

معرفی یک مدل نوین به منظور طبقه‌بندی ناهنجاری‌های کلیه مبتنی بر تکنیک‌های یادگیری عمیق و تصاویر توموگرافی کامپیوتری با رویکرد تشخیص سنگ کلیه

سید محمدجواد حسینی^{۱*}، حانیه ملک شاهی^۲

۱- کارشناسی ارشد، مهندسی پزشکی، واحد الکترونیکی، دانشگاه آزاد اسلامی، تهران، ایران

۲- کارشناسی ارشد، مهندسی پزشکی، واحد الکترونیکی، دانشگاه آزاد اسلامی، تهران، ایران

*Javadhosseini1377@yahoo.com

ارسال: بهمن ماه ۱۴۰۱ پذیرش: بهمن ماه ۱۴۰۱

چکیده

بیماری سنگ کلیه مرتباً در حال افزایش است. تشخیص این بیماری از سه راه امکان پذیر است؛ معاینه فیزیکی توسط پزشک، آزمایش‌های پاتولوژی و تصویربرداری. تصویربرداری نیز شامل اشعه ایکس، توموگرافی کامپیوتری، سونوگرافی و ام آر آی است. به دلیل اینکه تصاویر توموگرافی کامپیوتری قادرند حتی ریزترین سنگ‌ها را نمایش دهند، استفاده از این روش به شرط رعایت احتیاط‌های لازم، نتیجه مطلوبی در پی خواهد داشت. در این مطالعه با استفاده از تکنیک یادگیری عمیق به طراحی یک مدل تشخیصی و طبقه‌بندی‌کننده تصاویر توموگرافی کامپیوتری کلیه پرداخته شد. این مطالعه مبتنی بر استفاده از شبکه عمیق VGG-Net و در بستر زبان برنامه‌نویسی پایتون بود. فرآیند طراحی مطالعه شامل: جمع‌آوری داده‌ها، پیش‌پردازش تصاویر، اعمال مدل پیشنهادی، طبقه‌بندی تصاویر به چهار کلاس سالم، کیست، تومور و سنگ، آموزش و اعتبارسنجی و در نهایت تشکیل ماتریس درهم‌ریختگی بود. میزان صحت مدل پیشنهادی ۹۸ درصد و میزان دقت این مدل برای کلاس سنگ ۹۹ درصد، برای کلاس کیست ۹۹ درصد، برای کلاس سالم ۹۷ درصد و برای کلاس تومور ۹۸ درصد بود. با توجه به دقت و صحت این مدل طبقه‌بندی‌کننده، می‌توان از آن برای کمک به پزشک در تشخیص ناهنجاری کلیه به‌خصوص سنگ کلیه استفاده نمود.

کلمات کلیدی: سنگ کلیه، یادگیری عمیق، توموگرافی کامپیوتری، شبکه عصبی، ناهنجاری کلیه.

۱- مقدمه

بیماری سنگ کلیه به طور مداوم در سطح جهان در حال افزایش است [۱]. این سنگ‌ها که از کانی‌های موجود در ادرار تشکیل می‌شوند، معمولاً در کلیه شخص ایجاد شده و از طریق ادرار قابل دفع هستند [۲]. اگر اندازه یک سنگ به بیش از ۲ اینچ برسد، می‌تواند منجر به انسداد مجرای ادراری گردد [۳] که این مسئله باعث ایجاد دردهایی در قسمت پشتی بدن به خصوص کمر می‌گردد. این درد، قولنج کلیوی نام دارد و به صورت یک درد عودکننده در فواصل کوتاهی تکرار می‌شود [۴]. قولنج کلیوی اغلب با بی‌قراری، تعریق، تهوع و استفراغ همراه است [۵]. برخی از عواملی که باعث ایجاد سنگ کلیه می‌شوند عبارتند از: چاقی و کم‌تحرکی، کلسیم بالای ادرار، برخی داروها، پرکاری پاراتیروئید، کم‌آبی بدن و نفرس [۶]. نشانه بارز یک سنگ کلیه، درد ناگهانی است که از قسمت پشت بدن به پهلو و کشاله‌ی ران کشیده می‌شود [۷]. از مهمترین علائم و نشانه‌های سنگ کلیه می‌توان به سوزش ادرار [۸]، بدبو شدن ادرار [۹]، تکرر ادرار [۱۰]، قولنج کلیوی [۱۱]، خون در ادرار [۱۲]، کاهش غیرعادی حجم ادرار [۱۳] و حتی

تب و لرز [۱۴] اشاره کرد. تشخیص سنگ کلیه از سه طریق انجام می‌پذیرد؛ اول، معاینه فیزیکی توسط پزشک و تشخیص با استفاده از اطلاعات بدست آمده از شرح حال بیمار، دوم، آزمایش‌های پاتولوژی و سوم تصاویر اشعه ایکس^۱ و توموگرافی کامپیوتری^۲ و سونوگرافی^۳ و تصویربرداری تشدید مغناطیسی^۴ [۱۵]. از آنجایی که لمس سنگ‌ها در معاینه فیزیکی توسط پزشک امری بسیار دشوار است و از طرفی سنگ‌های کلسیم نسبتاً پرتوزا هستند، استفاده از تصاویر پزشکی کار تشخیص سنگ و یافتن اندازه آن را ساده‌تر می‌نماید [۱۶]. در این بین توموگرافی کامپیوتری، برای تشخیص سنگ‌های کلیه روشی مناسب به شمار می‌رود [۱۷]. چرا که می‌توان گفت تقریباً تمام سنگ‌ها در توموگرافی کامپیوتری قابل تشخیص هستند [۱۸]، به جز بقایای داروهای خاصی مانند Indinavir که در ادرار تشکیل می‌شوند [۱۹]. اگرچه سونوگرافی کلیه یک روش تقریباً بی‌خطر به خصوص در کودکان و زنان باردار به شمار می‌آید، اما نمی‌تواند به طور دائمی جایگزین تصاویر توموگرافی کامپیوتری گردد؛ چون سونوگرافی اغلب در تشخیص سنگ‌های کوچک عملکرد مطلوبی ندارد [۲۰]؛ از طرفی تصاویر اشعه ایکس نیز ممکن است در تشخیص سنگ‌های کوچک به خصوص سنگ‌های حالب ناکام باشند [۲۱]. به همین علت به نظر می‌رسد تصاویر توموگرافی کامپیوتری برای تشخیص بیماری سنگ کلیه با وجود خطرات احتمالی‌اش، گزینه مناسبی تلقی شود [۲۲]. البته استفاده از این روش در کودکان و زنان باردار توصیه نمی‌شود [۲۳]. با توجه به مطالب بیان شده، در این مطالعه به معرفی یک سیستم تشخیص دهنده سنگ کلیه با بهره‌گیری از شبکه‌های عصبی عمیق و استفاده از تصاویر توموگرافی کامپیوتری پرداخته می‌شود. سیستم مذکور پس از آموزش و یادگیری قادر خواهد بود پس از اخذ تصاویر توموگرافی کامپیوتری، آنها را در چهار کلاس کیست^۵، سنگ^۶، تومور^۷ و سالم^۸ طبقه‌بندی نموده و با این کار به پزشک در تشخیص درست ناهنجاری کلیه علی‌الخصوص سنگ کلیه یاری رساند.

۲- ادبیات و پیشینه پژوهش

Black و همکارانش [۲۴] در مطالعه‌ای که برای ارزیابی کارایی روش‌های یادگیری عمیق با هدف تشخیص خودکار ترکیب سنگ‌ها با استفاده از تصاویر دیجیتالی انجام دادند، ۶۳ سنگ کلیه را که دارای ترکیبات اسید اوریک، اگزالات کلسیم مونوهیدرات، کلسیم هیدروژن فسفات دی هیدرات و منیزیم آمونیوم فسفات هگزا هیدرات بود را مورد بررسی قرار داده و مدلی را با استفاده از شبکه عصبی ResNet-101 برای تشخیص سنگ کلیه معرفی نمودند که میزان دقت این مدل حدود ۹۶ درصد اعلام شد. در مطالعه دیگری Yildirim و همکارانش [۲۵] با استفاده از تصاویر توموگرافی کامپیوتری کلیه و با بهره‌گیری از تکنیک‌های یادگیری عمیق، سیستمی را طراحی کردند که قادر بود سنگ کلیه را دقت ۹۶٫۸۲ درصد تشخیص دهد. Elton و همکاران [۲۶] در پژوهشی که با هدف تشخیص زودهنگام و تعیین اندازه سنگ کلیه برای بهینه‌سازی درمان و پیشگیری از بیماری‌های سنگ کلیه بود، از ۹۱ تصویر کولونوگرافی با سنگ‌های کلیه علامت گذاری شده و ۸۹ تصویر کولونوگرافی بدون سنگ کلیه استفاده نموده و سپس با کمک شبکه عصبی U-Net یک مدلی طراحی کردند که توانست با دقت حدوداً ۹۵ درصد سنگ کلیه را تشخیص دهد. Ciu و همکارانش [۲۷] از تلفیق روش‌های یادگیری عمیق و آستانه، مدلی را برای تشخیص و امتیازدهی خودکار سنگ کلیه پیشنهاد دادند که این مدل دارای دقتی حدود ۹۶ درصد بود.

¹ X-ray

² Computed Tomography (CT)

³ Ultrasound

⁴ Magnetic resonance imaging (MRI)

⁵ Cyst

⁶ Stone

⁷ Tumor

⁸ Normal

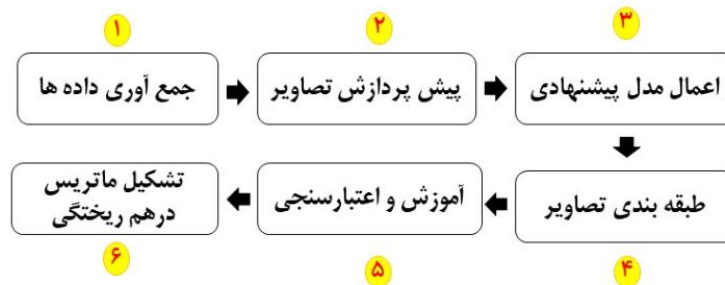
۳- مواد و روش‌ها

۳-۱- پایگاه داده

این مطالعه مبتنی بر استفاده از شبکه عصبی عمیق VGG-Net و پیاده‌سازی آن در بستر زبان برنامه نویسی پایتون است. داده‌های این مطالعه از پایگاه داده [۲۸] استخراج گردید. در این پایگاه داده، مجموعه داده‌ها از سیستم بایگانی و ارتباط تصاویر^۱ و از بیمارستان‌های مختلف در داکا و بنگلادش، جمع‌آوری شده است؛ جایی که بیماران قبلاً با داشتن تومور کلیه، کیست، یافته‌های طبیعی یا سنگ تشخیص داده شده بودند. هر دو برش تاجی و محوری از هر دو مطالعه کنتراست و بدون کنتراست با پروتکل برای کل شکم و اوروگرام انتخاب شدند. سپس مطالعه Dicom با دقت انتخاب شد. Dicom تصویربرداری دیجیتال و ارتباطات در پزشکی بوده و استاندارد بین‌المللی برای تصاویر پزشکی و اطلاعات مرتبط می‌باشد. این پلتفرم فرمت‌هایی را برای تصاویر پزشکی تعریف می‌کند که می‌توانند با داده‌ها و کیفیت لازم برای استفاده بالینی مبادله شوند. از بین آنها دسته‌ای از تصاویر Dicom از منطقه مورد نظر برای هر یافته رادیولوژیکی ایجاد گردیده است. به دنبال آن، اطلاعات و متا داده‌های هر بیمار از تصاویر Dicom حذف شده و تصاویر Dicom به فرمت تصویر jpg تبدیل شده است. پس از تبدیل، هر یافته تصویر مجدداً توسط یک رادیولوژیست و یک تکنسین پزشکی تأیید شد. جدول ۱ اطلاعات مربوط به این پایگاه داده و شکل ۱ فلوجارت طراحی مطالعه حاضر را نمایش می‌دهد. شکل ۲ نیز نمونه‌ای از تصاویر این پایگاه داده را در کلاس‌های تومور، سالم، کیست و سنگ نشان می‌دهد.

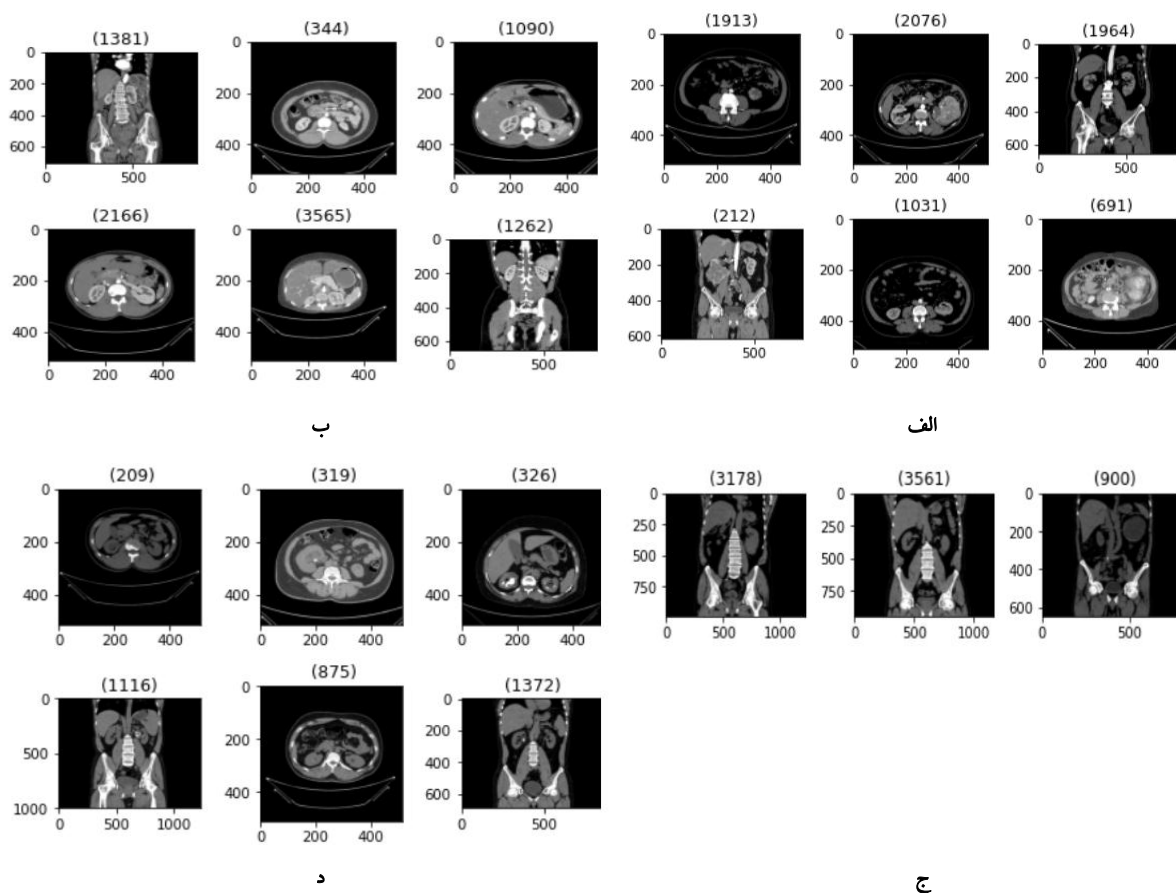
جدول ۱- مشخصات پایگاه داده

ردیف	کلاس	تعداد تصاویر
۱	کیست	۳۰۷۰۹
۲	سالم	۵۰۷۷
۳	سنگ	۱۰۳۷۷
۴	تومور	۲۰۲۸۳
۵	مجموع	۱۲۰۴۴۶



شکل ۱- فلوجارت طراحی مطالعه


¹ Picture Archiving and Communication System (PACS)



شکل ۲- نمونه‌ای از تصاویر توموگرافی کامپیوتری در کلاس (الف) تومور، (ب) سالم، (ج) کیست و (د) سنگ

۳-۲- مدل VGG-Net

VGG-Net که یک شبکه عصبی کانولوشنال از پیش آموزش دیده به شمار می‌رود، قادر است ویژگی‌هایی را از تصاویر استخراج کرده و در کلاس‌هایی مجزا، طبقه بندی نماید. این شبکه می‌تواند ۱۶ یا ۱۹ لایه داشته باشد [۲۹]. در این مطالعه، VGG-Net، ۱۶ لایه وزنی برای تشخیص اشیا دارد. این شبکه ورودی تصاویر با وضوح 224×224 را گرفته و آن‌ها را از میان لایه‌های کانولوشن با اندازه فیلتر ثابت 3×3 و گام ۱ عبور می‌دهد. پس از دسته‌بندی لایه‌های کانولوشن، ۳ لایه کاملاً به هم متصل می‌شوند که به ترتیب دارای 4096 ، 4096 و 1000 کانال هستند. آخرین لایه، لایه Soft-Max است [۳۰]. شکل ۳ معماری یک شبکه VGG-Net را نشان می‌دهد.



شکل ۳- معماری شبکه VGG-Net

۳-۳- ساختار یک شبکه VGG-Net

- لایه‌های کانولوشنال اول و دوم از ۶۴ فیلتر هسته ویزگی تشکیل شده و اندازه فیلتر 3×3 است. با عبور تصویر ورودی به لایه کانولوشن اول و دوم، ابعاد به $64 \times 64 \times 224$ تغییر می‌کند؛ سپس خروجی به دست آمده با گام ۲ به لایه حداکثر جمع آوری می‌شود.
- لایه‌های کانولوشنال سوم و چهارم از ۱۲۴ فیلتر کرنل ویزگی ساخته شده و اندازه فیلتر 3×3 است. پس از این دو لایه، یک لایه ادغام حداکثر با گام ۲ ایجاد می‌شود و خروجی به ابعاد $128 \times 128 \times 56$ کاهش می‌یابد.
- لایه‌های پنجم، ششم و هفتم لایه‌های کانولوشن با اندازه هسته 3×3 هستند. هر سه از ۲۵۶ نقشه ویزگی استفاده می‌کنند. این لایه‌ها با یک لایه حداکثر با گام ۲ دنبال می‌شوند.
- لایه‌های هشتم تا سیزدهم دو مجموعه لایه کانولوشن با اندازه هسته 3×3 بوده و همه این مجموعه لایه‌های کانولوشن دارای ۵۱۲ فیلتر هسته هستند. این لایه‌ها با حداکثر لایه جمع آوری با گام ۱ دنبال می‌شوند.
- لایه‌های چهاردهم و پانزدهم لایه‌های پنهان کاملاً متصل از ۴۰۹۶ واحد بوده و به دنبال آن یک لایه خروجی Soft-Max (لایه شانزدهم) ۱۰۰۰ واحدی قرار دارد.

۳-۴- فرآیند پیاده‌سازی مدل پیشنهادی

پیاده‌سازی مدل پیشنهادی در شش مرحله انجام می‌پذیرد:

- مرحله اول: اخذ تصاویر توموگرافی کامپیوتری از پایگاه داده مذکور
- مرحله دوم: پیش پردازش تصاویر؛ یعنی تغییر دادن قالب تصویر، حذف کردن نویزها، یکسان کردن دقت تصاویر در تمامی ابعاد موجود، بهبود کیفیت تصاویر، کاهش بعد تصاویر و در نهایت حذف کردن مناطق غیر کلیوی از تصاویر
- مرحله سوم: اعمال مدل پیشنهادی VGG-Net به سیستم
- مرحله چهارم: طبقه بندی تصاویر در چهار کلاس سالم، تومور، کیست و سنگ
- مرحله پنجم: آموزش^۱ و اعتبار سنجی^۲ مدل پیشنهادی
- مرحله ششم: تشکیل ماتریس درهم‌ریختگی و ارزیابی داده‌های بدست آمده

۴- نتایج و بحث

پس از پیاده‌سازی مدل پیشنهادی، ارزیابی و تحلیل نتایج و بحث در مورد آنها انجام گردید.

۴-۱- ارزیابی مدل

ارزیابی این مدل با استفاده از ماتریس درهم‌ریختگی و پارامترهای صحت، دقت، بازیابی و امتیاز F1 صورت می‌پذیرد. ماتریس درهم‌ریختگی دارای چهار پارامتر است: مثبت واقعی^۳، منفی واقعی^۴، مثبت کاذب^۵ و منفی کاذب^۶. این پارامترها را می‌توان این گونه تعریف نمود:

- مثبت واقعی (TP): تعداد ویزگی‌های درستی که به طور صحیح و درست تشخیص داده شده‌اند.
- منفی واقعی (TN): تعداد ویزگی‌های نادرستی که به طور صحیح و درست تشخیص داده شده‌اند.
- مثبت کاذب (FP): تعداد ویزگی‌های درستی که اشتبهاً به طور ناصحیح و نادرست تشخیص داده شده‌اند.

¹ Training

² Validation

³ True Positive (TP)

⁴ True Negative (TN)

⁵ False Positive (FP)

⁶ False Negative (FN)

• منفی کاذب (FN): تعداد ویژگی‌های نادرستی که اشتهاً به طور صحیح و درست تشخیص داده شده‌اند.
از این پارامترها، چهار المان صحت^۱، دقت^۲، بازیابی^۳ و امتیاز F1^۴ حاصل می‌گردد که از این قرار هستند: صحت یک مدل از رابطه ۱ بدست می‌آید:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

دقت یک مدل نیز بر رابطه ۲ استوار است:

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

میزان بازیابی یک مدل از رابطه ۳ حاصل می‌شود:

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

امتیاز F1 نیز مبتنی بر رابطه ۴ است:


$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

صحت مدل پیشنهادی ۰.۹۸ بدست آمد. جدول ۲- میزان دقت، بازیابی، امتیاز F1 و میانگین کلان و وزنی مدل پیشنهاد شده را نمایش می‌دهد.

جدول ۲- میزان دقت، بازیابی، امتیاز F1 و میانگین کلان و وزنی مدل پیشنهادی

ردیف	پارامتر	دقت	بازیابی	امتیاز F1
۱	کلاس سالم	۰.۹۷	۰.۹۹	۰.۹۷
۲	کلاس تومور	۰.۹۸	۰.۹۳	۰.۹۵
۳	کلاس کیست	۰.۹۹	۰.۹۸	۰.۹۸
۴	کلاس سنگ	۰.۹۹	۰.۹۶	۰.۹۸
۵	میانگین کلان	۰.۹۹	۰.۹۷	۰.۹۸
۶	میانگین وزنی	۰.۹۸	۰.۹۸	۰.۹۸

شکل ۴ میزان صحت و خطای آموزش و اعتبارسنجی را پس از اعمال مدل پیشنهادی نشان می‌دهد.



شکل ۴- شکل راست میزان خطای آموزش (آبی رنگ) و خطای اعتبارسنجی (نارنجی)؛ شکل چپ میزان صحت آموزش (آبی) و صحت اعتبارسنجی (نارنجی) پس از پیاده سازی مدل پیشنهادی

شکل ۵ ماتریس درهم ریختگی^۵ مدل پیشنهادی را نشان می‌دهد.

¹ Accuracy
² Precision
³ Recall
⁴ F1-Score
⁵ Confusion Matrix

Actual	Cyst	371	0	0	1
	Normal	0	509	0	0
	Stone	4	2	133	0
	Tumor	0	16	0	213
		Cyst	Normal	Stone	Tumor
		Predicted			

شکل ۵- ماتریس درهم‌ریختگی

۴-۲- بحث

بیماری سنگ کلیه به طور مرتب در تمام نقاط جهان در حال افزایش است. سنگ‌های کلیه رسوبات معدنی در کالیس‌ها و لگن کلیه هستند که به صورت آزاد یا چسبیده به پایلای کلیه یافت می‌شوند. آنها حاوی اجزای کریستالی و آلی هستند و زمانی تشکیل می‌شوند که ادرار نسبت به یک ماده معدنی فوق اشباع شود. اگزالات کلسیم ماده اصلی تشکیل دهنده بیشتر سنگ‌ها است که بسیاری از آنها بر روی پایه‌ای از فسفات کلسیم به نام پلاک‌های راندال تشکیل می‌شوند که در سطح پایلاری کلیه وجود دارد [۳۱]. چاقی، دیابت، فشار خون بالا و سندرم متابولیک از عوامل خطر تشکیل سنگ هستند که به نوبه خود می‌توانند منجر به فشارخون بالا و بیماری مزمن کلیوی نیز شوند. پیشگیری از عود نیاز به مداخلات رفتاری و تغذیه‌ای و همچنین درمان‌های دارویی خاص برای نوع سنگ دارد. نیاز زیادی به پیشگیری از عود وجود دارد که مستلزم درک بهتر مکانیسم‌های دخیل در تشکیل سنگ برای تسهیل ساخت داروهای مؤثرتر است [۳۲]. در این بین تشخیص درست و دقیق نوع ناهنجاری کلیه اهمیت بسیاری دارد، چرا که دستیابی به یک درمان دقیق، مستلزم یک تشخیص دقیق است. تصاویر توموگرافی کامپیوتری به دلیل اینکه قادرند انواع ناهنجاری‌های کلیه را با دقت بالایی تشخیص دهند، همواره یکی از روش‌های پر استفاده در این زمینه تلقی می‌شوند. به همین علت تلفیق این سیستم تصویربرداری با هوش مصنوعی و تکنیک‌های یادگیری عمیق، می‌تواند میزان دقت و صحت تشخیص را به مراتب افزایش دهد.

۵- نتیجه‌گیری

در این پژوهش یک سیستم طبقه‌بندی کننده تصاویر توموگرافی کامپیوتری کلیه با بهره‌گیری از تکنیک‌های یادگیری عمیق، زبان برنامه‌نویسی پایتون و معماری VGG-Net، برای تشخیص ناهنجاری‌های کلیه معرفی گردید. این مدل، تصاویر ورودی اخذ کرده و آن‌ها را در چهار کلاس تومور، سالم، کیست و سنگ طبقه‌بندی نمود. میزان صحت مدل پیشنهادی ۹۸ درصد و میزان دقت آن برای طبقه‌بندی کلاس سنگ ۹۹ درصد، برای کلاس کیست ۹۹ درصد، برای کلاس سالم ۹۷ درصد و برای کلاس تومور ۹۸ درصد بود. با توجه به دقت و صحت این مدل طبقه‌بندی کننده، می‌توان از آن برای کمک به پزشک در تشخیص ناهنجاری‌های کلیه علی‌الخصوص سنگ کلیه استفاده نمود.

۶- قدردانی

نویسندگان از تمام کسانی که به هر نحوی در انجام این مطالعه یاری رساندند، تشکر می‌کنند.

۷- نقش نویسندگان

همه نویسندگان در نگارش اولیه مقاله یا بازنگری آن سهیم بودند و همه با تایید نهایی مقاله حاضر، مسئولیت دقت و صحت مطالب مندرج در آن را می‌پذیرند.

۸- تضاد منافع

نویسندگان تصریح می‌کنند که هیچ‌گونه تضاد منافی در مطالعه حاضر وجود ندارد.

۹- مراجع

- Gharaibeh, M., Alzu'bi, D., Abdullah, M., Hmeidi, I., Al Nasar, M. R., Abualigah, L., & Gandomi, A. H. (2022). Radiology imaging scans for early diagnosis of kidney tumors: a review of data analytics-based machine learning and deep learning approaches. *Big Data and Cognitive Computing*, 6(1), 29.
- Altini, N., Prencipe, B., Casciarano, G. D., Brunetti, A., Brunetti, G., Triggiani, V., ... & Bevilacqua, V. (2022). Liver, kidney and spleen segmentation from CT scans and MRI with deep learning: A survey. *Neurocomputing*, 490, 30-53.
- Ma, F., Sun, T., Liu, L., & Jing, H. (2020). Detection and diagnosis of chronic kidney disease using deep learning-based heterogeneous modified artificial neural network. *Future Generation Computer Systems*, 111, 17-26.
- Caglayan, A., Horsanali, M. O., Kocadurdu, K., Ismailoglu, E., & Guneyli, S. (2022). Deep learning model-assisted detection of kidney stones on computed tomography. *International braz j urol*, 48, 830-839.
- Alzu'bi, D., Abdullah, M., Hmeidi, I., AlAzab, R., Gharaibeh, M., El-Heis, M., ... & Abualigah, L. (2022). Kidney Tumor Detection and Classification Based on Deep Learning Approaches: A New Dataset in CT Scans. *Journal of Healthcare Engineering*, 2022.
- da Cruz, L. B., Araujo, J. D. L., Ferreira, J. L., Diniz, J. O. B., Silva, A. C., de Almeida, J. D. S., ... & Gattass, M. (2020). Kidney segmentation from computed tomography images using deep neural network. *Computers in Biology and Medicine*, 123, 103906.
- Corbat, L., Henriot, J., Chaussy, Y., & Lapayre, J. C. (2020). Fusion of multiple segmentations of medical images using OV2ASSION and Deep Learning methods: Application to CT-Scans for tumoral kidney. *Computers in Biology and Medicine*, 124, 103928.
- Steuwe, A., Valentin, B., Bethge, O. T., Ljimani, A., Niegisch, G., Antoch, G., & Aissa, J. (2022). Influence of a deep learning noise reduction on the CT values, image noise and characterization of kidney and ureter stones. *Diagnostics*, 12(7), 1627.
- Coe, F. L., Evan, A., & Worcester, E. (2005). Kidney stone disease. *The Journal of clinical investigation*, 115(10), 2598-2608.
- Alelign, T., & Petros, B. (2018). Kidney stone disease: an update on current concepts. *Advances in urology*, 2018.
- Brisbane, W., Bailey, M. R., & Sorensen, M. D. (2016). An overview of kidney stone imaging techniques. *Nature Reviews Urology*, 13(11), 654-662.
- Cloutier, J., Villa, L., Traxer, O., & Daudon, M. (2015). Kidney stone analysis: "Give me your stone, I will tell you who you are!". *World journal of urology*, 33, 157-169.
- Parmar, M. S. (2004). Kidney stones. *Bmj*, 328(7453), 1420-1424.
- Khan, S. R., Pearle, M. S., Robertson, W. G., Gambaro, G., Canales, B. K., Doizi, S., ... & Tiselius, H. G. (2016). Kidney stones. *Nature reviews Disease primers*, 2(1), 1-23.
- Affan, A., & Hussain, S. (2023). Detecting multi-class kidney abnormalities using Deep learning. In *2023 17th International Conference on Ubiquitous Information Management and Communication (IMCOM)* (pp. 1-7). IEEE.
- Yoodee, S., & Thongboonkerd, V. (2023). Bioinformatics and computational analyses of kidney stone modulatory proteins lead to solid experimental evidence and therapeutic potential. *Biomedicine & Pharmacotherapy*, 159, 114217.
- Siener, R., & Metzner, C. (2023). Dietary weight loss strategies for kidney stone patients. *World Journal of Urology*, 1-8.

18. Shtukenberg, A. G., Hu, L., Sahota, A., Kahr, B., & Ward, M. D. (2022). Disrupting crystal growth through molecular recognition: designer therapies for kidney stone prevention. *Accounts of Chemical Research*, 55(4), 516-525.
19. Li, Q., Lv, H., Chen, Y., Shen, J., Shi, J., & Zhou, C. (2023). Development and Validation of a Machine Learning Predictive Model for Cardiac Surgery-Associated Acute Kidney Injury. *Journal of Clinical Medicine*, 12(3), 1166.
20. Khalal, D. M., Azizi, H., & Maalej, N. (2023). Automatic segmentation of kidneys in computed tomography images using U-Net. *Cancer/Radiothérapie*.
21. Geethanjali, T. M., & Dinesh, M. S. (2023, January). Semantic Segmentation of Kidney and Tumors Using LinkNet Models. In *Cognition and Recognition: 8th International Conference, ICCR 2021, Mandya, India, December 30–31, 2021, Revised Selected Papers* (pp. 380-389). Cham: Springer Nature Switzerland.
22. Luo, X. Q., Kang, Y. X., Duan, S. B., Yan, P., Song, G. B., Zhang, N. Y., ... & Zhang, H. (2023). Machine Learning-Based Prediction of Acute Kidney Injury Following Pediatric Cardiac Surgery: Model Development and Validation Study. *Journal of Medical Internet Research*, 25, e41142.
23. Zhang, L., Sun, K., Shi, L., Qiu, J., Wang, X., & Wang, S. (2023). Ultrasound Image-Based Deep Features and Radiomics for the Discrimination of Small Fat-Poor Angiomyolipoma and Small Renal Cell Carcinoma. *Ultrasound in Medicine & Biology*, 49(2), 560-568.
24. Black, K. M., Law, H., Aldoukhi, A., Deng, J., & Ghani, K. R. (2020). Deep learning computer vision algorithm for detecting kidney stone composition. *BJU international*, 125(6), 920-924.
25. Yildirim, K., Bozdag, P. G., Talo, M., Yildirim, O., Karabatak, M., & Acharya, U. R. (2021). Deep learning model for automated kidney stone detection using coronal CT images. *Computers in biology and medicine*, 135, 104569.
26. Elton, D. C., Turkbey, E. B., Pickhardt, P. J., & Summers, R. M. (2022). A deep learning system for automated kidney stone detection and volumetric segmentation on noncontrast CT scans. *Medical Physics*, 49(4), 2545-2554.
27. Cui, Y., Sun, Z., Ma, S., Liu, W., Wang, X., Zhang, X., & Wang, X. (2021). Automatic detection and scoring of kidney stones on noncontrast CT images using STONE nephrolithometry: combined deep learning and thresholding methods. *Molecular Imaging and Biology*, 23, 436-445.
28. <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>
29. Alippi, C., Disabato, S., & Roveri, M. (2018, April). Moving convolutional neural networks to embedded systems: the alexnet and VGG-16 case. In *2018 17th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN)* (pp. 212-223). IEEE.
30. Hong, D., Zheng, Y. Y., Xin, Y., Sun, L., Yang, H., Lin, M. Y., ... & Wang, S. S. (2021). Genetic syndromes screening by facial recognition technology: VGG-16 screening model construction and evaluation. *Orphanet Journal of Rare Diseases*, 16(1), 1-8.
31. Thongprayoon, C., Krambeck, A. E., & Rule, A. D. (2020). Determining the true burden of kidney stone disease. *Nature Reviews Nephrology*, 16(12), 736-746.
32. Coe, F., Worcester, E. M., Lingeman, J. E., & Evan, A. P. (2019). *Kidney stones: medical and surgical management*. Jaypee Brothers Medical Publishers.