



بررسی عملکرد تشخیصی سی تی- آنژیوگرافی جهت ارزیابی درصد تنگی عروق کرونر در مقایسه با آنژیوگرافی تهاجمی مبتنی بر پردازش تصاویر و یادگیری ماشین

شناختنامه طرح

	کد رهگیری طرح
	تاریخ تصویب پیش پروپوزال
بررسی عملکرد تشخیصی سی تی- آنژیوگرافی جهت ارزیابی درصد تنگی عروق کرونر در مقایسه با آنژیوگرافی تهاجمی مبتنی بر پردازش تصاویر و یادگیری ماشین	عنوان طرح
stenosis assessment in CCTA using angiography via image processing and machine learning approaches	عنوان لاتین طرح
09121973266	تلفن
bitarafan@hotmail.com	پست الکترونیکی
Cross-sectional-	نوع مطالعه
1401/12/24	تاریخ شروع
1402/12/28	تاریخ خاتمه
خبر	آیا طرح چند مرکزی است؟
	مرکز/مراکز دیگر
	نام سازمان تصویب کننده اولیه پروپوزال
	محل اجرای طرح
بیمارستان قلب شهید رجایی	محل اجرای طرح
بیمارستان قلب شهید رجایی	سازمان مجری
	سازمان مجری
سایر	دانشکده/ محل خدمت
فیزیک پزشکی	رشته تخصصی
	توضیحات
	نوع طرح ها

مجری همکاران

نام و نام خانوادگی	سمت در طرح	نوع همکاری	توضیحات
احمد بیطرفان رجبی	مجری و نویسنده مقاله	نظرارت بر اجرای طرح	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
علی محمد زاده کوه پاره	مجری اصلی / نویسنده مقاله	نظرارت بر اجرای طرح	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
محمد جواد عالم زاده انصاری	مجری و نویسنده مقاله	نظرارت بر اجرای طرح	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
مبین محبی	همکار طرح و نویسنده مقاله	سایر	- انجام کار ماشین لرنینگ : کلاس بندی و سگمنتیشن - دانشگاه تربیت مدرس
عرفان برزگر گلمغانی	همکار طرح و نویسنده مقاله	سایر	- انجام کار ماشین لرنینگ : پردازش تصویر و کلاس بندی - دانشگاه تربیت مدرس
امیر عظیمی	همکار طرح و نویسنده مقاله	سایر	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
کلانز هوشمند	همکار طرح	سایر	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
سیده مرضیه عمامی حائری	همکار طرح	سایر	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
کیانوش کسانی	همکار طرح	سایر	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
سید حسن فاتحی فیض آباد	همکار طرح	سایر	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
مرضیه تقی زاده	همکار طرح	سایر	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
احسان خلیلی پور	همکار طرح	سایر	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
محمد اکبرنژاد بایی	همکار طرح	جمع آوری نمونه ها	مرکز آموزشی تحقیقاتی و درمانی قلب و عروق شهید رجایی
عارفه قربانی	همکار طرح	سایر	
پرham صادقی پور	ناظر	نظرارت بر اجرای طرح	
حمدیرضا پورعلی اکبر	مجری و نویسنده مقاله	نظرارت بر اجرای طرح	

دانشده/مرکز مربوطه

نوع ارتباط با مرکز	رد
وارد کننده	مرکز تحقیقات مداخلات قلبی و عروقی

اطلاعات تفصیلی

آیتم ها	متن
بیان مسئله	یکی از اولین علل مرگ و میر در دنیا بیماری های قلبی عروقی میباشد. حدوداً سه چهارم از مرگ و میرهای ناشی از بیماری های قلبی-عروقی در کشورهایی با سطح اقتصادی

متوسط یا پایین اتفاق می افتد. بیشتر بیماری های قلبی عروقی قابل پیشگیری اند و با توجه به عوامل خطرناکی مانند مصرف دخانیات، چاقی و اضافه وزن، رژیم غذایی نامناسب، مصرف الکل و بی تحرکی می توان میزان مرگ و میر ناشی از این بیماری ها را با توجه به این عوامل کاهش داد. بیماری های قلبی عروقی یکی از تهدیدکننده ترین بیماری ها در سطح جهان و بیشترین علت مرگ و میر است [1]. بیماری عروق کرونری یکی از دلایل اولیه مربوط به بیماری های قلبی عروقی است [2]. برآورد سالانه بیش از 650.000 مورد جدید از نارسایی قلبی را نشان می دهد و تقریباً نیمی از این موارد با اختلال عملکرد بطن چپ اتفاق می افتد. در بیش از دو سوم بیماران مبتلا به اختلال عملکرد بطن چپ، بیماری عروق کرونری علت اصلی است [3]. انتظار می رود نرخ مرگ و میر بیماری عروق کرونری در کشورهای در حال توسعه افزایش یابد [2].

امروزه به طور گسترش دهنده سی تی آنژیوگرافی عروق کرونر به عنوان روش دیگر برای ارزیابی تنگی عروق کرونر مورد استفاده قرار می گیرد [4]. آنژیوگرافی تهاجمی و سی تی آنژیوگرافی هر دو روش هایی دقیق برای بررسی عروق کرونری هستند. زمانی که صرف آنژیوگرافی تهاجمی می شود چندین ساعت بیش از سی تی آنژیوگرافی است. روش سی تی آنژیو به اندازه آنژیوگرافی تهاجمی دقیق نیست. اگر احیاناً سی تی آنژیوگرافی تنگی یک رگ را نشان دهد این تنگی حتماً باید با آنژیوگرافی تهاجمی تایید شود.

تصاویر رادیولوژی حاوی حجم عظیمی از اطلاعات هستند که هر واحد تصویری (وکسل یا پیکسل) خواص مرتبط با بافت را نشان میدهد. تکنیک های تحلیل تصویر فعلی بیشتر به ارزیابی بصری کیفی تصاویر و اقدامات کمی خام ساختار قلبی و عملکردی وابسته هستند. به منظور بهینه سازی مقدار تشخیصی تصویربرداری قلبی، به تکنیک های پیشرفته تر تجزیه و تحلیل تصویر نیاز است که امکان سنجش عمیق تر فنوتیپ های تصویربرداری را فراهم می آورد. با این حال، با پیشرفت داده های بزرگ و یادگیری ماشین، فرصت های جدیدی برای ساخت ابزارهای هوش مصنوعی به وجود آمده که به طور مستقیم به پزشک در تشخیص بیماری های قلبی عروقی کمک خواهد کرد. رویکرد های یادگیری ماشین [1] با تشخیص مبتنی بر تصویر، به الگوریتم ها و مدل هایی که از مثال های بالینی گذشته از طریق شناسایی الگوهای تصویربرداری پنهان و پیچیده آموزش داده می شوند، متکی هستند. در حقیقت، یادگیری ماشین امکان مدیریت کارآمد حجم زیادی از داده ها را فراهم می کند.

یکی از دلایل نارسایی های قلبی ، بیماری های عروق کرونری می باشد که هر ساله به شمار افراد مبتلا به بیماری های عروق کرونری افزوده می شود . از شایع ترین بیماری های عروق کرونری انسداد یا گرفتگی عروق کرونری است که مانع رسیدن خون به عضلات قلب جهت انقباض عضلات برای پمپاز خون به تمام بدن می شود . برای تشخیص میزان درصد تنگی عروق کرونر عموماً از روش آنژیوگرافی تهاجمی که استاندارد طلایی^[1] است ، استفاده می شود. اما با توجه به ملاحظاتی و مشکلاتی که این روش تهاجمی دارد نیاز به یک روش غیر تهاجمی با میزان تشخیص بالا احساس می شود. از جمله مشکلاتی که پروسیجر آنژیوگرافی می تواند ایجاد کند ، به خونریزی های ناگهانی ، ایست قلبی ، سکته ، آسیب به عروق ، حساسیت به مواد کنتراست زا ، عفونت و همچنین محدودیت در دوز مواد حاجب، ریسک میکروبی شدن و نیز تولید ترومبوز در هنگام عبور کاتر، ریسک بروز شوک، دوز نسبتاً بالای پرتو ایکس برای بیمار، کاردیولوژیست، پرتوکاران و پرستاران می توان اشاره نمود. بعلاوه اینکه در برخی از بیماران با شرایط خاص انجام این پروسیجر ریسک زیادی را با خود به همراه دارد.

در این طرح برآئیم تا با استفاده از پارامتر هایی که از داخل تصاویر سی تی -آنژیوگرافی استخراج می شود و انجام روش های یادگیری ماشین بتوان تخمین دقیقی از میزان درصد گرفتگی عروق کرونر داشته باشیم. برای انجام این کار از تصاویر سی تی -آنژیوگرافی و نتایج حاصل از پروسیجر تهاجمی آنژیوگرافی استفاده خواهد شد تا پیش بینی دقیقی از درصد گرفتگی حاصل شود.

در حقیقت درصد گرفتگی عروق با استفاده از سی تی آنژیوگرافی با استفاده از ویژگی های رادیومیکس تا کنون در مطالعات انجام نشده است و به همین ترتیب در این طرح استفاده از ویژگی های رادیومیکس و اهمیت آنها در پیش بینی درصد تنگی عروق مد نظر است تا پزشکان بتوانند بدون استفاده از روش های تهاجمی از درصد دقیق گرفتگی برای اتخاذ تصمیم بهره ببرند.

Gold standard [1]

در مطالعه ای که در سال ۲۰۱۹ توسط Nils Hampe و همکاران به صورت مروری انجام شد این نتایج حاصل شد که توموگرافی کامپیوتری قلب به اجازه تجسم سریع قلب و عروق کرونر با وضوح فضایی بالا را می دهد. با

این حال، تجزیه و تحلیل سی تی اسکن قلب برای تظاهرات بیماری عروق کرونر زمان بر و چالش برانگیز است. رویکردهای یادگیری ماشین (ML) پتانسیل مقابله با این چالش‌ها را با دقت بالا و عملکرد ثابت دارند. در حالی که ML برای سال‌ها پایه اصلی تجزیه و تحلیل تصویر قلبی بوده است، ظهور اخیر یادگیری عمیق پیشرفت را در این زمینه تسريع کرده است. یادگیری ماشینی این پتانسیل را دارد که پزشکان را از وظایف وقت گیر رها کند و رویه‌های تشخیصی را تغییر دهد و در نتیجه هزینه‌های مراقبت‌های بهداشتی را کاهش دهد. علاوه بر این، تجزیه و تحلیل مبتنی بر ML کم هزینه می‌تواند به عنوان یک هدف ثانویه به مطالعات غربالگری اضافه شود.[10]

در مطالعه‌ای که در سال ۲۰۲۰ توسط Majd Zreik و همکاران به صورت گذشته نگر انجام شد اسکن cardiac CT angiography

۱۸۷ بیمار را جمع آوری شد، ۱۳۷ نفر از آنها تحت اندازه گیری fractional flow reserve (FFR). این اندازه گیری‌های FFR به عنوان یک استاندارد مرجع برای اهمیت عملکردی تنگی کرونری عمل می‌کند. خطوط مرکزی شریان‌های کرونر استخراج شد و برای بازسازی حجم‌های اصلاح شده چند صفحه‌ای (MPR) استفاده شد. برای شناسایی خودکار شریان‌های دارای تنگی قابل توجه عملکردی که نیاز به آنژیوگرافی تهاجمی دارند، هر حجم MPR در تعداد ثابتی از رمزگذاری‌ها با استفاده از دو رمزگذار خودکار کانولوشنال سه بعدی و ۱ بعدی که به ترتیب کدگذاری فضایی و متوالی را انجام می‌دهند، کدگذاری شد. تشخیص عروق کرونر نیازمند به ارزیابی تهاجمی، که با استفاده از آزمایش‌های اعتبار متقابل مکرر ارزیابی شد، منجر به ایجاد ناحیه‌ای در زیر منحنی مشخصه عملکرد گیرنده 0.81 ± 0.02 در سطح شریان و 0.87 ± 0.02 در سطح بیمار شد. نتایج نشان دهنده امکان تشخیص خودکار غیرتهاجمی بیمارانی است که نیاز به آنژیوگرافی تهاجمی و احتمالاً مداخله عروق کرونر دارند. در نهایت این نتیجه حاصل شد که به طور بالقوه این روش می‌تواند تعداد بیمارانی را که به طور غیر ضروری تحت ICA قرار می‌گیرند کاهش دهد.[11]

در مطالعه‌ای که در سال ۲۰۲۱ توسط Viacheslav V. Danilov و همکاران

با هدف بررسی امکان تشخیص تنگی عروق کرونر با استفاده از روش‌های یادگیری عمیق انجام شد برای رسیدن به این هدف، هشت آشکارساز با متد های عملکردی مختلف (MobileNet، ResNet-50، ResNet-101، Inception ResNet، NASNet آژیوگرافی بالینی 100 بیمار به این روش‌ها مورد ارزیابی قرار گرفت. سه شبکه عصبی نتایج بهتری را نشان داده‌اند. شبکه مبتنی بر Inception ResNet V2 دقیق‌ترین است و به میانگین دقت 0.95، امتیاز F1 0.96 و پایین‌ترین نرخ پیش‌بینی 3 فریم در ثانیه در زیر مجموعه اعتبارسنجی دست یافت. شبکه SSD MobileNet V2 به عنوان سریع‌ترین شبکه با mAP کم 0.83، امتیاز F1 0.80 و میانگین نرخ پیش‌بینی 38 فریم بر ثانیه ثبت کرد. مدل مبتنی بر RFCN ResNet-101 V2 نسبت دقت به سرعت بهینه‌ای را نشان داد. mAP آن 0.94، امتیاز F1 0.96 است در حالی که سرعت پیش‌بینی آن 10 فریم در ثانیه است. تعادل عملکرد-دققت امکان تشخیص تنگی عروق کرونر را تایید کرده است که از فرآیند تصمیم‌گیری تیم قلب در تفسیر یافته‌های آژیوگرافی کرونر پشتیبانی می‌کند.

[12]

در مطالعه‌ای که در سال ۲۰۱۸ توسط Robbert W van Hamersveld و همکاران به منظور ارزیابی ارزش افزوده تجزیه و تحلیل یادگیری عمیق میوکارد بطن چپ در سی تی آژیوگرافی عروق کرونر در حالت استراحت برای تعیین درجه تنگی عروق کرونر (DS) انجام شد. بیمارانی که قبل از اندازه گیری ذخیره جریان کسری تهاجمی (FFR) تحت CT آژیوگرافی کرونری قرار گرفتند به صورت گذشته نگر انتخاب شدند. بالاترین میزان تنگی از CT آژیوگرافی کرونری برای طبقه بندی بیماران به عنوان دارای تنگی غیر قابل توجه ($\geq 24\%$ DS)، متوسط (25–69% DS)، یا تنگی قابل توجه ($\leq 70\%$ DS) استفاده شد. بیماران مبتلا به تنگی متوسط برای آنالیز یادگیری عمیق تمام اتوماتیک LVM ارجاع داده شدند. این الگوریتم را مشخص می‌کند و اطلاعات مربوط به شکل، بافت، افزایش کنتراست و موارد دیگر را رمزگذاری می‌کند. بر اساس این کدگذاری‌ها، ویژگی‌ها استخراج شد و بیماران به عنوان تنگی غیر قابل توجه یا قابل توجه طبقه بندی

شند. عملکرد تشخیصی روش ترکیبی مورد ارزیابی قرار گرفت. تنگی عملکردی قابل توجه به عنوان $0.8 \leq FFR$ یا وجود تنگی با درجه بالا آنژیوگرافی ($\leq 90\%$ DS) تعریف شد.. روش پیشنهادی منجر به بهبود تعیین در مقایسه با طبقه بندی فقط بر اساس میزان تنگی شد. در نتیجه ترکیب میزان تنگی با تجزیه و تحلیل یادگیری عمیق LVM در تنگی عروق کرونر درجه متوسط ممکن است منجر به بهبود عملکرد تشخیصی برای شناسایی بیماران مبتلا به تنگی عروق کرونر از نظر عملکردی شود. [13]

در مطالعه ای که در سال ۲۰۱۹ توسط Philipp L von Knebel Doeberitz مشتق از سی تی آنژیوگرافی کرونر (cCTA) با ذخیره جریان کسری مبتنی بر یادگیری ماشین عمیق (CT-FFR) برای شناسایی ایسکمی با استفاده از FFR تهاجمی به عنوان استاندارد مرجع انجام شد. هشتاد و چهار بیمار که تحت cCTA و به دنبال آن FFR تهاجمی قرار گرفته بودند، در این مطالعه گذشته نگر تک مرکزی قرار گرفتند. نشانگرهای پلاک مختلفی از cCTA با استفاده از یک نمونه اولیه نرم افزار نیمه خودکار و CT-FFR مبتنی بر یادگیری ماشین عمیق استخراج شدند. ارزش تمایز نشانگرهای پلاک و CT-FFR برای شناسایی ایسکمی ضایعه خاص بر اساس هر رگ با استفاده از FFR تهاجمی به عنوان استاندارد مرجع ارزیابی شد. صد و سه عروق حاوی ضایعه مورد بررسی قرار گرفتند. ۳۲ ضایعات از نظر همودینامیک با FFR تهاجمی قابل توجه بودند. در یک تجزیه و تحلیل چند متغیره، نشانگرهای زیر ارزش پیش بینی کننده ایسکمی خاص ضایعه را نشان دادند: طول ضایعه، حجم پلاک غیر کلسیفیه و CT-FFR. تجزیه و تحلیل ویژگی های عملیاتی گیرنده، مزایای شناسایی نشانگرهای پلاک را نسبت به درجه بندی تنگی cCTA به تنها یی نشان داد، با افزایش AUC از ۰.۶۱ با تنگی بیش از ۵۰٪ به ۰.۸۳ با افزودن نشانگرهای پلاک برای تشخیص ایسکمی خاص ضایعه مزیت افزایشی بیشتر با افزودن CT-FFR محقق شد. نشانگرهای پلاک مشتق شده از CTA کرونر ارزش پیش بینی کننده ای را برای شناسایی ایسکمی خاص ضایعه در مقایسه با درجه بندی تنگی cCTA به تنها یی نشان می دهند. افزودن CT-FFR به نشانگرهای پلاک قدرت تمایز فزاینده ای را

- E. Braunwald, D. Mann, D. Zipes, P. Libby, and R. Bonow, [1] “Braunwald’s heart disease: a textbook of cardiovascular medicine,” pp. .1028–1028, 2015
- K. Okrainec, D. K. Banerjee, and M. J. Eisenberg, “Coronary artery [2] disease in the developing world,” Am. Heart J. , vol. 148, no. 1, pp. 7–15, .2004, doi: 10. 1016/j. ahj. 2003. 11. 027
- G. Athappan, E. Patvardhan, M. E. Tuzcu, S. Ellis, P. Whitlow, and S. [3] R. Kapadia, “Left main coronary artery stenosis: A meta-analysis of drug-eluting stents versus coronary artery bypass grafting,” JACC Cardiovasc. Interv. , vol. 6, no. 12, pp. 1219–1230, 2013, doi: 10. 1016/j. jcin. 2013. 07. 008
- Singh G, Al’Aref SJ, Van Assen M, Kim TS, van Rosendael A, Kolli [4] KK, et al. Machine learning in cardiac CT: basic concepts and contemporary data. Journal of Cardiovascular Computed Tomography. .2018;12(3):192–201
- Coronary Artery Disease | cdc. gov. ” https://www.cdc.gov/heartdisease/coronary_ad.htm (accessed Aug. 09, 2021)
- Arteriosclerosis / atherosclerosis – Symptoms and causes – Mayo“ [6] Clinic. ” <https://www.mayoclinic.org/diseases-conditions/arteriosclerosis-atherosclerosis/symptoms-causes/es/syc-20350569> (accessed Aug. 09, 2021)
- K. PA, “Cardiac hybrid imaging: state-of-the-art,” Ann. Nucl. Med. , [7] vol. 23, no. 4, pp. 325–331, Jun. 2009, doi: 10. 1007/S12149-009-0245-5
- O. Gaemperli et al. , “Coronary CT angiography and myocardial [8] perfusion imaging to detect flow-limiting stenoses: a potential gatekeeper for coronary revascularization?,” Eur. Heart J. , vol. 30, no. 23, pp. .2921–2929, Dec. 2009, doi: 10. 1093/EURHEARTJ/EHP304

H. Schunkert, "Focal coronary atherosclerosis proximal to myocardial [9] bridging," Circulation, vol. 107, no. 14, p. 1944, Apr. 2003, doi: 10.1161/01.CIR.0000061021.27026. DD

Hampe N, Wolterink JM, van Velzen SGM, Leiner T, Isgum I. [10] Machine Learning for Assessment of Coronary Artery Disease in Cardiac CT: A Survey. Front Cardiovasc Med. 2019;6:172. Published 2019 Nov 26. doi: 10.3389/fcvm.2019.00172

Zreik M, van Hamersveld RW, Khalili N, Wolterink JM, Voskuil M, Viergever MA, [11] Leiner T, Isgum I. Deep Learning Analysis of Coronary Arteries in Cardiac CT Angiography for Detection of Patients Requiring Invasive Coronary Angiography. IEEE Trans Med Imaging. 2020 May;39(5):1545–1557. doi: 10.1109/TMI.2019.2953054. Epub 2019 Nov 12. PMID: 31725371

Danilov, V.V., Klyshnikov, K.Y., Gerget, O.M. et al. Real-time coronary artery [12] stenosis detection based on modern neural networks. Sci Rep **11**, 7582 (2021).
<https://doi.org/10.1038/s41598-021-87174-2>

van Hamersveld RW, Zreik M, Voskuil M, Viergever MA, Isgum I, Leiner T. Deep [13] learning analysis of left ventricular myocardium in CT angiographic intermediate-degree coronary stenosis improves the diagnostic accuracy for identification of functionally significant stenosis. Eur Radiol. 2019 May;29(5):2350–2359. doi: 10.1007/s00330-018-5822-3. Epub 2018 Nov 12. PMID: 30421020; PMCID: PMC6443613

von Knebel Doeberitz PL, De Cecco CN, Schoepf UJ, Duguay TM, Albrecht MH, [14] van Assen M, Bauer MJ, Savage RH, Pannell JT, De Santis D, Johnson AA, Varga-Szemes A, Bayer RR, Schönberg SO, Nance JW, Tesche C. Coronary CT angiography-derived plaque quantification with artificial intelligence CT fractional flow reserve for the identification of lesion-specific ischemia. Eur Radiol. 2019 May;29(5):2378–2387. doi: 10.1007/s00330-018-5834-z. Epub 2018 Dec 6. PMID: 30523456

اهداف: هدف اصلی، اهداف
اخصاصی، هدف کاربردی

اهداف (خروجی ها) اصلی طرح 8 :

تعیین و بررسی عملکرد تشخیصی سی تی-آنژیوگرافی جهت ارزیابی درصد تنگی عروق کرونر در مقایسه با آنژیوگرافی تهاجمی مبتنی بر پردازش تصاویر و یادگیری ماشین.

تعیین مدل های ماشین لرنینگ برای تشخیص دقیق درصد تنگی عروق در تصاویر سی تی آنژیوگرافی.

تعیین مدلی توسط پارامترهای موثر نظیر طول و عرض تنگی و همچنین ویژگی های رادیومیکس جهت تعیین هرچه دقیق تر و ارائه نزدیکترین مدل به استاندارد طلایی تشخیصی.

اهداف (خروجی ها) اختصاصی طرح 9:

تعیین روش های مختلف و تلاش برای ارائه یک مدل با عملکرد و دقت بالا به منظور پیش بینی درصد حاصل از گرفتگی و در صورت امکان ارائه یک مدل سه بعدی از عروق و ضایعه ای داخل عروق به منظور کمک به تشخیص متخصصان در اتخاذ تصمیم برای ارائه طرح های درمانی.

بازسازی و ارائه تصاویر سه بعدی عروق بهمراه ضایعه و ارائه مدلی با نمای سه بعدی به متخصصان.

اهداف کاربردی طرح 10 :

1. تعیین و ارائه یک سیستم هوشمند برای پیش بینی درصد گرفتگی عروق کرونر در تصاویر سی تی - آنژیوگرافی
2. تعیین و ارائه مدل سه بعدی از عروق ضایعه جهت کمک در تشخیص پزشکان (مدلی با دید بصرس بهتر نسبت به ضایعه)
3. تعیین و بررسی عملکرد ویژگی های رادیومیکس در تشخیص گرفتگی عروق تصاویر سی تی آنژیوگرافی

فرضیات یا سوالات پژوهشی

- آیا ویژگی های رادیومیکس در عملکرد تشخیصی درصد تنگی عروق نقش دارند؟
- آیا میتوان مدلی با دقت بالا جهت تشخیص درصد تنگی در تصاویر سی تی آنژیوگرافی ارائه داد؟

روش اجرا

لازم به ذکر است که نوع انجام این مطالعه بصورت بررسی مقطعی می باشد.

یادگیری ماشینی تعریف

یادگیری ماشین مطالعه الگوریتم های رایانه ای است که به طور خودکار از طریق تجربه و با استفاده از داده ها بهبود می یابند که به عنوان بخشی از هوش مصنوعی دیده می شود.[1] الگوریتم های یادگیری ماشین برای ایجاد پیش بینی یا تصمیم گیری بدون برنامه ریزی از پیش تعیین شده برای انجام این کار، مدلی را بر اساس داده های نمونه ایجاد می کنند که به "داده های آموزشی" معروف است. الگوریتم های یادگیری ماشین در طیف گسترده ای از برنامه ها مانند پزشکی، فیلتر ایمیل، تشخیص گفتار و بینایی رایانه ای، جایی که توسعه الگوریتم های معمولی برای انجام کارهای مورد نیاز دشوار

یا غیرممکن است، استفاده می‌شود.

زیرمجموعه‌ای از یادگیری ماشین با آمار محاسباتی که بر پیش‌بینی با استفاده از رایانه مرکز است، ارتباط نزدیکی دارد. اما همه یادگیری ماشین یادگیری آماری نیست. مطالعه بهینه‌سازی شده‌ی روش‌ها بصورت ریاضی، تئوری و حوزه‌های کاربردی را در زمینه یادگیری ماشین ارائه می‌دهد. داده کاوی یک زمینه مرتبط با یادگیری ماشین است، که بر تجزیه و تحلیل داده‌های اکتشافی از طریق یادگیری بدون نظارت مرکز دارد[2].

یادگیری ماشین شامل رایانه است که می‌فهمد چگونه می‌توان وظایف را انجام داد بدون اینکه برای این کار به طور صریح برنامه‌ریزی شده باشد. یادگیری ماشین شامل کامپیوترهایی است که از داده‌های ارائه شده یاد می‌کنند تا وظایف خاصی را انجام دهند. برای کارهای ساده‌ای که به رایانه‌ها اختصاص داده شده است، می‌توان الگوریتم‌هایی را برنامه‌ریزی کرد که به ماشین می‌گویند چگونه تمام مراحل لازم برای حل مسئله را اجرا کند. برای کارهای پیشرفته‌تر ایجاد الگوریتم‌های مورد نیاز به صورت غیر خودکار برای یک انسان چالش برانگیز است. در عمل، به جای این که برنامه نویسان هر مرحله لازم را مشخص کنند، یادگیری ماشین می‌تواند در توسعه الگوریتم خود موثر باشد[3]. رشته یادگیری ماشین از روش‌های مختلفی برای آموزش کامپیوترها برای انجام وظایفی که الگوریتم کاملاً رضایت بخشی در دسترس نیست، استفاده می‌کند. در مواردی که تعداد زیادی پاسخ بالقوه وجود دارد، یک روش این است که برخی از پاسخ‌های صحیح را معتبر برجسب گذاری کنیم. و سپس می‌توان به عنوان داده‌های آموزشی رایانه را مورد استفاده قرار داد تا الگوریتم (های) مورد استفاده برای تعیین پاسخ‌های صحیح را بهبود بخشد. به عنوان مثال، برای آموزش سیستمی برای شناسایی شخصیت‌های دیجیتال، از مجموعه داده MNIST ارقام دست نویس اغلب استفاده شده است[3].

تاریخچه و ارتباط با زمینه‌های دیگر

اصطلاح یادگیری ماشین در سال 1959 توسط آرتور ساموئل، کارمند شرکت IBM امریکا و پیشگام در زمینه بازی‌های رایانه‌ای و هوش مصنوعی ابداع شد[4]. یک کتاب شاخص در تحقیقات یادگیری ماشین در طول دهه 1960 کتاب نیلسون در مورد ماشین‌های یادگیری بود که بیشتر به یادگیری ماشین برای طبقه‌بندی الگوها می‌پرداخت[5]. علاقه به تشخیص الگو تا دهه 1970 ادامه داشت، همانطور که دودا و هارت در سال 1973 توصیف کرده اند[6]. در سال 1981 گزارشی در مورد استفاده از استراتژی‌های تدریس ارائه شد به طوری که گفته شد یک شبکه عصبی یاد می‌گیرد 40 حرف (26 حرف، 10 رقم و 4 علامت ویژه) را از یک پایانه رایانه تشخیص دهد[7].

یادگیری ماشینی مدرن دو هدف دارد، یکی طبقه‌بندی داده‌ها بر اساس مدل‌های توسعه یافته و هدف دیگر پیش‌بینی نتایج آینده بر اساس این مدل‌ها. یک الگوریتم فرضی خاص برای طبقه‌بندی داده‌ها ممکن است از یادگیری نقاط همراه با یادگیری نظارت شده به منظور آموزش آن برای طبقه‌بندی نقاط (تومور)‌های سرطانی استفاده کند. در صورت وجود، یک الگوریتم یادگیری ماشین برای معاملات سهام ممکن است معامله گر را از پیش‌بینی‌های بالقوه آینده مطلع کند.

هوش مصنوعی

یادگیری ماشینی از تلاش برای دستیابی به هوش مصنوعی رشد کرد. در روزهای اولیه هوش مصنوعی به عنوان یک رشته دانشگاهی بود که برخی از محققان علاقه‌مند بودند که بتوانند کاری انجام دهند که ماشین آلات از داده‌ها بیاموزند. آنها سعی کردند با روش‌های مختلف و همچنین آنچه در آن زمان "شبکه‌های عصبی" نامیده می‌شد، به مسئله نزدیک شوند. این‌ها عموماً گیرنده‌ها و مدل‌هایی بودند که بعداً مشخص شد که بازآفرینی مدل‌های خطی تعیین یافته آماری هستند[8]. استدلال احتمالی نیز خصوصاً در تشخیص پژوهشی خودکار مورد استفاده قرار گرفت[9].

با این حال، تأکید فزاینده بر رویکرد منطقی و دانش بنیان باعث ایجاد اختلاف بین هوش مصنوعی و یادگیری ماشین شد. سیستم‌های احتمالی گرفتار مشکلات نظری و عملی اکتساب و بازنمایی داده‌ها بودند[9]. تا سال 1980، سیستم‌های خبره بر هوش مصنوعی مسلط شده بودند و آمارها مورد پسند نبود[10]. کار بر روی یادگیری دانش بنیان در هوش مصنوعی ادامه یافت، که منجر به برنامه‌ریزی منطق استقرایی شد، اما تحقیقات بیشتر در زمینه شناخت الگو و بازیابی اطلاعات، خارج از حوزه هوش مصنوعی بود[9]. تحقیقات مربوط به شبکه‌های عصبی تقریباً هم زمان توسط هوش مصنوعی و علوم رایانه کنار گذاشته شد. این زمینه نیز توسط محققان سایر رشته‌ها از جمله هایپلید، رومل هارت و هینتون در خارج از حوزه هوش مصنوعی به عنوان "ارتباط گرایی" ادامه یافت. موقوفیت اصلی آنها در اواسط دهه 1980 با اختراع مجدد گسترش عقب ماندگی حاصل شد[9].

یادگیری ماشین که به عنوان یک زمینه جداگانه از نو سازماندهی شده است، از دهه 1990 شروع به شکوفایی کرد. این رشته هدف خود را از دستیابی به هوش مصنوعی به مقابله با مشکلات قابل حل از ماهیت عملی تغییر داد. این تمرکز را از رویکردهای نمادین که از هوش مصنوعی به ارت برده بود، گرفته و به سمت روش‌ها و مدل‌های گرفته شده از آمار و نظریه احتمال سوق داد[10].

از سال 2020، بسیاری از منابع همچنان ادعا می‌کنند که یادگیری ماشینی زیرمجموعه هوش مصنوعی باقی مانده

است[11, 12]. اختلاف اصلی این است که آیا همه‌ی یادگیری ماشینی بخشی از هوش مصنوعی است، زیرا این بدان معنی است که هر کسی که از یادگیری ماشینی استفاده می‌کند می‌تواند ادعا کند که از هوش مصنوعی استفاده می‌کند. دیگران این دیدگاه را دارند که همه یادگیری ماشینی بخشی از هوش مصنوعی نیست بلکه فقط یک زیرمجموعه "هوشمند" از یادگیری ماشینی بخشی از هوش مصنوعی است.

این سوال که تفاوت بین یادگیری ماشینی و هوش مصنوعی چیست، توسط یودا پرل در کتاب چرا پاسخ داده شده است[13]. بر این اساس یادگیری ماشینی بر اساس مشاهدات منفعت یاد می‌گیرد و پیش‌بینی می‌کند، در حالی که هوش مصنوعی به معنای تعامل یک عامل با محیط برای یادگیری و اقداماتی است که حداکثر شانس خود را برای دستیابی به اهداف خود حداکثر می‌کند.

رویکردها

رویکردهای یادگیری ماشینی، بسته به ماهیت "سیگنال" یا "بازخورد" موجود در سیستم یادگیری، به طور سنتی به سه دسته گسترده تقسیم می‌شوند:

یادگیری تحت نظارت: رایانه با ورودی‌های نمونه و خروجی‌های دلخواه آنها که توسط "یاد دهنده" آورده شده است، ارائه می‌شود و هدف یادگیری یک قانون کلی است که ورودی‌ها را به خروجی‌ها ترسیم می‌کند.
یادگیری بدون نظارت: هیچ برچسبی به الگوریتم یادگیری داده نمی‌شود، و به تنهایی می‌گذارد تا ساختار ورودی آن را پیدا کند. یادگیری بدون نظارت می‌تواند به خودی خود هدف باشد (کشف الگوهای پنهان در داده‌ها) یا وسیله‌ای برای رسیدن به هدف (یادگیری ویژگی) باشد.

شکل 4) تفاوت یادگیری تحت نظارت و یادگیری بدون نظارت مشخص شده است. شکل چپ یادگیری تحت نظارت را نشان می‌دهد که خطوط کلاس‌های متفاوت را کلاس‌بندی می‌کند. شکل سمت راست یادگیری بدون نظارت رت نشان می‌دهد که برچسبی وجود ندارد و داده‌ها به صورت خوشه‌ای به خوشه‌های مختلف تقسیم می‌شوند[14].

یادگیری بازتقویت شده: یک برنامه رایانه‌ای با یک محیط پویا تعامل می‌کند که باید در آن هدف خاصی را انجام دهد (مانند رانندگی با وسیله نقلیه یا بازی با حریف). این برنامه در حالی که به فضای مشکل خود مسیریابی انجام می‌دهد، بازخوردی ارائه می‌دهد که مشابه پاداش است و سعی در به حداکثر رساندن آن دارد.

یادگیری تحت نظارت

یادگیری تحت نظارت یک کار یادگیری ماشینی است که تابعی از ورودی را به یک خروجی براساس نمونه جفت ورودی-خرجی ترسیم می‌کند[9]. این روش تابعی را از داده‌های آموزشی دارای برچسب که شامل مجموعه‌ای از نمونه‌های آموزش است، نتیجه گیری می‌کند. در یادگیری نظارت شده، هر مثال یک جفت است که متشکل از یک شی ورودی (نوعاً بردار) و یک مقدار خروجی دلخواه است (سیگنال نظارتی نیز نامیده می‌شود). یک الگوریتم یادگیری نظارت شده داده‌های آموزش را تجزیه و تحلیل می‌کند و یک عملکرد استنباط شده تولید می‌کند، که می‌تواند برای نگاشت نمونه‌های جدید استفاده شود. یک سناریو بهینه این امکان را برای الگوریتم فراهم می‌کند تا برچسب‌های کلاس را برای موارد بدون برچسب به درستی تعیین کند. این امر مستلزم الگوریتم یادگیری است که از داده‌های آموزش به صورت "معقول" از داده‌های آموزش به شرایط بدون برچسب تعیین می‌باید. کیفیت آماری یک الگوریتم از طریق اصطلاحاً خطای تعیین اندازه گیری می‌شود[15].

مراحل

برای حل یک مشکل معین یادگیری تحت نظارت، باید مراحل زیر انجام شود:

1. نوع داده‌های آموزشی را تعیین کنید. قبل از انجام هر کار دیگری، کاربر باید تصمیم بگیرد که چه نوع داده‌ای به عنوان مجموعه آموزشی استفاده شود. به عنوان مثال، در مورد تجزیه و تحلیل دست خط، این ممکن است یک حرف دست نویس، کل کلمه دست نویس، کل جمله دست خط یا شاید یک پاراگراف کامل از دست خط باشد.
2. یک مجموعه آموزشی جمع کنید. مجموعه آموزش باید نماینده استفاده واقعی از عملکرد باشد. بنابراین، مجموعه‌ای از ورودی‌ها جمع شده و خروجی‌های مربوطه نیز، یا از طریق متخصصان انسانی یا از اندازه گیری‌ها، جمع می‌شوند.
3. ویژگی ورودی تابع یادگرفته شده را تعیین کنید. دقت عملکرد یادگرفته شده بستگی زیادی به نحوه نمایش ورودی دارد. به طور معمول، ورودی به بردار ویژگی تبدیل می‌شود، که شامل تعدادی از ویژگی‌ها است که توصیف ورودی

است. تعداد ویژگی‌ها نباید زیاد باشد، به دلیل معضل ابعاد. اما باید شامل اطلاعات کافی برای پیش‌بینی دقیق خروجی باشد.

4. ساختار تابع یادگرفته شده و الگوریتم یادگیری مربوطه را تعیین کنید. به عنوان مثال، متخصص ممکن است استفاده از ماشین‌های بردار پشتیبان یا درختان تصمیم را انتخاب کند.

5. طرح را کامل کنید. الگوریتم یادگیری را روی مجموعه آموزش جمع شده اجرا کنید. برخی از الگوریتم‌های یادگیری تحت نظرارت کاربر را ملزم به تعیین پارامترهای کنترل خاصی می‌کنند. این پارامترها ممکن است با بهینه‌سازی تابع در زیر مجموعه‌ای (مجموعه اعتبار سنجد) آموزشی یا از طریق اعتبار سنجد مقابله تنظیم شوند.

6. دقت عملکرد یادگرفته شده را ارزیابی کنید. پس از تنظیم پارامتر و یادگیری، عملکرد تابع حاصل باید روی مجموعه آزمایشی جدا از مجموعه آموزش سنجدیده شود.

الگوریتم نزدیکترین همسایگی

در آمار، الگوریتم k-نزدیکترین همسایگی یک روش طبقه‌بندی غیر پارامتری است که اولین بار توسط اولین فیکس و جوزف هاجز در سال 1951 توسعه [16] و بعداً توسط توماس کاور گسترش یافت. [17] این روش برای طبقه‌بندی و رگرسیون استفاده می‌شود. در هر دو مورد، ورودی شامل نزدیکترین مثال‌های آموزش در مجموعه داده‌ها است.

خروجی پستگی به استفاده از نزدیکترین همسایگی برای طبقه‌بندی یا رگرسیون دارد:

در طبقه‌بندی نزدیکترین همسایگی، خروجی یک عضو کلاس است. یک داده با رأی اکثریت همسایگان طبقه‌بندی می‌شود، با اینکه داده به کلاس متداول در نزدیکی k همسایگان خود اختصاص می‌یابد (k یک عدد صحیح مثبت است، به طور معمول کوچک). اگر $k = 1$ باشد، آن داده به سادگی به کلاس آن نزدیکترین همسایه اختصاص می‌یابد. نزدیکترین همسایگی نوعی طبقه‌بندی است که در آن تابع فقط به صورت محلی تقریب می‌خورد و تمام محاسبات تا ارزیابی عملکرد به تعویق می‌افتد. از آنجا که این الگوریتم برای طبقه‌بندی به فاصله متنک است، اگر ویژگی‌ها واحدهای فیزیکی مختلفی را نشان دهند یا در مقیاس‌های کاملاً متفاوتی قرار بگیرند، عادی‌سازی داده‌های آموزش می‌تواند دقت آن را به طرز چشمگیری بهبود بخشد [18].

هم برای طبقه‌بندی و هم برای رگرسیون، یک تکنیک مفید می‌تواند اختصاص وزن به سهم همسایگان باشد، به طوری که همسایگان نزدیکتر نسبت به میانگین‌های دورتر به طور متوسط بیشتر کمک می‌کنند. همسایگان از داده‌ها گرفته می‌شوند که کلاس برای آنها شناخته شده است. می‌توان این را به عنوان مجموعه آموزش الگوریتم تصور کرد، اگرچه صرفاً به مرحله آموزش نیاز نیست. یک ویژگی الگوریتم نزدیکترین همسایگی این است که به ساختار محلی داده حساس است.

الگوریتم

داده‌های آموزشی بردارهایی در یک فضای ویژگی چند بعدی هستند که هر کدام دارای برچسب کلاس هستند. مرحله آموزش الگوریتم فقط شامل ذخیره بردارهای ویژگی و برچسب‌های کلاس نمونه‌های آموزشی است.

در مرحله طبقه‌بندی k یک ثابت تعریف شده توسط کاربر است و یک بردار بدون برچسب با اختصاص برچسبی که بیشترین فراوانی را در بین نمونه‌های آموزش k نزدیک به آن نقطه جستجو دارد، طبقه‌بندی می‌شود.

یک معیار فاصله‌ای که معمولاً برای متغیرهای پیوسته استفاده می‌شود، فاصله اقلیدسی است. برای متغیرهای گسسته، مانند طبقه‌بندی متن، می‌توان از معیار دیگری مانند متريک همپوشانی (یا فاصله همنگ) استفاده کرد. به عنوان مثال، در زمینه داده‌های ریزآرایه بیان ژن، نزدیکترین همسایگی با ضرایب همبستگی، مانند پیرسون و اسپرمن، به عنوان معیار استفاده شده است.

یک اشکال در طبقه‌بندی اساسی "رأی اکثریت" هنگامی اتفاق می‌افتد که توزیع کلاس کج باشد. به عنوان مثال، نمونه‌هایی از یک کلاس با داده‌های بیشتر تمایل دارند که پیش‌بینی نمونه جدید را تحت سلطه خود قرار دهند، زیرا به دلیل تعداد زیادشان تمایل دارند که بیشترین تعداد داده‌ها را داشته باشند. یکی از راههای غلبه بر این مشکل، وزن دهنی به کلاس‌بندی با در نظر گرفتن فاصله از نقطه آزمون تا هر یک از نزدیکترین همسایگان است. کلاس (یا مقدار، در رگرسیون) هر یک از k نزدیکترین نقاط در یک وزن متناسب با وارونه فاصله از آن نقطه تا نقطه آزمون ضرب می‌شود.

در یادگیری ماشین، ماشین‌های بردار پشتیبان [19] مدل‌های یادگیری تحت نظارت با الگوریتم‌های یادگیری همراه هستند که داده‌ها را برای طبقه‌بندی و تحلیل رگرسیون تجزیه و تحلیل می‌کنند. ماشین‌های بردار پشتیبان در آزمایشگاه‌های AT&T Bell و شرووننکیس (1974) ارائه شده است. با توجه به مجموعه‌ای از داده‌های آموزشی که هر یک از داده‌ها را به عنوان یکی از دو دسته مشخص می‌کند، الگوریتم آموزش ماشین‌های بردار پشتیبان مدلی را ایجاد می‌کند که نمونه‌های جدیدی را به یک دسته یا دیگر اختصاص می‌دهد و آن را به یک طبقه‌بندی خطی باینری غیر احتمالی تبدیل می‌کند. ماشین‌های بردار پشتیبان نمونه‌های آموزش را به نقاط موجود در فضای ترسیم می‌کند تا عرض شکاف بین دو دسته را به حداقل برساند. سپس نمونه‌های جدید در همان فضای ترسیم شده و پیش‌بینی می‌شود که به کدام دسته‌ای تقسیم شوند که بر اساس جهت شکاف کاهش می‌یابد.

علاوه بر انجام طبقه‌بندی خطی، ماشین‌های بردار پشتیبان می‌توانند با استفاده از آنچه کرنل نامیده می‌شود، طبقه‌بندی غیرخطی را به طور موثر انجام دهند و به طور ضمنی و رودی‌های آن‌ها را در فضاهای ویژگی‌های بعد بالا نگاشت کنند. وقتی داده‌ها بدون برچسب هستند، یادگیری تحت نظارت امکان پذیر نیست و یک رویکرد یادگیری بدون نظارت مورد نیاز است، که سعی دارد خوش‌بندی طبیعی داده‌ها را به گروه‌ها پیدا کند و سپس داده‌های جدید را برای این گروه‌های شکل گرفته ترسیم کند. الگوریتم خوش‌بندی بردار پشتیبان [20]، ایجاد شده توسط هوا سیگلمون و ولادیمیر و پنیک، از آمار بردارهای پشتیبان، توسعه یافته و در الگوریتم ماشین‌های بردار پشتیبان، برای دسته‌بندی داده‌های غیر برچسب دار استفاده می‌کند و یکی از پرکاربردترین الگوریتم‌های خوش‌بندی است.

شکل 5) نمایش شیوه تصمیم گیری در روش ماشین‌های بردار پشتیبان. دو داده نزدیکتر به خط مرزی بردارهای پشتیبان هستند که داده‌ها براساس این‌ها تقسیم می‌شوند[21].

جنگل‌های تصادفی

جنگل‌های تصادفی یا جنگل‌های تصمیم تصادفی یک روش یادگیری برای طبقه‌بندی رگرسیون و سایر وظایف است که با ساختن تعداد زیادی درخت تصمیم در زمان آموزش کار می‌کند. برای کارهای طبقه‌بندی خروجی جنگل تصادفی کلاسی است که توسط اکثر درختان انتخاب شده است. برای کارهای رگرسیون، میانگین یا متغیر پیش‌بینی تک تک درختان برگردانده می‌شود[22]، [23]. جنگل‌های تصادفی از نظر سازگاری درختان تصمیم گیری با مجموعه آموزشی آن‌ها بسیار کارآمد هستند. با این حال، ویژگی‌های داده می‌تواند عملکرد آن‌ها را تحت تأثیر قرار دهد.

اولین الگوریتم جنگل‌های تصمیمی تصادفی در سال 1995 توسط تین کم هو [22] با استفاده از روش تصادفی زیر فضایی ایجاد شد [23]، که در فرمول هو، روشی برای اجرای رویکرد "تبیین تصادفی" برای طبقه‌بندی ارائه شده توسط اوژن کلاینبرگ بود [24].

الگوریتم توسعه یافته توسط لئو بریمن [25] و آدل کاتلر، که "جنگل‌های تصادفی" را به عنوان علامت تجاری در سال 2006 (تا سال 2019 متعلق به Inc Minitab) ثبت کرد. پسوند ترکیبی از ایده "کیس‌بندی" بریمن و انتخاب تصادفی ویژگی‌ها است که ابتدا توسط هو [22] و بعداً به طور مستقل توسط آمیت و گمان [26] به منظور ساخت مجموعه‌ای از درختان تصمیم با واریانس کنترل شده معروفی شد.

جنگل‌های تصادفی معمولاً به عنوان مدل "جعبه سیاه" در مشاغل مورد استفاده قرار می‌گیرند، زیرا پیش‌بینی‌های معقولی را در طیف گسترده‌ای از داده‌ها ایجاد می‌کنند در حالی که نیاز به تنظیمات کمی دارند.

یادگیری بدون نظارت

یادگیری بدون نظارت نوعی الگوریتم است که الگوها را از داده‌های بدون برچسب یاد می‌گیرد. در مقابل یادگیری تحت نظارت که داده‌ها توسط یک انسان برچسب گذاری می‌شود، به عنوان مثال به عنوان "اتومبیل" یا "ماهی" و غیره، یادگیری بدون نظارت خود سازماندهی را نشان می‌دهد که الگوهایی را به عنوان تمایلات عصبی یا تراکم احتمالات ضبط می‌کند[27]. سایر سطوح در طیف نظارت عبارتند از یادگیری تقویت که در آن فقط امتیاز عملکرد عددی به عنوان راهنمای ماشین داده می‌شود و یادگیری نیمه نظارت شده برچسب گذاری براساس قسمت کوچکتری از داده‌ها انجام می‌شود. دو روش گسترده در یادگیری بدون نظارت، شبکه‌های عصبی و روش‌های احتمالی است.

یادگیری بازتقویت شده

یادگیری بازتقویت شده حوزه‌ای از یادگیری ماشینی است که به چگونگی اقدام عوامل هوشمند در یک محیط برای به حداقل رساندن مفهوم پاداش تجمعی مربوط می‌شود. [28] یادگیری بازتقویت شده یکی از سه الگوی اساسی یادگیری ماشین، در کنار یادگیری تحت نظارت و یادگیری بدون نظارت است. یادگیری بازتقویت شده با یادگیری تحت نظارت در عدم نیاز به ارائه جفت‌های ورودی / خروجی برجسب دارد و عدم نیاز به اقدامات بهینه‌سازی برای تشخیص کاملاً صحیح، متفاوت است. در عوض تمرکز بر یافتن تعادل بین اکتشاف (در قسمت ثبت نشده) و بهره‌برداری (از داشت فعلی) است.

محیط به طور معمول در قالب یک فرایند تصمیم‌گیری مارکوف بیان می‌شود، زیرا بسیاری از الگوریتم‌های یادگیری تقویت کننده برای این زمینه از تکنیک‌های برنامه نویسی پویا استفاده می‌کنند. تفاوت اصلی بین روش‌های برنامه نویسی پویا متداول و الگوریتم‌های یادگیری تقویت کننده این است که روش دوم دانش دقیق یک مدل ریاضی از فرایند تصمیم‌گیری مارکوف را فرض نمی‌کند و فرایندهای تصمیم‌گیری مارکوف بزرگ را در صورت غیرقابل اجرا بودن هدف قرار می‌دهند.

معیارهای ارزیابی

ارزیابی طبقه‌بندی کننده‌ها، یک ویژگی دوستایی یا سه تایی را مقایسه می‌کند که یکی از آنها معمولاً یک روش استاندارد است و دیگری در حال بررسی است. معیارهای زیادی وجود دارد که می‌توان برای اندازه گیری عملکرد طبقه‌بندی کننده یا پیش‌بینی کننده استفاده کرد. به دلیل اهداف متفاوت، زمینه‌های مختلف ترجیحات متفاوتی برای معیارهای خاص دارند. به عنوان مثال، در پزشکی اغلب از حساسیت و ویژگی استفاده می‌شود، در حالی که در علوم کامپیوتر دقت و فراخوانی ترجیح داده می‌شود. تمایز مهم بین معیارهای مستقل از میزان شیوع (تعداد دفعاتی که هر گروه در جمعیت رخ می‌دهد) و معیارهایی است که به میزان شیوع بستگی دارد - هر دو نوع مفید هستند، اما خواص بسیار متفاوتی دارند. در این مطالعه نیز این معیارها برای سه کلاس در نظر گرفته شده‌اند. در معادلات زیر روش‌های محاسبه هر کدام از این معیارها شرح داده شده است.

1. صحت :

$$\text{معادله 1} \quad 10$$

که TP مثبت صادق ، TN منفی صادق ، FN منفی کاذب ، FP مثبت کاذب ، P واقعیت مثبت (تعداد موارد مثبت در داده) و N واقعیت منفی (تعداد موارد منفی در داده)، می‌باشند.

2. حساسیت:

$$\text{معادله 2} \quad 20$$

که TPR نرخ مثبت درست و FNR نرخ منفی نادرست می‌باشند

3. ویژگی:

$$\text{معادله 3} \quad 30$$

که TNR نرخ منفی درست و FPR نرخ مثبت نادرست می‌باشند.

4. دقت:

$$\text{معادله 4} \quad 40$$

که PPV مقدار پیش‌بینی مثبت و FDR نرخ کشف نادرست می‌باشند.

5. نمره-:

$$\text{معادله 5} \quad 50$$

بیماران تحت مطالعه شامل افرادی هستند که در گذشته سی‌تی آنژیوگرافی و آنژیوگرافی تهاجمی انجام داده اند و گرفتگی عروق در آنها توسط رادیولوژیست و پزشک دیده شده است. در واقع در این مطالعه هدف تخمین دقیق درصد تنگی عروق این بیماران با دقت قابل قبول با استفاده از سی‌تی آنژیوگرافی و با استندارد طلایی آنژیوگرافی تهاجمی میباشد. هدف در واقع طراحی سیستم هوش مصنوعی میباشد که بتوان در آینده با استفاده از تنها تصاویر سی‌تی آنژیوگرافی تخمین دقیقی از گرفتگی عروق آنها بدست آورد. زمان در نظر گرفته شده برای این مطالعه شامل بیمارانی است که در بازه زمانی ۵ سال اخیر اقدام به انجام سی‌تی آنژیوگرافی و آنژیوگرافی کرده اند. تمام اطلاعات بیماران شامل نام و ... در تگ نرم افزار های تصویر برداری حذف خواهد شد و هیچگونه از اطلاعات بیمار بجز خود تصاویر ذکر نخواهد شد. اطلاعات تصاویر در اختیار متخصصان هوش مصنوعی قرار خواهد گرفت اما استخراج داده ها از پایگاه بیمارستانی (PACS) توسط متخصصان و کارشناسان بخش رادیولوژی که نامشان در طرح ذکر شده است، انجام خواهد گرفت.

منابع

- T. Mitchell, “Machine learning,” 1997, Accessed: Aug. 09, 2021. [Online]. Available: <https://akum.pw/mkk00nyuy5.pdf>.
- [2] J. H. Friedman, “Data Mining and Statistics: What’s the Connection?”
- [3] E. Alpaydin, “Introduction to machine learning,” p. 682.
- [4] A. L. Samuel, “Some Studies in Machine Learning Using the Game of Checkers,” IBM J. Res. Dev., vol. 3, no. 3, pp. 210–229, Jul. 1959, doi: 10.1147/rd.33.0210.
- [5] N. J. Nilsson, Learning machines (1965 edition) | Open Library. McGraw–Hill, 1965.
- [6] R. Duda and P. Hart, Pattern classification and scene analysis. 1973.
- [7] S. Bozinovski, Teaching space: A representation concept for adaptive pattern classification. COINS Technical Report, 1981.
- [8] W. Sarle, “Neural networks and statistical models,” 1994, Accessed: Aug. 09, 2021. [Online]. Available: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.27.699>.
- [9] S. Russell and P. Norvig, “Artificial intelligence: a modern approach,” 2002, Accessed: Aug. 09, 2021. [Online]. Available: <https://research.google/pubs/pub27702.pdf>.
- [10] P. Langley, “The changing science of machine learning,” Mach Learn, vol. 82, no. 3, pp. 275–279, Mar. 2011, doi: 10.1007/s10994-011-5242-y.
- [11] E. Kavlakoglu, “AI vs. Machine Learning vs. Deep Learning vs. Neural... – Google Scholar,” 2020.
- [12] D. M. J. Garbade, “Clearing the confusion: AI vs Machine learning vs Deep learning Differences,” 2018. https://scholar.google.com/scholar?hl=en&as_sdt=0%2C5&q=+Garbade%2C+Dr+Michael+J.+%282014+September+2018%29.++%22Clearing+the+Confusion%3A+AI+vs+Machine+Learning+vs+Deep+Learning+Differences%22+Medium.+.Retrieved+28+October+2020&btnG= (accessed Aug. 09, 2021).
- [13] J. Pearl, “The book of why: the new science of cause and effect,” 2018. https://scholar.google.com/scholar?hl=en&as_sdt=0%2C5&q=+Pearl%2C+Judea%3B+Mackenzie%2C+Dana+%282018%29.+.The+Book+of+Why%3A+The+New+Science+of+Cause+and+Effect+%282018+ed.%29.+.Basic+Books.+.ISBN+9780465097609.+.Retrieved+28+October+2020. &btnG= (accessed Aug. 09, 2021).
- [14] “Supervised Machine Learning, Unsupervised Machine Learning, and Deep Learning – CFA, FRM, and Actuarial Exams Study Notes.” <https://analystprep.com/study-notes/cfa-level-2/quantitative-method/supervised-machine-learning-unsupervised-machine-learning-deep-learning/> (accessed Aug. 09, 2021).
- [15] V. Cabannes, A. Rudi, and F. Bach, “Fast rates in structured prediction,” Proc. Mach. Learn. Res., vol. 134, pp. 1–43, Feb. 2021, Accessed: Aug. 09, 2021. [Online]. Available: <http://arxiv.org/abs/1905.09090>.

- org/abs/2102. 00760.
- [16] E. Fix, J. H. –S. R. I. de Statistique, and undefined 1989, “Discriminatory analysis. Nonparametric discrimination: Consistency properties,” JSTOR, Accessed: Aug. 09, 2021. [Online]. Available: <https://www.jstor.org/stable/1403797>.
- [17] N. S. Altman, “An introduction to kernel and nearest–neighbor nonparametric regression,” Am. Stat. , vol. 46, no. 3, pp. 175–185, 1992, doi: 10.1080/00031305.1992.10475879.
- [18] S. Piryonesi, T. E. –D. –J. of T. Engineering, and undefined 2020, “Role of data analytics in infrastructure asset management: Overcoming data size and quality problems,” ascelibrary.org, Accessed: Aug. 09, 2021. [Online]. Available: <https://ascelibrary.org/doi/abs/10.1061/JPEODX.0000175>.
- [19] C. Cortes and V. Vapnik, “Support–vector networks,” Mach. Learn. , vol. 20, no. 3, pp. 273–297, Sep. 1995, doi: 10.1007/BF00994018.
- [20] A. Ben-Hur et al. , “Support Vector Clustering,” J. Mach. Learn. Res. , vol. 2, pp. 125–137, 2001.
- [21] “Support Vector Machines (SVM) | LearnOpenCV.” <https://learnopencv.com/support-vector-machines-svm/> (accessed Aug. 09, 2021).
- [22] ... T. H. 3rd international conference on document analysis and undefined 1995, “Random decision forests,” ieeexplore.ieee.org, Accessed: Aug. 09, 2021. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/598994/>.
- [23] T. H. –I. transactions on pattern analysis and machine and undefined 1998, “The random subspace method for constructing decision forests,” ieeexplore.ieee.org, Accessed: Aug. 09, 2021. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/709601/>.
- [24] E. K. –I. T. on P. A. and and undefined 2000, “On the algorithmic implementation of stochastic discrimination,” ieeexplore.ieee.org, Accessed: Aug. 09, 2021. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/857004/>.
- [25] L. Breiman, “Random forests,” Mach. Learn. , vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [26] Y. Amit, D. G. –N. computation, and undefined 1997, “Shape quantization and recognition with randomized trees,” direct.mit.edu, vol. 9, no. 7, pp. 1545–1588, Oct. 1997, doi: 10.1162/neco.1997.9.7.1545.
- [27] D. G. Duda, Richard O. ; Hart, Peter E. ; Stork, “Unsupervised Learning and Clustering”. Pattern classification (2nd ed.)., Wiley, 2001. https://scholar.google.com/scholar?hl=en&as_sdt=0%2C5&q=Duda%2C+Richard+O.%3B+Hart%2C+Peter+E.%3B+Stork%2C+David+G.+%282001%29+%22Unsupervised+Learning+and+Clustering%22&btnG= (accessed Aug. 09, 2021).
- [28] T. Jaksch, R. Ortner, P. A. –J. of M. L. Research, and undefined 2010, “Near–optimal Regret Bounds for Reinforcement Learning.,” jmlr.org, vol. 11, pp. 1563–1600, 2010, Accessed: Aug. 09, 2021. [Online]. Available: <https://www.jmlr.org/papers/volume11/jaksch10a/jaksch10a.pdf>

مشخصات ابزار جمع آوری
اطلاعات و نحوه جمع آوری
آن

در این پژوهش از نرم افزار های هوش مصنوعی و پردازش تصاویر مانند 3d slicer , matlab, python, lifex خواهد شد.

روش محاسبه حجم نمونه و
تعداد آن

با توجه به بررسی های صورت گرفته ، تعداد حجم نمونه حداقل 60 بیمار و در صورت امکان تا 150 بیمار خواهد بود. برای تعیین تعداد نمونه های آزمایش، از نرم افزار G-power

اسفاده شده است که متعلق به دانشگاه Heinrich-hein- است. برای این منظور از تست آماری ttest استفاده شده است. با توجه به اینکه این مطالعه در گذشته انجام نشده است و با توجه به مطالعه [1] پارامتر alpha برابر 0.05 و p برابر با 0.6 در نظر گرفته شده است. مقدار پیشنهادی این نرم افزار برای حداقل جامعه آماری با وجهه به پارامتر های آماری برابر 21 است که ما برای دو گروه از بیماران نیاز به حداقل 42 بیمار خواهیم داشت.

Alizadehsani R, Hosseini MJ, Khosravi A, Khozeimeh F, Roshanzamir M, Sarrafzadegan N, [1] Nahavandi S. Non-invasive detection of coronary artery disease in high-risk patients based on the stenosis prediction of separate coronary arteries. Computer methods and programs in .biomedicine. 2018 Aug 1;162:119-27

ملاحظات اخلاقی

- طرح به صورت گذشته نگر می باشد.
- در استفاده از داده های کلینیکی قوانین بیمارستان که شامل حذف اطلاعات بیماران از داده ها است رعایت خواهد شد.
- در کار تشخیصی بیمار دخالت نخواهد شد.

جدول متغیرها

نحوه اندازه گیری	تعریف کاربردی	واحد اندازه گیری	نوع متغیر کیفی - اسمی است؟	نوع متغیر کیفی - رتبه ای است؟	نوع متغیر کمی - گستره است؟	نوع متغیر کمی - پیوسته است؟	نقش متغیر	نام متغیر
آنالیز تصاویر	پارامترهای کمی مستخرج از آنالیز رادیومیکس تصاویر CCTA	.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	مستقل	Radiomic Features
آنالیز تصاویر	عرض تنگی رگ	.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	وابسته	Stenosis width
آنالیز تصاویر	پراکنندگی	.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	وابسته	Variance
آنالیز تصاویر	طول تنگی رگ	.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	وابسته	Length of stenosis
آنالیز تصاویر	ترکیب سطوح خاکستری پیکسل ها یا وکسل های مجاور در یک حجم 3D که در یک راستای تصویر	.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	مستقل	GLCM

زمانبندی و اجرا

شرح مختصر مرحله	درصد مرحله	مدت زمان اجرا – ماه	از تاریخ	تا تاریخ
جمع آوری داده و قطعه بندی	2		1402/04/01	1402/02/01
پیش پردازش داده و آماده سازی داده	3		1402/07/01	1402/04/01
پردازش تصاویر و پیاده سازی هوش مصنوعی	4		1402/11/01	1402/07/01
ارزیابی سیستم	2		1403/01/01	1402/11/01
نتیجه گیری و نوشتن مقاله	2		1403/03/01	1403/01/01

هزینه پرسنلی

نام و نام خانوادگی	توصیف دقیق فعالیتی که فرد باید در این تحقیق انجام دهد	کل حق الزحمه – ریال
		140,000,000