مقاله پژوهشی

مجله انفورماتیک سلامت و زیست پزشکی
مرکز تحقیقات انفورماتیک پزشکی
دوره هشتم شماره سوم. ص ۳۲۵-۳۱۵، ۱۴۰۰

جداسازی ناحیه گوشک دهلیز چپ در تصاویر اکوکاردیوگرافی قلب با استفاده از شبکه عصبی عمیق

حسین قیومی زاده[۱،۲]*، علی فیاضی[۳]، خسرو رضایی[۴]، محمدحسین قلی زاده[۳]، مهدی اسکندری[۵]

• دریافت مقاله: ۱۴۰۰/۴/۱۸ • پذیرش مقاله: ۱۴۰۰/۸/۲۴

مقدمه: بیماری‌های قلبی و عروقی یکی از علل اصلی مرگ‌ومیر در جهان صنعتی امروز هستند. انسداد گوشک دهلیز چپ با استفاده از دستگاه‌های ساخته شده یک‌روند رو به رشد است. این مطالعه با هدف ایجاد یک سیستم تشخیصی به کمک رایانه برای شناسایی LAA در تصاویر اکوکاردیوگرافی انجام شد.

روش: داده‌های به کار رفته در این مطالعه توصیفی-تحلیلی، تصاویر اکوکاردیوگرافی سه‌بعدی از قلب مربوط به ۳۲ بیمار اخذ شده در بیمارستان کینگز کالج لندن است که تمامی آن‌ها با موفقیت با مسدودکننده درمان شدند. مجموع ۲۰۸ تصویر دوبعدی به‌دست‌آمده در صفحه محوری از هر مجموعه داده سه‌بعدی به دست آمد. سپس ۱۹۱۴ تصویر که در آن‌ها ناحیه مربوط به LAA به‌وضوح قابل‌تشخیص بودند برای این مطالعه انتخاب شدند. شبکه عصبی پیشنهادی در این مطالعه مبتنی بر الگوریتم YOLOv3 کامپایل شده است. در نهایت ۱۳۶۹ و ۵۴۵ تصویر به ترتیب برای آموزش و آزمایش الگوریتم مورد استفاده قرار گرفتند.

نتایج: عملکرد الگوریتم در شناسایی LAA بر روی مجموعه‌ای از ۵۴۵ تصویر با نواحی ردیابی شده در تصاویر مشابه توسط یک متخصص در اکوکاردیوگرافی با استفاده از یک تقاطع بر روی الگوریتم (IoU) مقایسه شد. الگوریتم قادر به شناسایی صحیح ناحیه LAA در تمامی ۵۴۵ تصویر بررسی شده با IoU میانگین ۹۹/۳۷٪ بود.

نتیجه‌گیری: الگوریتم پیشنهادی مبتنی بر تصویر، در این مطالعه دقت بالایی در تشخیص حدود LAA در تصاویر اکوکاردیوگرافی نشان داد. این روش می‌تواند در توسعه الگوریتم‌ها برای تجزیه‌وتحلیل خودکار ناحیه LAA جهت تعیین اندازه دستگاه و برنامه‌ریزی رویه‌ای در روش‌های انسداد LAA مورد استفاده باشد.

کلیدواژه‌ها: اکوکاردیوگرافی، شبکه عصبی عمیق، شبکه عصبی کانولوشن، فیبریلاسیون دهلیزی، گوشک دهلیز چپ قلب

•ارجاع: قیومی زاده حسین، فیاضی علی، رضایی خسرو، قلی‌زاده محمدحسین، اسکندری مهدی. جداسازی ناحیه گوشک دهلیز چپ در تصاویر اکوکاردیوگرافی قلب با استفاده از شبکه عصبی عمیق. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۰؛ ۸(۳): ۲۵-۳۱۵.

۱. مرکز تحقیقات بیماری‌های غیر واگیر، دانشگاه علوم پزشکی رفسنجان، رفسنجان، ایران
۲. دکتری مهندسی پزشکی، استادیار، گروه مهندسی برق، دانشگاه ولی‌عصر (عج) رفسنجان، رفسنجان، ایران
۳. دکتری مهندسی برق، استادیار، گروه مهندسی برق، دانشگاه ولی‌عصر (عج) رفسنجان، رفسنجان، ایران
۴. دکتری مهندسی پزشکی، استادیار، گروه مهندسی پزشکی، دانشگاه میبد، میبد، ایران
۵. دکترای پزشکی، بیمارستان کینگز کالج لندن، انگلستان

*** نویسنده مسئول:** حسین قیومی زاده
آدرس: رفسنجان، میدان امام خمینی، دانشگاه ولی عصر (عج)، دانشکده فنی و مهندسی، گروه مهندسی برق، صندوق پستی ۵۱۸
•شماره تماس: ۰۳۴۳۱۳۱۲۳۹۸ • **Email:** h.ghayoumizadeh@vru.ac.ir

[Downloaded from jhbmi.ir on 2024-04-19]

مقدمه

بیماری‌های قلبی و عروقی یکی از علل اصلی مرگ‌ومیر در جهان صنعتی امروز هستند، فیبریلاسیون دهلیزی شایع‌ترین آن‌ها است، که حدود ۱٪ از جمعیت عمومی جهان به آن مبتلا می‌باشند. میزان ابتلاء به این بیماری با بالا رفتن سن افزایش می‌یابد؛ به‌طوری‌که در آمریکا حدود ۱٪ از بیماران زیر ۶۰ سال و ۸٪ از بیماران بالای ۸۰ سال به این بیماری مبتلا هستند [۱]. بروز این بیماری در درصد بالایی از جمعیت جهان آن را به یک مشکل اجتماعی و اقتصادی تبدیل کرده است [۲]. بااین‌حال، نرخ رشد Atrial Fibrillation در میان مطالعات مختلف متفاوت است، تخمین زده می‌شود که وقوع AF تا سال ۲۰۳۰ در ایالات‌متحده دو برابر شود [۳]. با تشخیص زودهنگام این آریتمی کشنده قلبی، می‌توان آن را پیشگیری و مدیریت نمود. فیبریلاسیون دهلیزی یک آریتمی فوق بطنی است، که با فعالیت دهلیزی غیرهماهنگ و متعاقب آن وخامت عملکرد مکانیکی دهلیز، مشخص می‌شود [۴]. این بیماری ممکن است منجر به تشکیل لخته‌های خونی و انسداد رگ‌ها شود، توانایی و حجم خون‌دهی قلب را کاهش دهد، فعالیت و کارکرد بطن‌ها را معیوب سازد و کیفیت زندگی را کاهش دهد [۵]. تشکیل لخته‌های خونی خطر ابتلاء به سکته مغزی و مرگ‌ومیر را در بیماران مبتلا به فیبریلاسیون دهلیزی افزایش می‌دهد. به‌طوری‌که در حدود ۱۵٪ از جمعیت سکته‌های مغزی را افراد مبتلابه فیبریلاسیون دهلیزی تشکیل می‌دهند [۶].

Holmes و همکاران ادعا کردند که گوشک دهلیز چپ می‌تواند محرکی مناسب برای ایجاد فیبریلاسیون دهلیزی باشد و اکنون نتایج این کار آزمایی این موضوع را تأیید کرده است [۷]. ایزولاسیون الکتریکی ناحیه‌ای در قلب به نام گوشک دهلیز چپ می‌تواند بدون افزایش عوارض به بهبود بیماران مبتلابه فیبریلاسیون دهلیزی مزمن، بلندمدت و درمان‌ناپذیر کمک کند. در اغلب موارد گوشک دهلیزی را که محل تشکیل لخته است را نیز می‌بندند. هر وسیله مسدودکننده گوشک دارای محدوده‌ای از سایزها است که لازم است گوشک‌ها با اندازه‌های مختلف را پوشش دهد [۸]. یک گام مهم در جراحی مسدودکننده، تعیین اندازه وسیله مسدودکننده حاصل از بررسی ناحیه‌ای به نام landing zone در گوشک است؛ بنابراین یک ارزیابی دقیق از آناتومی Left Atrial Appendage در برنامه‌ریزی برای بسته شدن LAA بسیار مهم است. مطالعات نشان می‌دهد در یک درصد از بیماران، بیش از یک وسیله مسدودکننده در طی فرآیند جراحی، آزمایش شده است. بااین‌حال، شناسایی و تحلیل دستی ناحیه فرود LAA زمان‌بر و در معرض تغییرات بین مشاهده‌کنندگان است. اگر بخواهیم یک سیستم هوشمند جهت انتخاب و پیشنهاد یک سایز مناسب برای جراحی ارائه دهیم؛ شرط انجام آن جداسازی ناحیه landing zone است؛ که در این مطالعه سعی شد نواحی منتخب برای ناحیه گوشک از تصاویر اکوکاردیوگرافی جداسازی گردند.

تعداد محدودی از مطالعات بر روی تکنیک‌های تقسیم‌بندی LAA به‌خصوص تصویربرداری اکوکاردیوگرافی انجام شده است. با این‌حال، علاقه زیادی به انجام مطالعات تصویربرداری برای بهبود فرآیند تفسیر تصویر با استفاده از مدل‌های خودکار وجود داشته است. یک الگوریتم نیمه‌خودکار برای تقسیم‌بندی LAA با استفاده از الگوریتم رشد ناحیه ارائه شده است [۹]. در یک مطالعه دیگر، یک روش تقسیم‌بندی LAA کاملاً خودکار توسط یک عامل یادگیری تقویتی بازیگر منتقد پیشنهاد شد [۱۰]. Wang و همکاران، یک تکنیک تقسیم‌بندی LAA نیمه‌خودکار را بر اساس تصاویر Multislice Computed Tomography پیشنهاد کردند که شامل چهار نقطه بنیادی انتخاب‌شده به‌صورت دستی برای به دست آوردن ناحیه موردنظر یا جعبه مقیدکننده برای LAA است [۱۱]. استفاده از شبکه‌های عصبی کانولوشن و ترکیب آن‌ها نیز اخیراً به‌عنوان یک روش قوی برای انجام جداسازی خودکار LAA مورداستفاده قرارگرفته است [۱۲]. در مطالعه Ghayoumi Zadeh و همکاران [۱۳] با استفاده از yolov1 توانستند ناحیه کاندید برای گوشک را استخراج نمایند.

هدف از این پژوهش، شناسایی و ردیابی ناحیه کاندید برای گوشک دهلیز چپ قلب در تصاویر ویدیویی اکوی قلب است تا بتوان مسدود کننده‌های گوشک به درستی بنا به ناحیه گوشک انتخاب شوند. به همین منظور از شبکه‌های عصبی عمیق YOLOv3 استفاده شد. در همین راستا ابتدا تصاویر ۲ بعدی از سه بعدی استخراج و سپس ناحیه گوشک توسط پزشک متخصص لیبل بندی و در نهایت وارد شبکه عصبی عمیق گردید.

روش

داده‌های به کار در این مطالعه توصیفی-تحلیلی، تصاویر اکوکاردیوگرافی قلب واقعی اخذ شده در بیمارستان کینگز کالج لندن است. این داده‌ها مربوط به ۳۲ بیمار مرد/زن است (کد اخلاق: IR.RUMS.REC.1398.106). داده‌ها با توجه به

[Downloaded from jhbmi.ir on 2024-04-19]

استانداردهای مقررات عمومی حفاظت از داده اروپا، استانداردهای اخلاقی کمیته تحقیقات سازمانی آماده شدند. داده‌ها کاملاً ناشناس و غیرقابل‌پیگیری بودند. تصاویر با استفاده از دستگاه اکوکاردیوگرافی (Epiq 7XT Philips company, Best, Netherland) با استفاده از پروب‌های X7-2t یا X8-2t (Philips, Best, and Netherland) در حالت ۳ بعدی زوم شده به‌دست آمده‌اند.

اولین و تنها مرحله پیش‌پردازش در این روش، استخراج تصاویر محوری دوبعدی از مجموعه داده زوم شده سه‌بعدی بود. برای این منظور، از یک پلتفرم نرم‌افزاری منبع باز ۳ D slicer (Harvard University, version 4.11, United States) استفاده شد که تصاویر محوری دوبعدی با ابعاد ۱۱۲ * ۱۲۸ پیکسل را از مجموعه داده سه‌بعدی LAA بر می‌گرداند. در مرحله بعد، تصاویر محوری توسط یک متخصص در اکوکاردیوگرافی موردبررسی قرار گرفت و مرز LAA (یعنی ناحیه موردنظر برای آموزش شبکه عصبی) درجایی که امکان‌پذیر بود ردیابی شد. قابل‌ذکر است که در برخی اسلایس‌هایِ بیمار، مانند شکل ۱ ناحیه گوشک به‌درستی دیده و تشخیص داده نمی‌شد؛ بنابراین آن اسلایس از بررسی خارج گردید. در نهایت در مجموع ۱۹۱۴ تصویر محوری قابل‌تشخیص و ردیابی انتخاب شدند.

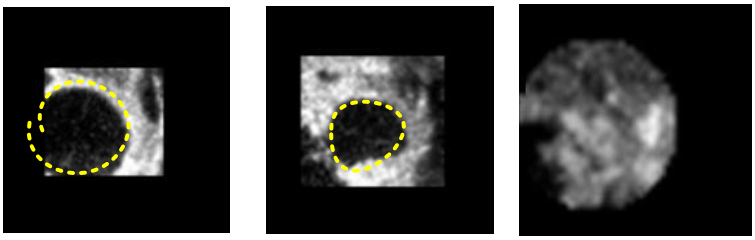

(الف) (ب) (ج)

شکل ۱: الف و ب) تصویر اسلایسِ ناحیه گوشک دهلیز چپ شناسایی‌شده‌ی بیمار توسط متخصص اکوکاردیوگرافی
ج) عدم شناسایی ناحیه گوشک در اسلایس موردنظر بیمار

سیستم Computer-aided design پیشنهادی مبتنی بر YOLO برای تشخیص و ردیابی ناحیه گوشک دهلیز چپ در شکل ۲ نشان داده شده است. در این کار، تصاویر اکوی قلب و Region Of Interest (یعنی گوشک) باید توسط YOLO ها آموخته شوند.

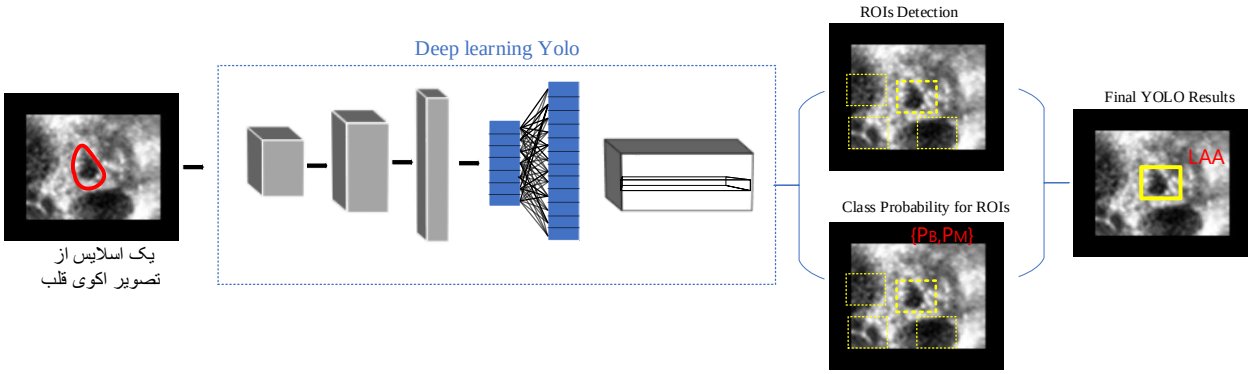

شکل ۲: سیستم CAD پیشنهادی برای تشخیص و ردیابی ناحیه گوشک دهلیز چپ با استفاده از مدل YOLO

[Downloaded from jhbmi.ir on 2024-04-19]

الگوریتم convolutional neural network ارائه‌شده در این مطالعه بر اساس یک پلتفرم شناسایی و طبقه‌بندی شی متن‌باز است که تحت پروژه (You Only Look Once) YOLO که مخفف «شما فقط یک‌بار نگاه کنید» است، کامپایل شد [۱۴]. به‌طور خلاصه، یک رديـاب شی معمولی از چندین قسمت تشکیل شده که شامل ورودی، ستون فقرات، گردن و درنهایت سر است. بخش ورودی شامل تصویر، وصله‌ها و هرم تصویر است. بخش ستون فقرات که یک شبکه عصبی عمیق است که عمدتاً از لایه‌های کانولوشن شکل گرفته است. در ستون فقرات استخراج ویژگی‌های اساسی از تصویر صورت می‌پذیرد. انتخاب ستون فقرات یک مرحله مهم در بهبود عملکرد تشخیص شی است. غالباً از شبکه‌های عصبی از پیش آموزش‌دیده برای آموزش ستون فقرات استفاده می‌شود. ستون فقرات آشکارسازها می‌توانند VGG، ResNet، SqueezeNet، DenseNet و غیره باشند [۱۷-۱۵]. بخش گردن که نقش اساسی آن جمع‌آوری نقشه‌های مشخصه از مراحل مختلف است. لایه‌های این بخش بین ستون فقرات و سر قرار دارند و برای استخراج نگاشت‌های ویژگی در مراحل مختلف ستون فقرات استفاده می‌شوند. گردن معماری عمومی این الگوریتم می‌تواند از یک شبکه هرم ویژگی (FPN)، یک شبکه متراکم سازی مسیر (PANet) یا یک شبکه دوطرفه هرم ویژگی (Bi-FPN) تشکیل‌شده باشد.

عبارت $\Pr(class_i)$ تعیین می‌کند که آیا نقطه مرکزی LAA در سلول شبکه قرار گیرد. وقتی مقدار عبارت $\Pr(classi)$ برابر یک است که نقطه مرکزی یک شی در یک شبکه وجود داشته باشد، در غیر این صورت صفر است. عبارت (intersection over union) IoU_{pred}^{truth} نسبت جعبه محدود پیش‌بینی‌شده LAA با جعبه محدودکننده حقیقت بافت است. مقدار IoU تشخیص LAA را در صورت مثبت بودن یا مثبت کاذب بودن تأیید می‌کند. وقتی جعبه محدود پیش‌بینی‌شده دارای IoU بیشتر از آستانه IoU داده شده باشد، پیش‌بینی به‌عنوان یک مثبت واقعی در نظر گرفته می‌شود، در غیر این صورت، یک مثبت کاذب در نظر گرفته می‌شود. سپس یک روش غیر حداکثر مهار (Non-Maximum Suppression) NMS برای نگه‌داشتن (مطمئن‌ترین جعبه‌ها و از بین بردن جعبه‌های کپی تکراری و زائد از همان اشیاء با تعیین آستانه اطمینان استفاده می‌شود. سرانجام، احتمالات کلاس مشروط با مقادیر اطمینان جعبه محدود منحصربه‌فرد برای تعیین نمره طبقه‌بندی هر شیء ضرب می‌شود که با استفاده از معادله ۲ محاسبه می‌شود.

$$Pr(class_i \mid object) \times Pr(object) \times IoU_{pred}^{truth} = \Pr(class_i) \times IoU_{pred}^{truth} \quad (۲)$$

[۱۵،۱۶]. در نهایت سرها که نقش آن در مورد رديـاب یک مرحله‌ای انجام پیش‌بینی متراکم است. پیش‌بینی متراکم پیش‌بینی نهایی است که از بردار حاوی مختصات جعبه محدود پیش‌بینی‌شده (مرکز، ارتفاع، عرض)، نمره اطمینان پیش‌بینی و برچسب تشکیل شده است.

در روش پیشنهادی از YOLOv3 استفاده شده است که همان‌طور که بیان شد یک آشکارساز شی، مبتنی بر CNN است که با استفاده از چارچوب darknet-53 ساخته شده است. این شبکه از ۵۳ لایه کانولوشن تشکیل شده است که از چارچوب قبلی Darknet19 بهبود یافته است. YOLOv3 مختصات جعبه محدود و احتمالات هر کلاس را مستقیماً از طریق رگرسیون ایجاد می‌کند. YOLOv3 یک تصویر ورودی را به شبکه‌های $S \times S$ تقسیم می‌کند و وقتی یک مرکز از یک هدف در هر سلول شبکه سقوط می‌کند، آن سلول وظیفه تشخیص اشیاء هدف را بر عهده دارد. این اشیاء را در سه مقیاس مختلف جعبه اتصال شناسایی می‌کند و هر یک از جعبه‌های اتصال دارای پنج جزء (c ،hw ،y ،x) است. مختصات (x,y) مرکز را نشان می‌دهد و (h,w) ارتفاع و عرض جعبه محدودکننده‌ای را نشان می‌دهد که C نشان‌دهنده نمره اطمینان است. نمره اطمینان نشان‌دهنده احتمال وجود یک شی در یک جعبه محدود است. نمره اطمینان توسط معادله ۱ محاسبه می‌شود.

$$C = \Pr(class_i) \times IoU_{pred}^{truth} \quad (۱)$$

[Downloaded from jhbmi.ir on 2024-04-19]

در این رابطه، $Pr(class_i | object)$ احتمال کلاس LAA را تعیین می‌کند. تابع Loss برای YOLOv3 چندین جعبه محدودکننده را در هر سلول شبکه پیش‌بینی می‌کند. برای محاسبه Loss برای مثبت واقعی، فقط یکی جعبه‌های محدودکننده مسئول تشخیص LAA می‌شود. برای این منظور، یکی را با بالاترین Intersection Over Union با حقیقت زمینه انتخاب می‌شود. این استراتژی منجر به تخصص در بین پیش‌بینی‌های جعبه محدود می‌شود. هر پیش‌بینی در پیش‌بینی اندازه‌ها و نسبت‌های خاص بهتر می‌شود. معادله ۳ عملکرد Loss را نشان می‌دهد:

$$loss = \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^{B} 1_{ij}^{obj} (2 - w_i \times h_i)[(x_i - x_i)^2 + (y_i - y_i)^2 + (w_i - w_i)^2 + (h_i - h_i)^2] + \lambda_{class} \sum_{i=0}^{S^2} \sum_{j=0}^{B} 1_{ij}^{obj} \sum_{c \in classes} p_i(c) \log(p_i(c)) + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^{B} 1_{ij}^{noobj} (c_i - \hat{c}_i)^2 + \sum_{i=0}^{S^2} \sum_{j=0}^{B} 1_{ij}^{obj} (c_i - \hat{c}_i)^2 \quad (۳)$$

نکته مهمی که باید اشاره شود این است که بهینه‌سازی CNN با استفاده از افزایش داده‌ها یک فرآیند مصنوعی برای بزرگ کردن یک مجموعه داده برای آموزش CNN با داده‌های متنوع است. تکنیک‌های افزایش شامل چرخش تصویر، تقسیم‌بندی مجموعه داده، برش تصویر، مقیاس‌گذاری، جابه‌جایی، آینه‌کاری است. این تکنیک‌ها توسط چندین محقق برای بهبود روند کلی یادگیری و عملکرد به کار گرفته شده‌اند [۱۴]. تصاویر مجموعه داده با استفاده از پنج تکنیک مختلف افزایش چرخش تصویر مانند چرخش (۳۰-و ۳۰+)، (۹۰-و ۹۰+) و (۱۸۰-و ۱۸۰+) نویز گوسی، معکوس کردن، بلور گوسی و اصلاح گاما استفاده شد. علاوه بر این برای بهبود نتایج تغییراتی بر روی پارامترهای پیش‌فرض نسخه yolov3 اعمال شد تا الگوریتم قوی‌تر گردد. برخلاف YOLOv3 در مدل پیشنهادی، به دلیل افزایش مقیاس‌های تشخیص، FPN را افزایش می‌دهد. همچنین کادرهای محصورکننده (Anchor Boxes) از ۹ به ۱۲ افزایش داده شد. ۱۲ جعبه لنگر تولیدشده با اجرای خوشه‌بندی k -means بر روی مجموعه داده‌ها عبارت‌اند از: (۴۰، ۲۵)، (۸۰، ۵۲)، (۱۱۲، ۸۴)، (۶۴، ۶۰)، (۱۱۰، ۹۸)، (۱۶۵، ۱۳۹)، (۱۱۲، ۱۱۵)، (۹۹، ۱۰۰)، (۱۱۲، ۷۰)، (۱۱۵، ۱۲۰)، (۱۱۸، ۱۱۶)، (۵۰، ۷۴).

نتایج

داده‌های آموزش شامل ۱۳۶۹ و تعداد تصاویر آزمایش ۵۴۵ تصویر است. حالات مختلف نتایج به دست آمده در شکل ۳ نمایش داده شده است. نتایج به‌دست‌آمده حاکی از عملکرد خوب شبکه پیشنهادی در مکان‌یابی LAA در تصویر است.

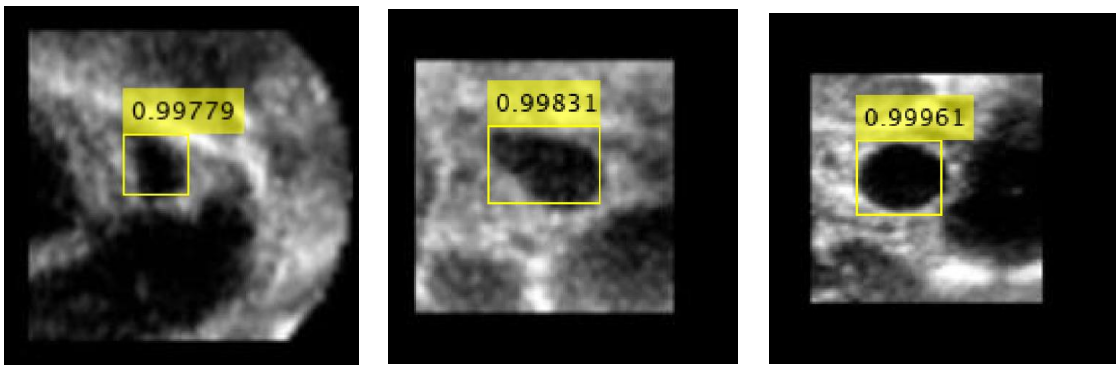

شکل ۳: نتایج به‌دست آمده از شبکه پیشنهادی جهت شناسایی ناحیه گوشک دهلیز چپ

[Downloaded from jhbmi.ir on 2024-04-19]

چندین معیار برای ارزیابی کارایی روش‌های تشخیص اشیاء وجود دارد. IoU معیاری برای اندازه‌گیری میزان سطح هم‌پوشانی بین کادرهای محصورکننده پیش‌بینی‌شده توسط شبکه با کادرهای محصورکننده واقعی است که طبق رابطه ۴ تعریف می‌شود:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \qquad (۴)$$

درصورتی‌که مقدار IoU بزرگ‌تر از ۰/۵ باشد، تشخیص، مثبت صحیح (True Positive) و در غیراین صورت، مثبت کاذب (False Positive) خواهد بود. منفی کاذب (False Negative) نیز به این معنی است که هدف در تصویر وجود دارد، اما شبکه آن را تشخیص نداده است. هیستوگرام نتایج دقت به‌دست‌آمده از تشخیص ناحیه LAA بر روی مجموعه تصاویر داده‌های آزمایش در شکل ۴ نشان داده شده است. همان‌طور که قابل‌مشاهده هست در اکثریت تصاویر، مقدار IoU نزدیک به ۱ است.

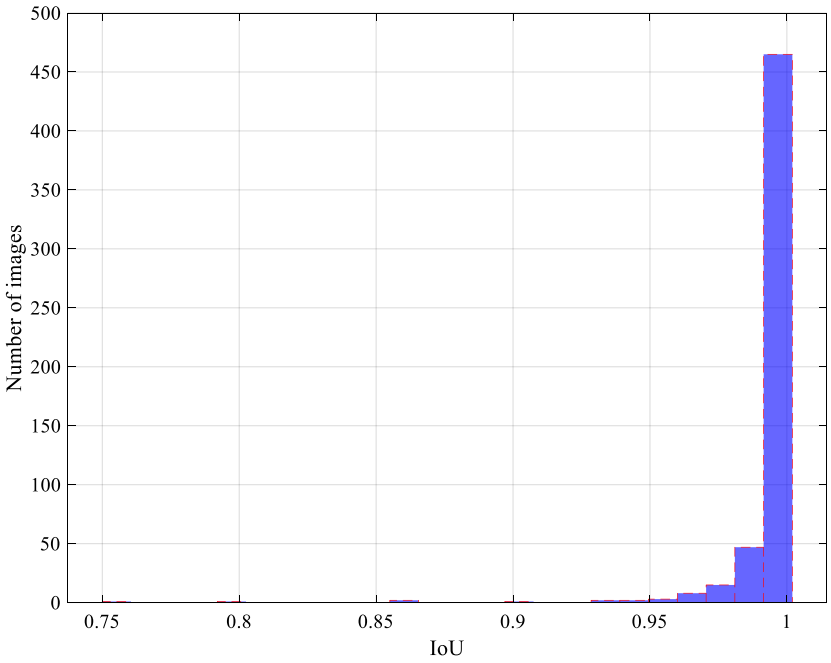

شکل ٤: هیستوگرام نتایج IoU به‌دست‌آمده از تشخیص ناحیه LAA بر روی مجموعه تصاویر داده‌های آزمایش

نتایج آماری IoU به‌دست‌آمده از تشخیص ناحیه LAA بر روی مجموعه تصاویر داده‌های آزمایش در جدول ۱ ارائه شده است که شامل میانگین، مینیمم، ماکزیمم و انحراف معیار مربوط به IoU است:

جدول ۱: نتایج آماری IoU از تشخیص ناحیه LAA بر روی مجموعه تصاویر داده‌های آزمایش

متغیرها	میانگین	مینیمم	ماکزیمم	انحراف معیار
IoU	۰/۹۹۳۷	۰/۷۵۶۴	۰/۰۹۹۹۹	۰/۰۱۸۰

نتایج نشان داد که CNN قادر به شناسایی ناحیه گوشک در مجموعه داده‌ها با میانگین ۹۹/۳۷٪ صحت بود. معیارهای دیگر شامل دقت و صحت هستند. دقت، شامل نرخ تعداد اشیاء درست تشخیص داده شده به کل تعداد اشیاء تشخیص داده

[Downloaded from jhbmi.ir on 2024-04-19]

شده است که می‌توان از طریق رابطه ۵ محاسبه نمود:

$$precision = \frac{TP}{TP + FP} \quad (۵)$$

صحت، نرخ تعداد اشیاء درست تشخیص داده شده به تعداد اشیاء موجود از کلاس خاص در مجموعه داده است؛ که طبق رابطه ۶ محاسبه می‌شود:

$$Recall = \frac{TP}{TP + FN} \quad (۶)$$

منحنی Recall-precision شبکه، در شکل ۵ مشاهده نشان داده شد.

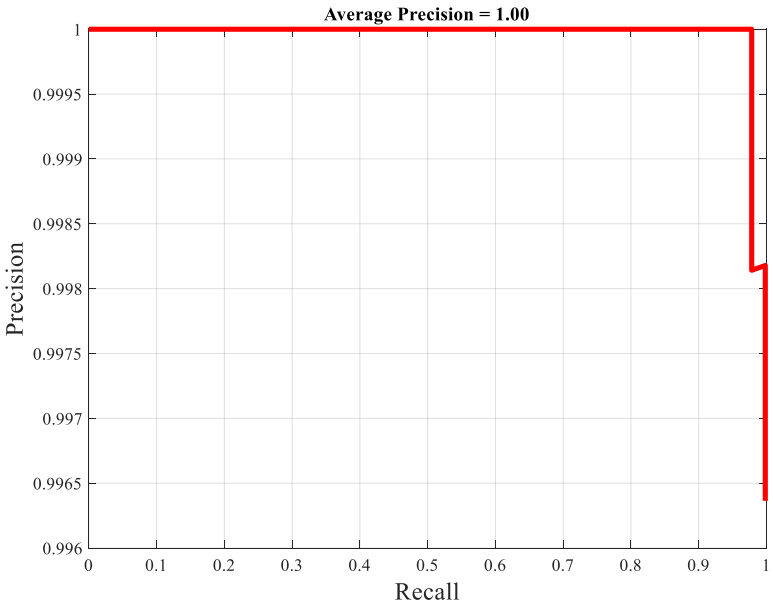

شکل ۵: منحنی Precision-Recall شبکه Yolov3 در تشخیص LAA

نمودار مربوط به total loss را به ازای iteration‌ها در تصویر ۶ قابل مشاهده است.

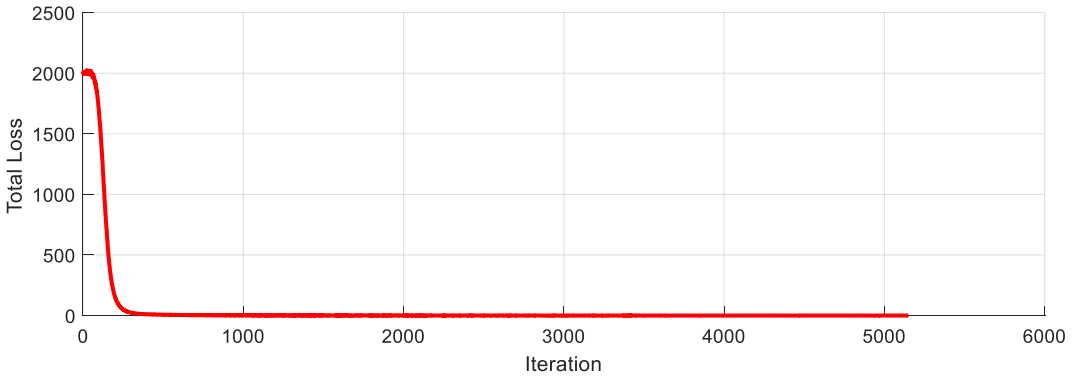

شکل ٦: مقدار total loss به ازای iterationهای شبکه Yolov3 در هنگام آموزش داده‌ها

[Downloaded from jhbmi.ir on 2024-04-19]

بحث و نتیجه‌گیری

در این مطالعه، یک الگوریتم CAD مبتنی بر YOLO برای ردیابی و تشخیص ناحیه LAA بر روی تصاویر محوری دوبعدی مشتق‌شده سه‌بعدی پیشنهاد شد که می‌تواند برای توسعه یک مدل برای تشخیص خودکار و آنالیز ناحیه فرود LAA استفاده شود. یک گام ضروری در برنامه‌ریزی بسته شدن LAA، شناسایی دستی ناحیه فرود LAA و اندازه‌گیری بلندترین و کوتاه‌ترین ابعاد و محیط آن است. کاربرد الگوریتم‌های یادگیری مبتنی بر ماشین در اکوکاردیوگرافی در مراحل ابتدایی خود است. در میان انواع مختلف یادگیری ماشین، کاربرد CNN در اکوکاردیوگرافی تنها در شناخت دیدگاه‌های به‌دست‌آمده از اکوکاردیوگرافی و کمی کردن ناهنجاری‌های حرکت دیوار گزارش شده است [۱۷]. به نظر می‌رسد CNN یک روش جذاب برای توسعه الگوریتم‌ها برای ردیابی خودکار و تشخیص منطقه فرود مسدودکننده‌ها از تصاویر دوبعدی مشتقات سه‌بعدی باشد. Ghayoumi Zadeh و همکاران تعداد تصاویری که موردبررسی و ارزیابی قرار دادند برابر با ۵۶۲ تصویر بود که به دقت ۹۰/۷٪ درصد دست پیدا کردند که در این پژوهش تعداد تصاویر (۱۹۱۴) و دقت (۹۹/۳۷٪) به‌دست آمد [۱۳].

عملاً برای تشخیص میزان قطر یک گوشک جهت انتخاب سایز واچمن، بایستی ابتدا ناحیه گوشک در اسلایس‌های تصاویر ویدیوی جداسازی شوند؛ که روش پیشنهادی بر مبنای شبکه‌های عصبی عمیق می‌تواند به‌صورت هوشمندانه این مهم را فراهم آورد.

از روش‌های محلی برای شناسایی می‌توان به RCNN، RPN، Fast R-CNN، Faster R-CNN و YOLO اشاره کرد. سرعت طبقه‌بندی در روش Fast R-CNN حدود ۱ فریم در هر ۲ ثانیه است که ۲۵ برابر سریع‌تر از R-CNN است. Simonyan و Zisserman [۱۸] در روشی برای یادگیری عمیق، مدل‌هایی خیلی عمیق با ۵ لایه کانولوشن ارائه کرد که این مدل‌ها اعم از ۱۱ لایه وزنی،۱۳ لایه وزنی، ۱۶ لایه وزنی و ۱۹ لایه وزنی است که سرعت Faster R-CNNبا مدل ۱۶ لایه‌ای زیسرمن، ۷ فریم در ثانیه، حدود ۲۰۰ برابر از R-CNNاست. در الگوریتم YOLO به‌مراتب خیلی بالاتر از Faster R-CNN نظر است [۱۸]. نتایج نشان داد که روش CNN برای شناسایی ناحیه گوشک دهلیز چپ قلب در تصاویر ویدیویی اکوی قلب ارائه‌شده در این مطالعه، بسیار دقیق و کارآمد است.

Pakizeh Moghadam و همکاران نیز تصاویر محوری دوبعدی را از مجموعه داده‌های سه‌بعدی استخراج کردند که نقطه اشتراک با این کار است؛ اما برای جداسازی ناحیه گوشک از ویژگی‌های استخراجی در ناحیه استفاده کردند. به این صورت که پس از پیش‌پردازش تصویر، تصاویر دودویی با استفاده از یک روش آستانه‌گذاری ایجاد کردند سپس یک ماتریس تصویر دودویی با استفاده از رویکرد مجاورت ۸ شکل گرفت و اسکن شد که منجر به قطعه‌بندی اشیاء با محیط بسته در تصویر شد. سپس از یک رویکرد مبتنی بر ویژگی برای تشخیص ناحیه LAA و سپس شناسایی ناحیه فرود دستگاه استفاده شد [۱۹] که این روش در مقایسه با روش ارائه شده در این مطالعه بسیار زمان‌بر و ممکن است بر روی تصاویر جدید نتایج قابل قبولی ارائه ندهد.

نکته‌ای که در این جا مطرح است، چگونگی تعیین تعداد ویژگی‌ها و میزان اهمیت و تأثیر آن‌ها در قدرت تشخیصی سیستم است. از سویی برخی از ویژگی‌ها به‌طور ضمنی با یکدیگر همبستگی دارند و می‌توانند نوعی پیچیدگی غیرضروری در حل مسئله ایجاد کنند (over fitting). در شبکه‌های عصبی ویژگی–محور، آنچه مسلم است، این است که هرگونه کاستی یا افزونگی در مراحل استخراج ویژگی و یا طراحی ساختار شبکه عصبی، به‌شدت بر روی کارایی سیستم عصبی از لحاظ درستی و حساسیت عملکرد سیستم هوشمند تأثیرگذار است، بنابراین ما را مجاب می‌کند که از روش‌هایی همچون شبکه‌های عصبی عمیق استفاده نماییم.

در برخی از کارهای گذشته از شبکه‌های عصبی U-Net برای جداسازی ناحیه گوشک استفاده کردند [۲۰]. باتوجه به این که ردیابی و دقت عملکرد مدل از جایگاه ویژه‌ای برخوردار است در این کار از شبکه‌های عصبی عمیق yolo به جای مدل‌های جداسازی استفاده شد.

تعداد کمی از محققان بر LAA در حوزه پردازش تصویر تمرکز کرده‌اند و بیشتر پژوهش‌های گذشته در زمینه تصاویر CT بوده است که در مطالعه حاضر بر خلاف کارهای گذشته بر روی تصاویر اکوکاردیوگرافی متمرکز شده است.

انسداد گوشک دهلیز چپ با استفاده از دستگاه‌های ساخته شده یک‌روند رو به رشد است. این مطالعه با هدف ایجاد یک سیستم تشخیصی به کمک رایانه برای شناسایی LAA در تصاویر اکوکاردیوگرافی انجام شده است. ارائه روشی نوین جهت جداسازی ناحیه کوشک از اهمیت منحصربه‌فردی برخوردار است. اهمیت موضوع موردمطالعه را می‌توان در قالب

[Downloaded from jhbmi.ir on 2024-04-19]

پردازش تصویر و مبحث پزشکی موردتوجه قرار داد. آنچه مسلم است ارتباط گوشک دهلیز چپ با سکته مغزی در بیماران با فیبریلاسیون قلبی است. در این پژوهش سعی شده است تا اصول طراحی یک سیستم هوشمند CAD تصویر محور برای تشخیص ناحیه گوشک دهلیز چپ بر اساس تصاویر اکوکاردیوگرافی قلب ارائه شود. این سیستم بر مبنای شبکه‌های عصبی کانولوشن استوار است و امتیاز این نوع از ساختارهای هوشمند در این است که برای تشخیص تصاویر، دیگر نیازی به تعریف و استخراج دستی ویژگی‌ها وجود ندارد. این شبکه‌ها به‌گونه‌ای طراحی شده‌اند تا با مدل‌سازی ساختار بینایی و فرآیندهای تشخیصی وابسته به آن در مغز، با استخراج خودکار ویژگی‌های موردنیاز، به یادگیری و شناسایی هدف موردنظر بپردازند. نتایج مدل پیشنهادی حاکی از دقت شناسایی محدوده گوشک دهلیز چپ قلب است. با توجه به سایزهای مختلف مسدودکننده‌ها، لازمه انتخاب صحیح سایز مسدودکننده در سیستم‌های هوش مصنوعی، شناسایی دقیق محل گوشک می‌باشد. نتایج این پژوهش برای متخصصان قلب و اکوکاردیوگرافی که در جهت جراحی و نصب مسدودکننده‌های گوشک دهلیز چپ فعالیت می‌کنند و به خصوصی سیستم‌های هوش مصنوعی در این زمینه، می‌تواند بسیار مفید واقع شود.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

References

1. Go AS, Hylek EM, Phillips KA, Chang Y, Henault LE, Selby JV, et al. Prevalence of diagnosed atrial fibrillation in adults: national implications for rhythm management and stroke prevention: the AnTicoagulation and Risk Factors in Atrial Fibrillation (ATRIA) Study. JAMA 2001;285(18):2370-5. doi: 10.1001/jama.285.18.2370.

2. Boriani G, Diemberger I. Globalization of the epidemiologic, clinical, and financial burden of atrial fibrillation. Chest 2012;142(6):1368-70. doi: 10.1378/chest.12-1091

3. Colilla S, Crow A, Petkun W, Singer DE, Simon T, Liu X. Estimates of current and future incidence and prevalence of atrial fibrillation in the US adult population. Am J Cardiol 2013;112(8):1142-7.

4. Hohnloser SH, Kuck K-H, Lilienthal J, investigators P. Rhythm or rate control in atrial fibrillation—Pharmacological Intervention in Atrial Fibrillation (PIAF): a randomised trial. Lancet 2000;356(9244):1789-94. doi: 10.1016/s0140-6736(00)03230-x.

5. Horie N, Tateishi Y, Morikawa M, Morofuji Y, Hayashi K, Izumo T, et al. Acute stroke with major intracranial vessel occlusion: characteristics of cardioembolism and atherosclerosis-related in situ stenosis/occlusion. J Clin Neurosci 2016;32:24-9. doi: 10.1016/j.jocn.2015.12.043.

6. American College of Physicians. Guidelines for medical treatment for stroke prevention. Ann Intern Med 1994;121(1):54-5. doi: 10.7326/0003-4819-121-1-199407010-00009

7. Holmes DR, Reddy VY, Turi ZG, Doshi SK, Sievert H, Buchbinder M, et al. Percutaneous closure of the left atrial appendage versus warfarin therapy for prevention of stroke in patients with atrial fibrillation: a randomised non-inferiority trial. Lancet 2009;374(9689):534-42.

8. Viles-Gonzalez JF, Kar S, Douglas P, Dukkipati S, Feldman T, Horton R, et al. The clinical impact of incomplete left atrial appendage closure with the Watchman Device in patients with atrial fibrillation: a PROTECT AF (Percutaneous Closure of the Left Atrial Appendage Versus Warfarin Therapy for Prevention of Stroke in Patients With Atrial Fibrillation) substudy. J Am Coll Cardiol 2012;59(10):923-9.

9. Leventic H, Babin D, Velicki L, Galie I, Zlokolica V, editors .Semi-automatic left atrial appendage segmentation from 3D CCTA images. 2017 International Symposium ELMAR; 2017 Sep 18-20; IEEE; 2017. doi: 10.23919/ELMAR.2017.8124430

10. Al WA, Yun ID, editors. Actor-Critic Reinforcement Learning for Automatic Left Atrial Appendage Segmentation. IEEE International Conference on Bioinformatics and Biomedicine (BIBM); 2018 Dec 3-6; Madrid, Spain: IEEE; 2018. doi: 10.1109/BIBM.2018.8621575

11. Wang L, Feng J, Jin C, Lu J, Zhou J, editors. Left atrial appendage segmentation based on ranking 2-D segmentation proposals. Springer: International Workshop on Statistical Atlases and Computational Models of the Heart; 2016. doi:10.1007/978-3-319-52718-5_3

12. Jin C, Feng J, Wang L, Yu H, Liu J, Lu J, et al. Left atrial appendage segmentation and quantitative assisted diagnosis of atrial fibrillation based on fusion of temporal-spatial information. Comput Biol Med 2018;96:52-68. doi: 10.1016/j.compbiomed.2018.03.002.

13. Ghayoumi Zadeh H, Fayazi A, Melikian N, J Monaghan M, Eskandari M. Algorithm for Recognition of Left Atrial Appendage Boundaries in Echocardiographic Images. Iranian Journal of Medical Physics 2021;18(2):123-32. doi: 10.22038/IJMP.2020.43736.1663

14. Redmon J, Divvala S, Girshick R, Farhadi A, editors. You only look once: Unified, real-time object detection. IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016 Jun 27-30; Las Vegas, NV, USA: 2016. doi: 10.1109/CVPR.2016.91

[Downloaded from jhbmi.ir on 2024-04-19]

15. He K, Zhang X, Ren S, Sun J. Spatial pyramid pooling in deep convolutional networks for visual recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence 2015;37(9):1904-16. doi: 10.1007/978-3-319-10578-9_23
16. Chen LC, Papandreou G, Kokkinos I, Murphy K, Yuille AL. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. IEEE Transactions On Pattern Analysis and Machine Intelligence 2017;40(4):834-48.
17. Alsharqi M, Woodward W, Mumith J, Markham D, Upton R, Leeson P. Artificial intelligence and echocardiography. Echo Res Pract 2018; 5(4): R115–R25.
18. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556
19. Pakizeh Moghadam A, Eskandari M, Monaghan M, Haddadnia J. A Semi-Automated Algorithm for Segmentation of the Left Atrial Appendage Landing Zone: Application in Left Atrial Appendage Occlusion Procedures. J of Biomed Phys & Eng 2020;10(2):205-14. doi:10.31661/jbpe.v0i0.1912-1019
20. Jia S, Despinasse A, Wang Z, Delingette H, Pennec X, Jaïs P, et al. Automatically segmenting the left atrium from cardiac images using successive 3D U-nets and a contour loss. arXiv:1812.02518

[Downloaded from jhbmi.ir on 2024-04-19]

Original Article

Journal of Health and Biomedical Informatics
Medical Informatics Research Center
2021; 8(3): 315-325

Segmentation of the Left Atrial Appendage in the Echocardiographic Images of the Heart Using a Deep Neural Network

Ghayoumi Zadeh Hossein[1,2]*, Fayazi Ali[3], Rezaee Khosro[4], Gholizadeh Mohammad Hossein[3], Eskandari Mehdi[5]

• **Received: 9 Jul 2021** • **Accepted: 15 Nov 2021**

Introduction: Cardiovascular diseases are one of the leading causes of mortality in today's industrial world. Occlusion of left atrial appendage (LAA) using the manufactured devices is a growing trend. The objective of this study was to develop a computer-aided diagnosis system for the identification of LAA in echocardiographic images.

Method: The data used in this descriptive analytical study included 3D echocardiographic images of the heart of 32 patients in King's College Hospital in London. All patients were treated successfully using the LAA closure device. A total of 208 two-dimensional images were first obtained from each 3D echocardiographic image data set. Then, 1914 images in which the LAA region was clearly recognizable were selected for this study. The proposed neural network was compiled based on the YOLOv3 algorithm. Finally, 1369 and 545 images were used for training and testing the algorithm, respectively.

Results: The performance of the algorithm in detecting the LAA on a set of 545 images was compared with the regions detected in similar images by an expert in echocardiography through intersection over union (IOU). The algorithm was able to correctly identify the LAA region in all 545 examined images with an average IOU of 99.37%.

Conclusion: The proposed image-based algorithm could detect LAA region in echocardiographic images with a high accuracy. This method can be used to develop algorithms for automatic analysis of the LAA region to determine the size of the closure device and to plan an efficient procedure in LAA occlusion methods.

Keywords: Echocardiography, Deep Neural Network, Convolutional Neural Network (CNN), Atrial Fibrillation (AF), Left Atrial Appendage (LAA)

• **Citation:** Ghayoumi Zadeh H, Fayazi A, Rezaee K, Gholizadeh MH, Eskandari M. Segmentation of the Left Atrial Appendage in the Echocardiographic Images of the Heart Using a Deep Neural Network. Journal of Health and Biomedical Informatics 2021; 8(3): 315-25. [In Persian]

1. Non-Communicable Diseases Research Center, Rafsanjan University of Medical Sciences, Rafsanjan, Iran
2. PhD. in Biomedical Engineering, Assistant Professor, Department of Electrical Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran
3. PhD. in Electrical Engineering, Assistant Professor, Department of Electrical Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran
4. PhD. in Biomedical Engineering, Assistant Professor, Department of Biomedical Engineering, Meybod University, Meybod, Iran
5. MD, FRACP, King's College Hospital, London, United Kingdom
***Corresponding Author:** Hossein Ghayoumi Zadeh
Address: Department of Electrical Engineering, Faculty of Engineering, Vali-e-Asr University of Rafsanjan, Imam Khomeini Square, Rafsanjan, Iran
• **Tel:** 034-31312398 • **Email:** h.ghayoumizadeh@vru.ac.ir

[Downloaded from jhbmi.ir on 2024-04-19]