

نقشه برداری بطن چپ قلب در حالت پایان دیاستولی در تصاویر اکوکاردیوگرافی با استفاده از یک شبکه عصبی عمیق هم آمیختی

مسلم درویشی

دانشجوی دکتری - دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران - ایران
پست الکترونیکی: darvishim@ut.ac.ir

مهدی آخوندزاده هنزائی*

دانشیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران - ایران
پست الکترونیکی: makhonz@ut.ac.ir

فهیمة درویشی

دانشجوی پزشکی عمومی - دانشکده پزشکی - دانشگاه علوم پزشکی همدان - ایران
پست الکترونیکی: fahimedarvishi95@gmail.com

چکیده

شده متناسب با روش‌های یادگیری عمیق می‌باشد. در این تحقیق دو حالت استفاده از داده‌های اولیه و تقویت داده‌ها با روش افزودنی داده مورد بررسی قرار گرفته است که تقویت داده موجب افزایش دقت و کارایی شبکه عصبی هم آمیختی پیشنهادی شده است. دقت کلی برآورد نقشه بطن چپ قلب در حالت پایان دیاستولی با استفاده از روش پیشنهادی در بهترین حالت ۹۷٫۹۹٪ و امتیاز F1 برای آن برابر با ۸۹٫۲۱٪ می‌باشد.


واژه‌های کلیدی: یادگیری عمیق، نقشه برداری، شبکه عصبی هم آمیختی، اکوکاردیوگرافی، بطن چپ قلب

۱- مقدمه

بررسی عملکرد قلب و شناسایی بیماری‌های احتمالی آن بر اساس تفسیر تصاویر دوبعدی اکوکاردیوگرافی^۱

تشخیص بیماری و بررسی کارایی قلب بر مبنای تصاویر اکوکاردیوگرافی از گذشته تاکنون مورد توجه پزشکان متخصص در این زمینه بوده است. در دهه‌های اخیر جهت کاهش خطای انسانی در تفسیر تصاویر پزشکی ارائه یک روش مبتنی بر یادگیری ماشین همواره مورد توجه محققان هوش مصنوعی بوده است. در این تحقیق یک روش یادگیری عمیق مبتنی بر شبکه‌های عصبی هم آمیختی جهت استخراج نقشه بطن چپ قلب در حالت پایان دیاستولی ارائه گردیده است. یکی از مهم‌ترین چالش‌ها در الگوریتم‌های یادگیری عمیق فراهم نمودن داده‌های آموزشی مناسب جهت یادگیری ماشین است، در این تحقیق از داده‌های ارائه شده توسط محققان بیمارستان دانشگاهی اتینن واقع در کشور فرانسه تحت عنوان CAMUS استفاده شده است که حجم داده ارائه

* نویسنده مسئول



شکل ۱: قلب انسان

شده است که بر پایه آموزش یک شبکه عصبی با ساختار رمزگذار-رمزگشا ابتدا آموزش لازم برای شبکه عصبی صورت پذیرفته است سپس با استفاده از داده‌های کنترلی به ارزیابی روش پیشنهادی پرداخته شده است به طور کلی از ۴۵۰ تصویر موجود، ۴۰۱ مورد جهت آموزش و ۴۹ مورد جهت ارزیابی مورد استفاده قرار گرفته اند.

در این تحقیق با هدف توسعه روش‌های هوشمند در تحلیل تصاویر پزشکی و تشخیص نارسایی در عملکرد قلب بر مبنای هوش مصنوعی به نقشه‌برداری از قلب در حالت پایان دیاستولی با استفاده از شبکه عصبی هم‌آمیختگی عمیق پرداخته شده است، استفاده از داده‌های مرجع بروز و پیاده‌سازی شبکه عصبی پیشنهادی بر روی این داده‌ها و ارزیابی نتایج از اهداف این تحقیق است.

۲- تحقیقات پیشین

تعدادی از محققان بر پایه پردازش تصویر جهت شناسایی بیماری‌های قلبی بطن چپ مبتنی بر حجم ضربه‌ای^۲ با محاسبه حجم بطن^۴ در حالت منقبض^۵ و منبسط^۶ به میانگین ضریب همبستگی ۰.۸۰٪ و میانگین خطای مطلق ۵.۶٪ دست یافته‌اند [۱].

هندسه و شکل بطن چپ قلب در شناسایی بیماری‌های قلبی از اهمیت بسیار بالایی برخوردار است، محاسبه حجم بطن چپ قلب در یک چرخه عملکردی قلب از حالت پایان

3- Ejection fraction
4- Ventricle
5- Systole
6- Diastole

یکی از مهم‌ترین وظایف متخصصان درمانی در این حوزه است، خودکارسازی این فرایند از گذشته مورد توجه متخصصان هوش مصنوعی بوده است، در دهه اخیر یادگیری عمیق بر پایه شبکه‌های عصبی هم‌آمیختگی^۲ به‌عنوان یک ابزار تحلیل هوشمند توسعه یافته است. در ابتدا لازم است برخی اصطلاحات پزشکی مورداستفاده در این پژوهش به‌صورت مختصر توضیح داده شوند، قلب انسان به‌عنوان یک عضو عضلانی توخالی از چهار حفره تشکیل شده است (شکل (۱))، دو حفره بالایی و کوچک‌تر دهلیز و دو حفره پایینی و بزرگ‌تر بطن نامیده می‌شوند، در هر دوره فعالیت قلب، خون تصفیه شده وارد دهلیز چپ شده و در حالت انقباضی که اصطلاحاً فاز دیاستول نامیده می‌شود از دهلیز چپ وارد بطن چپ می‌شود، بعد از پرشدن بطن چپ، در حالت انقباضی که اصطلاحاً فاز سیستول نامیده می‌شود، از بطن چپ به سراسر بدن ارسال می‌گردد. یک قلب سالم در حالت پایان سیستولی باید بیش از ۵۵٪ خون وارد شده در حالت پایان دیاستولی را از قلب خارج کند؛ لذا بررسی حجم قلب در حالت پایان دیاستولی و پایان سیستولی در مطالعه عملکرد صحیح این عضو حیاتی از بدن بسیار اهمیت دارد و با تعیین محدوده بطن چپ در حالت پایان دیاستولی و مقایسه آن با محدوده نرمال در این حالت می‌توان برخی نارسایی‌های قلبی را تشخیص داد. در حالت معمول پزشکان متخصص بر اساس تصاویر اکوکاردیوگرافی عملکرد قلب را مورد بررسی قرار می‌دهند، در این تحقیق یک روش تعیین حدود بطن چپ در حالت پایان دیاستولی بر مبنای پردازش تصاویر با تکیه بر هوش مصنوعی ارائه خواهد شد.

یکی از مهم‌ترین چالش‌ها در استفاده از شبکه‌های عصبی عمیق در کاربردهای پزشکی عدم دسترسی به داده‌های مناسب جهت پیاده‌سازی می‌باشد، در تحقیق پیش‌رو از یک مجموعه داده مرجع ارزشمند درمانی که از ابعاد لازم از نظر حجم و کیفیت جهت آموزش و ارزیابی عملکرد یک شبکه عصبی عمیق برخوردار است، استفاده


2- Convolutional Neural Networks (CNNs)

آموزشی و نوظهور بودن نسبت به روش‌های قدیمی کمتر مورد استفاده قرار گرفته است، از نمونه کارهای محققان در این زمینه می‌توان به مدل‌سازی سه‌بعدی بطن چپ در حالت پایان انقباضی و انبساطی اشاره کرد [۱۲]، ارائه یک معماری یونت سه‌بعدی^۹ جهت قطعه‌بندی بطن چپ یکی دیگر از روش‌های ارائه شده در زمینه پردازش تصاویر پزشکی مبتنی بر یادگیری عمیق است [۱۳].

شکل (۲) نشان‌دهنده مقالات منتشر شده در سال‌های اخیر در زمینه پردازش تصاویر اکوکاردیوگرافی با استفاده از الگوریتم‌های یادگیری ماشین^{۱۰} است [۱۴].

روند نمایی پرداختن به این مسئله در سال‌های اخیر در شکل (۲) نشان‌دهنده اهمیت آن برای محققان این حوزه است، امروزه با ایجاد حجم عظیم داده در زمینه‌های مختلف از جمله تصاویر پزشکی، روش‌های یادگیری عمیق می‌توانند نقش عمده‌ای در پردازش این تصاویر بر عهده داشته باشند. شبکه‌های عصبی هم‌آمیختگی با تعداد لایه‌های متفاوت و ابعاد تصاویر مختلف در کارهای محققان جهت پردازش تصاویر اکوکاردیوگرافی مورد استفاده قرار گرفته است [۱۵-۱۷].

یکی از مهم‌ترین چالش‌ها در بحث پیاده‌سازی شبکه‌های عصبی عمیق داده‌های مورد استفاده است، لزوم دسترسی به داده‌ها با ابعاد مناسب جهت آموزش و ارزیابی شبکه پیشنهادی و همچنین کیفیت تصاویر مورد استفاده همواره کارایی روش‌های پیشنهادی بر روی داده‌های خاص که عموماً در اختیار سایر محققان نبوده است را به چالش کشیده است، در این تحقیق روش پیشنهادی بر روی یکی از معدود داده‌هایی که از ویژگی‌های لازم جهت پیاده‌سازی این روش برخوردار است و اخیراً به صورت رایگان تحت وب در اختیار همه علاقه‌مندان قرار گرفته است، پیاده‌سازی شده است و ارزیابی بر مبنای استفاده از ۱۱٪ از داده‌ها که در آموزش شبکه نقشی نداشته‌اند، صورت پذیرفته است.



شکل ۲: یادگیری ماشین در تصاویر پزشکی قلب [۱۴]

انبساطی تا حالت پایان انقباضی نشان‌دهنده عملکرد قلب است [۲، ۳].

امروزه یادگیری عمیق به عنوان یک راهکار مدرن جهت پردازش تصویر مورد توجه است، در حال حاضر یکی از مهم‌ترین چالش‌ها در پیاده‌سازی الگوریتم‌های یادگیری عمیق، نیاز به تعداد بالای نمونه در مرحله آموزش شبکه است، به گونه‌ای که در صورت فراهم بودن تعداد نمونه‌های آموزشی بالا کارایی این روش نسبت به سایر روش‌های پردازش تصویر اثبات شده است. کمبود داده‌های مرجع و مناسب برای پیاده‌سازی الگوریتم‌های یادگیری عمیق موجب شده است که در پردازش تصاویر پزشکی کمتر از این روش استفاده شود [۴، ۵].

قبل از یادگیری عمیق در پردازش تصاویر پزشکی روش‌های متعدد توسط محققان مختلف مورد استفاده قرار گرفته است که تحت عنوان روش‌های غیر یادگیری عمیق می‌توان به آن‌ها اشاره نمود، در این روش‌ها بر پایه الگوریتم‌های یادگیری ماشین نظیر جنگل تصادفی^۷ [۶، ۷]، فیلتر کالمن^۸ [۸] و سایر روش‌های پیشنهادی به قطعه‌بندی تصاویر پزشکی پرداخته شده است [۹-۱۱].

استفاده از روش‌های یادگیری عمیق مبتنی بر شبکه‌های عصبی هم‌آمیختگی با توجه به محدودیت در داده

9- 3D U-Net
10- Machine learning

7- Random Forest
8- Kalman filter

۳- داده‌های مورد مطالعه

داده‌های مورد استفاده در این تحقیق، داده‌های مرجع ارائه شده توسط محققان بیمارستان دانشگاهی اتین^{۱۱} در کشور فرانسه تحت عنوان CAMUS^{۱۲} می‌باشد [۱۸].

تصاویر مورد استفاده در این تحقیق، تصاویری هستند که از قلب افراد مراجعه‌کننده به بیمارستان فوق‌الذکر اخذ شده است که برای هر تصویر یک تصویر واقعیت و تشخیصی مطابق با نظر سه پزشک متخصص قلب ایجاد شده است.

در این تحقیق تصاویر اولیه جهت معرفی به شبکه عصبی هم‌آمیختگی مورد پیش‌پردازش قرار گرفته‌اند به‌گونه‌ای که ابعاد هر تصویر ورودی شبکه ۵۱۲ در ۵۱۲ پیکسل در نظر گرفته شده است، به‌طور کلی ۴۵۰ تصویر در سه باند با ابعاد ۵۱۲ در ۵۱۲ ایجاد شده است که از این تعداد ۴۰۱ تصویر برای آموزش شبکه و ۴۹ تصویر جهت ارزیابی عملکرد شبکه مورد استفاده قرار گرفته‌اند، این تعداد از تصویر جهت پیاده‌سازی یک شبکه عصبی هم‌آمیختگی کیفیت می‌کند که می‌توان با اعمال روش‌های افزودگی داده^{۱۳} حجم داده را نیز افزایش داد، این مجموعه داده به‌صورت رایگان تحت وب قابل دریافت بوده که با توجه به همراهی داده‌های واقعیت زمینی یک مجموعه داده منحصر به فرد در زمینه تصاویر پزشکی جهت پیاده‌سازی الگوریتم‌های یادگیری عمیق مبتنی بر شبکه‌های عصبی هم‌آمیختگی محسوب می‌شود.

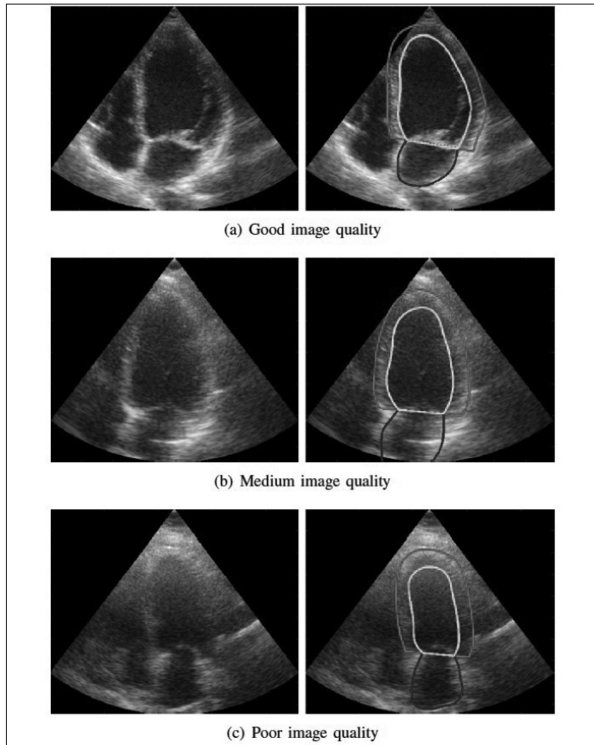
شکل (۳) بخشی از داده‌های مورد استفاده در این تحقیق را نمایش می‌دهد.

شکل (۳) - a: اکوکاردیوگرافی با کیفیت خوب

شکل (۳) - b: اکوکاردیوگرافی با کیفیت متوسط

شکل (۳) - c: اکوکاردیوگرافی با کیفیت ضعیف

جهت پردازش و پیاده‌سازی شبکه عصبی هم‌آمیختگی از سامانه گوگل کولب^{۱۴} بر پایه زبان برنامه‌نویسی پایتون^{۱۵}



شکل ۳: نمونه داده‌های مورد استفاده [۱]

استفاده شده است که پردازش اولیه بدون استفاده از پیش آموزش شبکه با داده‌های اولیه تخمینی در حدود ۳ ساعت زمان بر بوده است.

مطابق با نظر ارائه‌کنندگان داده‌های مرجع، ۱۹٪ از تصاویر ارائه شده از کیفیت پایینی برخوردار هستند و عدم حذف این تصاویر جهت بررسی کارایی الگوریتم‌های پیشنهادی و مطابقت با واقعیت‌های بیمارستانی الزامی به نظر می‌رسد که در این تحقیق از کلیه تصاویر با انواع کیفیت استفاده گردیده است.

همان‌گونه که پیش از این اشاره شد اکثر داده‌های مرجع پزشکی قابل دستیابی در این زمینه، از حجم بسیار کمی برخوردارند که عملاً توانایی به‌کارگیری الگوریتم‌های یادگیری عمیق را از محققان سلب می‌کنند ولی این داده با توجه به تعداد قابل قبول و ارائه نقشه واقعیت و تشخیصی قابلیت به‌کارگیری در الگوریتم‌های یادگیری عمیق را دارا می‌باشد.

تصاویر موجود در داده مرجع در حالت‌های پایان انقباضی بطن چپ قلب و پایان انقباضی بطن چپ قلب

11- University Hospital of St Etienne

12- Cardiac Acquisitions for Multi-structure Ultrasound Segmentation

13- Data Augmentation

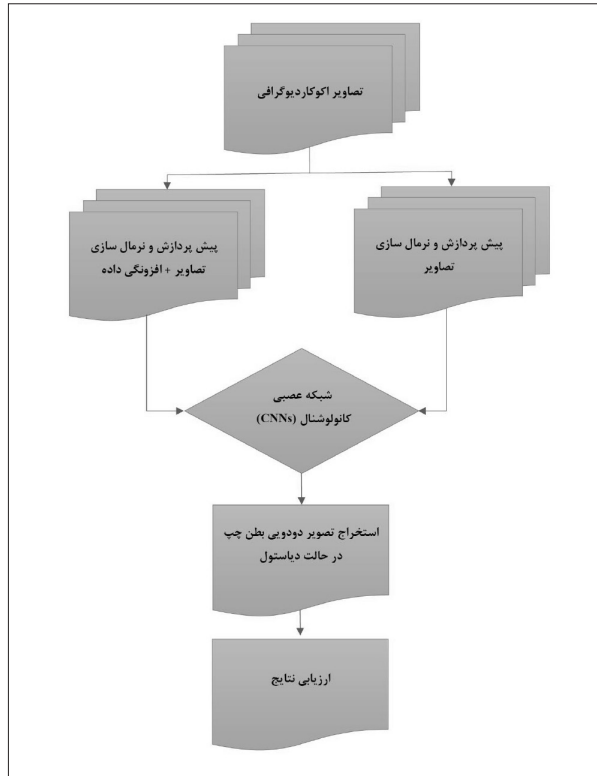
14- Google Colab

15- Python

اخذ شده‌اند که در این تحقیق صرفاً حالت انبساطی مورد بررسی قرار گرفته است.

۴- روش‌شناسی

۴-۱ روندنمای روش پیشنهادی



شکل ۴: روندنمای روش پیشنهادی

در این بخش به تشریح روندنمای روش پیشنهادی (شکل ۴)) و مبانی تحلیلی آن پرداخته خواهد شد.

داده‌های مورد استفاده در واقع تصاویر خامی هستند که توسط دستگاه تصویربردار ارائه شده‌اند و هر یک از ابعاد متفاوت با تصویر دیگر برخوردارند، ابتدا لازم است کلیه تصاویر نرمال‌سازی شده و مطابق با معماری شبکه بازتعریف شوند سپس مطابق با روندنمای ارائه شده داده‌ها در دو حالت عادی و همراه با افزودنی به شبکه عصبی هم‌آمیختگی معرفی می‌شوند، ابتدا تصاویر اولیه پس از پیش‌پردازش و نرمال‌سازی به شبکه معرفی شده و در ادامه یک روش افزودنی داده بر آن‌ها اعمال شده و تعداد داده‌ها را دوبرابر می‌کنیم. هدف از این کار مقایسه عملکرد الگوریتم در حالت افزودنی داده با حالت عادی است. با توجه به ماهیت روش‌های یادگیری عمیق مبتنی بر شبکه‌های عصبی هم‌آمیختگی مرحله آموزش این نوع از الگوریتم‌های یادگیری ماشینی به شدت وابسته به تعداد بسیار بالای داده است، لذا انتظار می‌رود افزایش داده موجب افزایش دقت شبکه شود که نتایج در بخش پنجم ارائه خواهد شد.

معماری شبکه عصبی هم‌آمیختگی مورد استفاده در زیربخش بعدی توضیح داده خواهد شد، در هر صورت خروجی این شبکه تصویر دودویی^{۱۶} بطن چپ قلب در حالت پایان دیاستولی با ابعاد ۵۱۲ در ۵۱۲ پیکسل است که پیکسل‌هایی که بطن چپ قلب در حالت پایان دیاستولی تشخیص داده شده‌اند در یک تصویر ۸ بیتی^{۱۷} با درجه روشنایی ۲۵۵ و پیکسل‌های پس‌زمینه با درجه روشنایی صفر نمایش داده می‌شوند.

در این تحقیق حدود ۱۱ درصد از داده‌ها جهت ارزیابی نهایی بدون مشارکت در فرایند آموزش کنار گذاشته می‌شوند و پس از تعیین پارامترهای شبکه عصبی هم‌آمیختگی و نهایی‌سازی آن این شبکه بر داده‌های آزمایشی^{۱۸} اعمال می‌شود، ضمن این‌که از داده‌های باقیمانده ۸۲ درصد جهت آموزش^{۱۹} و ۱۸ درصد برای صحت‌سنجی^{۲۰} مورد استفاده قرار گرفته‌اند.

مقایسه نقشه‌های تخمینی^{۲۱} و نقشه‌های واقعیت^{۲۲} بر اساس تشخیص پزشکان متخصص قلب برای داده‌های آزمایشی بخش آخر روند روش پیشنهادی است که بر مبنای انواع پارامترهای مطرح در این زمینه دقت برآورد نقشه بطن چپ قلب در حالت پایان دیاستولی با استفاده از شبکه عصبی هم‌آمیختگی پیشنهادی مورد بررسی قرار می‌گیرد، این موضوع در بخش پنجم تشریح شده است.

18- Test
19- Train
20- Validation
21- Prediction Map
22- Truth Map

16- Binary
17- Bit

۴-۲ معماری شبکه عصبی هم آمیختی

شبکه عصبی هم آمیختی طراحی شده از نوع رمزگذار^{۲۳} - رمزگشا^{۲۴} بوده که مطابق با ماهیت این طراحی ابتدا ابعاد تصویر کاهش یافته و عمق آن افزایش می یابد و در بخش دوم مجدداً فرایند معکوس اعمال شده و در نهایت نقشه تخمین با ابعاد تصویر ورودی ساخته می شود، در این شبکه از کرنل هم آمیختی دوبعدی سه در سه استفاده شده است و تابع فعال سازی^{۲۵} از نوع رلو^{۲۶} و تابع هزینه^{۲۷} از نوع کراس آنترپی^{۲۸} می باشد.

جدول (۱) و (۲) لایه های مختلف در معماری شبکه مورد نظر در دو بخش رمزگذار و رمزگشا را نمایش می دهد.

شکل (۵) نمای بصری از معماری شبکه عصبی هم آمیختی پیشنهادی را ارائه می دهد. مطابق با شکل در بخش اول در مرحله رمزگذاری با کاهش ابعاد تصویر و افزایش عمق آن مواجه هستیم و در بخش دوم و مرحله رمزگشایی عکس این عمل صورت می پذیرد. به طور کلی این شبکه دارای ۳,۱۴۳,۸۴۲ پارامتر جهت برآورد می باشد.

۴-۳ افزودنی داده

همان طور که پیش از این توضیح داده شد یکی از اهداف این تحقیق بررسی اثر اعمال افزودنی داده در بهبود عملکرد الگوریتم پیشنهادی است لذا با اعمال عملگر انعکاس عمودی^{۲۹} بر روی داده های اولیه تعداد آن ها را به دو برابر افزایش می دهیم، در این حالت داده های آموزشی ۸۰۲ تصویر و داده های ارزیاب ۹۸ تصویر خواهد شد.

۵- پیاده سازی

با توجه به اهداف تعریف شده برای پژوهش پیش رو،

- 23- Encoder
- 24- Decoder
- 25- Activation Function
- 26- ReLU
- 27- Loss Function
- 28- Cross Entropy
- 29- Vertical Flip

جدول ۱: معماری شبکه در بخش رمزگذار

Layer	Output Shape	Param
input_1	(512,512,3)	0
conv2d	(512,512,16)	448
batch_normalization	(512,512,16)	64
activation	(512,512,16)	0
conv2d_1	(512,512,16)	2320
batch_normalization_1	(512,512,16)	64
Concatenate	(512,512,32)	0
activation_1	(512,512,32)	0
max_pooling2d	(256,256,32)	0
conv2d_2	(256,256,32)	9248
batch_normalization_2	(256,256,32)	128
activation_2	(256,256,32)	0
conv2d_3	(256,256,32)	9248
batch_normalization_3	(256,256,32)	128
concatenate_1	(256,256,64)	0
activation_3	(256,256,64)	0
max_pooling2d_1	(128,128,64)	0
conv2d_4	(128,128,64)	36928
batch_normalization_4	(128,128,64)	256
activation_4	(128,128,64)	0
conv2d_5	(128,128,64)	36928
batch_normalization_5	(128,128,64)	256
concatenate_2	(128,128,128)	0
activation_5	(128,128,128)	0
max_pooling2d_2	(64,64,128)	0
conv2d_6	(64,64,128)	147584
batch_normalization_6	(64,64,128)	512
activation_6	(64,64,128)	0
conv2d_7	(64,64,128)	147584
batch_normalization_7	(64,64,128)	512
concatenate_3	(64,64,256)	0
activation_7	(64,64,256)	0
max_pooling2d_3	(32,32,256)	0
conv2d_8	(32,32,256)	590080
batch_normalization_8	(32,32,256)	1024
activation_8	(32,32,256)	0
conv2d_9	(32,32,256)	590080
batch_normalization_9	(32,32,256)	1024
concatenate_4	(32,32,512)	0
activation_9	(32,32,512)	0

جدول ۲: معماری شبکه در بخش رمزگشا

Layer	Output Shape	Param
conv2d_transpose	(64,64,128)	589952
concatenate_5	(64,64,384)	0
conv2d_10	(64,64,128)	442496
batch_normalization_10	(64,64,128)	512
activation_10	(64,64,128)	0
conv2d_11	(64,64,128)	147584
batch_normalization_11	(64,64,128)	512
concatenate_6	(64,64,256)	0
activation_11	(64,64,256)	0
conv2d_transpose_1	(128,128,64)	147520
concatenate_7	(128,128,192)	0
conv2d_12	(128,128,64)	110656
batch_normalization_12	(128,128,64)	256
activation_12	(128,128,64)	0
conv2d_13	(128,128,64)	36928
batch_normalization_13	(128,128,64)	256
concatenate_8	(128,128,128)	0
activation_13	(128,128,128)	0
conv2d_transpose_2	(256,256,32)	36896
concatenate_9	(256,256,96)	0
conv2d_14	(256,256,32)	27680
batch_normalization_14	(256,256,32)	128
activation_14	(256,256,32)	0
conv2d_15	(256,256,32)	9248
batch_normalization_15	(256,256,32)	128
concatenate_10	(256,256,64)	0
activation_15	(256,256,64)	0
conv2d_transpose_3	(512,512,16)	9232
concatenate_11	(512,512,48)	0
conv2d_16	(512,512,16)	6928
batch_normalization_16	(512,512,16)	64
activation_16	(512,512,16)	0
conv2d_17	(512,512,16)	2320
batch_normalization_17	(512,512,16)	64
concatenate_12	(512,512,32)	0
activation_17	(512,512,32)	0
dropout	(512,512,32)	0
conv2d_18	(512,512,2)	66
Total params: 3,143,842		
Trainable params: 3,140,898		
Non-trainable params: 2,944		

پایه‌سازی الگوریتم پیشنهادی را در دو بخش یادگیری عمیق بر پایه شبکه‌های عصبی هم‌آمیختگی و افزونگی داده پیش می‌بریم.

۵-۱ شبکه عصبی هم‌آمیختگی

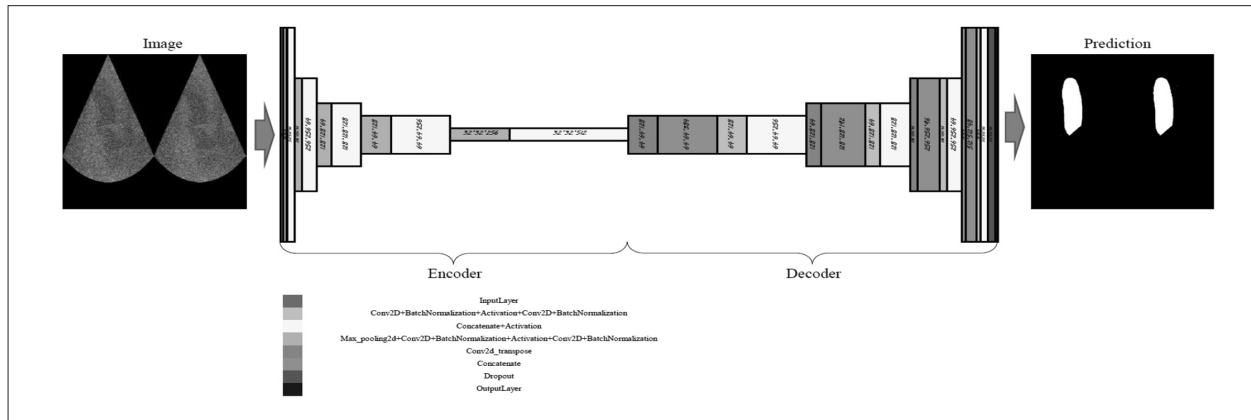
روش پیشنهادی در دو حالت مختلف اعمال شده است در حالت اول تصاویر پس از نرمال‌سازی و بدون اعمال افزونگی به شبکه معرفی شده است و در حالت دوم با تقویت داده تعداد نمونه‌های آموزشی و ارزیابی به دوبرابر افزایش پیدا کرده است و سپس نتایج وارد فرایند ارزیابی دقت شده‌اند.

در شکل (۶) نتایج بصری اعمال شبکه پیشنهادی در حالات دوگانه نمایش داده شده است، در این شکل ستون اول تصاویر اکوکاردیوگرافی، ستون دوم نقشه واقعیت حاصل از تشخیص سه پزشک متخصص، ستون سوم و چهارم نتیجه عملکرد روش پیشنهادی را نمایش می‌دهد. به‌طور کلی مطابق با انتظار با افزونگی داده دقت عملکرد مدل پیشنهادی افزایش یافته است که این موضوع در بخش بعدی مورد بررسی قرار می‌گیرد.

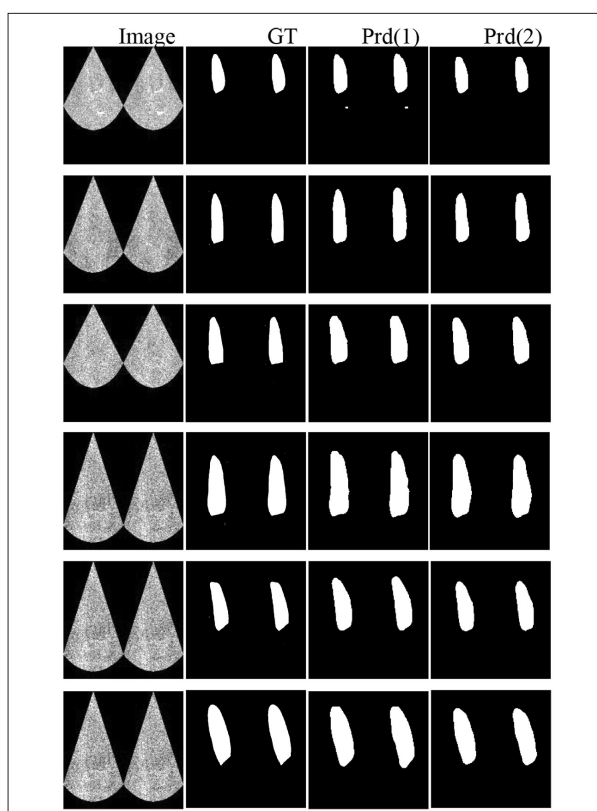
۵-۲ افزونگی داده

مطابق با انتظار با تقویت داده و دوبرابر کردن حجم آن در حالت دوم دقت افزایش می‌یابد ولی این افزایش چشمگیر نیست که در بخش بعدی تشریح خواهد شد.

نکته دیگر در رابطه با روش پیشنهادی مدت‌زمان لازم جهت اعمال الگوریتم یادگیری عمیق و برآورد حدود ۳ میلیون پارامتر شبکه است که با استفاده از حالت رایگان در سامانه گوگل کولب در حدود ۳ ساعت زمان لازم است تا در تکرارهای متعدد بهترین دقت عملکرد روی داده‌های ارزیابی اتفاق بیفتد ولی در صورتی که از پارامترهای خروجی از حالت اول برای پیش آموزش پارامترهای شبکه در حالت دوم استفاده شود شاهد آن خواهیم بود که مدت‌زمان رسیدن به بهترین عملکرد و کمترین خطا در داده‌های ارزیابی در حدود ۳۰٪ کاهش یافته و تنها با ۲



شکل ۵: معماری شبکه عصبی هم آمیختنی پیشنهادی



شکل ۶: نمونه‌های از نتایج بصری شبکه پیشنهادی

ساعت آموزش، شبکه به حالت بهینه خود می‌رسد و این در حالی است که حجم داده در حالت دوم را به دو برابر حالت اول افزایش داده‌ایم.

به بیان دیگر با جایگزینی پارامترهای خروجی حالت اول در حالت دوم به‌عنوان پارامترهای اولیه می‌توان زمان دستیابی به بهترین عملکرد را به شدت کاهش داد.

۶- ارزیابی نتایج

هرگونه مدل‌سازی و طبقه‌بندی همواره با مقادیر اجتناب‌ناپذیر از خطاها همراه است. جهت ارزیابی عملکرد روش پیشنهادی همان‌گونه که پیش‌ازاین توضیح داده شد در حدود ۱۱٪ از داده‌های اولیه که در حالت اول شامل ۴۹ تصویر با ابعاد ۵۱۲ در ۵۱۲ پیکسل و در حالت دوم شامل ۹۸ تصویر با ابعاد ۵۱۲ در ۵۱۲ پیکسل می‌شود به‌عنوان داده‌های ارزیابی و بدون مشارکت در مرحله آموزش و اعتبارسنجی شبکه یادگیری عمیق پیشنهادی مورد استفاده قرار گرفته‌اند، در ادامه مهم‌ترین پارامترهای ارزیابی که در این تحقیق مورد استفاده قرار گرفته‌اند بررسی شده و نتایج ارائه خواهد شد.

$$OA = \frac{TP + TN}{P + N} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$IOU = \frac{TP}{TP + FP + FN} \quad (4)$$

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (5)$$

در روابط (۱) تا (۵) تعداد نمونه‌های کلاس هدف، N تعداد نمونه‌های کلاس زمینه، TP تعداد نمونه‌های کلاس هدف که به درستی برچسب هدف خورده‌اند، FP تعداد نمونه‌های کلاس زمینه که به‌غلط برچسب هدف خورده‌اند، TN تعداد نمونه‌های

جدول ۳: معیارهای ارزیابی در حالات پیشنهادی

معیار ارزیابی	حالت (۱)	حالت (۲)
OA	۹۷,۶۷	۹۷,۹۹
Precision	۹۶,۴۴	۹۰,۹۲
Recall	۸۱,۵۰	۸۷,۵۶
IOU	۷۹,۱۲	۸۰,۵۲
F1	۸۸,۳۴	۸۹,۲۱

کلاس زمینه که به درستی برچسب زمینه خورده‌اند، FN تعداد نمونه‌های کلاس هدف که به غلط برچسب زمینه خورده‌اند و تعداد نمونه‌ها در هر تصویر برابر تعداد پیکسل‌های تصویر است.

روابط (۱) تا (۵) دقت کلی^{۲۰}، دقت آشکارسازی کلاس هدف^{۲۱} یا دقت کاربر^{۲۲}، میزان حساسیت^{۲۳} یا دقت تولیدکننده^{۲۴}، شاخص IOU^{۲۵} و امتیاز F1^{۲۶} را نشان می‌دهد.

جدول (۳) نتایج ارزیابی بر روی داده‌ها را نشان می‌دهد که حالت (۱) داده‌های اولیه بدون تقویت داده و حالت (۲) داده‌های اولیه پس از تقویت داده و افزایش آن‌ها به دو برابر حالت اولیه می‌باشد.

مطابق با انتظار حالت شماره (۲) یعنی در داده‌های اولیه تقویت شده و افزودگی داده به صورت دو برابری حالت شماره (۱)، نتایج بهتری را نشان می‌دهد ولی این تغییر بسیار جزئی بوده و در حدود ۱٪ امتیاز F1 را بهبود داده است.

۷- بحث و نتیجه‌گیری

تفسیر تصاویر اخذ شده از قلب انسان تحت عنوان اکوکاردیوگرافی از گذشته تاکنون نقش بسیار مهمی در تشخیص و بررسی کارایی قلب نزد متخصصان این رشته ایفا کرده است، بدیهی است تشخیص متخصصان مختلف می‌تواند نسبت به یکدیگر متفاوت بوده و یا حتی یک متخصص در شرایط مختلف تشخیص‌های متفاوتی را ارائه دهد، ارائه یک فرایند خودکار تشخیص بیماری بر

30- Overall Accuracy
31- Precision
32- User's Accuracy
33- Recall or Sensitivity
34- Producer's Accuracy
35- Intersection over Union
36- F1 Score

مبنای یادگیری ماشین در دهه‌های گذشته همواره مورد توجه محققان هوش مصنوعی بوده است.

در صورتی که بتوان یک سامانه تشخیص و تفسیر تصاویر پزشکی با دقت بسیار بالا را ارائه نمود طبیعتاً اشتباهات پزشکی حاصل از تشخیص‌های غیر صحیح نیز به شدت کاهش می‌یابد. در این تحقیق بر مبنای یادگیری عمیق مبتنی بر یک شبکه عصبی هم‌آمیختگی سعی در پردازش تصاویر اکوکاردیوگرافی داشته‌ایم، به صورتی که مهم‌ترین هدف این تحقیق استخراج نقشه بطن چپ قلب در حالت پایان دیاستولی بوده است که نتایج تا ۹۰٪ با تشخیص پزشکان متخصص در این زمینه تطابق دارد، این نتیجه کارایی روش پیشنهادی را نسبت به سایر روش‌های سنتی پردازش تصاویر پزشکی نشان می‌دهد.

همان‌گونه که پیش‌از این نیز اشاره شد در زمینه یادگیری عمیق برای کاربردهای پزشکی یکی از بزرگ‌ترین چالش‌ها عدم وجود منابع داده مطابق با نیازمندی روش‌های مذکور است که امید است با گسترش علم فناوری اطلاعات داده‌های پزشکی جدید در حجم مناسب در اختیار محققان جهت پیاده‌سازی الگوریتم‌های پیشنهادی قرار گیرد، در این تحقیق بر روی یکی از داده‌های بین‌المللی ارائه شده تحت وب به صورت رایگان، الگوریتم پیشنهادی پیاده‌سازی شد و پیشنهاد می‌شود روش پیشنهادی با تعداد بیشتری از تصاویر اکوکاردیوگرافی مورد ارزیابی قرار گیرد.

یکی از مهم‌ترین روش‌های تشخیصی برای سنجش عملکرد قلب محاسبه حجم ضربه‌ای آن بر مبنای مقایسه حجم بطن چپ در دو حالت پایان دیاستولی و پایان سیستولی است، در این تحقیق نقشه بطن چپ در حالت پایان دیاستولی با دقتی در حدود ۹۰٪ استخراج شده است. پیشنهاد می‌شود نقشه بطن چپ قلب در حالت پایان سیستولی نیز بر مبنای روش پیشنهادی یا سایر روش‌ها استخراج شده و بر اساس مقایسه این دو حالت یک سامانه تشخیص بیماری نارسایی قلبی^{۲۷} توسعه داده شود، مطابق با نظر متخصصان قلب در صورتی که حجم ضربه‌ای قلب کمتر از ۵۵٪ باشد،

37- Heart Failure

- ert, D., "Endocardial 3d ultrasound segmentation using auto-context random forests," Proceedings of the MICCAI Challenge on Echocardiographic Three-Dimensional Ultrasound Segmentation (CETUS), pp. 41-48, 2014.
7. Domingos, J., Stebbing, R., and Noble, J., "Endocardial segmentation using structured random forests in 3D echocardiography," In Proc. MICCAI Challenge Echocardiogr. Three-Dimensional Ultrasound Segmentation (CETUS), pp. 33-40, 2014.
 8. Smištad, E., and Lindseth, F., "Real-time tracking of the left ventricle in 3D ultrasound using Kalman filter and mean value coordinates," Medical Image Segmentation for Improved Surgical Navigation, vol. 189, 2014.
 9. Bernier, M., Jodoin, P., and Lalande, A., "Automatized evaluation of the left ventricular ejection fraction from echocardiographic images using graph cut," MICCAI Challenge Echocardiogr. Three-Dimensional Ultrasound Segmentation (CETUS), pp. 25-32, 2014.
 10. Milletari, F., Yigitsoy, M., and Navab, N., "Left ventricle segmentation in cardiac ultrasound using hough-forests with implicit shape and appearance priors," 2014.
 11. Oktay, O., Ferrante, E., Kamnitsas, K., Heinrich, M., Bai, W., Caballero, J., Cook, S. A., De Marvao, A., Dawes, T., and O'Regan, D. P., "Anatomically constrained neural networks (ACNNs): application to cardiac image enhancement and segmentation," IEEE transactions on medical imaging, vol. 37, no. 2, pp. 384-395, 2017.
 12. Oktay, O., Shi, W., Keraudren, K., Caballero, J., Rueckert, D., and Hajnal, J., "Learning shape representations for multi-atlas endocardium segmentation in 3D echo images," Proceedings MICCAI Challenge on Echocardiographic Three-Dimensional Ultrasound Segmentation (CETUS), Boston, MIDAS Journal, pp. 57-64, 2014.
 13. Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., and Ronneberger, O., "3D U-Net: learning dense volumetric segmentation from sparse annotation," In International conference on medical image computing and computer-assisted intervention, pp. 424-432. Springer, 2016.
 14. Martin-Isla, C., Campello, V. M., Izquierdo, C., Raisi-Estabragh, Z., Baeßler, B., Petersen, S. E., and Lekadir, K., "Image-based cardiac diagnosis with machine learning: a review," Frontiers in cardiovascular medicine, vol. 7, pp. 1, 2020.
 15. Wolterink, J. M., Leiner, T., de Vos, B. D., van Hamersvelt, R. W., Viergever, M. A., and Išgum, I., "Automatic coronary artery calcium scoring in cardiac CT angiography using paired convolutional neural networks," Medical image analysis, vol. 34, pp. 123-136, 2016.
 16. Zhang, J., Gajjala, S., Agrawal, P., Tison, G. H., Hallock, L. A., Beussink-Nelson, L., Lassen, M. H., Fan, E., Aras, M. A., and Jordan, C., "Fully automated echocardiogram interpretation in clinical practice: feasibility and diagnostic accuracy," Circulation, vol. 138, no. 16, pp. 1623-1635, 2018.
 17. Madani, A., Ong, J. R., Tibrewal, A., and Mofrad, M. R., "Deep echocardiography: data-efficient supervised and semi-supervised deep learning towards automated diagnosis of cardiac disease," NPJ digital medicine, vol. 1, no. 1, pp. 1-11, 2018.
 18. <https://www.creatis.insa-lyon.fr/Challenge>

قلب کارایی مورد انتظار را نداشته و این حالت نارسایی قلبی نامیده می‌شود.

نکته دیگر بحث پیش آموزش شبکه و تعیین مقادیر اولیه برای پارامترهای شبکه عصبی هم‌آمیختگی پیشنهادی است، در این تحقیق وقتی که خروجی‌های پارامتری حالت یک به‌عنوان مقادیر اولیه پارامترها در حالت شماره دو مورد استفاده قرار گرفت شاهد بودیم که زمان رسیدن شبکه به دقت بهینه در حدود ۳۰٪ کاهش می‌یابد و با تعداد تکرار کمتر، عملاً بهترین دقت در داده‌های ارزیاب و کمترین خطا مشاهده می‌شود این در حالی است که در حالت شماره (۲) عملاً داده‌های معرفی شده به شبکه جهت پردازش دوبرابر حالت شماره (۱) بوده است.

بنابراین توصیه می‌شود علاوه بر تقویت داده‌ها از پیش آموزش پارامترهای شبکه عصبی هم‌آمیختگی نیز استفاده شود.

مراجع

1. Leclerc, S., Smištad, E., Pedrosa, J., Østvik, A., Cervenansky, F., Espinosa, F., Espeland, T., Berg, E. A. R., Jodoin, P.-M., and Grenier, T., "Deep learning for segmentation using an open large-scale dataset in 2D echocardiography," IEEE transactions on medical imaging, vol. 38, no. 9, pp. 2198-2210, 2019.
2. White, H. D., Norris, R. M., Brown, M. A., Brandt, P. W., Whitlock, R. M. and Wild, C. J., "Left ventricular end-systolic volume as the major determinant of survival after recovery from myocardial infarction," Circulation., vol. 76, pp. 44-51, 1987.
3. Norris, R., White, H., Cross, D., Wild, C. and Whitlock, R., "Prognosis after recovery from myocardial infarction: the relative importance of cardiac dilatation and coronary stenoses," European Heart Journal, vol. 13, pp. 1611-1618, 1992.
4. Bernard, O., Lalande, A., Zotti, C., Cervenansky, F., Yang, X., Heng, P.-A., Cetin, I., Lekadir, K., Camara, O., and Ballester, M. A. G., "Deep learning techniques for automatic MRI cardiac multi-structures segmentation and diagnosis: Is the problem solved?," IEEE transactions on medical imaging, vol. 37, no. 11, pp. 2514-2525, 2018.
5. Bernard, O., Bosch, J. G., Heyde, B., Alessandrini, M., Barbosa, D., Camarasu-Pop, S., Cervenansky, F., Valette, S., Mirea, O., and Bernier, M., "Standardized evaluation system for left ventricular segmentation algorithms in 3D echocardiography," IEEE transactions on medical imaging, vol. 35, no. 4, pp. 967-977, 2015.
6. Keraudren, K., Oktay, O., Shi, W., Hajnal, J. V., and Rueck-