



شناسایی تغییرات پوشش مانگرو با استفاده از الگوریتم ماشین بردار پشتیبان در پلتفرم محاسباتی گوگل

ارث انجین

مطالعه موردی: جنگل‌های حرا قشم

تاریخ پذیرش: ۱۴۰۰/۱۱/۳۰

تاریخ دریافت: ۱۴۰۰/۰۸/۱۶

مصطفی مهدوی فرد^۱، شاهین جعفری^۲، خلیل ولیزاده کامران^{۳*}، صدرا کریمزاده^۴

۱- دانش‌آموخته کارشناسی ارشد سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز

۲- دانشجوی کارشناسی ارشد سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران

۳- دانشیار سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز

۴- استادیار سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز

چکیده

جنگل‌های مانگرو از مهم‌ترین جنگل‌های مناطق حاره‌ای و نیمه حاره‌ای هستند که در امتداد سواحل جزر و مدی یافت می‌شوند. این جنگل‌ها یکی از آسیب‌پذیرترین اکوسیستم‌های دریایی به‌شمار می‌آیند که طی چندین سال تحت تأثیر فعالیت‌های انسانی دستخوش تغییرات می‌شوند. بنابراین پیش‌بینی و به موقع آن‌ها بایست در اهداف برنامه‌ریزان زیست محیطی قرار گیرد. امروزه سنجش از دور به‌عنوان ابزاری قدرتمند و به‌روز جهت پیش‌بینی سریع جنگل‌ها شناخته شده است. هدف از این مطالعه بررسی تغییرات ۳۰ ساله جنگل‌های مانگرو دماغه شمالی جزیره قشم طی سال‌های ۱۹۸۶، ۲۰۰۰ و ۲۰۲۰ است. براساس اهداف پژوهشی نقشه پوششی مانگرو با اعمال الگوریتم ماشین بردار پشتیبان بروی تصاویر لندست ۵ و ۸ در محیط آئی گوگل ارث انجین استخراج گردید. نتایج بررسی تغییرات ۳۰ ساله حاکی از آن بود که جنگل‌های مانگرو طی ادوار پژوهشی (۱۹۸۶ تا ۲۰۲۰) روندی افزایشی داشته است بدین صورت که مساحت جنگل‌های مانگرو در سال ۱۹۸۶ از ۵۱۳۰/۷۸ هکتار به ۵۴۷۱/۸۷ هکتار در سال ۲۰۰۰ رسیده است که در حقیقت به میزان ۶/۲۳٪ مساحت جنگل‌ها افزایش داشته است. اما مساحت این جنگل‌ها در سال ۲۰۲۰ به ۵۹۶۷/۱۳ هکتار رسیده است که این میزان نسبت به مساحت یاد شده در سال ۱۹۸۶ به ۱۴/۰۲٪ افزایش یافته است. بطور کلی نتایج این پژوهش نشان می‌دهد که افزایش جنگل‌های مانگرو طی ادوار مطالعاتی نتیجه‌ی جنگل‌کاری مصنوعی توسط بومیان منطقه به منظور حفظ این اکوسیستم دریایی در منطقه بوده است که به تبع آن باعث رونق صنعت گردشگری در استان هرمزگان و حتی منطقه قشم شده است. آنچه که در پژوهش کنونی باعث تسریع فرایند پردازشی گردید، استفاده از الگوریتم ماشین بردار پشتیبان و سامانه آنلاین گوگل ارث انجین است.

کلمات کلیدی: جنگل مانگرو، آشکارسازی تغییرات، گوگل ارث انجین، الگوریتم SVM، لندست، جزیره قشم.

۱- مقدمه

جنگل‌های مانگرو به‌عنوان یک اکوسیستم منحصربه‌فرد شناخته می‌شوند که در امتداد خطوط ساحلی جزر و مدی یافت می‌شوند که حد واسط بین دریا و زمین هستند (Toosi et al., 2019, Chen et al., 2011). جنگل‌های مانگرو از مهم‌ترین جنگل‌های طبیعی هستند که در مناطق حاره‌ای و نیمه حاره‌ای یافت می‌شوند و بسیاری از خدمات اکوسیستمی مانند تصفیه کردن آب، حفاظت از خط ساحلی و مسائلی مانند تفریح و گردشگری را دارا هستند (Kanniah et al., 2015) اما این جنگل‌ها یکی از آسیب‌پذیرترین اکوسیستم‌هایی هستند که تحت تأثیر اختلالات طبیعی و تغییرات آب و هوایی و دخالت‌های انسانی مانند آلودگی استخراج نفت از بستر دریا، شهرنشینی، جنگل‌زدایی ناشی از فعالیت‌های انسانی و استخراج خرچنگ و میگو قرار می‌گیرند (Kuenzer et al., 2011, Gilman et al., 2008, Jhonnerie et al., 2015, Son et al., 2014). همین عوامل باعث کاهش بیش از ۵۰ درصدی مساحت جنگل‌های مانگرو در سراسر جهان در طول نیم‌قرن گذشته شده است (Shi et al., 2016).

به دلیل اثرات مخرب بر روی جنگل‌ها و اهمیت آن‌ها، تبلیغات مناسبی در جهت حفظ و احیای این نوع از اکوسیستم نشده است (Giri et al., 2007). بر همین اساس نظارت مکانی و زمانی بر اکوسیستم مانگرو بسیار ضروری است (Alatorre et al., 2011). استفاده از روش‌های سنتی مانند نقشه‌برداری از جنگل‌های مانگرو نیازمند زمان و هزینه زیادی است که غیرقابل‌دسترس بودن و دشواری این مناطق باعث شده کمتر از روش سنتی استفاده شود (Giri et al., 2007, Zhang et al., 2014). جنگل‌های مانگرو ایران هم به دلایل طبیعی و دخالت‌های انسانی باعث به وجود آمدن تغییرات نامطلوب در رشد و توسعه مانگروها شده است (Mehrabian et al., 2009).

یکی از راه‌هایی که می‌توان به بررسی مکانی و زمانی این جنگل‌ها پرداخت استفاده از تکنیک‌های سنجش از دور ماهواره‌ای است زیرا فناوری مبتنی بر فضا امکان جمع‌آوری اطلاعات از چشم‌اندازها را فراهم می‌کند (Son et al., 2014, Jia et al., 2014, Jones et al., 2016). تصاویر ماهواره‌ای با وضوح متوسط مانند لندست (Dan et al., 2016, Hoa, 2016, Brown et al., 2018) سنتینل-۱ و سنتینل-۲ (Chen et al., 2017)، SPOT (Pham and Brabyn, 2017) و همچنین تصاویر با وضوح بالا به‌عنوان مثال IKONOS، Quick و Worldview-2، Bird (Wang et al., 2008, Wang et al., 2016) برای بررسی جنگل‌های مانگرو در سراسر جهان استفاده شده است. ترکیب داده‌های اپتیک و رادار (Zhang et al., 2018)، استفاده از عکس‌های هوایی (Kuenzer et al., 2011) و همین‌طور استفاده از داده‌های لیدار (Olagoke et al., 2016) برای شناسایی جنگل‌های مانگرو مورد استفاده قرار گرفته است.

در مطالعه‌ای Pimple و همکاران (۲۰۱۸) با استفاده از تصاویر لندست اقدام به بررسی سه دهه جنگل‌های مانگرو در اطراف استان Trat کشور تایلند کردند. در این تحقیق با استفاده از روش طبقه‌بندی جنگل تصادفی در پلتفرم گوگل ارث انجین اقدام به بررسی جنگل‌های مانگرو نمودند و در طی سال‌های مورد بررسی نتایج را باهم مورد مقایسه و تحلیل قرار دادند (Pimple et al., 2018). در مطالعه‌ای دیگر Toosi و همکاران (۲۰۱۹) به پایش جنگل‌های مانگرو در جنوب کشور ایران پرداختند. در این مطالعه با استفاده از تصاویر سری زمانی لندست اقدام به مقایسه ۴ روش طبقه‌بندی کردند تا بهترین الگوریتم طبقه‌بندی را بدست آورند. با بررسی نتایج الگوریتم‌ها پی بردند که طبقه‌بندی جنگل تصادفی دارای صحت بالاتری نسبت به بقیه الگوریتم‌ها است (Toosi et al., 2019). در داخل کشور چندین مطالعه و بررسی جنگل‌های مانگرو صورت گرفته که می‌توان به مطالعه خورانی و همکاران (۱۳۹۴) اشاره کرد. در این مطالعه با استفاده از تصاویر لندست و دو روش طبقه‌بندی حداکثر احتمال و شاخص تفاضلی نرمال شده پوشش گیاهی^۱ به بررسی جنگل‌های مانگرو بین بندر خمیر و قشم پرداختند. مقایسه نتایج مساحت جنگل‌ها مشخص نمود که در بازه زمانی ۱۹۹۸-۲۰۰۱ روند کاهشی حاکم بوده اما در بین سال‌های ۱۹۸۴-۱۹۹۸ و ۲۰۰۱-۲۰۰۹ روند افزایشی بوده است (خورانی و همکاران، ۱۳۹۴). مافی غلامی و همکاران (۱۳۹۶) به پایش نرخ پیشروی و پسروی در جنگل‌های مانگرو با استفاده از سنجش از دور و سامانه تجزیه و تحلیل رقومی خط ساحلی پرداختند. در این مطالعه با استفاده از تصاویر لندست سال‌های ۱۹۸۶، ۲۰۰۰ و ۲۰۱۶ را بررسی کرده و نرخ تغییر مرزی مانگرو را محاسبه کردند. بر اساس نتایج، نرخ تغییرات مرز مانگروها در ذخیره‌گاه زیست‌کره حرا برابر با ۰/۶۲ متر در سال می‌باشد (مافی غلامی و همکاران، ۱۳۹۶).

در سال‌های اخیر، پلتفرم گوگل ارث انجین با دسترسی رایگان و امکان پردازش سریع‌تر داده‌های سری زمانی به وجود آمده که می‌توان در راستای تحقیقات به‌طور مناسبی در سطح جهانی و منطقه‌ای استفاده کرد (Midékisa et al., 2017, Giri et al., 2015). برای مثال در پلتفرم گوگل ارث انجین تصاویر سری زمانی لندست از سال ۱۹۸۲ تا حال موجود است که می‌تواند در تحلیل‌های سری زمانی خیلی مفید واقع شود (Giri et al., 2015). در این مورد، ترکیب گوگل ارث انجین^۲ و SVM^۳ به‌طور بالقوه برای ارائه سریع و دقیق نقشه‌های پوششی حرا برای اهداف شناسایی تغییرات ایدئال خواهد بود. هدف از این مطالعه، توسعه روشی برای نظارت بر تغییرات جنگل‌های حرا در دماغه شمالی جزیره قشم در یک دوره ۳۰ ساله از سال ۱۹۸۶ تا ۲۰۲۰ با بهره‌گیری ترکیبی از الگوریتم ماشین بردار پشتیبان و گوگل ارث انجین بروی داده‌های سری ماهواره‌ی لندست ۵ و ۸ است.

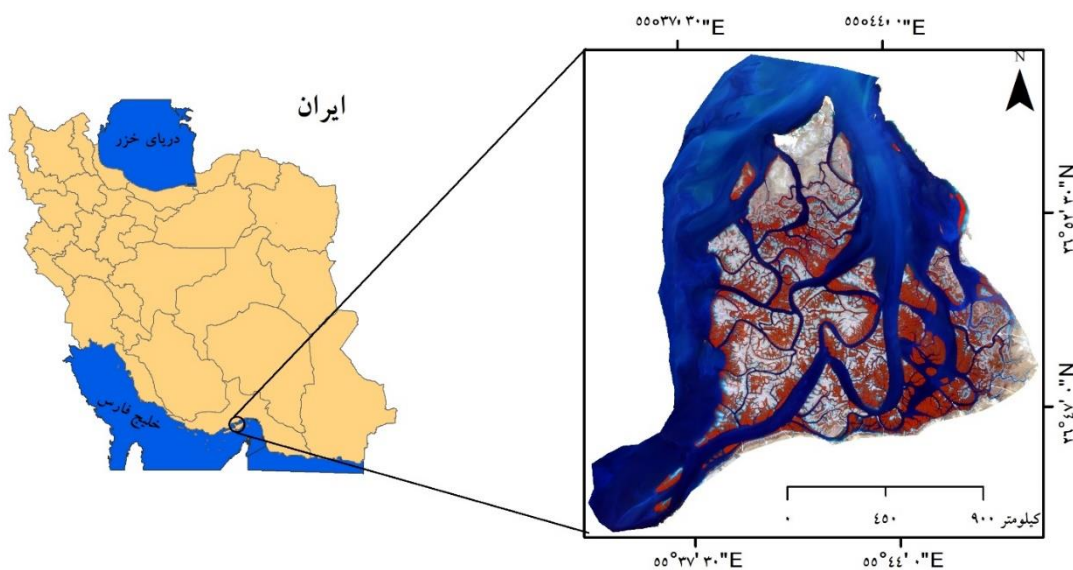
1- Normalized difference vegetation index (NDVI)
2- Google Earth Engine (GEE)

3- Support Vector Machine (SVM)

۲- روش تحقیق

۲-۱- منطقه مطالعاتی

جنگل‌های مانگرو در جزیره قشم واقع شده است (شکل ۱). این منطقه در حدفاصل رودخانه مهران و گورزین در دماغه شمالی جزیره قشم قرار دارد. منطقه حفاظتی مانگرو قشم یکی از ذخایر بیوسفری کره زمین و جز تالاب‌های بین‌المللی در خاورمیانه هست که عمده جنگل‌های مانگرو این منطقه از نوع حرا می‌باشند. بیشتر جنگل‌های مانگرو قشم در قسمت شمالی جزیره واقع شده‌اند. منطقه حفاظت شده مانگرو مساحتی به وسعت ۲۰ در ۲۰ کیلومتر را پوشش می‌دهد. این جنگل‌ها زیستگاه پرندگان مهاجر، لاکپشت‌ها و مارماهی‌های هستند. بطور کلی جنگل‌های مانگرو اهمیت ویژه‌ای برای ساکنان بومی دارد چرا که از برگ این درختان به منظور تغذیه دام نیز استفاده می‌شود (Bihamta et al. 2020).



شکل (۱): موقعیت جغرافیایی منطقه مطالعاتی

Fig. (1): Geography location of case study

۲-۲- مواد مورد استفاده

در این مطالعه برای شناسایی تغییرات دوره ۳۰ ساله و تخمین مساحت جنگل‌های مانگرو از تصاویر چند طیفی بازتاب سطحی^۱ سری لندست^۲ در سال‌های ۱۹۸۶، ۲۰۰۰ و ۲۰۲۰ در گوگل ارث انجین استفاده شد. تغییرات شرایط آب و هوایی سالانه در منطقه مطالعاتی طوری است که منجر به فرورفتن جنگل‌ها و سایر اراضی منطقه

1- Surface Reflectance

2- Landsat

به زیر آب می‌شود بنابراین به‌منظور پوشش چنین مشکلی و ایجاد تصویری فاقد ابر برای هر سال به‌طور مجزا میانگین تصاویر فصلی (بهار، تابستان، پاییز و زمستان) محاسبه و انتخاب گردید. اطلاعات مربوط به تصاویر لندست استفاده شده در جدول ۱ آورده شده است.

جدول (۱): مشخصات داده‌های ماهواره‌ای

Table (1): Satellite data specifications

ماهواره/سنجنده	آی-دی	بازه زمانی	باندها	قدرت تفکیک مکانی
Landsat-5/TM	LANDSAT/LT05/C01/T1_SR	۱۹۸۶/۴/۱-۱۹۸۶/۱/۱	۳ و ۴	۳۰ متر
		۱۹۸۶/۷/۱-۱۹۸۶/۴/۱		
		۱۹۸۶/۱۰/۱-۱۹۸۶/۷/۱		
		۱۹۸۷/۱/۱-۱۹۸۶/۱۰/۱		
		۲۰۰۰/۴/۱-۲۰۰۰/۱/۱		
		۲۰۰۰/۷/۱-۲۰۰۰/۴/۱		
		۲۰۰۰/۱۰/۱-۲۰۰۰/۷/۱		
		۲۰۰۱/۱/۱-۲۰۰۰/۱۰/۱		
Landsat-8/OLI	LANDSAT/LC08/C01/T1_SR	۲۰۲۰/۴/۱-۲۰۲۰/۱/۱	۵ و ۴	
		۲۰۲۰/۷/۱-۲۰۲۰/۴/۱		
		۲۰۲۰/۱۰/۱-۲۰۲۰/۷/۱		
		۲۰۲۱/۱/۱-۱۹۸۶/۱۰/۱		

Google Earth Engine

۳-۲- روش کار

در منطقه مطالعاتی فقط پوشش گیاهی از نوع مانگرو وجود دارد، به‌منظور شناسایی، شناسایی تغییرات و تفکیک هر چه بهتر پوشش مانگرو از سایر اراضی از شاخص تفاضلی نرمال شده پوشش گیاهی^۱ استفاده گردید. بدین منظور بروی تمامی تصاویر (۱۲ تصویر لندست) این شاخص اعمال شد. شاخص تفاضلی نرمال شده پوشش گیاهی یک شاخص سنجش‌ازدوری پرکاربرد و متداول است (Viana et al, 2019).

در مطالعات پیشین به‌صورت ویژه از شاخص نرمال شده پوشش گیاهی (Adi et al. 2016; Bihamta et al. 2019; Bihamta et al. 2020). برای توزیع، شناسایی تغییرات جنگل‌های مانگرو استفاده شده است. مقادیر این شاخص از معادله زیر محاسبه می‌شود (رابطه ۱):

1- Normalized difference vegetation index (NDVI)

$$NDVI = \frac{NIR - Red}{NIR + RED} \quad [1]$$

که: منظور از NIR^۱ باند مادون قرمز نزدیک در لندست ۵ (B4) و لندست ۸ (B5)، Red: باند قرمز در لندست ۵ (B3) و لندست ۸ (B4)، است.

سپس در گام بعدی تمامی شاخص‌های تفاضلی نرمال شده پوشش گیاهی فصلی مربوط به سال‌های مورد مطالعه به صورت مجزا در یک دیتاست انباشت و ترکیب شدند تا در فرایند بعدی مورد پردازش قرار گیرند.

۲-۴- انتخاب نمونه آموزشی و طبقه‌بندی

طبقه‌بندی نظارت‌شده بر اساس دانش موجود از نواحی تصویر مورد مطالعه صورت می‌گیرد. در این روش‌ها ابتدا لازم است مقادیری (کلاس‌های پوشش اراضی) توسط کاربر وارد الگوریتم شوند. به‌طور کلی این روش‌ها بر اساس الگوریتم‌های آماری یا شبکه‌عصبی کار می‌کنند (Mather, 2011). ماشین بردار پشتیبان یکی از الگوریتم‌های یادگیری ماشین است که می‌تواند در سامانه گوگل ارث انجین استفاده شود. این الگوریتم یک الگوریتم یادگیری آماری غیرپارامتری نظارت‌شده است و می‌تواند برای طبقه‌بندی یا رگرسیون استفاده شود. الگوریتم یادگیری ماشین بردار پشتیبان می‌تواند با استفاده از شناسایی بازتاب پیکسل، برای طبقه‌بندی حرا و غیر حرا استفاده شود (Mahendra et al., 2019). طبقه‌بندی با الگوریتم ماشین بردار پشتیبان نیازمند تعداد کافی نمونه آموزشی با پراکنش مناسب در کلاس‌های مختلف اراضی است. بدین منظور به صورت مجزا برای هر سال مطالعاتی تعداد ۱۵۵ نمونه مانگرو، ۱۲۱ نمونه گل‌ولای و اراضی جذر و مدی و ۱۱۰ نمونه برای کلاس آب جمع‌آوری گردید. نمونه‌های مانگرو دارای بیشترین نمونه است چون تمرکز این مطالعه بروی جنگل‌های مانگرو است. در نهایت این نمونه‌ها در ورودی الگوریتم یاد شده جهت طبقه‌بندی تصاویر تفاضلی نرمال شده پوشش گیاهی سالانه قرار گرفتند. شکل زیر موقعیت نمونه‌های برداشت‌شده برای هر کلاس در سال ۱۹۸۶ در گوگل ارث انجین را نشان می‌دهد.

۲-۵- ارزیابی دقت و شناسایی تغییرات

در این مطالعه به منظور اعتبارسنجی نقشه‌های پوشش اراضی ۱۹۸۶، ۲۰۰۰ و ۲۰۲۰ از روی تصاویر کیفیت بالای گوگل ارث مجموع تعداد ۵۰ نمونه نقطه‌ای برای کلاس‌ها برداشت گردید سپس با استفاده از ماتریس ابهام که شامل پارامترهای آماری دقت کلی^۲، ضریب کاپا^۳ است، نقشه‌ها ارزیابی شدند. دقت کلی و ضریب کاپا از معادلات زیر محاسبه می‌شوند (Jansen, 2015). در آخر برای تخمین درصد کاهش و افزایش پوشش‌های اراضی

1- Near Inferred
2- Overall accuracy

3- kappa

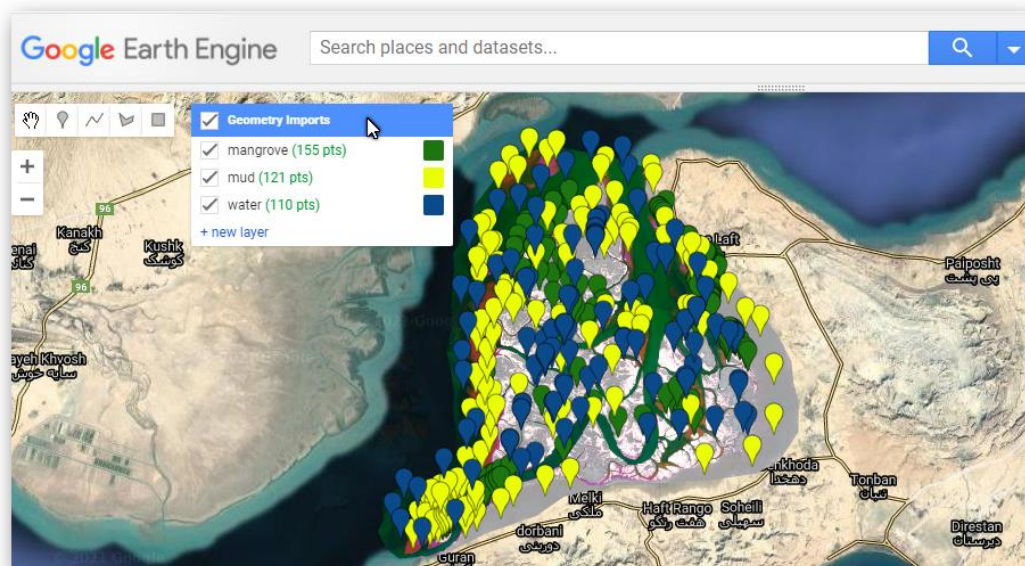
خصوصاً مانگرو نقشه‌های طبقه‌بندی شده ۱۹۸۵، ۲۰۰۰ از نقشه ۲۰۲۰ کسر یا کم گردید تا میزان تغییرات برآورد گردد (رابطه ۲).

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad [2]$$

که در آن k ضریب کاپا، x_{ii} تعداد مشاهدات در ردیف i و ستون i است، و x_{i+} و x_{+j} مجموع‌های حاشیه‌ای برای ردیف i و ستون j هستند. به ترتیب، و N تعداد کل نمونه‌ها است (رابطه ۳).

$$OA = \frac{1}{N} \sum P_{ii} \quad [3]$$

در جایی که OA دقت کل مدل را تعریف می‌کند، پیکسل‌های آزمایشی با N توصیف می‌شوند و p_{ii} نشان‌دهنده تعداد کل پیکسل‌های طبقه‌بندی شده صحیح است (شکل ۲).



شکل (۲): موقعیت پراکنش نمونه‌های آموزشی در گوگل ارث انجین

Figure (2): Location of distribution of training samples in Google Earth Engine

۳- بحث و نتایج

در جدول ۲، ۳ و ۴ به ترتیب نتایج ماتریس ابهام نقشه‌های پوشش اراضی ۱۹۸۶، ۲۰۰۰ و ۲۰۲۰ آورده شده

است. همان‌طور که در جداول پیداست دقت کاربر کلاس مانگرو در هر ۳ سال مطالعاتی بیش از ۹۳/۳۳ درصد است که نشان از دقت بالای استخراج کلاس پوشش مانگرو از سایر اراضی را دارد. دقت کلی نقشه‌ها به ترتیب در سال‌های مطالعه شده برابر با ۹۷/۷۷، ۹۷/۱۱ و ۹۳/۳۳ درصد است. همچنین ضریب کاپای نقشه‌ها به ترتیب برابر با ۰/۹۶، ۰/۸۶ و ۰/۹۰ است. به‌طور کلی نتایج دقت کلی و ضریب کاپا بیانگر دقت بالای نقشه‌های تهیه‌شده است که می‌توان از آن برای شناسایی تغییرات کلاس مانگرو استفاده کرد (جدول ۲ تا ۴).

جدول (۲): نتایج پارامترهای ماتریس ابهام نقشه پوشش اراضی ۱۹۸۶

Table (2): Results of the Error matrix parameters of the 1986 land cover map

Land Cover 1986					
Classes	Mangrove	Mud and Tidal	Sea	User Accuracy	Producer Accuracy
Mangrove	100	0	0	100	100
Mud and Tidal	0	100	6.67	100	93.75
Sea	0	0	93.33	93.33	100
Overall Accuracy: 97.77					
Kappa Coefficient: 0.96					

جدول (۳): نتایج پارامترهای ماتریس ابهام نقشه پوشش اراضی ۲۰۰۰

Table (3): Results of Error matrix parameters of land cover map 2000

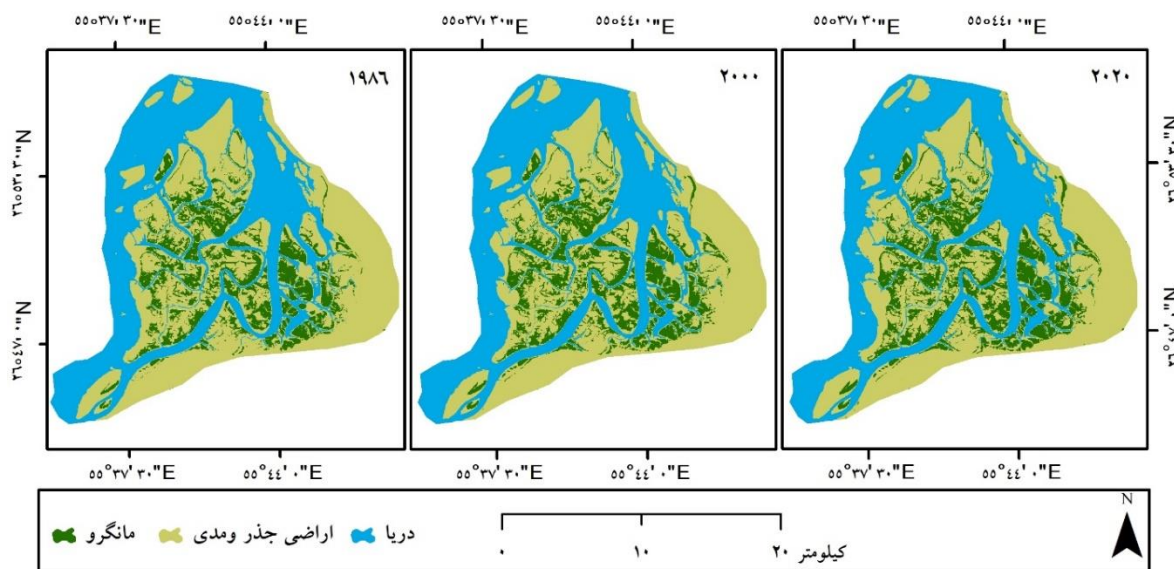
Land Cover 2000					
Classes	Mangrove	Mud and Tidal	Sea	User Accuracy	Producer Accuracy
Mangrove	93.33	0	6.67	93.33	93.33
Mud and Tidal	6.67	86.67	0	92.86	86.67
Sea	0	13.33	93.33	87.50	93.33
Overall Accuracy: 91.11					
Kappa Coefficient: 0.86					

جدول (۴): نتایج پارامترهای ماتریس ابهام نقشه پوشش اراضی ۲۰۲۰

Table (3): Results of Error matrix parameters of land cover map 2020

Land Cover 2020					
Classes	Mangrove	Mud and Tidal	Sea	User Accuracy	Producer Accuracy
Mangrove	93.33	6.67	0	93.33	93.33
Mud and Tidal	6.67	86.67	0	92.86	86.67
Sea	0	6.67	100	93.75	100
Overall Accuracy: 93.33					
Kappa Coefficient: 0.90					

شکل ۳، نقشه‌های تهیه شده ۱۹۸۶، ۲۰۰۰ و ۲۰۲۰ با استفاده از الگوریتم طبقه‌بندی SVM را نشان می‌دهد.



شکل (۳): نقشه پوشش اراضی به تفکیک سال


Figure (3): Figure 3. Land cover map to separate each year

در جدول ۵، مساحت پوشش اراضی سال‌های ۱۹۸۶، ۲۰۰۰ و ۲۰۲۰ و همچنین میزان نرخ تغییرات دوره ۳۰ ساله پوشش مانگرو آورده شده است. طبق این جدول جنگل‌های مانگرو در سال ۱۹۸۶ از میزان ۵۱۳۰/۷۸ هکتار به میزان ۵۴۷۱/۸۷ هکتار در سال ۲۰۰۰ رسیده است که نشان‌گر نرخ افزایش وسعت مانگرو در حدود ۶/۲۳ درصدی شده است. در سال ۲۰۲۰ میزان مساحت مانگرو حدود ۵۹۶۷/۱۳ هکتار رسیده است که نسبت به مساحت پوشش مانگرو در سال ۲۰۰۰ حدود ۸/۳۰ درصد افزایش مساحت داشته است. به‌طور کلی نرخ مساحت تغییرات اراضی مانگرو طی دوره ۳۰ ساله یعنی از ۱۹۸۶ تا ۲۰۲۰ حدود ۱۴/۰۲ درصد افزایش داشته است. شکل ۴، نقشه سری زمانی تغییرات جنگل‌های مانگرو قشم طی دوره ۳۰ ساله را نشان می‌دهد.

جدول (۵): مساحت و نرخ تغییرات پوشش اراضی از ۱۹۸۶ تا ۲۰۲۰

Table (5): Area and rate of land cover changes from 1986 to 2020

Categories	Extent (ha)			Change (%)		
	1986	2000	2020	1986-2000	2000-2020	1986-2020
Classes						
Mangrove	5130.78	5471.87	5967.13	6.23	8.30	14.02
Mud and Tidal	17019.0	16971.7	16334.5	-0.28	-3.90	-4.19
sea	14079.6	13785.6	13927.3	-2.13	1.02	-1.09



شکل (۴): نقشه سری زمانی تغییرات ۳۰ ساله جنگل‌های مانگرو

Figure (4): Time series map of 30-year changes in mangrove forests

هدف از این پژوهش بررسی تغییرات ۳۰ ساله منطقه حفاظت‌شده جنگل‌های مانگرو جزیره قشم بود. بدین منظور داده‌های ۳۰ ساله سری ماهواره‌ی لندست در محیط ابری گوگل ارث انجین مورد پردازش قرار گرفتند. نتایج این پژوهش نشان داد که میزان مساحت جنگل‌های مانگرو در سال ۱۹۸۶ که ۵۱۳۰/۷۸ بوده است به

میزان ۶/۲۳ درصد در سال ۲۰۰۰ یعنی حدود ۵۴۷۱/۸۷ هکتار رسیده است. طبق پژوهش جعفرنیا و همکاران (۱۳۹۰)، مساحت جنگل‌های مانگرو منطقه خورخوران در سال ۱۹۸۸ از ۵۱۶۰/۵۲ هکتار به میزان ۵۳۰۸/۳۲ هکتار در سال ۱۹۹۸ رسیده است که نتایج این محققین بر پژوهش کنونی تأیید دارد. جنگل‌های مانگرو در سال ۱۹۸۶ به میزان ۵۱۳۰/۷۸ هکتار بوده است که این میزان در سال ۲۰۲۰ به ۵۹۶۷/۱۳ هکتار رسیده است در واقع جنگل‌های مانگرو این منطقه طی سال‌های ۱۹۸۶ تا ۲۰۲۰ روند تغییرپذیری رو به افزایش به میزان ۱۴/۱۴،۰۲ درصد داشته است که به تبع این افزایش میزان تغییرپذیری بیشتر در کرانه شرقی و همچنین پایینی منطقه مطالعاتی مشاهده شده است. نتایج پژوهش Bihamtatosi و همکاران (۲۰۲۰) با استفاده از اعمال الگوریتم طبقه‌بندی SVM بروی تصاویر لندست در منطقه خورخوران نشان داد که نرخ تغییرات جنگل‌های مانگرو از سال ۱۹۹۸ تا ۲۰۱۷ میزان ۱۳،۸ درصد افزایش داشته است که بازهم پژوهش این محققین نشانگر افزایش جنگل‌های مانگرو در بخش شرقی و جنوبی منطقه مطالعاتی دارد که در واقع همخوانی مناسبی با نرخ فزونی در منطقه مطالعاتی پژوهش کنونی دارد. در پژوهشی Mahandera و همکاران (۲۰۱۹) با استفاده از پردازش داده‌های ماهواره‌ای در ارث انجین به این پی بردند که پوشش جنگل‌های مانگرو از سال ۲۰۱۶ تا ۲۰۱۸ در ضلع جنوبی خلیج اندونزی افزایش یافته است که علل این فزونی را توسعه پرورشگاه‌های آبی در منطقه مطالعاتی دانسته‌اند. طبق ادعای خورانی و همکاران (۱۳۹۵)، افزایش جنگل‌های مانگرو در منطقه کنونی و منطقه حفاظت‌شده خورخوران نتیجه جنگل‌کاری مصنوعی و دست کاشت توسط بومیان این منطقه بوده است که با یافته پژوهشگران در اندونزی مغایرت دارد.

۴- نتیجه‌گیری

به‌طور کلی افزایش سطح پوششی مانگرو در جزیره قشم تابع عوامل متعددی نظیر بالا آمدن سطح اساسی دریاها، آزاد، تغییر خواص شیمیایی آب‌های ورودی به این منطقه از تنگه هرمز، ورود آب‌های شور رودخانه مهران و همچنین شرایط حاصلخیزی رسوبات و از همه مهم‌تر عملکرد گنبدهای نمکی در منطقه مطالعاتی هست. آنچه بیش‌ازپیش نظارت بر تغییرات جنگل‌های مانگرو را در جهان میسر ساخته استفاده از داده‌های ماهواره‌ای قدمت بالای لندست است. امروزه این حجم عظیم از داده‌های رایگان ماهواره‌ای بدون دریافت داده‌ی ماهواره‌ای حجیم و همچنین دارا بودن سخت‌افزار قدرتمند در فضای ابری گوگل ارث انجین قابل دسترسی و پردازش است، چراکه این پلتفرم محاسباتی قدرتمند دارای الگوریتم‌های طبقه‌بندی و ماژول‌های پردازشی قدرتمند است. در آخر پیشنهاد می‌شود از این سامانه نوین به‌منظور آشکارسازی تغییرات کاربری اراضی در ابعاد مقیاس متفاوت استفاده شود.

۵-منابع

- Adi, W., & Sari, S. P. (2016). Detection of mangrove distribution in Pongok Island. *Procedia Environmental Sciences*, 33, 253-257.
- Alatorre, L. C., Sánchez-Andrés, R., Cirujano, S., Beguería, S., & Sánchez-Carrillo, S. (2011). Identification of mangrove areas by remote sensing: The ROC curve technique applied to the northwestern Mexico coastal zone using Landsat imagery. *Remote Sensing*, 3(8), 1568-1583.
- Bihamta, N., Soffianian, A. R., Fakheran, S., & Pourmanafi, S. (2019). Incorporating CART algorithm and i for mapping Mangrove using Landsat 8 imagery. *Journal of Forest Research and Development*, 5(4), 557-569.
- Bihamta Toosi, N., Soffianian, A. R., Fakheran, S., Pourmanafi, S., Ginzler, C., & T Waser, L. (2020). Land Cover Classification in Mangrove Ecosystems Based on VHR Satellite Data and Machine Learning—An Upscaling Approach. *Remote Sensing*, 12(17), 2684.
- Brown, M.I., Pearce, T., Leon, J., Sidle, R., & Wilson, R. (2018). Using remote sensing and traditional ecological knowledge (TEK) to understand mangrove change on the Maroochy River, Queensland, Australia. *Applied Geography*, 94, 71-83.
- Chen, B., Xiao, X., Li, X., Pan, L., Doughty, R., Ma, J., . . . Wu, Z. (2017). A mangrove forest map of China in 2015: Analysis of time series Landsat 7/8 and Sentinel-1A imagery in Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 104-120.
- Chen, P., Liew, S. C., Lim, R., & Kwoh, L. K. (2011). *Mapping coastal ecosystems of an offshore landfill island using WorldView-2 high resolution satellite imagery*. Paper presented at the Proceedings of the 34th International Symposium on Remote Sensing of Environment, Sydney, Australia.
- Dan, T., Chen, C., Chiang, S., & Ogawa, S. (2016). MAPPING AND CHANGE ANALYSIS IN MANGROVE FOREST BY USING LANDSAT IMAGERY. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 3(8).
- Jafarnia, S., Oladi, J., Hoojati, S., & Mir Akhor Loo, K. (2016). Status and change detection of Mangrove forest in Qeshm Island using satellite imagery from 1988 to 2008. *Journal of Environmental Science and Technology*, 18(1), 177-191. (In Persian)
- Jensen, J. R. (1986). *Introductory digital image processing: a remote sensing perspective*. Retrieved from
- Jhonnerie, R., Siregar, V. P., Nababan, B., Prasetyo, L. B., & Wouthuyzen, S. (2015). Random forest classification for mangrove land cover mapping using Landsat 5 TM and ALOS PALSAR imageries. *Procedia Environmental Sciences*, 24, 215-221.
- Jia, M., Zhang, Y., Wang, Z., Song, K., & Ren, C. (2014). Mapping the distribution of mangrove species in the Core Zone of Mai Po Marshes Nature Reserve, Hong Kong, using hyperspectral data and high-resolution data. *International Journal of Applied Earth Observation and Geoinformation*, 33, 226-231.

- Jones, T.G., Glass, L., Gandhi, S., Ravaoarinarotsihoarana, L., Carro, A., Benson, L., . . . Cripps, G. (2016). Madagascar's mangroves: Quantifying nation-wide and ecosystem specific dynamics, and detailed contemporary mapping of distinct ecosystems. *Remote Sensing*, 8(2), 106.
- Hoa, N. H. (2016). Using Landsat imagery and vegetation indices differencing to detect mangrove change: A case in Thai Thuy district, Thai Binh province. *J. For. Sci. Technol*, 5, 59-66.
- Gilman, E. L., Ellison, J., Duke, N. C., & Field, C. (2008). Threats to mangroves from climate change and adaptation options: a review. *Aquatic botany*, 89(2), 237-250.
- Giri, C., Long, J., Abbas, S., Murali, R. M., Qamer, F. M., Pengra, B., & Thau, D. (2015). Distribution and dynamics of mangrove forests of South Asia. *Journal of environmental management*, 148, 101-111.
- Giri, C., Pengra, B., Zhu, Z., Singh, A., & Tieszen, L. L. (2007). Monitoring mangrove forest dynamics of the Sundarbans in Bangladesh and India using multi-temporal satellite data from 1973 to 2000. *Estuarine, coastal and shelf science*, 73(1-2), 91-100.
- Kanniah, K. D., Sheikhi, A., Cracknell, A. P., Goh, H. C., Tan, K. P., Ho, C. S., & Rasli, F. N. (2015). Satellite images for monitoring mangrove cover changes in a fast growing economic region in southern Peninsular Malaysia. *Remote Sensing*, 7(11), 14360-14385.
- Khoorani, A., Biniiaz, M., & Amiri, H. R. (2015). Investigating the changes of mangrove forests between Khamir port and Gheshmiseland and its correlation with climatic elements. *Journal of Aquatic Ecology*, 5(2), 100-111. (In Persian)
- Kuenzer, C., Bluemel, A., Gebhardt, S., Quoc, T. V., & Dech, S. (2011). Remote sensing of mangrove ecosystems: A review. *Remote Sensing*, 3(5), 878-928.
- Mafi Gholami, D., Baharlouii, M., & Mahmoudi, B. (2018). Erosion and accretion monitoring in mangrove forests using remote sensing and Digital Shoreline Analysis System (DSAS)(Case study: Hara Biosphere reserve). *Journal of Environmental Studies*, 43(4), 633-646. doi:10.22059/jes.2018.225288.1007381 (In Persian)
- Mahendra, W., Jamaluddin, I., & Kamal, M. (2019). Mangroves Change Detection using Support Vector Machine Algorithm on Google Earth Engine (A Case Study in Part of Gulf of Bone, South Sulawesi, Indonesia). *The 40th Asian Conference on Remote Sensing*, 1-8.
- Mather, P. M., & Koch, M. (2011). *Computer processing of remotely-sensed images: an introduction*: John Wiley & Sons.
- Toosi, N. B., Soffianian, A. R., Fakheran, S., Pourmanafi, S., Ginzler, C., & Waser, L. T. (2019). Comparing different classification algorithms for monitoring mangrove cover changes in southern Iran. *Global Ecology and Conservation*, 19, e00662.
- Mehrabian, A., Naqinezhad, A., Mahiny, A. S., Mostafavi, H., Liaghathi, H., & Kouchekezadeh, M. (2009). Vegetation mapping of the Mond protected area of Bushehr province (south-west Iran). *Journal of integrative plant biology*, 51(3), 251-260.

- Midekisa, A., Holl, F., Savory, D. J., Andrade-Pacheco, R., Gething, P. W., Bennett, A., & Sturrock, H. J. (2017). Mapping land cover change over continental Africa using Landsat and Google Earth Engine cloud computing. *PloS one*, 12(9), e0184926.
- Olagoke, A., Proisy, C., Féret, J.-B., Blanchard, E., Fromard, F., Mehlig, U., . . . Berger, U. (2016). Extended biomass allometric equations for large mangrove trees from terrestrial LiDAR data. *Trees*, 30(3), 935-947.
- Pham, L. T., & Brabyn, L. (2017). Monitoring mangrove biomass change in Vietnam using SPOT images and an object-based approach combined with machine learning algorithms. *ISPRS Journal of Photogrammetry and Remote Sensing*, 128, 86-97.
- Pimple, U., Simonetti, D., Sitthi, A., Pungkul, S., Leadprathom, K., Skupek, H., . . . Towprayoon, S. (2018). Google earth engine based three decadal landsat imagery analysis for mapping of mangrove forests and its surroundings in the trat province of Thailand.
- Shi, T., Liu, J., Hu, Z., Liu, H., Wang, J., & Wu, G. (2016). New spectral metrics for mangrove forest identification. *Remote Sensing Letters*, 7(9), 885-894.
- Son, N.-T., Chen, C.-F., Chang, N.-B., Chen, C.-R., Chang, L.-Y., & Thanh, B.-X. (2014). Mangrove mapping and change detection in Ca Mau Peninsula, Vietnam, using Landsat data and object-based image analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(2), 503-510.
- Toosi, N. B., Soffianian, A. R., Fakheran, S., Pourmanafi, S., Ginzler, C., & Waser, L. T. (2019). Comparing different classification algorithms for monitoring mangrove cover changes in southern Iran. *Global Ecology and Conservation*, 19, e00662.
- Viana, C. M., Oliveira, S., Oliveira, S. C., & Rocha, J. (2019). Land use/land cover change detection and urban sprawl analysis *Spatial modeling in GIS and R for earth and environmental sciences* (pp. 621-651): Elsevier.
- Wang, L., Silván-Cárdenas, J. L., & Sousa, W. P. (2008). Neural network classification of mangrove species from multi-seasonal Ikonos imagery. *Photogrammetric Engineering & Remote Sensing*, 74(7), 921-927.
- Wang, T., Zhang, H., Lin, H., & Fang, C. (2016). Textural-spectral feature-based species classification of mangroves in Mai Po Nature Reserve from Worldview-3 imagery. *Remote Sensing*, 8(1), 24.
- Zhang, C., Kovacs, J. M., Liu, Y., Flores-Verdugo, F., & Flores-de-Santiago, F. (2014). Separating mangrove species and conditions using laboratory hyperspectral data: A case study of a degraded mangrove forest of the Mexican Pacific. *Remote Sensing*, 6(12), 11673-11688.
- Zhang, H., Wang, T., Liu, M., Jia, M., Lin, H., Chu, L., & Devlin, A. T. (2018). Potential of combining optical and dual polarimetric SAR data for improving mangrove species discrimination using rotation forest. *Remote Sensing*, 10(3), 467.