

طبقه‌بندی اتوماتیک چربی کبد با استفاده از ویژگی‌های بافت از روی تصاویر اولتراسوند

چکیده

دریافت: ۱۳۹۹/۰۹/۱۲ ویرایش: ۱۳۹۹/۰۹/۱۹ پذیرش: ۱۳۹۹/۱۲/۲۳ آنلاین: ۱۴۰۰/۰۱/۰۱

امیر رضا نادری یاقوتی^۱، احمد شالباف^{۲*}، آرش مقصودی^۳

۱- گروه مهندسی پزشکی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
۲- گروه مهندسی و فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران.
۳- گروه مهندسی پزشکی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

* نویسنده مسئول: تهران، دانشگاه علوم پزشکی شهید بهشتی، دانشکده پزشکی، گروه مهندسی و فیزیک پزشکی.

تلفن: ۰۲۱-۲۳۸۷۲۵۶۶
E-mail: Shalbaf@sbmu.ac.ir

زمینه و هدف: تشخیص دقیق و به‌هنگام بیماری کبدچرب غیرالکلی که عامل اصلی بیماری‌های مزمن کبد است، بسیار مهم می‌باشد. سونوگرافی از کبد متداول‌ترین روش تشخیص میزان کبدچرب می‌باشد. اما به دلیل کیفیت پایین تصاویر اولتراسوند، نیاز به روش‌های هوش مصنوعی برای تشخیص دقیق میزان چربی کبدی، ضروری می‌باشد. هدف این مقاله توسعه یک مدل یادگیری ماشین برای ارزیابی سطح چربی کبد براساس تصاویر اولتراسوند کبد می‌باشد. **روش بررسی:** در این مطالعه تحلیلی که از اردیبهشت ۱۳۹۹ تا آذر ۱۳۹۹ در تهران به طول انجامیده است، از تصاویر اولتراسوند ۵۵ فرد مبتلا به چاقی مفرط که قصد جراحی لاپاروسکوپی داشته‌اند، استفاده شده و از نتیجه بافت‌شناسی نمونه برداشتی از کبد در آزمایشگاه به‌عنوان مرجع میزان چربی کبد استفاده شده است. ابتدا ۸۸ ویژگی مبتنی بر بافت با استفاده از ماتریس هم‌رخداد سطح خاکستری از تصاویر استخراج شده است. در مرحله‌ی بعد با استفاده از روش حداقل افزونگی و حداکثر ارتباط ۲۰ ویژگی برتر از میان ۸۸ ویژگی انتخاب شده و به ورودی طبقه‌بند اعمال شده است. در انتها با استفاده از سه طبقه‌بند آنالیز افتراقی خطی، ماشین بردار پشتیبان و آدابوست، تصاویر به چهار گروه براساس میزان چربی طبقه‌بندی شده‌اند.

یافته‌ها: صحت به‌دست آمده در این مدل، برای طبقه‌بند آدابوست برابر با ۹۲/۷۲٪ شد. درحالی‌که صحت به‌دست آمده برای هر دو طبقه‌بند ماشین بردار پشتیبان و آنالیز افتراقی خطی به‌ترتیب برابر با ۸۷/۸۸٪ و ۷۵/۷۶٪ شده‌است. **نتیجه‌گیری:** رویکرد پیشنهادی مبتنی بر ویژگی‌های بافت با استفاده از طبقه‌بند آدابوست از روی تصاویر اولتراسوند، میزان چربی کبد را با دقت بالا و به‌صورت اتوماتیک تشخیص می‌دهد و می‌تواند در تشخیص نهایی به پزشکان و رادیولوژیست‌ها کمک شایانی کند.

کلمات کلیدی: کبد چرب، پردازش تصویر، یادگیری ماشین، تصاویر اولتراسوند.

مقدمه

سیروزیس، سرطان کبد و غیره است. از این‌رو، در تشخیص زودهنگام و دقیق این بیماری نقش مهمی دارند و اگر درمان مناسب برای این بیماری در نظر گرفته نشود، می‌تواند پیشرفت کرده و به بیماری‌های مزمن تبدیل شود و در نهایت ممکن است منجر به کارافتادگی کبد شود.^۱ برای تشخیص بیماری کبدچرب غیرالکلی، سونوگرافی به‌طور گسترده‌ای مورد استفاده قرار می‌گیرد.

بیماری کبد چرب غیرالکلی به‌دلیل حضور گرانول‌های چربی اضافی در سلول‌های کبد رخ می‌دهد و حدود ۳۰٪ از جمعیت در کشورهای توسعه‌یافته تحت‌تاثیر آن قرار دارند.^۲ این رسوبات بیش از حد چربی در کبد عامل اصلی بیماری‌های مزمن مانند فیبروزیس،

تصویربرداری سونوگرافی به دلیل ایمنی نسبی، هزینه کم، ماهیت غیرتهاجمی، نمایش هم‌زمان و راحتی اپراتور، یکی از روش‌های پرکاربرد تصویربرداری بوده و به‌عنوان ابزاری قدرتمند و همه‌گیر در تشخیص برای پزشکان و رادیولوژیست‌ها شناخته می‌شود.^{۷،۸} اما به دلیل کیفیت پایین تصاویر التراسوند، دقت تشخیص میزان چربی کبد به آموزش و تخصص بسیار رادیولوژیست بستگی دارد. از این‌رو، یک روش طبقه‌بندی اتوماتیک و هوشمند براساس روش‌های هوش مصنوعی برای تشخیص میزان چربی کبدی از روی تصاویر التراسوند با دقت بالا ضروری بوده و می‌تواند به پزشکان و رادیولوژیست‌ها کمک شایانی کند و دقت و سرعت تشخیص را بهبود بخشد.

تاکنون محققان مختلفی با استفاده از روش‌های هوش مصنوعی به تشخیص میزان کبدچرب از روی تصاویر التراسوند پرداخته‌اند. در یک مطالعه برای تشخیص میزان چربی کبد از تصاویر سونوگرافی، ویژگی‌های تصاویر اسپکل (Speckle) و فرکانس رادیویی استخراج و از روش بیزین (Bayesian statistics) به‌عنوان طبقه‌بند استفاده کردند.^۹


هدف این مقاله، توسعه یک مدل یادگیری ماشین پیشرفته مبتنی بر ویژگی‌های بافت برای ارزیابی سطح چربی کبد براساس تصاویر التراسوند کبد می‌باشد. داده‌های سونوگرافی انجام شده در این مطالعه، از بیماران مبتلا به چاقی قبل از عمل جراحی چاقی جمع‌آوری شده است. در این روش، نمونه‌برداری کبد و در نهایت نتیجه پاتولوژی به عنوان مرجع در نظر گرفته شده است.

در مطالعه دیگر به مقایسه ارزیابی اتوماتیک چربی کبد با استفاده از طبقه‌بندی‌کننده‌های جنگل تصادفی و ماشین بردار پشتیبان (Random forest and support vector machines classifiers) پرداخته شده است. برای این منظور چربی کبد را در چهار مرحله درجه‌بندی کردند و دو طبقه‌بندی‌کننده را آموزش دادند تا شدت بیماری را براساس مجموعه بزرگی از تصاویر برچسب‌دار و مجموعه بزرگی از ویژگی‌ها، درجه‌بندی کنند.^۹ در مطالعه دیگر، هفت ویژگی بافتی از مجموعه ۳۵ ویژگی استخراج شده را انتخاب کردند و سپس این ویژگی‌های انتخاب شده را با استفاده از یک طبقه‌بند خطی ادغام کردند.^{۱۰}


روش بررسی

دادگان متشکل از داده‌های ۵۵ بیمار به شدت چاق است که برای جراحی چاقی پذیرش شده‌اند. داده‌های سونوگرافی از کبد در بخش پزشکی داخلی، دانشگاه علوم پزشکی ورشو لهستان، یک یا دو روز قبل از جراحی به‌دست آمده است. به‌عنوان بخشی از پروتکل روتین این دانشگاه، هر بیمار که تحت عمل جراحی چاقی قرار می‌گیرد، بیوپسی انجام و سپس ارزیابی بافت‌شناسی کبد توسط یک آسیب‌شناس انجام می‌شود و سطح میزان چربی کبد براساس درصد سلول‌های کبدی با نفوذ چربی تعریف شده است. توزیع سطح چربی کبد در میان جمعیت دادگان جمع‌آوری شده براساس نتایج بیوپسی توسط یک آسیب‌شناس در شکل ۱ نشان داده شده است. دادگان براساس میزان چربی کبد به چهار گروه سالم (سطح چربی کبد کمتر از ۵٪) (۱۷ فرد)، کبد با چربی پایین (سطح چربی کبد بین ۵ تا ۳۰٪) (۲۰ فرد)، کبد با چربی متوسط

در همان سال، یک سیستم تشخیص برای طبقه‌بندی تصاویر سونوگرافی کبد معمولی، کبد چرب و سیروز با استفاده از ترکیب ویژگی‌های حوزه مکانی و ویژگی‌های حوزه تبدیل پیشنهاد شد. در این مطالعه، ویژگی‌های ماتریس هم‌رخدادی سطح خاکستری Gray-Level Co-Occurrence Matrix (GLCM) را به‌عنوان ویژگی حوزه مکانی و همچنین انحراف انرژی و انرژی تبدیل بسته موجک دو بعدی و فیلتر گابور (Energy deflection, energy conversion of



شکل ۲: نمونه یک تصویر اخذ شده و نتیجه بعد از پیش‌پردازش.



شکل ۱: توزیع فراوانی داده‌ها از لحاظ میزان چربی کبد براساس نتایج بیوپسی.

و فقط اطلاعات اصلی که حاوی تمامی ویژگی‌های حیاتی و ارزشمند تصویر هستند، حفظ شده است. بنابراین تصاویر با ابعاد ابتدایی 434×636 بعد از برش، به ابعاد 399×399 درآورده می‌شوند. در شکل ۲ نمونه یک تصویر اخذ شده و نتیجه بعد از پیش‌پردازش نمایش داده شده است.

استخراج ویژگی‌های بافتی: استخراج ویژگی یک مرحله مهم برای هر کار شناسایی الگو، به‌ویژه برای طبقه‌بندی بافت کبد در تصاویر التراسوند است. در این مقاله، ماتریس هم‌رخدادی سطوح خاکستری برای استخراج ویژگی‌های بافتی به‌کار گرفته می‌شود. ماتریس هم‌رخدادی سطوح خاکستری یک روش آماری مرتبه دوم پرکاربرد برای توصیف بافت می‌باشد. این ماتریس براساس توزیع احتمال مشترک جفت پیکسل تصویر در فواصل و زوایای مختلف تعریف می‌شود. ماتریس هم‌رخدادی سطح خاکستری، یک ماتریس مربعی است که در آن تعداد سطرها و ستون‌ها با تعداد سطوح خاکستری در تصویر برابر است. 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 ماتریس هم‌رخدادی سطوح خاکستری به‌ازای کل ناحیه مرکزی تصویر در نظر گرفته شد و محدود

(سطح چربی کبد بین ۳۰ تا ۷۰٪) (۸ فرد) و کبد با چربی بالا (سطح چربی کبد بالاتر از ۷۰٪) (۱۰ فرد) تقسیم شده‌اند.

اطلاعات سونوگرافی با استفاده از دستگاه سونوگرافی GE Vivid (GE Healthcare INC, Horten, Norway) E9 که مجهز به یک پروب $2/5$ MHz اخذ شده است. رزولوشن تصاویر التراسوند برابر با 434×636 است. برای هر بیمار، توالی تصاویر متناظر با یک تپش قلب به‌دست آمده و با فرمت دایکام (DICOM format) برای پردازش‌های بعدی ذخیره شده است. به‌دلیل حرکت، الگوی اسپکل و موقعیت نسبی کبد و کلیه، تصاویر در هر توالی تفاوت اندکی با هم دارند. علاوه بر این، تعداد تصاویر در هر توالی ثابت نبوده و به نرخ فریم پروب اسکنر دستگاه وابسته است. در این دادگان برای هر فرد در تصاویر یک توالی، ده تصویر برای پردازش بیشتر مورد استفاده قرار گرفته است. با این کار تعداد دادگان افزایش پیدا کرده و ما را قادر خواهد ساخت تا داده‌های متنوع‌تری را به مدل‌ها ارایه دهیم. در نهایت، مجموعه داده‌ها شامل ۵۵۰ تصویر التراسوند (۵۵ فرد و از هر فرد ۱۰ تصویر) است. باید توجه داشت که در طول کسب اخذ تصاویر با پروب قلبی، ما تصاویر را با کلیه در سمت چپ صفحه ثبت کردیم.^۳

پیش‌پردازش: در مرحله پیش‌پردازش، اعداد، سیگنال‌ها و علائم حاشیه تصاویر التراسوند حذف شده و سپس تصویر را برش داده و ناحیه حاشیه تصاویر و برخی اطلاعات اضافی حذف شده

افتراقی خطی در مقایسه با سایر طبقه‌بندهای دیگر، پیاده‌سازی آسان و یادگیری سریع‌تری دارد.^{۱۵}

در طبقه‌بند ماشین بردار پشتیبان همواره سعی بر انتخاب خطی است که حاشیه‌ی اطمینان بیشتری بین دو کلاس داشته باشد.^{۱۶} ماشین بردار پشتیبان با کمک یک نگاهت غیرخطی فضای داده‌های آموزشی را به یک بعد بالاتر تبدیل می‌کند و سپس در این بعد جدید به دنبال ابرصفحه‌ای است که نمونه‌های یک کلاس را از کلاس‌های دیگر جدا کند. با یک نگاهت غیرخطی مناسب، مجموعه داده‌های دو کلاس می‌توانند توسط یک ابرصفحه جدا شوند.^{۱۸}

در این مقاله، تابع کرنل گوسی (Gaussian kernel function) انتخاب شده است. ماشین بردار پشتیبان اساساً یک جداکننده دودویی است. یک مسئله چند کلاسه می‌تواند به وسیله ترکیب ماشین‌های بردار پشتیبان دو کلاسه حاصل شود. استراتژی به کار برده شده، یک کلاس در مقابل بقیه کلاس‌ها برای دسته‌بندی هر کلاس است. سپس خروجی جداکننده‌های دودویی ماشین بردار پشتیبان با هم ترکیب شده و به این ترتیب مسئله چند کلاس حل می‌شود.^{۱۹} آخرین روش استفاده شده به عنوان طبقه‌بند، روش آدابوست می‌باشد. در سال‌های اخیر، طبقه‌بندی‌کننده‌های ترکیبی نقش گسترده‌ای در الگوریتم‌های یادگیری ماشین داشته‌اند.^{۲۰} ایده اصلی این است که طبقه‌بندهای مختلف ضعیف با استفاده از یک مجموعه داده یکسان آموزش داده شوند و سپس برای ایجاد طبقه‌بند قوی‌تر ترکیب می‌شوند.

در طبقه‌بند آدابوست در هر تکرار، تمرکز طبقه‌بند بیشتر بر تشخیص نمونه‌هایی است که به اشتباه توسط طبقه‌بندهای مراحل قبل برچسب گذاری شده‌اند. در این رویکرد، اولین طبقه‌بند ضعیف، با استفاده از نمونه‌برداری با جایگذاری از مجموعه آموزشی، آموزش داده می‌شود. سپس طبقه‌بند مرحله اول، با تمام نمونه‌های آموزشی تست می‌شود و تعیین می‌گردد که کدام نمونه‌ها توسط این طبقه‌بند به درستی قابل تشخیص می‌باشند و کدام نمونه‌ها به اشتباه طبقه‌بندی می‌شوند. سپس احتمال انتخاب نمونه‌هایی که به اشتباه طبقه‌بندی شده‌اند، برای نمونه‌برداری مرحله بعد، افزایش می‌یابد و احتمال انتخاب نمونه‌هایی که به درستی طبقه‌بندی شده‌اند، کاهش می‌یابد.

بنابراین، طبقه‌بندهای بعدی به احتمال زیاد با نمونه‌هایی آموزش داده می‌شوند که توسط طبقه‌بندهای مراحل قبلی به درستی قابل تشخیص نبوده‌اند. پس احتمال آن‌که مجدداً با نمونه‌هایی که توسط

به یک ناحیه مورد نظر نشده و تنها ناحیه حاشیه‌ای قابل تفکیک تصویر که فاقد اطلاعات است را حذف کردیم تا نیازی به متخصص برای تعیین ناحیه مورد نظر نداشته باشیم. برای این ماتریس چهار زاویه صفر، ۴۵، ۹۰ و ۱۳۵ را در نظر گرفته شده است. ۲۲ ویژگی از ماتریس هم‌رخدادی سطوح خاکستری به دست آمد که عبارت بودند از: کنتراست، همسبستگی، انرژی، همگنی، همبستگی خودکار، برتری خوشه‌ای، سایه خوشه، آنتروپی، مجموع مربعات واریانس، مجموع متوسط، مجموع واریانس، مجموع آنتروپی، اختلاف متوسط، اختلاف واریانس، اختلاف آنتروپی، ماکسیمم احتمال، واریانس تفاوت، معیار واریانس، عدم‌شباهت، لحظه تغییرات معکوس، تغییرات معکوس نرمال شده، تغییر معکوس نرمال شده لحظه‌ای. این ویژگی‌ها توسط ماتریس هم‌رخدادی سطوح خاکستری در چهار زاویه استخراج شدند. بنابراین ۸۸ ویژگی از هر تصویر با این روش استخراج شده است.

انتخاب ویژگی: انتخاب ویژگی یکی از چالش برانگیزترین و از مهمترین فعالیت‌ها در توسعه یادگیری ماشین و تشخیص الگو است. ما برای انتخاب ویژگی از روش حداقل افزونگی و حداکثر ارتباط استفاده می‌کنیم. حداکثر افزونگی و حداکثر ارتباط یک روش انتخاب ویژگی با ناظر است. در این روش، با بکارگیری ضریب اسپیرمن (Spearman correlation) تلاش می‌شود تا یک مصالحه بین بیشترین ارتباط (قدرت ویژگی در تعیین گروه هدف) و کمترین افزونگی (میزان نزدیکی با سایر ویژگی‌ها) برقرار نماید.

بنابراین آن ویژگی که بتواند این دو رویکرد را با هم برآورده سازد رتبه بهتری را به خود اختصاص می‌دهد.^{۲۱} بنابراین از ۸۸ ویژگی استخراج شده، ویژگی‌هایی که بیشترین ارتباط و کمترین افزونگی را دارند انتخاب می‌شوند.^{۲۴}

طبقه‌بند: در این تحقیق از سه روش آنالیز افتراقی خطی، ماشین بردار پشتیبان و آدابوست (Linear differential analysis, support vector machine and AdaBoost) برای طبقه‌بندی تصاویر براساس ویژگی‌های بافت استفاده شده است. آنالیز افتراقی خطی روش آماری شناخته شده‌ای است که نسبت پراکندگی بین کلاسی به پراکندگی درون کلاسی را ماکسیمم می‌کند و بیشترین تفکیک‌کنندگی را به دست می‌آورد. این طبقه‌بند در مصالحه زمان و حجم پردازش، از دقت طبقه‌بندی خوبی برخوردار است. به عبارت دیگر، طبقه‌بند آنالیز

خاکستری برای استخراج ویژگی‌های مبتنی بر بافت استفاده شده است.

۲۲ ویژگی در چهار همسایگی استخراج شد. بنابراین ۸۸ ویژگی از هر تصویر با این روش استخراج شده است. سپس با استفاده از روش حداقل افزونگی و حداکثر ارتباط، ۲۰ ویژگی با رتبه‌ی بالاتر را از میان ۸۸ ویژگی موجود انتخاب کرده و به ورودی طبقه‌بند اعمال می‌کنیم. ۲۰ ویژگی انتخاب شده توسط روش حداقل افزونگی و حداکثر عبارتند از مجموع متوسط در زاویه صفر درجه، انرژی در زوایای صفر و ۴۵ درجه، مجموع آنروپی در زوایای ۴۵ و ۹۰ درجه، مجموع واریانس در زوایای صفر و ۹۰ درجه، اختلاف آنروپی در زوایای ۴۵ و ۱۳۵ درجه، برتری خوشه‌ای در زوایای صفر، ۴۵ و ۱۳۵ درجه و در نهایت کنتراست و همبستگی در هر چهار زاویه. در نهایت با استفاده از سه طبقه‌بند آنالیز افتراقی خطی، ماشین بردار پشتیبان چند کلاسه و طبقه‌بند آدابوست مبتنی بر درخت تصمیم‌گیری، تصاویر را به چهار کلاس تقسیم‌بندی می‌کنیم. برای این کار، ۷۰٪ از مجموعه داده را به‌عنوان داده‌های آموزش و ۳۰٪ را به‌عنوان داده‌های آزمایش یا تست انتخاب شده است.

نتایج حاصل شده براساس صحت چهار کلاس در جدول ۱ نشان داده شده است. بالاترین مقدار صحت، برابر با ۹۲/۷۲٪ برای طبقه‌بند آدابوست به‌دست آمده است. صحت عملکردی طبقه‌بند ماشین بردار پشتیبان و طبقه‌بند آنالیز افتراقی خطی به ترتیب برابر با ۸۷/۸۸ و ۷۵/۷۶ بود و به‌طور قابل توجهی کم‌تر از صحت به‌دست آمده برای طبقه‌بند آدابوست بود. میزان حساسیت و اختصاصیت در بهترین طبقه‌بند که آدابوست می‌باشد برای کبد سالم به ترتیب برابر ۹۲ و ۹۶٪ برای کبد با چربی کم به ترتیب برابر ۹۴ و ۹۷٪، برای کبد با چربی متوسط به ترتیب برابر ۸۴ و ۹۷٪ و برای کبد با چربی بالا به ترتیب برابر ۹۶ و ۹۸٪ می‌باشد. در جدول ۲ می‌توان ماتریس درهم‌ریختگی برای طبقه‌بند آدابوست را مشاهده کرد.

جدول ۱: صحت نتایج طبقه‌بندی کبد چرب به چهار کلاس.

آدابوست	ماشین بردار پشتیبان	آنالیز افتراقی خطی	طبقه‌بند
۹۲/۷۲±۱/۵۲٪	۸۷/۸۸±۲/۱۲٪	۷۵/۷۶±۲/۶۷٪	صحت کل

طبقه‌بندهای قبلی به درستی قابل تشخیص بوده‌اند، آموزش داده شوند، کاهش می‌یابد.^{۳۱} آدابوست نسبت به داده‌های نویزی و پرت حساس است ولی نسبت به مشکل بیش‌پردازش از بیشتر الگوریتم‌های یادگیری برتری دارد. از دیگر مزیت‌های این الگوریتم این است که به پارامترهای ورودی کمتری نیاز دارد و به دانش اولیه کمی در مورد یادگیرنده‌های ضعیف نیاز دارد. در این پژوهش آدابوست مبتنی بر روش درخت تصمیم‌گیری را به‌کار گرفته‌ایم.^{۳۳}

یافته‌ها

در شکل ۳ بلوک دیاگرام کلی فرایند پیاده‌سازی شده جهت طبقه‌بندی مقدار چربی کبد از روی تصاویر التراسوند نشان داده شده است. بعد از جمع‌آوری تصاویر التراسوند کبد، پیش‌پردازش شامل حذف اعداد و علائم انجام شده و سپس تصاویر برش داده شده و ناحیه حاشیه تصویر و برخی اطلاعات اضافی حذف شده است. بنابراین تصاویر با ابعاد ابتدایی ۶۳۶×۴۳۴ بعد از برش به ابعاد ۳۹۹×۳۹۹ درآورده می‌شوند. سپس از ماتریس هم‌رخداد سطح



شکل ۳: بلوک دیاگرام کلی فرایند پیاده‌سازی شده جهت طبقه‌بندی مقدار چربی کبد از روی تصاویر التراسوند.

بهترین ویژگی‌ها که شامل ۲۰ عدد بوده را انتخاب می‌کنیم و در پایان با استفاده از طبقه‌بند آداپوست تصاویر را به چهار کلاس تقسیم‌بندی کرده‌ایم. مدل اتوماتیک پیشنهادی با استفاده از داده‌های به‌دست‌آمده در بیماران چاقی که در طی جراحی بیوپسی کبدی گرفته‌اند، مورد ارزیابی قرار گرفت و به صحت پیش‌بینی قابل‌توجه ۹۲/۷۲٪ در میزان چربی کبد رسید. بنابراین، نتایج این مطالعه نشان می‌دهد که استفاده از ویژگی‌های مبتنی بر بافت به همراه روش‌های پیشرفته یادگیری ماشین پیش‌بینی‌کننده خوبی برای طبقه‌بندی میزان چربی کبد از روی تصاویر التراسوند می‌باشد.

از آنجایی که بیماری کبد چرب روز به روز گسترده‌تر می‌شود و سیر پیشرونده دارد، ضروری است که آن را به‌موقع تشخیص دهیم تا روند درمانی و بهبود تسریع یابد. تشخیص دقیق و زودهنگام میزان چربی کبد با استفاده از رویکرد اتوماتیک پیشنهادی مدت زمان درمان و هزینه‌های آن را به‌صورت قابل‌توجهی کاهش می‌دهد.

رویکرد ما بی‌نیاز به تعامل با اپراتور است و می‌تواند به‌طور کامل خودکار به طبقه‌بندی داده‌های جمع‌آوری شده بپردازد. به‌عبارت دیگر، مانند روش‌های دیگر نیازی به تعیین یک ناحیه در تمام تصاویر توسط یک متخصص با تجربه نداریم. در ادامه کار می‌توان برای بهبود نتایج از یک یادگیری جمعی استفاده کرد. به این معنا که با استفاده از رویکردهای مختلف یادگیری ماشین به‌طور مجزا به طبقه‌بندی دادگان پرداخته و در نهایت نتایج را با استفاده از روش‌های یادگیری جمعی ترکیب کرد. ضمناً می‌توان از روش‌های یادگیری عمیق برای طبقه‌بندی تصاویر استفاده کرد.

همانطور که در این جدول قابل مشاهده است. طبقه‌بند آداپوست توانسته تمایز خوبی بین کبد سالم و کبد با چربی متوسط و بالا ایجاد کند.

بحث

در این مقاله، یک سیستم تشخیص طبی به کمک کامپیوتر و روش‌های هوش مصنوعی برای تشخیص میزان چربی کبد از روی تصاویر التراسوند با موفقیت ارائه شد. ابتدا ۸۸ ویژگی مبتنی بر بافت با استفاده از ماتریس هم‌رخداد سطح خاکستری استخراج شده و در مرحله‌ی بعد استفاده از روش حداقل افزونگی و حداکثر ارتباط

جدول ۲: ماتریس درهم‌ریختگی برای طبقه‌بند آداپوست در تشخیص میزان چربی کبد به چهار سطح (کبد سالم، کبد با چربی کم، کبد با چربی متوسط، و کبد با چربی بالا).

	کلاس‌های واقعی			
	کبد سالم	چربی پایین	چربی متوسط	چربی بالا
کلاس‌های	کبد سالم	۲	۲	۰
پیش‌بینی شده	چربی پایین	۳	۵۵	۰
	چربی متوسط	۱	۲۲	۱
	چربی بالا	۰	۰	۲۹

References

- Jamali R, Jamali A. Non-alcoholic fatty liver disease. *Feyz J Kashan Univ Med Sci* 2010;14(2):169-79.
- Yang Y, He Q, Hu C, Liao J, Meng MQ-H, editors. Method of edge energy template for detection of ultrasonic based fatty liver. 2010 3rd International Congress on Image and Signal Processing; 2010: IEEE.
- 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(12):1895-903.
- 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 Phys* 2013;40(5):052904.
- Wu C-C, Yeh W-C, Hsu W-D, 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.
- Sani ZA, Shalbf A, Behnam H, Shalbf R. Automatic computation of left ventricular volume changes over a cardiac cycle from echocardiography images by nonlinear dimensionality reduction. *J Digit Imaging* 2015;28(1):91-8.
- Acharya UR, Fujita H, Sudarshan VK, Mookiah MRK, Koh JE, Tan JH, et al. An integrated index for identification of fatty liver disease using radon transform and discrete cosine transform features in ultrasound images. *Inf Fusion* 2016;31:43-53.
- Ribeiro R, Sanches J, editors. Fatty liver characterization and classification by ultrasound. Iberian conference on pattern recognition and image analysis; 2009: Springer.
- Mihailescu DM, Gui V, Toma CI, Popescu A, Sporea I. Computer aided diagnosis method for steatosis rating in ultrasound images using random forests. *Med ultrasonography* 2013;15(3):184-90.

10. Singh M, Singh S, Gupta S. An information fusion based method for liver classification using texture analysis of ultrasound images. *Inf Fusion* 2014;19:91-6.
11. Alivar A, Daniali H, Helfroush MS, editors. Classification of liver diseases using ultrasound images based on feature combination. 2014 4th International Conference on Computer and Knowledge Engineering (ICCKE); 2014: IEEE.
12. Sharma V, Juglan K. Automated classification of fatty and normal liver ultrasound images based on mutual information feature selection. *IRBM* 2018;39(5):313-23.
13. Azadi H, Akbarzadeh-T M-R, Kobravi H-R, Sarcheshmeh AN, Shahsavanpour N, Asgharzade MR, editors. Presentation of a new gender dependent feature selection approach for diagnosis of Parkinson disease using speech signal processing. 2015 International Congress on Technology, Communication and Knowledge (ICTCK); 2015: IEEE.
14. Peng H, Long F, Ding C. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Trans Pattern Anal Mach Intell* 2005;27(8):1226-38.
15. Torkkola K, editor Linear discriminant analysis in document classification. IEEE ICDM Workshop on Text Mining; 2001.
16. Jakkula V. Tutorial on support vector machine (svm). *School of EECS, Washington State University* 2006;37.
17. Vapnik V. The nature of statistical learning theory: Springer science & business media; 2013.
18. Berzal F, Matfn N. Data mining: concepts and techniques by Jiawei Han and Micheline Kamber. *ACM Sigmod Record* 2002;31(2):66-8.
19. Huang G-B, Zhou H, Ding X, Zhang R. Extreme learning machine for regression and multiclass classification. *IEEE Trans Syst Man Cybern Part B* 2011;42(2):513-29.
20. Freund Y, Schapire RE. A decision-theoretic generalization of on-line learning and an application to boosting. *J Comput Syst Sci* 1997;55(1):119-39.
21. Cortes C, Vapnik V. Support-vector networks. *Mach Learn* 1995;20(3):273-97.
22. Hastie T, Rosset S, Zhu J, Zou H. Multi-class adaboost. *Stat Interface* 2009;2(3):349-60.
23. Rajesh KN, Dhuli R. Classification of imbalanced ECG beats using re-sampling techniques and AdaBoost ensemble classifier. *Biomed Signal Process Control* 2018;41:242-54

Automatic classification of Non-alcoholic fatty liver using texture features from ultrasound images

Amir Reza Naderi Yaghouti
M.D.¹
Ahmad Shalbf Ph.D.^{2*}
Arash Maghsoudi Ph.D.³

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

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

3- Department of Biomedical
Engineering, Science and Research
Branch, Islamic Azad University,
Tehran, Iran.

* Corresponding author: Department of
Biomedical Engineering and Medical
Physics, School of Medicine, Shahid
Beheshti University of Medical Sciences,
Tehran, Iran.
Tel: +98-21-23872566
E-mail: Shalbf@sbmu.ac.ir

Abstract

Received: 2 Dec. 2020 Revised: 9 Dec. 2020 Accepted: 13 Mar. 2021 Available online: 21 Mar. 2021

Background: Accurate and early detection of non-alcoholic fatty liver, which is a major cause of chronic diseases is very important and is vital to prevent the complications associated with this disease. Ultrasound of the liver is the most common and widely performed method of diagnosing fatty liver. However, due to the low quality of ultrasound images, the need for an automatic and intelligent classification method based on artificial intelligence methods to accurately detect the amount of liver fat is essential. This paper aims to develop an advanced machine learning model based on texture features to assess liver fat levels based on liver ultrasound images.

Methods: In this analytic study, which is done from April to November 2020 in Tehran, ultrasound images of 55 obese people who have undergone laparoscopic surgery have been used and the histological result of a liver biopsy has been employed as a reference for liver fat. First, 88 texture-based features were extracted from the images using the Gray-Level Co-Occurrence Matrix (GLCM) method. In the next step, using the method of minimum redundancy and maximum correlation, the top features were selected from among 88 features and applied to the classifier input. Finally, using the three classifiers of linear discriminant analysis, support vector machine and AdaBoost, the images were classified into 4 groups based on the amount of liver fat.

Results: The accuracy of the automatic liver fat prediction model from ultrasound images for AdaBoost classification was 92.72%. However, the accuracies obtained for support vector machine and linear discriminant analysis classification were 87.88% and 75.76%, respectively.

Conclusion: The proposed approach based on texture features using the GLCM and the AdaBoost classification from ultrasound images automatically detects the amount of liver fat with high accuracy and can help physicians and radiologists in the final diagnosis.

Keywords: fatty liver, image processing, machine learning, ultrasound imaging.