



سنجش از دور

GIS ایران



سنجش از دور و GIS ایران
سال پانزدهم، شماره سوم، پاییز ۱۴۰۲
Vol. ۱۵, No. ۳, Autumn ۲۰۲۳
Iranian Remote Sensing &
GIS

۴۱-۶۰

مقاله پژوهشی

بهبود طبقه‌بندی تصاویر ابرطیفی با استفاده از مدل ترکیبی شبکه‌های کپسول و درخت تصمیم تقویتی

پویا احمدی^{۱*}، طیبه مناقبی^۲، حمید عبادی^۳، بهنام اصغری بیرامی^۴

- دانشجوی دکتری سنجش از دور، گروه مهندسی نقشه‌برداری و اطلاعات مکانی، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران
- استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشگاه تهران، تهران، ایران
- استاد گروه مهندسی فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران
- دکتری سنجش از دور، گروه مهندسی فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

*تاریخ دریافت مقاله: ۱۴۰۰/۰۸/۱۰

تاریخ پذیرش مقاله: ۱۴۰۰/۱۰/۲۹

چکیده

با گسترش دانش سنجش از دور، استفاده از تصاویر هایپرسپکتروال روزبه روز افزایش و عمومیت می‌یابد. طبقه‌بندی یکی از محبوب‌ترین موضوعات در سنجش از دور ابرطیفی است. طی دو دهه گذشته، روش‌های بسیاری برای مقابله با مشکل طبقه‌بندی داده‌های هایپرسپکتروال پیشنهاد شده است. در پژوهش حاضر، ساختاری مبتنی بر یادگیری شبکه‌های کپسول برای طبقه‌بندی تصاویر ابرطیفی به کار رفته است؛ به‌گونه‌ای که ساختار شبکه بتواند، با استفاده از یک لایه کانولوشنی و یک لایه کپسول، بهترین حالت تولید ویژگی‌ها را داشته باشد و در عین حال از بیش برآرash شبکه روی نمونه‌های آموزشی جلوگیری کند. نتایج به دست آمده نشان از کیفیت بالای ویژگی‌های تولیدی در ساختار پیشنهادی دارد. در اینجا بهبود دقت طبقه‌بندی، رویکرد استخراج ویژگی از طریق شبکه طراحی شده و طبقه‌بندی با استفاده از الگوریتم درخت تقویتی XGBoost، با روش طبقه‌بندی از طریق شبکه عمیق سراسری مقایسه شد تا، علاوه بر بررسی و کیفیت سنجی ویژگی‌های عمیق برداری تولیدی به روش پیشنهادی در طبقه‌بندی کننده‌های گوناگون، میزان توانایی شبکه‌های عمیق سراسری نیز، در کاربرد طبقه‌بندی، بررسی شود. رویکرد کپسول پیشنهادی شامل سه لایه اصلی است: ۱) با کپسول‌هایی به اندازه ۸ و ۳۲ فیلتر 9×9 و ۲) گام حرکتی 2×2 و ۳) دارای ده کپسول شانزده بعدی؛^۳ لایه تمامًا متصل. نتایج بررسی دو رویکرد برای شبکه عمیق و نیز ترکیب شبکه‌های کپسول با الگوریتم درخت تقویتی XGBoost مقایسه شد. رویکردهایی همچون RF-200، GRU-Pretanh، LSTM، GRU، و GRU-MQایسه با دقت ۹۷٪/۵ روی داده‌های Indian Pines نیز، شامل شانزده کلاس متفاوت، به کار رفت. با استفاده از روش پیشنهادی ترکیبی، طبقه‌بندی تصاویر با دقت ۹۹٪ روی داده‌های آموزش و دقت ۹۷٪ روی داده‌های تست انجام می‌شود.

کلید واژه‌ها: طبقه‌بندی، تصاویر ابرطیفی، شبکه‌های کپسول، درخت تصمیم تقویتی، مدل ترکیبی.

* نویسنده مکاتبه‌کننده: تهران، خیابان ولی‌عصر، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، تلفن: ۰۹۱۸۵۳۶۳۶۰۴.

Email: ahmadi.pouya@ut.ac.ir

https://orcid.org/0009-0001-7308-1054

https://dx.doi.org/10.48308/gisj.2023.102347



Copyright: © ۲۰۲۳ by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

۱- مقدمه

سنجنده‌های ابرطیفی^۱ نوع خاصی از سنجنده‌های طیف‌سنجی‌اند که پهنه‌ای باند مورد نظر را به صدها باند پاریک مجاور هم تقسیم می‌کنند. در دسترس قرار گرفتن سنجنده‌هایی، با توان تفکیک طیفی^۲ بالا و تعداد باند زیاد، دستیابی به جزئیات بیشتر در مورد کلاس‌ها را امکان‌پذیر کرده و باعث افزایش دقت و اعتبار طبقه‌بندی شده است. با توجه به تعداد بسیار باندها، تصاویر ابرطیفی کاربردهای فراوانی می‌یابند (Ghassemian et al., 2003). استفاده از تصاویر ابرطیفی در کاربردهایی مانند کشاورزی و برآورد دقیق محصولات، جنگل‌داری و مطالعه پوشش‌های گیاهی، مطالعه منابع آب و شناسایی آводگی‌ها، اکتشاف منابع طبیعی و معدنی، زمین‌شناسی و نفت، کاربردهای صلح‌آمیز همچون شناسایی و پاکسازی مناطق جنگی آلوده، کاربردهای نظامی و شناسایی ادوات استارتارشده نتایج مطلوبی به دست آورده است.

مهم‌ترین چالش، در پردازش تصاویر ابرطیفی، اندک‌بودن تعداد نقاط آموزشی به نسبت تعداد باندهای تصویر است. در واقع، مسئله این است که اگر تعداد نقاط آموزشی به نسبت تعداد باندهای داده، کمتر از یک‌صد نمونه به‌ازای هر کلاس باشد، با افزایش تعداد باندها، خطای تخمین پارامترهای طبقه‌بندی کننده بیشتر می‌شود (Keshavarz & Ghasemiany, 2005). با توجه به این مسئله، یک راه حل برای بهبود عملکرد طبقه‌بندی کننده‌های آماری، کاهش فضای ویژگی پیش‌آز طبقه‌بندی این تصاویر است که به افزایش نسبت تعداد نقاط آموزشی به تعداد ویژگی منجر می‌شود. برای این منظور، دو دسته‌الگوریتم به کار می‌رود: الگوریتم‌های انتخاب باند^۳ و الگوریتم‌های کاهش ابعاد فضای ویژگی^۴. در سال‌های اخیر، الگوریتم‌های متعددی برای استخراج ویژگی مطرح و استفاده شده‌اند. استخراج ویژگی با مرز تصمیم‌گیری^۵ (Lee & Landgrebe, 1993)، نگاشت جستجوگر (Jimenez & Landgrebe, 1999) موجک^۶ (Kaewpijit et al., 2003)، تحلیل مؤلفه‌های

اصلی^۷، تحلیل مؤلفه‌های مستقل^۸ (Du et al., 2008) از جمله الگوریتم‌هایی‌اند که به منظور کاهش ابعاد فضای ویژگی و بهبود طبقه‌بندی تصاویر ابرطیفی به کار رفته‌اند. بین سال‌های ۱۹۹۸ تا ۲۰۰۰، گوالتیری و چتری^۹ (۲۰۰۰) کارآیی ماشین‌های بردار پشتیبان^{۱۰} در طبقه‌بندی تصاویر ابرطیفی را بررسی کردند و نشان دادند این روش امکان آنالیز تصاویر ابرطیفی را در فضای ویژگی با ابعاد زیاد و بدون نیاز به فرایند کاهش ویژگی، فراهم می‌کند. ملگانی و بروزونه^{۱۱} (۲۰۰۴) نیز کارآیی ماشین‌های بردار پشتیبان در طبقه‌بندی تصاویر ابرطیفی را مطالعه کردند. لیانگ^{۱۲} و همکاران (۲۰۰۵) ماشین‌بردار رگرسیون^{۱۳} را برای طبقه‌بندی تصاویر ابرطیفی پیشنهاد دادند. از دید آنها، پیش‌بینی‌های احتمالی، تخمین اتوماتیک پارامترها و امکان انتخاب هسته‌های اختیاری از مزایای RVM بر SVM است. فوکوناگا و اسبر^{۱۴} (۲۰۰۸) مشکل اندک‌بودن تعداد نمونه‌های آموزشی در طبقه‌بندی تصاویر ابرطیفی را بررسی و نشان دادند تعداد نقاط آموزشی مورد نیاز برای طبقه‌بندی کننده‌های خطی، متناسب با افزایش تعداد باندها، به صورت خطی افزایش می‌باشد. بروزونه و همکاران (۲۰۰۶) روش^{۱۵} TSVM را برای طبقه‌بندی داده‌هایی مطرح کردند که نمونه‌های آموزشی آنها کاملاً مورد اعتماد نیستند. فاول^{۱۶} و همکاران (۲۰۰۷) استفاده

-
1. Hyperspectral
 2. Spectral Resolution
 3. Band Selection
 4. Dimension reduction
 5. Feature Extraction Based on Decision Boundaries
 6. Automatic Wavelet Spectral Analysis
 7. Principal Component Analysis
 8. Independent Component Analysis
 9. Gualtieri & Chetri
 10. Suport Vector Machin
 11. Melgani & Bruzzone
 12. Liyang
 13. Regression Vector Machin
 14. Fukunaga & Sber
 15. Transductive SVM
 16. Fauvel

هو^۹ و همکاران (۲۰۱۵) شبکه کانولوشنی عصبی پنج‌لایه‌ای برای داده‌های ابرطیفی ارائه دادند. در این روش، از اطلاعات طیفی بدون درنظرگرفتن اطلاعات مکانی استفاده شد. یو^{۱۰} و همکاران (۲۰۱۹) شبکه کانولوشنی کپسول را برای تشخیص وسایل نقلیه، با استفاده از تصاویر سنجش از دور پیشنهاد دادند. در رویکرد پیشنهادی، تصویر سنجش از دور با استفاده از استراتژی قطعه‌بندی سوپرپیکسل^{۱۱} به چندین تکه^{۱۲} تقسیم شد و به صورت ورودی برای تشخیص وجود وسایل نقلیه به کار رفت. گائو^{۱۳} و همکاران (۲۰۲۰)، رویکرد شبکه عصبی کپسول چندمقایسه را برای تشخیص تغییرات از تصاویر رادار با دهانه مصنوعی^{۱۴} طراحی کردند. در این مطالعه، مدل کپسول صرفاً برای مشخص کردن رابطه بین ویژگی‌ها استفاده شد و یک انطباقی کانولوشن، برای افزایش قدرت شناسایی رابطه بین ویژگی‌ها به کار رفت. در ادامه، درمورد شبکه‌های عصبی کانولوشن سه‌بعدی (CNN)، به‌منظور طبقه‌بندی تصاویر ابرطیفی با استفاده همزمان از ویژگی‌های طیفی و مکانی، بحث و بررسی شد و درنهایت مدل شبکه کپسول سه‌بعدی، با استفاده از کپسول‌های طیفی-مکانی، جایگزین Paoletti et al., 2018; شو^{۱۵} و همکاران (۲۰۲۰) یک شبکه عصبی کپسول با شبکه کانولوشنی اکتاو^{۱۶} را برای طبقه‌بندی

همزمان از ویژگی‌های طیفی و مکانی در طبقه‌بندی تصاویر ابرطیفی به‌روش SVM را بررسی کردند. نتایج این بررسی روی تصویر ROSIS مؤید افزایش کم‌دقیق طبقه‌بندی، بدون کاهش ابعاد فضای ویژگی و بهبود چشمگیر دقت، با استفاده از الگوریتم کاهش ابعاد فضای ویژگی بود. اکبری^۱ و همکاران (۲۰۱۶) با استخراج اطلاعات از پیکسل‌های همسایگی در فرایند انتخاب نمونه‌ها، کوشیدند دقت الگوریتم‌های طبقه‌بندی طیفی-مکانی در تصاویر ابرطیفی را بهبود ببخشند. غفاری^۲ و همکاران (۲۰۱۶) انتخاب باندهای بهینه به‌منظور بهبود جداسازی طیفی تصاویر ابرطیفی را بررسی کردند. آنها روش جدیدی برای انتخاب باند متتشکل از اولویت‌بندی‌ها، در راستای کاهش اثر تغییرپذیری طیفی و کاهش همبستگی بین باندها مطرح کردند و نشان دادند می‌توان به حذف مؤثر بسیاری از باندهای غیرضروری اقدام کرد.

در چند سال اخیر، شبکه‌های عصبی کانولوشن (CNN)^۳ به‌منزله روش منتخب بر مبنای یادگیری عمیق^۴ برای تولید ویژگی از تصاویر، درنظر گرفته شده است زیرا ساختاری مناسب برای کار با تصاویر دارد (Ghamisi et al., 2017). نکته مهم در این زمینه تعیین ساختار شبکه متناسب با داده‌های ورودی به شبکه است. لؤٹو^۵ (۲۰۱۸) تلاش داشت از شبکه‌های کپسول^۶ استفاده کند؛ وی رویکردي مبتنی بر CNN را با مدل مبتنی بر CapsNet مقایسه کرد. نتایج این مطالعه مؤید آن بود که روش مبتنی بر CapsNet مزایای موردنظر را فراهم نمی‌کند و هیچ بینش عمیقی نشان داده نشده است. وانگ^۷ و همکاران (۲۰۱۸) یک ساختار CapsNet براساس شبکه‌های عصبی بازگشتی (RNN)^۸ را به‌منظور تجزیه و تحلیل احساسات و عواطف مطرح کردند. در پژوهشی دیگر، شبکه‌های عصبی کپسول این‌گونه تعریف شد که نوع کاملاً جدیدی از معماری یادگیری عمیق را نشان می‌دهد که قصد دارد بر محدودیت‌ها و اشکالات CNN، همچون ازدست‌رفتن اطلاعات در مرحله Max Pooling غلبه کند (Sabour et al., 2017).

-
1. Akbari
 2. Ghaffari
 3. Convolution Neural Networks
 4. Deep Learning
 5. Luo, Zou
 6. CapsNet
 7. Wang
 8. Recurrent Neural Network
 9. Hu
 10. Yu
 11. Superpixel Segmentation Strategy
 12. Patch
 13. Gao
 14. Synthetic Aperture Radar
 15. Xu
 16. Octave Convolution

۲- داده‌ها و معرفی منطقه مورد مطالعه

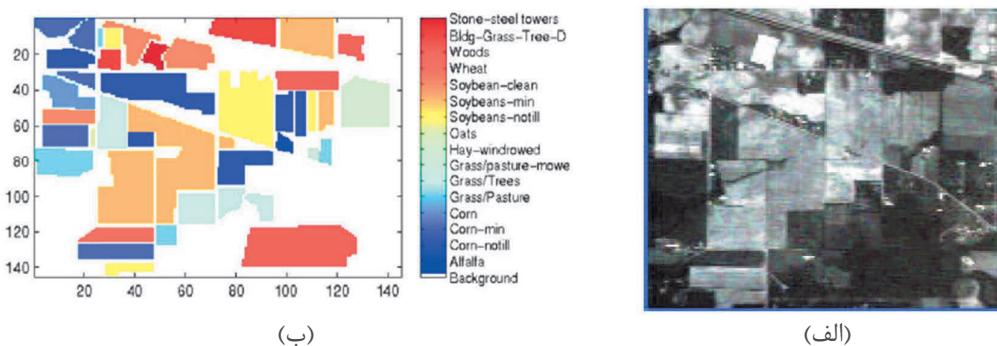
تصاویر ابرطیفی در جامعه سنجش از دور، بهمنظور استفاده از ترکیب صدھا کانال طیفی در صحنه‌ای واحد، کاربرد گستردۀ ای دارند. طبقه‌بندی این تصاویر، به دلیل ماهیت پیچیده صحنه تصویر (مثلًاً داده‌های بسیار، پیکسل‌های مختلط و نمونه‌های آموزشی محدود)، مسئله‌ای پرچالش به شمار می‌آید و به همین دلیل تلاش‌های بسیاری برای پرداختن به آن انجام شده است. مجموعه داده‌های مورد استفاده، در این تحقیق، داده‌های جامع از زمین‌های پایینس در امریکا است که در ژوئن سال ۱۹۹۲ جمع‌آوری شده‌اند و شانزده کلاس را شامل می‌شوند که اغلب مربوط به پوشش زمینی‌اند (Ghassemian et al., 2003). در شکل ۱، این تصویر به همراه نقشه کاربری نشان داده شده است.

این مجموعه داده، بهمنزلۀ داده‌های پایه، برای ارائه مدل‌های طبقه‌بندی در بیشتر تحقیقات بررسی و استفاده شده‌اند. داده‌های این مجموعه این امکان را فراهم می‌کند که مقایسات جامعی از رویکردها، در تحقیق پیش رو، انجام شود. ابعاد این تصاویر ابرطیفی ۱۴۵×۱۴۵ و ۱۴۵×۲۰۰ است و اطلاعات هریک از دسته‌ها در

جدول ۱ و پوشش زمینی در شکل ۷ آمده است.

تصاویر ابرطیفی، طراحی کردن. در رویکرد طراحی شده، شبکه کانولوشنی معماری‌های موازی را سازگار و ویژگی‌های تصاویر را استخراج کرد. در این پژوهش، از ساختاری مبتنی بر یادگیری عمیق برای طبقه‌بندی تصاویر ابرطیفی استفاده شده است؛ به گونه‌ای که بتوان از ویژگی‌های معماری شبکه کپسول برای رفع معایب شبکه کانولوشنی، بهمنظور طبقه‌بندی تصاویر ابرطیفی و مقایسه نتایج این دو شبکه، استفاده کرد. در این مطالعه، با توجه به اینکه خروجی‌های شبکه کپسول به صورت بردار است، می‌توان ارتباط بین ویژگی‌های استخراجی را از طریق اندازه و جهت بردار، استخراج کرد؛ هریک از المان‌های بردار خروجی نشان‌دهنده توصیف خاصی از موجودیت تصویر است. رویکرد استخراج ویژگی، از طریق شبکه طراحی شده و طبقه‌بندی با استفاده از الگوریتم درخت تقویتی^۱ XGBoost با روش طبقه‌بندی از طریق شبکه عمیق سراسری مقایسه شده است تا، علاوه بر بررسی و کیفیت‌سنجی ویژگی‌های عمیق تولیدی به روش پیشنهادی در طبقه‌بندی کننده‌های متفاوت، میزان توانایی شبکه‌های عمیق سراسری نیز در کاربرد طبقه‌بندی، بررسی شود.

1. Xtreme Gradient Boosting



شکل ۱. ترکیب رنگی تصویر Indian Pines (الف); نقشه کاربری تصویر Indian Pines (ب)

تکنیک‌های یادگیری ماشین^۱ سنتی داشته است (Xu et al., 2018; Li, 2018). تفاوت ساختار شبکه‌های عصبی کانولوشنی که یکی از تکنیک‌های یادگیری عمیق محسوب می‌شوند، با شبکه‌های عصبی مصنوعی، محدودیت‌های اعمال شده در ارتباطات بین نورون‌ها در شبکه‌های کانولوشنی است. اگرچه این محدودیت‌ها عمومیت شبکه‌های کانولوشن را در مواجهه با داده‌های متنوع کاهش می‌دهد، ساختار این شبکه‌ها با توجه به قیود خاص آن، کاملاً منطبق و مناسب با ساختار تصاویر است. همچنین در شبکه‌های عصبی کپسول، با توجه به اینکه خروجی شبکه بردار است، می‌توان ارتباط بین ویژگی‌های استخراجی از شبکه‌های کانولوشنی را در نظر گرفت (Maggiori et al., 2016).

برای اساس، پژوهش حاضر بر فرایندهای تولید ویژگی‌های عمیق و طبقه‌بندی برمبنای آن مرکز شده است؛ در ادامه، جزئیات روش‌های به کار رفته در هر مرحله را بیان می‌کنیم.

۳-۲- شبکه‌های عصبی کانولوشنی
شبکه‌های عصبی کانولوشنی نوعی از شبکه‌های رو به جلو هستند که اولین بار، برای تشخیص تصویر به کار گرفتند. این شبکه‌ها از مهم‌ترین و پرکاربردترین

به منظور جلوگیری از ایجاد مشکل در تحلیل‌های عددی، مقادیر باندها نرمال‌سازی شد. برای نرمال‌سازی داده‌ها، از دو روش بهره گرفته شد؛ در روش تمامی باندها، مقدار درجهٔ خاکستری هر پیکسل در هر بند بر جمع مقادیر درجات خاکستری آن پیکسل در تمامی باندها تقسیم می‌شود و در روش تک‌باند نیز، مقدار درجهٔ خاکستری هر پیکسل در هر بند بر جمع مقادیر درجات خاکستری تمامی پیکسل‌های آن بند تقسیم می‌شود. تأثیر روش نرمالیزه کردن در نتایج طبقه‌بندی با استفاده از هستهٔ گاوسین بررسی و نشان داده شد، با هر دو روش، نتایج مشابهی به دست می‌آید؛ از این‌رو در این پژوهش، روش تمامی باندها استفاده شد.

۳- مبانی نظری

۱- رویکردهای مبتنی بر یادگیری عمیق

در چند دههٔ اخیر، با افزایش قدرت پردازنده‌های گرافیکی و در دسترس بودن مجموعه‌های جیجیم داده‌ها، استفاده از تکنیک‌های یادگیری عمیق، در بسیاری از شاخه‌های مهندسی و کاربردی، مطرح شده است. به موازات آن حوزه‌های پردازش تصویر نیز تحت تأثیر قرار گرفته‌اند؛ به گونه‌ای که در بسیاری از کاربردهای پردازش تصویر، یادگیری عمیق کارآیی بیشتری از

جدول ۱. پوشش زمینی کلاس‌های تصویر

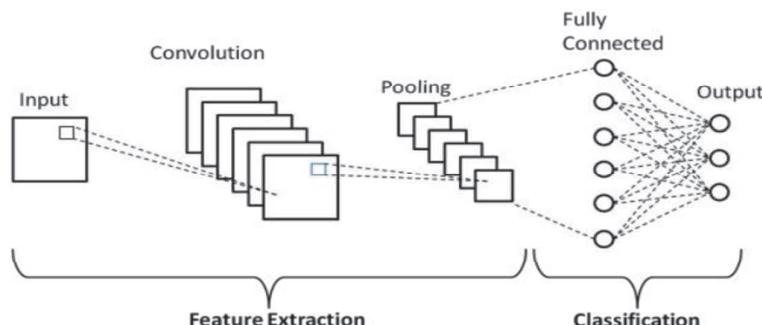
شماره کلاس	تعداد پیکسل‌های کلاس در تصویر	پوشش زمینی کلاس	شماره کلاس	تعداد پیکسل‌های کلاس در تصویر	پوشش زمینی کلاس
۱	۵۴	بیونجه	۹	۲۰	جو دوسر
۲	۱۴۳۴	ذرت بدون شخم	۱۰	۹۶۸	سویای بدون شخم
۳	۸۳۴	ذرت کم‌شخم	۱۱	۲۴۶۸	سویای کم‌شخم
۴	۲۳۴	ذرت	۱۲	۶۱۴	سویای شخم‌زده
۵	۴۹۷	سبزه/ چمن‌زار	۱۳	۲۱۲	گندم
۶	۷۴۷	سبزه/ درختان	۱۴	۱۲۹۴	بیشه
۷	۲۶	سبزه/ چمن‌زار/ کوتاه	۱۵	۳۸۰	ساختمان/ سبزه
۸	۴۸۹	کاه و خاشاک	۱۶	۹۵	سنگ/ برج

(بیشترین داده‌ها متعلق به کلاس‌های ۱۱، ۱۰ و ۱۴ است)

- واحد اصلاح شده خطی (ReLU): مزیت اصلی استفاده از این تابع بر سایر توابع این است که هم زمان تمامی نورون‌ها را فعال نمی‌کند؛ بدین معنی که در یک زمان، فقط نورون‌های اندکی فعال می‌شوند و این باعث می‌شود شبکه به صورت تنک در باید و ویژگی‌های مهمی را فراهم‌گیرد؛
- لایه Dropout: اصطلاح «Dropout» به واحد‌های حذف شده (پنهان و آشکار) در شبکه عصبی اشاره دارد. این تکنیک را اولین بار جفری هینتون^۳ به کار برد (Bengio & Ian, 2015). Dropout در واقع از تکنیک‌های Regularization تصادفی است که طی هر انتشار رو به جلوی واحدها در لایه‌های پنهان یا آشکار، به صورت تصادفی یا موقت، مطابق یک بردار از متغیرهای تصادفی برنولی بیرون اندخته می‌شوند.
- لایه تماماً متصل: پس از آخرین لایه تجمعی، لایه تماماً متصل^۴ وجود دارد که ویژگی‌های میانی دو بعدی را به بردارهای یک بعدی، به منظور ادامه فرایند یادگیری، نگاشت می‌کند. از سویی، می‌توان گفت این لایه وظیفه محاسبه امتیاز دسته‌های طبقه‌ها را بر عهده دارد. لایه تماماً متصل به ما این امکان را می‌دهد که خروجی شبکه را در قالب برداری با اندازه ثابت ارائه دهیم.

روش‌های یادگیری عمیق، به ویژه در زمینه استخراج ویژگی و طبقه‌بندی تصاویر سنجش از دور، محسوب می‌شوند (LeCun et al., 2015). شبکه‌های عصبی کانولوشنی لایه‌های متعددی دارند که هر یک از لایه‌ها یک سطح از ویژگی را نمایندگی می‌کنند. این سطوح متفاوت نمایندگی با کنار هم قرار گرفتن ساختارهای ساده و غیرخطی به دست می‌آیند و هر یک از ساختارها ویژگی‌ها را به سطح انتزاع بالاتری ارتقا خواهد داد. شبکه کانولوشنی چهار مشخصه اصلی دارند: ارتباطات محلی، اشتراک وزن، لایه ادغام و مشخصه عمق که این مشخصات آن را از سایر روش‌ها متمایز می‌سازد. ساختار شبکه‌های کانولوشنی بخش‌های متوالی زیر را شامل می‌شود (Bengio & Ian, 2015):

- لایه کانولوشنی: این لایه، به منظور استخراج ویژگی‌های ضمنی از ماتریس ورودی، از فیلترهای گوناگونی استفاده می‌کند؛
- لایه تجمعی: این گونه معمول است که به صورت دوره‌ای، پس از هر لایه کانولوشن، برای کاهش اندازه ویژگی‌های میانی از یک لایه تجمعی استفاده شود. کاهش حجم پارامترها سبب کاهش محاسبات شبکه می‌شود و از این‌رو می‌توان بیش‌برازش^۱ را کنترل کرد؛



شکل ۲. معماری شبکه‌های کانولوشنی

منبع: LeCun et al., 2015

-
1. Overfitting
 2. Rectified Linear Unit
 3. Geoffrey Everest Hinton
 4. Fully Connected Layer

اینکه شبکه دچار اشتباه نشود، باید شبکه کانولوشنی با تصاویری از چرخش‌های متفاوت آموزش بیینند؛ این کار نیازمند داده‌های آموزشی بسیار زیادی است. با توجه به معایب بیان شده، استفاده از شبکه کپسول برای رفع معایب شبکه‌های کانولوشنی پیشنهاد می‌شود.

۳-۳- شبکه کپسول

شبکه‌های عصبی کپسول روش کاملاً جدیدی از عماری یادگیری عمیق است که سعی دارد بر محدودیت‌ها و اشکالات شبکه کانولوشنی غلبه کند (Xue et al., 2015). خروجی‌های شبکه عصبی کپسول در مجموعه‌های از کپسول‌ها، به صورت بردار ذخیره

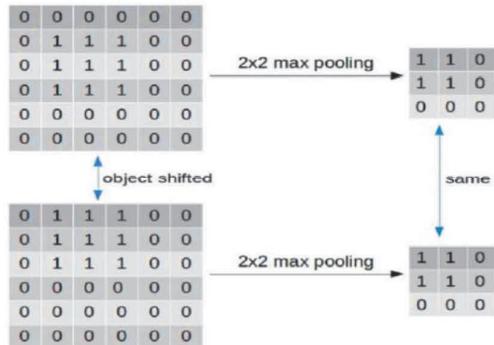


شکل ۴. تصویر چهره‌ای که نهوده قرارگیری و ابعاد اجزای آن تغییر یافته است

می‌شوند و کپسول‌ها محاسبات پیچیده‌ای را روی این ویژگی‌ها انجام می‌دهند؛ سپس نتایج این محاسبات را به بردار کوچکی که حاوی اطلاعات بسیار مفیدی است، نگاشت می‌کنند. از این‌رو می‌توان ارتباط بین ویژگی‌های استخراجی شبکه را از طریق اندازه و جهت بردار، حفظ کرد و هریک از المان‌های بردار خروجی نشان‌دهنده توصیفی خاص از تصویر است (Candemir et al., 2014). یکی از مهم‌ترین تفاوت‌های شبکه‌های کپسول با شبکه‌های کانولوشنی در شکل ویژگی‌های استخراج شده است که به صورت برداری با ویژگی اندازه و جهت است؛ در حالی که در شبکه‌های کانولوشنی و

۳-۲-۱- مزایای شبکه کانولوشنی

مهم‌ترین مزیت استفاده از شبکه عصبی کانولوشن توانایی آن در استخراج خودکار ویژگی‌های تصاویر، با استفاده از مفهوم یادگیری عمیق است. همچنین استفاده از لایه pooling در شبکه‌های کانولوشنی باعث کاهش حجم محاسبات می‌شود و تضمین می‌کند، حتی زمانی که ویژگی‌های استخراجی دچار تغییرات و چرخش‌های کوچکی شوند، خروجی شبکه همچنان یکسان بماند. این ویژگی در طبقه‌بندی اهمیت بسیاری دارد. استفاده از max pooling نیز باعث می‌شود، با تغییرات اندک و جابه‌جایی بسیار کم در تصویر، شبکه همچنان قادر به شناسایی شیء مورد نظر باشد (شکل ۳).



شکل ۳. مزیت استفاده از لایه pooling در شبکه‌های کانولوشنی

منبع: Bengio & Ian, 2015

۳-۲-۲- معایب شبکه کانولوشنی

یکی از کاربردهای شبکه‌های کانولوشنی استخراج ویژگی‌ها برای طبقه‌بندی تصاویر است اما، زمانی که نمونه معرفی شده به مدل آموزش دیده CNN تغییراتی داشته باشد، شبکه در تشخیص این تغییرات دچار مشکل می‌شود. دلیل این مشکل استفاده از لایه Max-pooling است که فضای ارتباطی بین ویژگی‌ها را از بین می‌برد. در شکل ۴، تصویری از چهره درهم‌ریخته و غیرواقعی ارائه شده است که شبکه‌های CNN به‌اشتباه، آن را چهره تشخیص می‌دهند زیرا ارتباط بین ویژگی‌های استخراجی و ابعاد ویژگی‌ها را در نظر نمی‌گیرند. برای

• لایه PrimeCaps

مطابق نسخه اولیه، این لایه دارای کپسول هایی به اندازه 8×8 فیلتر 9×9 و گام حرکتی ۲ است.

• DigitCaps

نسخه اولیه این لایه ده کپسول شانزده بعدی است که با توجه به مسئله تحقیق حاضر، این مقدار به دو کپسول شانزده بعدی تغییر یافت. در این لایه، مقدار الگوریتم سیمیریابی نیز، همانند نسخه اولیه، با مقدار ۳ تنظیم شد.

• لایه های تماماً متصل

برخلاف پژوهش هینتون که در آن لایه های تماماً متصل در نظر گرفته شده است، در این مطالعه، لایه های مورد اشاره منظور شده اند و در آن، می توان از چندین لایه استفاده کرد. درواقع، این لایه سعی در فراگرفتن ویژگی های استخراجی از لایه DigitCaps دارد. در این تحقیق، آخرین لایه تماماً متصل به اندازه طبقه های مد نظر این مطالعه (شانزده تا) است.

شکل ۵ ساختار کلی رویکرد شبکه های کپسول را نشان می دهد.

برای یک کپسول، مطابق شکل ۶، ورودی شبکه بردار $U_{j|l}$ و خروجی آن بردار s_j است و پارامترها از یک لایه به لایه دیگر منتقل می شوند. برای ارسال کپسول از لایه های به لایه بعدی، به فرایند خاصی نیاز است که در ادامه، به آن می پردازیم. برای این کار، یک ماتریس تبدیل W_i روی خروجی کپسول i به لایه پیشین اعمال می شود و سپس وزن جمعی s_j براساس وزن های c_{ij} ، مطابق رابطه (۱)، محاسبه می شود (Candemir et al., 2014).

$$\widehat{U_{j|l}} = w_{ij} U_j \quad \text{رابطه (1)}$$

$$s_j = \sum c_{ij} \cdot \widehat{U_{j|l}}$$

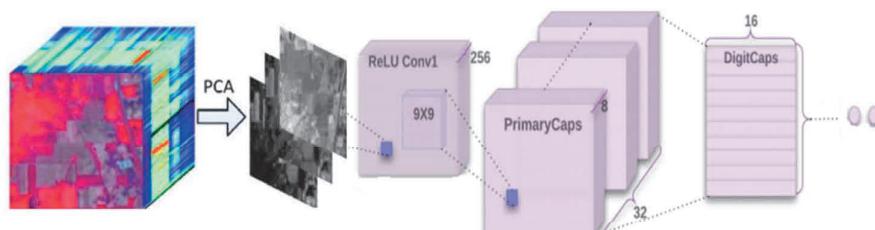
شبکه های تماماً متصل، خروجی ها به صورت عددی (اسکالر) هستند. شبکه های کپسول، مطابق شکل ۴، دارای لایه های Conv1d، PrimaryCaps و DigitCaps (Xue et al., 2015; Candemir et al., 2014) هستند. با توجه به اینکه ویژگی ها به صورت بردار ذخیره شده اند، با تغییر آنها در جای جای تصویر، اندازه بردار حفظ می شود اما جهت آن تغییر می کند و درنتیجه، برای شناسایی شیء با چرخش های مختلف، به نمونه های آموزشی بیشتری نیاز خواهد بود.

۳-۳-۱- اجزای شبکه کپسول پیشنهادی و محاسبه خروجی

شبکه کپسول طراحی شده، در این پژوهش، بسیار شبیه به شبکه کپسولی است که هینتون آن را توصیف کرده (Candemir et al., 2014)؛ با این تفاوت که تغییراتی روی آن اعمال شده است. لایه های شبکه طراحی شده بدین قرار است:

• لایه کانولوشن

این لایه دارای ۲۵۶ فیلتر کانولوشنی به اندازه 9×9 و گام حرکتی ۲ است که روی آن، تابع فعال ساز «ReLU» اعمال شده است. یکی از تغییرات اعمال شده در این مرحله، در قیاس با شبکه هینتون، تغییر مقدار گام حرکتی از ۱ به ۲ است زیرا مدل اصلی روی مجموعه داده های mnist استفاده شده بود و تصاویر mnist به صورت 28×28 است. با استفاده از گام حرکتی ۲، مقدار پارامترهایی که مدل در لایه بعد دریافت می کند، بسیار کاهش می یابد.



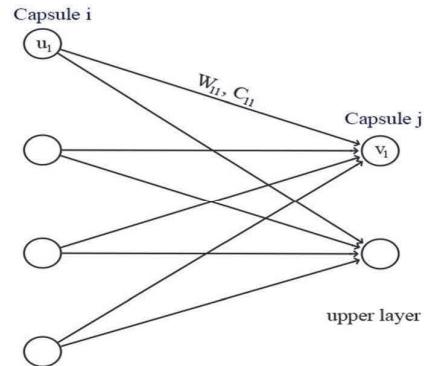
شکل ۵. شماتیک کلی از رویکرد شبکه های کپسول

$$v_j = \frac{\|s_j\|^2}{1 + \|s_j\|^2} \cdot \frac{s_j}{\|s_j\|} \quad \text{رابطه (۲)}$$

$$v_j \approx \|s_j\| s_j \quad \text{for small } s_j$$

$$v_j \approx \frac{s_j}{\|s_j\|} \quad \text{for large } s_j$$

لایه آخر تماماً متصل، در مقایسه با رویکردهای سنتی یادگیری ماشین مانند SVM و XGBoost، دقت کمتر و میزان محاسبات بیشتری دارد؛ از این‌رو در رویکرد پیشنهادی، مدل XGBoost به منزله جایگزین این لایه‌ها به کار رفت.



شکل ۶. ارسال پارامترها از یک لایه به کپسول‌های لایه بعدی

۳-۴- مدل درخت تقویتی

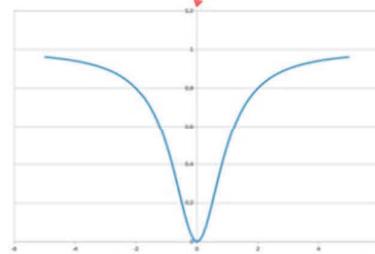
مدل درخت تقویتی روشی بسیار مؤثر و پرکاربرد در یادگیری ماشین است که چن و گواسترنین^۲ (۲۰۱۶) آن را پیشنهاد کرده‌اند. این شبکه نوعی تکنیک اجرایی کارآمد برای افزایش صحت و عملکرد ماشین افزایش گرادیان (GBM)^۳ و بهویژه، افزایش دقت طبقه‌بندی درخت‌های رگرسیون است. همچنین یکی از محبوب‌ترین و کارآمدترین عملی‌سازی و اجراهای گلگوریتم Gradient Boosted Trees و روش یادگیری نظارت‌شده‌ای مبتنی بر تقریب عملکرد با بهینه‌سازی Boosting (Paoletti et al., 2019) توابع خاص است.

در ML از تکنیک‌های یادگیری متوالی برای تبدیل فرضیه‌ای ضعیف به فرضیه‌ای قوی، به منظور افزایش دقت مدل به شمار می‌رود (Chen & Guestrin, 2016).

ساختار مدل پیشنهادی، پس از حذف لایه تماماً متصل و جایگزینی آن با XGBoost در شکل ۸ نشان داده شده است.

Squash

$$\text{Squash function: } v_j = \frac{\|s_j\|^2}{1 + \|s_j\|^2} \frac{s_j}{\|s_j\|}$$



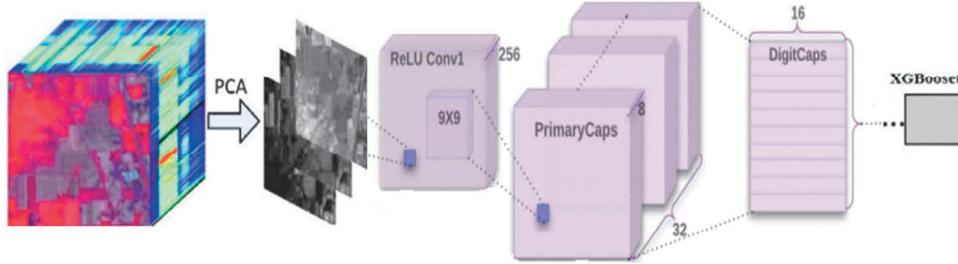
شکل ۷. شکل تابع Squash

منبع: Candemir et al., 2014

در این رابطه، c_{ij} ها ضرایب اتصالی‌اند که با استفاده از مسیریابی پویا^۱ محاسبه می‌شوند و $\sum c_{ij}$ برای جمع آنها در نظر گرفته شده است. به‌طور مفهومی، c_{ij} معیاری برای اندازه‌گیری میزان احتمال فعال‌سازی کپسول ز با کپسول i است. در شبکه‌های کپسول، به جای اعمال ReLU، تابع squash را روی خروجی s_j اعمال می‌کنند. این تابع بردارهای کوچک را به ۰ و بردارهای بزرگ را به بردارهای واحدی کاوش می‌دهد و به‌همین‌دلیل خروجی یک کپسول ز v_j ، مطابق رابطه (۲)، طولی بین [۰-۱] دارد. در شکل ۷، تابع squash ارائه شده و فرایند اعمال squash روی بردار ورودی s_j نیز در ادامه، آورده شده است (Candemir et al., 2014).

۱. در شبکه‌های کپسول، برای محاسبه خروجی کپسول، از مسیریابی پویایی با محاسبه ضریب اتصالی به صورت تکراری استفاده می‌کنند. این فرایند مشابه الگوریتم پس‌انتشار در شبکه‌های عصبی مصنوعی است؛ با این تفاوت که عمل مسیریابی به تعداد محدود انجام می‌شود (به صورت پیش‌فرض، سه بار).

2. Chen & Guestrin
3. Gradient Boosting Machine



شکل ۸. شماتیکی از رویکرد پیشنهادی تلفیق شبکه‌های کپسول و درخت تصمیم تقویتی

• شبکه‌های عصبی بازگشتی RNN-LSTM

LSTM^۱ نوعی مدل یا ساختار برای داده‌های ترتیبی است که در سال ۱۹۹۵ برای توسعه شبکه‌های عصبی بازگشتی ظهر یافت (Keshavarz & Ghasemiyani, 2005). عبارت Term به وزن‌های یادگرفته شده و Long Term Memory به حالت‌های درونی سلول‌ها اطلاق می‌شود. تغییر مهم و اصلی این ساختار، در قیاس با RNN، جایگزین کردن لایه میانی RNN با یک بلوک است (Keshavarz & Ghasemiyani, 2005) امکان یادگیری و استگی بلندمدت است که از طریق شبکه‌های عصبی بازگشتی، امکان پذیر نبود. برای پیش‌بینی گام زمانی بعدی، لازم است مقادیر وزن‌ها در شبکه به روزرسانی شوند که این کار مستلزم حفظ اطلاعات گام‌های زمانی ابتدایی است. در تحقیق مورد بررسی، شبکه‌های LSTM به منظور طبقه‌بندی تصویر ابراطیفی، اجرا شد. نتایج پژوهش در جدول ۳ آمده است (Keshavarz & Ghasemiyani, 2005).

• شبکه‌های عصبی بازگشتی RNN-GRU

معماری GRU^۲ (Keshavarz & Ghasemiyani, 2005) به منظور حل کاستی‌های شبکه عصبی بازگشتی قدیمی مانند مشکل محوش‌گی گرادیان و نیز معایب معماری LSTM مطرح شده است. GRU اغلب نسخه‌ای تغییر یافته از LSTM در نظر گرفته می‌شود زیرا هر دوی این معماری‌ها طراحی مشابهی دارند و در برخی موارد،

1. Long Short Term Memory
2. Gated Recurrent Unit

در این پژوهش، به منظور بررسی صحت روش پیشنهادی، نتایج با سایر روش‌های منابع پیشین نیز بررسی شد؛ در ادامه، توضیح مختصر روش‌ها خواهد آمد.

• رویکرد ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان نوعی از طبقه‌بندی کننده‌های آماری است که عملکرد کلی آن بیشتر بر الگوهای طبقه‌بندی و تخمین رگرسیون غیرخطی مرکز دارد (Landgrebe, 2002). ماشین‌های بردار پشتیبان، از طریق انتقال فضای ورودی به فضایی با بعد بالاتر، می‌توانند مسائل غیرخطی را حل کنند؛ این کار از طریق توابع کرنل امکان‌پذیر است. کرنل‌های متفاوت بسیاری همچون کرنل گوسی، کرنل خطی، کرنل چندجمله‌ای و کرنل تانژانت هایپربولیک وجود دارند. در پژوهش انجام شده، کرنل گوسی به منظور طبقه‌بندی تصاویر ابراطیفی به کار رفته است.

• رویکرد RF-200

الگوریتم جنگل تصادفی (Landgrebe, 2002) مبتنی بر دسته‌های از درخت‌های تصمیم‌گیری است که برچسب نهایی هر پیکسل را براساس برآورده از تصمیمات درخت‌ها و اغلب برمنای رأی اکثریت، تعیین می‌کند و برای بسیاری از مجموعه داده‌ها، طبقه‌بندی با صحت بالایی را تضمین می‌کند.

در شکل ۹، چهار عبارت TP ، FN ، FP و TN نمایش داده شده است. عبارت TP بیانگر تعداد نمونه‌های صحیح است که به درستی پیش‌بینی شده‌اند. عبارت FP گویای تعداد نمونه‌های نادرستی است که به درستی پیش‌بینی شده‌اند. TN بیانگر تعداد نمونه‌هایی نادرستی است که نادرست دسته‌بندی شده‌اند. عبارت FN نیز به تعداد نمونه‌های درستی اشاره دارد که نادرست دسته‌بندی شده‌اند. در طبقه‌بندی دودویی، معیار $Precision$ برای اشاره به نسبت بین نمونه‌های پیش‌بینی شده مثبت که دقیقاً مثبت‌اند، در قیاس با کل پیش‌بینی‌های مثبت انجام‌شده به کار می‌رود. این مسئله با رابطه (۳) نشان داده می‌شود (Ghamisi et al., 2017).

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

به‌طور کلی عبارت $Precision$ به معنی توانایی بالا برای پیش‌بینی درست است. معیار $Recall$ بیانگر تعداد اسناد پیش‌بینی شده مثبت، به نسبت کل اسناد موجود، شامل پیش‌بینی مثبت و منفی است که طبق رابطه (۴) نشان داده می‌شود.

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

عبارت $Recall$ به این معنی است که طبقه‌بندی مورد نظر توانسته بسیاری از اسناد را به درست طبقه‌بندی کند.

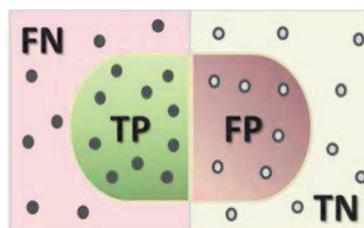
به صورت یکسان، نتایج عالی در بردارند. همان‌گونه که بیان شد، یکی از راه حل‌ها برای حل مشکل محوش‌دگی گرادیان در شبکه عصبی سنتی، استفاده از GRU است. این نوع معماری از مفهوم‌هایی به نام دروازه بهروزرسانی^۱ و دروازه بازنگشانی^۲ استفاده می‌کند. این دو دروازه، در اصل، دو بردارند که با استفاده از آنها تصمیم گرفته می‌شود چه اطلاعاتی به خروجی منتقل شود و چه اطلاعاتی انتقال نیابد. نکته خاص درباره دروازه‌های مورد نظر این است که این دروازه‌ها را می‌توان طوری آموزش داد که اطلاعات مربوط به گام‌های زمانی بسیار قبل را حفظ کند؛ بدون آنکه حین گذر زمان (طی گام‌های زمانی گوناگون) دستخوش تغییر شوند.

• رویکرد RNN-GRU-PRetanh

در این رویکرد، شبکه بازگشتی با بلوک‌های GRU و نیز تابع فعال ساز تانژانت هایپربولیک پارامتریک^۳، برای طبقه‌بندی تصویر ابرطیفی استفاده شده است (Keshavarz & Ghasemian, 2005). نتایج این رویکرد در جدول ۳ آمده است.

۳-۵- معیارهای ارزیابی

پیش‌از طرح و بررسی نتایج، معیارهای ارزیابی مورد استفاده را بررسی می‌کنیم. طبقه‌بندی دوکلاسه^۴ معیارهای ارزیابی گوناگونی دارند که قبل از بررسی آنها، پارامترهای به کار رفته در این معیارها توضیح داده می‌شود. اگر طبقه‌بندی دوکلاسه روی مجموعه‌ای داده تست اعمال شود، نتایج زیر (شکل ۹) به دست می‌آید .(Domingos, 2012)



شکل ۹. اعمال طبقه‌بندی دودویی روی یک مجموعه داده تست^۵

1. Update gate
2. Reset gate
3. Parametric Rectified Tanh (PRetanh)
4. Binary Classification
5. Apply Binary Classifications to a Test Data Set
6. True Positive
7. False Positive
8. True Negative
9. False Negative

جستجوی پارامترهای بهینه در مدل‌های یادگیری عمیق است. ۸۰٪ داده‌های این تحقیق، بهمنزله داده‌های آموزشی، برای آموزش مدل و ۲۰٪ به صورت داده‌های آزمون ارزیابی مدل، استفاده خواهند شد.

۴- نتایج

در این بخش، نتایج حاصل از شبکه کپسول پیشنهادی و شبکه CNN با استفاده از معیارهای ارزیابی (Ghamisi et al., 2017) مقایسه Recall و F1-score می‌شود. رویکرد پیشنهادی نیز با پنجم رویکرد مرسوم طبقه‌بندی مقایسه شده است که در ادامه، نتایج هریک از این مدل‌ها بیان می‌شود.

۱-۴- نتایج رویکرد مدل شبکه کانولوشنی

در این بخش، نتایج اجرای شبکه CNN روی داده پاینس هند بیان شده است. نتایج در دو حالت، بهازی هر کلاس مجزا، بهازی تمامی حالتها و برای مقایسه با سایر رویکردها گزارش داده شده است. برای تحلیل‌های بیشتر، نمودار خطای متریک‌های نتیجه اجرای شبکه CNN روی مجموعه داده‌های اندازه‌گیری در شکل ۱۰ آورده شده است. جدول ۲ نیز در این حالت تغییرات در معیارها بسیار ناچیز است و

در این نمودارها، محور X نشان‌دهنده تعداد دفعات اجرای الگوریتم روی داده‌ها و محور Y گویای معیار بهدست آمده، بهازی هر بار اجرای الگوریتم است. در شکل ۱۱ نیز، ماتریس خطای مرتبط با رویکرد اول ارائه شده است. جدول ۳ دقت نتایج بهدست آمده با استفاده از ساختار اول و مقایسه آن با نتایج دیگر پژوهش‌ها را درمورد این مجموعه از داده‌ها، بازگو می‌کند.

1. Patch Size

2. <https://optuna.org/>

معیار F-Measure که میانگین هارمونیک نیز نامیده شده، ترکیب دو معیار Precision و Recall است. این عبارت معمولاً F-Score متعادل نیز نامیده و به صورت رابطه (۵) نشان داده می‌شود (Ghamisi et al., 2017).

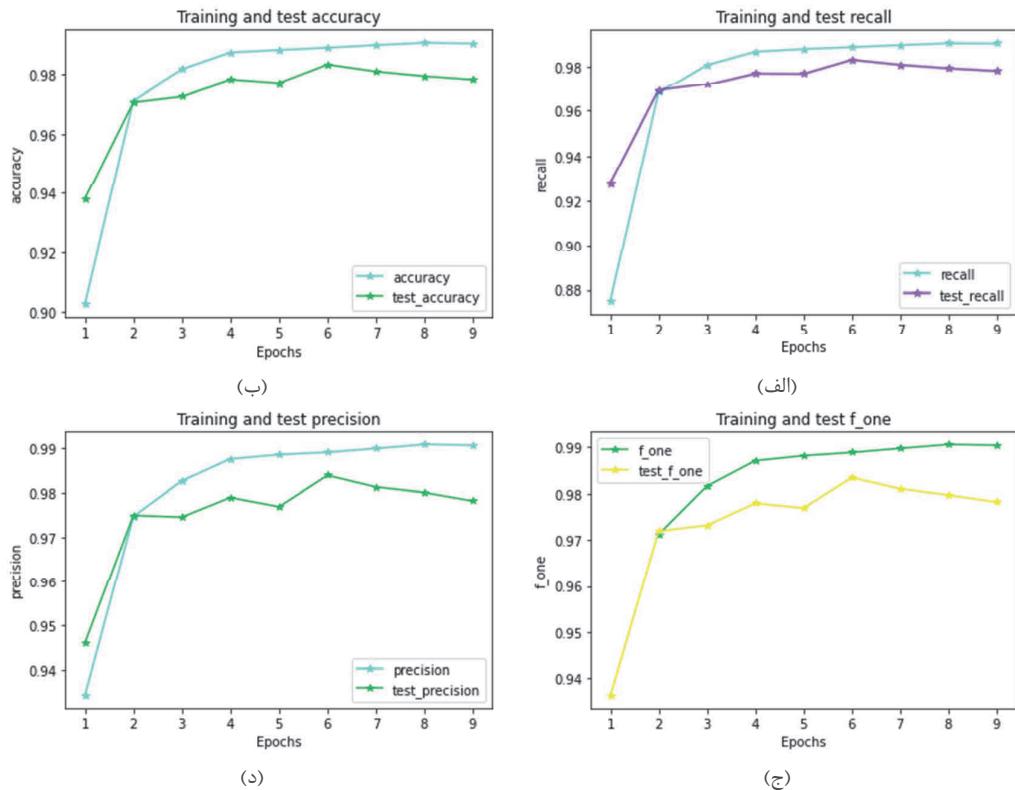
$$F_{\text{score}} = \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad \text{رابطه (5)}$$

یکی دیگر از معیارهایی است که در طبقه‌بندی دودویی کاربرد دارد. برای محاسبه این معیار، نسبت TP و TN به تعداد کل موارد پیش‌بینی شده در نظر گرفته می‌شود؛ بنابراین رابطه (۶) برای آن به دست می‌آید.

$$\text{Accuracy} = \frac{TP + FN}{TP + FP + FN + TN} \quad \text{رابطه (6)}$$

۶-۳- پارامترهای شبکه

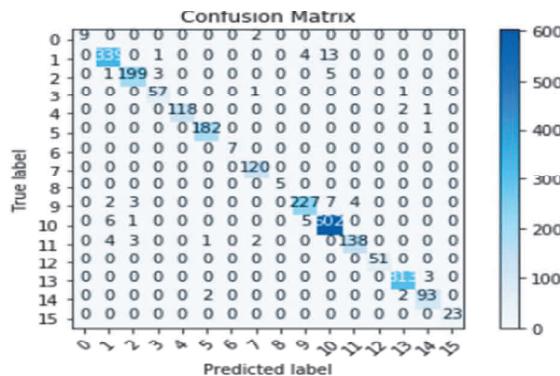
در پژوهش پیش رو، اندازه نمونه‌های آموزشی ۳۰×۳۰ است؛ ۵×۵ به اندازه دسته^۱ اشاره دارد و ۳۰ نتیجه اعمال الگوریتم کاهش بعد PCA روی باندهای تصویر ابراطیفی است. در بررسی‌های انجام شده‌ما، اندازه ۳۰×۳۰ بهینه‌ترین حالت برای کاهش بعد PCA است؛ در این حالت تغییرات در معیارها بسیار ناچیز است و بهطور کلی در افزایش بعد، بهبود حاصل نمی‌شود. در مجموع، اندازه فیلترهای کانولوشنی در شبکه‌های CNN یا کپسول ممکن است ۳×۳ و ۵×۵ باشد. در این تحقیق، از فیلتر ۹×۹ استفاده شده است. لایه کانولوشنی، در ساختار رویکرد پیشنهادی، دارای ۲۵۶ فیلتر کانولوشنی به اندازه ۹×۹ و گام حرکتی ۲ است که روی آن تابع فعال‌ساز ReLu اعمال شده است. در این ساختار رویکرد همچنین، کپسول‌هایی به اندازه ۸×۸ با ۳۲ فیلتر ۹×۹ و گام حرکتی ۲ به کار رفت و میزان Dropout، در تمامی لایه‌های شبکه، ۰/۵ در نظر گرفته شد. تمامی پارامترهای مدل با استفاده از Optuna^۲ به دست آمدند. Optuna کتابخانه‌ای متن باز برای



شکل ۱۰. نمودار Recall (الف); نمودار Accuracy (ب); نمودار F1 روى داده‌های آموزش و تست با رویکرد پیشنهادی اول (ج)
پیشنهادی اول (د)

جدول ۲. نتایج حاصل از ساختار پیشنهادی اول روی مجموعه داده‌های تست

Count	معیارهای ارزیابی			شماره کلاس
	F1-score	Recall	Precision	
۱۱	۹۰	۸۲	۱۰۰	۱
۳۵۷	۹۶	۹۵	۹۶	۲
۲۰۸	۹۶	۹۶	۹۷	۳
۵۹	۹۵	۹۷	۹۳	۴
۱۲۱	۹۹	۹۸	۱۰۰	۵
۱۸۳	۹۹	۱۰۰	۹۹	۶
۷	۱۰۰	۱۰۰	۱۰۰	۷
۱۲۰	۹۸	۱۰۰	۹۶	۸
۵	۱۰۰	۱۰۰	۱۰۰	۹
۲۴۳	۹۵	۹۴	۹۶	۱۰
۶۱۴	۹۷	۹۸	۹۶	۱۱
۱۴۸	۹۵	۹۳	۹۷	۱۲
۵۱	۱۰۰	۱۰۰	۹۸	۱۳
۳۱۶	۹۹	۹۹	۹۸	۱۴
۹۷	۹۵	۹۶	۹۵	۱۵
۲۳	۱۰۰	۱۰۰	۱۰۰	۱۶
۲۵۶۳	۹۶/۸۶	۹۶/۸۷	۹۶/۸۸	میانگین کل

شکل ۱۱. ماتریس خطای^۱ رویکرد اول

جدول ۳. مقایسه نتایج حاصل از ساختار پیشنهادی اول با نتایج موجود (مقادیر برحسب درصد است)

RF-200	SVM-RBF	RNN-LSTM	RNN-GRU-than	RNN-GRU-Pretanh	رویکرد اول	شماره کلاس
۵۸/۸۴	۶۰/۷۷	۴۶/۰۳	۶۸/۹۳	۷۰/۵۹	۹۷/۵۶	۱
۵۸/۴۲	۷۷/۶۸	۶۱/۳۷	۴۰/۹۴	۷۰/۲۸	۹۷/۵۲	۲
۸۲/۶۱	۷۹/۳۵	۸۶/۹۶	۷۸/۸۰	۸۱/۵۲	۸۵/۳۳	۳
۸۵/۹۱	۹۱/۰۵	۸۷/۰۲	۸۷/۹۲	۹۰/۱۶	۸۷/۹۲	۴
۸۰/۴۹	۸۴/۳۶	۸۶/۶۶	۸۷/۵۲	۹۱/۹۷	۸۵/۲۲	۵
۹۴/۷۶	۹۲/۰۳	۷۹/۴۹	۹۷/۲۷	۹۶/۱۳	۹۷/۴۹	۶
۷۷/۳۴	۶۹/۶۱	۵۹/۶۹	۸۲/۷۹	۸۴/۷۵	۷۴/۶۲	۷
۵۹/۴۳	۵۹/۳۱	۶۴/۸۹	۵۰/۵۸	۵۹/۶۴	۶۷/۹۹	۸
۶۳/۴۸	۷۹/۶۱	۶۰/۴۶	۷۹/۴۳	۸۶/۱۷	۸۷/۵۸	۹
۵۹/۰۶	۹۷/۵۳	۹۸/۷۷	۹۸/۷۷	۹۹/۳۸	۹۸/۷۷	۱۰
۸۸/۲۶	۸۵/۲۱	۷۵/۳۲	۸۴/۷۳	۸۴/۹۷	۸۷/۶۲	۱۱
۵۴/۸۵	۶۳/۶۴	۷۱/۸۲	۶۱/۲۱	۷۷/۵۸	۷۲/۴۲	۱۲
۹۷/۷۸	۱۰۰	۹۱/۱۱	۸۸/۸۹	۹۵/۵۶	۹۳/۳۳	۱۳
۵۸/۹۷	۸۷/۱۸	۷۹/۴۹	۷۹/۴۹	۸۴/۶۲	۷۱/۷۹	۱۴
۸۱/۸۲	۹۰/۹۱	۹۰/۹۱	۹۰/۹۱	۹۰/۹۱	۹۰/۹۱	۱۵
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۶

است با استفاده از شبکه‌های کپسول، تاحد بسیاری از این مشکلات کاسته شود. در هر دو رویکرد پیشنهادی، برای کنترل Overfitting از Early Stopping استفاده شده است. این سیاست، طی دو دور اجرایی، بررسی می‌کند که اگر مقدار Loss تغییری نکرده باشد، یادگیری را متوقف کند. برای یادگیری پارامترهای هر دو مدل نیز، Optuna به کار رفت و بهینه‌ترین پارامترها برای طبقه‌بندی انتخاب شد.

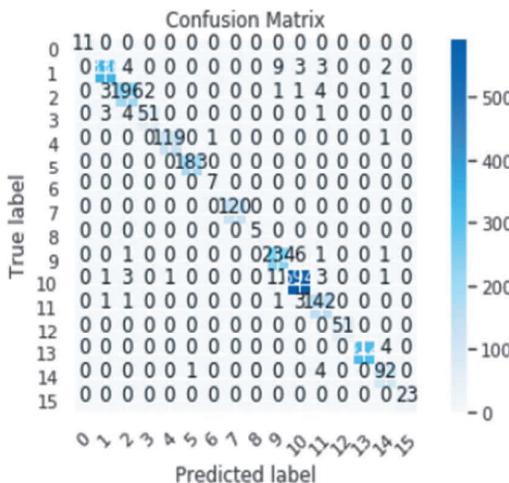
مقادیر ساختار اول، در مقایسه با رویکردهای قبلی، دقت شایان توجهی به دست آورده است. دقت این مدل، در بیشتر دامنه‌ها، کمتر از رویکرد-RNN-GRU-PRetanh است و همچنین فقط توانسته روی داده‌های کلاس Buildings-grass-trees دقت برابری کسب کند. این در حالی است که در سایر طبقه‌ها، میزان دقت نسبتاً کمتر بوده است. این مدل به دلیل داشتن عمق و تعداد فیلتر کمتر، در طبقه‌بندی تصاویر، دقت کمتری داشته از این‌رو در رویکرد پیشنهادی دوم، سعی شده

نتایج خروجی از الگوریتم روی مجموعه داده‌های تست، پس از سی بار یادگیری شبکه را بیان می‌کند که بهازای هر کلاس، گزارش داده شده است. در شکل ۱۲، ماتریس خطای مرتبط با رویکرد دوم ارائه شده است. نمودار خطای و سایر متريک‌های اندازه‌گیری در شکل ۱۳ آورده شده است.

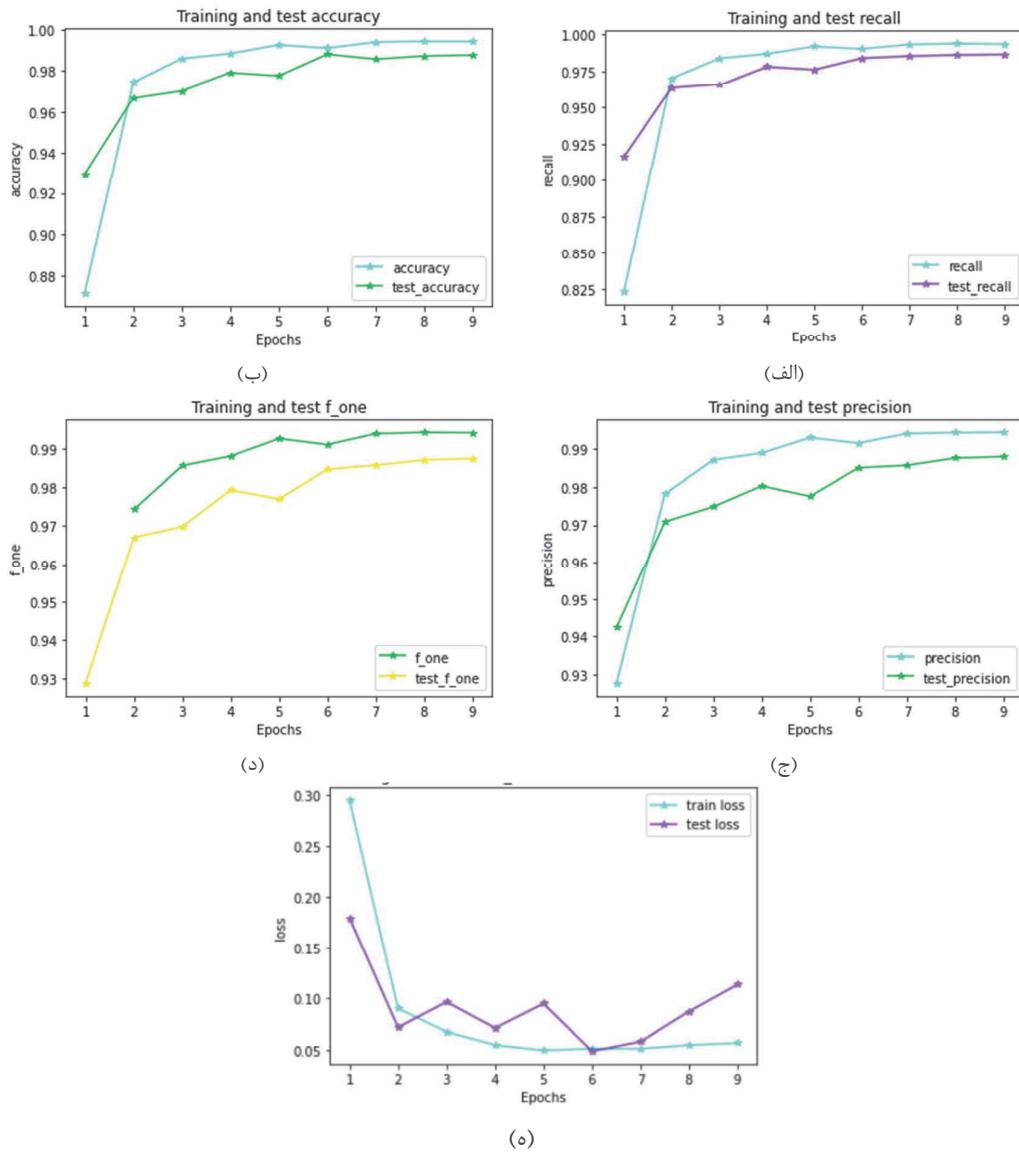
۴-۴- نتایج رویکرد پیشنهادی دوم شبکه‌های کپسول در رویکرد پیشنهادی دوم نیز، از ۸۰٪ داده‌ها برای آموزش و از ۲۰٪ آنها برای تست استفاده شده است. مشابه رویکرد پیشنهادی اول، نتایج در دو حالت (بهازای هر کلاس مجزا، بهازای تمامی حالت‌ها) برای مقایسه با سایر رویکردها گزارش شده است. جدول ۴

جدول ۴. نتیجه حاصل از رویکرد پیشنهادی دوم روی مجموعه داده‌های تست

Count	معیارهای ارزیابی			شماره کلاس
	F1-score	Recall	Precision	
۱۱	۱۰۰	۱۰۰	۱۰۰	۱
۳۵۷	۹۶	۹۴	۹۸	۲
۲۰۸	۹۴	۹۴	۹۴	۳
۵۹	۹۱	۸۷	۹۶	۴
۱۲۱	۹۹	۹۸	۹۹	۵
۱۸۳	۱۰۰	۱۰۰	۹۹	۶
۷	۹۳	۱۰۰	۸۸	۷
۱۲۰	۱۰۰	۱۰۰	۱۰۰	۸
۵	۱۰۰	۱۰۰	۱۰۰	۹
۲۴۳	۹۴	۹۶	۹۲	۱۰
۶۱۴	۹۷	۹۷	۹۸	۱۱
۱۴۸	۹۳	۹۶	۹۰	۱۲
۵۱	۱۰۰	۱۰۰	۱۰۰	۱۳
۳۱۶	۹۹	۹۹	۱۰۰	۱۴
۹۷	۹۲	۹۵	۹۰	۱۵
۲۳	۱۰۰	۱۰۰	۱۰۰	۱۶
۲۵۶۳	۹۶/۶۲	۹۶/۶۰	۹۶/۶۸	میانگین کل



شکل ۱۲. ماتریس خطای رویکرد دوم



شکل ۱۳. نمودار Recall (الف); نمودار Accuracy (ب); نمودار F1 score (ج); Precision (د); نمودار loss (ه) روی داده‌های آموزش و تست، با رویکرد پیشنهادی دوم (ه)

تأثیری در هیچ‌یک از معیارهای ارزیابی ندارد و هر چهار معیار، حدوداً پساز هفت مرحله یادگیری شبکه، بدون تغییر باقی می‌مانند. در جدول ۵، مقایسه دقت‌های به دست آمده از طریق رویکرد پیشنهادی دوم، با نتایج حاصل از دیگر پژوهش‌ها درباره این مجموعه از داده‌ها، آمده است.

منحنی‌های حاصل، با رویکرد پیشنهادی دوم، کاملاً متفاوت از منحنی‌های حاصل از رویکرد پیشنهادی اول است. در این رویکرد، اختلاف بین دو منحنی آموزش و تست در تمامی حالات، کمتر شده است و این منحنی‌ها به مجانبی افقی میل کرده‌اند. این نکته نشان می‌دهد افزایش تعداد یادگیری شبکه، از مقداری معین،

جدول ۵. مقایسه نتایج حاصل از ساختار پیشنهادی دوم، با نتایج سایر پژوهشگران

RF-2000	SVM-RBF	RNN-LSTM	RNN-GRU-than	RNN-GRU-Pretanh	رویکرد دوم	رویکرد اول	شماره کلاس
۵۴/۸۴	۶۰/۷۷	۶۴/۰۳	۶۸/۹۳	۷۰/۵۹	۹۵/۷۱	۹۷/۵۶	۱
۵۸/۴۲	۷۷/۶۸	۶۱/۳۷	۴۰/۹۴	۷۰/۲۸	۸۲/۷۷	۹۷/۵۲	۲
۸۲/۶۱	۷۹/۳۵	۸۶/۹۶	۷۸/۸۰	۸۱/۵۲	۸۶/۵۲	۸۵/۳۳	۳
۸۵/۹۱	۹۱/۰۵	۸۷/۰۲	۸۷/۹۲	۹۰/۱۶	۹۱/۹۳	۸۷/۹۲	۴
۸۰/۴۹	۸۴/۳۶	۸۶/۶۶	۸۷/۵۲	۹۱/۹۷	۹۲/۹۷	۸۵/۲۲	۵
۹۴/۷۶	۹۲/۰۳	۷۹/۴۹	۹۷/۲۷	۹۶/۱۳	۹۸/۱۲	۹۷/۴۹	۶
۷۷/۳۴	۶۹/۶۱	۵۹/۶۹	۸۲/۷۹	۸۴/۷۵	۸۴/۷۰	۷۴/۶۲	۷
۵۹/۴۳	۵۹/۳۱	۶۴/۸۹	۵۰/۵۸	۵۹/۶۴	۶۷/۶۴	۶۷/۹۹	۸
۶۳/۴۸	۷۹/۶۱	۶۰/۴۶	۷۹/۴۳	۸۶/۱۷	۷۶/۹۰	۸۷/۵۸	۹
۵۹/۰۶	۹۷/۵۳	۹۸/۷۷	۹۸/۷۷	۹۹/۳۸	۹۹/۶۰	۹۸/۷۷	۱۰
۸۸/۲۶	۸۵/۲۱	۷۵/۳۲	۸۴/۷۳	۸۴/۹۷	۸۵/۹۰	۸۷/۶۲	۱۱
۵۴/۸۵	۶۳/۶۴	۷۱/۸۲	۶۱/۲۱	۷۷/۵۸	۷۸/۵۹	۷۲/۴۲	۱۲
۹۷/۷۸	۱۰۰	۹۱/۱۱	۸۸/۸۹	۹۵/۵۶	۹۶/۵۰	۹۳/۳۳	۱۳
۵۸/۹۷	۷۸/۱۸	۷۹/۴۹	۷۹/۴۹	۸۴/۶۲	۷۹/۶۲	۷۱/۷۹	۱۴
۸۱/۸۲	۹۰/۹۱	۹۰/۹۱	۹۰/۹۱	۹۱/۹۱	۹۱/۹۱	۹۰/۹۱	۱۵
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۶

الگوریتم‌های طبقه‌بندی و افزایش قدرت تفکیک طیفی تصاویر، با وجود افزایش کلی دقت، چالش‌های طبقه‌بندی این تصاویر نیز بیشتر شده است.

یکی از مهم‌ترین مشکلات طبقه‌بندی این تصاویر، در مدل‌های یادگیری ماشین، انتخاب ویژگی‌هاست زیرا این مدل‌ها نیاز به انتخاب ویژگی به صورت دستی دارند و هرچه ویژگی‌های مناسب‌تری استخراج شود، این مدل‌ها می‌توانند طبقه‌بندی بهتری انجام دهند. از این‌رو با یادگیری عمیق، بهمنزله مدل‌هایی که می‌توانند ویژگی‌ها را به صورت خودکار انتخاب کنند، جایگزین مناسبی برای طبقه‌بندی این تصاویر شمرده می‌شوند. در این نوع یادگیری، ویژگی‌ها براساس فیلترهایی استخراج می‌شود که کاربر هیچ دخالتی در آن ندارد. برای افزایش دقت طبقه‌بندی این تصاویر، تکنیک‌های یادگیری عمیق شبکه‌های کانولوشنی روی این نوع تصاویر اعمال می‌شود. در پژوهش حاضر، از روش یادگیری عمیق شبکه‌های عصبی کانولوشنی و نیز شبکه‌های کپسول، برای افزایش دقت طبقه‌بندی تصاویر ابرطیفی استفاده شد. ابعاد تصویر ورودی به

نتایج رویکرد پیشنهادی دوم، در بیشتر کلاس‌ها، بهتر از رویکرد اول بوده و این ساختار توانسته است دقت بیشتر از RNN-GRU-Pretanh به دست آورد؛ به این دلیل که رویکرد دوم شبکه‌های کپسول، با استخراج مطلوب ویژگی‌ها، توانسته است مهندسی XGBoost ویژگی خودکار مناسبی برای مدل استاندارد ایجاد کند. همچنین با استفاده از رویکرد دوم در دامنه‌های Corn-min، Alfalfa، Grass-pasture، Soybean-clean، Soybean-notill، Grass-trees و Buildings-grass-trees دقت بیشتری حاصل شده است. ساختار دوم در سایر کلاس‌ها نیز دقت مورد قبولی داشته و البته علت اندک بودن دقت این ساختار، روی این طبقه‌ها، کم بودن تعداد نمونه‌ها در آن‌هاست که درنتیجه‌آن، مدل به خوبی نتوانسته است این داده را آموزش ببیند و یادگیری را کامل کند.

۵- بحث و نتیجه‌گیری
طبقه‌بندی تصاویر ماهواره‌ای همواره با چالش‌های بسیاری روبرو بوده است. با پیشرفت و گسترش

- Information to Select Symbols**, Scientific - Research Quarterly of Geographical Data (SEPEHR), 25(98), PP. 5-14.
- Bengio, Y. & Ian, J., 2015, **Goodfellow, and Aaron Courville. "Deep Learning"**, Nature, 521.7553, PP. 436-444.
- Bruzzone, L., Chi, M. & Marconconi, M., 2006, **A Novel Transductive SVM for Semisupervised Classification of Remote-Sensing Images**, IEEE Transactions on Geoscience and Remote Sensing, 44(11), PP. 3363-3373.
- Candemir, S., Jaeger, S., Palaniappan, K., Musco, J.P., Singh, R.K., Xue, Z. & McDonald, C.J., 2014, **Lung Segmentation in Chest Radiographs Using Anatomical Atlases with Nonrigid Registration**, IEEE Transactions on Medical Imaging, 33(2), PP. 577-590.
- Camps-Valls, G., Gomez-Chova, L., Munoz-Mari, J., Vila-Frances, J. & Calpe-Maravilla, J., 2006, **Composite Kernels for Hyperspectral Image Classification**, IEEE Geoscience and Remote Sensing Letters, 3(1), PP. 93-97.
- Camps-Valls, G., Shervashidze, N. & Borgwardt, K.M., 2010, **Spatio-Spectral Remote Sensing Image Classification with Graph Kernels**, IEEE Geoscience and Remote Sensing Letters, 7(4), PP. 741-745.
- Chen, T. & Guestrin, C., 2016, **Xgboost: A Scalable Tree Boosting System**, In Proceedings of the 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining.
- Dehghani, H., 2006, **Classification of Distance Measurement Images with Large Dimensions and Limited Educational Examples**, Ph.D. Thesis, Tarbiyat Modarres University, Department of Electronic Engineering, Tehran, Iran.
- Domingos, P., 2012, **A Few Useful Things to Know about Machine Learning**, Communications of the ACM.
- Du, P., Tan, K., Zhang, W. & Yan, Zh., 2008, **ANN Classification of OMIS Hyperspectral Remotely Sensed Imagery: Experiments and Analysis**, Congress on Image and Signal Processing, IEEE.

شبکه از عوامل تأثیرگذار در عملکرد استخراج ویژگی با استفاده از شبکه‌های کپسول است. در پژوهش حاضر، ابعاد $5 \times 5 \times 30$ درنظر گرفته شد. سه معیار F1-Score و Recall و Precision به کار رفت و نتایج، به صورت میانگین و انحراف معیار برای بیست بار اجرای شبکه، تهیه شد. از مجموع داده‌های درنظر گرفته شده، ۸۰٪ برای آموزش طبقه‌بندی و ۲۰٪ برای ارزیابی طبقه‌بندی استفاده شد. بهمنظور بهبود دقت طبقه‌بندی تصاویر نیز، دو رویکرد متفاوت در زمینه استفاده از شبکه‌های عصبی کانولوشنی و شبکه کپسول، در طبقه‌بندی تصاویر هوایی ابرطیفی به کار رفت. یکی از مهم‌ترین تفاوت‌های شبکه‌های کپسول با شبکه‌های کانولوشنی در ذخیره داده‌ها، در قالب یک بردار است. ویژگی برداربودن ویژگی اندازه و جهت را نیز به همراه خواهد داشت و می‌توان ارتباط بین ویژگی‌ها را نیز استخراج کرد و به دقت بالاتری رسید. در رویکرد اول، از این شبکه‌ها در حالت یکپارچه برای استخراج ویژگی و در ادامه، طبقه‌بندی استفاده شد و در رویکرد دوم، ویژگی‌های استخراج شده از طریق شبکه‌های کپسول، به منزله ورودی، به مدل درخت تقویتی XGBoost برای طبقه‌بندی معرفی شد. در رویکرد اول، از دو لایه کانولوشنی و دو لایه تماماً متصل استفاده شد که حصول دقت ۹۸٪ روی داده‌های آموزش و دقت ۹۶٪ روی داده‌های تست را در پی داشت. در رویکرد دوم، از یک لایه کانولوشنی، یک لایه کپسول و استفاده شد که به دقت ۹۹٪ روی داده‌های آموزش و نیز دقت ۹۷٪ روی داده‌های تست انجامید. رویکرد پیشنهادی اول فقط در یکی از طبقه‌ها توانسته است دقت برابر با رویکرد برتر در سایر پژوهش‌ها به دست آورد؛ در صورتی که رویکرد دوم، در بیشتر موارد، توانسته است به دقت بالاتر دست یابد.

۶- منابع

- Akbari, D., Safari, A.R. & Homayouni, S., 2016, **Improving Spectral-Spatial Classification of Supercritical Images by Using Spatial**

- Fauvel, M., Chanussot, J., Benediktsson, J.A. & Steinsson, J., 2007, **Spectral and Spatial Classification of Hyperspectral Data Using SVMs and Morphological Profiles**, IEEE Transactions on Geoscience and Remote Sensing, 46(11), PP. 2012-2020.
- Fukunaga, A. & Sber, G., 2008, **Providing an Optimal Method Based on Deep Learning for Spectral Classification Images with High Resolution Spatial Resolution in Semi-Urban Areas**, Journal of Geomatics Science and Technology, 9(2), PP. 151-170.
- Gao, Y., Gao, F., Dong, J. & Li, H.C., 2020, **SAR Image Change Detection Based on Multiscale Capsule Network**, IEEE Geosci. Remote Sens. Lett., 18(3).
- Ghaffari, O., Voldan-Zoj, M.J. & Mokhtarzadeh, M., 2016, **Selecting the Band in Order to Optimize the Spectral Separation of Supercritical Images**, The 1st National Conference on Geospatial Information Technology, K.N. Toosi University of Technology, Tehran, Iran.
- Ghamisi, P., Plaza, J., Chen, Y., Li, J. & Plaza, A.J., 2017, **Advanced Spectral Classifiers for Hyperspectral Images: A Review**, IEEE Geoscience and Remote Sensing Magazine, 5(1), PP. 8-32.
- Ghassemian, H., Keshavarz, A. & Landgrebe, D., 2003, **Hyper-Spectral Image Processing and Analyses**, Space Magazine, 1(3), PP. 32-41.
- Gualtieri, J.A. & Chetri, S.R., 2000, **Support Vector Machines for Classification of Hyperspectral Data**, Proc. IGARSS, Honolulu, HI, PP. 813-815.
- Gualtieri, J.A. & Cromp, R.F., 1999, **Support Vector Machines for Hyperspectral Remote Sensing Classification**, Proceedings Vol. 3584, 27th AIPR Workshop: Advances in Computer-Assisted Recognition.
- Gualtieri, J.A., Chetri, S.R., Cromp, R.F. & Johnson, L.F., 1999, **Support Vector Machines Classifiers as Applied to AVIRIS Data**, In Summaries 8th JPL Airborne Earth Science Workshop, JPL Pub., 99-17, PP. 217-227.
- Hu, W., Huang, Y., Wei, L., Zhang, F. & Li, H., 2015, **Deep Convolutional Neural Networks for Hyperspectral Image Classification**, J. Sens, 2015, P. 258619.
- Jimenez, L. & Landgrebe, D.A., 1999, **Hyperspectral Data Analysis and Feature Reduction via Projection Pursuit**, IEEE Trans. On Geoscience and Remote Sensing, 37(6), PP. 2653-2667.
- Kaewpijit, S., Moigne, J.L., Ghazawi, T.E., 2003, **Automatic Wavelet Spectral Analysis for Reduction of Hyperspectral Imagery**, IEEE Trans. on Geoscience and Remote Sensing, 41(4), PP. 863-871.
- Keshavarz, A. & Ghasemian, H., 2005, **A High-Speed Vector Machine-Based Algorithm for Classifying Hayperspectral Images Using Spatial Correlation**, Iranian Journal of Electrical and Computer Engineering, 3(1), PP. 37-44.
- Landgrebe, D.A., 2002, **Hyperspectral Image Data Analysis**, IEEE Signal Processing Magazine, 19(1), PP. 17-28.
- LeCun, Y., Bengio, Y. & Hinton, G., 2015, **Deep Learning**, Nature, 521, PP. 436-444.
- Lee, C. & Landgrebe, D.A., 1993, **Feature Extraction Based on Decision Boundaries**, IEEE Trans. on Pattern Analysis and Machine Intelligence, 15(4), PP. 388-400.
- Li, H., 2018, **Deep Learning for Natural Language Processing: Advantages and Challenges**, National Science Review., 5(1), PP. 24-26.
- Liyang, W., Yongyi, Y., Nishikawa, R.M., Wernick, M.N. & Edwards, A., 2005, **Relevance Vector Machine for Automatic Detection of Clustered Micro Calcifications**, IEEE Trans. Med. Imag., 24(10), PP. 1278-1285.
- Luo, Y., Zou, J., Yao, C., Li, T. & Bai, G., 2018, **HSI-CNN: A Novel Convolution Neural Network for Hyperspectral Image.**, arXiv 2018, arXiv:1802.10478.
- Maggiori, E., Tarabalka, Y., Charpiat, G. & Alliez, P., 2016, **High-Resolution Semantic Labeling with Convolutional Neural Networks**, ArXiv: 1611.01962.

- Melgani, F. & Bruzzone, L., 2004, **Classification of Hyperspectral Remote Sensing Images with Support Vector Machines**, IEEE Transactions on Geoscience and Remote Sensing, 42(8), PP.1778-1790.
- Paoletti, M.E., Plaza, J. & Plaza, A., 2018, **A New Deep Convolutional Neural Network for Fast Hyperspectral Image Classification**, ISPRS Journal of Photogrammetry and Remote Sensing, 145, PP. 120-147. doi:10.1016/j.isprsjprs.2017.11.021.
- Paoletti, M.E., Haut, J.M., Fernandez-Beltran, R., Plaza, J., Plaza, A., Jun, L. & Pla, F., 2019, **Capsul Networks for Hyperspectral Image Classification**, IEEE Transactions on Geoscience and Remote Sensing, 57(4), PP. 2145-2160. doi:10.1109/TGRS.2018.2871782.
- Sabour, S., Frosst, N. & Hinton, G.E., 2017, **Dynamic Routing between Capsules**, In Proceedings of the Advances in Neural Information Processing Systems, Long Beach, CA, USA, 4-9 December 2017, PP. 3859-3869.
- Shahhoseini, R., 2009, **Evaluation of Support Vector Machines in the Classification of Hyperspectral Remote Sensing Data**, Ms.c Thesis, University of Tehran, Tehran, Iran.
- Wang, Y., Sun, A., Han, J., Liu, Y. & Zhu, X., 2018, **Sentiment Analysis by Capsules**, In Proceedings of the 2018 World Wide Web Conference on World Wide Web, Lyon, France, 23-27 April 2018; PP. 1165-1174.
- Xu, J.L., Esquerre, C. & Sun, D.W., 2018, **Methods for Performing Dimensionality Reduction in Hyperspectral Image Classification**, Journal of Near Infrared Spectroscopy, 26(1), PP. 61-75.
- Xu, Q., Wang, D.Y. & Luo, B., 2020, **Faster Multiscale Capsule Network with Octave Convolution for Hyperspectral Image Classification**, IEEE Geosci. Remote Sens. Lett, 18(2).
- Xue, Z., You, D., Candemir, S., Jaeger, S., Antani, S., Long, L.R. & Thoma, G.R., 2015, **Chest X-Ray Image View Classification**, In Proceedings of the 28th International Symposium on Computer-Based Medical
- Systems (CBMS) (PP. 66-71), Brazil: Ribeão Preto.
- Yu, Y., Gu, T., Guan, H., Li, D. & Jin, S., 2019, **Vehicle Detection from High-Resolution Remote Sensing Imagery Using Convolutional Capsule Networks**, IEEE Geosci. Remote Sens. Lett., 16, PP. 1894-1898.



سنجش از دور

GIS ایران

سنجش از دور و GIS ایران
Vol.15, No. 3, Autumn 2023
Iranian Remote Sensing & GIS

41-60



Improving the Classification of Hyperspectral Images Using the Combined Model of CapsNet and the Extreme Gradient Boosting

Ahmadi P.^{1*}, Managhebi T.², Ebadi H.³, Asghari Beirami B.⁴

1. Ph.D. Student, Faculty of Geomatics Engineering, K.N. Toosi University of Technology, Tehran, Iran
2. Assistant Professor, Faculty of Mapping and Spatial Information Engineering, University of Tehran, Tehran, Iran

3. Prof. Photogrammetry & Remote Sensing Dept, K.N. Toosi University of Technology, Tehran, Iran
4. Ph. D. in Remote sensing engineering, Faculty of Geomatics Engineering, K.N. Toosi University of Technology, Tehran, Iran

Abstract

With the development of remote sensing science, the use of hyperspectral images is becoming more widespread. Classification is one of the most popular topics in hyperspectral remote sensing. In the last two decades, a number of methods have been proposed to address the problem of hyperspectral data classification. In the present study, a structure based on learning capsule networks has been used to classify hyperspectral images, so that the network structure can have the most optimal generation of features by using a convolution layer and a capsule layer, and at the same time Avoid overfitting on training data. The obtained results show the high quality of production features in the proposed structure.

In order to improve the classification accuracy, the feature extraction approach through the designed network and the classification by the Extreme Gradient Boosting was compared with the classification method by the global deep network. The proposed capsule approach consists of 3 basic layers: 1) Prime caps, which are capsules of size 8 and 32 with 9×9 filters and movement step 2, 2) Digitcaps with 10 16-dimensional capsules, and 3) fully connected layer. The results of examining two approaches for deep networking as well as combining capsule networks with XGBoost reinforcement tree algorithm were compared. Approaches such as SVM, RF-200, LSTM, GRU and GRU-Pretanh were considered to compare the proposed approach based on the configurations mentioned in their research.

Up in addition to the study and quality measurement of production vector deep features by the proposed method in different classifiers, the ability of deep global networks in the application of classification should also be examined. The results of examining two approaches for deep network and also combining CapsNet with XGBoost show that by using the proposed combined method, images are classified with 99% accuracy on training data and 97.5% accuracy on test data.

Keywords: Classification, Hyperspectral images, CapsNet, XGBoost, Fusion model.

* Correspondence Address: No. 1346, ValiAsr Street , Mirdamad Cross, Faculty of Geomatics Engineering, K.N. Toosi University of Technology, Tehran, Tel: 09185363604
Email: ahmadi.pouya@ut.ac.ir
<https://orcid.org/0009-0001-7308-1054>
<https://dx.doi.org/10.48308/gisj.2023.102347>



Copyright: © 2023 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).