

Winter 2024, 5 (4), 89-99
DOR:

Received: 24 Sep 2024
Accepted: 5 Nov 2024

مقاله پژوهشی

Feature Extraction and Classification of Colonoscopy Lesions based on the HCBA Framework

Vahid Bayramirad¹, Mahdi Mazinani^{2*}, Mitra Mirzarezaee³

1. Ph.D. Student, Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran. vahid.bairami.rad@srbiau.ac.ir
2. Associate professor, Department of Electrical and Electronic Engineering, Shahr-e-Qods Branch, Islamic Azad University, Tehran, Iran. * Corresponding author mahdi.mazinani@qodsiau.ac.ir
3. Associate professor, Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Tehran Iran. mirzarezaee@srbiau.ac.ir

Abstract

Introduction: Recent years have witnessed expansion of colon-related diseases expanding due to the expansion of modern lifestyles. Fortunately, early diagnosis of these diseases can significantly facilitate the treatment and control of these diseases. A novel deep learning framework, HCBA, was introduced to classify colonoscopy lesions. The framework consists of several methods such as hierarchical clustering, a bag of features, and an auto-encoder.

Method: Feature extraction was done using BOF and autoencoder, where hierarchical clustering and colonoscopy lesion classification were performed using DBN.

Results: The proposed method had a high performance in classifying colonoscopy images. The method exhibited the highest mean results in HCBA-DBN, including 93.0 in ACC, 87.1 in Pre, 87.6 in Rec, and 94.8 in Sen.

Discussion: The extraction of features was based on a set of features and hierarchical clustering was optimized. The separation of the similarity measurement between the samples within the cluster was based on the standard deviation. In addition, deep belief learning was used.

Keywords: Colonoscopy, Colon Lesions, Deep Learning, Image Processing, Classification.

استخراج ویژگی و طبقه‌بندی ضایعات کولونوسکوپی بر اساس چارچوب HCBA

دوره پنجم، زمستان ۱۴۰۳
شماره چهارم، صص: ۸۹-۹۹

تاریخ دریافت: ۱۴۰۳/۰۷/۰۳
تاریخ پذیرش: ۱۴۰۳/۰۸/۱۵

وحید بایرامی‌راد^۱، مهدی مزینانی^{۲*}، میترا میرزارضایی^۳

۱. دانشجوی دکتری، گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
۲. دانشیار، گروه مهندسی برق و الکترونیک، واحد شهرقدس، دانشگاه آزاد اسلامی، تهران، ایران. (نویسنده مسئول)
mahdi.mazinani@qodsiau.ac.ir
۳. دانشیار، گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

چکیده: سرطان روده یک بیماری کشنده است که به دلیل ناهگن بودن سلول‌های سرطانی، طبقه‌بندی آن برای پزشکان یک چالش بزرگ است. در سال‌های اخیر، استفاده از تکنیک‌های رایانه‌ای، به‌ویژه پردازش تصویر و ویدئو با الگوریتم‌های هوش مصنوعی ادغام شده در زمینه‌های پردازش تصاویر پزشکی و کاربردهای مرتبط با سلامت مورد توجه قرار گرفته است و تحقیقات زیادی در این زمینه صورت گرفته است. به عنوان مثال، تشخیص و طبقه‌بندی ضایعات کولون در کولونوسکوپی یکی از زمینه‌هایی است که می‌توان با استفاده از پردازش تصویر و الگوریتم‌های هوش مصنوعی، دقت تشخیص را افزایش داد و به پزشک کمک کرد تا ضایعات را با دقت بیشتری شناسایی و طبقه‌بندی کند. بنابراین در این مقاله، یک چارچوب یادگیری عمیق جدید به نام HCBA^۱ برای استخراج ویژگی ضایعات کولونوسکوپی که از چندین روش مانند خوشه‌بندی سلسله‌مراتبی بهینه‌شده کوله‌ای از ویژگی‌های بهینه‌شده و رمزگذار خودکار عمیق تشکیل شده‌اند و برای طبقه‌بندی ضایعات کولونوسکوپی از شبکه باور عمیق استفاده شده، پیشنهاد می‌شود. در نهایت با توجه به نتایج تجربی، عملکرد روش پیشنهادی در طبقه‌بندی تصاویر کولونوسکوپی با در نظر گرفتن معیار دقت به تصویر کشیده شده است.

واژه‌های کلیدی: کولونوسکوپی، ضایعات کولون، یادگیری عمیق، خوشه‌بندی، پردازش تصویر، طبقه‌بندی عمیق.

۱. مقدمه

بدن انسان مانند دنیای پیچیده و منظمی است که در آن عملکرد ایمن هر عضو و بافت برای حفظ سلامت عمومی افراد بسیار مهم است. نظارت پزشکی و تشخیص بیماری مربوط به هر عضو و بافت بسیار مهم است و نقش کلیدی در تشخیص پیش از بیماری و شروع مراحل اولیه درمان دارد که می‌تواند احتمال موفقیت درمان را افزایش دهد. به دلیل استفاده آن‌ها از روش‌های پایه پردازش تصویر، عملکرد این روش ساده و سریع می‌باشد. روش مذکور می‌تواند در سایر برنامه‌های کاربردی تصویربرداری پزشکی، نظیر استخراج ویژگی و انطباق الگو نیز کاربرد مؤثری داشته‌باشد. انتخاب دستی پارامترهای آستانه و اندازه فیلتر میانگین از نقاط ضعف روش پیشنهادی آن‌ها می‌باشد [۱]. استفاده از روش‌های انتقال یادگیری به واسطه افزایش هزینه برچسب‌گذاری از یک سو و از طرف دیگر افزایش روزافزون داده‌ها در فضای مجازی و اینترنت در چند سال اخیر از سوی دیگر موجب شده که پژوهش‌های قابل‌توجهی معطوف به حوزه انتقال یادگیری شود یکی از رهیافت‌های اصلی انتقال یادگیری تطبیق دامنه می‌باشد. تطبیق دامنه خود به دو بخش با نظارت و بدون نظارت تقسیم‌بندی می‌شود در صورتی که داده‌های با برچسب در دامنه هدف وجود نداشته‌باشد به آن تطبیق دامنه بدون نظارت گفته می‌شود و اگر داده‌های با برچسب موجود باشد روش با نظارت است در این پژوهش روش بدون نظارت مد نظر است [۲]. ممکن است عوامل تشدیدکننده خطر CRC^۲ مانند رژیم غذایی ناسالم (گوشت قرمز فرآوری شده با مقادیر کمی سبزیجات، میوه‌ها و فیبر رژیمی)، استفاده نادرست از الکل، عدم فعالیت بدنی و اضافه وزن، تغییر یا اصلاح شود [۳]. اگرچه هر یک از اندام‌ها و بافت‌های بدن انسان نقش مهمی در ارگانیسم بدن دارند، این مقاله بر روی کولون که بخشی از روده بزرگ است تمرکز دارد. روده بزرگ شامل چندین قسمت است که هر کدام وظایف مختلفی را انجام می‌دهند. یکی از این کارها جذب آب و مواد معدنی و دفع مواد زائد است. انتهای روده بزرگ که مواد زائد قبل از دفع در آنجا جمع آوری می‌شوند کولون نامیده می‌شود. روده بزرگ از طریق تغییرات سلولی ممکن است از بیماری‌های خاصی مانند سرطان رنج ببرد [۴]. برای تشخیص یا نظارت بر تغییرات سلولی، در این ناحیه، بررسی دوره ای کولون توسط پزشک با استفاده از کولونوسکوپی ضروری است. در کولونوسکوپی، تشخیص بیماری‌هایی که روده بزرگ را تحت تأثیر قرار می‌دهند مانند ضایعات هیپرپلاستیک، آدنوم دندانه‌دار، آدنوم، زخم، التهاب، پولیپ، عفونت و سرطان با استفاده از بررسی ویدیویی یا تصویری، در داخل روده مشاهده می‌شود. در بیشتر تحقیقات در نتیجه به‌کارگیری فناوری‌های رایانه‌ای جدید در زمینه تشخیص ضایعات کولونوسکوپی ممکن است منجر به بهبود در تشخیص واقعی شود و از این رو، می‌تواند زمان طلایی کافی برای انجام اقدامات پزشکی اولیه داشته‌باشد. برای این منظور، در این مقاله با تمرکز بر تکنیک‌های هوش مصنوعی، یک چارچوب یادگیری عمیق جدید به نام HCBA برای طبقه‌بندی ضایعات کولونوسکوپی پیشنهاد شده‌است که از چندین روش

مانند خوشه‌بندی سلسله‌مراتبی، کوله‌ای از ویژگی‌ها و رمزگذار خودکار تشکیل شده‌است.


نوآوری در این پژوهش شامل موارد زیر خواهد شد.

- ارائه مدل پیشنهادی برپایه HCBA
 - استخراج ویژگی‌ها بر پایه کوله‌ای از ویژگی‌ها، استفاده از خوشه‌بندی سلسله‌مراتبی بهینه‌شده و انحراف معیار در کوله‌ای از ویژگی‌های بهینه‌شده،
 - مقایسه نتایج به‌دست‌آمده با روش‌های پیشین که نشان‌دهنده کارایی مدل پیشنهادی است.
 - دقت بیشتر در استفاده از داده‌ها و مشاهدات کمتر،
- الکارزل و همکاران. (۲۰۲۳) از روش‌های یادگیری عمیق برای تشخیص و طبقه‌بندی پولیپ کولورکتال استفاده کردند، که در چند سال گذشته یک زمینه اصلی مطالعاتی بوده‌است. دلیل این جهش تحقیقات در این زمینه، عدم تشخیص پولیپ توسط پزشکان در بسیاری از موارد به دلیل بی‌تجربگی است. عدم شناسایی پولیپ می‌تواند منجر به عوارض بیشتری شود که می‌تواند منجر به سرطان کولورکتال شود که یکی از علل اصلی مرگ‌ومیر ناشی از سرطان است. در حالی که چندین تکنیک معرفی شده‌است، بسیاری از مسائل مانند تاری، انعکاس نور و کمبود داده‌های آموزشی تاکنون حل نشده باقی‌مانده‌اند [۵]. تاماکی و همکاران (۲۰۱۸) سیستمی متشکل از نمایش کیسه‌ای از کلمات بصری (BOW^۳) از ویژگی‌های محلی و به دنبال طبقه‌بندی‌کننده‌های ماشین بردار پشتیبانی (SVM^۴) پیشنهاد کرده‌اند. علاوه بر این، آن‌ها ترکیب جدیدی از ویژگی‌های محلی و طرح‌های نمونه‌گیری را پیشنهاد کرده‌اند [۶]. جدول (۱) مقایسه روش‌های انجام‌شده در سال‌های قبل را نشان می‌دهد.

۲. روش تحقیق

شکل (۱) فلوچارت سیستم پیشنهادی را نشان می‌دهد

کوله‌ای از ویژگی‌ها Bof^۴ یا Bow که برای استخراج ویژگی‌ها استفاده می‌شود که بر اساس مجموعه نامرتب کلمات است و ترتیب کلمات را نادیده می‌گیرد و ویژگی‌های تصاویر را در کیسه و یا کوله‌ای قرار می‌دهد [۷-۹] ایده اصلی، ما یک روش خوشه‌بندی جدید را ارائه می‌کنیم که خوشه‌بندی سلسله‌مراتبی و K-means را ترکیب می‌کند شکل (۲). روش خوشه‌بندی پیشنهادی در Bow برای تکمیل فرآیند طبقه‌بندی تصویر به کار گرفته شده است. ابتدا، از نظر خوشه‌بندی سلسله‌مراتبی، یک شاخص اعتبار خوشه‌ای جدید برای تعیین اندازه واژگان، یعنی تعداد بهینه خوشه‌ها برای مجموعه‌ای از ویژگی‌های تصویر، معرفی می‌شود. پس از تعیین تعداد بهینه خوشه‌ها، مراکز خوشه اولیه بهینه با یک روش انحراف معیار بهبودیافته محاسبه می‌شوند. سپس بهترین تعداد خوشه‌ها و مراکز اولیه به K-means وارد می‌شود و نتیجه نهایی برای مراکز خوشه (یعنی واژگان) به دست می‌آید. در نهایت، تصاویر بر اساس بردارهای هیستوگرام که تصاویر با Bow را نشان می‌دهند، دسته‌بندی می‌شوند. به طور خلاصه، اندازه واژگان برای Bow به صورت تطبیقی تنظیم می‌شود تا خطاهای ایجاد شده توسط کمی‌سازی تصویر را کاهش دهد، که منجر به عملکرد بهتر دسته‌بندی تصویر می‌شود.



شکل ۱: فلوچارت سیستم پیشنهادی

2.1. مفاهیم اولیه

جدول ۱: مقایسه روش‌ها

روش‌ها	پیشنهاد	نتایج	مزیت	معایب
[۱۰]	شبکه‌ای برای تشخیص برجستگی پولیپ بر اساس تصاویر ایستا پولیپ پیشنهاد شد	صحت = ۹۲,۳۰٪ اندازه‌گیری ۹۲,۴۰٪	یک تکنیک برای تصاویر کولونوسکوپی بدون انعکاس بازتاب نور سفید با استفاده از یک مجموعه نوتروسوفیک تک ارزشی (SVNS).	عدم استفاده از معیارهای دیگر برای ارزیابی عملکرد
[۱۱]	برای پیش‌بینی پولیپ‌های کولورکتال با استفاده از نتایج کولونوسکوپی، از یک پلتفرم بدون کد و یادگیری عمیق استفاده شد. پلتفرم Neuro-T با توجه به CUI ^۵ کاربر پسند و عملکرد بالا استفاده شد	صحت = ۷۸,۵٪ یادآوری = ۷۸,۸٪ اندازه‌گیری = ۹۲,۴۰٪	نویسندگان از یک پلت فرم بدون کد و یادگیری عمیق برای پیش‌بینی پولیپ‌های کولورکتال با استفاده از نتایج کولونوسکوپی استفاده کردند.	این سیستم چندین طبقه‌بندی اشتباه از رگ‌های خونی طبیعی به عنوان پولیپ داشت.
[۱۲]	شناسایی پولیپ‌ها با استفاده از الگوریتم‌های یادگیری عمیق معرفی شد و به آندوسکوپی GI Genius V2 اضافه شد	دقت = ۸۴,۴٪ حساسیت: ۸۰,۷٪ ویژگی ۸۷,۳٪	نتایج نشان‌دهنده امکان‌سنجی حمایت از آندوسکوپیست‌های غیرمتخصص در دستیابی سیستماتیک به کارایی آندوسکوپیست‌ها در تعیین مشخصات نوری است.	این مدل نتوانست پولیپ‌های آدنوم و غیر آدنوم را طبقه‌بندی کند
[۱۳]	استخراج ویژگی‌ها با استفاده از CNN ^۶ , 3D, SVM از لحاظ زمانی و مکانی	دقت = ۹۸,۳٪ حساسیت = ۹۸٪	دقت بالا	داده‌های محدود، نیمه خودکار و عدم استفاده از معیارهای دیگر برای ارزیابی عملکرد

[۱۴]	استخراج ویژگی‌ها با استفاده از 3D,CNN از لحاظ زمانی و مکانی	دقت = ۸۶,۳٪ حساسیت = ۹۷,۲٪	آموزش سریع از لحاظ زمانی عدم استفاده از معیارهای دیگر برای ارزیابی عملکرد
[۱۵]	خوشه‌بندی نرم و خود محدود برای برچسب زدن مبتنی بر گروه		عدم استفاده از فنون یادگیری عمیق عدم بررسی سایر روش‌های موجود برای ترکیب ویژگی‌ها
[۱۶]	کاربرد یادگیری عمیق برای تشخیص مستقل و محلی سازی پولیپ‌های کولورکتال در آندوسکوپی کپسول کولون بی‌سیم	دقت = ۹۸,۰ حساسیت = ۹۸,۱ باتوجه به تعداد تصاویر ۱۱۳۰۰	ترکیب یادگیری انتقال داده، پیش پردازش، و بهبود داده‌ها از اطلاعات اضافی مانند محل ضایعه در طبقه‌بندی استفاده نکرده‌است از مقیاس ضایعه در طبقه‌بندی استفاده نکرده‌است

۲.۲. طرح مسئله

مجموعه داده‌ها را X در نظر می‌گیریم، فواصل بین جفت نمونه داده در یک ماتریس $D_{n \times n}$ را ذخیره می‌کنیم. از آنجاکه نمونه‌های داده توسط خوشه‌بندی سلسله‌مراتبی تجمیعی خوشه‌بندی می‌شود، یک درخت خوشه‌بندی سلسله‌مراتبی H حاوی سطوح n تشکیل می‌شود یعنی $H = \{H_1, H_2, H_3, \dots, H_n\}$ هر سطح H_k از H با n_i نمونه از C خوشه تشکیل شده‌است، فشردگی و جدایی برای اندازه‌گیری شباهت بین نمونه‌های درون خوشه بر اساس انحراف معیار است [۱۷، ۱۸].

$$dist(x_i, x_j) = \xi = \sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}} \quad (1)$$

تعریف ۱. هر سطح H_k در خوشه‌بندی سلسله‌مراتبی از مجموعه داده ای X از C خوشه، $\{G_1, G_2, G_3, \dots, G_c\}$ و هر خوشه دارای نمونه‌های n_i است.

$$i = \{1, 2, 3, \dots, c\}$$

فشردگی درون خوشه‌ای، $cd(i)$ برای خوشه i به صورت زیر تعریف می‌شود.

$$cd(i) = \max(w(x_m, x_n)), \quad x_m \in G_p, x_n \in G_n \quad (2)$$

درخت پوشا که توسط همه نمونه‌ها در خوشه i شکل می‌گیرد و $w(x_m, x_n)$ نشان‌دهنده وزن لبه در حداقل است.

تعریف ۲. برای جدایی بین خوشه‌ها، $sd(i)$ برای خوشه i به صورت زیر تعریف می‌شود.

$$sd(i) = \min(\min(dist(x_i, x_j))) \quad 1 \leq j \leq c, \quad x_i \in G_p, x_j \in G_j \quad (3)$$

$dist(x_i, x_j)$ نشان‌دهنده انحراف معیار بین نمونه x_i در خوشه i و نمونه x_j در خوشه j است.

تعریف ۳. شاخص اعتبار خوشه $CS(i)$ برای خوشه i نسبت فشردگی درون خوشه‌ای به جدایی بین خوشه‌ها است، یعنی:


$$cs(i) = \frac{cd(i)}{sd(i)} \quad (4)$$

شاخص CS اعتبار خوشه‌ای را برای نمونه‌های خوشه‌بندی شده در یک مجموعه داده منعکس می‌کند. مقادیر CS پایین‌تر نشان‌دهنده نتایج خوشه‌بندی بهتر است. برای یک مجموعه داده، می‌توانیم نتیجه خوشه‌بندی را با میانگین‌گیری شاخص CS برای همه خوشه‌ها تحلیل کنیم. میانگین کمتر نشان‌دهنده نتایج خوشه‌بندی بهتر برای مجموعه داده‌است.

ما $avg\ cs(k)$ برای میانگین شاخص‌های CS ، برای خوشه‌بندی k می‌نویسیم و کلاس‌ها و تعداد بهینه خوشه‌ها را به صورت k_{opt} نشان می‌دهیم.

$$avgcs(k) = \sum_{i=1}^k \frac{cs(i)}{k} \quad (5)$$


$$k_{opt} = \min(avgcs(k)), \quad 2 \leq k \leq n \quad (6)$$



شکل (۳): ساختار شبکه عصبی خود رمزنگار

۴.۲. شبکه باور عمیق


در نهایت، برای طبقه‌بندی ضایعات کولونوسکوپی، از یک طبقه‌بندی کننده DBN⁹ همان‌طور که در شکل (۴) آمده‌است استفاده کرده‌ایم. در DBN پیشنهادی از ۳ لایه RBM¹⁰ در ساختار استفاده می‌کنیم.



شکل ۴: ساختار شبکه باور عمیق

۳. چارچوب پیشنهادی HCBA

تاکنون فعالیت‌های زیادی در زمینه تشخیص ضایعات کولونوسکوپی انجام شده‌است. این روش‌ها عموماً مبتنی بر روش‌های استخراج ویژگی و حل مسائل در روش‌های قبلی و ارائه الگوریتم‌های جدید برای طبقه‌بندی می‌باشند. در برخی موارد نیز باید توجه شود. اما با توجه به اینکه روش‌های آموزشی نیاز به مقدار زیادی داده دارد، این روش‌ها همچنان جایگاه خوبی در این زمینه برای خود ایجاد کردند. علاوه بر این، روش‌های پیشنهادی به اندازه کافی دقت بالا ندارند و اگرچه می‌توان از آن‌ها برای کمک به پزشکان استفاده کرد، اما همیشه لازم است در تحقیقات آتی دقت تشخیص خودکار افزایش یابد و همچنین می‌توان روش‌هایی ابداع کرد که سلامت انسان را در برنگیرد. تشخیص ضایعات کولونوسکوپی با دقت قابل قبول با توجه به چالش‌ها را دربرگیرد، در این مقاله با هدف دستیابی به یک روش جدید استخراج ویژگی، تشخیص ضایعات در تصاویر کولونوسکوپی پیشنهاد شده‌است که از ترکیب روش‌های خوشه‌بندی سلسله‌مراتبی، کوله‌ای از ویژگی‌های بهینه‌شده و رمزگذار خودکار بهره می‌برد. در شکل (۵) آمده‌است.




شکل ۲: مروری بر رویکرد پیشنهادی

۳.۲. شبکه عصبی اتوانکدر

شبکه‌های عصبی مصنوعی عمیق اتوانکدر با ایجاد یک نگاشت دقیق از داده‌های ورودی برای خودشان و به حداقل رساندن خطای نمایش، فضای ویژگی جدیدی از داده‌ها را در لایه مرکزی شبکه عصبی اتوانکدر ایجاد می‌کنند که ابعاد کوچک‌تری نسبت به داده‌های ورودی دارد. سپس با استفاده از نیمه اول این شبکه یک انکودر ساخته می‌شود و با استفاده از نیمه دوم رمزگشا که امکان نگاشت داده‌ها به فضای ویژگی و بالعکس را فراهم می‌کند [۱۹-۲۱]. از این روش برای کاهش ابعاد استفاده می‌شود، ساخته می‌شود.

ما از این ایده برای کاهش فضای ویژگی و حذف نویز در چارچوب پیشنهادی HCBA استفاده کرده‌ایم. در شکل (۳) شبکه‌های مصنوعی خود رمزنگار را نشان می‌دهد.



شکل (۵): چارچوب پیشنهادی HCBA

۴. مجموعه داده‌ها یا بانک اطلاعاتی

مجموعه داده‌های که برای ارزیابی روش پیشنهادی استفاده کرده‌ایم، شامل ۷۶ فیلم کولونوسکوپی است که در [۲۲-۲۵] معرفی شده‌است. این مجموعه داده شامل ۱۵ آدنوم دندانه دار، ۲۱ ضایعه هیپرپلاستیک و ۴۰ ضایعه آدنوم است. فیلم‌ها با استفاده از NBI^{11} و WL^{12} ضبط شده‌اند و شامل کروم و آندوسکوپی نمی‌شوند. هر فیلم تقریباً بین ۳۰ ثانیه تا ۱ دقیقه طول می‌کشد و ضایعات را از دیدگاه‌های مختلف ضبط می‌کند و با استفاده از NBI و WL به آرامی در اطراف آن‌ها می‌چرخد. در هر ثانیه ضبط‌شده با استفاده از کولونوسکوپی شامل ۳۰ فریم 768×576 پیکسلی است. شکل (۶) برخی از تصاویر نمونه از این مجموعه داده را در سه کلاس به نام‌های آدنوم، هیپرپلاستیک و آدنوم دندانه دار نشان می‌دهد.



شکل (۶): تصاویر نمونه مجموعه داده

۵. نتایج تجربی

برای ارزیابی عملکرد روش پیشنهادی از دو بانک اطلاعاتی متفاوت که یکی از Kvasir-SEG با رزولوشن ۳۸۴*۲۸۸ و دیگری CVC-ClinicVideoDB با رزولوشن ۷۶۸*۵۷۶ برای ۲۶ تصویر از هر کدام از ضایعات در ساختار پیشنهادی اجرا شده‌است. نتایج حاصل در جدول (۲) نشان داده شده‌است.

جدول ۲: نتایج حاصل بر روی بانک اطلاعاتی متفاوت

Dataset	Acc	Pre	Rec	Sen
Kvasir-SEG	89.3	85.2	85.5	90.1
CVC-ClinicVideoDB	94.1	88.0	88.4	95.3

در این بخش ابتدا بهترین طبقه‌بندی‌کننده برای روش خود را بررسی کرده، سپس آن را با برخی از روش‌های معروف پیشرفته به نام‌های SFM¹⁶، BOW+SPM¹⁵، ILSVRC¹⁴، Places205، TBE¹³، SVM مقایسه کرده‌ایم. برای این منظور، ما ۴ معیار در هر کلاس را در نظر گرفته‌ایم: دقت (ACC²¹)، صحت (Per²²)، یادآوری (Rec²³) و حساسیت (Sen²⁴). هر نمونه یا فردی در واقعیت، متعلق به یکی از کلاس‌های مثبت یا منفی است و از سوی دیگر، از هر الگوریتمی که برای دسته‌بندی داده‌ها استفاده شود، در نهایت هر نمونه عضو یکی از این دو «دسته» (Class) «دسته‌بندی خواهد شد. بنابراین برای هر نمونه داده، یکی از چهار حالتی که در ادامه بیان شده، ممکن است اتفاق بیفتد.

نمونه عضو دسته مثبت باشد و عضو همین کلاس تشخیص داده شود مثبت صحیح یا (TP¹⁷)

نمونه عضو کلاس مثبت باشد و عضو کلاس منفی تشخیص داده شود منفی کاذب یا (FN¹⁸)

نمونه عضو کلاس منفی باشد و عضو همین کلاس تشخیص داده شود منفی صحیح یا (TN¹⁹)
در نهایت، نمونه عضو کلاس منفی باشد و عضو کلاس مثبت تشخیص داده شود مثبت کاذب یا (FP²⁰)

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} \quad (7)$$

$$Per = \frac{TP}{TP + FP} \quad (8)$$

$$Rec = \frac{TP}{TP + FN} \quad (9)$$

$$Sen = \frac{TN}{TN + FP} \quad (10)$$

در اولین مجموعه آزمایش‌ها، ما از ۴ معیار ارزیابی مختلف برای روش خود استفاده کرده‌ایم. سپس ما هر روش را با توجه به هر معیار خاص رتبه‌بندی کرده‌ایم. همان‌طور که در جدول (۳) نشان داده شده‌است، DBN بهترین طبقه‌بندی‌کننده برای روش ما در تمام معیارها بدون هیچگونه مبادله‌ای است. در مواقعی که دقت و صحت تشخیص یک دسته در مقایسه با دقت و صحت تشخیص کلی، اهمیت بیشتری دارد، ماتریس در هم ریختگی²⁵ استفاده می‌کنیم جدول (۴) ماتریس در هم ریختگی برای طبقه‌بندی‌های مختلف را نشان می‌دهد. روش‌های ارزیابی با ۴ معیار ارزیابی (دقت) ACC، (پیش‌بینی) Pre، (یادآوری) Rec و (حساسیت) Sen، همان‌طور که در جدول (۳) آمده‌است و ماتریس کانفوژن در جدول (۴) آمده‌است. متعاقباً، ما متوجه شدیم که روش پیشنهادی ما در همه معیارهای ارزیابی بهتر از سایر روش‌های مقایسه‌شده عمل می‌کند.

جدول ۳: بهترین نتایج متوسط طبقه‌بندی نوع پولیپ با استفاده از روش‌های مختلف

Method	ACC	Pre	Rec	Sen
BOW+SPM	71.5	39.8	34.0	79.7
ILSVRC	79.9	63.5	60.6	85.5
Places205	82.1	67.0	65.2	87.2
TBE	64.9	34.3	34.6	74.6
SVM	84.4	72.2	72.7	88.5
SFM	89.0	79.1	80.6	92.0
HCBA-DBN	93.0	87.1	87.6	94.8

جدول ۴: ماتریس سردرگمی، بهترین میانگین‌ها با استفاده از روش‌های مختلف

	BOW+SPM			ILSVRC			Places205			TBE			BVM			SFM		
	Hyp	Ser	Ade	Hyp	Ser	Ade	Hyp	Ser	Ade	Hyp	Ser	Ade	Hyp	Ser	Ade	Hyp	Ser	Ade
Hyp	2	0	19	14	0	7	15	1	5	14	0	7	8	3	10	18	0	3
Ser	1	0	14	1	6	8	1	7	7	1	6	8	2	2	11	2	9	4
Ade	0	3	37	4	6	30	3	6	31	4	6	30	12	7	21	7	4	29

۶. نتیجه‌گیری و کارهای آینده

ترکیب طبقه‌بندی‌کننده‌های مختلف، ممکن است منجر به بهبود روش‌ها شود.

در این مقاله، یک چارچوب یادگیری عمیق جدید به نام HCBA برای طبقه‌بندی ضایعات کولونوسکوپی پیشنهاد شده است که از چندین روش مانند خوشه‌بندی سلسله‌مراتبی بهینه‌شده، کوله‌ویژگی‌های بهینه‌شده و رمزگذار خودکار عمیق برای استخراج ویژگی و از یادگیری باور عمیق برای طبقه‌بندی تشکیل شده است. در نهایت با توجه به نتایج تجربی بر روی داده‌های مختلف علمی تأیید شده، عملکرد روش پیشنهادی در طبقه‌بندی تصاویر کولونوسکوپی با در نظر گرفتن معیار دقت به تصویر کشیده شده است. علی‌رغم فعالیت‌های متنوعی که تاکنون در تشخیص ضایعات کولونوسکوپی گزارش شده است، اما هنوز فعالیت‌های گسترده‌ای وجود دارد که می‌تواند در آینده مورد توجه محققان قرار گیرد. استفاده از روش‌های یادگیری ماشین، بینایی کامپیوتر، یادگیری عمیق و به‌ویژه استخراج ویژگی‌های عمیق، نقش مهمی در تحقیقات جاری دارد و توسعه چارچوب‌های نوآورانه دیگر، ترکیب روش‌های مختلف و بررسی معماری‌های ترکیبی ممکن است به نتایج قابل توجهی منجر شود. با استفاده از تکنیک‌های پردازش توزیع‌شده، هوش چندرشته‌ای و ازدحام می‌تواند جنبه‌های دیگری از پیشرفت‌های آینده باشد که ممکن است بر نیازهای استفاده‌های بلندپایه تأثیر بگذارد. با رشد روزافزون پیشرفت روزافزون در دوربین‌های پزشکی و تکنیک‌های تصویربرداری، کیفیت تصاویر و فیلم‌های ضبط‌شده نیز در کولونوسکوپی افزایش می‌یابد. بنابراین، توجه به این جنبه و توسعه تکنیک‌های پردازش تصویر و پردازش ویدئو ممکن است منجر به پیشرفت در روش‌های تشخیص کولونوسکوپی خودکار شود. پیشنهاد دیگری که می‌تواند مورد توجه قرار گیرد و ممکن است بر تحقیقات آتی تأثیر بگذارد، توجه به روش‌های شناخت انسانی و توسعه روش‌های شناختی است که در حوزه کولونوسکوپی سفارشی شده است. برای این منظور توجه به دانش پزشکان متخصص در تشخیص ضایعات کولونوسکوپی و تشخیص نوع پولیپ ضروری است. در نهایت، ما از جامعه پژوهشی دعوت می‌کنیم تا از حسگرهای مختلف استفاده کنند و از تکنیک‌های ترکیب داده‌ها و اطلاعات در سطوح مختلف مانند ترکیب حسگر و ترکیب تصمیم‌گیری‌ها استفاده کنند. علاوه بر این، استفاده از تکنیک‌های ترکیب تصمیم

۱۸. Stasiowski, M.J., et al., *Adequacy of anesthesia guidance for colonoscopy procedures*. Pharmaceuticals, 2021. **14**(5): p. 464.
۱۹. Wang, D., et al., *Afp-mask: Anchor-free polyp instance segmentation in colonoscopy*. IEEE Journal of Biomedical and Health Informatics, 2022. **26**(7): p. 2995-3006.
۲۰. Tian, Y., et al., *Detecting, localizing and classifying polyps from colonoscopy videos using deep learning*, in *Deep Learning for Medical Image Analysis*. 2024, Elsevier. p. 425-450.
۲۱. Hossain, M.S., et al., *Deeppoly: deep learning based polyps segmentation and classification for autonomous colonoscopy examination*. IEEE Access, 2023.
۲۲. Ma, C., et al. *A Real-Time Polyp Detection Framework for Colonoscopy Video*. in *Chinese Conference on Pattern Recognition and Computer Vision (PRCV)*. 2022. Springer.
۲۳. Nisha, J., V.P. Gopi, and P. Palanisamy, *Automated colorectal polyp detection based on image enhancement and dual-path CNN architecture*. Biomedical Signal Processing and Control, 2022. **73**: p. 10346.
۲۴. Carrinho, P. and G. Falcao, *Highly accurate and fast YOLOv4-Based polyp detection*. Expert Systems with Applications, 2023. **232**: p. 120834.
۲۵. Krenzer, A., et al., *A real-time polyp-detection system with clinical application in colonoscopy using deep convolutional neural networks*. Journal of imaging, 2023. **9**(2): p. 26.
۱. H. N. Mahdi Hariri, "Improve the Quality of Mammogram Images by Image Processing Techniques," *Intelligent Multimedia processing and Communication Systems (IMPCS)*, vol. 3, no. 1, pp. 57-69, 2022.)
۲. Farhadi, et al., "Unsupervised Domain Adaptation for image Classification Based on Deep Neural Networks" *Intelligent Multimedia processing and Communication Systems (IMPCS)*, vol.4, no. 1, pp.27-37, 2023.
۳. Jheng, Y.-C., et al., *A novel machine learning-based algorithm to identify and classify lesions and anatomical landmarks in colonoscopy images*. Surgical Endoscopy, 2022. **36**: p. 640-6.
۴. Zhang, R., et al., *Automatic detection and classification of colorectal polyps by transferring low-level CNN features from nonmedical domain*. IEEE journal of biomedical and health informatics, 2016. **21**(1): p. 41-47.
۵. ELKarazle, K., et al., *Detection of colorectal polyps from colonoscopy using machine learning: A survey on modern techniques*. Sensors, 2023. **23**(3): p. 1225.
۶. Wimmer, G., et al., *Fisher encoding of convolutional neural network features for endoscopic image classification*. Journal of Medical Imaging, 2018. **5**(3): p. 034504-034504.
۷. Guo, Z., et al. *Automatic polyp recognition from colonoscopy images based on bag of visual words*. in *2017 IEEE 8th International Conference on Awareness Science and Technology (iCAST)*. 2017. IEEE.
۸. Saluja, K., et al. *Efficient bag of deep visual words based features to classify CRC images for colorectal tumor diagnosis*. in *2022 2nd international conference on advance computing and innovative technologies in engineering (ICACITE)*. 2022. IEEE.
۹. Nawarathna, R., et al., *Abnormal image detection in endoscopy videos using a filter bank and local binary patterns*. Neurocomputing, 2014. **144**: p. 70-91.
۱۰. Cherubini, A., *A novel AI device for real-time optical characterization of colorectal polyps*.
۱۱. Gong, E.J., et al., *No-code platform-based deep-learning models for prediction of colorectal polyp histology from white-light endoscopy images: development and performance verification*. Journal of Personalized Medicine, 2022. **12**(6): p. 963.
۱۲. Biffi, C., et al., *A novel AI device for real-time optical characterization of colorectal polyps*. NPJ digital medicine, 2022. **5**(1): p. 84.
۱۳. Zhou, J., et al., *Feature fusion for diagnosis of atypical hepatocellular carcinoma in contrast-enhanced ultrasound*. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2021. **69**(1): p. 114-123.
۱۴. Chen, C., et al., *Domain knowledge powered deep learning for breast cancer diagnosis based on contrast-enhanced ultrasound videos*. IEEE Transactions on Medical Imaging, 2021. **40**(9): p. 2439-2451.
۱۵. Harada, S., et al., *Soft and self constrained clustering for group-based labeling*. Medical Image Analysis, 2021. **72**: p. 102097.
۱۶. Nadimi, E.S., et al., *Application of deep learning for autonomous detection and localization of colorectal polyps in wireless colon capsule endoscopy*. Computers & Electrical Engineering, 2020. **81**: p. 106531.
۱۷. Huang, H. and Y. Ma, *A hybrid clustering approach for bag-of-words image categorization*. Mathematical Problems in Engineering, 2019. **2019**: p. 1-11.

۱. hierarchical clustering bag of features auto-encoder
2. Colorectal cancer
۳. Bag of words
4. Support vector Machine
5. Character User Interface
6. Convolution Neural Network
7. Support vector machine
8. Bag of features
9. Deep Belief Networks
10. Restricted Boltzmann Machine
11. Narrow Band Imaging
12. White light
13. TCF-binding elements
14. ImageNet Large Scale Visual Recognition Challenge
15. spatial pyramid matching
16. structure from motion
17. True Positive
18. False Negative
19. True Negative
20. False Positive
21. Accuracy
22. Prediction
23. Recall
24. Sensitivity
25. Confusion Matrix