

Improving Data Quality in a Network of Optimizers

Tahereh Bahraini*

Postdoctorate in Electrical Engineering;
Sharif University of Technology-Doctorate; Tehran, Iran;
Email: bahraini.tahereh@mail.um.ac.ir

Alireza Naeimi-Sadigh

PhD in Computer Engineering; Faculty of Semnan University;
Semnan, Iran Email: anaemi@semnan.ac.ir

Iranian Journal of
**Information
Processing and
Management**

Received: 27, Jun. 2023 Accepted: 16, Jun. 2024

Iranian Research Institute
for Information Science and Technology
(IranDoc)

ISSN 2251-8223

eISSN 2251-8231

Indexed by SCOPUS, ISC, & LISTA

Vol. 39 | No. 4 | pp. 1419-1442

Summer 2024

<https://doi.org/10.22034/ijpm.2024.2005788.1236>



Abstract: In the process of data generation or transmission, the quality of data may degrade and not meet the required level for subsequent processing steps. Improving data quality is one of the crucial steps that needs to be taken to obtain accurate information hidden within the data in any field. Researchers have proposed various methods to perform this process, which differ based on the type of data. However, it is important to note that often these methods do not consider the existing similarities in different dimensions of the data simultaneously. This can have an undesirable or detrimental impact on certain parts of the data and may not improve the damaged segments. As a result, the obtained output will not contain all the desired information. In this paper, a new method is introduced in which data quality improvement is carried out using a set of collaborative nodes in an interactive network structure. This method enhances resistance against various types of degradation by employing a set of nodes. The performance of the proposed method is compared with six other state-of-the-art data quality improvement methods on real degraded datasets. The results obtained from the simulation show that the proposed method outperforms the other compared methods.

Keywords: Image Denoising, Hyperspectral Images, Interactive Denoising, Distributed Filter Network, Hybrid Noise

* Corresponding Author

بهبود کیفیت داده در شبکه‌ای از بهینه‌سازها

طاهره بحرینی

دکتری مهندسی برق مخابرات؛
دانشگاه صنعتی شریف؛ تهران، ایران؛
bahraini.tahereh@mail.um.ac.ir

علیرضا نعیمی صدیق

دکتری مهندسی کامپیوتر؛ استادیار؛ گروه علوم
کامپیوتر؛ دانشگاه سمنان؛ سمنان، ایران؛
anaeimi@semnan.ac.ir



دریافت: ۱۴۰۲/۰۴/۰۶ | پذیرش: ۱۴۰۳/۰۳/۲۷ | مقاله برای اصلاح به مدت ۳۶ روز نزد پدیدآوران بوده است.

نشریه علمی | رتبه بین‌المللی
پژوهشگاه علوم و فناوری اطلاعات ایران
(ایرانداک)

شابا (جایی) ۲۲۵۱-۸۲۲۳
شابا (الکترونیکی) ۸۲۳۱-۲۲۵۱

نمایه در SCOPUS، LISTA، ISC، و
jipm.irandoc.ac.ir

دوره ۳۹ | شماره ۴ | صص ۱۴۱۹-۱۴۴۲
تایستان ۱۴۰۳

<https://doi.org/10.22034/jipm.2024.2005788.1236>



چکیده: در فرایند تولید یا ارسال داده، کیفیت داده کاهش یافته و یا به میزان مورد نیاز برای انجام سایر گام‌های پردازشی نیست. بهبود کیفیت داده یکی از مهم‌ترین گام‌هایی است که برای دستیابی صحیح به اطلاعات نهفته در داده در هر حوزه‌ای لازم است که انجام شود. محققان روش‌های مختلفی برای انجام این فرایند پیشنهاد داده‌اند که با توجه به نوع داده متفاوت است، اما باید توجه داشت که اغلب این روش‌ها به شباهت‌های موجود در ابعاد مختلف داده به‌طور هم‌زمان توجه نمی‌کنند. این موضوع می‌تواند بر بخش‌هایی از داده تأثیری نامطلوب و یا مخرب بگذارد و همچنین بخش‌هایی را که تخریب شده، بهبود نیخشد. در نتیجه، خروجی به‌دست‌آمده دارای همه اطلاعات مورد نظر نخواهد بود. در این مقاله، روشی جدید ارائه شده است که در آن با استفاده از مجموعه‌ای از گره‌های همکار در قالب یک شبکه تعاملی، فرایند بهبود کیفیت داده انجام می‌شود. این روش با به‌کارگیری مجموعه‌ای از گره‌ها موجب بهبود مقاومت در مقابل انواع مختلف تخریب‌ها نیز می‌شود. عملکرد روش پیشنهادی با شش روش جدید بهبود کیفیت داده بر روی داده‌های واقعی تخریب‌شده مقایسه شده است. نتایج به‌دست‌آمده در شبیه‌سازی نشان می‌دهد که روش پیشنهادی عملکرد بهتری نسبت به سایر روش‌های مورد مقایسه دارد.

کلیدواژه‌ها: حذف نویز تصویر، تصاویر فراطیفی، حذف نویز تعاملی، شبکه فیلترهای توزیع‌شده، نویز ترکیبی

۱. مقدمه

بهبود داده یکی از مهم‌ترین گام‌های پیش‌پردازشی در اغلب سیستم‌های پردازشی است. این گام می‌تواند منجر به بهبود عملکرد انواع الگوریتم‌های پردازشی با اهداف مختلف شود. برای مثال، بهبود کیفیت سیگنال گفتار می‌تواند منجر به بالا رفتن دقت در تشخیص منابع صوتی در پردازش‌های بعدی شود. همچنین در پردازش انواع تصاویر، بهبود کیفیت داده می‌تواند باعث بالا رفتن دقت الگوریتم‌های شناسایی اهداف یا ردگیری اهداف شود. در این حوزه می‌توان به تصاویر فراطیفی (HSI) اشاره کرد. تصاویر فراطیفی که با استفاده از صدها باند طیف الکترومغناطیسی از یک صحنه دریافت می‌شوند، امکان تهیه امضا یا اثر طیفی^۲ برای آن صحنه را به‌منظور استفاده در کاربردهای مختلف فراهم می‌کنند. در این تصاویر، دوربین فراطیفی شدت روشنایی را برای طیف گسترده‌ای از باندهای فرکانسی پیوسته برای هر پیکسل در تصویر به‌دست می‌آورد. این باعث می‌شود که هر پیکسل با دقت و جزئیات بالا برای تشخیص و تعیین اهداف و اشیای موجود در صحنه استفاده شود.

اکنون، تصاویر فراطیفی به‌عنوان ابزاری مؤثر در حوزه‌های نظامی، مدیریت منابع، استخراج معادن، نظارت بر پوشش گیاهی سطح کره زمین و سایر حوزه‌های مرتبط به کار گرفته می‌شوند. پایگاه‌های دادگان ارزشمندی در زمینه سنجش از راه دور و علوم زمینی توسط تصویربرداری فراطیفی برای بسیاری از تحلیل‌ها از جمله زیست‌محیطی و زمین‌شناسی ارائه شده‌اند که شامل حجم بالایی از اطلاعات دقیق هستند.

در شرایط واقعی، تصاویر HSI به‌طور معمول، با نویزهای زیادی همراه هستند که ناشی از محدودیت‌های موجود در تجهیزات تصویربرداری است. این محدودیت‌ها شامل جریان تاریکی^۳، خطای کالیبراسیون، نوسانات در منبع تغذیه، حساسیت سنجنده، تأثیر فوتون‌ها و پاسخ غیریکنواخت آشکارساز است. همچنین به‌دلیل انرژی تابشی محدود و پهنای باند باریک، انرژی گرفته‌شده توسط هر یک از سنجنده‌ها در مقایسه با انرژی نویزها ضعیف است و بنابراین، اطلاعات ارسالی تحت تأثیر نویز به‌شدت تخریب می‌شود (Chen et al. 2017). سطح نویز موجود در داده‌های HSI به عوامل مختلفی همچون مشخصات سنجنده‌های استفاده‌شده، فاصله بین سنجنده‌ها، سطح تصویربرداری و

1. hyperspectral image (HSI)

2. spectral signature

3. dark current

شرایط جوی وابسته است. نویز به‌طور جدی کیفیت تصویربرداری و در نتیجه، اطلاعات استخراج‌شده از پردازش‌های بعدی HSI را کاهش می‌دهد. برای بهبود کیفیت داده‌های HSI در پردازش‌های بعدی، فرایند کاهش و یا حذف اثر نویز یک گام پیش‌پردازشی اساسی و اجتناب‌ناپذیر است. این پردازش‌ها شامل طبقه‌بندی، استخراج ویژگی، استخراج مواد پایه^۱ یا تجزیه طیفی^۲ و آشکارسازی هدف است. به‌عنوان مثال، برای پردازش‌های اعمالی بر روی داده فراطیفی می‌توان به مقاله «شریفی، ترابی جهرمی و کشاورز» اشاره کرد که در آن نویسندگان یک روش استخراج ویژگی برای طبقه‌بندی داده فراطیفی و در ادامه، یک روش طبقه‌بندی فازی پیشنهاد داده‌اند. نویسندگان همچنین برای استخراج ویژگی مکانی از تصاویر فراطیفی یک شبکه عصبی کانولوشنی^۳ عمیق که از پیش آموزش داده شده، استفاده نمودند (۱۴۰۰). همچنین می‌توان به مقاله «صادقی» اشاره کرد که در آن، نویسندگان به کاهش بُعد تصاویر فراطیفی برای سرعت بخشیدن به سایر گام‌های پردازشی پرداخته‌اند. در این تحقیق یک روش نظارت‌نشده خودکار برای کاهش ابعاد تصاویر فراطیفی بر اساس خوشه‌بندی فازی باندها پیشنهاد شده است. این روش دو مرحله دارد که در مرحله اول بُعد ذاتی داده با تخمین گر هایسیم^۴ تعیین شده و در ادامه، به‌عنوان تعداد خوشه‌های بهینه برای خوشه‌بندی تصویر فراطیفی به کار گرفته می‌شود. در مرحله دوم، باندهای غیرمشابه با تکنیک خوشه‌بندی مشخص می‌شود (۱۴۰۱). ادغام تصاویر نیز از دیگر حوزه‌های پردازشی پُرکاربرد است که در مقاله‌های «حسنی مقدم، تراهی و ضیایان فیروزآبادی» (۱۳۹۹) و «جواهری، تراهی و توکلی صبور» (۱۳۹۹) به آن پرداخته شده است. با توجه به این حوزه‌های پردازشی و به‌دلیل محدودیت تفکیک‌پذیری سنجنده‌های HSI و وجود نویز، حذف نویز HSI به‌زمینه تحقیقاتی مهم در حوزه سنجنش از راه دور و پردازش تصویر تبدیل شده است.

۲. پیشینه پژوهش

روش‌های مختلفی برای حذف نویز در تصاویر HSI وجود دارد. در این متن، به این نکته اشاره می‌شود که روش‌های موجود برای حذف نویز، نویز را با ساختار $i.i.d$ مدل

1. endmember extraction

2. spectral unmixing

3. convolution neural network

4. Hysime

5. independent and identically distributed

می‌کنند. در اینجا، روشی مشابه با روش NMoG-LRMF^۱ (Yang et al. 2017)، که نویز را با ساختاری متشکل از چندگوسی غیر i.i.d^۲ مدل می‌کند، پیشنهاد شده است. عملکرد این روش برای حذف و کاهش اثر نویز، با آخرین روش‌های موجود مقایسه شده است. در دهه گذشته، تلاش‌های فراوانی برای بهبود کیفیت تصاویر HSI صورت گرفته که منجر به پیدایش روش‌های متعدد حذف نویز با چارچوب‌های متفاوت شده است. در این راستا، روش‌های حذف نویز یک-بعدی و دو-بعدی از شیوه‌های ساده‌تری برای کاهش سطح نویز در داده‌های HSI استفاده می‌کنند. در این روش‌ها، پردازش به شکل پیکسل به پیکسل (Green et al. 1988)، باندباند (روش‌های BM3D^۳ (Dabov et al. 2007)، Buades, Coll and Morel 2005؛ و یا به شکل غیرمحملی (Elad and Aharon 2006^۴) و یا به شکل غیرمحملی (Liu et al. 2016; Shao 2013; Yan, Shao, and Liu 2013; Wang 2014) انجام می‌شود و به همین لحاظ، نتایج با کیفیت نامطلوبی به دست می‌آید. این امر به دلیل عدم استفاده از همبستگی بین پیکسل‌های همسایه یا همبستگی بین باندهای طیفی در این روش‌هاست.

تحقیقات بسیاری بر روی بهبود کیفیت HSI مبتنی بر همبستگی‌های طیفی و مکانی تمرکز دارند. یکی از روش‌های معمول در این زمینه مبتنی بر PCA^۵ است. این روش شامل تبدیل NAPCT^۶ (Green et al. 1988)، تداخل و تجزیه و تحلیل INAPCA^۷ (Chang and Du 1999)، حذف نویز با استفاده از PCA و موجک (Chen and Qian 2010)^۸ و غیره است. افزون بر این، در پژوهش (Bollenbeck, Backhaus, and Seiffert 2011) نویسندگان روشی را برای حذف نویز از سیگنال و فیلترینگ با استفاده از روش PCA چندمتغیره چندمقیاسه^۹ بررسی کرده‌اند. در مقاله (Zhang et al. 2013) مدل بازبازی ماتریس رتبه پایین (LRMR)^{۱۰} و PCA مقاوم (RPCA)^{۱۱} برای حذف سه نوع نویز ارائه شده است. در پژوهشی دیگر ترکیبی از آستانه‌گذاری موجک دو-متغیره^{۱۲} و PCA برای کد کردن اطلاعات مکانی-طیفی استفاده شده است (Chen and Qian 2008). اما در این روش‌ها، نوع مقابله با انواع نویز یکسان است و به همین دلیل، کاهش نویز به بهترین نحو ممکن صورت نمی‌گیرد.

1. non i.i.d mixture of Gaussian low rank matrix factorization (LRMF)

2. non independent and identically distribution mixture of Gaussian

3. block-matching 3-D filtering

4. K-singular value decomposition (K-SVD)

5. principal component analysis (PCA)

6. noise adjusted principal components (NAPCs)

7. interference and NAPCs analysis (INAPCA)

8. wavelet

9. multivariate multi-resolution PCA

10. low rank matrix recovery (LRMR)

11. robust PCA

12. bivariate wavelet thresholding

یک مدل تغییرات کلی (TV)¹ مکانی-طیفی وقتی به منظور بهبود عملکرد روش‌های حذف نویز در مقاله (Yuan, Zhang, and Shen 2012) پیشنهاد شد که برای حذف نویز تفاضل‌های مربوط به اطلاعات مکانی و طیفی نویز را به کار برده است. در پژوهش آن‌ها، روش تکراری «برگمن»² استفاده شده تا بار پیچیدگی محاسباتی کاهش یابد. در مقاله (Chen, Hu and Peng 2012) نویسندگان با استفاده از یک چارچوب حداکثر احتمال پسین (MAP)³ به حذف نویز HSI پرداخته‌اند که در آن حوزه مکانی-طیفی جدیدی مبتنی بر اطلاعات وزن‌دار وقتی مکانی، ترکیب با اطلاعات مربوط به صاف‌شدگی‌ها و ناپیوستگی‌های طیفی تعریف شده است. همچنین، در مقاله (Zhong and Wang 2012) مدل MSB-CRF⁴ در یک چارچوب احتمالاتی برای به کارگیری وابستگی‌های مکانی-طیفی مطالعه شد.

باید توجه داشت که HSI می‌تواند به صورت یک داده چندبعدی در نظر گرفته شود که بر این اساس، روش‌های مبتنی بر تحلیل چندبعدی برای کاهش نویز توسعه یافتند. برای مثال، یک تنسور تعمیم‌یافته و فیلتر وینر چندبعدی (MWF)⁵ برای فرایند حذف نویز پیشنهاد شد (Letexier and Bourennane 2008). در ادامه، به هدف غلبه بر نویز غیرسفید در مقاله (Liu, Bourennane, and Fossati 2011) یک روش دو-مرحله‌ای متشکل از یک گام پیش سفیدکننده و یک MWF مبتنی بر تجزیه تنسور با استفاده از Tucker3⁶ پیشنهاد شد. Tucker3 شامل تجزیه یکتا و تخمین چندین رتبه است که به منظور غلبه بر پیچیدگی این دو، تحلیل موازی عامل‌ها (PARAFAC)⁷ به عنوان یک مدل جبر چندخطی معرفی شد (Liu, Bourennane, and Fossati 2012). نوع دیگری از روش‌های مبتنی بر تجزیه تنسور در حوزه طیفی و مکانی الگوریتم GKTD⁸ است (Karami, Yazdi, and Zolghadri 2011). افزون بر این، مدل یادگیری لغت‌نامه مبتنی بر تنسورهای غیرمحلّی تجزیه‌پذیر در (Peng et al. 2014) پیشنهاد شد که از شباهت‌های مکانی غیرمحلّی و همبستگی سراسری در راستای طیف برای تصاویر چندطیفی (MSI)⁹ استفاده می‌کند. با فرض داشتن رفتار تنسور گونه برای داده HSI و MSI دسته دیگری از روش‌ها همچون آنچه که در مقاله (Xie et al. 2016) ارائه شده.

-
- | | | |
|---|------------|--|
| 1. total variation | 2. Bergman | 3. maximum a posteriori (MAP) |
| 4. multiple-spectral-band conditional random fields (MSB-CRF) | | 5. multidimensional Wiener filtering (MWF) |
| 6. three-mode factor analysis (Tucker3) model | | 7. parallel factor analysis |
| 8. genetic kernel tucker decomposition (GKTD) | | 9. multispectral image (MSI) |

اگر فرض شود که داده HSI به صورت یک مکعب سه-بعدی است، روش‌های پیشرفته مبتنی بر تطبیق بلوکی و فیلترینگ سه-بعدی مانند، (VBM3D)^۱ (Dabov et al. 2007) و تطبیق بلوکی و فیلترینگ چهار-بعدی (BM4D)^۲ (Maggioni et al. 2012) را می‌توان بر روی HSI برای کاهش اثر نویز اعمال کرد. برای مثال، مدل BM4D به عنوان تعمیمی از روش BM3D پیشنهاد شد (Maggioni et al. 2012). در بسیاری از مسائل حذف نویز از HSI و MSI، روش‌های BM4D و یادگیری لغت‌نامه تنسور (TDL)^۳ به عملکرد بسیار خوبی رسیده‌اند. در مقاله (Maggioni et al. 2012) برای نخستین بار با اعمال مفهوم گروه‌بندی و فیلترینگ مشارکتی برای حذف نویز روش VBM3D ارائه شده است.

از دیگر ابزارهای موجود برای کاهش نویز HSI تبدیل موجک است. برای مثال، در پژوهشی که محققان در پژوهش (Othman and Qian 2006) انجام دادند، بخش بزرگی از ضرایب تبدیل موجک دارای مقادیر کوچکی بودند که متناظر با نویز در نظر گرفته شد. تعداد اندکی از این ضرایب دارای مقدار بزرگی بودند، که سیگنال فرض شد. برای بهبود کیفیت HSI، در مقاله (Chen and Zhu 2012) الگوریتمی با استفاده از ضرایب موجک همسایه پیشنهاد شد که در آن برای هر دو نسخه تغییرپذیر و تغییرناپذیر با جابه‌جایی، تبدیل موجک درخت دو-تایی^۴ مورد استفاده قرار گرفت. همچنین، روش‌های مبتنی بر معادلات دیفرانسیل جزئی (PDE)^۵ به منظور کاهش نویز HSI به کار برده شده است. برای مثال، در مقاله (Martin-Herrero 2007)، مدلی انتشاری به عنوان تکنیک حذف نویز پیشنهاد شد که در این روش یک مدل TV مکعبی با ترکیب مدل TV دو-بعدی و مدل TV یک-بعدی استفاده شد. افزون بر این، در پژوهش (Yuan, Zhang and Shen 2013)، با ترکیب مکانی-طیفی مبتنی بر TV سه-بعدی روشی برای کاهش نویز از حوزه مکان و طیف از HSI پیشنهاد شد. همچنین، روش مبتنی بر موجک به صورت ترکیبی برای بهبود سایر روش‌های کاهش نویز HSI همچون PCA (Chen and Qian 2010)، فیلتر وینر چندراهه^۶ (Lin and Bourennane 2012)، و روش جمله ناهمواری مرتبه اول (FORP)^۷ (Rasti et al. 2013) استفاده شده است.

1. video block matching and 3D (VBM3D)

2. block matching and 4D (BM4D)

3. tensor dictionary learning (TDL)

4. dual-tree complex wavelet transform

5. partial differential equation-based (PDE)

6. multi-way Wiener filtering

7. first-order roughness penalty (FORP)

به دلیل پایین بودن رتبه ماتریس HSI، استفاده از روش تقریب ماتریس رتبه پایین (LRMA)¹ در برخی از تحقیقات این حوزه مورد استفاده قرار گرفته است (Zhang et al. 2013; Ely, Aeron, and Miller 2013; Rasti, Sveinsson, and Ulfarsson 2014; Hu et al. 2014; Li et al. 2014). روشی برای تجزیه ماتریس رتبه پایین HSI و نویز با ساختار تنگ در پژوهش (Li et al. 2014) ارائه شد. سطح نویز در باندهای مختلف HSI متفاوت است. بر این اساس، روش تجزیه تکراری مقادیر تکین تصادفی با تنظیم نویز (NAIRSVD)² مبتنی بر تجزیه SVD برای کاهش نویز HSI ارتقا یافت (He et al. 2014). روش NMoG-LRMF نیز نویز با توزیع MoG غیر i.i.d. را با استفاده از تجزیه ماتریس رتبه پایین از HSI حذف می‌کند (Chen et al. 2017). روش بازیابی ماتریس رتبه پایین (LRMR)³ شباهت‌های محلی HSI را در نظر گرفته و مبتنی بر روش بازیابی رتبه پایین (LRR)⁴ عمل می‌کند (Zhang et al. 2013). روش تغییرات کلی رتبه پایین (LRTV)⁵ می‌تواند به‌طور همزمان از اطلاعات مکان و طیف برای کاهش نویز HSI استفاده نماید که در مسئله بهینه‌سازی خود از کمینه‌سازی نرم هسته‌ای (NNM)⁶ و TV استفاده کرده است (He et al. 2015). در دو روش LRMR و LRTV نویز مد نظر به صورت تنگ و گوسی است. اما در روش MoG-RPCA که از RPCA توسعه یافته در چارچوب بیزین استفاده شده، نویز به صورت ترکیبی از گوسی‌های i.i.d. و i.i.d. MOG⁷ در نظر گرفته می‌شود (Zhao et al. 2014). روش RegL1-ALM یک جمله تنظیم نرم-1 را به مسئله بهینه‌سازی اضافه و با استفاده از روش ضریب لاگرانژ تقویت شده (ALM)⁹ مسئله را حل کرده است (Zheng et al. 2012). افزون بر این، روش میانه وزندار شده چرخشی (CWM)¹⁰ نیز روشی کاهشی برای مسئله نرم-1 در LRMF است (Meng et al. 2013). در دو روش RegL1-ALM (Zheng et al. 2012) و CWM (Meng et al. 2013) نویز دارای توزیع لاپلاس¹¹ است.

از دیگر رویکردهای مورد استفاده در این مقاله که می‌توان به آن پرداخت، روش‌های انتشاری (Cattivelli and Sayed 2009) است. در این روش‌ها مجموعه‌ای از گره‌های همکار که هر یک نماینده‌ای از یک بهینه‌ساز هستند، به منظور رسیدن به یک هدف واحد، به

-
1. low rank matrix approximation (LRMA)
 2. noise adjusted iterative randomized singular value decomposition (NAIRSVD)
 3. low rank matrix recovery (LRMR)
 4. low rank recovery
 5. low rank total variation (LRTV)
 6. nuclear norm minimization (NNM)
 7. independent and identically distribution
 8. independent and identically distribution Mixture of Gaussian
 9. augmented lagrange multiplier (ALM)
 10. cyclic weighted median (CWM)
 11. Laplace

تعامل و همکاری تحت یک شبکه می‌پردازند. روش‌های مختلفی در این حوزه معرفی شده است که برای مثال، می‌توان به مقاله (Sadigh and Zayyani 2022) اشاره کرد که در آن نویسندگان یک روش بازگشتی مقاوم را با استفاده از تابع ضرر هایپربولیک کوساین^۱ تحت شبکه انتشاری طراحی کردند. همچنین در مقاله (Zayyani 2020)، روش مقاوم دیگری برای شبکه انتشاری حداقل میانگین خطا (LMS)^۲ ارائه شده است که منجر به افزایش دقت و مقاومت در برابر نویز نسبت به سایر روش‌های مقایسه شده است.

از جمله مهم‌ترین روش‌های رقیب برای روش پیشنهادی، روش ارائه شده در مقاله (Wang et al. 2017) است که در آن از یک روش بازتابی تصویر فراطیفی مبتنی بر جمله تغییرات کلی و مفهوم رتبه پایین استفاده کرده است. همان‌طور که در ادامه بیشتر توضیح داده خواهد شد، در روش پیشنهادی پژوهش حاضر نیز از این دو مفهوم بهره برده شده، با این تفاوت که در روش پیشنهادی یک شبکه از بهینه‌سازهایی که هر یک با استفاده از این دو مفهوم طراحی شده‌اند، با هم به تعامل و همکاری می‌پردازند.

ساختار مقاله پیش رو به این صورت است: روش پیشنهادی در بخش ۳، آورده شده است. نتایج شبیه‌سازی و مقایسه با سایر روش‌های کاهش نویز HSI در بخش ۴، و سرانجام، نتیجه‌گیری در بخش ۵، آمده است.

۳. روش پژوهش

۳-۱. مدل سیگنال

داده HSI در فرایند اخذ و ارسال توسط انواع نویز تخریب می‌شود که این موضوع موجب شده کاهش اثر نویز یکی از گام‌های مهم در این حوزه باشد. میزان تخریب باندهای مختلف یکسان نیست. برای مثال، برخی فرکانس‌ها بیشتر جذب بخارهای آب موجود در جو می‌شوند. در نتیجه، میزان تخریب باندهای طیفی و عملکرد روش‌ها بر روی هر باند متفاوت است.

در ابتدا لازم است مدل‌سازی مناسبی برای تخریب HSI ارائه شود. فرض کنید سیگنال HSI بدون نویز با $X \in \mathbf{R}^{M \times \tilde{N} \times B}$ نشان داده شود که در آن، M و \tilde{N} اندازه تصاویر HSI در باند و B تعداد باندهای طیفی است. داده HSI نویزی $Y \in \mathbf{R}^{M \times \tilde{N} \times B}$

1. hyperbolic cosine

2. least mean square (LMS)

نویز اضافه‌شده به آن $E \in \mathbf{R}^{M \times \tilde{N} \times B}$ است. فرض کنید E نویز جمع‌شونده باشد و بتوان آن را به صورت حاصل جمع نویز تنک $S \in \mathbf{R}^{M \times \tilde{N} \times B}$ با تابع توزیع احتمال لاپلاسین و نویز $N \in \mathbf{R}^{M \times \tilde{N} \times B}$ با تابع توزیع احتمال چندگوسی به صورت $E = N + S$ مدل کرد (He et al. 2015; (Wang et al. 2017; Bishop and Nasrabadi 2006; Song, Wang, and Zhang) 2014; Sayed 2014). مدل سیگنال به صورت زیر خواهد بود:

$$Y = X + E \quad (1)$$

هدف تخمین سیگنال HSI بدون نویز یعنی X است. با توجه به ماهیت نویز HSI، مؤلفه‌های N برای هر باند i.i.d است و این مؤلفه‌ها در باندهای مختلف غیر i.i.d هستند. به‌طور مشابه، S درون هر باند i.i.d و در باندهای مختلف غیر i.i.d است.

۲-۳. چارچوب پیشنهادی

چارچوب پیشنهادی در این مقاله، استفاده از شبکه‌ای از گره‌هاست که هر گره نقش یک حذف‌کننده نویز در این شبکه را دارد. این گره‌های موجود هر یک مبتنی بر روش تغییرات کلی اضافه‌شده به تجزیه تنسور رتبه پایین تنظیم شده (LRTDTV)^۱ (Song, Wang, and Zhang 2014) عمل کرده و داده شفاف HSI یعنی ماتریس X را تخمین زده و با یکدیگر تعامل می‌نمایند. خروجی نهایی این شبکه بر مبنای این تعامل تصویری شفاف از داده HSI است. طرح ارائه‌شده در شکل ۱، نمای کلی از این چارچوب پیشنهادی را که (DN-LRTDTV)^۲ نام دارد، نمایش می‌دهد.

مطابق این شکل، ۱۲ گره شبکه هر کدام مبتنی بر روش LRTDTV از تصاویر فراطیفی ورودی خود اثر نویز را کاسته و خروجی خود را در یک چارچوب تعاملی با سایر نودهای شبکه به اشتراک می‌گذارند. این تعامل مبتنی بر رویکرد تطبیق سپس ترکیب (ATC)^۳ (Sayed 2014) انجام شده و اجازه می‌دهد هر گره از نتایج گره‌های موجود در همسایگی خود بهره‌مند شده و اثر نویز را بهتر بکاهد.

مسئله بهینه‌سازی هر یک از گره‌ها در این شبکه یک تابع هزینه به فرم $J_k(n)$ است که این توابع هزینه در کنار هم قرار گرفته و تابع هزینه سراسری شبکه را به شکل

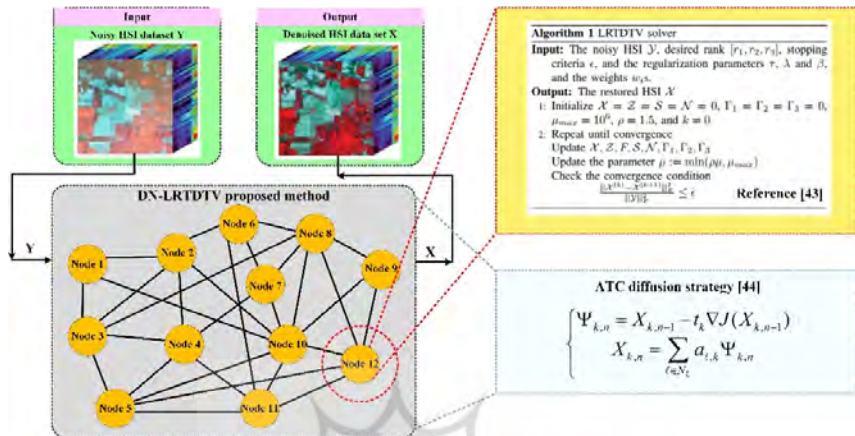
1. total variation regularized low-rank tensor decomposition (LRTDTV)

2. distributed network-LRTDTV (DN_LRTDTV)

3. adapte then combine (ATC)

زیر می‌سازند:

$$J^{Global}(n) = \sum_{k=1}^{12} J_k(n) \quad (2)$$



شکل ۱. بلوک دیاگرام روش پیشنهادی

که در آن، $J_k(n)$ تابع هزینه گره k -ام در شبکه است و ۱۲، تعداد کل گره‌های موجود در شبکه پیشنهادی است. مسئله بهینه‌سازی کلی شبکه به شکل زیر است:

$$\{X, S, N\} = \arg \min_{X, S, N} J^{Global}(n) \quad (3)$$

که بر روی سه متغیر هدف شبکه یعنی X, S و N بهینه می‌شود. تابع هزینه محلی هر یک از گره‌ها $J_k(n)$ است که به شکل زیر تعریف می‌شود:

$$\{X, S, N\} = \arg \min_{X, S, N} \tau \|X\|_{SSTV} + \lambda \|S\|_1 + \beta \|N\|_F^2 \quad (4)$$

$$s.t. \quad Y = X + S + N$$

$$X = C \times_1 U_1 \times_2 U_2 \times_3 U_3, \quad U_i^T U_i = I (i=1,2,3),$$

که در آن، $C \times_1 U_1 \times_2 U_2 \times_3 U_3$ تجزیه Tucker با تنسور هسته C و ماتریس‌های فاکتور $U_i S$ با رتبه r_i است. همچنین، $\|\cdot\|_1$ و $\|\cdot\|_F^2$ به ترتیب نرم ۱ و نرم فروبنیوس^۱ است.

1. Frobenius norm

جمله تغییرات کلی فضایی-طیفی (SSTV)^۱ که در رابطه بالا به صورت $\|X\|_{SSTV}$ آورده شده، به شکل زیر تعریف می‌شود:

$$\|X\|_{SSTV} := \sum_{i,j,k} w_1 |x_{i,j,k} - x_{i,j,k-1}| + w_2 |x_{i,j,k} - x_{i,j-1,k}| + w_3 |x_{i,j,k} - x_{i-1,j,k}| \quad (5)$$

که در آن، $x_{i,j,k}$ المان (i, j, k) -ام از ماتریس X است و w_j ($j=1, 2, 3$) وزن در راستای مد j -ام از ماتریس X است که میزان تأثیر جمله تنظیم را کنترل می‌کند. از آنجا که رابطه (۴) به دلیل وجود جمله تجزیه Tucker یک مسئله غیر محدب است، برای حل آن می‌توان از روش ALM استفاده کرد و به یک نقطه بهینه محلی رسید. ابتدا برای حل رابطه (۴) از چند متغیر کمکی در مسئله به شکل زیر کمک می‌گیریم:

$$\begin{aligned} \{X, S, N\} &= \arg \min_{C, U_i, X, F, S, N} \tau \|F\|_{SSTV} + \lambda \|S\|_1 + \beta \|N\|_F^2 \\ \text{s.t. } & Y = X + S + N, \quad X = Z, \quad D_w(Z) = F \\ & X = C \times_1 U_1 \times_2 U_2 \times_3 U_3, \quad U_i^T U_i = I (i=1, 2, 3), \end{aligned} \quad (6)$$

که در این رابطه $D_w(\cdot) = [w_1 \times D_h(\cdot); w_2 \times D_v(\cdot); w_3 \times D_t(\cdot)]$ عملگر دیفرانسیل وزن دار سه-بعدی (W3DD) نام دارد و D_t, D_v, D_h ، عملگرهای دیفرانسیلی رتبه-۳ متناظر با سه جهت مختلف در مکعب داده HSI هستند. بر مبنای روش حل ALM، ابتدا تابع لاگرانژ^۴ متناظر با رابطه (۶) تشکیل شده، سپس این تابع لاگرانژ بر روی هر یک از متغیرهای هدف مسئله، بهینه می‌شود. سرانجام، در الگوریتم متناظر با مسئله، این متغیرهای هدف به صورت تکراری مقداردهی و به‌روزرسانی می‌شوند تا شرط همگرایی برقرار شود. این فرایند در شکل ۱، در بلوک زردرنگ نمایش داده شده است. بعد از همگرایی در گره k -ام، این گره نتیجه به‌دست آمده خود را با گره‌های همسایه خود به صورت زیر به اشتراک گذاشته و با آن‌ها تعامل می‌کند:

$$\begin{aligned} \Psi_{k,n} &= X_{k,n-1} - t_k \nabla J_k(X_{k,n-1}) \\ X_{k,n} &= \sum_{\ell \in N_k} a_{\ell,k} \Psi_{k,n} \end{aligned} \quad (7)$$

1. spatial-spectral total variation (SSTV)

2. weighted three-dimensional difference (W3DD)

3. first-order difference operators

4. lagrange

که در آن $\Psi_{k,n}$ ، t_k و ∇J_k به ترتیب متغیر میانی، گام به روزرسانی در روش گرادیان نزولی، گرادیان تابع هزینه محلی و تعداد گره‌های موجود در همسایگی گره k -ام است. همچنین $a_{\ell,k}$ میزان تأثیر خروجی گره‌های همسایه بر گره k را نشان می‌دهد که در اینجا به صورت زیر به دست می‌آید:

$$a_{\ell,k} = \begin{cases} 1/|N_k| & \forall \ell \in N_k, \ell \neq k \\ 0 & \forall \ell \notin N_k \\ 1 - \sum_{\ell \in N_k \setminus k} a_{\ell,k} & \ell = N_k \end{cases} \quad (8)$$

باید توجه داشت که $a_{\ell,k} \geq 0$ و $\sum_{\ell \in N_k} a_{\ell,k} = 1$.

۴. تجزیه و تحلیل یافته‌ها

در اینجا نتایج شبیه‌سازی مربوط به روش پیشنهادی DN-LRTDTV در مقایسه با سایر روش‌ها آورده شده است. روش پیشنهادی با شش روش مقایسه شده است که عبارت‌اند از: LRMR (Zhang et al. 2013)، LRTV (He et al. 2015)، MoG-RPCA (Zhao et al. 2014)، RegL1-ALM (Zheng et al. 2012)، CWM (Meng et al. 2013) و LRTDTV (Song, Wang, and Zhang 2014).

معیارهای ارزیابی مورد استفاده به منظور مقایسه عملکرد روش‌ها روی داده مصنوعی عبارت‌اند از: MSSIM، MFSIM، MERGAS و زمان اجرای الگوریتم. همه روش‌های مورد استفاده روی نرم‌افزار متلب نسخه R2016a شبیه‌سازی شده و نتایج بر روی کامپیوتری با 4-GHz CPU و 32-GB RAM به دست آمده‌اند.

۴-۱. مجموعه داده HSI

در شبیه‌سازی‌ها دو نوع داده با نویز مصنوعی و واقعی مورد استفاده قرار گرفته است که عبارت‌اند از: الف) مجموعه‌ای از داده‌ها با نویز مصنوعی، به عنوان مثال مجموعه داده Washington DCMall (با ابعاد $1208 \times 307 \times 191$)، و ب) مجموعه‌ای از داده با نویز واقعی که برای مثال می‌توان Urban (با ابعاد $307 \times 307 \times 210$) و IndianPines (با ابعاد $145 \times 145 \times 220$) را نام برد. به منظور آماده کردن داده‌های مصنوعی لازم است بر روی آن‌ها

یک پیش‌پردازش اعمال شود. در نتیجه این پیش‌پردازش بخشی از مکعب داده HSI برای پردازش‌های بعدی برش داده می‌شود. همچنین برخی باندهای طیفی حذف می‌شود. در نتیجه، ابعاد مجموعه داده Washington DCMall به $200 \times 200 \times 160$ خواهد شد. دو داده Urban و IndianPines واقعی هستند که با نویز واقعی آلوده شده‌اند. همان‌طور که در ادامه آورده شده، برخی باندها در این دو داده تحت تأثیر عوامل محیطی و جوی، به شدت خراب شده‌اند (Liu et al. 2012).

۴-۲. تولید انواع تصاویر مصنوعی برای آزمایش

داده HSI در هنگام جمع‌آوری به وسیله نویزهای مختلف تخریب می‌شود. به گفته دیگر، این داده به ترکیبی از انواع نویزها مانند نویز گوسی، نویز ددلاین^۱ و پیکسل^۲، استرایپ^۳ و ضربه آلوده است که از نظر مقدار توان در باندهای مختلف متفاوت اعمال شده‌اند (Liu et al. 2012). در اینجا شش نوع مختلف نویز در تولید تصاویر مصنوعی تعریف شده و ترکیبی از این نویزها به داده HSI اضافه می‌شود. این شش نوع نویز عبارت‌اند از: نویز گوسی از نوع i.i.d، نویز گوسی از نوع غیر i.i.d، ترکیبی از نویز گوسی غیر i.i.d و استرایپ، ترکیبی از نویز گوسی غیر i.i.d و ددلاین، ترکیبی از نویز گوسی غیر i.i.d و نویز ضربه، و در آخر نویز ترکیبی (به صورت ترکیبی از همه نویزهای تعریف شده) (Chen et al. 2017).

۴-۳. معیارهای ارزیابی

برای ارزیابی و مقایسه کمی روش پیشنهادی با سایر روش‌های حذف نویز، از زمان پردازش برای ارزیابی سرعت و ۵ معیار کمی (عینی) و معیار کیفی تصویر (PQI)^۴ برای ارزیابی دقت در آزمایشات استفاده شده است. این معیارها در زیر معرفی شدند (Xie et al. 2017; Zou and Xia 2016).

۱. میانگین پیک نرخ توان سیگنال به توان نویز (MPSNR)^۵: این معیار بین تصویر HSI بدون نویز

$$MPSNR = \frac{1}{B} \sum_{i=1}^B 10 \log_{10} \left(\frac{\max(x_i)^2}{MSE(x_i, \hat{x}_i)} \right)$$

با استفاده از رابطه \hat{X} ، HSI بازبازی شده \hat{X} ،

محاسبه می‌گردد که در آن $MSE(x_i, \hat{x}_i)$ مقدار میانگین مربعات خطا بر روی باند

1. deadline noise

2. pixel noise

3. stripe noise

4. picture quality indices (PQI)

5. mean of PSNR

میانگین اندازه‌گیری شاخص تشابه ساختاری (MSSIM): این معیار برای اندازه‌گیری

سازگاری ساختاری بین دو داده بدون نویز و بازیابی شده مناسب است، و کمتر است، رنگ و شکل را ارزیابی می‌کند و دارای مقادیری بین صفر و یک است. مقادیر نزدیک به یک به معنای شباهت بیشتر دو تصویر است. فرمول معیار SSIM

$$\text{به صورت } SSIM_i = \frac{(2\mu_{x_i} \mu_{\hat{x}_i} + C_1)(2\sigma_{x_i \hat{x}_i} + C_2)}{(\mu_{x_i}^2 + \mu_{\hat{x}_i}^2 + C_1)(\sigma_{x_i}^2 + \sigma_{\hat{x}_i}^2 + C_2)}$$

میانگین و انحراف معیار تصویر مرجع μ_{x_i} و σ_{x_i} است (به‌طور مشابه، $\mu_{\hat{x}_i}$ و $\sigma_{\hat{x}_i}$ برای تصویر بازیابی شده). کوواریانس بین x_i و \hat{x}_i برابر با $\sigma_{x_i \hat{x}_i}$ است و C_1 و C_2 مقدار ثابت هستند (Fan et al. 2017; Bahraini et al. 2021).

میانگین شباهت ویژگی‌ها (MFSIM): این شاخص بر مبنای مشخصه‌های دیداری انسان طراحی و میزان سازگاری ادراکی موجود در دو تصویر را می‌سنجد. این معیار نیز بین صفر و یک قرار دارد و شباهت بیشتر دو تصویر با مقادیر بیشتر آن تعبیر می‌شود.

$$\text{مقدار FSIM برابر با } FSIM_i = \frac{\sum_{x'_i \in \Omega} S_{PC}(x_i) S_G(x_i) PC_m(x_i)}{\sum_{x'_i \in \Omega} PC_m(x_i)}$$

آن، $MFSIM = \frac{1}{B} \sum_{i=1}^B FSIM_i$ و x'_i بلوک‌هایی از x_i و \hat{x}_i را که در یک موقعیت (Ω) قرار دارند^۳ نشان می‌دهد^۴ (Fan et al. 2017).

خطای کلی بدون بعد نسبی در سنتز (MERGAS): برای محاسبه دیورژانس طیفی و مکانی به کار می‌رود. مقدار ERGAS برابر است با $ERGAS_i = \frac{mse(x_i, \hat{x}_i)}{Mean_2(x_i)}$ که در

$$\text{این رابطه MERGAS برابر است با } MERGAS = \sqrt{\frac{1}{B} \sum_{i=1}^B ERGAS_i}$$

Zou and Xia) (2016).

1. mean of SSIM

2. mean of FSIM

3. co-located block

۴. S_G و S_{PC} به منظور تخمین شباهت تجانس فاز و دامنه گرادیان

5. mean of ERGAS

۴-۴. تحلیل نتایج و مقایسه عملکرد روش‌ها

در تحلیل مقادیر به‌دست آمده باید توجه داشت که مقادیر بزرگتر مربوط به معیارها به معنای عملکرد بهتر روش است که عبارت‌اند از: معیار $MPSNR$ ، $MFSIM$ و $MSSIM$. همچنین، مقادیر کوچک‌تر برخی معیارها نیز به معنای عملکرد بهتر است؛ از جمله معیار $MERGAS$ و زمان. باید توجه شود که در همه شبیه‌سازی‌های انجام شده مقدار N برابر با ۱۲ در نظر گرفته شده است. در جدول ۱، مقدار میانگین این معیارها برای روش‌های رقیب به همراه روش پیشنهادی در شش نوع نویز برای داده $Washington\ DCMall$ به‌دست آمده است. با توجه به این نتایج می‌توان چنین نتیجه گرفت که با توجه به مقادیر به‌دست آمده برای معیارهای $MPSNR$ ، $MFSIM$ ، $MSSIM$ و $MERGAS$ در مواجهه با انواع نویزها، روش پیشنهادی به نتایج بهتری رسیده است. باید توجه داشت که برای معیار زمان روش $MoG-RPCA$ سریع‌ترین روش است که در نویز گوسی $i.i.d.$ و نویز گوسی غیر $i.i.d.$ به ترتیب به زمان اجرای برابر با ۱۳/۵۷۹ و ۱۷/۱۵۵ ثانیه رسیده است. اما چهار نوع دیگر نویز، کمترین زمان اجرا مربوط به روش $RegL1-ALM$ است. ذکر این نکته دارای اهمیت است که هزینه‌ای که روش پیشنهادی در مقابل افزایش دقت و بهبود کیفیت پیکسل‌های بازیابی می‌دهد، افزایش پیچیدگی روش است. بر همین اساس در همه نتایج زمان اجرای روش پیشنهادی بیشتر از سایر روش‌هاست. همچنین، روش $RegL1-ALM$ در اغلب موارد سریع‌ترین زمان اجرا و به گفته‌ای، کمترین پیچیدگی محاسباتی را دارد.

جدول ۱. مقایسه عملکرد روش پیشنهادی $DN-LRTDTV$ با ۶ روش دیگر برای ۶ نوع نویز و براساس ۵ معیار

ارزیابی برای داده $Washington\ DCMall$

روش پیشنهادی	LRTDTV (Song, Wang, and Zhang 2014)	CWM [(Meng et al. 2013)	LRTV (He et al. 2015)	LRMR (Zhang et al. 2013)	RegL1-ALM (Zheng et al. 2012)	MoG-RPCA (Zhao et al. 2014)	HSI نویزی	معیارها	
i.i.d Gaussian Noise									
	۴۰/۱۵	۳۹/۴۶	۳۸/۰۸	۳۸/۶۹	۳۹/۲۲	۳۷/۹۱	۳۹/۵۸	۲۶/۰۲	MPSNR
	۰/۹۹	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۷۶	MSSIM
	۰/۹۹	۰/۹۹	۰/۹۸	۰/۹۹	۰/۹۹	۰/۹۸	۰/۹۹	۰/۸۹	MFSIM
	۲/۱۲	۲/۴۰	۲/۸۱	۲/۶۱	۲/۴۶	۲/۸۷	۲/۳۶	۱۱/۴۳	MERGAS

روش پیشنهادی	LRTDTV (Song, Wang, and Zhang 2014)	CWM [(Meng et al. 2013)	LRTV (He et al. 2015)	LRMR (Zhang et al. 2013)	RegL1- ALM (Zheng et al. 2012)	MoG- RPCA (Zhao et al. 2014)	HSI نویزی	معیارها
۲۳۰/۴۰	۹۱/۵۳	۳۹/۴۲	۸۲/۳۸	۱۱۰/۹۴	۳۴/۷۸	۱۳/۵۷	-	TIME
Non i.i.d Gaussian Noise								
۳۹/۷۰	۳۸/۸۶	۳۶/۱۹	۳۶/۸۱	۳۸/۲۰	۳۶/۳۰	۳۶/۲۱	۲۴/۹۶	MPSNR
۰/۹۸	۰/۹۸	۰/۹۷	۰/۹۷	۰/۹۸	۰/۹۷	۰/۹۶	۰/۷۲	MSSIM
۰/۹۹	۰/۹۹	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۸۷	MFSIM
۲/۳۶	۲/۶۳	۳/۵۸	۳/۳۴	۲/۷۸	۳/۵۴	۳/۷۶	۱۳/۳۱	MERGAS
۱۶۷/۹۴	۹۶/۸۳	۳۹/۴۵	۸۲/۷۷	۱۱۱/۰۵	۳۴/۹۶	۱۷/۱۵	-	TIME
Gaussian + Stripe Noise								
۳۹/۶۹	۳۸/۹۷	۳۶/۰۴	۳۶/۶۵	۳۷/۶۶	۳۶/۲۵	۳۶/۵۴	۲۴/۳۹	MPSNR
۰/۹۸	۰/۹۸	۰/۹۷	۰/۹۷	۰/۹۸	۰/۹۷	۰/۹۶	۰/۷۰	MSSIM
۰/۹۹	۰/۹۹	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۸۶	MFSIM
۲/۲۰	۲/۵۷	۳/۶۵	۳/۳۹	۲/۹۷	۳/۵۵	۳/۶۶	۱۴/۲۶	MERGAS
۲۰۰/۹۳	۱۲۷/۳۰	۳۹/۱۹	۸۰/۷۹	۱۰۸/۷۴	۳۴/۷۱	۹۸/۴۴	-	TIME
Gaussian + Deadline Noise								
۳۹/۸۰	۳۸/۵۴	۳۵/۹۱	۳۶/۶۶	۳۷/۵۹	۳۶/۱۴	۳۴/۶۲	۲۴/۲۳	MPSNR
۰/۹۸	۰/۹۸	۰/۹۷	۰/۹۷	۰/۹۸	۰/۹۷	۰/۹۵	۰/۷۰	MSSIM
۰/۹۹	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۸	۰/۸۶	MFSIM
۲/۴۷	۲/۷۵	۳/۷۴	۳/۴۱	۳/۰۴	۳/۶۱	۴/۶۰	۱۴/۵۸	MERGAS
۲۰۸/۴۹	۱۲۸/۰۴	۳۹/۴۲	۸۰/۷۵	۱۰۸/۵۶	۳۵/۱۳	۱۲۸/۲۱	-	TIME
Gaussian + Impulse Noise								
۴۲/۷۸	۴۱/۸۶	۳۷/۳۶	۳۷/۷۳	۳۹/۸۲	۳۷/۵۲	۳۶/۴۰	۲۴/۱۹	MPSNR
۰/۹۹	۰/۹۹	۰/۹۸	۰/۹۸	۰/۹۸	۰/۹۷	۰/۹۷	۰/۷۱	MSSIM
۰/۹۹	۰/۹۹	۰/۹۸	۰/۹۸	۰/۹۹	۰/۹۸	۰/۹۸	۰/۸۶	MFSIM
۱/۶۶	۱/۸۸	۳/۱۶	۳/۰۳	۲/۳۱	۳/۱۳	۳/۶۹	۱۴/۷۰	MERGAS
۲۵۰/۳۷	۱۲۸/۸۷	۳۹/۷۶	۸۳/۹۲	۱۱۱/۲۲	۳۵/۴۶	۱۴۵/۵۴	-	TIME

روش پیشنهادی	LRTDTV (Song, Wang, and Zhang 2014)	CWM [(Meng et al. 2013)	LRTV (He et al. 2015)	LRMR (Zhang et al. 2013)	RegL1-ALM (Zheng et al. 2012)	MoG-RPCA (Zhao et al. 2014)	HSI نویزی	معیارها	
Mixture Noise									
	۳۷/۷۲	۳۶/۴۸	۳۳/۹۳	۳۴/۱۶	۳۶/۱۳	۳۴/۵۷	۳۴/۴۶	۲۲/۸۰	MPSNR
	۰/۹۷	۰/۹۷	۰/۹۶	۰/۹۶	۰/۹۷۲۳	۰/۹۶	۰/۹۵	۰/۶۵	MSSIM
	۰/۹۸	۰/۹۸	۰/۹۷	۰/۹۷	۰/۹۸	۰/۹۷	۰/۹۷	۰/۸۳	MFSIM
	۳/۲۰	۳/۷۳	۴/۹۲	۴/۸۲	۳/۷۵	۴/۵۲۴	۴/۹۶	۱۷/۷۲	MERGAS
	۲۴۴/۳۳	۱۲۸/۷۷	۳۹/۷۲	۸۲/۵۶	۱۱۰/۴۹	۳۴/۷۹	۱۲۱/۱۴	-	TIME

در شکل ۲، نتایج بازبازی مربوط به روش‌های رقیب به همراه روش پیشنهادی برای باند شماره ۱۱۰ از مجموعه داده مصنوعی Washington DCMal نمایش داده شده است. در اینجا، نویز اضافه شده به داده به صورت ترکیبی از چهار نوع نویز: گوسی غیر i.i.d، استریپ، ضربه‌ای و ددلاین است. مطابق این نتایج، چهار روش LRTV، RegL1-ALM، MoG-RPCA و LRMR عملکرد ضعیفی دارند و در خروجی آن‌ها نویزهای استریپ و ددلاین همچنان وجود دارد. افزون بر این، در برخی نواحی جزئیات تصویر تضعیف شده است. در مقایسه با این چهار روش، دو روش CWM و LRTDTV بهتر عمل کرده‌اند و با مقایسه کلی بین همه روش‌ها باید گفت روش پیشنهادی DN-LRTDTV به خروجی بهتری دست یافته است. باند شماره ۲۰۷ از Urban به همراه نویز واقعی اضافه شده و نتایج حذف نویز مربوط به روش‌های رقیب در شکل ۳، آورده شده است. بر اساس این نتایج، به صورت دیداری می‌توان نتیجه گرفت که دو روش LRMR و MoG-RPCA در تخمین جزئیات موجود در تصویر موفق نبوده و بخش زیادی از جزئیات از بین رفته است. از طرفی، سه روش RegL1-ALM، LRTV و CWM تنها در کاهش بخش کمی از نویز و تنها بازبازی بخش کمی از جزئیات صحنه موفق بودند.


به منظور به تصویر کشیدن بهتر عملکرد روش‌های مختلف بر داده واقعی، داده بعدی Indian Pines است که در سال ۱۹۹۲، اخذ شده است. این داده از سایت Indian Pines واقع در شمال غربی ایالت ایندیانا، کشور آمریکا گرفته شده است. مطابق شکل ۴، این نتایج برای باند ۱۱۰ نمایش داده شده است. همچنین، به منظور نمایش دقیق‌تر یک ناحیه از تصویر بزرگنمایی شده است. با توجه به خروجی‌های به دست آمده می‌توان گفت که دو روش

CWM و RegL1-ALM نسبت به روش‌های دیگر عملکرد بدتری داشته‌اند. دیده می‌شود که دو روش LRMR و LRTV نیز نسبت به این دو روش نتایج بهتری به دست آورده‌اند. در آخر باید گفت که عملکرد روش DN-LRTDTV در بازیابی پیکسل‌های تخریبی بهتر از سایر روش‌هاست.

۵. نتیجه‌گیری


حذف نویز از تصاویر فراطیفی یکی از مهم‌ترین گام‌هایی است که برای بهبود کیفیت این نوع تصاویر لازم است. روش‌های مختلفی برای انجام این کار پیشنهاد شده، اما اغلب آن‌ها به شباهت‌های مکانی-طیفی به‌طور همزمان توجه ندارند. این موضوع می‌تواند به پیکسل‌هایی با سطح

پایین نویز تأثیر نامطلوبی بگذارد و پیکسل‌هایی را که توسط سطح بالای نویز تخریب شده‌اند، بازیابی نکند. در این مقاله روشی جدید ارائه شده است که در آن با استفاده از مجموعه‌ای از حذف‌کننده‌های نویز در قالب یک شبکه‌ی تعاملی فرایند بهبود کیفیت تصاویر فراطیفی انجام می‌شود. این روش با به‌کارگیری مجموعه‌ای از گره‌ها موجب بهبود مقاومت در مقابل انواع نویز نیز می‌شود. عملکرد روش پیشنهادی با شش روش جدید بر روی تصاویر واقعی آلوده به نویز مقایسه شده و نتایج شبیه‌سازی نشان می‌دهد که روش پیشنهادی عملکرد بهتری نسبت به سایر روش‌های مورد مقایسه دارد. آزمایشات روی داده‌های مختلف HSI برای ۵ معیار ارزیابی و ۶ نوع نویز در سناریوهای مختلف انجام گرفت. مقایسه عملکرد روش پیشنهادی با روش‌های حذف نویز رقیب که در نتایج آورده شد، نشان داد که روش ارائه‌شده نسبت به سایر روش‌ها در حذف انواع نویز عملکرد مناسب‌تری دارد. به‌عنوان پیشنهاد برای کارهای آتی می‌توان به این موضوع اشاره داشت که همکاری مجموعه‌ای از حذف‌کننده‌های نویز در قالب یک شبکه‌ی تعاملی می‌تواند استفاده‌ی گسترده‌تر برای انواع کاربردها و انواع داده‌ها داشته باشد؛ اگرچه برای هر مورد نیاز به تطابق ساختار شبکه با حوزه مد نظر است که در ادامه این پژوهش می‌توان به آن پرداخت.



شکل ۳. مقایسه نتایج باند ۲۰۷ از Urban، برای حالت‌های الف) داده نویزی اولیه، ب) MoG-RPCA، ج) RegL1-ALM، د) LRMV، ذ) LRTV، ر) CWM، ز) LRTDTV، و س) روش پیشنهادی DN-LRTDTV

پژوهشگاه علوم انسانی و مطالعات فرهنگی
 پرتال جامع علوم انسانی



شکل ۴. مقایسه نتایج باند ۱۱۰ از IndianPines، برای حالت‌های الف) داده نوپزی اولیه، ب) MoG-RPCA، ج) RegL1-ALM، د) LRM، ذ) LRTV، ر) CWM، ز) LRTDTV، و س) روش پیشنهادی DN-LRTDTV

فهرست منابع

- شریفی، فرشته، امین ترابی جهرمی، و احمد کشاورز. ۱۴۰۰. ترکیب شبکه عصبی فازی پویا و مدل‌های پیش‌آموزش دیده شبکه عصبی کانولوشن به منظور طبقه‌بندی تصاویر فراطیفی. چهارمین کنفرانس بین‌المللی محاسبات نرم، گیلان، دانشگاه گیلان. <https://civilica.com/doc/1418634> (دستیابی در ۱۴۰۰/۱۲/۲۴)
- صادقی، وحید. ۱۴۰۱. کاهش بعد تصاویر سنجنش از دور فراطیفی با تخمین گره‌های Hysime و Kmeans، نهمین کنفرانس ملی توسعه پایدار در مهندسی عمران. تهران. جامعه و مرکز راهکارهای دستیابی به توسعه پایدار <https://civilica.com/doc/1524059> (دستیابی در ۱۴۰۱/۷/۶)
- حسنی مقدم، حسن، علی اصغر تراهی، و پرویز ضیایان فیروزآبادی. ۱۳۹۹. ادغام تصاویر فراطیفی با تصاویر دارای قدرت تفکیک مکانی بالا بر پایه سطوح مختلف تبدیل موجک گسسته‌ها. فصلنامه کاربرد سیستم اطلاعات جغرافیایی و سنجنش از دور در برنامه‌ریزی ۱۱ (۴). <https://civilica.com/doc/1225674> (دستیابی در: ۱۴۰۰/۳/۱۷)

جواهری، سامان، و علی اصغر تراهی و سید محمد توکلی صبور. ۱۳۹۹. شناسایی اهداف با استفاده از تلفیق تصاویر فراطیفی و تصاویر با قدرت تفکیک مکانی بالا فصلنامه کاربرد سیستم اطلاعات جغرافیایی و سنجش از دور در برنامه‌ریزی ۱۱ (۱). <https://civilica.com/doc/1140139> (دستیابی در بهار ۱۳۹۹)

References

- Bahraini, T., M. Khademi, A. Ebrahimi-moghadam and H. Sadoghi Yazdi. 2021. Variational Bayesian inference in Noise Removal from Hyperspectral Images Using Cluster-Based Latent Variables. *Nashriyyah-i Muhandisi-i Barq va Muhandisi-i Kampyutar-i Iran* 80 (2): 85.
- Bishop, Christopher M., and Nasser M. Nasrabadi. 2006. Pattern recognition and machine learning. *Spring* 4 (4).
- Bollenbeck, Felix, Andreas Backhaus, and Udo Seiffert. 2011. A multivariate wavelet-PCA denoising-filter for hyperspectral images. In 2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), pp. 1-4. Lisbon, Portugal.
- Buades, Antoni, Bartomeu Coll, and J-M. Morel. 2005. A non-local algorithm for image denoising. In 2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05), vol. 2, pp. 60-65. Ieee. San Diego, CA, USA.
- Cattivelli, Federico S., and Ali H. Sayed. 2009. Diffusion LMS strategies for distributed estimation. *IEEE transactions on signal processing* 58 (3): 1035-1048.
- Chang, Chien-I., and Qian Du. 1999. Interference and noise-adjusted principal components analysis. *IEEE transactions on geoscience and remote sensing* 37 (5): 2387-2396.
- Chen, Guangyi, and Shen-En Qian. 2008. Simultaneous dimensionality reduction and denoising of hyperspectral imagery using bivariate wavelet shrinking and principal component analysis. *Canadian Journal of Remote Sensing* 34 (5): 447-454.
- _____. 2010. Denoising of hyperspectral imagery using principal component analysis and wavelet shrinkage. *IEEE Transactions on Geoscience and remote sensing* 49 (3): 973-980.
- Chen, Guangyi, and W-P. Zhu. 2012. Signal denoising using neighbouring dual-tree complex wavelet coefficients. *IET signal processing* 6 (2): 143-147.
- Chen, Shao-Lin, Xi-Yuan Hu, and Si-Long Peng. 2012. Hyperspectral imagery denoising using a spatial-spectral domain mixing prior. *Journal of computer science and technology* 27 (4): 851-861.
- Dabov, Kostadin, Alessandro Foi, Vladimir Katkovnik, and Karen Egiazarian. 2007. Image denoising by sparse 3-D transform-domain collaborative filtering. *IEEE Transactions on image processing* 16 (8): 2080-2095.
- Dabov, Kostadin, Alessandro Foi, Vladimir Katkovnik, and Karen Egiazarian. 2007. Image denoising by sparse 3-D transform-domain collaborative filtering. *IEEE Transactions on image processing* 16 (8): 2080-2095.
- Elad, Michael, and Michal Aharon. 2006. Image denoising via sparse and redundant representations over learned dictionaries. *IEEE Transactions on Image processing* 15 (12): 3736-3745.
- Ely, Gregory, Shuchin Aeron, and Eric L. Miller. 2013. Exploiting structural complexity for robust and rapid hyperspectral imaging. In 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 2193-2197. Vancouver, British Columbia, Canada.
- Fan, Fan, Yong Ma, Chang Li, Xiaoguang Mei, Jun Huang, and Jiayi Ma. 2017. Hyperspectral image denoising with superpixel segmentation and low-rank representation. *Information Sciences* 397: 48-68.
- Green, Andrew A., Mark Berman, Paul Switzer, and Maurice D. Craig. 1988. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions*

on geoscience and remote sensing 26 (1): 65-74.

- He, Wei, Hongyan Zhang, Liangpei Zhang, and Huanfeng Shen. 2014. A noise-adjusted iterative randomized singular value decomposition method for hyperspectral image denoising. In 2014 IEEE Geoscience and Remote Sensing Symposium, pp. 1536-1539. Quebec City, Quebec, Canada.
- He, Wei, Hongyan Zhang, Liangpei Zhang, and Huanfeng Shen. 2015. Total-variation-regularized low-rank matrix factorization for hyperspectral image restoration. *IEEE transactions on geoscience and remote sensing* 54 (1): 178-188.
- Hu, Ting, Hongyan Zhang, Huanfeng Shen, and Liangpei Zhang. 2014. Robust registration by rank minimization for multiangle hyper/multispectral remotely sensed imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7 (6): 2443-2457.
- Karami, Azam, Mehran Yazdi, and Alireza Zolghadre Asli. 2011. Noise reduction of hyperspectral images using kernel non-negative tucker decomposition. *IEEE Journal of Selected Topics in Signal Processing* 5 (3): 487-493.
- Letexier, Damien, and Salah Bourennane. 2008. Noise removal from hyperspectral images by multidimensional filtering. *IEEE Transactions on Geoscience and Remote Sensing* 46 (7): 2061-2069.
- Li, Qian, Houqiang Li, Zhenbo Lu, Qingbo Lu, and Weiping Li. 2014. Denoising of hyperspectral images employing two-phase matrix decomposition. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7 (9): 3742-3754.
- Lin, Tao, and Salah Bourennane. 2012. Hyperspectral image processing by jointly filtering wavelet component tensor. *IEEE Transactions on Geoscience and Remote Sensing* 51 (6): 3529-3541.
- Liu, Ji, Przemyslaw Musialski, Peter Wonka, and Jieping Ye. 2012. Tensor completion for estimating missing values in visual data. *IEEE transactions on pattern analysis and machine intelligence* 35 (1): 208-220.
- Liu, Licheng, Long Chen, CL Philip Chen, and Yuan Yan Tang. 2016. Weighted joint sparse representation for removing mixed noise in image. *IEEE transactions on cybernetics* 47 (3): 600-611.
- Liu, Xuefeng, Salah Bourennane, and Caroline Fossati. 2011. Nonwhite noise reduction in hyperspectral images. *IEEE Geoscience and Remote Sensing Letters* 9 (3): 368-372.
- Liu, Xuefeng, Salah Bourennane, and Caroline Fossati. 2012. Denoising of hyperspectral images using the PARAFAC model and statistical performance analysis. *IEEE Transactions on Geoscience and Remote Sensing* 50 (10): 3717-3724.
- Maggioni, Matteo, Vladimir Katkovnik, Karen Egiazarian, and Alessandro Foi. 2012. Nonlocal transform-domain filter for volumetric data denoising and reconstruction. *IEEE transactions on image processing* 22 (1): 119-133.
- Martin-Herrero, Julio. 2007. Anisotropic diffusion in the hypercube. *IEEE Transactions on Geoscience and Remote Sensing* 45 (5): 1386-1398.
- Meng, Deyu, Zongben Xu, Lei Zhang, and Ji Zhao. 2013. A cyclic weighted median method for l1 low-rank matrix factorization with missing entries. In Proceedings of the AAAI Conference on Artificial Intelligence, vol. 27, no. 1, pp. 704-710. Washington, USA.
- Othman, Hisham, and Shen-En Qian. 2006. Noise reduction of hyperspectral imagery using hybrid spatial-spectral derivative-domain wavelet shrinkage. *IEEE Transactions on Geoscience and Remote Sensing* 44 (2): 397-408.
- Peng, Yi, Deyu Meng, Zongben Xu, Chenqiang Gao, Yi Yang, and Biao Zhang. 2014. Decomposable nonlocal tensor dictionary learning for multispectral image denoising. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2949-2956. OH, USA.
- Rasti, Behnood, Johannes R. Sveinsson, and Magnus Orn Ulfarsson. 2014. Wavelet-based sparse reduced-rank regression for hyperspectral image restoration. *IEEE Transactions on Geoscience*

- and *Remote Sensing* 52 (10): 6688-6698.
- Rasti, Behnood, Johannes R. Sveinsson, Magnus Orn Ulfarsson, and Jón Atli Benediktsson. 2013. Hyperspectral image denoising using first order spectral roughness penalty in wavelet domain. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7 (6): 2458-2467.
- Sadigh, Alireza Naeimi, and Hadi Zayyani. 2022. A proportionate robust diffusion recursive least exponential hyperbolic cosine algorithm for distributed estimation. *IEEE Transactions on Circuits and Systems II: Express Briefs* 69 (4): 2381-2385.
- Sayed, Ali H. 2014. Adaptive networks. *Proceedings of the IEEE* 102 (4): 460-497.
- Shao, Ling, Ruomei Yan, Xuelong Li, and Yan Liu. 2013. From heuristic optimization to dictionary learning: A review and comprehensive comparison of image denoising algorithms. *IEEE transactions on cybernetics* 44 (7): 1001-1013.
- Song, Huihui, Guojie Wang, and Kaihua Zhang. 2014. Hyperspectral image denoising via low-rank matrix recovery. *Remote sensing letters* 5 (10): 872-881.
- Wang, Qian, Lifu Zhang, Qingxi Tong, and Feizhou Zhang. 2014. Hyperspectral imagery denoising based on oblique subspace projection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7 (6): 2468-2480.
- Wang, Yao, Jiangjun Peng, Qian Zhao, Yee Leung, Xi-Le Zhao, and Deyu Meng. 2017. Hyperspectral image restoration via total variation regularized low-rank tensor decomposition. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 11 (4): 1227-1243.
- Xie, Qi, Qian Zhao, Deyu Meng, and Zongben Xu. 2017. Kronecker-basis-representation based tensor sparsity and its applications to tensor recovery. *IEEE transactions on pattern analysis and machine intelligence* 40 (8): 1888-1902.
- Xie, Qi, Qian Zhao, Deyu Meng, Zongben Xu, Shuhang Gu, Wangmeng Zuo, and Lei Zhang. 2016. Multispectral images denoising by intrinsic tensor sparsity regularization. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1692-1700. Las Vegas, NV, USA.
- Yan, Ruomei, Ling Shao, and Yan Liu. 2013. Nonlocal hierarchical dictionary learning using wavelets for image denoising. *IEEE transactions on image processing* 22 (12): 4689-4698.
- Yang, Chen, Cao Xiangyong, Zhao Qian, Meng Deyu, and Xu Zongben. 2017. Denoising hyperspectral image with non-iid noise structure. *IEEE transactions on cybernetics* 48 (3): 1054-1066.
- Yuan, Qiangqiang, Liangpei Zhang, and Huanfeng Shen. 2012. Hyperspectral image denoising employing a spectral-spatial adaptive total variation model. *IEEE Transactions on Geoscience and Remote Sensing* 50 (10): 3660-3677.
- _____. 2013. Hyperspectral image denoising with a spatial-spectral view fusion strategy. *IEEE Transactions on Geoscience and Remote Sensing* 52 (5): 2314-2325.
- Zayyani, Hadi. 2020. Robust minimum disturbance diffusion LMS for distributed estimation. *IEEE Transactions on Circuits and Systems II: Express Briefs* 68 (1): 521-525.
- Zhang, Hongyan, Wei He, Liangpei Zhang, Huanfeng Shen, and Qiangqiang Yuan. 2013. Hyperspectral image restoration using low-rank matrix recovery. *IEEE transactions on geoscience and remote sensing* 52 (8): 4729-4743.
- Zhao, Qian, Deyu Meng, Zongben Xu, Wangmeng Zuo, and Lei Zhang. 2014. Robust principal component analysis with complex noise. In *International conference on machine learning*, pp. 55-63. PMLR. Beijing, China
- Zheng, Yingqiang, Guangcan Liu, Shigeki Sugimoto, Shuicheng Yan, and Masatoshi Okutomi. 2012. Practical low-rank matrix approximation under robust l_1 -norm. In *2012 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1410-1417. Providence, Rhode Island, USA.

- Zhong, Ping, and Runsheng Wang. 2012. Multiple-spectral-band CRFs for denoising junk bands of hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing* 51 (4): 2260-2275.
- Zou, Changzhong, and Youshen Xia. 2016. Poissonian hyperspectral image superresolution using alternating direction optimization. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9 (9): 4464-4479.

طاهره بحرینی

دارای مدرک دکتری مهندسی برق-مخابرات، گرایش سیستم از دانشگاه فردوسی مشهد است. وی در حال حاضر مشغول دوره پسادکتر در دانشگاه صنعتی شریف است.

پردازش سیگنال، یادگیری ماشین، فیلترهای وفقی، بهینه‌سازی از جمله علایق پژوهشی وی است.



علیرضا نعیمی صدیق

دارای مدرک دکتری در رشته مهندسی کامپیوتر-هوش مصنوعی از دانشگاه فردوسی مشهد است. ایشان هم‌اکنون استادیار گروه علوم کامپیوتر دانشگاه سمنان است.

یادگیری توزیع شده، پردازش سیگنال و شبکه‌های تطبیقی از جمله علایق پژوهشی وی هستند.



پژوهشگاه علوم انسانی و مطالعات فرهنگی
رتال جامع علوم انسانی