

## بهبود عملکرد شبکه نواحی تصادفی با استفاده از آنالیز تفکیک پذیری خطی به منظور استخراج ویژگی‌های عمیق از تصاویر ابرطیفی

بهنام اصغری بیرامی<sup>۱\*</sup>، مهدی مختارزاده<sup>۲</sup>

۱- دانشجوی دکتری سنجش از دور- دانشکده مهندسی نقشه برداری- دانشگاه صنعتی خواجه نصیرالدین طوسی  
۲- دانشیار گروه فتوگرامتری و سنجش از دور- دانشکده مهندسی نقشه برداری- دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۳۹۸/۰۸/۲۶ تاریخ پذیرش مقاله: ۱۳۹۹/۰۲/۲۰

### چکیده

در چند سال گذشته مدل‌های عمیق، توفیق فراوانی در شاخه‌های مختلف پردازش تصویر پیدا کرده‌اند. به طور خاص در سنجش از دور ابرطیفی از این مدل‌ها در شاخه‌هایی نظیر طبقه‌بندی و شناسایی اهداف با موفقیت استفاده شده است. اخیراً روش شبکه نواحی تصادفی به منظور استخراج ویژگی‌های عمیق برای طبقه‌بندی تصاویر ابرطیفی پیشنهاد شده است. اهمیت این شبکه در آن است که ویژگی‌های عمیق را به صورت نظارت نشده استخراج می‌کند و عملکردی سریع دارد. علیرغم عملکرد مطلوب این شبکه، از آنجایی که در ساختار اصلی آن از روش تبدیل مؤلفه اصلی استفاده می‌شود، در ویژگی‌های استخراج شده قید بیشینه شدن تفکیک‌پذیری میان کلاس‌ها در نظر گرفته نشده است. از این رو در این تحقیق از آنالیز تفکیک‌پذیری خطی به منظور بهبود ساختار این شبکه استفاده شده است. نتایج پیاده‌سازی‌ها بر روی دو مجموعه داده ابرطیفی نشان از آن دارد که روش پیشنهادی ویژگی‌های مناسب‌تر و فشرده‌تری را برای طبقه‌بندی تصاویر ابرطیفی استخراج می‌کند. به طور کلی روش پیشنهادی توانسته است که ضمن افزایش سرعت و فشرده‌سازی بیشتر ابعاد داده، دقت کلی طبقه‌بندی را تا ۲٫۵ درصد نسبت به روش شبکه نواحی تصادفی افزایش دهد.

کلید واژه‌ها: طبقه‌بندی تصاویر ابرطیفی، شبکه‌های نواحی تصادفی، تبدیل آنالیز تفکیک‌پذیری خطی، تبدیل مؤلفه اصلی، ویژگی‌های سلسله مراتبی عمیق

\* نویسنده مکاتبه کننده: ایران-تهران- خیابان ولی عصر- دانشکده مهندسی ژئودزی و ژئوماتیک دانشگاه صنعتی خواجه نصیرالدین طوسی

تلفن: ۰۲۱-۸۸۷۷۰۷۱

## ۱- مقدمه

سنجنده‌های ابرطیفی به دلیل توانایی بازسازی نسبتاً دقیق امضای طیفی مواد، به ابزاری سودمند برای مطالعات پدیده‌های سطح زمین تبدیل شده‌اند. طبقه‌بندی تصاویر ابرطیفی از جمله‌ی مهم‌ترین شاخه‌های پردازشی این تصاویر است که تا به حال تلاش‌های مختلفی به منظور بهبود آن صورت گرفته است. در طبقه‌بندی نظارت‌شده این تصاویر به طور کلاسیک از ویژگی‌های طیفی استفاده می‌شود. به دلیل شباهت امضای طیفی برخی عارضه‌های موجود در سطح زمین (مانند شباهت پشت بام ساختمان از جنس آسفالت و عارضه راه)، عموماً طبقه‌بندی با ویژگی‌های طیفی منجر به تولید نقشه‌های طبقه‌بندی‌شده نویزی می‌شود. برای حل این مشکل از ویژگی‌های مکانی در کنار ویژگی‌های طیفی در طبقه‌بندی این تصاویر استفاده می‌شود. تاکنون روش‌های زیادی به منظور تولید و بکارگیری مناسب اطلاعات مکانی در طبقه‌بندی تصاویر ابرطیفی پیشنهاد شده است که به طور کلی در سه دسته زیر خلاصه می‌شوند:

- در دسته اول، ویژگی‌های مکانی قبل از پروسه طبقه‌بندی در مرحله‌ای مجزا تولید شده و سپس در کنار اطلاعات طیفی قرار می‌گیرد. بردارهای طیفی- مکانی حاصل شده در نهایت وارد طبقه‌بندی‌کننده می‌شوند. روش‌هایی نظیر ماتریس هم‌رخداد، بانک فیلتر گابور، الگوی دودویی محلی، پروفیل‌های مورفولوژی از جمله مهم‌ترین این روش‌ها هستند [۱].

- در دسته دوم، از ویژگی‌های مکانی در فاز پس-پردازش و به منظور نرم‌سازی نقشه‌های طبقه‌بندی‌شده استفاده می‌شود. روش میدان‌های تصادفی مارکوف از جمله روش‌های شاخص این دسته است که بهبودهای گوناگونی نیز بر روی آن انجام شده است. همچنین، در سال‌های اخیر از انواع فیلترهای حافظ لبه در فاز پس‌پردازش به منظور افزایش دقت طبقه‌بندی شده استفاده شده است [۲].

- در دسته سوم، ویژگی‌های مکانی در طی مرحله طبقه‌بندی به طور توأمان تولید می‌شوند که شبکه‌های عصبی عمیق و مدل‌های تنک مشترک<sup>۱</sup> از جمله روش‌های این دسته هستند [۳].

این روزها از شبکه‌های عصبی عمیق به دلیل توانایی استخراج ویژگی‌های سطح بالا که مطابق سیستم بینایی انسان است، در حوزه‌های مختلف شناسایی الگو و بینایی ماشین استفاده می‌شود. به طور اخص در پردازش تصاویر ابرطیفی از این شبکه‌ها در مباحث طبقه‌بندی، شناسایی عوارض، تولید نمونه‌های آموزشی مجازی، استخراج ویژگی و ... استفاده شده است.

در سالیان اخیر سه نوع کلی از شبکه‌های عصبی عمیق برای آنالیز تصاویر ابرطیفی توسعه داده شده است. مدل‌های اتوانکدر برای اولین بار توسط چن و همکاران (۲۰۱۴) در طبقه‌بندی تصاویر ابرطیفی استفاده شدند که در این روش از ترکیب چند اتوکدر<sup>۲</sup> (SAE) برای استخراج ویژگی‌های عمیق استفاده شد [۴]. شبکه‌های باور عمیق<sup>۳</sup> (DBN) توسط چن و همکاران (۲۰۱۵) برای طبقه‌بندی تصاویر ابرطیفی استفاده شد که در آن از یک لایه ماشین بولتزمان محدود شده<sup>۴</sup> (RBM) استفاده شده است [۵]. به عنوان اولین تلاش در طبقه‌بندی تصاویر ابرطیفی به کمک شبکه‌های عصبی پیچشی<sup>۵</sup> (CNN)، وی هو و همکاران (۲۰۱۵) از یک شبکه CNN برای طبقه‌بندی تصاویر ابرطیفی استفاده کردند که در معماری شبکه مورد استفاده آنها از یک لایه کانولوشن، یک لایه حداکثر جمع (MaxPooling) و دو لایه با اتصال کامل استفاده شده است که لایه اتصال نهایی با استفاده از تابع بیشینه هموار (Softmax) میزان تعلق پیکسل موردنظر را به

<sup>۱</sup> Joint sparse representation

<sup>۲</sup> Stacked Autoencoder

<sup>۳</sup> Deep believe network

<sup>۴</sup> Restricted Boltzmann machine

<sup>۵</sup> Convolutional neural network

سلسله مراتبی<sup>۵</sup> را دارند [۱۱]. در این راستا، شو و همکاران (۲۰۱۸) روش شبکه نواحی تصادفی<sup>۶</sup> (*RPNet*) را برای طبقه‌بندی تصاویر ابرطیفی پیشنهاد داده‌اند [۱۲]. در این شبکه با الهام از *PCANet* که مبتنی بر تبدیل مؤلفه اصلی است، ویژگی‌های مکانی عمیق با استفاده از نواحی تصادفی انتخاب شده از تصویر و تبدیل مؤلفه اصلی استخراج می‌شود. در سال گذشته نیز دو تحقیق ارائه شد که در ساختار خود از *RPNet* استفاده می‌کنند. سان و همکاران (۲۰۱۹) در مقاله خود از یک ساختار دو شاخه بر مبنای روش *RPNet* و تکنیک نمایش ماتریس کواریانس محلی برای طبقه‌بندی تصاویر ابرطیفی استفاده کردند [۱۳]. همچنین اصغری و مختارزاده (۲۰۱۹) در مقاله خود از ادغام ویژگی عمیق سلسله مراتبی گابور مستخرج شده از شبکه *RPNet* با ویژگی‌های گابور و ویژگی‌های اصلی *RPNet* برای طبقه‌بندی تصاویر ابرطیفی استفاده کرده‌اند [۱۴]. از آنجایی که روش *RPNet* به صورت نظارت‌نشده ویژگی‌های عمیق را استخراج می‌کند، ضعف مدل‌های کلاسیک عمیق در خصوص زمان‌بر بودن پردازش و نیاز به تعداد زیاد نمونه آموزشی را ندارد. مدل *RPNet* علیرغم عملکرد نسبتاً مطلوب دارای برخی نقاط ضعف است که در ادامه به آن اشاره خواهیم کرد:

۱- از آنجا که در مدل *RPNet* ویژگی‌های عمیق به صورت نظارت‌نشده استخراج می‌شوند، ویژگی‌های عمیق استخراج شده الزاماً در راستای تفکیک‌پذیری بهتر کلاس‌های زمینی موجود در تصویر نیستند (قید بیشینه شدن تفکیک‌پذیری میان کلاس‌ها در نظر گرفته نمی‌شود). به عبارت بهتر دانش کاربر از صحنه تصویر برداری (داده آموزشی) در این مدل هیچ جایگاهی ندارد و ویژگی‌ها بصورت کاملاً غیرنظارت‌شده استخراج می‌شوند که

کلاس‌های مختلف مشخص می‌کند [۶]. نتایج نهایی نشان از برتری شبکه *CNN* مورد استفاده نسبت به طبقه‌بندی‌کننده ماشین بردار پشتیبان<sup>۱</sup> (*SVM*) با استفاده از کرنل تابع پایه شعاعی دارد. اخیراً هم روشی توسط ژائو و همکاران (۲۰۱۹) ارائه شده است که در آن اطلاعات استخراج شده از چندین لایه کانولوشن با هم ادغام شده و به منظور طبقه‌بندی تصاویر ابرطیفی استفاده می‌شود [۷]. هر چند در مدل شبکه *CNN* زمانی که کرنل‌ها به صورت دوبعدی یا سه‌بعدی در نظر گرفته شوند ذاتاً استخراج ویژگی مکانی نیز در دل شبکه صورت می‌گیرد ولی در مدل‌های ارائه شده در سال‌های اخیر به طور مجزا هم در فاز پس‌پردازش و هم در فاز پیش‌پردازش از اطلاعات مکانی استفاده شده است. به عنوان نمونه در شبکه عمیق با فیلتر گابور<sup>۲</sup> (*GFDN*) از ویژگی‌های گابور تولید شده از سه مؤلفه اول *PCA* در کنار ویژگی‌های طیفی به عنوان ورودی شبکه عمیق اتوانکدر تنک<sup>۳</sup> استفاده می‌شود [۸]. ژاو و همکاران (۲۰۱۹) نیز در تحقیقی از ادغام ویژگی‌های بافتی ماتریس هم‌رخداد و ویژگی‌های عمیق به منظور طبقه‌بندی تصاویر ابرطیفی استفاده کردند [۹]. همچنین در تحقیق کالو و همکاران (۲۰۱۸) از مقیدسازی مکانی بر مبنای میدان تصادفی مارکوف در ترکیب با شبکه‌های *CNN* (*CNN-MRF*) به منظور طبقه‌بندی تصاویر ابرطیفی استفاده شده است [۱۰].

در کنار این روش‌های کلاسیک یادگیری عمیق، در سال‌های اخیر شبکه‌هایی نیز مانند شبکه تبدیل مؤلفه اصلی (*PCANet*) معرفی شده‌اند که در آن‌ها از تبدیل آنالیز مؤلفه اصلی<sup>۴</sup> (*PCA*) به منظور یادگیری کرنل‌های کانولوشنی استفاده می‌شود. به عنوان یک مزیت مهم، این شبکه‌ها توانایی استخراج ویژگی عمیق

<sup>۱</sup> Support vector machines

<sup>۲</sup> Gabor filtering and deep network

<sup>۳</sup> Sparse Autoencoder

<sup>۴</sup> Principal components analysis

<sup>۵</sup> Hierarchical deep features

<sup>۶</sup> Random patches network

## ۲-۱- آنالیز تفکیک پذیری خطی (LDA)

از نظر مفهومی LDA در پی یافتن یک ماتریس انتقال خطی است که داده را به فضایی با ابعاد کمتر منتقل کند که در آن، مقدار نسبت واریانس بین کلاسی به واریانس درون کلاسی بیشینه شود. داده‌ای با  $N$  نمونه آموزشی را در فضای  $d$  بعدی (تعداد باندها) نظر بگیرید  $(\{x_i\}_{i=1}^N \text{ in } \mathbb{R}^d)$ . تعداد نمونه‌های آموزشی در کلاس  $i$  ام را با  $n_i$  و تعداد کلاس‌ها را با  $n_c$  نمایش می‌دهیم. ماتریس‌های پراکندگی درون کلاسی  $(S_w)$  و بین کلاسی  $(S_b)$  به صورت رابطه (۱) و رابطه (۲) تعریف می‌شوند [۱۶]:

$$S_b = \sum_{i=1}^{n_c} n_i (m_i - m)(m_i - m)^T \quad \text{رابطه (۱)}$$

$$S_w = \sum_{i=1}^{n_c} \left( \sum_{j=1}^{n_i} (x_{ji} - m_i)(x_{ji} - m_i)^T \right) \quad \text{رابطه (۲)}$$

که در روابط (۱) و (۲) فوق  $m_i$  میانگین کلاس  $i$  ام،  $m$  مانگین کل نمونه‌های آموزشی و  $x_{ji}$  نمونه آموزشی  $j$  ام در کلاس  $i$  ام و  $T$  ترانپوز ماتریس است. ماتریس انتقال تبدیل LDA،  $(W)$ ، به صورت رابطه (۳) به دست می‌آید [۱۶]:

$$W = \arg \max_w ((W^T S_b W) / (W^T S_w W)) \quad \text{رابطه (۳)}$$

در نهایت ماتریس انتقال بهینه در فضای کاهش بعد یافته  $m$  بعدی از بردارهای ویژه  $S_w^{-1} S_b$  متناظر با  $m$  مقدار ویژه بیشینه به دست می‌آید. داده منتقل شده از رابطه (۴) به دست می‌آید:

$$y_i = W^T x_i \quad \text{رابطه (۴)}$$

که در رابطه (۴)،  $W_{d \times m}$  بیانگر ماتریس انتقال به فضای  $m$  ( $m \leq d$ ) است. از آنجایی در تصاویر ابرطیفی نسبت تعداد نمونه‌های آموزشی به ابعاد داده کوچک است و این موضوع احتمال بروز تکینگی<sup>۳</sup> در ماتریس‌های کوواریانس را افزایش می‌دهد، در تئوری

الزاماً مناسب برای طبقه‌بندی تصویر نیستند [۱۵].  
۲- این روش منجر به تولید تعداد زیادی از ویژگی‌های نهایی می‌شود که علاوه بر صرف زمان زیاد به منظور تولید آنها، باعث ایجاد محدودیت‌های اجرایی در بهره‌برداری از آنها، بویژه در شرایطی که داده‌های آموزشی کافی در اختیار نباشد، می‌گردد. نقدهای فوق این ایده را به ذهن می‌رساند که روش‌های نظارت‌شده‌ی استخراج ویژگی می‌توانند باعث بهبود عملکرد مدل  $RPNet$  به منظور طبقه‌بندی تصاویر ابرطیفی شوند. به طور خلاصه نوآوری‌های این تحقیق که در راستای حل نقاط ضعف مدل کلاسیک  $RPNet$  است، به شرح زیر است:

- استفاده از روش نظارت‌شده آنالیز تفکیک پذیری خطی<sup>۱</sup> ( $LDA$ ) به جای تبدیل مؤلفه اصلی در ساختار مدل  $RPNet$  به منظور تولید ویژگی‌های عمیق سلسله مراتبی با توان تفکیک‌پذیری بالا.

- تولید فضای طیفی-مکانی سلسله مراتبی عمیق نظارت‌شده با ابعاد کمتر نسبت به مدل کلاسیک  $RPNet$  که باعث افزایش کارایی روش پیشنهادی می‌شود.

ساختار تحقیق به این صورت است که در قسمت دوم پس از مرور مفهوم آنالیز تفکیک‌پذیری خطی، روش پیشنهادی معرفی می‌شود. در قسمت سوم، دو تصویر ابرطیفی مورد استفاده معرفی خواهند شد. در فصل چهارم نتایج پیاده‌سازی‌ها ارائه و آنالیز خواهد شد. در قسمت آخر نیز نتیجه‌گیری و جمع‌بندی نهایی صورت می‌گیرد.

## ۲- روش تحقیق

در این قسمت در ابتدا مروری بر روی مفهوم آنالیز تفکیک‌پذیری خطی انجام می‌شود و سپس ساختار و نحوه عملکرد شبکه  $RPNet$  مبتنی بر آنالیز تفکیک‌پذیری خطی<sup>۲</sup> ( $LDA-RPNET$ ) معرفی می‌شود.

<sup>۱</sup> Linear discriminant analysis<sup>۲</sup> Linear discriminant analysis random patches

network

<sup>۳</sup> Singularity

عمیق، ویژگی‌های عمیق به صورت نظارت‌نشده در هر لایه از شبکه با استفاده از نواحی تصادفی استخراج شده از خود تصویر و اعمال تبدیل  $PCA$  بر روی آن‌ها به دست می‌آیند [۱۲]. شکل (۱) نمای کلی از مدل  $RPNet$  با دو لایه عمیق را نمایش می‌دهد.

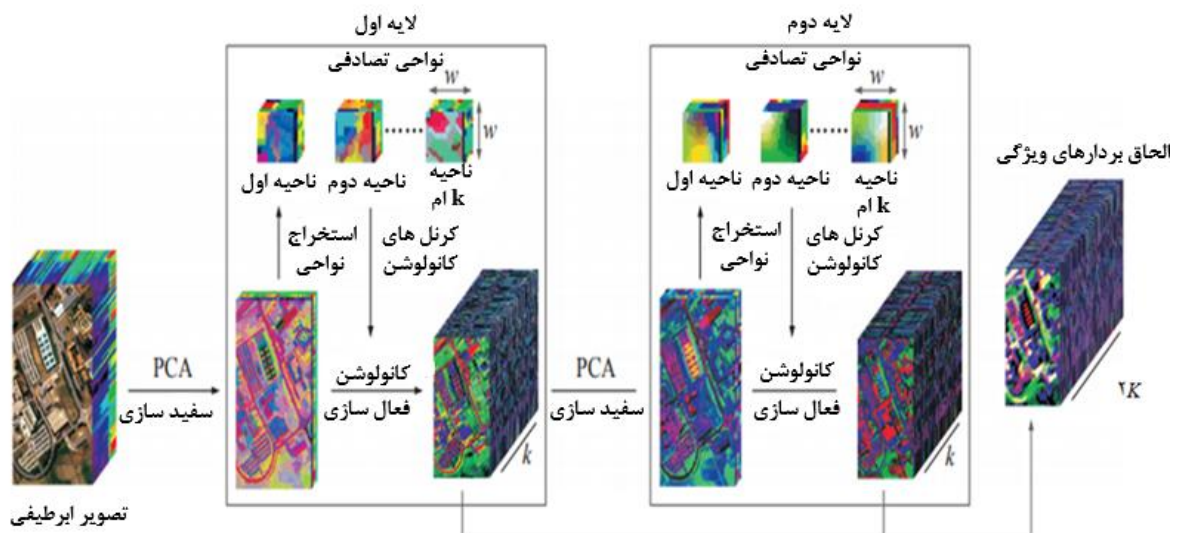
می‌توان از تکنیک مقیدسازی به صورت رابطه (۵) استفاده کرد [۱۷]:

$$S_w = S_w + \lambda I, \lambda \in [0, \infty) \quad (۵)$$

که در رابطه (۵)،  $\lambda$  پارامتر مقیدساز و  $I$  ماتریس یکه است.

## ۲-۲- LDA-RPNET

در مدل  $RPNet$  بر خلاف بسیاری دیگر از مدل‌های



شکل ۱: نمای کلی مدل شبکه نواحی تصادفی  $RPNet$  [۱۲]

با مقدار پله  $1^3$  برای کل تصویر اعمال می‌شود و در لبه از تکنیک گسترش آینه‌وار تصویر استفاده می‌شود. به عنوان تابع فعال‌ساز نیز از تابع واحد خطی اصلاح شده<sup>۴</sup> استفاده می‌شود. مجدداً تبدیل  $PCA$  بر روی ویژگی‌های تولید شده از از مرحله‌ی قبل اعمال می‌شود و در لایه دوم نیز همین پروسه ادامه پیدا می‌کند. همان‌طور که گفته شد از آنجایی که هدف طبقه‌بندی، تفکیک‌پذیری بین کلاس‌های زمینی است و اساساً شبکه  $RPNet$  ویژگی‌های عمیق را به صورت نظارت

به طور خلاصه در  $RPNet$  پس از فاز اولیه کاهش بعد به وسیله تبدیل  $PCA$ ، در لایه اول نواحی به صورت تصادفی از هر باند کاهش بعد یافته استخراج می‌شوند و عملگر کانولوشن بر روی تصویر به کمک آن‌ها انجام می‌شود که رابطه (۶) بیانگر آن است [۱۲]:

$$I_i = \sum_{j=1}^p X_{whitened}^j * P_i^j, i = 1, \dots, k \quad (۶)$$

که در رابطه (۶) \* عملگر کانولوشن دو بعدی،  $k$  تعداد نقشه‌های ویژگی<sup>۱</sup>،  $X_{whitened}^j$  باند  $i$  ام تصویر سفیدسازی شده<sup>۲</sup> و  $P_i^j$  بعد  $z$  ام کرنل تصادفی  $i$  ام است. کانولوشن

<sup>۳</sup> Stride

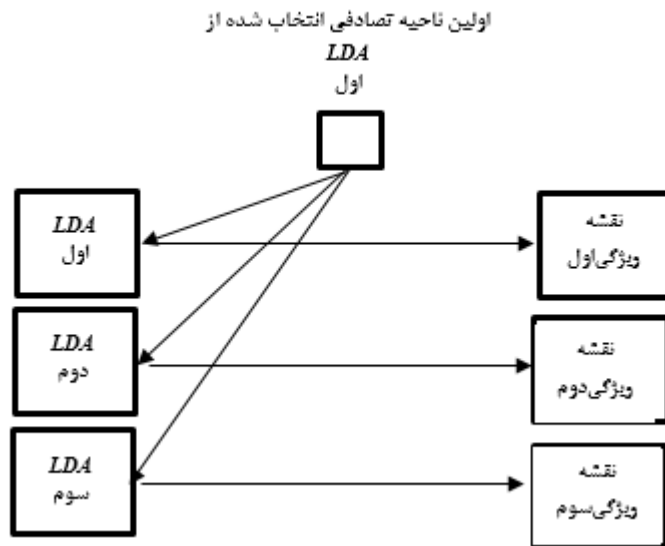
<sup>۴</sup> Rectified linear unit

<sup>۱</sup> Feature maps

<sup>۲</sup> whitened

هایی با ابعاد زیاد با صرف زمان محاسباتی بالا بود. برای رفع این مشکل در روش پیشنهادی، به شرح زیر عمل شده است. در هر لایه از شبکه، نواحی تصادفی سه بعدی، با نواحی تصادفی دو بعدی مستخرج از باندهای مختلف تبدیل *LDA* جایگزین شده‌اند. در این روش، عملیات کانولوشن بین هر کرنل تصادفی سه بعدی و تمامی مولفه‌های *LDA* تصویر ورودی صورت می‌گیرد. شکل (۲) نمای کلی این روش را نشان می‌دهد.

نشده استخراج می‌کند، به نظر می‌رسد که عملکرد آن را بتوان با تبدیل *LDA* که هدف اصلی آن افزایش تفکیک پذیری کلاس‌ها است، بهبود داد. در این راستا در شبکه *LDA-RPNET* پیشنهادی، در ابتدا تصویر ابرطیفی به کمک تبدیل *LDA* مقید شده (با پارامتر  $\lambda=1$ ) به فضای جدید (با ابعاد یکی کمتر از تعداد کلاس‌ها) منتقل می‌شود. این اقدام دانش موجود از وضعیت کلاس‌ها را در روش پیشنهادی وارد می‌سازد. از طرف دیگر نقد دوم به روش *RPNet* تولید ویژگی-



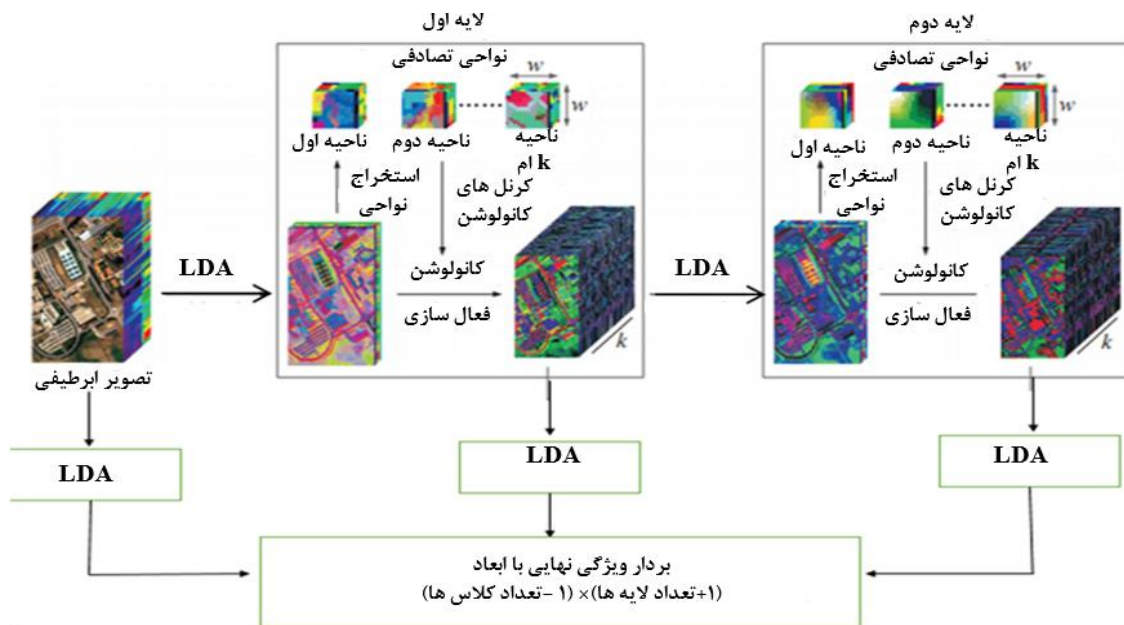
شکل ۲: کانولوشن در هر لایه از شبکه *LDA-RPNet*

برای لایه دوم استفاده می‌شود. با تکرار این روند برای چندین لایه، ویژگی‌های عمیق سلسله مراتبی از لایه-های مختلف تولید شده و از زیر هم قرار دادن<sup>۲</sup> بردارهای ویژگی به دست آمده، ویژگی‌های مطلوب برای طبقه‌بندی *SVM* حاصل می‌شود. نمای کلی شبکه *LDA-RPNet* در شکل (۳) نمایش داده شده است. از جمله خصوصیات شبکه *LDA-RPNet* استخراج ویژگی‌های عمیق نظارت‌شده در سطوح مختلف است که نسبت به روش *RPNet* دارای ابعاد به مراتب کمتر و قدرت تفکیک پذیری بالاتری است.

باید توجه داشت که در مقاله حاضر تنها سه مؤلفه اول تبدیل *LDA* که دارای بیشترین میزان تفکیک‌پذیری هستند وارد هر لایه از شبکه *LDA-RPNet* می‌شوند. همچنین برای هر مولفه *LDA* نیز تنها سه ناحیه تصادفی سه بعدی استخراج و مورد استفاده قرار گرفته است. با در نظر داشتن آنکه ۱- هر ناحیه سه ویژگی تولید می‌کند، ۲- برای هر مولفه *LDA* سه ناحیه در نظر گرفته شده است و ۳- از سه مولفه اول *LDA* استفاده شده است، در مجموع ۲۷ نقشه ویژگی<sup>۱</sup> در هر لایه تولید می‌شود که از آن‌ها مجدداً به عنوان ورودی

<sup>۲</sup> Stacking

<sup>۱</sup> Feature map



شکل ۳: نمای کلی شبکه LDA-RPNet

### ۳- داده‌های مورد استفاده

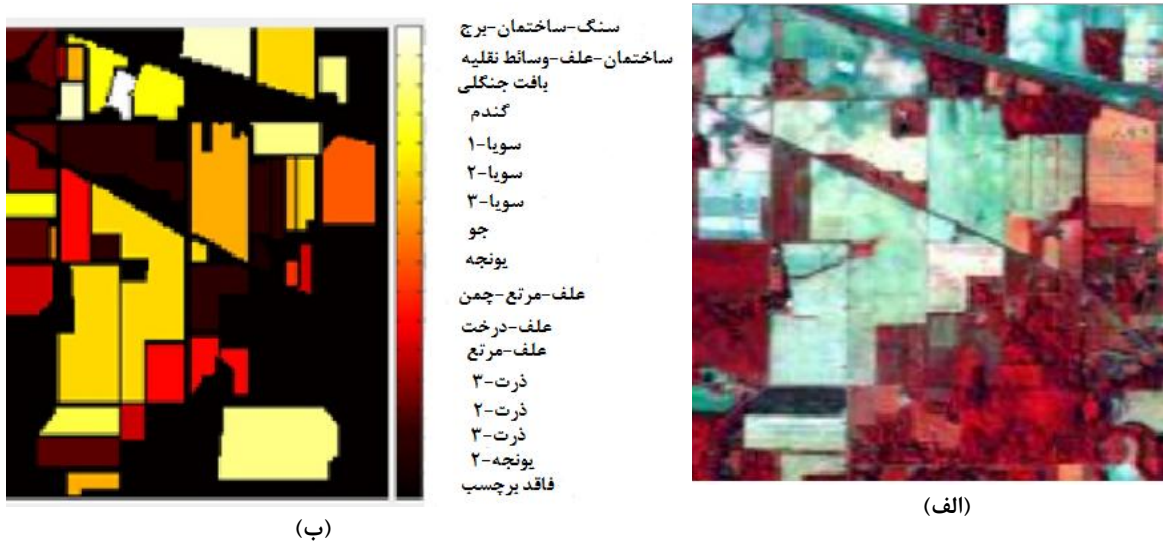
این‌دین پابن: اولین داده مورد استفاده در این پژوهش تصویر اخذ شده توسط سنجنده ابرطیفی هواپرد اویریس<sup>۱</sup> از منطقه این‌دین پابن در شمال غربی منطقه ایندیانا در ایالات متحده آمریکا در تاریخ ۱۲ ژوئن ۱۹۹۲ است. این تصویر با قدرت تفکیک مکانی ۲۰ متر دارای ابعاد ۱۴۵ × ۱۴۵ پیکسل و ۲۲۴ باند طیفی در محدوده ۰/۴ تا ۲/۵ میکرومتر با پهنای باند ۱۰ نانومتر است. به طور کلی ناحیه غالب در این تصویر ناحیه کشاورزی است. با حذف ۲۴ باند در محدوده‌های جذبی بخار آب از بقیه ۲۰۰ باند باقی‌مانده در پردازش‌های این پژوهش در ادامه استفاده شده است. این منطقه شامل شانزده کلاس از گیاهانی نظیر ذرت، سویا، علف، گندم و غیره است. به طور کلی طبقه‌بندی این داده به علت وجود کلاس‌هایی با رفتار طیفی مشابه همواره چالش برانگیز بوده است. یک ترکیب رنگی کاذب و

نقشه واقعیت زمینی این داده که توسط آزمایشگاه سنجش از دور دانشگاه پردو تهیه شده است در شکل (۴) نشان داده شده است.

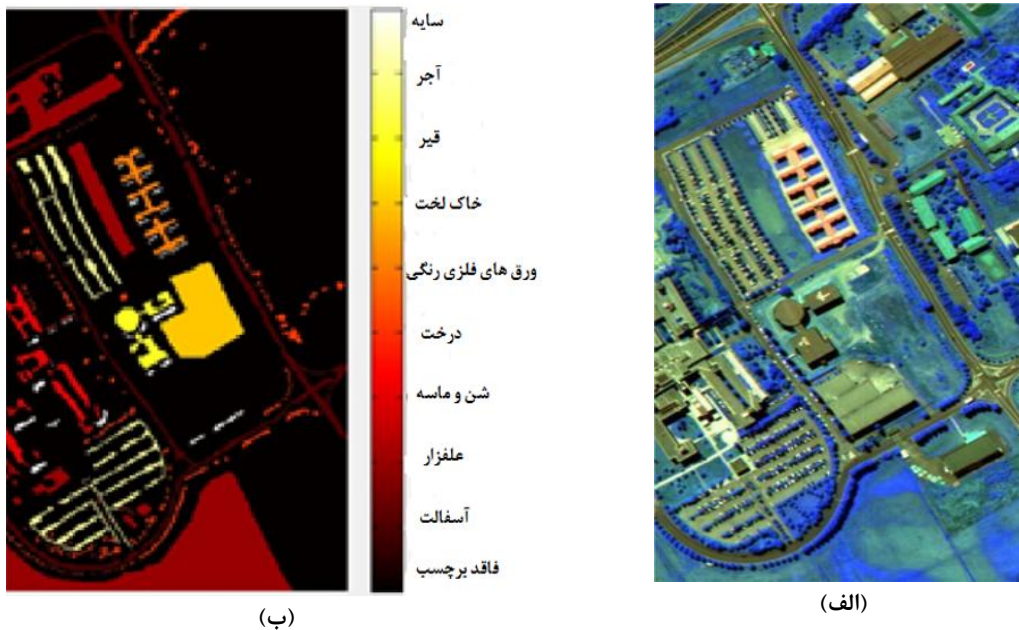
دانشگاه پابن: تصویر دوم توسط سنجنده ابرطیفی روسیس-۲۳ از دانشگاه پابن در شمال ایتالیا در ابعاد ۳۴۰ × ۶۱۰ پیکسل اخذ شده است. سنجنده مذکور دارای ۱۱۵ باند طیفی در محدوده ۴۳۰ تا ۸۶۰ نانومتر است. پس از حذف ۱۲ باند نویزی، از ۱۰۳ باند باقی‌مانده در این تحقیق استفاده شده است. قدرت تفکیک مکانی این تصویر ۱/۳ متر و دارای ۹ کلاس اطلاعاتی شهری مانند آسفالت، سایه، خاک لخت و غیره می‌باشد. طبقه‌بندی این تصویر به علت وجود کلاس‌های پیچیده شهری با امضاهای طیفی نزدیک به هم چالش برانگیز است. در شکل (۵)، تصویر با ترکیب رنگی کاذب و نقشه واقعیت زمینی این داده که نشان‌دهنده پراکندگی کلاس‌ها می‌باشد، نشان داده شده است.

<sup>۲</sup> ROSIS-3

<sup>۱</sup> AVIRIS



شکل ۴: داده ایندین پایین الف - تصویر رنگی کاذب ب - نقشه واقعیت زمینی



شکل ۵: داده دانشگاه پویا الف - تصویر رنگی کاذب ب - نقشه واقعیت زمینی

#### ۴- نتایج پیاده‌سازی و آنالیز آن

در این قسمت پس از بررسی تاثیر تنظیم پارامترهای شبکه *LDA-RPNet*، آنالیزهایی بر روی دقت طبقه‌بندی و مقایسه نتایج با چند تحقیق دیگر انجام شده

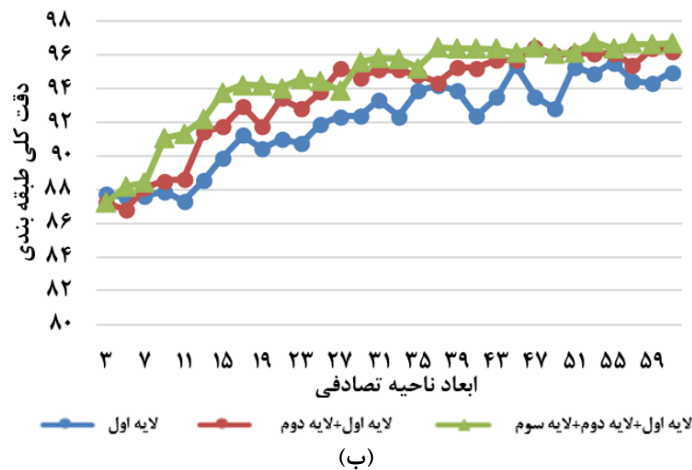
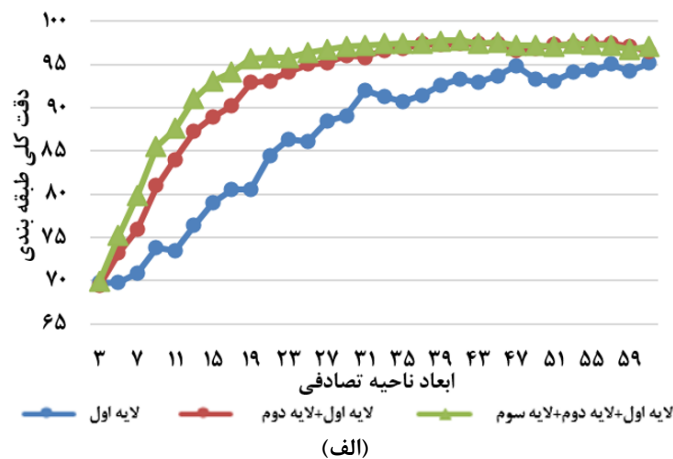
است.

#### ۴-۱- آنالیز پارامترها

به طور کلی شبکه *LDA-RPNet* دارای سه پارامتر کلیدی ابعاد ناحیه تصادفی مربعی ( $w$ )، تعداد ناحیه

( $w$ ) برای هر دو داده بررسی می‌شود. ویژگی‌های استخراج شده در هر حالت با استفاده از طبقه‌بندی-کننده  $SVM$  با فرض تعداد داده‌های آموزشی ۵٪ حقیقت زمینی در هر کلاس، طبقه‌بندی می‌شود. نتایج دقت کلی طبقه‌بندی به دست آمده برای دو مجموعه داده در شکل (۶) نمایش داده شده است.

تصادفی ( $k$ ) و تعداد لایه‌های شبکه است که تنظیم درست آن‌ها بر روی کیفیت ویژگی‌های عمیق استخراج شده تأثیرگذار است. به منظور ساده‌سازی مطالعه تأثیر این پارامترها، تعداد نواحی تصادفی ( $k$ ) در این تحقیق برابر سه در نظر گرفته شده است و میزان دقت طبقه‌بندی در مقادیر مختلف تعداد لایه‌ها و ابعاد ناحیه



شکل ۶: بررسی تأثیر اندازه پنجره‌ها و تعداد لایه‌ها در شبکه  $LDA-RPNet$  (الف) تصویر ایندین پاین، (ب) تصویر دانشگاه پابوا

پس تعداد لایه‌های شبکه برای هر دو داده در این تحقیق برابر با سه در نظر گرفته شده است. همچنین گفتنی است که شبکه  $LDA-RPNet$  نسبت به شبکه  $RPNet$  که در مقاله مرجع آن نیاز به ۵ لایه عمیق

همان طور که از شکل (۶) دریافت می‌شود، به طور کلی با افزایش تعداد لایه‌های شبکه و به تبع آن افزایش تعداد ویژگی‌های عمیق، دقت طبقه‌بندی بالا می‌رود ولی پس از لایه سوم این افزایش دقت محسوس نیست

پارامترهای آن از روش ارائه شده در میرزاپور و قاسمیان (۲۰۱۶) استفاده می‌شود [۱۸]. به منظور بررسی حساسیت نسبت به تعداد داده‌های آموزشی از دو سایز داده آموزشی (۵٪ و ۱۰٪ نقشه واقعیت زمینی هر کلاس برای ایندین پایین و ۱٪ و ۵٪ نقشه واقعیت زمینی هر کلاس برای دانشگاه پاویا) استفاده شده است و از الباقی نمونه‌های نقشه واقعیت زمینی برای ارزیابی نتایج استفاده شده است. به منظور ارزیابی نهایی نیز از چهار معیار دقت کلی (OA)، دقت متوسط (AA)، اعتبار متوسط (Average validity (AV)) و ضریب کاپا استفاده می‌شود [۱۹]. نتایج طبقه‌بندی برای دو داده در جداول (۱) و (۲) و تصاویر نقشه‌های طبقه‌بندی شده در شکل (۷) و (۸) نمایش داده شده است.

همان‌طور که در جداول (۱) و (۲) مشخص است، دقت طبقه‌بندی با ویژگی‌های استخراج شده از شبکه LDA-RPNet در سطوح بالاتری نسبت به طبقه‌بندی با ویژگی‌های مستخرج از RPNet قرار دارد. دلیل این برتری روش LDA-RPNet توجه به تفکیک‌پذیری کلاس‌ها است که امکان آن با تبدیل LDA فراهم شده است. همچنین گفتنی است که این افزایش دقت هنگامی که نمونه‌های آموزشی کوچک‌تر باشد محسوس‌تر نیز می‌باشد و به طور کلی در نواحی کشاورزی همانند داده ایندین پایین میزان برتری روش LDA-RPNet نسبت به RPNet بیشتر است.

دارد، نیاز به تعداد لایه‌های کمتری دارد. این مسئله خود باعث افزایش کارایی و کاهش تعداد ویژگی‌های عمیق استخراج شده نهایی به منظور طبقه‌بندی می‌شود. در خصوص مقدار بهینه ابعاد نواحی از آنجایی که در تصویر دانشگاه پاویا عوارض با ابعاد بزرگ‌تری وجود دارد منطقی است که ابعاد ناحیه بهینه ( $w=53$ ) نسبت به تصویر ایندین پایین ( $w=41$ ) بزرگتر باشد.

#### ۴-۲- آنالیز دقت طبقه‌بندی

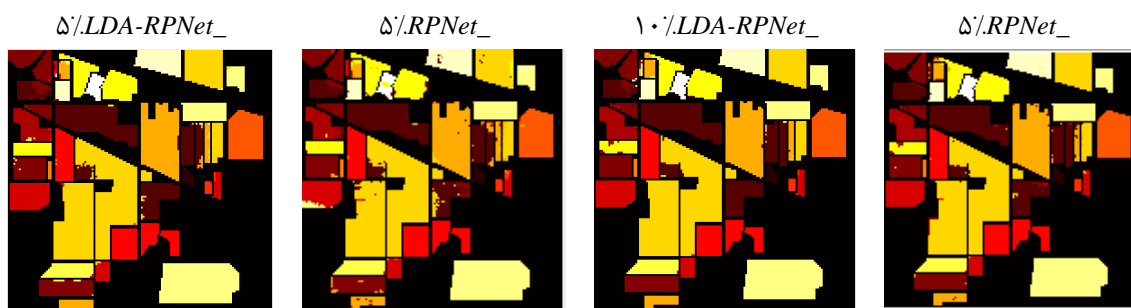
در این قسمت، دقت‌های طبقه‌بندی ویژگی‌های استخراج شده با LDA-RPNet با ویژگی‌های استخراج شده از RPNet مقایسه می‌شود. به منظور تولید ویژگی‌های LDA-RPNet از سه لایه عمیق با ابعاد کرنل  $53 \times 53$  برای دانشگاه پاویا و  $41 \times 41$  برای ایندین پایین با تعداد سه ناحیه تصادفی در هر لایه استفاده می‌شود. با توجه به اینکه تصویر ایندین پایین دارای ۱۶ کلاس می‌باشد تعداد ویژگی‌های نهایی با روش LDA-RPNet برابر با ۶۰ ویژگی می‌باشد. این در حالی است که در تصویر دانشگاه پاویا ۹ کلاس وجود دارد و تعداد ویژگی‌های استخراج شده در روش LDA-RPNet برابر با ۳۲ ویژگی است. در روش RPNet پارامترهای روش با توجه به مقاله اصلی تنظیم شده‌اند و تعداد ویژگی‌های نهایی در تصویر ایندین پایین برابر با ۳۰۰ ویژگی و در تصویر دانشگاه پاویا برابر با ۲۰۳ ویژگی است. ویژگی‌های استخراج شده از هر دو روش وارد طبقه‌بندی کننده SVM می‌شود که برای تنظیم

جدول ۱: نتایج دقت طبقه برای داده ایندین پایین

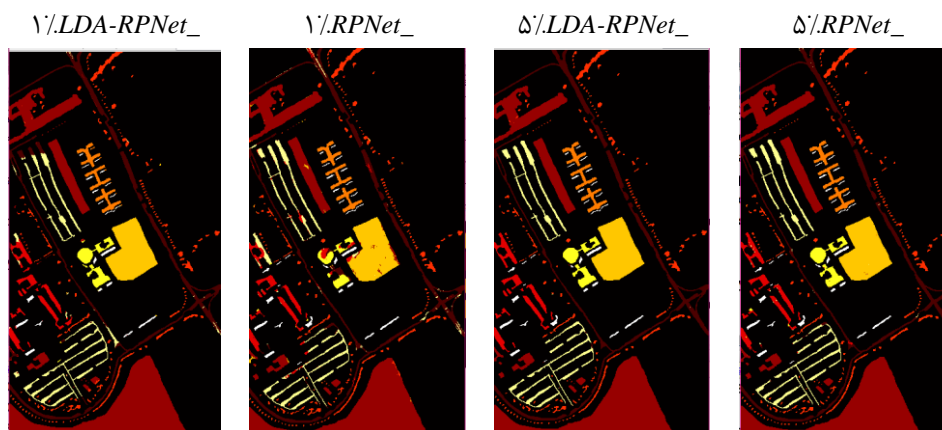
		داده ایندین پایین			
		۵٪		۱۰٪	
درصد نمونه آموزشی	روش طبقه‌بندی	RPNet	LDA-RPNet	RPNet	LDA-RPNet
	معیار ارزیابی	دقت کلی	۹۴٫۹۱	۹۷٫۸۶	۹۷٫۸
دقت متوسط		۹۴٫۷۴	۹۷٫۸۵	۹۸٫۱۱	۹۸٫۵۸
اعتبار متوسط		۹۱٫۷۵	۹۶٫۲۵	۹۷٫۴۸	۹۶٫۸
ضریب کاپا		۰٫۹۴	۰٫۹۷۵	۰٫۹۷	۰٫۹۸

جدول ۲: نتایج دقت طبقه برای داده دانشگاه پاویا

		داده دانشگاه پاویا			
		۱٪		۵٪	
درصد نمونه آموزشی					
روش طبقه‌بندی		<i>RPNet</i>	<i>LDA-RPNet</i>	<i>RPNet</i>	<i>LDA-RPNet</i>
معیار ارزیابی	دقت کلی	۹۴٫۵۹	۹۶٫۷۵	۹۹٫۲۱	۹۹٫۷۴
	دقت متوسط	۹۰٫۵۶	۹۴٫۱۸	۹۸٫۶۸	۹۹٫۵۶
	اعتبار متوسط	۹۳٫۱۵	۹۶٫۲۷	۹۹	۹۹٫۷۸
	ضریب کاپا	۰٫۹۳	۰٫۹۷	۰٫۹۹	۰٫۹۹۶



شکل ۷: تصاویر نقشه‌های طبقه‌بندی برای داده ایندین پایین



شکل ۸: تصاویر نقشه‌های طبقه‌بندی برای داده دانشگاه پاویا

$$Z_{ij} = (n_{ij} - n_{ij}) / (n_{ij} + n_{ij})^{1/2} \quad \text{رابطه (۷)}$$

در رابطه (۷)،  $n_{ij}$  تعداد نمونه‌های تستی می‌باشد که در روش  $i$  درست طبقه‌بندی شده‌اند ولی در روش  $j$  اشتباه طبقه‌بندی شده‌اند و بالعکس. در آماره "ز" اگر  $|Z_{i,j}| > 1.96$  باشد اختلاف بین دو روش از نظر آماری

در ادامه به منظور بررسی دقیق‌تر برتری از نگاه آماری، از آماره زد<sup>۱</sup> استفاده شده است. این آماره به صورت رابطه (۷) تعریف می‌شود:

<sup>۱</sup> Z-statistics

قابل توجه می‌باشد [۱۸]. مقادیر محاسبه شده برای آماره "زد" بین دو روش *LDA-RPNet* و *RPNet* در جدول (۳)

جدول ۳: نتایج تست آماری برای دو مجموعه داده

نام داده	ایندین پایین		دانشگاه پابویا	
	۵٪	۱۰٪	۱٪	۵٪
درصد نمونه آموزشی				
آماره "زد"	۴/۹۱	۰/۰۶	۰/۷۸۲	۷/۵۱

ابتدا تصویر ابرطیفی به کمک تبدیل *PCA* کاهش بعد داده می‌شود. سپس چندین ویژگی مکانی نظیر فیلتر گابور، پروفیل‌های مورفولوژی، ماتریس هم-رخداد از مؤلفه اول *PCA* تولید شده و در ترکیب‌های مختلفی در کنار ویژگی‌های طیفی قرار می‌گیرند [۱].

(۲) روش نمایش مشارکتی مکان-آگاه<sup>۲</sup> (*JSaCR*): در این روش که با نام نمایش مشارکتی مکان-آگاه شناخته می‌شود برخلاف روش‌های مرسوم، از اطلاعات مکانی به کمک یک ترم مقیدساز مکانی در تابع هدف مدل استفاده می‌شود [۲۰].

(۳) *GFDN*: در روش *GFDN* ابتدا ویژگی‌های گابور برای سه مؤلفه اول *PCA* استخراج شده سپس این ویژگی‌ها در کنار ویژگی‌های طیفی قرار گرفته و بردار طیفی-مکانی حاصل وارد شبکه عمیق اتوانکدر تنک می‌شود [۸].

(۴) *CNN-MRF*: روش *CNN-MRF* از ترکیب طبقه‌بندی‌کننده شبکه عصبی *CNN* و مقیدسازی مکانی با میدان تصادفی مارکوف تشکیل شده است [۱۰].

نتایج دقت کلی طبقه‌بندی برای این تحقیقات و روش پیشنهادی در جدول (۴) نمایش داده شده است.

با توجه به جدول (۳) می‌توان گفت که در دو حالت روش *LDA-RPNet* از نظر آماری نیز نسبت به *RPNet* برتری دارد. اگر چه در دو حالت دیگر نتایج دقت طبقه‌بندی *LDA-RPNet* بهتر از *RPNet* است اما این بهتر بودن از نظر آماری محسوس نیست. از آنجایی که از سویی ابعاد ویژگی‌های تولید شده توسط شبکه *LDA-RPNet* بسیار کمتر از ابعاد ویژگی‌های تولید شده در روش *RPNet* است و از سوی دیگر از نقطه نظر زمان پردازش *LDA-RPNet* (۴ ثانیه در تصویر ایندین پایین) حداقل ۲۰٪ سریع‌تر از *RPNet* (۵/۵ ثانیه در تصویر ایندین پایین) است از این رو به طور کلی روش *LDA-RPNet* روشی بهینه‌تر نسبت به روش *RPNet* است.

#### ۳-۴- مقایسه با سایر روش‌ها

هدف از این قسمت مشخص شدن جایگاه روش پیشنهادی نسبت به دیگر روش‌های طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی است. از این رو روش پیشنهادی با دو روش طبقه‌بندی طیفی شامل طبقه‌بندی با باندهای اصلی تصویر ابرطیفی و طبقه‌بندی طیفی با مؤلفه‌های *LDA* و چهار روش طیفی-مکانی که دو روش آن‌ها جز روش‌های عمیق و دو روش دیگر جز روش‌های غیر عمیق است مقایسه شده است. این روش‌ها به شرح زیر هستند:

(۱) روش طبقه‌بندی تصاویر ابرطیفی با چندین ویژگی طیفی-مکانی-ساختاری<sup>۱</sup> (*MSSSF*): در این روش

<sup>۱</sup> *Hyperspectral classification with multiple spatial-spectral-structural features*

<sup>۲</sup> *Joint spatial-aware collaborative classification*

جدول ۴: مقایسه با روش‌های رقیب

داده ابر طیفی	درصد داده آموزشی	نتایج دقت کلی طبقه‌بندی						
		باند‌های اصلی طیفی	LDA	MSSSF (2015)	JSaCR (2017)	GFDN (2017)	CNN-MRF (2018)	LDA-RPNet
آیندین	۵٪	۷۴,۵۴	۶۷,۱	۹۲,۷۸	۹۴,۰۷	---	---	۹۷,۸۶
پاین	۱۰٪	۷۸,۸۹	۷۱,۴۴	۹۶,۴۸	۹۷,۱۷	---	۹۶,۱۲	۹۸,۳۰
دانشگاه	۱٪	۸۴,۷۷	۸۴,۵۹	---	۹۳,۸۴	۳۲,۹۲	۷۸	۹۶,۷۵
پلویا	۵٪	۸۹,۶۶	۸۴,۸۷	۹۸,۹۵	۹۷,۳۳	۷۰,۹۴	۹۵	۹۹,۷۴

گفت که روش LDA-RPNet (با زمان حدود ۴ ثانیه) از نظر زمانی نیز یا بهینه‌تر از سایر روش‌ها است یا دست کم دارای نتایج قابل رقابت با آنها است.

#### ۵- نتیجه‌گیری و پیشنهادات

در این مقاله سعی شد که مدل RPNet به منظور استخراج ویژگی‌های سلسله مراتبی عمیق مکانی با استفاده از تبدیل آنالیز تفکیک‌پذیری خطی بهبود داده شود. مدل جدید عمیق پیشنهادی با نام LDA-RPNet بر مبنای انتخاب نواحی تصادفی از تصویر و تبدیل آنالیز تفکیک‌پذیری خطی می‌باشد و سعی در تولید ویژگی‌های سلسله مراتبی عمیق با تفکیک‌پذیری بالا دارد. ویژگی‌های مکانی عمیق استخراج شده در هر لایه در کنار یکدیگر قرار گرفته و به منظور طبقه‌بندی به طبقه‌بندی‌کننده SVM داده می‌شود. پیاده‌سازی‌ها بر روی دو داده حقیقی ابرطیفی یکی از ناحیه کشاورزی و دیگری از ناحیه شهری با در نظر گرفتن دو سائز نمونه آموزشی انجام شد. نتایج نهایی نشان از برتری روش پیشنهادی در مقایسه با روش RPNet و چهار روش دیگر طبقه‌بندی طیفی-مکانی از نقطه نظر دقت دارد. از آنجایی که استخراج ویژگی‌های عمیق سلسله مراتبی بحثی نسبتاً جدید در طبقه‌بندی تصاویر سنجش از دوری می‌باشد، می‌توان تحقیقات گسترده‌ای را به منظور استخراج عوارض مختلف با این ویژگی‌ها انجام داد.

باید توجه داشت که نتایج گزارش شده در جدول (۴) برای سه روش MSSSF، GFDN و CNN-MRF و مقالات مرجع استخراج شده‌اند و جاهای خالی به این علت می‌باشد که در در مقالات مربوطه در این تعداد نمونه آموزشی دقت طبقه‌بندی گزارش نشده است، اما روش JSaCR با توجه به مقاله مرجع و کدهای مربوطه پیاده‌سازی شده است. در مقاله حاضر به منظور پیاده‌سازی کلیه الگوریتم‌ها از نرم افزار متلب<sup>۱</sup> ۲۰۱۸ در سیستمی با پردازنده ۴ هسته‌ای Q6700<sup>۲</sup> و رم ۴ گیگ استفاده شده است.

جدول (۴) نشان می‌دهد که نتایج الگوریتم پیشنهادی دارای برتری نسبت به دیگر نتایج روش‌های ارائه شده در نشریات معتبر می‌باشد. علت این برتری می‌تواند به علت معماری جدید در نظر گرفته شده در LDA-RPNet به سبب استفاده از تبدیل LDA و تولید ویژگی‌های سلسله مراتبی عمیق با تفکیک‌پذیری بالا دانست. همچنین با توجه به زمان پردازش داده که در برخی از مقالات فوق به آن اشاره شده است (به عنوان نمونه بالای ۱۰۰۰ ثانیه در روش CNN-MRF در سیستمی با مشخصات بسیار بهتر از سیستم مقاله حاضر) می‌توان

<sup>۱</sup> MATLAB

<sup>۲</sup> Intel® core™ 2 quad Q6700

## مراجع

- [1] F. Mirzapour, and H. Ghassemian, "Improving hyperspectral image classification by combining spectral, texture, and shape features", *International Journal of Remote Sensing*, Vol. 36(4), pp. 1070-1096, 2015. DOI: 10.1080/01431161.2015.1007251
- [2] P. Duan, X. Kang, S. Li, P. Ghamisi, and J.A. Benediktsson, "Fusion of multiple edge-preserving operations for hyperspectral image classification", *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 57(12), pp.10336-10349, 2019.
- [3] J. Peng, X. Jiang, N. Chen, and H. Fu, "Local adaptive joint sparse representation for hyperspectral image classification", *Neurocomputing*, Vol 334, pp.239-248, 2019
- [4] Y. Chen, Z. Lin, X. Zhao, G. Wang, and Y. Gu, "Deep learning-based classification of hyperspectral data", *IEEE Journal of Selected topics in applied earth observations and remote sensing*, Vol. 7(6), pp. 2094-2107, 2014. DOI: 10.1109/JSTARS.2014.2329330
- [5] 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(6): pp. 2381-2392, 2015. DOI: 10.1109/JSTARS.2015.2388577
- [6] W. Hu, Y. Huang, L. Wei, F. Zhang, H. Li, "Deep convolutional neural networks for hyperspectral image classification", *Journal of Sensors*, 2015. DOI: 10.1155/2015/258619
- [7] G. Zhao, G. Liu, L. Fang, B. Tu, and P. Ghamisi, "Multiple convolutional layers fusion framework for hyperspectral image classification", *Neurocomputing*, Vol.339, pp.149-160. 2019.
- [8] X. Kang, C. Li, S. Li, H. Lin, "Classification of hyperspectral images by Gabor filtering based deep network", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 11(4), pp. 1166-1178, 2017. DOI: 10.1109/JSTARS.2017.2767185
- [9] W. Zhao, S. Li, A. Li, B. Zhang, and Y. Li, "Hyperspectral images classification with convolutional neural network and textural feature using limited training samples", *Remote sensing letters*, Vol. 10(5), pp.449-458, 2019.
- [10] X. Cao, F. Zhou, L. Xu, D. Meng, Z. Xu, J. Paisley, "Hyperspectral image classification with Markov random fields and a convolutional neural network", *IEEE Transactions on Image Processing*, Vol. 27(5), pp. 2354-2367, 2018. DOI: 10.1109/TIP.2018.2799324
- [11] T. H. Chan, K. Jia, S. Gao, J. Lu, Z. Zeng, Y. Ma, "PCANet: A simple deep learning baseline for image classification? ", *IEEE transactions on image processing*, Vol. 24(12), pp. 5017-5032, 2015. DOI: 10.1109/TIP.2015.2475625
- [12] Y. Xu, B. Du, F. Zhang, L. Zhang, "Hyperspectral image classification via a random patches network", *ISPRS journal of photogrammetry and remote sensing*, Vol. 142, pp. 344-357, 2018. DOI: 10.1016/j.isprsjprs.2018.05.014
- [13] Y. Sun, F. Fu, and L. Fan, "A Novel Hyperspectral Image Classification Pattern Using Random Patches Convolution and Local Covariance", *Remote Sensing*, Vol.11(16), pp.1954. 2019.
- [14] B. A. Beirami, and M. Mokhtarzade, "Spatial-Spectral Random Patches Network for Classification of Hyperspectral Images", *Traitement du Signal*, Vol. 36(5), pp.399-406, 2019.
- [15] Z. Wang, H. Hu, L. Zhang, J. H. Xue, "Discriminatively guided filtering (DGF) for hyperspectral image classification",

- Neurocomputing*, Vol. 275, pp. 1981-1987, 2018. DOI: 10.1016/j.neucom.2017.10.046
- [16] M. Imani, and H. Ghassemian, "Two dimensional linear discriminant analyses for hyperspectral data", *Photogrammetric Engineering & Remote Sensing*, Vol. 81(10), pp. 777-786, 2015. DOI: 10.14358/PERS.81.10.777
- [17] Y. Guo, , T. Hastie, and R. Tibshirani, "Regularized linear discriminant analysis and its application in microarrays", *Biostatistics*, Vol. 8(1), pp. 86-100, 2006. DOI: 10.1093/biostatistics/kxj035
- [18] F. Mirzapour, and H. Ghassemian, "Moment-based feature extraction from high spatial resolution hyperspectral images", *International Journal of Remote Sensing*, Vol. 37(6), pp. 1349-136, 2016. DOI: 10.1080/2150704X.2016.1151568
- [19] B. Asghari Beirami, and M. Mokhtarzade, "SVM classification of hyperspectral images using the combination of spectral bands and Moran's I features", presented at *IEEE 10th Iranian Conference on Machine Vision and Image Processing (MVIP)*, Isfahan, Iran, 2017. DOI: 10.1109/IranianMVIP.2017.8342334
- [20] J. Jiang, C. Chen, Y. Yu, X. Jiang, J. Ma, "Spatial-aware collaborative representation for hyperspectral remote sensing image classification", *IEEE Geoscience and Remote Sensing Letters*, Vol. 14(3), pp. 404-408. 2017. DOI: 10.1109/LGRS.2016.2645708



## *Improving the performance of RpNet with LDA for extracting the deep features for the classification of hyperspectral images*

*Behnam Asghari Beirami*<sup>1\*</sup>, *Mahdi Mokhtarzadeh*<sup>2</sup>

1- Ph.D Student, Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

2- Associate professor in Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

### **Abstract**

*In recent years, deep models have achieved great success in various fields of image processing. These models have been used in some research fields of hyperspectral data processing, such as; classification and target detection. The random patches network (RpNet) has recently been proposed to extract hierarchical deep features for hyperspectral image classification. RpNet is important as it is an unsupervised method, and as a consequence, it has a fast performance to extract deep features. Despite the good performance of this network, due to the usage of the principal component analysis (PCA) method in its main structure, maximum discrimination between classes is not guaranteed in extracted features. Therefore, in this paper, in order to improve the performance of RpNet, a new method called LDA-RpNet based on linear discriminant analysis (LDA) is proposed. Experiments on two hyperspectral datasets, Indian Pines and Pavia University, show that the LDA-RpNet can extract more compact and suitable features for classifying hyperspectral images. Also, based on the experiments, the LDA-RpNet can increase the overall accuracy by up to 2.5% compared to the classical RpNet.*

**Key words:** *Hyperspectral image classification, Random patches network, linear discriminant analysis, Principal component analysis, Hierarchical deep features.*