

ORIGINAL ARTICLE

Detection of Liver Cancer from CT Scan Images Using Convolutional Neural Network and Support Vector Machine

Pegah Davrpanah¹, Somayeh Saraf Esmeili^{2*}

1 Ph.D. Student in Biomedical Engineering, Department of Biomedical Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.

2 Assistant Professor, Department of Biomedical Engineering, Garmsar Branch, Islamic Azad University, Garmsar, Iran.

Correspondence

Somayeh Saraf Esmeili

Email: saraf.bme@gmail.com

How to cite

Davrpanah, P. Saraf Esmeili, S. (2024). Detection of Liver Cancer from CT Scan Images Using Convolutional Neural Network and Support Vector Machine, Optoelectronic, 7 (1), 35-46.

ABSTRACT

Liver cancer is the fifth most common cancer in men and the seventh most common cancer in women, and is the third leading cause of cancer-related deaths worldwide. In general, the disease is less common in women, and in most regions of the world, the rate of liver cancer in men is two to three times higher than in women, which is probably due to the higher prevalence of risk factors in men and gender differences. In this regard, the aim of this research was to detect liver cancer from CT scan images using a convolutional neural network and support vector machine. In this research, a new lightweight CNN neural network with seven layers and only one conventional layer is proposed for segmented liver classification. This proposed model used in two different ways. The first path used deep learning classification and achieved accuracies of 83.7% and 95.9%. Meanwhile, the second route used automatically extracted features together with a support vector machine (SVM) classifier and achieved accuracies of 95.9% and 97.9%. The proposed network is lightweight, fast, reliable and accurate. This approach can be used by an oncologist, making detection a simple task. In addition, the proposed network achieves high accuracy without adjusting images, which reduces time and cost.

KEYWORDS

Detection of Liver Cancer, Convolutional Neural Network, Support Vector Machine.

فصلنامه علمی

اپتوالکترونیک

«مقاله پژوهشی»

تشخیص سرطان کبد از تصاویر سی تی اسکن با استفاده از شبکه عصبی پیچشی و ماشین بردار پشتیبانی

پگاه داورپناه¹، سمیه صراف اسماعیلی^{2*}

چکیده

سرطان کبد، به طور عمده، پنجمین سرطان شایع در مردان و هفتمین سرطان شایع در زنان است و سومین علت اصلی مرگ و میر ناشی از سرطان در سراسر جهان است. به طور کلی، این بیماری در زنان کمتر شایع است و در بیشتر مناطق جهان، میزان سرطان کبد مردان نسبت به زنان دو تا سه برابر بیشتر است که احتمالاً به دلیل شیوع بیشتر عوامل خطر در مردان و تفاوت‌های جنسی است. در همین رابطه هدف از پژوهش حاضر تشخیص سرطان کبد از تصاویر سی تی اسکن با استفاده از شبکه عصبی پیچشی و ماشین بردار پشتیبانی بوده است. در این پژوهش، یک شبکه عصبی CNN سبک جدید با هفت لایه و فقط یک لایه معمولی برای طبقه‌بندی کبد تقسیم‌بندی شده پیشنهاد شده است. این مدل پیشنهادی در دو مسیر مختلف استفاده شد. مسیر اول از طبقه‌بندی یادگیری عمیق استفاده نمود و به دقت 83/7% و 95/9% دست یافت. در همین حال، مسیر دوم از ویژگی‌های استخراج شده به طور خودکار همراه با یک طبقه‌بندی کننده ماشین بردار پشتیبانی (SVM) استفاده نمود و به دقت 95/9% و 97/9% دست یافت. شبکه پیشنهادی سبک، سریع، قابل اعتماد و دقیق است. این رویکرد می‌تواند توسط یک متخصص انکولوژی استفاده شود، که تشخیص را به یک کار ساده تبدیل می‌کند. علاوه بر این، شبکه پیشنهادی دقت بالایی را بدون تنظیم تصاویر به دست می‌آورد که باعث کاهش زمان و هزینه می‌شود.

واژه‌های کلیدی

تشخیص سرطان کبد، شبکه عصبی پیچشی، ماشین بردار پشتیبانی.

1 دانشجوی دکتری مهندسی پزشکی، گروه مهندسی پزشکی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
2 استادیار، گروه مهندسی پزشکی، واحد گرمسار، دانشگاه آزاد اسلامی، گرمسار، ایران.

نویسنده مسئول:

سمیه صراف اسماعیلی

رایانامه: saraf.bme@gmail.com

استناد به این مقاله:

پگاه داورپناه، سمیه صراف اسماعیلی (1403). تشخیص سرطان کبد از تصاویر سی تی اسکن با استفاده از شبکه عصبی پیچشی و ماشین بردار پشتیبانی. فصلنامه علمی اپتوالکترونیک، 7 (1)، 35-46.

مقدمه

(دانگ¹²، 2020)، استفاده از ویژگی‌های CNN خارج از برنامه به عنوان کانال‌های اطلاعاتی مکمل برای ویژگی‌های تصویر دست‌ساز موجود و انجام پیش‌آموزشی بدون نظارت بر تصاویر طبیعی یا پزشکی و تنظیم دقیق با استفاده از مدل‌های یادگیری عمیق (سومادی¹³، 2022). تقسیم‌بندی اندام‌ها یا ساختارهای تشریحی یک تکنیک پردازش تصویر عملکردی برای تجزیه و تحلیل تصاویر پزشکی مانند ارزیابی کمی پارامترهای بالینی و سیستم تشخیص به کمک رایانه است (ناکای¹⁴، 2021).

سرطان کبد، به طور عمده، پنجمین سرطان شایع در مردان و هفتمین سرطان شایع در زنان است (آراجو¹⁵، 2021) و سومین علت اصلی مرگ و میر ناشی از سرطان در سراسر جهان است (فرید-آدار¹⁶، 2018). به طور کلی، این بیماری در زنان کمتر شایع است و در بیشتر مناطق جهان، میزان سرطان کبد مردان به زنان دو تا سه برابر بیشتر است که احتمالاً به دلیل شیوع بیشتر عوامل خطر در مردان و تفاوت‌های جنسی (قونیم¹⁷، 2020)، هورمون‌های استروئیدی و شاید عوامل اپی ژنتیکی (اسچلچتر¹⁸، 2019) است. مطالعات نشان داد که میزان سرطان کبد در سرتاسر جهان رو به افزایش است که ممکن است تا حدی به ویروس هپاتیت B و عفونت‌های ویروس هپاتیت C، چاقی، دیابت، سندرم متابولیک و انفیلتراسیون چربی غیر الکلی کبد مربوط باشد (نقوی¹⁹، 2022).

با این حال، بار سرطان کبد بسته به موقعیت جغرافیایی متفاوت است (وانگ و همکاران²⁰، 2019). به عنوان مثال، در منطقه آسیا و اقیانوسیه، این یک مشکل بهداشت عمومی قابل توجه است (قونیم²¹، 2020). از آنجایی که کبد محل متابولیسم از سرطان‌های سایر اندام‌ها، عمدتاً سرطان‌های کولورکتال، معده، پانکراس، سینه و ریه است، ثانویه کبد بر بار سرطان کبد می‌افزاید (کاکار²²، 2018).

در حال حاضر و طبق دستورالعمل‌های جوامع کبدی آمریکا و اروپا و سازمان‌های جهانی گوارش، اولتراسوند به طور گسترده در نظارت بر سرطان کبد استفاده می‌شود (تریویزاکیز²³، 2018) و سی‌تی‌اس و تصاویر تشدید مغناطیسی (MRI) برای مشخص

امروزه پیشرفت قابل توجهی در تشخیص تصویر در درجه اول به دلیل احیای اخیر یادگیری عمیق، به ویژه شبکه عصبی کانولوشنال (CNN) که یک کلاس از شبکه‌های عصبی مصنوعی که به طور گسترده در تحقیقات زیست پزشکی و بالینی استفاده شده است، حاصل شده است (آقامحمدی¹، 2021). به عنوان مثال، استفاده بالقوه از CNN در تشخیص خونریزی گوارشی در تصاویر آندوسکوپی کپسول بی‌سیم با استفاده از ویژگی‌های دست‌ساز و CNN نشان داده شده است (آراجو²، 2021)، تشخیص عفونت هلیکوباکتر پیلوری بر اساس تصاویر آندوسکوپی (آیالو³، 2021) و تشخیص دستگاه گوارش نشان داده شده است. پولیپ با استفاده از تصاویر آندوسکوپی (آذر⁴، 2019) تشخیص داده شده است. همچنین علاقه زیادی به پتانسیل CNNها در تحقیقات رادیولوژی (بروکس⁵، 2015) و در بررسی‌های سلولی و هیستوپاتولوژیکی (چنگ⁶، 2018) وجود دارد (پنگ⁷، 2020). چندین مطالعه توانایی الگوریتم‌های CNN را در تشخیص ضایعه نشان داده‌اند که وظیفه رایج آندوسکوپیست‌ها، رادیولوژیست‌ها و پاتولوژیست‌ها برای تشخیص ناهنجاری‌ها با تصاویر پزشکی است (نیسا⁸، 2022). اینها شامل تشخیص پولیپ کولون، تشخیص ضایعات در تصاویر رادیولوژیکی و تشخیص تغییرات بدخیم هیستوپاتولوژیک در تصاویر بیوپسی است (مین⁹، 2018). الگوریتم‌های CNN همچنین برای طبقه‌بندی مفید هستند، CNNها از ضایعات هدف نشان‌داده‌شده در تصاویر پزشکی استفاده می‌کنند و این ضایعات به کلاس‌هایی طبقه‌بندی می‌شوند (رلا¹⁰، 2022). یکی از اینها طبقه‌بندی ضایعات به دسته‌های خاص (ضایعات یا طبیعی، بدخیم یا خوش‌خیم) است (منگ¹¹، 2021).

بنابراین؛ وظیفه تعیین مرزهای «بهینه» برای جداسازی کلاس‌ها در فضای ویژگی‌های چند بعدی است که توسط ویژگی‌های ورودی تشکیل می‌شود. حداقل سه تکنیک مهم توصیف شده است که از CNNها برای طبقه‌بندی تصاویر پزشکی استفاده می‌کنند، از جمله آموزش CNNها از ابتدا

12 Dong
13 Sumathy
14 Nakai
15 Araújo
16 Frid-Adar
17 Ghoniem
18 Schlachter
19 Naaqvi
20 Wang
21 Ghoniem
22 Kakkar
23 Trivizakis

1 Aghamohammadi
2 Araújo
3 Ayalew
4 Azer
5 Bruix
6 Cheng
7 Peng
8 Nisa
9 Meine
10 Rela
11 Meng

فرید-آدر و همکاران (2018) به بررسی شبکه‌های متخاصم مولد (GANs) برای افزایش داده‌های مصنوعی پرداختند. این پژوهش منجر به افزایش دقت طبقه‌بندی ضایعات کبدی از 78/6% به 92/4% با استفاده از داده‌های مصنوعی شد.

رضاپور و همکاران (1398) با استفاده از الگوریتم‌های فراابتکاری در کنار شبکه عصبی مصنوعی به دقت 95/12% و حساسیت 92/36% دست پیدا کردند.

جعفری و همکاران (1399) از الگوریتم ترکیبی ازدحام ذرات و انفیس برای بهبود دقت پیش‌بینی سرطان کبد استفاده کردند و به دقت 97.48% رسیدند.

در سال 2020، لی و همکاران با استفاده از شبکه ++Attention UNet در تقسیم‌بندی تصاویر CT کبدی، به نتایج بسیار رقابتی دست یافتند. همچنین کاوور و همکاران (2020) با بهره‌گیری از مدل‌های یادگیری عمیق برای طبقه‌بندی تصاویر CT کبد، به دقت 90/08% دست پیدا کردند. دانگ و همکاران (2020) با استفاده از یک شبکه عصبی کاملاً کانولوشن هیبرید شده (HFCNN) برای تشخیص سرطان کبد، به تحلیل لایه‌های داخلی شبکه عصبی پرداختند و ویژگی‌های مرتبط با پیش‌بینی را مشخص کردند.

در سال 2021، آیالتو و همکاران با معرفی یک روش متعادل‌سازی کلاس جدید توانستند بهبود قابل‌توجهی را در تقسیم‌بندی تومورهای کبدی به‌دست آورند. روش پیشنهادی آن‌ها به بهبود 0/01 در تقسیم‌بندی کبد و 0/11 در تقسیم‌بندی تومور منجر شد.

یزدی و همکاران (1400) با استفاده از الگوریتم K-means و الگوریتم‌های هوش ازدحامی و تکاملی به دقت 98/97% در تشخیص سرطان کبد دست یافتند.

در سال 2022، رلا و همکاران از الگوریتم گرگ خاکستری (GW-CTO) به‌همراه شبکه عصبی عمیق برای تشخیص تومورهای کبدی در تصاویر CT استفاده کردند. این مدل توسعه‌یافته، دقت تشخیص بالاتری نسبت به روش‌های دیگر داشت و بهبود 4/3% نسبت به سایر الگوریتم‌ها را نشان داد.

این تحقیقات نشان‌دهنده پیشرفت قابل توجه در استفاده از تکنیک‌های یادگیری عمیق و هوش مصنوعی در تشخیص و طبقه‌بندی سرطان کبد است که به طور پیوسته در حال بهبود است و به نتایج دقیق‌تر و قابل‌اعتمادتر منجر می‌شود.

روش پژوهش

هدف پژوهش پیش‌بینی و تشخیص سرطان کبد از تصاویر سی تی اسکن با استفاده از شبکه عصبی پیچشی و ماشین بردار پشتیبانی، است. پژوهش حاضر توصیفی تحلیلی بوده و از نظر

کردن ضایعه کانونی مشکوک در کبد نشان داده می‌شوند. تشخیص سرطان کبد به تصاویر MR یا سی تی اسکن با کنتراست متکی است که امکان شناسایی تا 65 درصد از گره‌های سلولی کوچک با اندازه کمتر از 2 میلی متر را فراهم می‌کند (کاوری¹، 2020). با این حال، تشخیص گره‌های کوچک به الگوی تقویت دینامیک عروقی در طول مراحل مختلف مطالعه بستگی دارد (لی²، 2020). همچنین، تنوع بین اپراتور ناشی از ارزیابی کیفی بصری وجود دارد (لیو³، 2020). بنابراین؛ استفاده از چارچوب تشخیصی به کمک رایانه ممکن است ما را قادر به حل این محدودیت‌ها و افزایش نتایج تشخیصی این روش‌های رادیولوژیکی کند (قونیم⁴، 2020).

با توجه به مطالب ارائه شده هدف پژوهش حاضر پیش‌بینی و تشخیص سرطان کبد از تصاویر سی تی اسکن با استفاده از شبکه عصبی پیچشی و ماشین بردار پشتیبانی بوده، که طی این تحقیق به این پرسش پاسخ داده می‌شود که چگونه می‌توان با استفاده از تصاویر سی تی اسکن و به‌کارگیری شبکه عصبی پیچشی و ماشین بردار پشتیبانی به تشخیص تومورهای کبد پرداخت؟

پیشینه پژوهش

در سال‌های اخیر، مطالعات گسترده‌ای در زمینه تشخیص و تقسیم‌بندی سرطان کبد با استفاده از شبکه‌های عصبی عمیق و الگوریتم‌های یادگیری ماشین انجام شده است.

رستگار و همکاران (1397) با طراحی یک شبکه عصبی تابع پایه شعاعی جدید با استفاده از الگوریتم فراابتکاری تکاملی تفاضلی توانستند به دقت 100% در تشخیص و دسته‌بندی سرطان کبد در مراحل آموزش و آزمون برسند که بهترین عملکرد نسبت به سایر روش‌ها را نشان داد.

تریویزاکیس و همکاران (2018) در پژوهشی به گسترش شبکه‌های عصبی کانولوشنال دوبعدی به سه‌بعدی پرداختند. آن‌ها نشان دادند که این معماری سه‌بعدی می‌تواند در طبقه‌بندی کبد در تصاویر DW-MRI مزایای قابل‌توجهی داشته باشد و دقت آن به 83% در مقابل 69.6% و 65.2% مدل‌های دوبعدی رسید.

چلباس و همکاران (2018) با استفاده از شبکه‌های عصبی کاملاً پیچشی و پس‌پردازش مبتنی بر شی، موفق به کاهش 85% از مثبت‌های کاذب شدند. دقت تشخیص در این مطالعه 92% بود.

1 Kavur

2 Li


3 Liu

4 Ghoniem

بعدی کبد را توصیف می‌کند. از سوی دیگر، شکل (2) حالت خوش‌خیم کبد و بخش مربوط به آن را با نمای سه بعدی آن نشان می‌دهد. لازم به ذکر است که جدول (1) تعداد تصاویر قبل و بعد از تقویت را نشان می‌دهد.




شکل 1. الف) از چپ به راست: نمایش برش کبد، کبد تقسیم شده و نمای سه بعدی از کبد بدخیم



شکل 1. ب) تصاویر از برش کبدی با ضایعات بدخیم



شکل 2. الف) از چپ به راست: برش کبد، کبد تقسیم شده و نمای سه بعدی از کبد خوش‌خیم



شکل 2. ب) تصاویر از برش کبدی با ضایعات خوش‌خیم

جدول 1. تعداد تصاویر بعد و قبل از تقویت

کل	بدخیم	خوش‌خیم	
124	85	39	تعداد تصاویر حجمی قبل از افزایش
163	85	78	تعداد تصاویر حجمی پس از تقویت

در این پژوهش، هدف استفاده از شبکه عصبی مصنوعی کانولوشن برای تقسیم‌بندی تومورهای کبدی در تصاویر CT

هدف کاربردی است. تقسیم‌بندی تومورهای کبد از تصاویر توموگرافی کامپیوتری (CT) یک کار ضروری برای تشخیص و درمان سرطان کبد است. با این حال، به دلیل تنوع ظاهری، مرزهای فازی، تراکم ناهمگن، شکل‌ها و اندازه ضایعات دشوار است. در این پژوهش، یک روش خودکار مبتنی بر شبکه‌های عصبی کانولوشن (CNN) برای بخش‌بندی ضایعات از تصاویر CT ارائه خواهد شد. شبکه‌های عصبی کانولوشن یکی از مدل‌های یادگیری عمیق با چند فیلتر کانولوشن است که می‌تواند ویژگی‌های سلسله مراتبی را از داده‌ها یاد بگیرد.

اهداف درک داده‌ها شامل درک ویژگی‌های داده و شناسایی خصوصیات اصلی مانند حجم داده و تعداد کل متغیرها برای جمع‌بندی داده‌ها است. قبل از پردازش و تجزیه و تحلیل، آماده‌سازی داده‌ها انجام می‌شود که فرآیندی است که از طریق آن داده‌های خام تصفیه و تبدیل می‌شوند. به عبارت دیگر، این فرآیندی است که در آن داده‌ها دوباره اصلاح، تصحیح و با داده‌های غنی شده ترکیب می‌شوند. جمع‌آوری، تجزیه و تحلیل و استفاده از داده‌ها مانند داده‌های مصرف‌کننده، بیمار، فیزیکی و بالینی، به داده‌های بزرگ ختم می‌شود. در این مرحله است که مداخله انسان، به عنوان بخشی از روش‌های یادگیری ماشین، انجام می‌شود و متخصصان با استخراج و تجزیه و تحلیل داده‌ها، داده‌ها را با بهترین ساختارها، الگوها و ویژگی‌ها استخراج می‌کنند.


داده‌های بحث‌شده در اینجا شامل اطلاعات پزشکی، مانند گزارش‌های بالینی، سوابق و سایر اشکال مختلف اطلاعات است که می‌تواند به داده‌هایی تبدیل شود که برای ماشین قابل درک باشد.

مجموعه داده حاضر در نتیجه تقسیم‌بندی تومور کبد ایجاد شد که در ارتباط با سمپوزیوم بین‌المللی IEEE در تصویربرداری زیست پزشکی (ISBI) 2017 و کنفرانس بین‌المللی محاسبات تصویر پزشکی و مداخلات به کمک رایانه (MICCAI) 2017 برگزار شد. تصاویر کبد از یک تصویر CT سه بعدی قطعه‌بندی و منتشر شده است. در جهت محوری، اندازه پیکسل‌ها از 0/56 میلی‌متر تا 1/0 میلی‌متر و در جهت z، از 0/45 میلی‌متر تا 6/0 میلی‌متر متغیر است. تعداد برش‌ها در هر سی‌تی اسکن از 42 تا 1026 متغیر است و اندازه همه برش‌ها به 150 پیکسل تغییر داده شد. داده‌ها از پایگاه داده LiTS17 جمع‌آوری شده است.

در این پایگاه داده، تعداد موارد خوش‌خیم 39 مورد، تعداد موارد بدخیم 85 مورد، در حالی که 6 مورد بدون ضایعه تشخیص داده شده است، یعنی طبیعی هستند. موارد عادی از مجموعه داده حذف می‌شوند، زیرا برای طبقه‌بندی کافی نیستند. روش پیشنهادی فقط بر اساس موارد خوش‌خیم و بدخیم طراحی شده است. شکل (1) برش بدخیم کبد، کبد تقسیم‌شده و نمای سه

عنوان ورودی با اندازه 6×6 گرفت. ما دوباره از همان عملیات کانولوشن برای به دست آوردن 64 نقشه ویژگی با اندازه 4×4 استفاده کردیم. سپس همان عملیات را مانند S2 انجام دادیم، در لایه S4 به نتیجه رسیدیم. نقشه‌های ویژگی با اندازه 2×2 . آخرین لایه کانولوشن C5 شامل 128 نقشه ویژگی با اندازه 1×1 بود. ششمین لایه کاملاً متصل F6 در بالای CNNها اعمال شد تا روابط بین ویژگی‌های سطح بالا به دست آمده را کشف کند.

از لایه‌های قبلی که در آن 64 نورون در این لایه وجود داشت. لایه نهایی شامل دو واحد کاملاً متصل به لایه F6 بود، یک نورون فعال شده با رگرسیون softmax مقداری بین 0 و 1 تولید کرد که می‌توان آن را به عنوان احتمال تومور بودن یا نبودن پیکسل در مرکز پیچ تفسیر کرد.



شکل 4. معماری CNNها برای تقسیم بندی تومور کبد

در تقسیم‌بندی تصاویر CT، دو چالش اصلی شامل مرزهای فازی و تراکم ناهمگن تومورها است که باعث کاهش دقت مدل‌ها می‌شود. برای مقابله با مرزهای نامشخص بین بافت‌های سالم و ناسالم، در این مطالعه از شبکه‌های عصبی پیچشی (CNN) استفاده شده که با استخراج ویژگی‌های پیچیده مانند لبه‌ها و بافت‌ها، به بهبود شناسایی مرزهای فازی کمک می‌کند. علاوه بر این، تکنیک‌های پیش‌پردازش تصاویر مانند نرمال‌سازی و حذف نویز، وضوح تصاویر را افزایش داده و به تفکیک بهتر نواحی توموری کمک می‌کنند.

برای مدیریت تراکم ناهمگن تومورها، تصاویر به وصله‌های کوچک‌تری تقسیم شده‌اند تا مدل بتواند تراکم‌های مختلف را در مناطق کوچک‌تر شناسایی کند. این رویکرد باعث می‌شود ویژگی‌های دقیق‌تری از تراکم‌های متنوع استخراج شود و عملکرد مدل در طبقه‌بندی تومورها بهبود یابد. این روش‌های پیشنهادی به‌طور مؤثری مشکلات مربوط به مرزهای فازی و تراکم ناهمگن را حل کرده‌اند و دقت نهایی مدل را افزایش داده‌اند.

مراحل پیش‌پردازش و تقویت داده‌ها در تشخیص و تقسیم‌بندی تصاویر پزشکی، به‌ویژه تصاویر سی‌تی‌اسکن (CT)، نقش بسیار مهمی در بهبود دقت و عملکرد مدل‌های یادگیری عمیق دارند. پیش‌پردازش داده‌ها شامل مجموعه‌ای از تکنیک‌هاست که داده‌های خام را برای ورود به مدل آماده می‌کند. تصاویر CT از کیفیت و اندازه‌های متفاوتی برخوردارند.

است. چارچوب کلی برای فرآیند آموزش و آزمایش در شکل (3) نشان داده شده است.



شکل 3. بلوک دیاگرام روش پیشنهادی

این روش‌ها شامل پیش‌پردازش، استخراج پیچ، آموزش طبقه‌بندی کننده، طبقه‌بندی، پس‌پردازش است. در این پژوهش CNNها با استفاده از وصله‌های تصویر در مرکز هر پیکسل آموزش داده شده است. این تکه‌ها به دو دسته تومور و بافت کبد طبیعی تقسیم شدند. اگر پیچ داده شده حاوی حداقل 50 درصد یا بیشتر از پیکسل‌های تومور کبد باشد، به عنوان نمونه مثبت برچسب‌گذاری می‌شود، در غیر این صورت به عنوان نمونه منفی برچسب‌گذاری می‌شود. با در نظر گرفتن زمان آموزش و تراز نمونه‌های آموزشی، تعداد نمونه‌های منفی به اندازه نمونه‌های مثبت به طور تصادفی انتخاب شد.

مدل CNN میدان‌های دریافتی محلی، وزن‌های مشترک، نمونه‌برداری فرعی را برای اطمینان از درجه‌ای از تغییر، مقیاس و تغییرناپذیری اعوجاج ترکیب می‌کند. این مدل می‌تواند بسیاری از نقشه‌های ویژگی را با انحراف تصویر ورودی با یک فیلتر خطی، افزودن یک اصطلاح با یاس و اعمال یک تابع غیرخطی بیاموزد. به ویژه برای کاهش ابعاد ویژگی‌ها و جلوگیری از برازش بیش از حد، لایه max-pooling معرفی شده است.

کل شبکه پارامترها را با به حداقل رساندن تابع هزینه با استفاده از نزول گرادیان تصادفی (SGD) بهینه می‌کند. در این مطالعه، یک شبکه CNN با اندازه‌های مختلف پیچ برای تقسیم‌بندی تومورهای کبدی طراحی خواهد شد.

یک تصویر دقیق از CNNها با اندازه پیچ ورودی 17×17 و هفت لایه در شکل (4) نشان داده شده است که شامل سه لایه کانولوشن، دو لایه max-pooling یک لایه کاملاً متصل و یک طبقه‌بندی کننده softmax است. عملیات max-pooling پس از لایه‌های کانولوشن پذیرفته شد. اولین لایه کانولوشن C1 از 32 نقشه ویژگی تشکیل شده است که از طریق فیلترهایی با اندازه 5×5 و گام‌های یک پیکسل به تمام تصاویر پیچ شده 17×17 وصل شده است.

اندازه نقشه‌های ویژگی تولید شده در این لایه 13×13 بود. لایه دوم S2 حداکثر ادغام با اندازه هسته 2×2 و گام 2 است. فیلدهای گیرنده همپوشانی نداشتند. لایه C3 خروجی S2 را به

مانند شبکه‌های عصبی پیچشی (CNN)، افزایش حجم داده‌ها از اهمیت ویژه‌ای برخوردار است.

تجزیه و تحلیل

داده‌ها به 70 درصد داده‌های آموزشی و بقیه داده‌ها برای آزمایش استفاده شده است. استراتژی یادگیری انتقالی در اینجا به کار گرفته شده است تا برای دو کلاس مناسب باشد. حداکثر دقت به دست آمده با استفاده از ResNet50 مقدار 83/7% به دست آمده است. شکل (7) ماتریس سردرگمی ResNet50 را نشان می‌دهد.

Output Class	benign	23 46.9%	8 16.3%	74.2% 25.8%
	malignant	0 0.0%	18 36.7%	100% 0.0%
		100% 0.0%	69.2% 30.8%	83.7% 16.3%
		benign	malignant	
		Target Class		

شکل 5. نتایج ماتریس سردرگمی ResNet50

با شبکه عمیق ResNet50

تعداد و درصد طبقه‌بندی‌های صحیح توسط شبکه از پیش آموزش دیده در دو سلول قطر اصلی شکل (5) نشان داده شده است. برای مثال، 23 رخداد به طور مناسب به عنوان خوش‌خیم طبقه‌بندی شدند. این نشان دهنده 46/9% از کل 49 وقوع است. به همین ترتیب، 18 مورد به‌طور دقیق به عنوان بدخیم برچسب‌گذاری شد که 36/7 درصد از کل موارد در این دسته قرار گرفتند.

هشت مورد از موارد بدخیم به اشتباه به عنوان خوش‌خیم طبقه‌بندی شدند که 16/3% از کل 49 مورد در مطالعه را تشکیل می‌دهد. به همین ترتیب، 0 نمونه‌برداری خوش‌خیم به اشتباه به عنوان بدخیم برچسب‌گذاری شد که 0 درصد از کل داده‌ها را تشکیل می‌دهد.

از 31 پیش‌بینی خوش‌خیم، 74/2 درصد صحیح و 25/8 درصد نادرست بودند. از 18 پیش‌بینی بدخیم، 100% درست و 0% اشتباه بود. از 23 مورد خوش‌خیم، 100% به درستی به عنوان خوش‌خیم پیش‌بینی شد، در حالی که 0% به عنوان بدخیم پیش‌بینی شد. از 26 مورد بدخیم، 69/2% به درستی به عنوان بدخیم طبقه‌بندی شدند، در حالی که 30/8% به عنوان خوش‌خیم

در این پژوهش، اندازه تصاویر به 150 پیکسل تغییر داده شده و پیکسل‌ها در جهت‌های مختلف تنظیم شده‌اند. نرمال‌سازی باعث می‌شود مدل درک بهتری از تصاویر داشته باشد و به دلیل حذف اثرات نویز و مقیاس‌های مختلف، عملکرد بهتری از خود نشان دهد.

در این مطالعه، اندازه پیکسل‌ها در جهت محوری (0/56 تا 1/0 میلی‌متر) و در جهت Z (0/45 تا 6/0 میلی‌متر) تغییر داده شد. این تنظیمات برای اطمینان از همگن بودن داده‌های ورودی انجام می‌شود که به مدل اجازه می‌دهد ویژگی‌های مهم را به صورت یکپارچه تشخیص دهد. تقسیم تصاویر به وصله‌های کوچک‌تر، مانند پچ‌های 17×17 پیکسلی که در این مطالعه استفاده شده است، باعث می‌شود مدل ویژگی‌های محلی مهم را شناسایی کند. استفاده از پچ‌ها همچنین می‌تواند باعث کاهش ابعاد ویژگی‌ها و بهبود دقت مدل شود.

تقویت داده‌ها به‌عنوان یکی از مراحل مهم در فرآیند یادگیری عمیق به‌کار گرفته می‌شود. در این پژوهش نیز، تعداد تصاویر خوش‌خیم با استفاده از روش‌های تقویت داده دو برابر شد (از 39 به 78 تصویر) تا حجم داده‌های آموزشی افزایش یافته و مدل توانایی تعمیم‌پذیری بهتری داشته باشد. روش‌های تقویت داده در این پژوهش شامل:

چرخش تصاویر: چرخش تصاویر با زوایای مختلف به مدل کمک می‌کند تا نسبت به تغییرات جهت و زوایای مختلف تصویر مقاوم باشد.

اعوجاج و تغییر اندازه: اعمال تغییرات جزئی در اندازه و شکل تصاویر به مدل اجازه می‌دهد با انواع تنوع‌های موجود در داده‌های واقعی مواجه شود.

افزایش تعادل داده‌ها: با توجه به اینکه تعداد موارد خوش‌خیم در مقایسه با موارد بدخیم کمتر بود، تقویت داده‌ها باعث ایجاد تعادل نسبی بین نمونه‌های خوش‌خیم و بدخیم شد. این تعادل در داده‌ها باعث کاهش بایاس مدل و بهبود دقت کلی در تشخیص می‌شود.


پیش‌پردازش داده‌ها باعث کاهش نویز و ناهنجاری‌ها در تصاویر CT می‌شود که در نهایت منجر به افزایش دقت مدل در تشخیص ضایعات می‌شود. تقویت داده‌ها نیز با افزایش تعداد نمونه‌های آموزشی و تعادل میان دسته‌ها، به مدل کمک می‌کند تا ویژگی‌های مهم را بهتر فراگیرد و عملکرد بهتری در شرایط مختلف داشته باشد.

کاهش خطر بیش‌برازش (Overfitting): با استفاده از روش‌های تقویت داده و افزایش حجم مجموعه آموزشی، خطر بیش‌برازش در مدل کاهش می‌یابد. به‌ویژه در مدل‌های پیچیده

رخدادها بود.

دو مورد از موارد بدخیم به اشتباه به عنوان خوش خیم طبقه‌بندی شدند که 4/1 درصد از کل 49 مورد در مطالعه را تشکیل می‌دهند.

از 23 پیش‌بینی خوش‌خیم، مشخص شد که 100 درصد درست بوده است. در همین حال، از 24 پیش‌بینی بدخیم، 100 درصد درست بوده است. همچنین از 23 مورد خوش‌خیم، 100 درصد به درستی خوش‌خیم پیش‌بینی شد، در حالی که از 26 مورد بدخیم، 92/3 درصد به درستی به عنوان بدخیم طبقه‌بندی و 7/7 درصد اشتباه تشخیص داده شد. در مجموع 95/9 درصد از پیش‌بینی‌ها درست و 4/1 درصد نادرست بودند. عملکرد شبکه پیشنهادی بهتر از CNN (ResNet50) از پیش آموزش دیده بود. شکل (8) منحنی طبقه‌بندی ROC را با استفاده از LiverNet نشان می‌دهد.



شکل 8. منحنی AROC با استفاده از LiverNet


تعداد لایه‌های کانولوشن در LiverNet یک لایه است که باعث می‌شود در آموزش و تست سریع باشد. جدول (2) زمان مورد نیاز برای مراحل آزمایش را برای CNN موجود و پیشنهادی نشان می‌دهد.

جدول 2. مقایسه زمان آزمایش ResNet50 و LiverNet

شبکه	آزمایش
ResNet50	32 ثانیه
شبکه حاضر	22 ثانیه

در مرحله بعد ResNet50 و LiverNet به عنوان استخراج‌کننده ویژگی در هر دو شبکه، دو ویژگی از لایه نهایی کاملاً متصل بازایی می‌شوند. در نهایت، داده‌های برچسب‌گذاری شده با استفاده از SVM گاوسی طبقه‌بندی

طبقه‌بندی شدند. در مجموع 83/7 درصد از پیش‌بینی‌ها درست و 16/3 درصد از آنها اشتباه بوده است. شبکه مربوطه به موارد بدخیم بسیار حساس است. تقریباً 31 درصد از موارد بدخیم به عنوان خوش‌خیم تشخیص داده شدند که در کاربردهای پزشکی قابل قبول نیست. شکل (6) منحنی ROC را برای این مورد نشان می‌دهد.



شکل 6. منحنی AROC با استفاده از ResNet50.


شبکه پیشنهادی در مقایسه با ResNet50 دقت بالایی به دست آورد و شکل (7) ماتریس سردرگمی LiverNet را نشان می‌دهد. در اینجا، دقت به 95/9% رسید.

		test Confusion matrix		
		benign	malignant	
Output Class	benign	23 46.9%	2 4.1%	92.0% 8.0%
	malignant	0 0.0%	24 49.0%	100% 0.0%
		benign	malignant	
		100% 0.0%	92.3% 7.7%	95.9% 4.1%
		Target Class		

شکل 7. نتایج ماتریس سردرگمی LiverNet

با شبکه عمیق LiverNet

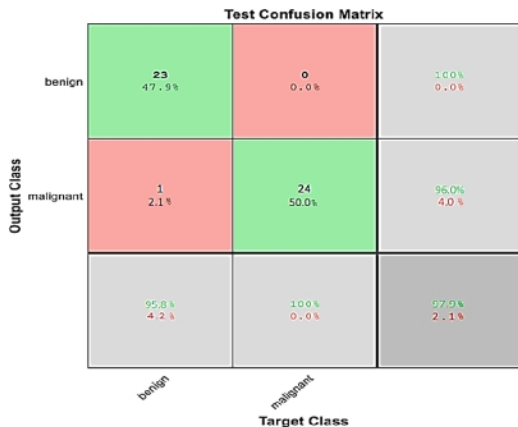
تعداد و درصد طبقه‌بندی‌های صحیح توسط شبکه پیشنهادی در دو سلول اول قطر اصلی شکل (7) نشان داده شده است. به عنوان مثال، در مجموع 23 رخداد به طور دقیق به عنوان خوش‌خیم طبقه‌بندی شدند. این نشان دهنده 46/9% از کل 49 وقوع است. در همین رویکرد، 24 مورد به طور دقیق به عنوان بدخیم برچسب‌گذاری شدند. این مورد در 49 درصد از تمام



شکل 10. منحنی AROC شبکه SVM با ویژگی‌های ResNet50

با شبکه عمیق LiverNet و SVM

دو سلول اول قطر اصلی در شکل (11) تعداد و درصد طبقه‌بندی‌های صحیح را با استفاده از SVM گاوسی شبکه پیشنهادی با ویژگی‌های گرافیکی سه بعدی نشان می‌دهد. به عنوان مثال، طبقه‌بندی خوش‌خیم برای 23 رخداد صحیح بود که نشان‌دهنده 47/9% از کل 48 رخداد است. در همین رویکرد، 24 مورد به طور دقیق بدخیم شناسایی شد که 50/0 درصد از کل موارد بود.



شکل 11. ماتریس سردرگمی SVM با ویژگی‌های LiverNet

از 23 مورد خوش‌خیم، 100 درصد آنها به درستی خوش‌خیم پیش‌بینی شدند، در حالی که از 25 مورد بدخیم، 96 درصد به درستی به عنوان بدخیم طبقه‌بندی شدند. در کل 97/9% پیش‌بینی‌ها درست بود. شکل (12) منحنی ROC سیستم هیبریدی را با استفاده از ویژگی‌های LiverNet نشان می‌دهد.

می‌شوند.

این مدل با استفاده از طبقه‌بندی کننده SVM گاوسی برای تمایز بین تومورهای بدخیم و خوش‌خیم ساخته شده است. شکل (9) ماتریس سردرگمی SVM گاوسی را با استفاده از ویژگی‌های گرافیکی سه بعدی ResNet50 توصیف می‌کند. در اینجا، دقت کل به مقدار 95/9% رسید.



شکل 9. ماتریس سردرگمی SVM با ویژگی‌های ResNet50

با شبکه عمیق SVM و ResNet50

دو سلول اول قطر اصلی در شکل (9) تعداد و درصد طبقه‌بندی‌های صحیح را در ResNet50 با استفاده از SVM گاوسی با ویژگی‌های گرافیکی سه بعدی نشان می‌دهد. به عنوان مثال، در مجموع 23 رخداد به طور دقیق به عنوان خوش‌خیم طبقه‌بندی شدند. این نشان‌دهنده 46/9% از کل 49 وقوع است. در همین رویکرد، 24 مورد به طور دقیق به عنوان بدخیم برچسب‌گذاری شدند. این مورد در 49 درصد از تمام رخدادهای بود.

دو مورد از موارد بدخیم به اشتباه به عنوان خوش‌خیم طبقه‌بندی شدند که 4/1 درصد از کل 49 مورد در مطالعه را تشکیل می‌دهند. از 23 پیش‌بینی خوش‌خیم، مشخص شد که 100 درصد درست بوده است. در همین حال، از 24 پیش‌بینی بدخیم، 100 درصد درست بوده است. همچنین از 23 مورد خوش‌خیم، 100 درصد به درستی خوش‌خیم پیش‌بینی شد، در حالی که از 24 مورد بدخیم، 92/3 درصد به درستی به عنوان بدخیم طبقه‌بندی و 7/7 درصد اشتباه تشخیص داده شد. در مجموع 95/9 درصد از پیش‌بینی‌ها درست و 4/1 درصد نادرست بودند. شکل (10) منحنی ROC سیستم هیبریدی را با استفاده از یک CNN از پیش آموزش دیده نشان می‌دهد.

نتیجه گیری

بیماران مبتلا به سرطان کبد میزان مرگ و میر بالایی دارند که علت اصلی آن تشخیص دیرهنگام این بیماری است. سیستم‌های تشخیصی کمک‌رسان رایانه‌ای، با استفاده از تکنیک‌های مختلف تصویربرداری پزشکی، می‌توانند به تشخیص زودهنگام سرطان کبد کمک کنند. روش‌های مختلفی برای شناسایی سرطان کبد به کار گرفته شده‌اند که از طبقه‌بندی‌کننده‌های یادگیری ماشینی و یادگیری عمیق استفاده می‌کنند.

یافته‌های این مطالعه نشان می‌دهد که استفاده از شبکه‌های عصبی پیچشی (CNN) برای استخراج خودکار ویژگی‌ها، همراه با طبقه‌بندی کننده ماشین بردار پشتیبان (SVM)، به طور قابل توجهی عملکرد طبقه‌بندی را بهبود می‌بخشد. همچنین نتایج نشان می‌دهد که مدل پیشنهادی زمان پردازش را به 22 ثانیه کاهش می‌دهد، در حالی که ResNet50 به 32 ثانیه نیاز دارد.

معیارهای عملکرد شامل حساسیت، صحت، ویژگی و دقت به ترتیب برابر با 100، 100، 95/8، 97/9 است. این رویکرد می‌تواند تومورها را با دقت بالا حتی در تصاویر سی‌تی‌اسکن با کنتراست پایین تشخیص دهد.


در نهایت، نتایج زیر را می‌توان از این پژوهش استنتاج کرد: (1) عملکرد مدل یادگیری عمیق برای استفاده در تجهیزات پزشکی بسیار مطلوب است و بهبود قابل توجهی را نشان می‌دهد. (2) طبقه‌بندی‌کننده، تومور را با دقت نسبتاً بالایی تشخیص می‌دهد. (3) تقسیم‌بندی تومورهای بسیار کوچک چالش‌برانگیز است و سیستم ممکن است نویز محلی را به عنوان تومور بالقوه در نظر بگیرد.

روش پیشنهادی با استفاده از مجموعه داده LiTs17 مقایسه شده است و عملکرد مطلوبی در بین پژوهش‌های مرتبط به دست آورده است. جدول (4) مقایسه این مطالعه با پژوهش‌های گذشته را بر اساس سطح زیر منحنی (AUC)، ویژگی، حساسیت و دقت نشان می‌دهد.

جدول 4. مقایسه مطالعه حاضر با وضعیت موجود

منبع	روش	دقت	حساسیت	ویژگی	AROC
کاکار ¹ و همکاران (2018)	شبکه عصبی مصنوعی	97/11	-	-	-
قائیم ² (2020)	SegNet-UNet-ABC	97/5	-	97/2	-
السعید ³ (2022)	Fast Generalized Fuzzy C-Means	95/5	96/23	95/83	0/98
پژوهش حاضر	CNN-SVM	97/9	100	95/8	97/8

1 Kakkar
2 Ghoniem
3 Al-Saeed



شکل 12. AROC سیستم هیبریدی با ویژگی‌های LiverNet

معیارهای ارزیابی که در این مطالعه استفاده شده است در زیر مشخص آمده است. جدول (3) نتایج را در مسیر یادگیری عمیق و مسیر ترکیبی برای ResNet50 و LiverNet پیشنهادی توصیف می‌کند. از معادلات زیر برای محاسبه عملکرد طبقه‌بندی کننده استفاده می‌شود.

$$\text{حساسیت} = \frac{TP}{TP+FN} \quad (1)$$

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

$$\text{ویژگی} = \frac{TN}{TN+FP} \quad (3)$$


$$\text{دقت} = \frac{TP}{TP+TN+FP+FN} \quad (4)$$

در معادلات بالا، TP مثبت واقعی، TN منفی واقعی، FP مثبت کاذب و FN منفی کاذب است.

جدول 3. مقایسه بین یادگیری عمیق و مدل ترکیبی پیشنهادی

روش	حساسیت	صحت	ویژگی	دقت	یادگیری عمیق
ResNet50	100	74/2	69/2	83/7	یادگیری عمیق
LiverNet	100	92	92/3	95/9	یادگیری عمیق
ResNet50	100	92	92/3	95/9	روش ترکیبی
LiverNet	100	100	95/8	97/9	روش ترکیبی

عملکرد بالای شبکه پیشنهادی به عنوان یک استخراج‌کننده مشخص است. علاوه بر این، شکل (13) زیر عملکرد بالای رویکرد پیشنهادی را در دستیابی به تشخیص دقیق تومورهای کبدی نشان می‌دهد.



شکل 13. دقت، صحت، ویژگی و حساسیت رویکردهای مختلف

سوق دهد، که این امر دقت مدل را کاهش می‌دهد. مسئله دیگری که باید مد نظر قرار گیرد، نیاز به مجموعه داده‌های بزرگ و با کیفیت است. هر چقدر کیفیت تصاویر پایین‌تر باشد یا داده‌ها محدودتر باشند، عملکرد مدل نیز به همان نسبت ضعیف‌تر خواهد بود. تنظیم دقیق پارامترهای CNN و SVM نیز از جمله چالش‌های مهم دیگر است؛ زیرا اگر این پارامترها به درستی تنظیم نشوند، ممکن است مدل دچار بیش‌برازش (Overfitting) یا کم‌برازش (Underfitting) شود، که این امر به شدت بر دقت و تعمیم‌پذیری مدل تأثیر می‌گذارد.

در مقایسه با سایر روش‌ها، مدل‌های کاملاً مبتنی بر یادگیری عمیق، مانند ResNet50، ممکن است در دقت طبقه‌بندی به اندازه ترکیب CNN-SVM مؤثر نباشند. اگرچه این مدل‌ها پیاده‌سازی ساده‌تری دارند و ممکن است زمان پردازش کوتاه‌تری نیاز داشته باشند، اما عملکرد کلی آن‌ها در بسیاری از موارد به اندازه روش‌های ترکیبی مؤثر نیست. از سوی دیگر، روش‌های سنتی طبقه‌بندی یا استفاده از شبکه‌های مولد تخصصی (GANs)، هرچند ممکن است در برخی کاربردها به‌ویژه با داده‌های کمتر مناسب‌تر باشند، اما دقت آن‌ها معمولاً پایین‌تر از روش‌های ترکیبی مانند CNN-SVM است.

در نهایت، روش ترکیبی CNN-SVM برای تشخیص سرطان کبد از تصاویر CT یک راهکار بسیار مؤثر و قابل اعتماد به شمار می‌آید. این روش مزایای قابل توجهی در زمینه استخراج ویژگی‌های دقیق و تشخیص با دقت بالا ارائه می‌دهد. با این حال، برای رسیدن به بهترین نتایج باید به چالش‌های موجود، مانند تشخیص تومورهای کوچک، تنظیم دقیق پارامترها و استفاده از داده‌های با کیفیت، توجه ویژه‌ای داشت تا از هرگونه خطا و کاهش دقت جلوگیری شود.

این پژوهش سطح بالایی از اطمینان به‌دست‌آمده با استفاده از LiverNet به عنوان یک استخراج‌کننده خودکار ویژگی‌ها، علاوه بر استفاده از مزایای یادگیری ماشینی برای تمایز بین تومورهای خوش‌خیم و بدخیم کبد را نشان می‌دهد.

استفاده از شبکه عصبی پیچشی (CNN) به همراه ماشین بردار پشتیبانی (SVM) به‌عنوان یک روش ترکیبی برای تشخیص و پیش‌بینی سرطان کبد از تصاویر CT، رویکردی قابل اعتماد به شمار می‌آید. این روش به دلیل ترکیب توانایی‌های CNN در استخراج ویژگی‌های پیچیده و غیرخطی تصاویر و قدرت طبقه‌بندی SVM، منجر به افزایش دقت در تشخیص می‌شود. CNN ویژگی‌های دقیق تصاویر را استخراج می‌کند و سپس SVM به‌عنوان یک طبقه‌بند کارآمد، از این ویژگی‌ها برای تشخیص دقیق استفاده می‌کند. به‌طور کلی، این ترکیب می‌تواند دقت بالایی تا 97/9% و زمان پردازش کوتاهی را به همراه داشته باشد. به عنوان مثال، در این مدل زمان پردازش به 22 ثانیه کاهش یافته است. این روش همچنین به دلیل ویژگی‌هایش می‌تواند عملکرد بهتری در تمایز بین موارد بدخیم و خوش‌خیم نشان دهد که حساسیت 100% و ویژگی 95/8% مؤید این نکته است. به‌علاوه، در مقایسه با سایر روش‌ها مانند ResNet50، این رویکرد می‌تواند نتایج بهتری ارائه دهد و عملکرد بالاتری در تشخیص تومورهای کبدی نشان دهد.

با این حال، این روش دارای محدودیت‌ها و چالش‌هایی نیز هست. یکی از این چالش‌ها، دشواری در تشخیص تومورهای کوچک و وجود نویز در تصاویر CT است که می‌تواند به تشخیص نادرست منجر شود. به‌ویژه در مواردی که نویز با تومور اشتباه گرفته شود، احتمال خطا در نتایج افزایش می‌یابد. علاوه بر این، استفاده از مجموعه داده‌های نامتعادل ممکن است مدل را به سمت تمرکز بیش از حد بر روی دسته غالب

References

- [1] Aghamohammadi, A., Ranjbarzadeh, R., Naiemi, F., Mogharrebi, M., Dorosti, S., & Bendeche, M. (2021). TPCNN: two-path convolutional neural network for tumor and liver segmentation in CT images using a novel encoding approach. *Expert Systems with Applications*, 183, 115406.
- [2] Al-Saeed, Y., Gab-Allah, W. A., Soliman, H., Abulkhair, M. F., Shalash, W. M., & Elmogy, M. (2022). Efficient computer aided diagnosis system for hepatic tumors using computed tomography scans. *CMC-Comput Mater Cont*, 71 (3), 4871-94.
- [3] Araújo, J. D. L., da Cruz, L. B., Ferreira, J. L., da Silva Neto, O. P., Silva, A. C., de Paiva, A. C., & Gattass, M. (2021). An automatic method for segmentation of liver lesions in computed tomography images using deep neural networks.

منابع

- [4] Ayalew, Y. A., Fante, K. A., & Mohammed, M. A. (2021). Modified U-Net for liver cancer segmentation from computed tomography images with a new class balancing method. *BMC Biomedical Engineering*, 3, 1-13.
- [5] Azer, S. A. (2019). Deep learning with convolutional neural networks for identification of liver masses and hepatocellular carcinoma: A systematic review. *World journal of gastrointestinal oncology*, 11 (12), 1218.
- [6] Bruix, J., Han, K. H., Gores, G., Llovet, J. M., & Mazzaferro, V. (2015). Liver cancer: approaching a personalized care. *Journal of hepatology*, 62 (1), S144-S156.
- [7] Cheng, L., Zhang, Z., Zuo, D., Zhu, W., Zhang, J.,

- Zeng, Q., ... & Zhao, Y. (2018). Ultrasensitive detection of serum microRNA using branched DNA-based SERS platform combining simultaneous detection of α -fetoprotein for early diagnosis of liver cancer. *ACS applied materials & interfaces*, 10 (41), 34869-34877.
- [8] Chlebus, G., Schenk, A., Moltz, J. H., van Ginneken, B., Hahn, H. K., & Meine, H. (2018). Automatic liver tumor segmentation in CT with fully convolutional neural networks and object-based postprocessing. *Scientific reports*, 8 (1), 15497.
- [9] Dong, X., Zhou, Y., Wang, L., Peng, J., Lou, Y., & Fan, Y. (2020). Liver cancer detection using hybridized fully convolutional neural network based on deep learning framework. *IEEE Access*, 8, 129889-129898.
- [10] Frid-Adar, M., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018, April). Synthetic data augmentation using GAN for improved liver lesion classification. In *2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018)* (pp. 289-293). IEEE.
- [11] Frid-Adar, M., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018, April). Synthetic data augmentation using GAN for improved liver lesion classification. In *2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018)* (pp. 289-293). IEEE.
- [12] Ghoniem, R. M. (2020). A novel bio-inspired deep learning approach for liver cancer diagnosis. *Information*, 11 (2), 80.
- [13] Hamm, C. A., Wang, C. J., Savic, L. J., Ferrante, M., Schobert, I., Schlachter, T., ... & Letzen, B. (2019). Deep learning for liver tumor diagnosis part I: development of a convolutional neural network classifier for multi-phasic MRI. *European radiology*, 29, 3338-3347.
- [14] Kakkar, P., Nagpal, S., & Nanda, N. (2018). Automatic liver segmentation in CT images using improvised techniques. In *Smart Health: International Conference, ICSH 2018, Wuhan, China, July 1-3, 2018, Proceedings 6* (pp. 41-52). Springer International Publishing.
- [15] Kavur, A. E., Kuncheva, L. I., & Selver, M. A. (2020). Basic ensembles of vanilla-style deep learning models improve liver segmentation from ct images. In *Convolutional Neural Networks for Medical Image Processing Applications* (pp. 52-74). CRC Press.
- [16] Li, C., Tan, Y., Chen, W., Luo, X., Gao, Y., Jia, X., & Wang, Z. (2020, October). Attention unet++: A nested attention-aware u-net for liver ct image segmentation. In *2020 IEEE international conference on image processing (ICIP)* (pp. 345-349). IEEE.
- [17] Li, J., Wu, Y., Shen, N., Zhang, J., Chen, E., Sun, J., ... & Zhang, Y. (2020). A fully automatic computer-aided diagnosis system for hepatocellular carcinoma using convolutional neural networks. *Biocybernetics and Biomedical Engineering*, 40 (1), 238-248.
- [18] Liu, S., Wang, M., Zheng, C., Zhong, Q., Shi, Y., & Han, X. (2020). Diagnostic value of serum glypican-3 alone and in combination with AFP as an aid in the diagnosis of liver cancer. *Clinical biochemistry*, 79, 54-60.
- [19] Liu, Z., Suo, C., Mao, X., Jiang, Y., Jin, L., Zhang, T., & Chen, X. (2020). Global incidence trends in primary liver cancer by age at diagnosis, sex, region, and etiology, 1990-2017. *Cancer*, 126 (10), 2267-2278.
- [20] Meng, L., Zhang, Q., & Bu, S. (2021). Two-stage liver and tumor segmentation algorithm based on convolutional neural network. *Diagnostics*, 11 (10), 1806.
- [21] Meng, L., Zhang, Q., & Bu, S. (2021). Two-stage liver and tumor segmentation algorithm based on convolutional neural network. *Diagnostics*, 11 (10), 1806.
- [22] Naaqvi, Z., Akbar, S., Hassan, S. A., & Ain, Q. U. (2022, May). Detection of Liver Cancer through Computed Tomography Images using Deep Convolutional Neural Networks. In *2022 2nd International Conference on Digital Futures and Transformative Technologies (ICoDT2)* (pp. 1-6). IEEE.
- [23] Nakai, H., Fujimoto, K., Yamashita, R., Sato, T., Someya, Y., Taura, K., ... & Nakamoto, Y. (2021). Convolutional neural network for classifying primary liver cancer based on triple-phase CT and tumor marker information: a pilot study. *Japanese Journal of Radiology*, 39, 690-702.
- [24] Nisa, M., Buzdar, S. A., Khan, K., & Ahmad, M. S. (2022). Deep Convolutional Neural Network Based Analysis of Liver Tissues Using Computed Tomography Images. *Symmetry*, 14 (2), 383.
- [25] Peng, J., Kang, S., Ning, Z., Deng, H., Shen, J., Xu, Y., ... & Liu, L. (2020). Residual convolutional neural network for predicting response of transarterial chemoembolization in hepatocellular carcinoma from CT imaging. *European radiology*, 30, 413-424.
- [26] Rela, M., Suryakari, N. R., & Patil, R. R. (2022). A diagnosis system by U-net and deep neural network enabled with optimal feature selection for liver tumor detection using CT images. *Multimedia Tools and Applications*, 1-43.
- [27] Sumathy, B., Dadheech, P., Jain, M., Saxena, A., Hemalatha, S., Liu, W., & Nuagah, S. J. (2022). A Liver Damage Prediction Using Partial Differential Segmentation with Improved Convolutional Neural Network. *Journal of Healthcare Engineering*, 2022.
- [28] Trivizakis, E., Manikis, G. C., Nikiiforaki, K., Drevelegas, K., Constantinides, M., Drevelegas, A., & Marias, K. (2018). Extending 2-D convolutional neural networks to 3-D for advancing deep learning cancer classification with application to MRI liver tumor differentiation. *IEEE journal of biomedical and health informatics*, 23 (3), 923-930.
- [29] Wang, C. J., Hamm, C. A., Savic, L. J., Ferrante, M., Schobert, I., Schlachter, T., ... & Letzen, B. (2019). Deep learning for liver tumor diagnosis part II: convolutional neural network interpretation using radiologic imaging features. *European radiology*, 29, 3348-3357.