

طبقه بندی تصاویر هایپر اسپکترال با استفاده از تجزیه تنسور زیرباند و

شبکه عصبی پیچشی

سایه میرزایی^۱ و جواد حق شناس^۲

چکیده

در این مقاله، به موضوع طبقه بندی تصاویر ابرطیفی پرداخته می شود. با استفاده از روش های تجزیه، ماتریس یا تنسور تصویر ابرطیفی به دو ماتریس تجزیه می شود که یکی نمایانگر امضاهای طیفی مواد تشکیل دهنده تصویر می باشد و دیگری میزان فراوانی هر ماده در هر پیکسل را نشان می دهد. از آنجاییکه ذات تصویر ابرطیفی سه بعدی است، روش های تجزیه تنسور نامنظمی بسیار بهتر به مساله منطبق هستند چرا که به جای به دنبال هم نشان دادن اطلاعات مکانی در یک بردار، اطلاعات مکانی را حفظ می کنند و ساختار همسایگی پیکسل ها در مدل لحاظ می شود. با هدف بهره گیری مشترک از اطلاعات مکانی و طیفی، کل طیف فرکانسی به چندین زیرباند تقسیم می شود و تجزیه روی هر زیر باند به صورت جداگانه صورت می پذیرد و ماتریس های فراوانی زیرباندها به دنبال هم قرار می گیرند و ماتریس ویژگی را می سازند. ماتریس فراوانی حاصل از روش های تجزیه تنسور نسبت به تجزیه ماتریس، به نتایج بهتری منجر می شود. آزمایشها بر روی سه مجموعه داده شناخته شده، مبین بهبود چشمگیر در دقت طبقه بندی حاصل با استفاده از روش پیشنهادی هستند. برای طبقه بندی از شبکه عصبی پیچشی سه بعدی استفاده شده است.

کلیدواژه‌ها

طبقه بندی تصاویر ابرطیفی، روش تجزیه تنسور نامنظمی (NTF)، NTF در زیرباند (Subband NTF)، شبکه های عصبی پیچشی سه بعدی (3D-CNN)

۱ مقدمه

تصویربرداری ابرطیفی یک تکنیک جدید و پرکاربرد است که از تلفیق مفهوم تصویربرداری کلاسیک و طیف سنجی استفاده می

کند. این نوع تصویربرداری دارای کاربردهای بسیار متنوعی در کشاورزی، ستاره شناسی، زمین شناسی، نفت و گاز و نظامی است. از جمله کاربردها در صنعت کشاورزی به مانیتور کردن محصولات از منظر رشد، سلامت، تشخیص نوع محصول، پایش کلی سطوح زیر کشت، انواع آفتها و ... می توان اشاره نمود که به منظور برنامه ریزی های کلان و استراتژیک کشور مورد نیاز مبرم می باشند. در یک محموله تصویربرداری ابرطیفی، پیکسلها ترکیبی از داده های مختلفی هستند که نیازمند جداسازی و دسته بندی مجزا می باشد. برای مثال در بعد ماکروسکوپی زمانی که یک تصویر از سطح زمین گرفته میشود، هر پیکسل ممکن است سطوح مختلفی نظیر خاک، گیاه، آب و ... را شامل شود که

این مقاله در فروردین ماه سال ۹۸ دریافت، در شهریورماه بازنگری و در مهرماه همان سال پذیرفته شد.

^۱ دانشکده علوم مهندسی، دانشکده فنی، دانشگاه تهران

رایانامه: S.mirzaei@ut.ac.ir

^۲ پژوهشگر پژوهشکده سامانه های ماهواره ای

رایانامه: j.haghshenas@isrc.ac.ir

Archive of SID

از آنجاییکه داده های ابرطیفی نامنفی هستند، روش های تجزیه نامنفی ماتریس (NMF) به صورت گسترده ای برای جداسازی تصاویر مورد استفاده قرار گرفته اند [۱۷] و [۲۱] تا [۲۵]. ستونهای ماتریس داده متناظر با بردارهای طیفی مربوط به هر پیکسل هستند. ماتریس های حاصل از تجزیه شامل ماتریس endmember و ماتریس abundance است که اولی شامل امضاهای طیفی مواد تشکیل دهنده تصویر و دومی فراوانی هر یک از این مواد در هر پیکسل است. واضح است که NMF انطباق مناسبی با مساله جداسازی دارد چراکه داده ها و مولفه های سازنده همگی نامنفی هستند. به علاوه، با فرض مدل ترکیب خطی، داده ابرطیفی درست مانند مدل NMF با ترکیب خطی مولفه های سازنده آن حاصل می شود. قیود مختلفی مانند تنک بودن ماتریس فراوانی و یا برخی شرایط طیفی و یا مکانی را می توان به مساله NMF اضافه نمود.

طبقه بندی هر پیکسل یک تصویر در بسیاری از کاربردهای سنسجش از دور مورد توجه می باشد. روش های طبقه بندی مختلفی در مقالات پیشنهاد شده اند. در [۲۶] تا [۲۸]، نتایج جداسازی برای بهبود عملکرد طبقه بندی مورد استفاده قرار گرفته اند. در [۲۹]، یک تکنیک استخراج ویژگی مکانی-طیفی با Deep Belief Network (DBN) ترکیب شده است. در [۳۰]، یک روش یادگیری دیکشنری با مرتبه پایین برای طبقه بندی مورد استفاده قرار گرفته است. رویکرد یادگیری تنسور با مرتبه کم در [۳۱] پیشنهاد شده است. در [۳۲]، گسترش تنک روش k-SVD برای یادگیری دیکشنری متمایز کننده به کار رفته است. قید نامنفی بودن به مدل تنک مشترک (JSM) اعمال شده و در طبقه بندی مورد استفاده قرار گرفته است [۳۳]. در [۳۴]، تنسور هایپراسپکترال شامل اطلاعات مکانی-طیفی پیکسل مورد نظر و پیکسل های همسایه به صورت یک مکعب با چندین ویژگی برای طبقه بندی به کار رفته است. یک شبکه عصبی Residual در [۳۵] پیشنهاد شده که اطلاعات خام سه بعدی را به عنوان ورودی استفاده می کند.


در این پژوهش، بر روی مدل خطی تمرکز می کنیم. استفاده از روش NMF بیزی را پیشنهاد می دهیم که بر اساس آن ماتریس فراوانی با توزیع پیشین گامافرض می شود. مدل تولید کننده ماتریس داده ها توزیع پواسون فرض می شود. نشان داده شده است که اعمال شرط تنک بودن بر روی عناصر ماتریس فراوانی با توزیع گاما، با داده های ابرطیفی مطابقت دارد و مدل خوبی خواهد بود که به نتایج جداسازی رضایت بخشی می انجامد.

بردارهای طیفی و ماتریس فراوانی حاصل از NMF، در مرحله بعدی می توانند به عنوان نقطه شروع روش های NTF به کار روند. به خاطر ساختار سه بعدی داده ابرطیفی، برخی کارهای پژوهشی اخیر به موضوع به کارگیری روش های تجزیه تنسور برای جداسازی تصاویر پرداخته اند [۳۶] و [۳۷]. در اینجا، ۳ مدل NTF مختلف به ماتریس داده ها اعمال می شود. ماتریس های

بایستی از یکدیگر تفکیک شوند. در مقیاس میکروسکوپی، هر پیکسل ممکن است شامل مواد معدنی مختلف باشد که مساله جداسازی در این حالت پیچیده خواهد بود.

پردازش تصاویر ابرطیفی مورد نظر بسیاری از کاربردها از جمله تصاویر پزشکی، کشاورزی، معدن، تحلیل داده های سنسجش از دور و علوم محیطی می باشد [2-1]. تصاویر ابرطیفی به صورت گسترده ای برای کاربرد سنسجش از دور، مشاهدات زمینی و پزشکی مورد استفاده قرار گرفته اند [3-6]. در تصویر برداری ابرطیفی هم توزیع طیفی و هم توزیع مکانی مواد تشکیل دهنده تصویر بدست می آیند. این تصاویر قابلیت پوشش ناحیه 2500-300nm از طیف الکترومغناطیسی را دارند و برخلاف تصویر برداری چندطیفی، می توانند باندهای پیوسته داشته باشند [۱] و [۳].

حسگرهای استفاده شده در این تصویربرداری معمولاً تفکیک پذیری مکانی کمی دارند [۳] و [۴] و [۷]. بنابراین، طیف هر پیکسل می تواند شامل ترکیبی از طیف چند ماده باشد. روش های جداسازی تصاویر ابرطیفی در سالهای اخیر بسیار مورد توجه قرار گرفته اند و هدف آنها تفکیک کردن مواد سازنده هر پیکسل است. به طیف هر ماده، امضای طیفی گفته می شود و وزن هر ماده در هر پیکسل فراوانی نسبی آن ماده را نشان می دهد. مثلاً همانطور که در شکل (۱) نشان داده شده است، یک پیکسل می تواند از ۳ ماده تشکیل شده باشد که با روش های جداسازی طیف هر پیکسل به امضاهای طیفی مواد تشکیل دهنده و فراوانی هر یک از آنها تجزیه می گردد.



شکل ۱ جداسازی مواد تشکیل دهنده هر پیکسل

معمولاً مدل ترکیب خطی برای مخلوط شدگی پذیرفته می شود. مطابق با این فرض، طیف هر پیکسل به صورت ترکیب خطی طیف مواد تشکیل دهنده آن مدل می شود. تاکنون، بسیاری از رویکردهای جداسازی با فرض مدل خطی ارائه شده اند، از جمله آنها می توان به روش های هندسی تحلیل مولفه برداری (VCA) [۷]، الگوریتم simple growing [۸]، N-Finder [۹]، PPI [10] و maximization successive volume [۱۱] اشاره نمود. برخی دیگر از روش ها بر اساس اعمال قید تنک بودن به ماتریس فراوانی ارائه شده اند [۱۲] تا [۱۴]. همچنین برخی راهکارهای شبکه عصبی برای جداسازی مواد یک تصویر پیشنهاد شده اند [۱۵] و [۱۶]. دسته دیگر روش ها به عنوان روش های احتمالاتی شناخته می شوند. در این روش ها، توزیع احتمال پیشین معینی برای پارامترهای نامعلوم مدل فرض می شود و براساس آن تخمین مجهولات بدست می آید [۱۷] تا [۲۰].

استفاده می شوند [۳۹]. رویکرد بیزین مزایای متعددی دارد که از جمله آنها می توان به قدرت مدل سازی و امکان تخمین درجه مدل (در اینجا تعداد مواد تشکیل دهنده تصویر) نام برد.

۳ تکنیک های NTF استفاده شده برای بدست آوردن ویژگی ها

تکنیک های تجزیه تنسور در زمینه های مختلف پردازش سیگنال مورد استفاده قرار می گیرند. دو روش اصلی تجزیه تنسور روش Canonical Polyadic Decomposition (CPD) و روش Tucker هستند. استفاده از روش Tucker برای مساله مورد نظر امکان پذیر نمی باشد چرا که هیچ تناظری میان تنسورهای تجزیه شده و مولفه های سازنده تصویر وجود ندارد. قید نامنفی بودن باید به فاکتورهای بدست آمده اعمال شود تا نتایج تعبیرپذیر حاصل شوند.

یک مدل بر اساس تجزیه CP (Canonic Polyadic) نامنفی در [۳۶] به منظور جداسازی داده ابرطیفی پیشنهاد شده است. هرچند مود سوم نمایش تنسوری داده ها نمایانگر تعامل چندخطی میان مواد تشکیل دهنده می باشد و تنسور سه بعدی HSI با یک ماتریس بیان می شود که به این ترتیب ساختار مکانی حفظ نمی شود. در [۳۷]، تجزیه تنسور ماتریس-برداری برای جداسازی با هدف حفظ اطلاعات مکانی داده تصویر معرفی شده است. در پژوهش حاضر، سه روش تجزیه تنسور نامنفی مورد بررسی و مقایسه قرار می گیرند: (۱) Beta-NTF، (۲) Bayesian CP (BCP^T) و (۳) تجزیه تنسور نامنفی ماتریس برداری (MV-NTF^T). ماتریس های تجزیه شده حاصل از NMF بیزین (BNMF) در مرحله قبل می توانند به عنوان نقاط شروع الگوریتم های NTF مورد استفاده قرار گیرند. این امر بسیار کمک کننده خواهد بود چرا که روش های NTF به دلیل غیرمحدب بودن دارای حساسیت زیادی به انتخاب نقاط اولیه هستند. با استفاده از نتایج BNMF، می توان این مشکل را مرتفع نمود.

۳-۱ روش Beta-NTF

فرض کنید $\mathbf{V} \in \mathbb{R}^{F \times I \times J}$ یک تنسور HSI باشد که $I \times J$ تعداد پیکسل های مکانی و F تعداد باندهای فرکانسی است. مدل Beta-NTF تنسور \mathbf{V} را به سه ماتریس $\mathbf{E}_{F \times K}$ ، $\mathbf{H}_{I \times K}$ و $\mathbf{Q}_{J \times K}$ تجزیه می کند به طوری که داریم:

$$\mathbf{V}_{f,i,j} \approx \sum_{k=1}^K e_{fk} h_{ik} q_{jk} \quad \mathbf{E}, \mathbf{H}, \mathbf{Q} \geq \mathbf{0} \quad (3)$$

فاصله بتا (Beta divergence) تابع هزینه ای است که برای حل این مساله بهینه سازی مورد استفاده قرار می گیرد و باید حداقل

فراوانی حاصل به عنوان ویژگی های آموزشی برای طبقه بندی مورد استفاده قرار می گیرند. با هدف بهبود ویژگیها و استفاده مشترک از محتوای طیفی و مکانی، طیف تصویر به چندین زیرباند تجزیه می شود و روش های تجزیه تنسور به تنسورهای متناظر با هر زیرباند به صورت جداگانه اعمال می شوند. ماتریس های فراوانی بدست آمده برای هر زیرباند به دنبال هم قرار داده می شوند و ویژگیهای ورودی به شبکه عصبی را می سازند. در [۴۹]، ویژگیهای مشابه حاصل از NTF به کار گرفته شده اند ولی روش MLR^۱ برای طبقه بندی مورد استفاده قرار گرفته است. در [۵۲]، ساختار شبکه طبقه بندی تقریباً مشابهی به کار رفته است ولی ویژگیهای استخراج شده متفاوت هستند.

۲ مدل NMF بیزی برای تجزیه تصویر ابرطیفی

مدل NMF دارای کاربردهای وسیعی در زمینه های متعدد پردازش سیگنال می باشد. ماتریس نامنفی $\mathbf{V}_{F \times N}$ به صورت حاصل ضرب دو ماتریس نامنفی \mathbf{E} و \mathbf{A} تقریب زده می شود که اندازه اولی $F \times K$ و دومی $K \times N$ است. در مورد تصاویر ابرطیفی، \mathbf{V} نمایانگر داده ابرطیفی سه بعدی با F باند طیفی و N پیکسل است. ماتریس \mathbf{E} ماتریس endmember خوانده می شود که ستونهای آن امضاهای طیفی مواد تشکیل دهنده تصویر را بیان می کنند. ماتریس \mathbf{A} هم ماتریس فراوانی است که سهم هر ماده در هر پیکسل را نشان می دهد. یک معیار اختلاف میان ماتریس های $\mathbf{V} = \mathbf{E}\mathbf{A}$ و \mathbf{V} تعریف می شود و با حداقل سازی آن تجزیه مورد نظر بدست می آید. برخی معیارهای اختلاف مرسوم، فاصله اقلیدسی یا فاصله Kullback-Leibler (KL) هستند. در [۳۸]، روابط به روزرسانی ضرب شونده برای حل این مساله بهینه سازی و حصول پارامترهای مجهول داده شده اند.

به جای افزودن یک قید تنک بودن مانند حداقل سازی نرم l_1 به مساله NMF استاندارد، در اینجا نسخه بیزین NMF مورد استفاده قرار می گیرد. به این ترتیب که عناصر ماتریس فراوانی \mathbf{A} متغیر تصادفی فرض می شوند که با یک توزیع پیشین تنک داده شده اند. مدل تولید کننده داده های ابرطیفی به صورت زیر فرض می شود:

$$v_{fn} \sim P(v_{fn} | \sum_k e_{fk} a_{kn}) \quad (1)$$

که در آن P بیانگر توزیع پواسون می باشد که به صورت زیر تعریف می شود:

$$P(x | \lambda) = e^{-\lambda} \frac{\lambda^x}{\Gamma(x+1)} \quad (2)$$

عناصر ماتریس endmember غیرتصادفی فرض می شوند. روابط Variational Bayesian برای بدست آوردن این ماتریسها

^۲ Bayesian Candecomp/PARAFAC

^۳ Matrix-Vector NTF

Archive of SID

که در آن \mathbf{A}_k یک ماتریس $I \times J$ است که نمایانگر k امین

نقشه فراوانی می‌باشد و \mathbf{e}_k امضای طیفی k ام را نشان می‌دهد. ماتریسهای فراوانی به صورت حاصلضرب دو ماتریس \mathbf{B}_k و \mathbf{C}_k با ابعاد $I \times L_k$ و $J \times L_k$ مدل می‌شوند. L_k درجه ماتریس فراوانی k ام را کنترل می‌کند. روابط به هنگام سازی ضرب شونده بر اساس روش ALS^۳ در [۳۷] آورده شده است.

ماتریس های فراوانی بدست آمده با روش های NMF و یا NTF به عنوان ویژگی‌ها در طبقه بندی با استفاده از 3D CNN مورد استفاده قرار می‌گیرند. با استفاده از تکنیک‌های NTF ساختار مکانی پیکسل‌ها در تنسور تصویر حفظ می‌شود و بنابراین اطلاعات مکانی از بین نمی‌رود که این امر به بهبود ویژگی‌های استخراج شده و افزایش قدرت متمایزکنندگی آنها منجر می‌شود. همچنین در اینجا تنسورها در بعد فرکانس به چندین زیر باند تقسیم می‌شوند و تجزیه برای هر زیر تنسور مجزا صورت می‌پذیرد که باعث می‌شود اطلاعات مکانی و طیفی به صورت مشترک در بهبود ویژگی‌ها نقش ایفا کنند.

۴ توضیح چارچوب استخراج ویژگیها و طبقه بندی

در این بخش طبقه بندی با استفاده از شبکه‌های عصبی پیچشی مورد توجه قرار می‌گیرد. ویژگیهای بدست آمده در بالا به عنوان ورودی یک شبکه پیچشی سه بعدی استفاده خواهند شد. شبکه سه بعدی از هر دو دسته مشخصات مکانی و طیفی بهره می‌برد. ورودی شبکه به پنجره‌های سه بعدی با ابعاد $s \times s \times c$ تجزیه می‌شود که c همان بعد طیفی ورودی است. در مورد تجزیه زیر تنسورها، c برابر با $N = N_{sub} \times K$ می‌باشد که K تعداد کلاس‌ها و N_{sub} تعداد زیرباندها می‌باشد. شمای کلی روش پیشنهادی در بلوک دیاگرام شکل ۲ نمایش داده شده است. در مرکز هر یک از این پنجره‌ها پیکسلی قرار دارد که برچسب پنجره متناظر با این پیکسل مرکزی است. فرض کنید داده ورودی یک شبکه سه بعدی متشکل از M مکعب \mathbf{X}_m ($m=1,2,\dots,M$) با اندازه $I \times J \times K$ باشد. در این صورت خروجی هر هسته با اندازه $A \times B \times D$ یک تنسور سه بعدی \mathbf{Y} خواهد بود که به صورت زیر بدست می‌آید:

$$\mathbf{Y}(i, j, k) = \sum_{m=1}^M \sum_{a=0}^{A-1} \sum_{b=0}^{B-1} \sum_{d=0}^{D-1} \mathbf{X}_m(i+a, j+b, k+d). \text{Kernel}_m(a, b, d)$$

$$i = 1, 2, \dots, I - A + 1 \quad j = 1, 2, \dots, J - B + 1 \quad k = 1, 2, \dots, K - D + 1$$

(۶)

معماری شبکه پیشنهادی ما شامل دو لایه پیچشی پشت سر هم، یک لایه max-pooling و سپس سه لایه کاملاً متصل می‌باشد. لایه های اول و دوم n_1 هسته با اندازه $a_1 \times a_1 \times d_1$ و n_2

شود. در اینجا، $\beta=2$ لحاظ می‌شود که فاصله بتا را معادل با فاصله اقلیدسی قرار می‌دهد. روابط به هنگام سازی ضرب شونده [۴۰] و [۴۱] برای حل مساله و بدست آوردن ضرایب مجهول مورد استفاده قرار می‌گیرند. ماتریس \mathbf{E} شامل امضاها طیفی مواد است که در ستونهای ماتریس واقع شده‌اند. ضرب Khatri-Rao ماتریس های \mathbf{H} و \mathbf{Q} ماتریس فراوانی \mathbf{A} را بدست می‌دهد:

$$\mathbf{A}_{I \times K} = \mathbf{H} \odot \mathbf{Q}$$

۳-۲ تجزیه به روش CP بی‌زین

در چارچوب CP هم مشابه قسمت قبل مدل Candecomp/PARAFAC برای تجزیه تنسور در نظر گرفته می‌شود و تنسور $\mathbf{V}_{F \times I \times J}$ با مجموع K تنسور با درجه ۱ تقریب زده می‌شود [۴۲-۴۴]:

$$\mathbf{V} \approx \sum_{k=1}^K \mathbf{e}_k \otimes \mathbf{h}_k \otimes \mathbf{q}_k \quad \mathbf{E}, \mathbf{H}, \mathbf{Q} \geq 0$$

$$\mathbf{W} = [\mathbf{e}_1 \dots \mathbf{e}_K] \quad (۴)$$

$$\mathbf{H} = [\mathbf{h}_1 \dots \mathbf{h}_K]$$

$$\mathbf{Q} = [\mathbf{q}_1 \dots \mathbf{q}_K]$$

که \otimes بیانگر عملگر ضرب خارجی است و ضرب خارجی سه بردار $\mathbf{e}_k \otimes \mathbf{h}_k \otimes \mathbf{q}_k$ یک تنسور درجه یک خوانده می‌شود. کوچکترین مقدار K که به ازای آن معادله بالا به تساوی تبدیل می‌شود به عنوان درجه تنسور شناخته می‌شود.

قالب BCD^1 و الگوریتم ANLS^2 برای حل مساله بهینه سازی با تابع هزینه خطای مربعات به کار می‌روند [۴۲]. در نسخه بی‌زین (BCP)، عناصر تنسور تصویر متغیرهای تصادفی با توزیع پواسون فرض می‌شوند. روش Alternating Poisson Regression برای حل این مساله بهینه‌سازی و یافتن ماتریس‌های حاصل از تجزیه به کار می‌رود [۴۸]. در اینجا نیز ماتریس فراوانی با ضرب Khatri-Rao ماتریسهای \mathbf{H} و \mathbf{Q} حاصل می‌شود.

۳-۳ تجزیه تنسور نامنفی به روش ماتریس برداری (MV-NTF)

این رویکرد در مرجع [۳۷] به منظور جداسازی تصاویر معرفی شده است. با استفاده از این روش تنسور سه بعدی $\mathbf{V}_{I \times J \times F}$ به صورت زیر تقریب زده می‌شود:

$$\mathbf{V} \approx \sum_{k=1}^K \mathbf{A}_k \otimes \mathbf{e}_k = \sum_{k=1}^K \mathbf{B}_k \cdot \mathbf{C}_k \otimes \mathbf{e}_k$$

$$\mathbf{B}_k, \mathbf{C}_k, \mathbf{e}_k \geq 0 \quad (۵)$$

^۱ Block Coordinate Descent

^۲ Alternating Non-negative Least Square
www.SID.ir

^۳ Alternating Least Square

آمده است. لایه اول دارای ۲ هسته با اندازه $3 \times 3 \times 7$ می باشد. لایه دوم ۴ هسته با ابعاد $3 \times 3 \times 1$ دارد. تکنیک dropout با نسبت ۰,۲۵، بعد از لایه دوم قرار گرفته است. در نهایت، ۳ لایه کاملاً متصل با ۴۲، ۶۴ و ۴۲ نورون قرار دارند که K برابر با تعداد کلاس‌ها برای هر مجموعه داده است. اندازه batch ۲۰ قرار داده شده است. Cross entropy برای تعریف تابع تلف استفاده شده است. نتایج میانگین دقت طبقه بندی با استفاده از معبرسازی ۱۰ لایه به عنوان معیار عملکرد الگوریتم گزارش می شوند. در اینجا ویژگی‌های ورودی حاصل از BNMF با سه روش تجزیه تسور

است. الگوریتم Gradient descent با مونتوم برای حل مساله


بهینه سازی به کار می رود [۴۷].

جدول ۱ معماری شبکه CNN

Layer#	Type	#kernels	kernel-size	Activation
1	conv3d	2	(3, 3, 7)	ReLU
2	conv3d	4	(3, 3, 1)	ReLU
3	Dropout(.25)	-	-	-
4	Dense(64)	-	-	ReLU
5	Dense(42)	-	-	ReLU
6	Dense(K)	-	-	softmax

هسته با اندازه $a_2 \times a_2 \times d_2$ دارند. برای هر دو لایه پیشگی گام‌های $1 \times 1 \times 1$ انتخاب می شوند. بنابراین خروجی لایه اول n_1 مکعب است که هریک دارای ابعاد $(s-a_1+1) \times (s-a_1+1) \times (c-d_1-1)$ هستند و خروجی لایه دوم n_2 مکعب با ابعاد $(s-a_1-d_1+1) \times (s-a_1-d_1+1) \times (c-d_1-d_2+2)$ می باشد.

برای پیشگیری از مساله ناپدید شدن گرادیان تابع فعالسازی ReLU برای همه لایه ها انتخاب می شود به جز لایه آخر که از تابع softmax استفاده می نماید. برای اجتناب از بیش برآزش، از تکنیک‌های dropout [۴۵] و early stopping [۴۶] استفاده شده است. الگوریتم Gradient descent با مونتوم برای حل مساله



شکل ۲ شمای کلی روش پیشنهادی

۵ آزمایش‌ها

۱-۵ داده Indiana Pines

این تصویر توسط سنسور AVIRIS از محل Indiana Pines واقع در ایندیانا جمع آوری شده است. تصویر شامل 145×145 پیکسل و ۲۲۴ باند طیفی در بازه طول موج $0.4-2.5 \mu m$ می باشد. وضوح مکانی این داده ۲۰ متر در پیکسل است. تصویر شامل مناطق کشاورزی، جنگل و پوشش گیاهی می باشد. ۱۶ کلاس وجود دارد و اطلاعات مربوط به تخصیص پیکسل‌ها به هر کلاس موجود است (شکل ۳). با حذف باندهای مربوط به جذب آب تعداد باندها به ۲۰۰ کاهش پیدا می کند. داده Indiana به جهت توزیع بسیار غیر یکنواخت نمونه‌ها در ۱۶ کلاس موجود داده چالشی محسوب می شود. نتایج طبقه بندی برای روش های مختلف استخراج ویژگی در شکل ۴ آورده شده است. دقت طبقه بندی برای هر کلاس به صورت مجزا بدست آمده و مقدار دقت های میانگین، overall و kappa در جدول ۲ گزارش شده اند. همانطور که مشاهده می شود روش های Beta-NTF و BCP به نتایج بهتری می رسند. این امر می تواند به استخراج خوب ویژگی های مکانی توسط این دو روش ارتباط داده شود. نقشه کلاس های بدست آمده با روش BCP در شکل ۵ ارائه شده است که نشان می دهد بیشتر خطاها مربوط به کلاس های با تعداد کمتر نمونه آموزشی موجود می باشد.

عملکرد الگوریتم با به کارگیری آن برای طبقه بندی تصاویر HSI واقعی Indiana Pines، دانشگاه Pavia و Salinas ارزیابی می شود. منبع داتلود این داده ها [۵۰] می باشد که علاوه بر ارائه تصاویر اصلی، نقشه مرجع کلاس های درست را برای هر پیکسل مشخص کرده است. توضیح این داده ها در زیربخش های مرتبط داده خواهد شد. دقت طبقه بندی برای هر کلاس به صورت مجزا بدست می آید و نتایج BNMF با روش های NTF مورد مقایسه قرار می گیرد. پارامتر L_k که بیانگر درجه ماتریس های فراوانی است همه جا ۱۰۰ قرار داده می شود.


تعداد مولفه های تجزیه شده برابر با تعداد معلوم طبقه ها، K ، برای هر داده قرار داده می شود. در بعد فرکانس، داده ها به $N_s = 10$ زیرباند تقسیم می شوند. ۲۰ درصد نمونه های هر کلاس برای آموزش و باقی برای تست مورد استفاده قرار می گیرند. فرآیندهای توزیع گاما برابر با $\alpha = 0.2, \beta = 1$ انتخاب می شوند. معیار متوقف سازی الگوریتم های NMF و NTF برای همگرایی با مقایسه تغییرات تابع هزینه با یک حد آستانه حاصل می شود. همه الگوریتم ها ۱۰ بار تکرار می شوند و میانگین نتایج گزارش می شوند.

برای یافتن مقادیر بهینه پارامترهای شبکه کانولوشنال سه بعدی، به صورت تصادفی ۱۰ درصد نمونه ها از هر کلاس برای آموزش، ۱۰ درصد برای اعتبارسنجی و مابقی برای آزمودن انتخاب می شوند. معماری بهینه شبکه در جدول ۱ نشان داده شده است که به صورت تجربی برای حصول بهترین عملکرد بدست


Archive of SID

۲-۵ داده Pavia

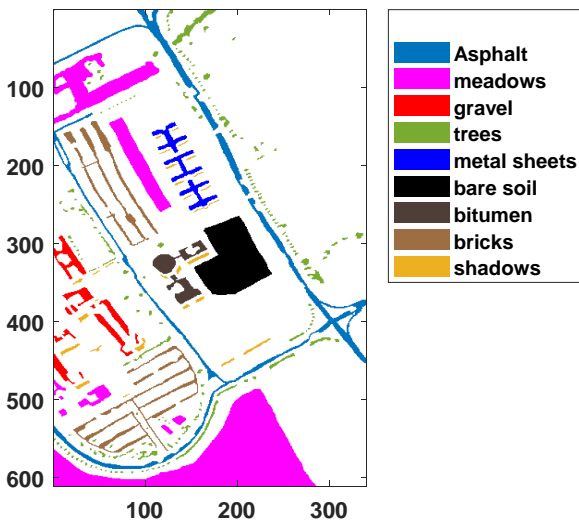
این تصویر توسط سنسور ROSIS از دانشگاه پابویا در شمال ایتالیا جمع آوری شده است. تعداد 610×340 پیکسل در تصویر وجود دارد و تعداد باندهای طیفی ۱۰۳ است. وضوح مکانی ۱,۳ متر می‌باشد. در این تصویر ۹ طبقه مختلف وجود دارد که در شکل ۶ نشان داده شده است. دقت‌های بدست آمده در شکل ۷ و جدول ۳ فهرست شده‌اند. باز هم روش BCP بهتر از بقیه عمل می‌کنند. نقشه کلاسهای بدست آمده با روش BCP در شکل ۸ ارائه شده است که نشان می‌دهد بیشتر خطاها مربوط به نواحی باریک تر یا نقاط مرزی می‌باشد.




شکل ۳ داده Indiana Pines با ۱۶ کلاس



شکل ۴ دقت‌های بدست آمده برای داده Indiana



شکل ۶ داده دانشگاه Pavia با ۹ کلاس



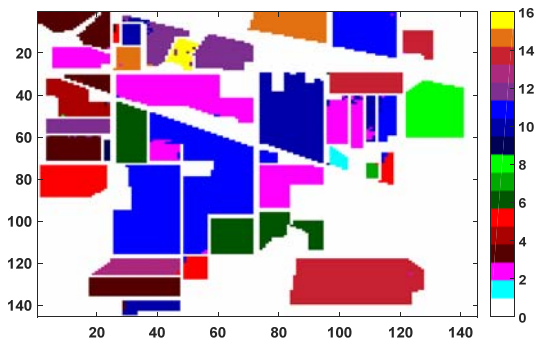
شکل ۷ دقت‌های بدست آمده برای داده دانشگاه Pavia

جدول ۳ عملکرد روش‌های مختلف برای داده دانشگاه Pavia

METHODS	BNMF	BCP	BETA-NTF	MV-NTF
AVERAGE ACCURACY(%)	91.42	97.63	96.72	96.49
OVERALL ACCURACY(%)	92.59	97.62	97.01	97.27
Kappa Accuracy(%)	90.26	96.90	96.01	96.66


جدول ۲ عملکرد روش‌های مختلف برای داده Indiana

METHODS	BNMF	BCP	BETA-NTF	MV-NTF
AVERAGE ACCURACY(%)	77.35	98.61	97.32	92.1
OVERALL ACCURACY(%)	90.41	98.83	98.23	9522
Kappa Accuracy(%)	89.48	98.71	97.92	94.35



شکل ۵ نقشه کلاسهای بدست آمده برای داده Indiana با روش BCP


Archive of SID



شکل ۱۰ دقت های بدست آمده برای داده Salinas

جدول ۴ عملکرد روش های مختلف برای داده Salinas


METHODS	BNMF	BCP	BETA-NTF	MV-NTF
AVERAGE ACCURACY(%)	93.53	99.11	97.25	98.75
OVERALL ACCURACY(%)	92.12	99.05	96.42	98.43
Kappa Accuracy(%)	93.38	98.95	96.07	98.36



شکل ۸ نقشه کلاسهای بدست آمده برای داده Pavia با روش BCP


۳-۵ داده Salinas

این تصویر هم توسط سنسور AVIRIS از دره Salinas در کالیفرنیا گرفته شده است. وضوح مکانی ۳,۷ متر است. تصویر شامل 512×217 پیکسل و ۲۲۴ باند طیفی می باشد. مانند داده Indiana در اینجا هم ۲۰ باند مربوط به جذب آب حذف می شوند و ۲۰۴ باند باقی می ماند. داده Salinas شامل ۱۶ کلاس است که در شکل ۸ نشان داده شده اند. نتایج طبقه بندی در شکل ۹ و جدول ۴ مشاهده می شود. روش BCP به طور چشمگیری بهتر عمل می کند. نقشه کلاسهای بدست آمده با روش BCP در شکل ۱۱ ارائه شده است که عملکرد بهینه روش پیشنهادی را نشان می دهد. بیشتر خطاها مربوط به نواحی باریک تر یا نقاط مرزی می باشد.




شکل ۱۱ نقشه کلاسهای بدست آمده برای داده Salinas با روش BCP

به منظور سنجش میزان کارایی عملکرد شبکه عصبی ۳ بعدی استفاده شده، نتایج برای داده ایندیانا با به کارگیری روش SVM هم محاسبه شده اند (جدول ۵). همانطور که مشاهده می شود، استفاده از CNN پیشنهادی به عملکرد بسیار بهتری منجر می شود. در مورد SVM هم ویژگیهای BCP به نتیجه بهتری می رسد.




شکل ۹ داده Salinas با ۱۶ کلاس

Archive of SID



شکل ۱۲ تغییرات دقت میانگین (%) با اندازه پنجره ورودی



شکل ۱۳ تغییرات دقت میانگین (%) با اندازه هسته پیچشی

جدول ۶ مقایسه با نتایج مرجع [۵۱] برای داده Indiana

METHODS	O-CNN	E-CNN	Multifeatu re-CNN	Our proposed method
AVERAGE ACCURACY(%)	94.77	95.04	98.46	98.72
OVERALL ACCURACY(%)	89.14	93.04	97.57	98.53
Kappa Accuracy(%)	87.73	92.11	97.23	98.73

جدول ۷- مقایسه با نتایج مرجع [۵۱] برای داده Pavia

METHODS	O-CNN	E-CNN	Multifeature-CNN	Our proposed method
AVERAGE ACCURACY(%)	96.17	98.44	99.61	98.13
OVERALL ACCURACY(%)	95.25	98.99	99.64	98.02
Kappa Accuracy(%)	93.75	98.67	99.53	97.94

جدول ۵ نتایج بدست آمده برای روش SVM

METHODS	BNMF	BCP	BETA-NTF	MV-NTF
AVERAGE ACCURACY(%)	47.46	88.45	88.28	65.93
OVERALL ACCURACY(%)	46.33	92.18	91.21	70.64
Kappa Accuracy(%)	45.32	91.22	91.01	68.91

۶ بحث و بررسی بیشتر

در این بخش، به سنجش میزان حساسیت روش ارائه شده به برخی پارامترها نظیر ابعاد پنجره به کار رفته روی داده ورودی به شبکه و ابعاد هسته‌های پیچش پرداخته می‌شود. سپس روش پیشنهادی با روش‌های ارائه شده در مقاله [۵۱] مقایسه می‌شود. در ابتدا، اثر ابعاد پنجره در ورودی (s) بر روی عملکرد مورد بررسی قرار می‌گیرد. برای این منظور مقدار دقت میانگین برای همه داده‌ها با روش BCP بدست آمده و در نمودار میله‌ای شکل ۱۲ به ازای مقادیر مختلف s نمایش داده شده است. همانطور که مشاهده می‌شود استفاده از پنجره 7×7 (s=7) برای هر سه داده به مقادیر دقت بهتری می‌انجامد.

در [۵۱]، سه ساختار مختلف شبکه پیچشی برای طبقه بندی طراحی شده‌اند. شبکه اول که O-CNN نام گرفته، با ویژگی‌های شامل داده‌های تصویر اصلی آموزش داده می‌شود. شبکه E-CNN، ۵ مجموعه ویژگی را با هم ترکیب نموده و در ورودی شبکه قرار می‌دهد و با آنها آموزش داده می‌شود. شبکه نهایی پیشنهادی این مقاله به صورت چندویژگی^۱ عمل می‌کند و به ازای هر یک از ۵ دسته ویژگی یک شبکه کانولوشنال مجزا آموزش داده می‌شود. به منظور مقایسه، تعداد نمونه‌های آموزشی و آزمون برای هر مجموعه داده مطابق با جداول ۱-۳ از مرجع [۵۱] قرار داده شده است. نتایج عملکرد با روش BCP برای سه داده Indiana، Pavia و Salinas به ترتیب در جداول ۶-۸ گزارش شده‌اند. همانطور که مشاهده می‌شود، با وجودی که در روش چندویژگی یا E-CNN پیشنهادی مقاله [۵۱] ابعاد ویژگی‌ها بسیار بزرگتر هستند و پیچیدگی شبکه پیچشی ارائه شده بیشتر است ولی عملکرد روش ما در مقایسه با بهترین نتایج این مقاله در مورد داده‌های ایندیانا و سالیناس پیشی گرفته است و در مورد داده پاولیا قابل قبول است. عملکرد حاصله برای داده پاولیا را می‌توان به کمتر بودن تفکیک پذیری مکانی این داده نسبت داد.

METHODS	O-CN N	E-CN N	Multifeature-CNN	Our proposed method
AVERAGE ACCURACY(%)	96.9	98.5	99.33	99.41
OVERALL ACCURACY(%)	94.0	96.6	98.34	99.07
Kappa Accuracy(%)	93.3	96.2	98.15	98.83

۷ نتیجه گیری

در این مقاله به مساله طبقه بندی پیکسل ها در تصاویر ابرطیفی ماهواره ای پرداخته شد. روش های تجزیه تنسور نامفنی به عنوان تکنیک های موثر برای یافتن ویژگیهای متمایز کننده به کار گرفته شدند. به این ترتیب که ماتریس فراوانی حاصل از تجزیه تنسور تصویر به عنوان ویژگی به کار می رود. نشان داده شده است که ماتریس فراوانی حاصل از تجزیه تنسور بسیار بهتر از تجزیه ماتریس عمل می کند چون اطلاعات مکانی و ساختار مکانی پیکسل های تصویر را حفظ می کند. همچنین تصاویر در بعد فرکانس به چندین زیرباند تقسیم شدند و ماتریس فراوانی برای هر زیرتنسور حاصل به صورت جداگانه بدست آمد. این ماتریس ها ویژگی های ورودی به شبکه عصبی را تشکیل می دهند و به این ترتیب اطلاعات مکانی و طیفی تواما در بهبود عملکرد تاثیرگذار خواهند بود. برای طبقه بندی، یک شبکه پیچشی سه بعدی پیشنهاد شد که ماتریس های فراوانی را در ورودی به عنوان ویژگی مورد استفاده قرار می دهد. نتایج روش SVM به عنوان مقایسه ارائه شده است. همچنین عملکرد روش پیشنهادی با روش مقاله اخیر در همین زمینه مورد مقایسه قرار گرفته است که کارایی مدل پیشنهادی را نمایان می سازد.

تقدیر و تشکر

این پژوهش با حمایت مالی پژوهشگاه فضایی ایران بر اساس قرارداد شماره ۹۶/۱۰۵۰/۳۹۴/ق انجام شده است. همچنین ضروری است از وبسایت [۵۰] برای در اختیار قرار دادن تصاویر استفاده شده تشکر شود.

مراجع

- [3] J. Bioucas-Dias et al., "Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, no. 2, pp. 354–379, April 2012.
- [4] T. M. Lillesand, *Remote Sensing and Image Interpretation*. John Wiley & Sons, 2006.
- [5] N. Keshava and J. Mustard, "Spectral unmixing," *IEEE Signal Processing Magazine*, vol. 19, no. 1, pp. 44–57, Jan 2002.
- [6] G. Shaw and D. Manolakis, "Signal processing for hyperspectral image exploitation," *IEEE Signal Processing Magazine*, vol. 19, no. 1, pp. 12–16, Jan 2002.
- [7] J. M. P. Nascimento and J. Bioucas-Dias, "Vertex component analysis: A fast algorithm to unmix hyperspectral data," *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 4, pp. 898–910, Apr. 2005.
- [8] C. I. Chang, C. C. Wu, W. Liu, and Y. C. Ouyang, "A new growing method for simplex-based endmember extraction algorithm," *IEEE Trans. Geosci. Remote Sens.*, vol. 44, no. 10, pp. 2804–2819, Oct. 2006.
- [9] M. E. Winter, "N-FINDR: An algorithm for fast autonomous spectral end-member determination in hyperspectral data," in *Proc. SPIE's Int. Symp. Opt. Sci., Eng., Instrum.*, Oct. 1999, pp. 266–275.
- [10] J. W. Boardman, F. A. Kruse, and R. O. Green, "Mapping target signatures via partial unmixing of AVIRIS data," in *Proc. JPL Airborne Earth Sci. Workshop*, 1995, pp. 23–26.
- [11] T. H. Chan, W. K. Ambikapathi, and C. Y. Chi, "A simplex volume maximization framework for hyperspectral endmember extraction," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 11, pp. 4177–4193, Nov. 2011.
- [12] M.-D. Iordache, J. Bioucas-Dias, and A. Plaza, "Sparse unmixing of hyperspectral data," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 6, pp. 2014–2039, Jun. 2011.
- [13] M.-D. Iordache, J. Bioucas-Dias, and A. Plaza, "Total variation spatial regularization for sparse hyperspectral unmixing," *IEEE Trans. Geosci. Remote Sens.*, vol. 50, no. 11, pp. 4484–4502, Nov. 2012.
- [14] X.-L. Zhao, F. Wang, T.-Z. Huang, M. K. Ng, and R. J. Plemmons, "Deblurring and sparse unmixing for hyperspectral images," *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 7, pp. 4045–4058, Jul. 2013.
- [15] G. A. Licciardi and F. Del Frate, "Pixel unmixing in hyperspectral data by means of neural networks," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 49, no. 11, pp. 4163–4172, Nov 2011.
- [16] R. Guo, W. Wang, and H. Qi, "Hyperspectral image unmixing using autoencoder cascade," in *IEEE 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, 2015, pp. 1–4.
- [1] J. A. Richards, *Remote Sensing Digital Image Analysis: An Introduction*, Springer Berlin Heidelberg, NJ, USA, 5th edition, 2013.
- [2] *Hyperspectral Imaging Remote Sensing: Physics, Sensors, and Algorithms* 1st Edition, Dimitris G. Manolakis, Ronald B. Lockwood, Thomas W. Cooley, Cambridge University Press 2016.

Archive of SID

- 5, no. 3, pp. 521–533, June 2011. doi: 10.1109/JSTSP.2010.2096798
- [29] Y. Chen, X. Zhao, and X. Jia, "Spectral-spatial classification of hyperspectral data based on deep belief network," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 6, pp. 2381–2392, 2015.
- [30] He, Zhi, Lin Liu, Ruru Deng, and Yi Shen. "Low-rank group inspired dictionary learning for hyperspectral image classification." *Elsevier Signal Processing* 120 (2016): 209–221.
- [31] He, Zhi, Jie Hu, and Yiwen Wang. "Low-rank tensor learning for classification of hyperspectral image with limited labeled samples." *Elsevier Signal Processing* 145 (2018): 12–25.
- [32] Wang, Ziyu, Jianxiong Liu, and Jing-Hao Xue. "Joint sparse model-based discriminative K-SVD for hyperspectral image classification." *Elsevier Signal Processing* 133 (2017): 144–155.
- [33] Wang, Ziyu, Rui Zhu, Kazuhiro Fukui, and Jing-Hao Xue. "Cone-based joint sparse modelling for hyperspectral image classification." *Elsevier Signal Processing* 144 (2018): 417–429.
- [34] Leng, Jiabing, Tao Li, Gang Bai, Qiankun Dong, and Han Dong. "Cube-CNN-SVM: A Novel Hyperspectral Image Classification Method." In *Tools with Artificial Intelligence (ICTAI)*, 2016 IEEE 28th International Conference on, pp. 1027–1034. IEEE, 2016.
- [35] Zhong, Zilong, Jonathan Li, Zhiming Luo, and Michael Chapman. "Spectral-Spatial Residual Network for Hyperspectral Image Classification: A 3-D Deep Learning Framework." *IEEE Transactions on Geoscience and Remote Sensing* 56, no. 2 (2018): 847–858.
- [36] Veganzones, Miguel A., Jérémy E. Cohen, Rodrigo Cabral Farias, Jocelyn Chanussot, and Pierre Comon. "Nonnegative tensor CP decomposition of hyperspectral data." *IEEE Transactions on Geoscience and Remote Sensing* 54, no. 5 (2016): 2577–2588.
- [37] Qian, Yuntao, Fengchao Xiong, Shan Zeng, Jun Zhou, and Yuan Yan Tang. "Matrix-vector nonnegative tensor factorization for blind unmixing of hyperspectral imagery." *IEEE Transactions on Geoscience and Remote Sensing* 55, no. 3 (2017): 1776–1792.
- [38] D. D. Lee and H. S. Seung, "Learning the parts of objects with nonnegative matrix factorization," *Nature*, vol. 401, pp. 788–791, 1999.
- [39] O. Dikmen, C. Fevotte, "Maximum Marginal Likelihood Estimation for Nonnegative Dictionary Learning in the Gamma-Poisson Model," *IEEE Transactions on Signal Processing*, vol. 60, no. 10, pp. 5163–5175, Oct. 2012.
- [40] Algorithms for non-negative tensor factorization, Markus Flatz, Technical report 2013–05, Salzburg University, Nov. 2013.
- [17] Arngren, Morten, Mikkel N. Schmidt, and Jan Larsen. "Unmixing of hyperspectral images using Bayesian non-negative matrix factorization with volume prior." *Journal of Signal Processing Systems* 65, no. 3 (2011): 479–496.
- [18] Gewali, Utsav B., Sildomar T. Monteiro, and Eli Saber. "Machine learning based hyperspectral image analysis: A survey." *arXiv preprint arXiv:1802.08701* (2018).
- [19] . M. Bioucas-Dias et al., "Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-Based Approaches," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, no. 2, pp. 354–379, April 2012. doi: 10.1109/JSTARS.2012.2194696
- [20] Caiafa, Cesar F., Emanuele Salerno, Araceli N. Proto, and L. Fiumi. "Blind spectral unmixing by local maximization of non-Gaussianity." *Elsevier Signal Processing* 88, no. 1 (2008): 50–68.
- [21] Y. Qian, S. Jia, J. Zhou, and A. Robles-Kelly, "Hyperspectral unmixing via $l_1=2$ sparsity-constrained nonnegative matrix factorization," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 49, no. 11, pp. 4282–4297, Nov 2011.
- [22] S. Jia and Y. Qian, "Constrained nonnegative matrix factorization for hyperspectral unmixing," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 1, pp. 161–173, Jan 2009.
- [23] X. Lu, H. Wu, Y. Yuan, P. Yan, and X. Li, "Manifold regularized sparse nmf for hyperspectral unmixing," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 5, pp. 2815–2826, May 2013.
- [24] L. Tong, J. Zhou, X. Li, Y. Qian, and Y. Gao, "Region-based structure preserving nonnegative matrix factorization for hyperspectral unmixing," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 4, pp. 1575–1588, April 2017.
- [25] Zechao Li, Jing Liu, and Hanqing Lu, "Structure preserving nonnegative matrix factorization for dimensionality reduction," *Computer Vision and Image Understanding*, vol. 117, no. 9, pp. 1175–1189, 2013.
- [26] Yi-Hsing TSENG, "Spectral unmixing for the classification of hyperspectral images," 2010.
- [27] A. Villa, J. Li, A. Plaza and J. M. Bioucas-Dias, "A new semi-supervised algorithm for hyperspectral image classification based on spectral unmixing concepts," *2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Lisbon, 2011, pp. 1–4. doi: 10.1109/WHISPERS.2011.6080875
- [28] A. Villa, J. Chanussot, J. A. Benediktsson and C. Jutten, "Spectral Unmixing for the Classification of Hyperspectral Images at a Finer Spatial Resolution," in *IEEE Journal of Selected Topics in Signal Processing*, vol.

Archive of SID



سایه میرزایی مدرک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی برق-مخابرات از دانشگاه تهران دریافت کرده است. دوره دکتری را در دانشگاه KULeuven بلژیک در همین رشته سپری نموده و عضو تیم تحقیقاتی پروژه‌های اروپایی VASI و Cametron بوده است. در

حال حاضر عضو هیات علمی دانشکده علوم مهندسی دانشکده فنی دانشگاه تهران است. زمینه‌های پژوهشی مورد علاقه ایشان شامل کاربرد روش‌های یادگیری ماشین در پردازش سیگنال‌های صدا، تصویر و سیگنال‌های پزشکی می‌باشد. حاصل این پژوهش‌ها در مجلات یا کنفرانس‌های بین‌المللی متعددی به چاپ رسیده است. همچنین به عنوان عضو هسته پژوهشی پردازش سیگنال و یادگیری ماشین در دانشگاه تهران فعالیت می‌نماید و در قالب طرح‌های پژوهشی با پژوهشکده سامانه‌های ماهواره‌ای و پژوهشگاه زلزله‌شناسی همکاری داشته است.



جواد حق شناس مدرک کارشناسی ارشد خود را در رشته فیزیک اتمی در سال ۸۹ از دانشگاه علم و صنعت ایران دریافت کرد. او سابقه فعالیت بعنوان طراح اپتیک و الکترواپتیک در ماهواره‌های ملی نوید و ظفر، مشاور فنی در پروژه‌های ماهواره‌ای مختلف،

پژوهشگر ارشد در پژوهشکده سامانه‌های ماهواره را دارا است و در حال حاضر مدیر بخش محموله‌های سنجشی آن پژوهشکده می‌باشد. او تاکنون بیش از ۳۰ مقاله علمی، کتاب و اختراع را به طبع رسانده است. او همچنین داور رسمی مجلات Applied Optics و Optics Express است و از سال ۲۰۱۳ عضو انجمن‌های SPIE و OSA می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان، مدلسازی اتمسفر، طراحی الکترواپتیک و ساخت دوربین‌های ماهواره و همچنین تصحیح و پردازش تصاویر ماهواره‌ای است.

- [41] Cichocki, Andrzej, Rafal Zdunek, Anh Huy Phan, and Shun-ichi Amari. Nonnegative matrix and tensor factorizations: applications to exploratory multi-way data analysis and blind source separation. John Wiley & Sons, 2009.
- [42] Jingu Kim, Yunlong He, and Haesun Park. Algorithms for Nonnegative Matrix and Tensor Factorizations: A Unified View Based on Block Coordinate Descent Framework. *Journal of Global Optimization*, 58(2), pp. 285-319, 2014.
- [43] Jingu Kim and Haesun Park. Fast Nonnegative Matrix Factorization: An Active-set-like Method And Comparisons. *SIAM Journal on Scientific Computing (SISC)*, 33(6), pp. 3261-3281, 2011.
- [44] Jingu Kim and Haesun Park, Fast Nonnegative Tensor Factorization with an Active-set-like Method. In *High-Performance Scientific Computing: Algorithms and Applications*, Springer, 2012, pp. 311-326.
- [45] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov; "Dropout: A Simple Way to Prevent Neural Networks from Overfitting " 15(Jun):1929-1958, 2014.
- [46] Prechelt, Lutz. "Early stopping—but when?." *Neural networks: tricks of the trade*. Springer, Berlin, Heidelberg, 2012. 53-67.
- [47] Ruder (2016). An overview of gradient descent optimization algorithms. arXiv preprint arXiv: 1609.04747
- [48] Chi, Eric C., and Tamara G. Kolda. "On tensors, sparsity, and nonnegative factorizations." *SIAM Journal on Matrix Analysis and Applications* 33, no. 4 (2012): 1272-1299.
- [49] Sayeh Mirzaei, "Hyperspectral Image Classification using Band-Group Non-negative Tensor Factorization", *The Fourth Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS 2018)*.
- [50] http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes
- [51] Gao, Qishuo, Samsung Lim, and Xiuping Jia. "Hyperspectral image classification using convolutional neural networks and multiple feature learning." *Remote Sensing* 10, no. 2 (2018): 299.
- [52] Sayeh Mirzaei, Hugo Van hamme and Shima Khosravani. "Hyperspectral image classification using Non-negative Tensor Factorization and 3D Convolutional Neural Networks." *Signal Processing: Image Communication* 76 (2019): 178-185.