های نویری ایجاد می‌کنند که منجر به نتایج نامطلوبی به‌ویژه در همگرایی‌ها می‌شود. برای حل این مشکل در مرحله آموزش از تقطیع تصاویر به برش‌های عمودی استفاده می‌کنیم که در شکل ۴ نشان داده شده است. علاوه بر این تعداد داده‌ها با در نظر گرفتن برگردان^{۱۳} افقی و انتقال مکانی



شکل ۴: تقطیع تصاویر به برش‌های عمودی در مرحله آموزش به دلیل ملاحظات حافظه

داده‌های موجود افزایش داده می‌شود. در مرحله پیش‌بینی، تصاویر با اندازه‌های کامل مورد استفاده قرار می‌گیرند که یک قطعه‌بندی مناسب را نتیجه می‌دهد.

۵.۲ معیار آنتروپی متقاطع

معیار آنتروپی متقاطع^{۱۴} شباهت احتمال‌های بین برچسب‌های واقعی و پیش‌بینی شده را نشان می‌دهد. متوسط آنتروپی متقاطع تمام کلاس‌ها به عنوان تابع هزینه در نظر گرفته شده و مطابق رابطه زیر تعریف می‌شود [۱۱]

$$L = - \sum g_l(x) \log(p_l(x)),$$

که در آن $p_l(x)$ احتمال تخمین زده شده تعلق پیکسل x به کلاس l و $g_l(x)$ برداری از صفر/یک بیانگر قطعه‌بندی معیار از پزشک متخصص با مقادیر یک برای برچسب‌های درست و صفر برای بقیه برچسب‌هاست. در این تابع در هر پیکسل در مکان x هرچه احتمال پیش‌بینی شده $p_l(x)$ از مقدار یک انحراف بیشتری داشته باشد، مقدار بزرگتری را نتیجه می‌دهد. در زمان آموزش، همچنین جملات مربوط به نرم اندازه وزن‌های شبکه نیز به این تابع هزینه با ضریب ۰/۰۰۱ اضافه می‌شوند.

^{۱۴}Cross-Entropy

۳ کاربرد و ارزیابی اقتصادی و فنی طرح

۱.۳ کاربرد طرح

شبکیه بخشی از چشم است که اطلاعات بسیار زیادی درباره بدن و سلامتی فرد در بر دارد. بنابراین پیش‌بینی می‌شود کیت ارائه شده از جهات زیر مورد توجه کاربران قرار گیرد:

۱. افرادی که ساکن روستاها و مناطق دورافتاده هستند و توانایی دسترسی آسان و سریع به پزشکان متخصص را ندارند.

۲. افرادی پرمشغله‌ای که زمان مراجعه به مراکز معاینه چشم را ندارند.

۳. افرادی که بیماری‌های خاص دارند و ناچار به مراجعه مکرر به مراکز پزشکی هستند. به عنوان مثال تشخیص روند عود بیماری ام.اس. با استفاده از تصاویر MRI مغز و نخاع امکان‌پذیر است، اما نمی‌توان زمان شروع دقیق علائم بیماری را مشخص نمود. نتیجه تحقیقات نشان داده است که روش اسکن OCT می‌تواند به عنوان یک روش مکمل، نظارت بر عود بیماری ام.اس. را تسهیل کند. اندازه‌گیری ضخامت شبکیه در اسکن OCT بیماران نشان داده است که شبکیه چشم در مراحل اولیه و فعالیت بیماری به سرعت نازک می‌شود. بنابراین روش اسکن OCT می‌تواند روند عود ام.اس. را به سرعت مشخص کند.

۲.۳ ارزیابی اقتصادی طرح

الگوریتم‌های یادگیری عمیق ارائه شده در پروژه متشکل از شبکه‌های عصبی کانولوشن است، که محاسبات آن در یک قصعه سخت افزاری برنامه‌ریزی می‌شود. شرکت NVIDIA در حال حاضر با GPU های موازی متعدد و ارایه چارچوب‌های قدرتمند برنامه‌نویسی GPU تحت عنوان CUDA یکی از پرچم‌داران ارایه سخت افزارهای یادگیری عمیق است. محاسبات مربوط به مرحله آموزش شبکه عمیق بر Nvidia GB ۱۱ دارد. شرکت این انجام می‌گیرد که قیمتی در حدود ۱۰۰۰ دلار امریکا دارد. مرحله آموزش این شبکه به زمانی در حدود یک هفته نیازمند است. محاسباتی که در گوشی هوشمند در استفاده از این کیت در مرحله پیش‌بینی انجام می‌شود، حجم بسیار

کمی در مقایسه با مرحله آموزش دارد و تنها شامل محاسبات پیشخور در شبکه آموزش دیده است. چنین مزیتی زمان پیش‌بینی شبکه برای تصویر ورودی را بسیار کم و در حدود $ms 10$ برای هر B-Scan، می‌سازد که به راحتی در گوشی‌های هوشمند اجرا می‌شود. با افزایش زمان محاسبات میزان مصرف شارژ گوشی را باید در نظر گرفت که شاخص بسیار مهمی برای طراحی سخت افزاری روش‌ها به شمار می‌رود.

۳.۳ ارزیابی فنی طرح

شبکه ارائه شده بر داده‌های واقعی جمع‌آوری شده از بیماران ماکولای دیابتی مورد ارزیابی قرار گرفته است. این داده‌ها از 110 تصویر با ابعاد 512×512 مربوط به ده بیمار (۱۱ تصویر برای هر بیمار) تشکیل شده است. 11 تصویر مربوط به هر بیمار شامل یک تصویر در fovea و 5 تصویر در هر طرف آن که در فواصل زمانی 2 ، 5 ، 10 ، 15 و 20 ثانیه گرفته شده‌اند. تصاویر برای تمام لایه‌های شبکه و نواحی آنگونه توسط گروهی از پزشکان متخصص نشانه‌گذاری و قطع‌بندی می‌شوند تا از آنها برای آموزش شبکه عمیق استفاده شود. روش بهینه‌سازی گرادیان کاهشی^{۱۵} با نرخ یادگیری 0.01 بر دسته داده‌های (batch-size) با اندازه 30 اجرا می‌شود. نشانه‌گذاری‌های گروه اول چشم پزشکان متخصص برای آموزش مورد استفاده قرار می‌گیرد و نشانه‌گذاری‌های گوه دوم چشم پزشکان متخصص تنها برای فرآیند ارزیابی مورد استفاده قرار می‌گیرد. محاسبات مربوط به آموزش شبکه عمیق بر سیستم با مشخصات CPU Xeon Intel با $32GB$ RAM و $11GB$ Nvidia GTX 1080 GPU انجام می‌گیرد.

^{۱۵} Stochastic-Gradient-Descent

۴ مقایسه نتایج عددی رویکرد پیشنهادی با قضاوت‌های چشم پزشکان متخصص در چارچوب رهیافت تصمیم‌گیری‌های چندشاخصه (MADM)

۱.۴ رهیافت تصمیم‌گیری‌های چندشاخصه

هر مسئله تصمیم‌گیری چندشاخصه عبارت است از انتخاب یک یا چند گزینه از بین تعدادی متناهی گزینه موجود با نظر داشت تعدادی متناهی شاخص $[۱, ۳, ۴, ۱۰]$. در این چارچوب، فرض بر این است که $A = \{A_1, \dots, A_m\}$ مجموعه‌ای متناهی از گزینه‌ها و $C = \{C_1, \dots, C_n\}$ مجموعه‌ای متناهی از معیارها یا شاخص‌های ارزیابی باشد. معمولاً وضعیت گزینه‌های تصمیم در ارتباط با شاخص‌های مساله در قالب ماتریس تصمیم $D = [d_{ij}]_{n \times m}$ ، $i = 1, \dots, n$ و $j = 1, \dots, m$ نشان داده می‌شود که در آن d_{ij} به معنی وضعیت گزینه j ام در ارتباط با شاخص i ام است. اگر چه دسته‌بندی‌های وسیعی در رابطه با روش‌های متنوع تصمیم‌گیری چندشاخصه وجود دارد که هر یک مبتنی بر پیش فرض‌ها و شرایط مسایل تصمیم‌گیری قابل به‌کارگیری هستند اما از میان روش TOPSIS دارای سطح دقت بسیار بالا و ظرافت قابل توجهی جهت تحلیل رتبه‌بندی گزینه‌ها است و از این رو همواره مورد توجه پژوهشگران حوزه تصمیم‌گیری‌های چندشاخصه بوده و تعمیم‌های متعددی نیز از آن به ثبت رسیده است [۲]. در ادامه الگوریتم تاپسیس که در آن از آنتروپی شانون به منظور وزن‌دهی شاخص‌ها استفاده شده است، بیان می‌شود. الگوریتم تاپسیس با وزن‌دهی آنتروپی ورودی: گزینه‌ها $A = \{A_1, \dots, A_m\}$ ، شاخص‌ها $C = \{C_1, \dots, C_n\}$ و ماتریس تصمیم‌گیری $D_{n \times m}$. خروجی: رتبه‌بندی گزینه‌های $A = \{A_1, \dots, A_m\}$. گام‌های الگوریتم:

۱. نرمال‌سازی اقلیدسی ماتریس تصمیم $D_{n \times m}$ را به صورت زیر انجام دهید

$$\delta_{ij} = \frac{d_{ij}}{\sqrt{\sum_{j=1}^m d_{ij}^2}}, \quad i = 1, \dots, n, \quad j = 1, \dots, m.$$

۲. ماتریس وزن‌های نرمال شده $W = \text{diag}[w_1, \dots, w_n]_{n \times n}$ را تعیین کنید و

قرار دهید $\Lambda = \mathbf{W} \times \Delta = [\lambda_{ij}]_{n \times m}$. در این الگوریتم از آنتروپی شانون برای وزن‌یابی شاخص‌ها استفاده می‌شود. برای اینکار، گام‌های زیر را انجام دهید:

(آ) ماتریس تصمیم $\mathbf{D}_{n \times m}$ را به صورت زیر نرمال کنید

$$\varepsilon_{ij} = \frac{d_{ij}}{\sum_{j=1}^m d_{ij}}, \quad i = 1, \dots, n, \quad j = 1, \dots, m.$$

(ب) اندازه آنتروپی هر سطر را به صورت زیر محاسبه نمایید

$$E_i = -\frac{1}{\ln(m)} \sum_{j=1}^m \varepsilon_{ij} \ln(\varepsilon_{ij}), \quad i = 1, \dots, n.$$

(ج) بردار وزن شاخص‌ها یعنی $\mathbf{w} = [w_1, \dots, w_n]_{1 \times n}$ را به صورت زیر تعیین کنید

$$w_i = \frac{1 - E_i}{\sum_{l=1}^n (1 - E_l)}, \quad i = 1, \dots, n.$$

۳. گزینه‌های ایده‌آل و ضد ایده‌آل را به صورت زیر مشخص کنید

$$R^+ = [\lambda_1^+, \dots, \lambda_n^+] = \{(\max_j \lambda_{ij} | i \in B), (\min_j \lambda_{ij} | i \in B')\},$$

$$R^- = [\lambda_1^-, \dots, \lambda_n^-] = \{(\min_j \lambda_{ij} | i \in B), (\max_j \lambda_{ij} | i \in B')\}.$$

که $B \cup B' = \{1, \dots, n\}$ ، $B' \subseteq \{1, \dots, n\}$ ، $B \subseteq \{1, \dots, n\}$ و $B \cap B' = \emptyset$ به ترتیب مجموعه اندیس‌های معیارهای سود و زیان را تعیین و مشخص می‌کنند.

۴. با استفاده از فاصله اقلیدسی انحراف گزینه زام از گزینه‌های ایده‌آل و ضد ایده‌آل را

به صورت زیر محاسبه کنید

$$d_j^+ = \sqrt{\sum_{i=1}^n (\lambda_{ij} - \lambda_j^+)^2}, \quad j = 1, \dots, m,$$

$$d_j^- = \sqrt{\sum_{i=1}^n (\lambda_{ij} - \lambda_j^-)^2}, \quad j = 1, \dots, m,$$

۵. نزدیکی نسبی گزینه j ام به گزینه‌های ایده‌آل را به صورت زیر محاسبه نمایید

$$L_j = \frac{d_j^-}{d_j^- + d_j^+}, \quad j = 1, \dots, m.$$


۶. با رتبه‌بندی مقادیر $\{L_1, \dots, L_m\}$ ، بهترین گزینه را به صورت زیر انتخاب کنید

$$j^* = \operatorname{argmax}_{j \in \{1, \dots, m\}} \{L_1, \dots, L_m\}. \quad (۱)$$

۲.۴ جمع‌آوری داده‌ها

برای بررسی و مقایسه عملکرد رویکرد ارائه شده در چارچوب رهیافت تصمیم‌گیری چند شاخصه ابتدا باید ماتریس تصمیم‌گیری ساماندهی شود. لذا به منظور استخراج نتایج رویکرد پیشنهادی، ابتدا داده‌ها به دو بخش آموزش، که شامل اطلاعات ۸ بیمار و بخش تست، که شامل اطلاعات ۲ بیمار باقی مانده است، تقسیم شده است. آموزش تعداد ۸ شبکه طبقه‌بندی کننده با استفاده از روش ارزیابی متقاطع^{۱۶} با ۸ دسته بر داده‌های آموزش انجام گرفته است. یک مقایسه بصری از عملکرد روش ارائه شده بر داده‌های تست در برابر نتایج قطعه‌بندی گروه اول چشم پزشکان متخصص در شکل ۵ نشان داده شده است. نتایج حاصل از عملکرد تنها یک پیش‌بینی کننده^{۱۷} و همچنین پیش‌بینی گروهی^{۱۸} طبقه‌بندی کننده‌های آموزش داده شده توسط رویکرد CE (خطای منحنی مرزهای

Cross-Validation^{۱۶}
 Single-Prediction^{۱۷}
 Ensemble-Prediction^{۱۸}



شکل ۵: بصری‌سازی پیش‌بینی‌ها و خروجی‌های شبکه‌های ارائه شده (سمت راست: خروجی شبکه ساده و سمت چپ: خروجی شبکه چندحالتی)

پیش‌بینی شده بین لایه‌ها و مرزهای تعیین شده توسط گروه اول چشم پزشکان متخصص) و رویکرد DICE (درصد همپوشانی ناحیه پیش‌بینی شده با قطعه‌بندی معیار) مورد ارزیابی قرار گرفت [۱۱]. نتایج این دو رویکرد و نتایج نهایی به ترتیب در ماتریس‌های تصمیم‌گیری در جدول ۱ و جدول ۲ گزارش شده است. در این جداول نتایج رویکردها برای انطباق قطعه‌بندی گروه دوم چشم پزشکان متخصص با قطعه‌بندی گروه اول چشم پزشکان متخصص نشان داده شده است.

۳.۴ مقایسه توان تشخیصی دستگاه

در ادامه هدف این است که بر اساس الگوریتم تاپسیس-آنتروپی به رتبه‌بندی گزینه‌های سه‌گانه ماتریس تصمیم که از قرار زیر هستند، پرداخته شود:

جدول ۱: ماتریس تصمیم بر اساس نتایج رویکردهای استخراج شده از ساختار شبکه عمیق ارائه شده برای قطعه‌بندی لایه‌های OCT بر مبنای رویکرد DICE (که دارای مطلوبیت صعودی است و مقادیر ۷ سطر اول ماتریس تصمیم مربوط به آن است) و رویکرد CE (که دارای مطلوبیت نزولی است و مقادیر ۷ سطر انتهایی ماتریس تصمیم مربوط به آن است)

Expert	Deep - net (ensemble)	Deep - net (single)	Items
۰.۸۶	۰.۹۰	۰.۸۵	ILM_{dice}
۰.۹۰	۰.۹۲	۰.۹۰	$NFL - IPL_{dice}$
۰.۷۹	۰.۸۱	۰.۷۸	INL_{dice}
۰.۷۴	۰.۸۲	۰.۷۵	OPL_{dice}
۰.۹۲	۰.۹۲	۰.۸۹	$ONLI_{ISM_{dice}}$
۰.۸۶	۰.۹۱	۰.۸۸	ISE_{dice}
۰.۸۲	۰.۹۰	۰.۸۶	$OS - RPE_{dice}$
۱.۱۴	۱.۰۸	۱.۱۲	ILM_{ce}
۱.۶۸	۱.۴۱	۱.۵۹	$NFL - IPL_{ce}$
۱.۶۸	۱.۴۸	۱.۷۱	INL_{ce}
۱.۷۲	۱.۶۶	۱.۶۸	OPL_{ce}
۱.۹۵	۱.۸۴	۱.۸۱	$ONL - ISM_{ce}$
۱.۱۰	۰.۹۸	۱.۰۷	ISE_{ce}
۱.۲۷	۱.۰۱	۱.۱۴	$OS - RPE_{ce}$

جدول ۲: نتایج اعمال الگوریتم تاپسیس بر ماتریس تصمیم جدول ۱.

Expert	Deep - net (ensemble)	Deep - net (single)	TOPSIS Rank
۰.۴۹۸۳۶۴۹	۰.۴۹۸۵۰۰۳	۰.۴۹۸۲۹۷۱	۲
۲	۱	۳	

۱. Expert: میانگین نظرات گروه چشم پزشکان متخصص که به صورت گزاره‌های زبانی و یا مجموعه‌های فازی ثبت شده‌اند.

۲. Deep net (ensemble): شبکه عمیق که از چند لایه در قطعه‌بندی‌ها و آموزش استفاده می‌کند.

۳. Deep net (single): شبکه عمیق که از یک لایه در قطعه‌بندی و آموزش استفاده می‌کند.

در این ماتریس تصمیم، شاخص‌ها (سطرهای ماتریس تصمیم) ۲ سری از هفت لایه شبکه هستند که توسط پزشکان متخصص مشخص شده‌اند. این هفت لایه طی دو مرحله با رویکردهای تشابه DICE و اندازه خطای CE ارزیابی شده‌اند تا ماتریس تصمیم جدول حاصل شود. اکنون با اعمال الگوریتم تاپسیس-آنتروپی بر ماتریس تصمیم‌گیری جدول ۱، نتایج رتبه‌بندی جدول ۲ حاصل می‌شود. نتایج حاصل از روش تاپسیس بیانگر آن است که با رویکرد پیشنهادی پژوهش حاضر با دو روش برنامه‌نویسی، بسیار مشابه و نزدیک به اجماع گروه چشم پزشکان متخصص است. مقایسه پیش‌بینی گروهی شبکه‌ها با نتایج تنها یک شبکه برای قطعه‌بندی لایه‌های شبکه در جدول ۱ تأیید می‌کنند که استفاده

از مدل‌های گروهی به بهبود عملکرد قطعه‌بندی منجر می‌شود ولی زمان پیش‌بینی را افزایش می‌دهد. مقایسه نتایج روش ارائه شده با میانگین قضاوت‌های گروه دوم چشم پزشکان متخصص نشان می‌دهد که روش ارائه شده حتی گاهی بهتر از پیش‌بینی‌های انسان متخصص عمل می‌کند.

۵ نتیجه‌گیری

در این مقاله دستاوردهای حاصل از پروژه طراحی یک کیت با کاربرد در تسهیل پایش بینایی کاربران ارائه شد. این سیستم شامل یک ساختار انتها-به-انتها مبتنی بر یادگیری عمیق برای تحلیل و قطعه‌بندی لایه‌های شبکه است که برخلاف روش‌های سنتی نیاز به استخراج دستی ویژگی‌ها از تصویر ورودی را حذف می‌کند. این شبکه از یک بخش کدکننده، با هدف کاهش ابعاد تصویر، و به دنبال آن یک بخش کدگشا، با هدف افزایش ابعاد تصویر، تشکیل شده است. اتصالات پرشی برای ترکیب اطلاعات کلی از لایه‌های عمیق‌تر با اطلاعات جزئی از لایه‌های کم عمق و در نتیجه بهبود جزئیات قطعه‌بندی در این ساختار استفاده می‌شوند. زمان پیش‌بینی شبکه آموزش دیده برای تصاویر OCT ورودی در حدود 10ms برای هر B-Scan قابل مقایسه با تحلیل متخصص انسانی است. نوآوری اصلی طرح ارائه شده در آن است که این کیت تحلیلی ساده قابل نصب بر گوشی‌های هوشمند با سیستم‌های عامل‌های مختلف اندروید و iOS می‌باشد. نتایج حاصل از این دستگاه با دو حالت برنامه‌ریزی شده با اجماع نظرات پزشکان متخصص در چارچوب رهیافت تصمیم‌گیری‌های چند شاخصه مورد مقایسه قرار گرفت. از روش تاپسیس برای مقایسه نتایج حاصل شده استفاده شد. نزدیکی مقادیر حاصل شده از روش تاپسیس گویای این واقعیت است که کیت نتایجی نزدیک با قضاوت‌های چشم پزشکان متخصص دارد هرچه که در برنامه‌نویسی چندلایه میزان خطای کیت کمتر از میزان خطای قضاوت‌های پزشکان متخصص است. به نظر می‌رسد که با برنامه‌نویسی‌های پیشرفته و تعیین بهینه و یا حتی با آزمون و خطای مقادیر پارامترهای ورودی و خروجی شبکه عصبی به‌کار رفته، نتایج بهتری توسط کیت تشخیصی پیشنهاد شده در این مقاله، حاصل شود. این موارد بستر مناسبی برای تحقیقات آتی در این زمینه را پیشنهاد می‌دهد. به عنوان نمونه، پیاده‌سازی روش و سیستم ارائه شده در این مقاله در رابطه با دیگر اختلالات

چشمی و حتی اختلالات قسمت‌های دیگر بدن انسان، از جمله تشخیص بهینه و دقیق مرز تومورها (به علت عدم مرزبندی دقیق در بافت‌های سرطانی) امکان‌پذیر است. همچنین در مطالعات جامعی، می‌توان از سایر روش‌ها و فرآیندهای *MADM* جهت مقایسات مربوطه نیز استفاده نمود.

مراجع

[۱] چاچی، ج.، کاظمی فرد، ا. و فهیمی، ح. (۱۴۰۰). رهیافت تصمیم‌گیری‌های چند معیاره در ارزیابی نیکویی برازش مدل‌های آماری، سیستم‌های فازی و کاربردها، دوره ۴، شماره ۱، ص ۲۴۷-۲۶۷.

[۲] کاظمی فرد، ا. (۱۳۹۹). یک تعمیم از مدل تصمیم‌گیری چندشاخصه‌ی *TOPSIS* مبتنی بر یکنواخت‌سازی مطلوبیت شاخص‌ها، مجله مدلسازی پیشرفته ریاضی، دوره ۱۰، شماره ۱، ص ۱۹۶-۲۱۴.

[۳] کاظمی فرد، ا. و صادقیان، ر. تصمیم‌گیری‌های چند معیاره، انتشارات دانش‌پرور، ۱۳۹۷.

[4] Chachi, J., Kazemifard, A., Jalalvand, M. (2021). A multi-attribute assessment of fuzzy regression models, *Iranian Journal of Fuzzy Systems*, 18, 131-148.

[5] Dodo, B.I., Li, Y., Liu, X. (2017). Retinal OCT image segmentation using fuzzy histogram hyperbolization and continuous max-flow و *IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)*, pp. 745-750.

[6] Dodo, B.I., Li, Y., Tucker, A., Liu, X. (2019). Retinal OCT segmentation using fuzzy region competition and level set methods, *IEEE 32nd International Symposium on Computer-Based Medical Systems (CBMS)*, pp. 93-98.

[7] Fang, L., Cunefare, D., Wang, C., Guymer, R.H., Li, S., Farsiu, S. (2017). Automatic segmentation of nine retinal layer boundaries in OCT images of non-

- exudative AMD patients using deep learning and graph search, *Biomedical Optics Express*, 8, 2732-2744.
- [8] Garvin, M.K., Abramoff, M.D., Wu, X., Russell, S.R., Burns, T.L., Sonka, M. (2009). Automated 3-D intraretinal layer segmentation of macular spectral-domain optical coherence tomography images, *IEEE Transactions on Medical Imaging*, 28, 1436-1447.
- [9] González-López, A., de Moura, J., Novo, J., Ortega, M., Penedo, M.G. (2019). Robust segmentation of retinal layers in optical coherence tomography images based on a multistage active contour model, *Heliyon*, 5(2), pp 01271.
- [10] Kazemifard, A., Chachi, J. (2021). MADM approach to analyse the performance of fuzzy regression models, *J. Ambient Intell. Human. Comput.* <https://doi.org/10.1007/s12652-021-03394-4>.
- [11] Kiaee, F., Fahimi, H., Rabbani, H. (2018). Intra-retinal layer segmentation of optical coherence tomography using 3d fully convolutional networks, In 2018 25th IEEE International Conference on Image Processing (ICIP), pp. 2795-2799.
- [12] Lee, K., Niemeijer, M., Garvin, M.K., Kwon, Y.H., Sonka, M., Abramoff, M.D. (2009). Segmentation of the optic disc in 3-D OCT scans of the optic nerve head, *IEEE Transactions on Medical Imaging*, 29, 159-168.
- [13] Long, J., Shelhamer, E., Darrell, T. (2015). Fully convolutional networks for semantic segmentation, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 3431-3440.
- [14] Lu, D., Heisler, M., Lee, S., Ding, G.W., Navajas, E., Sarunic, M.V., Beg, M.F. (2019). Deep-learning based multiclass retinal fluid segmentation and detection in optical coherence tomography images using a fully convolutional neural network. *Medical Image Analysis*, 54, 100-110.

- [15] McDonough, K., Kolmanovsky, I., Glybina, I.V. (2015). A neural network approach to retinal layer boundary identification from optical coherence tomography images, In 2015 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB), pp. 1-8.
- [16] Noh, H., Hong, S., Han, B. (2015). Learning deconvolution network for semantic segmentation, In Proceedings of the IEEE International Conference on Computer Vision (pp. 1520-1528).
- [17] Ronneberger, O., Fischer, P., Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation, In International Conference on Medical Image Computing and Computer-Assisted Intervention, pp. 234-241, Springer, Cham.
- [18] Roy, A.G., Conjeti, S., Karri, S.P.K., Sheet, D., Katouzian, A., Wachinger, C., Navab, N. (2017). ReLayNet: retinal layer and fluid segmentation of macular optical coherence tomography using fully convolutional networks, *Biomedical Optics Express*, 8, 3627-3642.
- [19] Sleman, A.A., Soliman, A., Elsharkawy, M., Giridharan, G., Ghazal, M., Sandhu, H., Schaal, S., Keynton, R., Elmaghraby, A., El-Baz, A. (2021). A novel 3D segmentation approach for extracting retinal layers from optical coherence tomography images, *Medical Physics*, 48, 1584-1595.
- [20] H. Soltanizadeha, H., Rezaee Oshterinana, S. (2014). Fully Automated lumen detection in intravascular OCT images by using fuzzy system, *International Journal of Engineering and Technology sciences* 2, 388-389.
- [21] Xu, J., Tolliver, D.A., Ishikawa, H., Wollstein, G., Schuman, J.S. (2009). 3D OCT retinal vessel segmentation based on boosting learning. In *World Congress on Medical Physics and Biomedical Engineering*, September 7-12, 2009, Munich, Germany (pp. 179-182). Springer, Berlin, Heidelberg.

- [22] Zacks, J.M., Speer, N.K., Swallow, K.M., Maley, C.J. (2010). The brain's cutting-room floor: Segmentation of narrative cinema, *Frontiers in human neuroscience*, 4, 168.