

شناسایی گردوغبار در تصاویر ماهواره‌ای MODIS با استفاده از روش‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی و درخت تصمیم‌گیری

محسن شهریسوند^{۱*}، مهدی آخوندزاده هنزائی^۲، امیر حسین سوری^۱

^۱کارشناس ارشد سنجش‌ازدور - گروه مهندسی نقشه‌برداری - پردیس دانشکده‌های فنی - دانشگاه تهران
{m.shahrisvand, souri_rs}@ut.ac.ir

^۲استادیار گروه مهندسی نقشه‌برداری - پردیس دانشکده‌های فنی - دانشگاه تهران
makhonz@ut.ac.ir

(تاریخ دریافت بهمن ۱۳۹۱، تاریخ تصویب آبان ۱۳۹۳)

چکیده

یکی از مهم‌ترین بلاهای طبیعی که طی سالیان اخیر موردتوجه قرار گرفته، پدیده‌ی گردوغبار است. در سال‌های اخیر این پدیده در ایران ابعاد تازه‌ای گرفته و از یک معضل محلی، به مسئله‌ای ملی تبدیل شده است. شناسایی و تشخیص طوفان گردوغبار اولین مرحله در بررسی و پایش آن می‌باشد. این تحقیق باهدف شناسایی مناطق دارای گردوغبار از تصاویر ماهواره‌ای، در منطقه خاورمیانه انجام گرفته است. در بررسی پدیده گردوغبار تصاویر سنجنده MODIS با توجه به قدرت تفکیک زمانی و طیفی مناسب، از اهمیت ویژه‌ای برخوردار می‌باشند. در این مطالعه با استفاده از روش‌های طبقه‌بندی درخت تصمیم‌گیری، شبکه عصبی مصنوعی (ANN) و ماشین‌های بردار پشتیبان (SVM) تلاش شده است که گردوغبار در تصاویر ماهواره‌ای MODIS تشخیص داده شود، که روش طبقه‌بندی ماشین‌های بردار پشتیبان به عنوان یک ایده جدید مطرح شده است. به‌علاوه به‌منظور بررسی دقت هر سه روش بکار برده شده، از محصول AOD (Aerosol Optical Depth) سنجنده OMI استفاده شده است، که نتایج نشان دهنده دقت و صحت بالاتر روش SVM نسبت به سایر روش‌ها می‌باشد. با توجه به نتایج بدست آمده، این الگوریتم قادر به شناسایی گردوغبار در هر دو منطقه خشکی و آب به‌طور همزمان می‌باشد و می‌تواند جایگزین مناسبی برای محصول AOT (Aerosol Optical Thickness) تولید شده برای گردوغبار توسط ناسا (NASA) باشد.

واژگان کلیدی: گردوغبار، تصاویر ماهواره‌ای MODIS، ماشین‌های بردار پشتیبان، شبکه عصبی، درخت تصمیم‌گیری

* نویسنده رابط

۱- مقدمه

همواره ذرات جامد به صورت معلق در جو زمین وجود دارند اما اگر تراکم این ذرات از حد معینی بیشتر شود به مثابه یک حادثه‌ی غیرمترقبه بوده و خسارت‌زا و خطرناک خواهند بود. یکی از مهم‌ترین بلاهای طبیعی که طی سالیان اخیر مورد توجه قرار گرفته، پدیده‌ی گردوغبار است. در سال‌های اخیر در مناطق خشک و نیمه‌خشک جهان که از میانگین بارش کمی برخوردار هستند پدیده‌ی گردوغبار از اهمیت بالایی برخوردار شده و به یک مسئله‌ی نگران‌کننده تبدیل شده است. کشور ایران نیز به دلیل همجوار بودن با بخش وسیعی از پهنه‌های بیابانی تحت آثار نامطلوب این پدیده قرار می‌گیرد. طوفان‌های گردوغبار در مناطق مختلف تعاریف گوناگونی دارند اما طبق توافق سازمان بین‌المللی هواشناسی، هرگاه سرعت باد از ۱۵ متر بر ثانیه تجاوز کند و دید افقی به کمتر از یک کیلومتر برسد طوفان خاک گزارش می‌شود [۱].

طوفان‌های گردوغبار می‌توانند موجب کاهش حاصلخیزی اراضی کشاورزی، آلودگی هوا، مشکلات تنفسی و کاهش میدان دید شوند. همچنین طوفان‌های گردوغبار روی چرخه‌های زیست‌محیطی تأثیر می‌گذارند و سبب تغییر شرایط اقلیمی می‌شوند، لذا بررسی طوفان‌های گردوغبار می‌تواند به فهمیدن چگونگی تغییر شرایط اقلیمی کمک کند؛ بنابراین توانایی شناسایی و تشخیص گردوغبار و پیش‌بینی آن امری مهم است. ماهواره‌های سنجنش‌ازدور به دلیل تهیه تصاویر با پوشش مکانی و توان تفکیک زمانی مناسب، در مطالعه و بررسی طوفان‌های گردوغبار بسیار کارآمد می‌باشند. گردوغبار بر میزان انرژی رسیده به سنجنده در طول موج‌های مرئی و مادون قرمز طیف الکترومغناطیس اثر می‌گذارد و با استفاده از همین اثر می‌توان آن را در تصاویر ماهواره‌ای تشخیص داد. در سال‌های اخیر پژوهش‌هایی به منظور مطالعه و بررسی گردوغبار با استفاده از تصاویر ماهواره‌ای در مناطق مختلف جهان انجام شده است.

چندین روش به منظور استخراج گردوغبار با استفاده از باندهای حرارتی و انعکاسی در تصاویر ماهواره‌ای پیشنهاد شده است. Qu و همکاران (۲۰۰۶)، شاخص (Normalized Difference Dust Index) را معرفی کردند که با استفاده از اختلاف میزان انعکاس در باندهای $2/1 \mu\text{m}$ و آبی، گردوغبار را در تصویر شناسایی کردند [۲]. بدلیل انعکاس

بالای پدیده‌های ابر، برف و آب در طول موج آبی طیف الکترومغناطیس و اینکه گردوغبار دارای منحنی طیفی مشابه خاک می‌باشد می‌توان از این شاخص به منظور شناسایی گردوغبار در آب استفاده نمود. مطالعات اخیر در زمینه تشخیص گردوغبار در تصاویر ماهواره‌ای نشان داده است که استفاده از دمای ظاهری (Brightness Temperature) می‌تواند ابزار بسیار مناسبی جهت تشخیص گردوغبار باشد. Hao و Qu (۲۰۰۷) شاخص (Thermal-infrared dust index) را به منظور تشخیص طوفان گردوغبار در تصاویر MODIS پیشنهاد دادند. برای بدست آوردن این شاخص از چهار باند در ناحیه‌ی مادون قرمز حرارتی سنجنده‌ی MODIS استفاده کردند [۳]. در سال ۱۹۹۷ Ackerman، وابستگی میزان گردوغبار در تصویر و اختلاف دمای ظاهری بین باندهای $3/7 \mu\text{m}$ و $11 \mu\text{m}$ را بیان نمود [۴]. او در سال ۱۹۹۷ استفاده سه باند 8.0 ، $3/7$ و 11 میکرومتر را به منظور شناسایی و تشخیص گردوغبار در تصاویر MODIS و AVHRR پیشنهاد داد [۵].

اما کلیه این روش‌ها از یک حد آستانه استفاده می‌کنند که برای هر منطقه متفاوت می‌باشد و در هر روش از تعداد محدودی از باندهایی که در دسترس هستند استفاده می‌شود. بنابراین یک روش خودکار برای استخراج گردوغبار در تصاویر ماهواره‌ای می‌تواند بسیار کارا و مفید باشد. Revas-Prea و همکاران (۲۰۱۰) با استفاده از طبقه بندی تصویر با روش‌های بیشترین شباهت و شبکه‌ی عصبی (Probabilistic Neural Network) PNN توانستند طوفان گردوغبار را در تصاویر MODIS شناسایی کنند. روش بکار برده شده توسط ایشان از میزان رادیانس در ۴ باند ۲۰، ۲۹، ۳۱ و ۳۲ سنجنده‌ی MODIS نیز استفاده می‌کند [۶]. با توجه به این مطلب که در سایر طول موج‌ها، گردوغبار خواص طیفی متفاوتی در مقایسه با سایر پدیده‌ها دارد، می‌توان به منظور تشخیص بهتر این پدیده از دیگر باندهای سنجنده MODIS استفاده نمود. به‌علاوه اغلب روش‌های گفته‌شده نیاز به اطلاعات کمکی مانند ماسک ابر دارند. استفاده از این اطلاعات کمکی موجب افزایش دقت روش و کاهش عدم قطعیت در الگوریتم بکار رفته می‌شود، اما استفاده از این اطلاعات کمکی یک ضعف محسوب می‌شود. در این مقاله با افزایش ابعاد فضای ویژگی‌ها با استفاده از باندهای بیشتر، تلاش شده است که گردوغبار در تصاویر MODIS بهتر شناسایی شود.

با توجه به اینکه در طول موج‌های مرئی و مادون قرمز نزدیک بازتاب موج الکترومغناطیس برای ابر بسیار زیاد است، بنابراین می‌توان از این خاصیت برای شناسایی ابر استفاده کرد. به علاوه طول موج ۲/۱ میکرومتر (باند ۷) را می‌توان جهت تفکیک گردوغبار از ابر و برف استفاده نمود. باندهای در ناحیه مادون قرمز حرارتی نیز به دلیل اینکه بیان‌گر دمای ظاهری پدیده‌ها می‌باشند می‌توانند در جداسازی کلاس‌ها کمک فراوانی کنند.

جدول ۱- باندهای انتخاب شده از میان ۳۶ باند MODIS

Band number	λ	IFOV
۱	۶۴۵ nm	250 m
۲	۸۴۵ nm	250 m
۳	۴۶۹ nm	500 m
۴	۵۵۵ nm	500 m
۵	۱۲۴۰ nm	500 m
۶	۱۶۴۰ nm	500 m
۷	۲۱۳۰ nm	500 m
۱۷	۹۰۵ nm	1 km
۱۸	۹۳۶ nm	1 km
۱۹	۹۴۰ nm	1 km
۲۰	۳/۷۵ μm	1 km
۲۲	۳/۹۶ μm	1 km
۲۳	۴/۶۰ μm	1 km
۲۶	۱۳/۷۵ μm	1 km
۲۹	۸/۵۵ μm	1 km
۳۱	۱۱/۰۳ μm	1 km
۳۲	۱۲/۰۲ μm	1 km

با توجه به اینکه افزایش تعداد باندها بدون افزایش اطلاعات مفید، موجب کاهش دقت روش‌های طبقه‌بندی می‌شود، از ۳۶ باند موجود با توجه به خواص فیزیکی گردوغبار و سایر پدیده‌های طبیعی که در تصاویر وجود دارند، فقط باندهایی انتخاب شده‌اند که دارای اطلاعات مفیدی می‌باشند.

در این مطالعه سه طوفان گردوغبار در تاریخ‌های ۱۴ Sep ۲۰۰۸، ۱۸ Jun ۲۰۰۹ و ۴ March ۲۰۱۰ مربوط به عراق، غرب و جنوب غرب ایران، شمال و شرق عربستان مورد بررسی قرار گرفته‌اند. با توجه به اینکه در این مطالعه محصول Level 1-B سنجنده‌ی MODIS استفاده شده

این مقاله از ۵ بخش تشکیل شده است. در بخش دوم داده‌های استفاده شده در مقاله همراه با ویژگی آن‌ها بیان شده است. در بخش سوم گردوغبار در تصاویر با روش‌های مختلف شناسایی می‌شود. در بخش چهارم نتایج بدست آمده با یکدیگر و همچنین با نتایج سنجنده OMI مقایسه شده‌اند. بخش پنجم شامل نتیجه‌گیری می‌باشد.

۲- داده

در این مقاله تصاویر Level 1-B سنجنده‌ی MODIS مورد استفاده قرار می‌گیرند. سنجنده‌ی MODIS به دلیل دارا بودن توان تفکیک مکانی، زمانی و طیفی مناسب ابزار بسیار کارآمدی جهت تشخیص گردوغبار می‌باشد. این سنجنده دارای ۳۶ باند در محدوده‌ی $0.4 \mu\text{m}$ تا $14.4 \mu\text{m}$ طیف الکترومغناطیس می‌باشد، که ۲۰ باند آن در محدوده‌ی مرئی و ۱۶ باند در ناحیه‌ی حرارتی می‌باشد [۷]. توان تفکیک مکانی برای باندهای ۸ تا ۳۶، یک کیلومتر، برای ۴ تا ۷، ۵۰۰ متر و برای باندهای ۱۰، ۲۵۰ متر می‌باشد. در این مقاله به منظور یکسان کردن توان تفکیک مکانی کلیه باندها، سایر باندها با توان تفکیک مکانی بهتر از یک کیلومتر، نیز به ۱ کیلومتر تبدیل شده‌اند، که برای تشخیص گردوغبار مناسب می‌باشد. برای این منظور از یک تابع وزن مثلی در جهت اسکن کردن تصاویر و از یک تابع وزن مربعی در جهت عمود بر اسکن کردن تصاویر استفاده شد. ضمن انجام این پروسه خطای هندسی موسوم به خطای Bowtie موجود در داده‌های MODIS از روی داده‌ها حذف شد.

به منظور استفاده از تصاویر ماهواره‌ای جهت انجام استخراج گردوغبار، پیش‌پردازش‌های رادیومتریکی مختلفی انجام شد. ابتدا ارزش‌های رقومی ثبت شده توسط سنجنده (DN) به تابش طیفی تبدیل شده است. این تصحیح با استفاده از ضرایب کالیبراسیون موجود در داده انجام شد. در مرحله بعد مقدار تابش طیفی به بازتاب طیفی تبدیل می‌شود. این پروسه با اعمال تأثیر زاویه ارتفاعی خورشید و فاصله خورشید تا زمین بر اساس واحدهای ستاره‌شناسی انجام می‌شود [۲۱]. در نهایت خطای نوارنوارشدگی داده‌ها، در صورت موجود بودن در برخی از باندها حذف شد. سپس با توجه به خواص طیفی و ویژگی‌های گردوغبار از ۳۶ باند موجود در تصاویر، برخی از باندها برای ورود به الگوریتم در نظر گرفته شدند که در جدول ۱ آورده شده‌اند.

۳- روش‌های مورد استفاده به‌منظور شناسایی و تشخیص گردوغبار

در این مقاله برای اولین بار به‌منظور تشخیص گردوغبار در تصاویر ماهواره‌ای از روش ماشین‌های بردار پشتیبان استفاده شده و نتایج بدست آمده از این روش با نتایج حاصله از روش‌های شبکه‌ی عصبی و درخت تصمیم مقایسه گردیده‌اند. در ادامه روش‌های به کار رفته توضیح داده می‌شوند.

۳-۱- درخت تصمیم‌گیری (Tree Decision)

Xie در سال ۲۰۰۹، با استفاده از یک روش تلفیقی توانست گردوغبار را در تصاویر سنجنده‌ی MODIS با دقت قابل قبولی استخراج کند. نتایج بدست آمده از روش پیشنهادی او نه تنها با گردوغباری که به‌وسیله‌ی چشم در تصاویر MODIS دیده می‌شد سازگار بود بلکه با نتایج سنجنده‌ی OMI (Ozone Monitoring Instrument) و CALIPSO (Cloud-Aerosol Lidar and Infrared Pathfinder Satellite Observation) نیز سازگار بود. به علاوه او بیان نمود که این الگوریتم قادر به شناسایی و تشخیص گردوغبار نزدیک به مناطق ابری و مخلوط با ابرها نیز می‌باشد و نشان داد که دقت این روش بسیار دقیق‌تر از محصول AOT می‌باشد. در این روش تلفیقی از ۴ حد آستانه مختلف استفاده می‌شود. دو حد آستانه اول جهت کنار گذاشتن ابر، آب و برف و دو حد آستانه دوم جهت جدا کردن پیکسل‌های گردوغبار از خاک و پوشش گیاهی می‌باشد [۹].

اولین حد آستانه شاخص NDDI می‌باشد. برای محاسبه شاخص NDDI از اختلاف نرمال شده رادیانس در باندهای ۳ و ۷ سنجنده‌ی MODIS استفاده می‌گردد.

$$NDDI = \frac{R7 - R3}{R7 + R3} \quad (1)$$

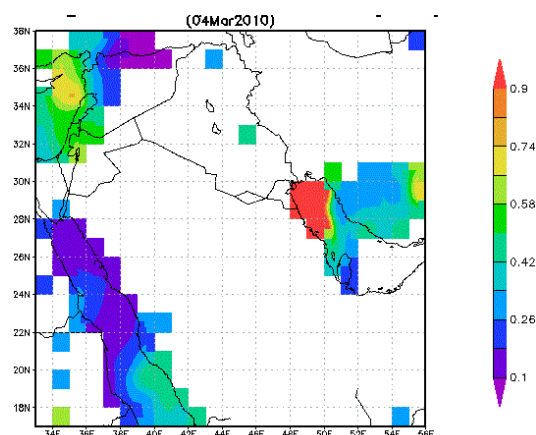
که $R7$ و $R3$ به ترتیب میزان انعکاس در باندهای ۳ و ۷ سنجنده‌ی مادیس می‌باشد [۲].

در این روش با توجه به اینکه گردوغبار برخلاف ابر، برف و آب در باند ۷ (۱/۲ میکرومتر) نسبت به باند ۳ (آبی) دارای میزان رادیانس بیشتری است، بنابراین مقدار

است، بنابراین با استفاده از اطلاعات طول و عرض جغرافیایی موجود، تصحیح هندسی انجام گرفته است.

جهت بررسی دقت نتایج بدست آمده از محصول سنجنده AOD (Aerosol Optical Depth) از مشاهدات OMI (Ozone Monitoring Instrument) استفاده شده است. سنجنده OMI در طول موج‌های ۲۶۴ تا ۵۰۴ نانومتر با قدرت تفکیک طیفی ۰/۴۳ و ۰/۶۳ نانومتر و با قدرت تفکیک مکانی ۱۳*۲۴ کیلومتر در نادر تصویر تهیه می‌کند [۸]. OMI به دلیل تهیه تصاویر روزانه از کل کره‌ی زمین گزینه مناسبی جهت بررسی تغییرات بوجود آمده در سطح زمین می‌باشد. به علاوه این سنجنده قادر به شناسایی و تفکیک بین ذرات گردوغبار و دود می‌باشد. در برخی از مطالعات از محصول AOT تولید شده از تصاویر MODIS برای ارزیابی نتایج استخراج گردوغبار از تصاویر MODIS استفاده شده است [۲۲]. نکته‌ی قابل ذکر در مورد این محصول این است که فقط برای مناطق پوشیده شده توسط آب دارای دقت بالایی است و نمی‌توان از آن برای مناطق خشکی استفاده نمود. انعکاس بالا در مناطق خشکی علت اصلی نداشتن داده در این مناطق است. در شکل ۱ نمونه‌ای از محصول AOT سنجنده MODIS برای طوفان سال ۲۰۱۰ بررسی شده در مقاله آورده شده است.

همان‌طور که در شکل ۱ دیده می‌شود فقط مناطق آب دارای مقدار می‌باشند و سایر مناطق بدون مقدار هستند. با توجه به مطالب گفته شده، در این مقاله نمی‌توان به‌منظور ارزیابی دقت نتایج از این محصول استفاده نمود. زیرا موارد مطالعاتی بررسی شده در مناطق خشکی هستند.



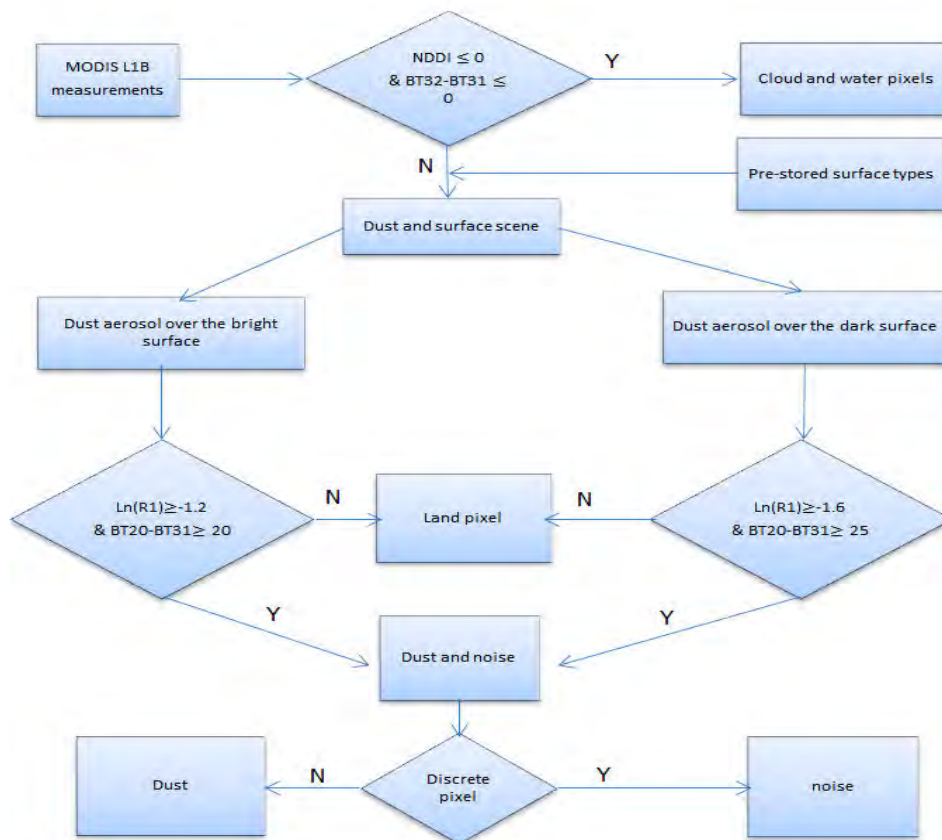
شکل ۱- محصول AOT تولید شده توسط NASA از تصویر مربوط به طوفان گردوغبار ۴ مارس ۲۰۱۰

حد آستانه‌ی انتخاب‌شده برای لگاریتم باند ۱، ۱/۲- برای مناطق روشن و ۱/۶- برای مناطق تیره می‌باشد. بنابراین با استفاده همزمان از $BTD(3.7-11)$ و $\ln(R1)$ می‌توان سطح زمین را از گردوغبار تفکیک نمود و طوفان گردوغبار را تشخیص داد. الگوریتم بکار برده شده توسط وی را در شکل ۲ می‌بینیم.

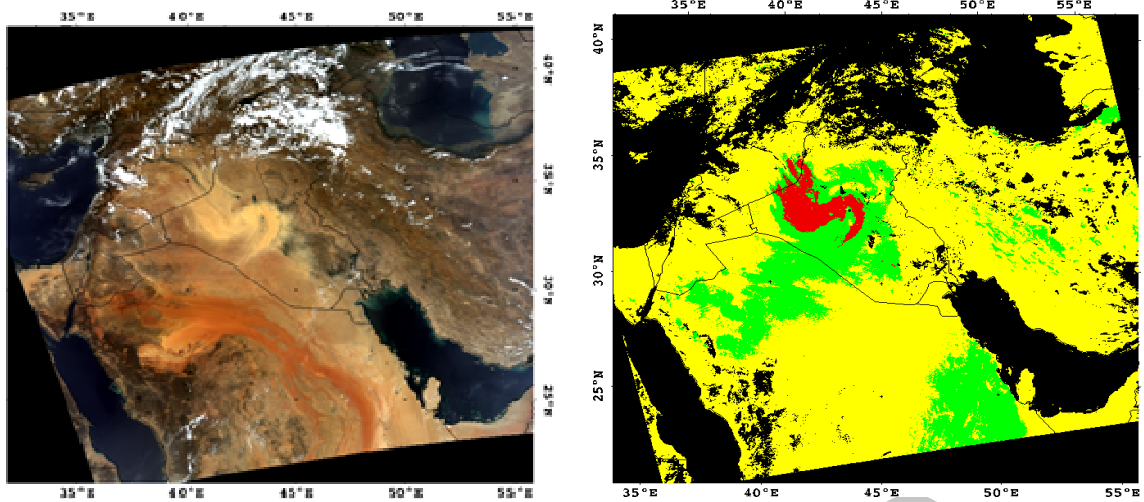
ما در این تحقیق این الگوریتم را برای سه طوفان گردوغبار در تاریخ‌های متفاوتی در سال‌های ۲۰۰۸، ۲۰۰۹ و ۲۰۱۰ اجرا نموده‌ایم. نحوه‌ی بکارگیری این الگوریتم در این مقاله به این صورت است که حد آستانه‌ها به‌عنوان قوانین تصمیم‌گیری درخت تصمیم در نظر گرفته شدند و تصاویر با روش طبقه‌بندی درخت تصمیم‌گیری، طبقه‌بندی شده است. نتایج پیاده‌سازی این الگوریتم را به همراه تصویر رنگی منطقه که توسط سنجنده MODIS گرفته شده است در شکل‌های ۳ و ۴ و ۵ می‌بینیم. رنگ قرمز در تصاویر نمایانگر منطقه‌ی طوفان گردوغبار می‌باشد.

شاخص NDDI برای گردوغبار و زمین طبیعی مثبت و برای ابر، برف و آب منفی خواهد شد که با توجه به این مطلب در این مرحله پیکسل‌های ابر و برف و آب کنار گذاشته شده و وارد مرحله‌ی بعد نمی‌شوند. حد آستانه دوم اختلاف دمایی ظاهری می‌باشد. مقدار اختلاف دمایی ظاهری باندهای ۱۱ و ۱۲ میکرومتر برای ابر منفی و برای گردوغبار مثبت است و این فیلتر نیز

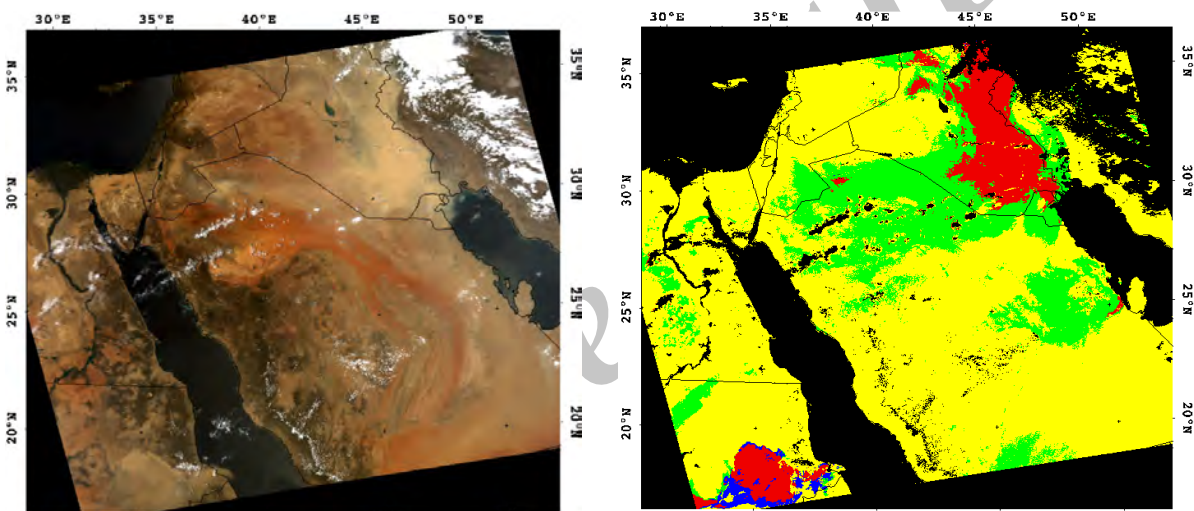
همراه با شاخص NDDI استفاده می‌شود. سپس با توجه به اینکه تصویر ما در منطقه‌ی تیره یا روشن قرار دارد از دو حد آستانه‌ی متفاوت استفاده می‌شود. طبق نتایجی که Xie بدست آورد مقدار $BTD(3.7-11)$ (اختلاف دمایی ظاهری در بین باند ۳/۷ میکرومتر و ۱۱ میکرومتر) در مناطق روشن برای پیکسل‌های گردوغبار بیشتر از ۲۵ درجه‌ی کلوین و در مناطق تیره بیشتر از ۲۰ درجه‌ی کلوین می‌باشد. بعلاوه استفاده از لگاریتم باند ۱ می‌تواند به جداسازی بهتر گردوغبار و سطح زمین کمک کند. به دلیل اینکه دامنه‌ی تغییرات باند ۱ ناحیه‌ی کوچکی می‌باشد از لگاریتم این باند استفاده شده است.



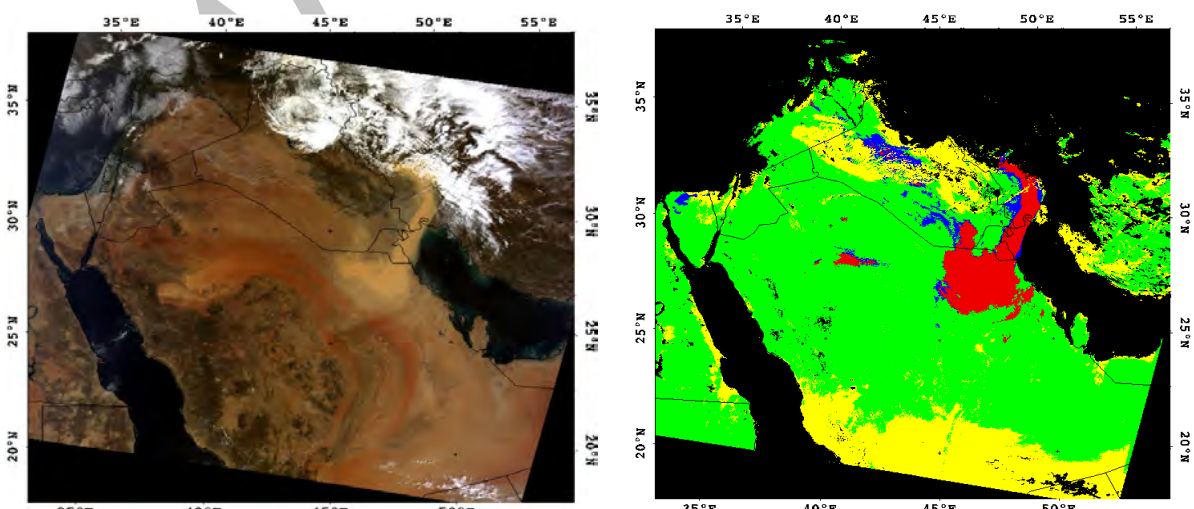
شکل ۲- الگوریتم پیشنهادی توسط Xie



شکل ۳ - تصویر رنگی منطقه، گرفته شده توسط ماهواره Aqua، سنجنده MODIS در تاریخ ۱۴ Sep ۲۰۰۸ (سمت چپ) به همراه گردوغبار استخراج شده بوسیله طبقه‌بندی به روش درخت تصمیم‌گیری (سمت راست)




شکل ۴ - تصویر رنگی منطقه، گرفته شده توسط ماهواره Aqua، سنجنده MODIS، در تاریخ ۱۴ Jun ۲۰۰۹ (سمت چپ) به همراه گردوغبار استخراج شده بوسیله طبقه‌بندی به روش درخت تصمیم‌گیری (سمت راست)



شکل ۵ - تصویر رنگی منطقه، گرفته شده توسط ماهواره Terra، سنجنده MODIS، در تاریخ ۴ March ۲۰۱۰ (سمت چپ) به همراه گردوغبار استخراج شده بوسیله روش درخت تصمیم‌گیری (سمت راست)

۳-۲- شبکه‌ی عصبی مصنوعی (Artificial Neural Network)

روش‌های طبقه‌بندی با نظارت به‌طور کلی به دو دسته-ی پارامتریک و غیرپارامتریک تقسیم می‌شوند. مشکل اصلی روش‌های پارامتریک وابستگی آن‌ها به توزیع آماری داده‌ها و تأثیر تعداد نمونه‌های آموزشی در برآورد این توزیع است، به همین دلیل روش‌های غیر پارامتریک از جمله شبکه‌های عصبی و درخت تصمیم‌گیری برای طبقه‌بندی بکار گرفته شده‌اند [۱۰]. شبکه‌های عصبی مصنوعی مدل ریاضی غیرخطی مشابه سیستم عصبی انسان هستند. هر شبکه عصبی از یک سری نورون و ارتباط وزن‌دار میان آن‌ها تشکیل شده است. نمونه‌ای از ساختار شبکه عصبی را در شکل ۶ می‌بینیم.



شکل ۶- ساختار شبکه عصبی

ورودی و خروجی‌های شناخته شده‌ای استفاده می‌کند که به آن آموزش نظارت‌شده می‌گویند. انتشار به عقب (Back propagation) معمول‌ترین الگوریتم آموزشی می‌باشد که در این مقاله نیز از این روش استفاده شده است. پس از آموزش در مرحله‌ی فراخوانی، شبکه بر اساس وزن‌های آموزش یافته-ی خود عمل می‌نماید و اعمال درون‌یابی و برون‌یابی را انجام می‌دهد. یکی از مزایای مهم شبکه‌های عصبی در مقایسه با روش‌های آماری سنتی این است که این شبکه‌ها از نظر توزیع آزادند به‌طوری که آموزش و فراخوانی به ترکیبات خطی بین الگوها وابسته بوده و به پارامترهای آماری داده‌های ورودی وابسته نیستند [۱۰].

دلایلی که باعث انجام موفق طبقه‌بندی شبکه عصبی می‌شوند عبارت‌اند از: ۱- هیچ نیازی به پیش‌فرض در مورد توزیع داده‌ها ندارند. ۲- امکان شرکت دادن دانش اولیه در مورد موضوع کلاس‌ها و محدودیت‌های واقعی وجود دارد. ۳- قادر به مدیریت داده‌های چندمنبعی می‌باشد و می‌تواند نتیجه‌ی طبقه‌بندی برابر برای آن‌ها به دست آورد.

میزان رادیانس هر پیکسل در باندهای گفته شده در جدول ۱ به عنوان ورودی می‌باشند. همچنین لایه خروجی دارای ۵ نورون و در جدول ۲ پارامترهای بهینه‌ی شبکه عصبی بکار برده شده را می‌بینیم.

جدول ۲- پارامترهای آموزشی بهینه شبکه عصبی

نرخ آموزش (Training Rate)	۰/۱
سرعت آموزش (Training Momentum)	۰/۹
حداکثر مقدار خطا برای خروج از مرحله آموزش (RMS)	۰/۰۱
تعداد لایه‌های پنهان (Number of Hidden Layer)	۱
حداکثر تعداد تکرار در مرحله آموزش (Number of Training Iteration)	۱۰۰۰

انتخاب مقادیر پارامترهای آموزش شبکه می‌تواند تأثیر قابل توجهی روی عملکرد شبکه عصبی داشته باشد. طبق نتایج بدست آمده حداقل تعداد لایه پنهان برای یک شبکه عصبی به‌منظور طبقه‌بندی، یک لایه می‌باشد [۱۱]. شبکه عصبی با یک لایه پنهان معمولاً برای اغلب مسائل مربوط به طبقه‌بندی تصاویر مناسب می‌باشد اما در صورتی که تعداد کلاس‌های خروجی بیشتر از ۲۰ کلاس باشد، دو لایه پنهان پیشنهاد می‌شود. [۱۲] تعداد نورون‌های لایه‌ی پنهان نیز طی یک فرآیند سعی و خطا بدست آمدند.


وظیفه‌ی اصلی هر نورون در شبکه‌ی عصبی این است که ورودی را از نورون‌های همسایه‌اش برای محاسبه‌ی یک خروجی دریافت نموده (خروجی نورون‌های دیگر) و خروجی محاسبه‌شده را به نورون‌های دیگر بفرستد. در واقع نورون‌ها بوسیله‌ی وزن‌های ارتباط دهنده به لایه‌های مختلف در شبکه‌ی عصبی مربوط می‌شوند. در شبکه عصبی لایه‌های مختلفی همچون لایه‌های ورودی، پنهان و خروجی وجود دارد. لایه‌های خروجی پس از دریافت ورودی و انجام پردازش بر روی آن‌ها، نتایج را در خروجی نمایش می‌دهند. شبکه‌ی عصبی در زمینه‌ی طبقه‌بندی دارای دو مرحله‌ی اساسی است:

۱- آموزش (Training)

۲- فراخوانی (Simulink)

در مرحله آموزش، بهبود بخشیدن وزن‌های ارتباطی از طریق یک روند تکراری انجام می‌شود. این سیستم آموزش از


سطح زمین می‌باشد. به منظور انتخاب نمونه‌های آموزشی در تصاویر از ترکیب‌های رنگی مختلف، به منظور تشخیص هر چه بهتر پدیده‌ها استفاده شده است. نتایج پیاده‌سازی این روش را برای سه تاریخ متفاوت در شکل ۷ می‌بینیم.



شکل ۷- گردوغبار استخراج شده بوسیله‌ی طبقه‌بندی با روش شبکه عصبی، از راست به چپ به ترتیب تصاویر اخذ شده مربوط به تاریخ‌های ۲۰۰۸، ۲۰۰۹ و ۲۰۱۰، رنگ قرمز نشان دهنده گردوغبار می‌باشد.

تصمیم‌گیری بهینه را تعیین می‌کند. به این داده‌ها بردارهای پشتیبان گویند [۱۴]. با استفاده از داده‌های آموزشی معادله‌ی ابر صفحه‌ی جداکننده‌ی دو کلاس بدست می‌آید: $\langle \vec{w}, \vec{x} \rangle + b = 0$ در جایی که \vec{x} نقطه‌ای از فراصفحه و \vec{w} بردار نرمال فراصفحه با بعد n بوده و b فاصله‌ی نزدیک‌ترین نقطه‌ی فراصفحه از مبدأ می‌باشد (شکل ۸).

ماشین‌های بردار پشتیبان دارای ۳ ویژگی اساسی می‌باشند: (۱) قابلیت تعمیم بالا: SVM برای جداسازی نمونه‌هایی که به دو کلاس متفاوت تعلق دارند، از یک فراصفحه با حاشیه‌ی بیشینه استفاده می‌کند که به آن فراصفحه تصمیم‌گیری بهینه گفته می‌شود.



شکل ۸- روش حاشیه بیشینه برای تعیین فراصفحه‌ی بهینه

پس از انتخاب نمونه‌های آموزشی در تصاویر، شبکه آموزش داده شده و سپس به وسیله‌ی وزن‌های بدست آمده تصویر طبقه‌بندی شده است. در اینجا نمونه‌های آموزشی مربوط به ۵ کلاس گردوغبار، پوشش گیاهی، آب، ابر و

۳-۳- روش ماشین‌های بردار پشتیبان (Support Vector Machine)

روش طبقه‌بندی SVM یکی دیگر از الگوریتم‌های طبقه‌بندی غیرپارامتریک می‌باشد. شبکه‌های عصبی علیرغم توانایی پردازش داده‌های پیچیده در مرحله‌ی آموزش کند هستند. به علاوه به صورت یک جعبه سیاه عمل کرده و فرآیند داخلی آن‌ها مشخص نیست. در هنگام مواجهه با داده‌های سنجش‌ازدوری، همواره سطحی از نویز وجود دارد که ممکن است به عواملی چون مشکلات سنجنده یا اثرات محیطی مربوط باشد. فرآیندهای یادگیری معمولی به طور ناخودآگاه این داده‌های نادرست را برای آموزش طبقه‌بندی کننده لحاظ و تابع تقریب را مخدوش می‌کنند که به این مشکل Overfitting گویند. الگوریتم طبقه‌بندی SVM قادر به حل این مشکل در مرحله‌ی آموزش می‌باشد [۱۳]. روش SVM به دلیل اینکه تحت تأثیر محدودیت در داده‌های آموزشی و تعداد باندها نیست روشی بسیار مناسب برای طبقه‌بندی تصاویر فراتر از چندطیفی می‌باشد.

این روش به طور مستقیم از طریق یک فرآیند بهینه‌سازی و با استفاده از تمامی باندها به دنبال داده‌های آموزشی که مرز بین کلاس‌ها را تشکیل می‌دهند، می‌پردازد و با استفاده از آن‌ها سطح جداکننده و مرز

$$f(x) = \text{sign} \left(\sum_{SV} y_i \alpha_i^0 (x_i \cdot x) + b^0 \right) \quad (3)$$

با این وجود مواردی وجود دارد که در آن با یک فراصفحه‌ی خطی، نمی‌توان داده‌ها را از یکدیگر جدا نمود. در این موارد داده‌ها به فضایی با بعد بالاتر منتقل می‌شوند که در این فضا، با یک فراصفحه‌ی خطی، قابل جداسازی باشند (شکل ۹). برای این کار، یک تابع تبدیل غیرخطی ϕ به فرم یک تابع هسته k با رابطه زیر در نظر گرفته می‌شود [۱۵].

$$k(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (4)$$

و تابع تصمیم‌گیری از رابطه‌ی زیر بدست می‌آید.

$$f(x) = \text{sign} \left(\sum_{SV} y_i \alpha_i^0 K(x_i, x) + b^0 \right) \quad (5)$$

هسته‌های مورد استفاده در این تابع برای تبدیل داده‌ها از فضای ورودی به فضایی با بعد بالاتر معمولاً از یکی از سه دسته زیر هستند [۱۶]:


- ۱- هسته‌ی خطی
- ۲- هسته‌ی چندجمله‌ای
- ۳- هسته‌ی گوسین (RBF)

روابطی که در بالا تشریح شدند برای یک طبقه‌بندی دو کلاسه کارایی دارند، چراکه SVM، در فرم اولیه، یک طبقه‌بندی‌کننده‌ی دودویی است. با بکارگیری چند راهکار در الگوریتم SVM، می‌توان طبقه‌بندی‌های چند کلاسه نیز با این روش پیاده نمود [۱۷، ۱۸].

- ۱- ترکیب طبقه‌بندی‌کننده‌های یکی در برابر بقیه
 - ۲- ترکیب طبقه‌بندی‌کننده‌های یکی در برابر یکی
- ما در این مقاله با بکارگیری الگوریتم SVM و انتخاب ۵ کلاس (گردوغبار، ابر، پوشش زمینی عاری از گردوغبار، پوشش گیاهی و آب) تصاویر را طبقه‌بندی نمودیم. جهت بکارگیری الگوریتم SVM در این مسئله ابتدا باید هسته‌ی مورد استفاده و پارمترهای آن تعیین شوند. با توجه به نتایج بدست آمده بهترین هسته، هسته‌ی گوسین می‌باشد [۱۸] که در این مسئله هم، از هسته‌ی گوسین استفاده شده است. هسته‌ی گوسین دارای ۲ پارامتر C و γ می‌باشد که باید قبل از انجام طبقه‌بندی تعیین شوند.

(۲) هنگامی که داده‌ها به صورت خطی قابل جداسازی نیستند SVM این قید را به کمک یک متغیر کمکی ξ برای هر نمونه‌ی i در نظر می‌گیرد.

(۳) SVM با تبدیل داده‌ها از فضای R^N به فضای ویژگی با ابعاد R^H که در آن $H > N$ یک تابع تصمیم‌گیری غیرخطی ایجاد می‌کند که در فضای ویژگی حاصل از آن، داده‌ها به صورت خطی قابل جدا شدن هستند (شکل ۹).



شکل ۹ - تبدیل داده‌ها از فضای R^N به فضای ویژگی با ابعاد R^H

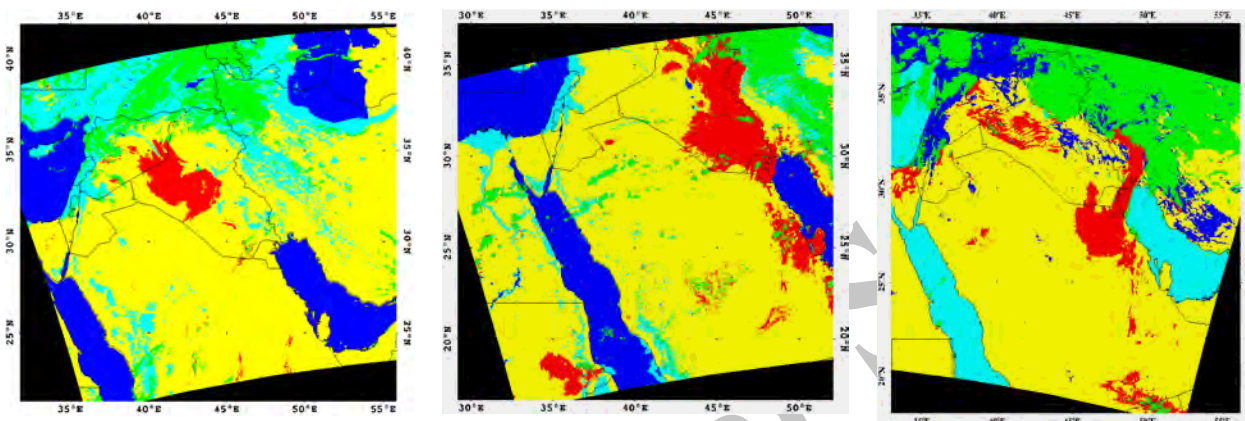
به علت وجود نویز و ترکیب کلاس‌ها در هنگام انتخاب نمونه‌های آموزشی، از متغیر آزاد $\xi_i > 0$ جهت در نظر گرفتن اثر نمونه‌های آموزشی بدون طبقه‌بندی، استفاده می‌شود. بنابراین معادله‌ی فراصفحه در این حالت برای دو کلاس، با رابطه‌ی $y_i(w \cdot x_i + b) \geq 1 - \xi_i$ مشخص می‌شود. فراصفحه‌ی بهینه مکانی است که حاشیه‌ی بین دو کلاس را بیشینه و مقدار خطا را کمینه کند. این فراصفحه با حل مسئله بهینه‌سازی قید دار زیر حل می‌شود:

$$\min \left\{ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^k \xi_i \right\} \quad i = 1, \dots, k \quad (2)$$

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i$$

پارامتر ثابت C که در آن $0 < C < \infty$ می‌باشد پارامتر تنظیم است، این پارامتر، تعادلی بین اثر نمونه‌های آموزشی و اثر نمونه‌های آموزشی بدون طبقه‌بندی و حاشیه بیشینه برقرار می‌کند و مقدار آن با سعی و خطا بدست می‌آید. مسئله بهینه‌سازی قیددار بالا با روش ضرایب لاگرانژ، قابل حل است و در نهایت تابع تصمیم‌گیری، برای طبقه‌بندی از رابطه‌ی زیر بدست می‌آید.

چندان بیشتر از روش‌های پیشرفته نیست. به‌علاوه چون هر دو پارامتر مستقل از یکدیگر هستند این روش می‌تواند به صورت موازی انجام گیرد و این در حالی است که اکثر روش‌های پیشرفته روند تکراری دارند و ممکن است طی فرآیند موازی سازی دچار مشکل شوند. نتایج پیاده‌سازی SVM با پارمترهای گفته شده در شکل ۱۰ نشان داده شده است.



شکل ۱۰- گردوغبار استخراج شده بوسیله‌ی طبقه‌بندی با روش SVM، از راست به چپ به ترتیب ۲۰۰۸، ۲۰۰۹ و ۲۰۱۰، رنگ قرمز نشان دهنده گردوغبار می‌باشد.

تفکیک آن بسیار پایین‌تر از تصاویر MODIS می‌باشد و در خشکی و دریا دارای دقت متفاوت می‌باشد. به‌منظور امکان بررسی صحت و دقت هر یک از سه روش با استفاده از نتایج سنجنده OMI، با اعمال یک حد آستانه گردوغبار از تصاویر OMI استخراج شد. سپس در هر مورد مطالعاتی تعداد پیکسل‌های درست تشخیص داده شده توسط الگوریتم محاسبه شد (جدول ۳).

جدول ۳- دقت روش‌های استفاده شده با استفاده از نتایج OMI

	Decition Tree	ANN	SVM
2008	37.3%	67.3%	71.1%
2009	45.2%	74.6%	73.8%
2010	40.4%	63.4%	79.0%

با توجه به جدول ۳ مشاهده می‌کنیم که دقت روش درخت تصمیم‌گیری در مقایسه با دو روش شبکه عصبی و ماشین‌های بردار پشتیبان بسیار کمتر است. زیرا حد-آستانه‌های تعریف‌شده در این روش بسیار سخت‌گیرانه عمل می‌کنند و فقط توده اصلی طوفان را کشف می‌کنند. روش شبکه عصبی نیز با وجود اینکه نواحی که گردوغبار از غلظت کمتری برخوردار است را تشخیص داده است، اما

به‌منظور انتخاب پارمترهای هسته از روش ارزیابی متقابل و یک الگوریتم جستجوی شبکه‌ای بر روی پارامتر تنظیم C و پارامتر گاما استفاده شد [۱۹]. در این روش زنجیره-هایی از پارامتر C و گاما که به‌طور نمایی افزایش می‌یابند تشکیل می‌شود. با بکارگیری این روش بهترین مقدار به ازای گاما برابر ۰/۰۰۸ و $C=100$ بدست آمد. به دلیل جستجو فقط برای دو پارامتر زمان محاسبه جستجوی پارامترهای بهینه از طریق روش جستجوی شبکه‌ای

۴- مقایسه نتایج با یکدیگر

به‌طور کلی به دلیل عدم وجود داده‌ی زمینی معتبر ارزیابی دقت روش‌های شناسایی و پایش گردوغبار از تصاویر ماهواره‌ای امری بسیار مشکل می‌باشد. یکی از روش‌های ارزیابی دقت در الگوریتم‌های شناسایی گردوغبار استفاده از محصولات استاندارد NASA می‌باشد. در این قسمت نتایج بدست آمده از هر سه الگوریتم بکار برده شده در مقاله با AOD (Aerosol Optical Depth) بدست از سنجنده OMI مقایسه می‌شوند (OMAERUV AOD). به دلیل مقدار نداشتن اکثر پیکسل‌های محصول AOT بدست آمده از تصاویر MODIS و دقت پایین آن در مناطق غیر از آب، در این مقاله از این محصول استفاده نشده است. به‌طور کلی هر چه مقدار AOD بیشتر باشد، مقدار گردوغبار موجود در منطقه بیشتر است و بنابراین می‌توان از این شاخص در بررسی دقت روش‌های استخراج گردوغبار استفاده نمود. مزیت عمده استفاده از AOD این است که میزان گردوغبار موجود برحسب غلظت گردوغبار نشان می‌دهد. اما مشکل استفاده از آن این است که توان

دقت نتایج بدست آمده از روش‌های طبقه‌بندی هوشمند مطرح‌شده، ضریب کاپا و overall accuracy محاسبه گردیده‌اند. نحوه‌ی محاسبه overall accuracy طبق رابطه‌ی زیر می‌باشد.

$$\text{overall accuracy} = \frac{\text{true value}}{\text{total value}} \quad (6)$$

که true تعداد پیکسل‌هایی است که درست طبقه بندی شده‌اند و total تعداد کل پیکسل‌های موجود در تصویر می‌باشد.


ضریب کاپا نیز از رابطه زیر بدست می‌آید.

$$k = \frac{P \sum_k x_{kk} - \sum_k x_{k+} x_{+k}}{P^2 - \sum_k x_{k+} x_{+k}} \quad (7)$$


قسمت عمده‌ای از پیکسل‌های ابر را خصوصاً در نواحی مرزی گردوغبار با ابر، به‌عنوان گردوغبار در نظر گرفته است.

بر اساس نتایج بدست آمده در جدول ۳ الگوریتم پیشنهاد شده در این مقاله (SVM) نسبت به سایر روش‌ها تطابق بیشتری با محصول AOD سنجنده OMI دارد. به علاوه SVM همزمان با شناسایی توده اصلی گردوغبار در هر دو منطقه خشکی و آب، سایر مناطق که طوفان از غلظت کمتری برخوردار است را تشخیص داده است. قابل ذکر است که برای هر ۲ روش شبکه عصبی و SVM از یک سری داده‌های آموزشی استفاده شده است. نتایج پیاده‌سازی به همراه تصویر رنگی منطقه و AOD در شکل‌های ۱۱، ۱۲ و ۱۳ دیده می‌شود.

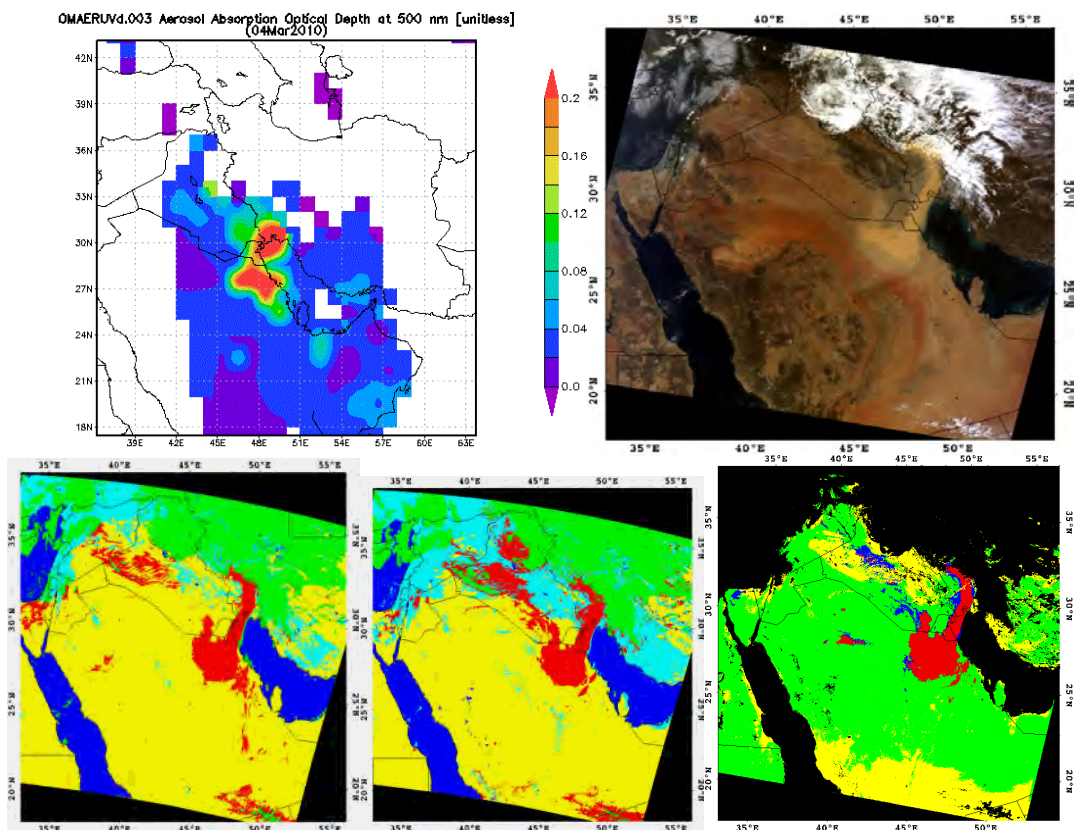
در ادامه با استفاده یکسری داده‌ی چک که با استفاده از ترکیب‌های رنگی کاذب مختلف از تصاویر بدست آمدند



شکل ۱۱ - مقایسه بین AOD بدست آمده از سنجنده OMI و نتایج استخراج گردوغبار به هر سه روش مطرح‌شده در مقاله برای تصویر گرفته شده در ۱۴ سپتامبر ۲۰۰۸ توسط ماهواره Aqua (سنجنده MODIS) به ترتیب از راست به چپ روش درخت تصمیم‌گیری، شبکه عصبی و SVM



شکل ۱۲ - مقایسه بین AOD بدست آمده از سنجنده OMI و نتایج استخراج گردوغبار به هر سه روش مطرح شده در مقاله برای تصویر گرفته شده در ۱۸ ژوئن ۲۰۰۹ توسط ماهواره Aqua (سنجنده MODIS) به ترتیب از راست به چپ روش درخت تصمیم‌گیری، شبکه عصبی و SVM



شکل ۱۳ - مقایسه بین AOD بدست آمده از سنجنده OMI و نتایج استخراج گردوغبار به هر سه روش مطرح شده در مقاله برای تصویر گرفته شده در ۴ مارس ۲۰۱۰ توسط ماهواره Aqua (سنجنده MODIS) به ترتیب از راست به چپ روش درخت تصمیم‌گیری، شبکه عصبی و SVM

بدست آمده، روش ماشین‌های بردار پشتیبان عملکرد بهتری داشت.

استفاده از این روش علاوه بر امکان تشخیص گردوغبار به صورت اتوماتیک، می‌تواند به عنوان یک روش جایگزین محصول AOT (Aerosol Optical Thickness) مادیس بکار برده شود، چراکه این محصول دارای توان تفکیک مکانی ۱۰ کیلومتر بوده و دو روز پس از اخذ تصویر، در اختیار کاربران قرار داده می‌شود و فقط در مناطق آب دارای دقت خوبی می‌باشد. محصول بدست آمده با روش پیشنهاد شده در این مقاله، علاوه بر اینکه دارای توان تفکیک یک کیلومتر می‌باشد، بلافاصله پس از تهیهی تصویر می‌تواند با دقت مناسب در هر دو منطقه خشکی و آب ارائه گردد. علاوه بر این در روش استفاده شده در این مقاله، ابر به عنوان یک کلاس در نظر گرفته شده و همزمان با تشخیص گردوغبار در تصویر، ابر نیز تشخیص داده می‌شود و نیازی به استفاده از اطلاعات کمکی جهت ماسک ابر ندارد، که این امر یکی از مزایای مهم استفاده از این روش می‌باشد.

محدودیت‌هایی در این مطالعه وجود داشته است. داده‌های آموزشی انتخاب شده در تصاویر با استفاده از ترکیب‌های رنگی مختلف بدست آمده‌اند و در صورتی که از داده‌های زمینی در منطقه استفاده شود نتایج بدست آمده قابلیت اطمینان بالاتری خواهند داشت.

که در این رابطه P تعداد کل پیکسل‌ها، k تعداد کلاس‌ها، X_{k+} مجموع تمامی ستون‌ها به ازای سطر k ام در ماتریس درهم‌ریختگی (Confusion matrix) و X_{+k} مجموع تمامی سطرها به ازای ستون k ام در ماتریس درهم‌ریختگی می‌باشند [۲۰]. مقادیر ضریب کاپا و دقت کلی در جدول ۴ آورده شده‌اند. بنابراین طبق نتایج بدست آمده روش SVM از صحت و دقت بالاتری برخوردار است.

جدول ۴ - دقت روش‌های طبقه‌بندی برای هر سه تصویر

	Date of image	Overall Accuracy	Kappa Coefficient
MLP	2008	81.4064%	0.771
SVM	2008	84.0400%	0.8091
MLP	2009	88.0776%	0.8510
SVM	2009	92.8694%	0.9115
MLP	2010	77.2567%	0.7185
SVM	2010	93.3357%	0.9170

۵- خلاصه و نتیجه‌گیری

هدف از این تحقیق شناسایی و تشخیص طوفان‌های گردوغبار با استفاده از تصاویر ماهواره‌ای MODIS، در منطقه‌ی خاورمیانه بوده است. در این مقاله برای اولین بار به منظور تشخیص گردوغبار در تصاویر ماهواره‌ای از روش ماشین‌های بردار پشتیبان استفاده شده و نتایج بدست آمده از این روش با نتایج حاصله از روش‌های شبکه‌ی عصبی و درخت تصمیم‌گیری و محصول AOD بدست آمده از سنجنده OMI مقایسه گردیده‌اند. با توجه به نتایج

مراجع

- [1] James, T. K., Chuang, C. C., and Anthony, S. W. (2007). Influence of dust composition on cloud droplet formation. *Atmospheric Environment*, vol.41, No. 14, 2904-2916.
- [2] John J. Qu, Xianjun Hao, Wanting Wang, (2005), "A Study of African Dust Storm and Its Effects on Tropical Cyclones over Atlantic Ocean from Space", IEEE Liguang Wu GEST/UMBC NASA/GSFC/912.0Greenbelt, MD 20771
- [3] Xianjun Hao, John J.Qu (2007), "Saharan dust storm detection using moderate resolution imaging Spectroradiometer thermal infrared bands", *Journal of Applied Remote Sensing*, Vol. 1, 013510
- [4] S. A. Ackerman. (1989). Using the radiative temperature difference at 3.7 μ m and 11 μ m to trace dust outbreaks. *Remote Sensing of Environment* 27(2), 129-133.
- [5] S. A. Ackerman. (1997). Remote sensing aerosols using satellite infrared observations. *Journal of Geophys. Res.* 102, 17069-17079.
- [6] Mario I. Chacon-Murguía, Yearim Quezada-Holguín, Pablo Rivas-Perea, Sergio Cabrera. (2011). Dust Storm Detection Using a Neural Network with Uncertainty and Ambiguity Output Analysis. *Pattern Recognition, Lecture Notes in Computer Science Volume 6718*. pp. 305-313

- [7] Richard A. Frey, Steven A. Ackerman, Yinghui Liu, Kathleen I. Strabala, Hong Zhang, Jeffrey R. Key, And Xuangi Wang. (2008) "Cloud Detection with MODIS. Part I: Improvements in the MODIS Cloud Mask for Collection 5", *Journal of atmospheric and oceanic technology*, volume 25, July, 1057-107.
- [8] http://www.nasa.gov/mission_pages/aura/spacecraft/omi.html
- [9] Xie Yong (2009), "Detection of Smoke and Dust Aerosols Using Multi-sensor Satellite Remote Sensing Measurements", dissertation of Doktor of philosophy at George Mason University
- [10] Kröse, B., Krose, B., van der Smagt, P., & Smagt, P. (1993). An introduction to neural networks.
- [11] Kavzoglu, T. (2001). An investigation of the design and use of feed-forward artificial neural networks in the classification of remotely sensed images. Ph.D. thesis, School of Geography, The University of Nottingham.
- [12] Kanellopoulos, I., G. G. Wilkinson, F. Roli, and J. Austin, (1997). *Neurocomputation in remote sensing data analysis*. Berlin: Springer-Verlag.
- [۱۳] شاه‌حسینی، ر.، ۱۳۸۸، ارزیابی ماشین‌های بردار پشتیبان در طبقه‌بندی تصاویر سنجش‌ازدور فراطیفی، پایان‌نامه کارشناسی ارشد، دانشگاه تهران
- [14] G. F. Hughes, (1968) "On the mean accuracy of statistical pattern recognizers", *IEEE Transactions on Information Theory* 14 (1).
- [15] Cover, T. M. (1965). Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *Electronic Computers, IEEE Transactions on*, (3), 326-334.
- [16] Camps-Valls, G., Gómez-Chova, L., Calpe-Maravilla, J., Martín-Guerrero, J. D., Soria-Olivas, E., Alonso-Chordá, L., & Moreno, J. (2004). Robust support vector method for hyperspectral data classification and knowledge discovery. *Geoscience and Remote Sensing, IEEE Transactions on*, 42(7), 1530-1542.
- [17] B. Schölkopf, K.-K. Sung, C. Burges, F. Girosi, P. Niyogi, T. Poggio, and V. N. Vapnik, (1997), "Comparing support vector machines with Gaussian kernels to radial basis function classifiers," *IEEE Trans. Signal Processing*, vol. 45, pp. 2758–2765, Nov
- [18] T. Hastie and R. Tibshirani, (1998) "Classification by pairwise coupling," *Ann. Stat.*, vol. 26, no. 2, pp. 475–471.
- [19] M. Chi and L. Bruzzone, (2007). Semisupervised Classification of Hyperspectral Images by SVMs Optimized in the Primal. *IEEE Transaction on Geoscience and Remote Sensing*, Vol. 45, NO. 6.
- [20] John A. Richards Xiuping Jia (2005): "Remote Sensing Digital Image Analysis", Springer.
- [21] Xiong, X., & Barnes, W. (2006). An overview of MODIS radiometric calibration and characterization. *Advances in Atmospheric Sciences*, 23(1), 69-79.
- [22] Zhao, T. X. P., Ackerman, S., & Guo, W. (2010). Dust and smoke detection for multi-channel imagers. *Remote Sensing*, 2(10), 2347-2368.