

Automatic Recognition of Non-alcoholic Fatty Liver by using Transfer Deep Learning Networks from Ultrasound Images

Hamed Zamanian¹, Ahmad Shalbf^{2,*}

¹ Ph.D. candidate, Department of Biomedical Engineering and Medical Physics, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran

² Assistant Professor, Department of Biomedical Engineering and Medical Physics, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran

ABSTRACT

Background:

One of the common diseases is fatty liver disease, which can be seen significantly in patients with excessive obesity as well as patients with diabetes. Using ultrasound imaging methods, it can be possible to identify and evaluate patients affected by this disease. The aim of this study was to use advanced machine learning algorithms for better and more accurate classification of the acquired images from different patients affected by fatty liver disease.

Materials and Methods:

In this study, the acquired ultrasound images of 55 patients suspicious as having fatty liver disease have been used. The level of fat for different patients was labeled by biopsy sampling. Based on this experiment, the patients were predicated as having a fatty liver when more than 5% of their liver hepatocytes were accompanied by infiltration of fat. Then, we utilized some pre-trained convolutional neural networks, including Inception-ResNetV2, GoogleNet, and AlexNet to extract high-level features of the collection of the acquired images. After that, a SoftMax layer was implemented to classify the images that indicated fatty liver.

Results:

The resulted precisions for Inception-ResNetV2, GoogleNet, and AlexNet pre-trained convolutional networks were 0.8108, 0.9459, and 0.9932, respectively. Also, the area under the curve of receiver operating characteristics (AUC) for these networks were 0.9757, 0.9960, and 0.9963, respectively.

Conclusion:

The proposed intelligent algorithm can help sonography experts to recognize the liver tissues with fat automatically and accurately without the need for a specialist to assign the region of interest for evaluation.

Keywords: Fatty liver, Ultrasound imaging, Machine learning, Deep transfer learning networks

please cite this paper as:

Zamanian H, Shalbf A. Automatic Recognition of Non-alcoholic Fatty Liver by using Transfer Deep Learning Networks from Ultrasound Images. *Govaresh* 2020;25:188-197.

*Corresponding author:

Ahmad Shalbf, PhD
Department of Biomedical Engineering and Medical Physics,
School of Medicine, Shahid Beheshti University of Medical
Sciences, Tehran, Iran

Tel: + 98 21 23872566
Fax: + 98 21 22439941
E-mail: shalbf@sbmu.ac.ir

Received: 07 Apr. 2020
Edited: 19 Aug. 2020
Accepted: 20 Aug. 2020

تشخیص اتوماتیک چربی کبد با استفاده از شبکه‌های یادگیری انتقالی عمیق از روی تصاویر اولتراسوند

حامد زمانیان^۱، احمد شالباف^{۲*}

^۱ دانشجوی دکتری، گروه مهندسی و فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران
^۲ استادیار، گروه مهندسی و فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران

چکیده

زمینه و هدف:

امروزه یکی از رایج‌ترین بیماری‌های موجود در زمینه کبد، عارضه چربی کبد است که به میزان قابل توجهی در افراد مبتلا به چاقی مفرط و بیماران دیابتی دیده می‌شود. با استفاده از روش تصویربرداری اولتراسوند می‌توان به شناسایی و ارزیابی افراد مبتلا به این عارضه پرداخت. لذا هدف از این مطالعه، استفاده از الگوریتم‌های مبتنی بر یادگیری ماشین پیشرفته برای تشخیص اتوماتیک دقیق چربی کبد از روی تصاویر اولتراسوند می‌باشد.

روش بررسی:

در این مقاله از تصاویر اولتراسوند گردآوری شده از ۵۵ فرد که مبتلا به چاقی مفرط بوده و قصد جراحی چربی‌برداری به شیوه لاپاروسکوپی داشته‌اند، استفاده شده است. سطح چربی کبد بیماران مختلف مورد آزمایش، با استفاده از نمونه‌برداری تعیین شده است. براساس نمونه‌برداری انجام شده، دارا بودن کبد چرب به بیمارانی اطلاق می‌شود که بیش از ۵٪ هیپاتوسیت کبدی آنها با نفوذ چربی همراه شده است. در این مطالعه، ما از سه شبکه عصبی عمیق از پیش آموزش دیده شده کانولوشنی به عنوان الگوریتم‌های پیشرفته یادگیری ماشین با نام‌های AlexNet، GoogleNet، Inception-ResNetV2 برای استخراج ویژگی‌های سطح بالای مجموعه تصاویر اولتراسوند جمع‌آوری شده استفاده کردیم. پس از استخراج ویژگی از تصاویر، از لایه SoftMax برای کلاس‌بندی تصاویر شامل چربی کبد استفاده شد.

یافته‌ها:

دقت بدست آمده برای شبکه‌های عصبی عمیق Inception-ResNetV2، GoogleNet و AlexNet در تشخیص اتوماتیک چربی کبد به ترتیب، برابر با ۰/۸۱۰۸، ۰/۹۴۵۹ و ۰/۹۹۳۲ حاصل شد. میزان سطح زیر منحنی مشخصه‌های کاری گیرنده (AUC) برای این سه شبکه نیز به ترتیب برابر با ۰/۹۷۵۷، ۰/۹۹۶۰ و ۰/۹۹۶۳ بدست آمد.

نتیجه‌گیری:

الگوریتم هوشمند پیشنهادی به متخصصین سونوگرافی کمک می‌کند تا به طور اتوماتیک و با دقت بالا، چربی بافت کبدی بیماران را بی‌نیاز از حضور یک متخصص برای تعیین ناحیه مورد نظر تشخیص دهند.

کلید واژه: کبد چرب، تصویربرداری اولتراسوند، یادگیری ماشین، شبکه‌های یادگیری انتقالی عمیق

گوارش / دوره ۲۵، شماره ۳ / پاییز ۱۳۹۹ / ۱۸۸-۱۹۷

*نویسنده مسئول: احمد شالباف

استادیار، گروه مهندسی و فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهید بهشتی
تهران، ولنجک، میدان شهید شهریار، خیابان کودکان، دانشکده پزشکی

تلفن: ۰۲۱-۲۳۸۷۲۵۶۶

نمابر: ۰۲۱-۲۲۴۳۹۹۴۱

پست الکترونیک: shalbaf@sbm.ac.ir

تاریخ دریافت: ۹۹/۰۱/۱۹

تاریخ اصلاح نهایی: ۹۹/۰۵/۲۹

تاریخ پذیرش: ۹۹/۰۵/۳۰

زمینه و هدف:

کبد، به عنوان یک جزء از سیستم گوارشی، یکی از حیاتی‌ترین ارگان‌هایی معرفی می‌شود و نقش غیر قابل انکاری در زنجیره گوارش مواد غذایی دارد؛ چرا که وظیفه تولید صفرا^۱، به عنوان یک ترکیب آلكالینی برای هموارسازی روند شکست مولکول‌های چربی، را عهده‌دار می‌باشد. (۱) یکی از بیماری‌های شایع این عضو بیماری کبد چرب می‌باشد. تاکنون، روش‌های درمانی متعددی برای رفع و یا کاهش اثرات چربی کبد پیشنهاد و اجرا شده است. (۲ و ۳) با توجه به اهمیت توجه جدی به این بیماری، در سال‌های اخیر، استفاده از روش‌های مبتنی بر هوش مصنوعی برای افزایش دقت تشخیص‌ها براساس تصاویر اولتراسوند جمع‌آوری شده از بافت کبدی توسعه یافته است. (۴). تصویربرداری اولتراسوند یکی از روش‌های رایج برای فرایندهای تشخیصی پزشکی

1. Bile

محاسباتی بالای آن، وابستگی نتیجه این الگوریتم به روش بخش بندی، تعیین ناحیه مورد ارزیابی توسط یک فرد متخصص و نظرات متعدد متخصصان می باشند. هدف از این مقاله، رفع مشکلات ذکر شده در بالا با استفاده از الگوریتم‌های یادگیری عمیق به عنوان یکی از روش های پیشرفته یادگیری ماشین برای ارزیابی نفوذ چربی در بافت کبدی از روی تصاویر اولتراسوند جمع آوری شده از بافت کبدی و همچنین، مقایسه آنها برای بررسی عملکرد است. تصاویر اولتراسوند مورد استفاده در این کار از ۵۵ بیمار مبتلا به چاقی مفرط پیش از عمل جراحی چربی برداری گردآوری شده است.

ساختار کلی این مقاله در چند بخش تقسیم بندی می شود؛ در بخش نخست، به توصیف گروه بیمارانی که برای تصویربرداری استفاده شدند، و داده‌های مورد کاربرد می پردازیم. سپس روش پیاده سازی شبکه‌های یادگیری برای ارزیابی سطح چربی کبد توصیف می گردد. در این قسمت، نحوه بکارگیری یادگیری انتقالی عمیق برای استخراج ویژگی از تصاویر به کمک شبکه‌های مبتنی بر CNN ارائه می شود. پس از آن، نتایج بدست آمده برای ارزیابی نفوذ چربی در بافت کبدی ارائه و در نهایت، در مورد مزایا و معایب الگوریتم‌های بکار برده شده بحث خواهد شد.

روش بررسی:

داده‌های مورد استفاده


در این مطالعه، از تصاویر اولتراسوند دریافت شده از ۵۵ متقاضی که مبتلا به چاقی مفرط بوده و قصد جراحی چربی برداری به شیوه لاپاروسکوپی داشته‌اند استفاده گردید (متوسط سن ۴۰ سال، ۲۰٪ مرد، متوسط شاخص BMI معادل ۴۵/۹). تصاویر اکوکاردیوگرافی مود B یک تا دو روز پیش از عمل جراحی بر روی بیماران در دانشگاه پزشکی ورشو لهستان، اخذ شده است. این اطلاعات، براساس لیسانس بین المللی انتساب خلایق عمومی^۵ ۴/۰ (۲۷) امکان استفاده، توزیع و بازتولید نامحدود را در اختیار کاربران و محققین قرار داده است. داده‌های اولتراسوند از طریق یک سیستم اولتراسوند GE Vivid E9، مجهز به یک پروب فعال در فرکانس ۲/۵ MHz جمع آوری شده‌اند. تصاویر در قالب فرمت DICOM برای کاربردهای offline ذخیره شده و از طریق آرشیو Zenodo (<https://doi.org/10.5281/zenodo.1009146>) قابل دسترسی هستند. در این کار، برای در نظرگیری حرکت‌های طبیعی بدن و تغییرات شکل تصویربرداری شده برای بیماران، از هر بیمار، ۱۰ تصویر مختلف با فاصله زمانی یکسان گرفته شده و در بررسی مورد استفاده قرار گرفته است. برای هر بیمار، یک نمونه برداری کبدی در حین جراحی چربی برداری، به عنوان بخشی از پروتکل معمول انجام شده و به این سبب میزان نفوذ چربی در کبد هر بیمار تعیین شده است. ارزیابی پاتولوژیکی این نمونه‌ها توسط یک پاتولوژیست، که معیارها و توصیه‌های شبکه تحقیقات کلینیکی را دنبال می کند، انجام گرفته است (۲۸). براساس این ارزیابی، بیماران با سطح نفوذ چربی در سلول‌های کبدی بیشتر از ۵٪،

به شمار می‌رود (۸-۵) در این راه حل، یادگیری ماشین، به عنوان یکی از ابزارهای این توسعه، تکنیک‌هایی را ارائه می‌نماید که به طور خودکار براساس تجربه از داده‌های موجود به آموزش خود می‌پردازند. کاربردهای متنوعی برای این ابزارها در نظر گرفته شده است که از آن جمله می‌توان به طراحی مدل‌های ساختاری، تشخیص الگوها، و فرایندهای پیش‌بینی اشاره کرد (۹-۱۱). الگوریتم‌های یادگیری اصولاً براساس ویژگی‌های داده‌های موجود برای سیستم عمل می‌کنند. به عبارتی دیگر، هدف عملکردی آنها یادگیری ویژگی‌های موثر موجود در داده‌ها برای فعالیت صورت گرفته است (۱۲). در این راستا، تلاش‌های متعددی برای استخراج ویژگی‌های موثری از تصاویر اولتراسوند و در نهایت طبقه بندی بهتر با استفاده از الگوریتم‌های یادگیری ماشین برای تخمین بیماری کبد چرب صورت گرفته است (۱۳).


در ۲۰۰۵، کائو و همکاران توانستند با کمک ویژگی‌های مشترک بعد بخشی^۱ و ماتریس هم‌رخداد لبه بافت، از تصاویر اولتراسوند ویژگی‌ها را استخراج کرده و سپس، کلاس بندی را با استفاده از الگوریتم‌های SVM انجام دهند (۱۴). در ۲۰۱۲، آچاریا نیز یک الگوریتم ترکیبی بر پایه شرایط بافت، روش انتقال wavelet، و طیف‌های مرتبه بالاتر تصاویر، برای استخراج ویژگی‌های موثر و دسته بندی با استفاده از کلاس بندی های فازی و SVM معرفی کرد. آندرید با کمک رویکرد کلاس بندی نیمه اتوماتیک، چند ویژگی از تصاویر جمع آوری شده استخراج می نمود و از روش‌های شبکه عصبی، SVM و روش نزدیکترین k همسایگی برای کلاس بندی تصاویر گردآوری شده استفاده می کرد (۱۵). در ۲۰۱۴، گائو از GLCM برای استخراج ۲۲ ویژگی با بیشترین نرخ تغییرات از تصاویر اولتراسوند جمع آوری شده از بافت کبدی با هدف کلاس بندی استفاده کرد (۱۶). در ۲۰۱۶، آچاریا و همکاران از تصاویر اولتراسوند و الگوریتم انتقال^۲ curvelet (CT)، برای تفکیک تصاویر استفاده کردند که مطابق با آنروپی تصاویر و با کمک یک روش تحلیل حساسیت محلی (LSDA)^۳، به انتخاب ویژگی‌های موثر در کلاس بندی می‌پرداختند و پس از رتبه بندی با کمک f -value برای کلاس بندی به شبکه‌های مختلف اعمال می شدند. (۱۷) در ۲۰۱۷، کاپیلی و گروه همکاران استفاده از یک الگوریتم مبتنی بر یادگیری ماشین فوق العاده سریع^۴ و قابل اطمینان (ELM) برای سطح بندی میزان نفوذ چربی در تصاویر اولتراسوند ارائه کردند (۱۸). در همان سال، حسن از الگوریتم زنجیره‌ای اتوانکدر پراکنده استخراج ویژگی‌های تصاویر برای بیماری‌های ناحیه‌ای ارائه نمود و با استفاده از لایه SoftMax به کلاس بندی آنها برای بیماری‌های مختلف پرداخت (۱۹). الگوریتم پیشنهادی لوو مبتنی بر استخراج ویژگی و کلاس بندی تصاویر، از ویژگی‌های ژئومتری ناحیه کبدی هدف بود (۲۰). کارهای متعدد دیگری نیز در این زمینه انجام و به صورت گزارش ارائه شده‌اند (۲۵-۲۱) اما این روش‌ها دارای مشکلاتی از جمله وابستگی به شرایط داده‌های جمع آوری شده، عدم امکان استخراج همه ویژگی‌های موثر تصویر، پیچیدگی

1. Fractal dimension
2. Curvelet Transform algorithm
3. Locality sensitive discriminant analysis
4. fast Extreme Learning Machine

5. Creative Commons Attribution



شکل ۱: هیستوگرام توزیع سطح نفوذ چربی نسبت به جمعیت بیماران مورد آزمایش



شکل ۲: نمایش دو نمونه از تصاویر التراسوند برای بیماران: الف) بدون کبد چرب (شاخص ۳٪)، ب) با کبد چرب (شاخص ۲۰٪)

جمله می‌توان به انتقال‌های سنتی^۱ (۲۹)، شبکه‌های GAN^۲ (۳۰)، انتقال بافت^۳ (۳۱)، تکنیک پاک کردن تصادفی^۴ (۳۲) و تکنیک افزودن تصادفی نویز اشاره نمود. یکی از ساده‌ترین روش‌های موجود، روش انتقال سنتی تصاویر است. در این روش رایج، ترکیبی از انتقال‌های رایج تصویر و اصلاح رنگ در تصاویر موجود صورت گرفته و به عنوان تصویر جدید مورد استفاده قرار می‌گیرد. برخی از این انتقال‌های رایج عبارتند از: چرخش، انعکاس، تغییر مقیاس (زوم کردن)، و برش دادن. در زمینه تغییر رنگ تصاویر نیز از الگوریتم‌های مختلفی بهره برده می‌شود، مثل: متعادل‌سازی هیستوگرام، افزایش کنتراست یا روشنایی تصاویر، متعادل کردن سفیدی تصاویر، و بلور کردن. این روش به عنوان یک روش سریع و قابل اتکا برای بسیاری از شبکه‌های آموزش عمیق قابل استفاده می‌باشد (۳۳). با توجه به نوع تصاویر خروجی اولتراسوند، در این مطالعه تنها از دوران تصاویر برای یکسان‌سازی تعداد تصاویر در کلاس افراد سالم استفاده شده است؛ بطوری‌که هر تصویر به میزان تنها ۲ درجه به صورت پادساعتگرد دوران داده می‌شود. با این روش، تعداد تصاویر در دو کلاس به سطح قابل مقایسه‌ای رسانده می‌شوند.

به بیماران با کبد چرب اطلاق شده است. لذا، بیماران به دو دسته دارای کبد چرب (سطح نفوذ بیشتر از ۵٪)، و افراد سالم (نفوذ چربی کمتر از ۵٪) تقسیم‌بندی می‌شوند. شکل ۱ هیستوگرام توزیع نفوذ چربی در کبد هر بیمار را برای افراد مورد آزمایش نشان می‌دهد.

پیش پردازش تصاویر

تصاویر گردآوری شده برای بیماران مختلف، با ابعاد 434×636 پیکسل (به ازاء هر پیکسل با اندازه 0.373×0.373 میلی متر) اخذ شده است. در بانک داده جمع‌آوری شده، تعداد تصاویر برای بیماران متقاضی در دو کلاس یکسان نمی‌باشد (۳۸ فرد با چربی کبد و ۱۷ فرد سالم). برای حل این مشکل، از روش‌های افزایش تصاویر استفاده می‌شود. این نوع روش‌ها، بدون افزودن تصویر یا داده جدیدی، از همان داده‌های قبلی، یک سری اطلاعات جدید تولید می‌کند؛ به عبارتی دیگر، در این روش‌ها، هیچ تصویر جدیدی با ویژگی‌های متفاوت به مجموعه تصاویر افزوده نمی‌شود، بلکه فقط با تغییر دادن ترکیب ویژگی‌های موجود، تعداد دادگان در همه کلاس‌ها قابل مقایسه می‌شود. روش‌های مختلفی برای انجام این کار معرفی شده است که از آن

1. Traditional transformation
2. Generative adversarial Networks
3. Texture transfer
4. Random erasing technique

ویژگی‌های استخراج شده به روش GLCM

الگوریتم ماتریس هم رخداد سطح خاکستری (GLCM)، یکی از روش‌های رایج در استخراج ویژگی‌های تصاویر مورد استفاده است. (۳۴ و ۳۵) این روش، اطلاعات قابل کاربردی را برای ارزیابی الگوهای بافتی تصاویر مورد نظر فراهم می‌آورد. در این الگوریتم، در همسایگی‌های تعریف شده، به دلیل خصوصیات و وابستگی مرتبط، ویژگی‌های قابل اهمیت استخراج شده و به عنوان یک معیار اختصاصی برای هر تصویر در بیان خصوصیات و ویژگی‌های مختلف آن مورد استفاده قرار می‌گیرد. در این مطالعه، با توجه به نوع تصاویر و عدم امکان تفکیک دقیق مرکز کبد و کلیه سمت راست، استخراج ویژگی با استفاده از روش GLCM به ازاء کل ناحیه مرکزی تصویر در نظر گرفته شد و محدود به یک ناحیه مورد نظر^۲ (ROI) محدود نشد و تنها ناحیه حاشیه‌ای قابل تفکیک تصویر که فاقد اطلاعات است، حذف گردید تا نیازی به یک متخصص برای تعیین ناحیه ROI نداشته باشد. برای استخراج ویژگی‌های تصاویر به روش GLCM، از ۹ حالت مختلف به ازاء فواصل ۱، ۲ و ۳ پیکسلی و زوایای ۰، ۴۵ و ۹۰ درجه‌ای استفاده شد. برای این تصاویر، ۲۲ ویژگی استخراج شد که عبارتند از: ممان دوم زاویه‌ای^۱، آنترپوی، عدم شباهت^۲، کنتراست، دیفرانسیل معکوس، کورولیشن، همگنی، اتوکورولیشن، سایه خوشه^۳، برجستگی خوشه^۴، ماکزیمم احتمال، مجموع مربعات، متوسط مجموع آنترپوی مجموع، واریانس دیفرانسیل، آنترپوی دیفرانسیل، اندازه اطلاعات کورولیشن نرمالایز شده، اندازه اطلاعات کورولیشن نمایی، ماکزیمم ضریب کورولیشن^۵، دیفرانسیل معکوس نرمالایز شده^۶ (INV)، و ممان دیفرانسیل معکوس نرمالایز شده^۷ (IDN). این ویژگی‌ها دارای مقادیر مختلفی هستند که از نظر رنج تغییرات متفاوت از یکدیگرند. لذا، در ابتدا، داده‌های هر ستون از ویژگی‌های استخراج شده، نرمال‌سازی شده و سپس، کواریانس ویژگی‌های بدست آمده نسبت به هم محاسبه می‌شود. ویژگی‌های دارای بیشترین کواریانس با سایر ویژگی‌ها، دلیل شامل بودن اثر و عملکرد آنها، با اهمیت‌تر فرض شده و به عنوان ویژگی‌های غالب در نظر گرفته می‌شوند. با انتخاب این ویژگی‌ها، در وهله نخست، اثرگذارترین ویژگی‌ها برای کلاس‌بندی نهایی مورد استفاده قرار می‌گیرند و دوم اینکه حجم محاسبات بعدی کاهش می‌یابد. با این کار، تعداد ویژگی‌های استخراج شده به ۱۲ عدد کاهش یافت.

ویژگی‌های استخراج شده با شبکه‌های یادگیری عمیق

امروزه شبکه‌های یادگیری عمیق از جمله شبکه‌های عصبی کونولوشنی CNN به عنوان یکی از روش‌های پیشرفته یادگیری ماشین، به عنوان یکی از اعضای خانواده سیستم‌های هوشمند، برای پردازش‌های

1. Gray level co-occurrence matrix
2. Region of interest
3. Angular Second moment
4. Dissimilarity
5. Cluster Shade
6. Cluster Prominence
7. Maximal correlation coefficient
8. Inverse difference normalized
9. Inverse difference moment normalized

وسعی مورد استفاده قرار می‌گیرند. این شبکه‌ها، مشابه با شبکه‌های عصبی رایج، از لایه‌های ورودی، پنهان، و خروجی تشکیل شده و در لایه‌های مختلف خود، یک سری نورون دارند. اتصال کامل نورون‌ها برای تصاویر، چندان منطقی بنظر نمی‌رسد؛ چراکه، به عنوان مثال برای یک تصویر با اندازه $3 \times 32 \times 32$ ، تعداد وزن‌های مورد نیاز برای اتصال کامل در هر گره، $3 \times 32 \times 32 = 3072$ خواهد بود. لذا، لایه‌های مختلف شبکه از آرایش ConvNet تبعیت می‌کنند. در این آرایش، هر لایه به طور کلی از سه طبقه مختلف تشکیل می‌شود: طبقه کونولوشنی، طبقه پولینگ و طبقه اتصال کامل. طبقه کونولوشنی، مهمترین طبقه از آرایش ConvNet مطرح شده است زیرا این طبقه، موجب کاهش حجم بالایی از میزان محاسبات لازم برای وزن‌های نورون‌های هر طبقه است. همچنین، در آرایش یاد شده، برای کنترل تعداد پارامترهای لایه‌های کونولوشنی، از به اشتراک‌گذاری پارامترها استفاده می‌شود. چرا که فرض بر آنست که اگر یک ویژگی در موقعیت فضایی (x_1, y_1) قابل استناد است، پس می‌تواند برای موقعیت $(x_1 + \Delta x, y_1 + \Delta y)$ نیز در نظر گرفته شود. این نحوه آرایش شبکه CNN می‌تواند برای یک شبکه با وزن‌های تصادفی تشکیل شده و در هر مرحله، با کمک الگوریتم‌های انتشار به عقب^{۱۰}، به بروزرسانی و اصلاح وزن‌ها پردازیم. در نوع دوم، می‌توان از شبکه‌ها با آرایش‌هایی بهره برد که با ساختار از قبل تعیین شده برای لایه‌های مختلف، وزن‌های مربوطه نیز به ازاء یک مجموعه داده یا تصویر، از قبل آموزش دیده و یک مقدار اولیه برای وزن‌های مختلف آن تعیین گردیده است. برای این نوع شبکه‌ها، وزن‌های لایه‌های مختلف برای یکبار، به ازای طیف وسیعی از ویژگی‌های یک مجموعه تصویر غنی، بروزرسانی شده و از آنجا که، بسیاری از ویژگی‌های اولیه، مثل خطوط کلی، تعداد انحنای، مرز بین نواحی تیره و روشن، و غیره برای همه مشترک است، مدت زمان زیادی برای بروزرسانی وزن‌های لایه‌های مختلف خود نیاز خواهد داشت. به عبارتی دیگر، یادگیری صورت گرفته در این شبکه، به ازای مجموعه داده‌های اولیه، به یک سری داده جدید انتقال داده می‌شود. این فرایند، یادگیری انتقالی نامیده می‌شود. در این مطالعه نیز، یک شبکه CNN از ابتدا وزن‌دهی و آموزش داده نشد، بلکه از شبکه‌های از پیش آموزش دیده برای بازتنظیم وزن‌های لایه‌های مختلف استفاده گردید. شبکه‌های از پیش آموزش دیده متعددی معرفی شده‌اند که از مهمترین آنها، می‌توان به شبکه‌های Inception-ResNetV2، GoogleNet و AlexNet اشاره نمود. این شبکه‌ها، بوسیله مجموعه تصاویر ImageNet Dataset آموزش دیده و وزن‌های آنها تنظیم شده است. شبکه Inception-ResNetV2 از مجموعه شبکه‌های از پیش آموزش دیده است که دارای ۸۲۵ لایه کلی بوده و از ویژگی کاهش حجم محاسبات برخوردار است. در این شبکه، فرض بر آنست که بسیاری از فعالیت‌ها در شبکه عمیق، بخاطر کورولیشن بین آنها، غیرضروری و یا اضافی است. لذا می‌توان با استفاده از لایه‌های dropout، برخی از این فعالیت‌های مشابه را کاهش داده و یا حذف نمود. جدول ۱ آرایش لایه‌های مختلف برای اعمال این کاهش محاسباتی را برای شبکه Inception-ResNetV2 نشان می‌دهد. شبکه AlexNet نیز

10. Backpropagation

جدول ۱: ساختار لایه‌های شبکه Inception-ResnetV2

نوع لایه	سایز دسته/stride	سایز داده خروجی	عمق لایه	نوع Pooling
Convolution	۷ × ۷/۲	۱۱۲ × ۱۱۲ × ۶۴	۱	
Max. Pool	۳ × ۳/۲	۵۶ × ۵۶ × ۶۴	۰	
Convolution	۳ × ۳/۱	۵۶ × ۵۶ × ۱۹۲	۱	
Max. Pool	۳ × ۳/۲	۲۸ × ۲۸ × ۱۹۲	۰	
Inception(3a)		۲۸ × ۲۸ × ۲۵۶	۳	Avg. + ۳۲
Inception(3b)		۲۸ × ۲۸ × ۳۲۰	۳	Avg. + ۶۴
Inception(3c)	Stride2	۲۸ × ۲۸ × ۵۷۶	۳	Max + pass through
Inception(4a)		۱۴ × ۱۴ × ۵۷۶	۳	Avg. + ۱۲۸
Inception(4b)		۱۴ × ۱۴ × ۵۷۶	۳	Avg. + ۱۲۸
Inception(4c)		۱۴ × ۱۴ × ۵۷۶	۳	Avg. + ۱۲۸
Inception(4d)		۱۴ × ۱۴ × ۵۷۶	۳	Avg. + ۱۲۸
Inception(4e)	Stride2	۱۴ × ۱۴ × ۱۰۲۴	۳	Max + pass through
Inception(5a)		۷ × ۷ × ۱۰۲۴	۳	Avg. + ۱۲۸
Inception(5b)		۷ × ۷ × ۱۰۲۴	۳	Max. + ۱۲۸
Avg. Pool	۷ × ۷/۱	۱ × ۱ × ۱۰۲۴	۰	

استفاده از این تابع، شرایط تعریف تابع جرم احتمال را برای ورودی‌های مختلف، به صورت زیر بیان کرد:

$$(p_1, p_2, \dots, p_n) = f(s_1, s_2, \dots, s_n) = \left(\frac{\exp(s_1)}{\sum_{i=1}^n \exp(s_i)}, \dots, \frac{\exp(s_n)}{\sum_{i=1}^n \exp(s_i)} \right)$$

در این رابطه، p_i مقدار احتمال تخصیصی برای n کلاس مختلف، و s_i مقادیر حقیقی امتیازهای تعیین شده برای هر کلاس است. در واقع، این تابع نرمالایز شده نمایی، به عنوان یک تابع سیگموئید به کلاس‌بندی ویژگی‌های مختلف براساس میزان احتمالات حاصل شده می‌پردازد. معیارهای ارزیابی صحت خروجی شبکه‌های مورد کاربرد متفاوت است. از میان این معیارها، برآورد شاخص‌های دقت، حساسیت^۱ و میزان اختصاصی بودن^۲ را می‌توان نام برد. حساسیت به عنوان میزان کلاس‌بندی شده کلاس ۱ به طور درست به کل تعداد دیتاهای با کلاس‌بندی یک در مجموعه داده است و با رابطه $TP / (TP + FN)$ بدست می‌آید. میزان اختصاصی بودن برابر با نرخ تعداد داده های کلاس‌بندی شده درست در کلاس ۲ به تعداد کل دیتای موجود در کلاس ۲ است و با رابطه $TN / (TN + FP)$ حاصل می‌شود. شاخص دقت برابر با تعداد کل دیتای درست کلاس‌بندی شده به کل دیتاهای موجود در بانک داده است و برابر است با $(TP + TN) / (TP + TN + FP + FN)$. مقادیر شاخص دقت، حساسیت و اختصاصی بودن در ازای الگوریتم‌های ارائه

یک شبکه ۵ لایه است که به ازاء مجموعه تصاویر ImageNet آموزش داده شده است. این شبکه، با وجود تعداد لایه‌های اندک، اما بدلیل استفاده از لایه‌های معمول در ساختار بندی خود، تعداد پارامترهای زیادی را شامل می‌شود. ولی با توجه به آرایش ساختاری آن (شکل ۳)، با سرعت بالاتری نسبت به سایر شبکه‌ها آموزش می‌بیند. شبکه GoogleNet، شبکه‌ای متشکل از ۲۲ لایه کانولوشنی است که با چند لایه dropout، برای کاهش تعداد پارامترهای شبکه، همراه شده است. استفاده از این طبقه‌ها، موجب کاهش تعداد پارامترهای آن به ۴ میلیون پارامتر (در مقایسه با شبکه AlexNet با ۶۰ میلیون پارامتر) گردیده است. این شبکه نیز، همانند سایر شبکه‌های CNN، از تابع ReLU بجای توابع تانژانتی و سیگموئیدی در ساختارهای شبکه عصبی استفاده می‌کند که مزیت این تابع نسبت به دو تابع قبلی مورد کاربرد، سرعت بالای آموزش آن است. شکل ۴ ساختار لایه‌بندی این شبکه را نمایش می‌دهد.

کلاس‌بندی و ارزیابی

پس از استخراج ویژگی، از تابع SoftMax برای کلاس‌بندی این ویژگی‌ها استفاده گردید. مطابق با این تابع، اگر در یک سیستم با n کلاس مختلف، به خروجی الگوریتم بنگریم، الگوریتم به طور مشخص، حضور قطعی هر ورودی را در یک کلاس مشخص، تضمین نمی‌کند، بلکه برداری از امتیاز اعطایی به ورودی‌ها را برای کلاس‌های مختلف ارائه می‌نماید. از این رو، با کمک تابع احتمال فوق، می‌توان امتیازهای اعطایی را برای کلاس‌های مختلف، به یک بردار احتمال تبدیل کرد؛ یعنی با

1. Sensitivity
2. Specificity

جدول ۲: جمع‌بندی نتایج ارزیابی کارایی شبکه‌های مختلف


نوع شبکه	شاخص AUC	دقت	حساسیت	اختصاصی بودن
Inception-ResNetV2	۰/۹۷۵۷	٪۸۱/۰۸	۱	۰/۶۳۲
GoogleNet	۰/۹۹۶۰	٪۹۴/۶	۱	۰/۸۹۵
AlexNet	۰/۹۹۶۳	٪۹۹/۳۲	۰/۹۸۶	۱
GLCM	-	٪۶۶/۷۲	۰/۱۳	۰/۹۸۵

شبکه‌ها معادل گردد. دوم این که تعداد تصاویر برای دو کلاس به طور یکسان جمع‌آوری نشده است. برای حل مشکل اول، ابتدا تصاویر را به کمک نرم‌افزار متلب، به اندازه و سایز قابل قبول برای آن شبکه تبدیل می‌کنیم. در این صورت، پردازش مجموعه تصاویر برای شبکه‌های از پیش آموزش دیده با سهولت امکان‌پذیر می‌شود. برای مشکل دوم، از روش‌های افزایش تصاویر توضیح داده شده در بخش قبل استفاده می‌شود. سپس، براساس ویژگی‌های استخراج شده، به کلاس‌بندی تصاویر به دو کلاس بیماران با کبد چرب و بیماران بدون کبد چرب، براساس لایه SoftMax پرداختیم. در این کار، نتایج حاصل از نمونه‌برداری به عنوان مرجع کلاس‌بندی و برچسب گذاری تعیین شد. به طور خلاصه، فرایند کلی انجام شده در این مقاله در بلوک دیاگرام شکل ۵ نشان داده شده است. همچنین، ویژگی‌های این تصاویر، در ۹ حالت مختلف، از طریق الگوریتم GLCM استخراج شد. پس از آن، ویژگی‌های بدست آمده با استفاده از طبقه SoftMax، برای کلاس‌بندی مورد استفاده قرار می‌گیرند.


فرایند آموزش شبکه‌ها در شکل ۶ نشان داده شده است. نتایج مربوط به سه شبکه یادگیری عمیق استفاده شده با استفاده از کلاسیفایر SoftMax در جدول ۲ آورده شده است. مقادیر حساسیت، اختصاصی بودن، و دقت برای شبکه‌های مورد استفاده تعیین و محاسبه شد. در این بررسی، تعداد epoch های آموزش و اعتبارسنجی، برای تمام شبکه‌ها ۷ در نظر گرفته شده است. کارایی شبکه‌های یادگیری عمیق مختلف مربوط به کلاسیفایر SoftMax به ازاء آستانه‌گذاری های مختلف محاسبه شد و نتایج حاصل از آن به صورت نمودار ROC در شکل ۷ آمده است. تمام شبکه‌های مورد استفاده عملکرد خوبی را نشان داده‌اند. مطابق با شکل ۷، بیشترین AUC، معادل ۰/۹۹۶۳، به ازای کلاس‌بندی با استفاده از شبکه AlexNet بدست آمده است. کمترین AUC، به ازاء بکارگیری شبکه Inception-ResNetV2، حاصل شد که برابر ۰/۹۷۵۷ بود. نتیجه حاصل شده به ازاء شبکه GoogleNet تقریباً برابر ۰/۹۹۶ بدست آمد. با وجود آنکه در این کار، از تعداد داده‌های مربوط به ۵۵ بیمار مختلف برای کلاس‌بندی استفاده شد، نتایج نشان داد که همین تعداد داده خوبی می‌تواند توانایی شبکه‌های یادگیری انتقالی را نشان دهد. سیستم پردازنده متشکل از هسته CPU i5-4460 3.2 GHz و RAM 16GB برای انجام این فرایند محاسباتی بکار برده شد.

بحث:

در این مطالعه، تلاش کردیم تا با استفاده از تصاویر التراسوند مربوط به بافت کبدی ۵۵ بیمار مختلف، که مبتلا به چاقی مفرط بوده و قصد چربی‌برداری داشتند، به یک کلاس‌بندی با دقت قابل قبول



شکل ۳: ساختار شبکه AlexNet و نوع آرایش لایه‌های مختلف آن (۳۶)



شکل ۴: ساختار شبکه GoogleNet و لایه‌های آن (۳۷)

شده محاسبه شده است. در این کار، یک ارزیابی 10-fold cross-validation برای بررسی و صحت‌سنجی نتایج حاصل شده انجام گرفته و میزان خطای بین نتایج این ارزیابی‌ها به عنوان یک شاخص ارائه شده است. در این روش اعتبارسنجی شبکه، مجموعه داده‌های آموزش به ده قسمت مساوی تقسیم می‌شود. در این فرایند، در هر مرحله، یک بخش به عنوان مجموعه داده‌های تست و ۹ بخش دیگر، برای آموزش شبکه مورد استفاده قرار گرفته، و دقت و خطای ناشی از هر بار تست شبکه برای این نوع تقسیم‌بندی اندازه‌گیری می‌شود. پس از آموزش، برای هر تصویر انتخاب شده برای مجموعه تست، احتمالات خلفی محاسبه شده و برای استخراج منحنی مشخصه کاری گیرنده (ROC) مورد استفاده قرار می‌گیرد. برای تعیین این منحنی، با در نظر گرفتن یک سطح آستانه متغیر، نسبت تعیین صحیح کلاس به تعیین اشتباه کلاس برای داده‌های هر کلاس سنجیده می‌شود. این نسبت، به ازاء مقادیر احتمالی خلفی برای داده‌های تست انتخابی قابل استحصال است. احتمال توزیع خلفی یک کمیت احتمالاتی پس از مشاهده داده است. به عبارتی دیگر، احتمال توزیع خلفی، احتمال شرطی یک کمیت به شرط دیدن داده است. همچنین مساحت زیر منحنی ROC (AUC) برای ارزیابی عملکرد فرایند کلاس‌بندی مورد استفاده قرار می‌گیرد.

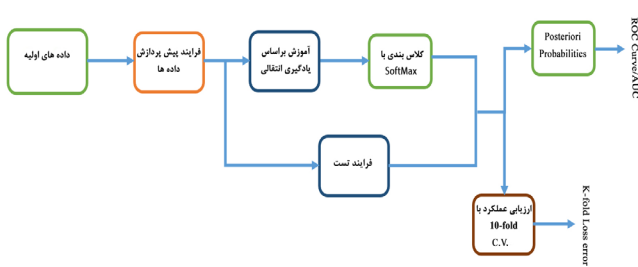
یافته‌ها:

در این مطالعه، ما از شبکه‌های CNN از پیش آموزش دیده برای استخراج ویژگی تصاویر استفاده نمودیم. دو مشکل برای این نوع تصاویر می‌توان متصور بود؛ اول این که برای بکارگیری این تصاویر در شبکه‌های از پیش آموزش دیده، بایست این سایز با سایز مورد قبول در لایه ورودی


1. Receiver operating characteristic



شکل ۶: فرایند آموزش و اعتبارسنجی با سمت راست) شبکه Inception-ResNetV2، وسط با سمت چپ) GoogleNet، و AlexNet (پایین)



شکل ۵: بلوک دیاگرام کلی فرایند پیاده سازی شده در مقاله



شکل ۷: نمودارهای ROC برای شبکه های مختلف مورد استفاده در کلاس بندی با استفاده از SoftMax، شبکه Inception-ResNetV2 و GoogleNet و AlexNet

با شبکه AlexNet است که نشان می دهد، بدلیل تعداد کم لایه های تشکیل دهنده شبکه آنها، این شبکه ها به نتیجه نسبتا مشابهی از نظر AUC دست یافته اند. همچنین بکارگیری الگوریتم اعتبارسنجی 10 fold در cross validation مورد شبکه های مورد نظر، باز هم نشان دهنده خطای اندکی کمتر نتیجه نهایی شبکه AlexNet نسبت به سایر شبکه های مورد استفاده است. در کنار معیارهای حساسیت و اختصاصی بودن، اختلاف بین دقت حاصل از شبکه AlexNet نسبت به سایر شبکه ها قابل توجه است و این پارامترها، با در نظر گرفتن تعداد کمتر لایه های تشکیل دهنده آن و در نتیجه مدت زمان محاسباتی پایین تر، می تواند تایید کننده امکان جایگزینی این الگوریتم برای کاربردهای مشابه باشد. بنابراین در قیاس میزان دقت، حساسیت، و اختصاصی بودن، می توان شبکه AlexNet را به عنوان انتخاب مناسبی، با تعداد لایه های کمتر و در نتیجه حجم محاسباتی کمتر مورد استفاده قرار داد.

در کنار همه تفاسیر بیان شده، می توان روش کلاس بندی با کمک شبکه های یادگیری عمیق را به عنوان یک روش کارآمد نسبت به روش های تجربی قبلی عنوان نمود چرا که استفاده از این روش، همراه با چند مزیت مختلف است: اول این که این روش نیازی به تعامل با یک فرد متخصص ندارد و می تواند به طور کاملا اتوماتیک به کلاس بندی داده های جمع آوری شده بپردازد. به عبارتی دیگر، نیاز نیست تا مشابه روش های

براساس روش های یادگیری عمیق دست یابیم. در روند این مقاله، ابتدا تصاویر جمع آوری شده طی یک فرایند پیش پردازش، از نظر اندازه و تعداد نمونه های هر کلاس اصلاح شده و پس از آن، به جهت استخراج ویژگی، به ورودی شبکه های Inception-ResNetV2، GoogleNet و AlexNet داده شدند. سپس، ویژگی های بدست آمده، با استفاده از طبقه SoftMax، برای کلاس بندی مورد استفاده قرار می گیرند. نتایج قابل توجهی در ارزیابی و کلاس بندی سطح نفوذ چربی در کبد بدست آمده برای الگوریتم های مختلف مبتنی بر یادگیری عمیق، موید عملکرد خوب این الگوریتم ها در کلاس بندی تصاویر مورد نظر است. نتایج بدست آمده از شبکه های یادگیری انتقالی مورد نظر نشان می دهد که شبکه AlexNet بالاترین کارایی را به ازاء AUC برابر با ۰/۹۹۶۳ بدست آورده است. بدترین AUC، از میان شبکه های عمیق مورد بررسی، مربوط به شبکه Inception-ResNetV2 است که برابر با ۰/۹۷۵۷ بدست آمد. مقادیر AUC بدست آمده برای شبکه GoogleNet تقریبا مشابه

نتیجه گیری:

در مقاله، یک رویکرد بکارگیری شبکه‌های از پیش آموزش دیده CNN برای کلاس بندی تصاویر جمع‌آوری شده از بافت کبدی ارائه گردید. این تصاویر با استفاده از دستگاه التراسوند در مود B و از بیماران مبتلا به چاقی مفرط، قبل از عمل جراحی چربی‌برداری گرفته شده‌اند. رویکرد ارائه شده نشان‌دهنده کارایی و مستقل بودن روش از دخالت کاربر یا متخصص مربوطه است. در این رویکرد، نتایج برای شبکه‌های یادگیری عمیق مختلف ارائه، و یک مقایسه برای بررسی کارایی آنها صورت گرفته است.

تعارض منافع:

هیچ گونه تعارضی در میان نویسندگان وجود ندارد.

دیگر، به تعیین یک ناحیه ROI در تمام تصاویر توسط یک متخصص با تجربه پردازیم. ضمناً نظرات متخصصین در انتخاب ناحیه مورد علاقه نیز بسیار مختلف می‌باشد. به طور مثال در روش GLCM دیدیم که استفاده از کل تصویر برای استخراج ویژگی نتوانست موجب بهبود دقت عملکرد الگوریتم در کلاس بندی تصاویر شود. برای تخمین بهتر با کمک این الگوریتم و الگوریتم‌های مشابه، نیاز است تا یک متخصص به تعیین ناحیه مورد نظر در تمام تصاویر پردازد که بدلیل نظرات مختلف متخصصین، این امر از مشکلات روش بشمار می‌رود و بایست براساس یک Gold Standard از پیش تعریف شده صورت گیرد.

به عنوان فعالیت‌های آینده در این زمینه: (۱) می‌توان با توجه به نوع توزیع داده‌های جمع‌آوری شده، به کلاس بندی تصاویر در ۴ سطح مختلف پرداخت، (۲) می‌توان به ارزیابی امکان بکارگیری تصاویر جمع‌آوری شده از دستگاه‌های التراسوند مختلف با تنظیمات متفاوت و مقدار توانایی الگوریتم‌ها در کلاس بندی تصاویر نتیجه شده پرداخت، (۳) همچنین، در فعالیت‌های بعدی، برآنیم تا به جمع‌آوری داده‌های بومی بیشتر و بکارگیری الگوریتم‌های یادگیری عمیق پیچیده‌تر برای مطالعات تخصصی‌تر پردازیم.

REFERENCES:

- Chalasan N, Younossi Z, Lavine J. E, Diehl A. M, Brunt E. M, Cusi K, et al. The diagnosis and management of non-alcoholic fatty liver disease: Practice Guideline by the American Association for the Study of Liver Diseases, American College of Gastroenterology, and the American Gastroenterological Association. *Hepatology* 2012;55:2005-23.
- Koncarevic A, Lachey J, Seehra, J, Sherman ML. Methods for treating fatty liver disease U.S. Patent Application No. 12/939,084. 2009
- Hormati A, Shakeri M, Iranikah A, Affian M, Sarkeshikian SS. Non-Alcoholic Fatty Liver Disease. *Govaresh* 2019;23:203-12.
- Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian, M, et al. A survey on deep learning in medical image analysis. *Med Image Analysis* 2017;42:60-88.
- Shalbf A, Behnam H, Alizade-Sani Z, Shojafard M. Automatic assessment of regional and global wall motion abnormalities in echocardiography images by nonlinear dimensionality reduction. *Med Phy* 2013;40:052904.
- Shalbf A, AlizadehSani Z, Behnam H. Echocardiography without electrocardiogram using nonlinear dimensionality reduction methods. *J Med Ultrason* 2015;42:137-49.
- Shalbf A, Behnam H, Alizade-Sani Z, Shojafard M. Left ventricle wall motion quantification from echocardiographic images by non-rigid image registration. *Int J Comput Assist Radiol Surg* 2012;7:769-83.
- ZA Sani, A Shalbf, H Behnam, R Shalbf. Automatic computation of left ventricular volume changes over a cardiac cycle from echocardiography images by nonlinear dimensionality reduction. *J Digit Imaging* 2015;28:91-8.
- Vanderbeck S, Bockhorst J, Komorowski R, Kleiner D. E, Gawrieh, S. Automatic classification of white regions in liver biopsies by supervised machine learning. *Hum Pathol* 2014;45:785-92.
- Hashem EM, Mabrouk MS. A study of support vector machine algorithm for liver disease diagnosis. *Am J Intell Sys* 2014;4:9-14.
- Rau HH, Hsu CY, Lin YA, Atique S, Fuad A, Wei LM, et al. Development of a web-based liver cancer prediction model for type II diabetes patients by using an artificial neural network. *Comput Methods Programs Biomed* 2016;125: 58-65.
- Hinton G. Deep learning-a technology with the potential to transform health care. *JAMA* 2018;320:1101-2.
- Wu CC, Yeh WC, Hsu WD, Islam MM, Nguyen PAA, Poly TN, et al. Prediction of fatty liver disease using machine learning algorithms. *Comput Methods Programs Biomed* 2019;170:23-9.
- Cao GT, Shi PF, Hu B. Liver fibrosis identification based on ultrasound images captured under varied imaging protocols. *J Zhejiang Univ Sci B* 2005;6:1107-14.
- Andrade A, Silva JS, Santos J, Belo-Soares P. Classifier approaches for liver steatosis using ultrasound images. *Procedia Tech* 2012;5:763-70.
- Gao S, Peng Y, Guo H, Liu W, Gao T, Xu Y, et al. Texture analysis and classification of ultrasound liver images. *Biomed Mater Eng* 2014;24:1209-16.
- Acharya UR, Raghavendra U, Fujita H, Hagiwara Y, Koh JE, Hong TJ, et al. Automated characterization of fatty liver disease and cirrhosis using curvelet transform and entropy features extracted from ultrasound images. *Comput Biol Med* 2016;79:250-8.
- Kuppili V, Biswas M, Sreekumar A, Suri HS, Saba L, Edla DR, et al. Extreme learning machine framework for risk stratification of fatty liver disease using ultrasound tissue characterization. *J Med Syst* 2017;41:152.

19. Hassan TM, Elmogy M, Sallam ES. Diagnosis of focal liver diseases based on deep learning technique for ultrasound images. *Arabian J Sci Engin* 2017;42:3127-40.
20. Liu X, Song J, Wang S, Zhao J, Chen Y. Learning to diagnose cirrhosis with liver capsule guided ultrasound image classification. *Sensors* 2017;17:149.
21. Bharath R, Rajalakshmi P. Deep scattering convolution network based features for ultrasonic fatty liver tissue characterization. *Conf Proc IEEE Eng Med Biol Soc* 2017;2017:1982-5.
22. Biswas M, Kuppli V, Edla DR, Suri HS, Saba L, Marinho RT, et al. Symtosis: A liver ultrasound tissue characterization and risk stratification in optimized deep learning paradigm. *Comput Methods Programs Biomed* 2018;155:165-77.
23. Islam MM, Wu CC, Poly TN, Yang HC, Jack Li YC. Applications of Machine Learning in Fatty Live Disease Prediction. *Stud Health Technol Inform* 2018;247:166-70.
24. Reddy DS, Bharath R, Rajalakshmi P. A novel computer-aided diagnosis framework using deep learning for classification of fatty liver disease in ultrasound imaging. 2018 IEEE 20th International Conference on e-Health Networking, Applications and Services (Healthcom).
25. Frid-Adar M, Klang E, Amitai M, Goldberger J, Greenspan H. Synthetic data augmentation using GAN for improved liver lesion classification. *IEEE* 2018;2018:289-93.
26. Byra M, Styczynski G, Szmigielski C, Kalinowski P, Michałowski Ł, Paluszkiwicz R, et al. Transfer learning with deep convolutional neural network for liver steatosis assessment in ultrasound images. *Int J Comput Assist Radiol Surg* 2018;13:1895-903.
27. <http://creativecommons.org/licenses/by/4.0/>
28. Kleiner DE, Brunt EM, Van Natta M, Behling C, Contos MJ, Cummings OW, et al. Design and validation of a histological scoring system for nonalcoholic fatty liver disease. *Hepatology* 2005;41:1313-21.
29. DeVries T, Taylor GW. Dataset augmentation in feature space. *arXiv preprint arXiv:1702.05538*. 2017 Feb 17.
30. Frid-Adar M, Diamant I, Klang E, Amitai M, Goldberger J, Greenspan H. GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification. *Neurocomputing* 2018;321:321-31.
31. Mikołajczyk A, Grochowski M. Data augmentation for improving deep learning in image classification problem. *IEEE* 2018;2018:117-22.
32. Zhong Z, Zheng L, Kang G, Li S, Yang Y. Random erasing data augmentation. *arXiv* 2017;1708.04896.
33. Perez L, Wang J. The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*. 2017 Dec 13.
34. Bharti P, Mittal D, Ananthasivan R. Computer-aided characterization and diagnosis of diffuse liver diseases based on ultrasound imaging: a review. *Ultrason Imaging* 2017;39:33-61.
35. Rivas EC, Moreno F, Benitez A, Morocho V, Vanegas P, Medina R. Hepatic Steatosis detection using the co-occurrence matrix in tomography and ultrasound images. In: 20th symposium on signal processing, Images and Computer Vision (STSIVA), Bogota 2015;2015:1-7. <https://doi.org/10.1109/STSIVA.2015.7330417>
36. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *In Advances in neural information processing systems* 2012;2012:1097-105.
37. Guo Z, Chen Q, Wu G, Xu Y, Shibasaki R, Shao X. Village Building Identification Based on Ensemble Convolutional Neural Networks. *Sensors* 2017;17:2487.