

کلیدواژه‌ها: آب‌های سطحی، سنجش از راه دور، طبقه‌بندی
نظارت شده، رای‌گیری حداکثری

مقدمه

وابستگی جوامع امروزی و اکوسیستم به محیط‌زیست باعث شده که در چند سال اخیر تغییرات محیط‌زیست از اهمیت بالایی برخوردار باشند [۳، ۷، ۳۲ و ۳۵]. در این میان، آب‌های سطحی (آب‌های جاری سطح زمین از قبیل باتلاق‌ها، دریاچه‌ها، و رودخانه‌ها) را می‌توان به‌عنوان یکی از مهم‌ترین و اساسی‌ترین نیازهای جامعه بشری عنوان کرد، به‌طوری‌که هر نوع تغییر در پارامترهای کمی و کیفی آن سبب ایجاد خسارات جبران ناپذیری می‌شود [۱۸].

سنجش از دور در شناسایی عوارض زمین و هم‌چنین تهیه مجموعه داده‌هایی از سطح زمین، نقش مهمی ایفا می‌کند [۱]. دو دهه اخیر به‌منظور شناسایی و پایش منابع آبی همچون شناسایی دریاچه‌ها، پیش‌بینی سیل و ارزیابی کیفیت منابع آب، نظارت بر تغییرات ساحل و فرسایش آن، ماهواره‌های سنجش از دور مورد استفاده قرار گرفته‌اند [۲۶].

همان‌طور که پیشتر بررسی شد، رویکردهای متفاوتی جهت استفاده از ماهواره‌ها در شناسایی آب‌های سطحی توسط محققین مورد استفاده قرار گرفته است. در این زمینه با بکارگیری شاخص‌های آب از قبیل شاخص تفاوت نرمال‌شده آب^۴ و شاخص بهبودیافته نرمال‌شده آب^۵ بر روی داده‌های ماهواره لندست-۸، به بررسی تاثیر گسترش شهرک سازی در مناطق ساحلی پرداخته شده است [۲، ۴]. اخیراً به جهت مزایای رادارهای دیافراگم مصنوعی^۶ در تهیه تصویر با شرایط آب و هوایی نامساعد، برای شناسایی و پایش آب‌های سطحی و سیلاب بسیار مورد استفاده قرار گرفته‌اند. در روشی دیگر با استفاده از داده‌های ماهواره راداری سنتینل-۱ و پیاده‌سازی سه رویکرد آستانه‌گذاری امواج بازتاب شده از سطح زمین، طبقه‌بندی کننده جنگل تصادفی^۷ و ماشین بولتزمن محدود^۸ به استخراج نقشه زمین‌های متأثر از سیلاب پرداخته شد. با مقایسه نتایج حاصل از رویکردهای پیشنهادی، طبقه‌بندی کننده جنگل تصادفی (RF) نسبت به دیگر طبقه‌بندی کننده‌ها از دقت بالاتری در شناسایی آب‌های

شناسایی آب‌های سطحی با استفاده از ادغام داده‌های ماهواره‌ای نوری و راداری

مصطفی تقفی^۱، احمد احمدی^۲ و بهناز بیگدلی^۳

تاریخ دریافت: ۱۴۰۰/۰۱/۱۵ تاریخ پذیرش: ۱۴۰۰/۰۷/۰۵

چکیده

شناسایی و پایش آب‌های سطحی با استفاده از سنجش از دور بدلیل اهمیت در تامین نیازهای بشر و هم‌چنین تصمیم‌گیری‌های سیاسی در دهه‌های اخیر بسیار مورد توجه و استفاده قرار گرفته است. از همین‌رو، در این مطالعه با استفاده از سیستم‌های سنجش از دور و با بکارگیری ماهواره‌های راداری سنتینل-۱ و نوری سنتینل-۲ به مطالعه بر روی آب‌های سطحی پرداخته شده است. در این مقاله دو رویکرد ادغام داده‌ها و سپس ادغام تصمیم‌گیری‌ها به‌منظور بهبود دقت شناسایی آب‌های سطحی برای دو منطقه پیشنهادی در استان مازندران بدلیل وجود جنگل‌های انبوه، رودخانه‌های گل‌آلود، و زمین‌های کشاورزی، پیشنهاد شده‌اند. رویکرد ادغام داده‌ها با افزایش توان تفکیک مکانی ماهواره نوری سنتینل-۲ از ۲۰ متر به ۱۰ متر و استفاده از داده‌های راداری و شاخص‌های آب در یک لایه، پایش آب‌های سطحی با دقت مناسبی توسط ابزار طبقه‌بندی نظارت‌شده‌ای همچون ماشین بردار پشتیبان، شبکه عصبی، و جنگل تصادفی صورت پذیرفت. در ادامه با تلفیق نتایج و با استفاده از روش رای‌گیری حداکثری، دقت نتیجه خروجی نسبت به رویکرد ادغام داده‌ها ۴ الی ۵ درصد افزایش پیدا کرد. از آنجایی‌که رودخانه‌های کم‌عرض و گل‌آلود به‌راحتی قابل شناسایی و استخراج نیستند، رویکرد پیشنهادی می‌تواند نقشه دقیقی از آب‌های سطحی را استخراج کند.

- ۱- کارشناس ارشد آب و سازه‌های هیدرولیکی، گروه آب، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، ایران.
- ۲- دانشیار مهندسی آب و سازه‌های هیدرولیکی، گروه آب، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، ایران.
- ۳- نویسنده مسئول و استادیار نقشه‌برداری و سنجش از دور، گروه نقشه‌برداری و فتوگرامتری، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، ایران. پست الکترونیک: bigdeli@shahroodut.ac.ir


4. Normalized Difference Water Index (NDWI)

5. Modified Normalized Difference Water Index (MNDWI)

6. Synthetic Aperture RADAR (SAR)

7. Random Forest (RF)

8. Restricted Boltzmann Machines (RBM)



شکل ۱- تلفیق سنجنش از راه دور پیشنهادی به منظور استخراج آب های سطحی

Fig 1. Proposed remote sensing fusion for surface water extraction

استفاده از فرایند پن شارپ کردن، دقت مکانی آن از ۲۰ متر به ۱۰ متر ارتقا پیدا می کند و سپس پنج شاخص پرکاربرد آب با استفاده از این تصاویر استخراج می گردند. در ادامه باندهای بکار رفته در شاخص ها به همراه خود شاخص های آب و باند VH^2 و VV سنیتل-۱ به منظور استخراج آب سطحی در یک لایه قرار می گیرند. در ادامه به جهت استخراج آب از غیر آب از سه طبقه بندی کننده ماشین بردار پشتیبان، شبکه عصبی و جنگل تصادفی در محیط نرم افزار ENVI استفاده شده است. در این مرحله خروجی بدست آمده شامل سه تصویر می باشد که در هر تصویر حجم مشخصی از آب های سطحی استخراج شده است. به همین منظور، در مرحله دوم رویکرد ادغام تصمیم گیری بکار می آید تا سه نتیجه بدست آمده از طبقه بندی کننده های نظارت شده مرحله اول با یکدیگر تلفیق شده تا یک تصویر خروجی بدست آید. در این مرحله، رای گیری حداکثری با استفاده از برنامه نویسی در نرم افزار MATLAB، تصاویر را با یکدیگر ادغام می کند و نتیجه شامل یک تصویر با دقت نسبت به رویکرد ادغام داده ها می باشد.

جدول ۱- مشخصات ماهواره های سنیتل-۱ و سنیتل-۲

Table 1. Information of Sentinel-2 and Sentinel-1

ماهواره Satellite	دقت Resolution	تاریخ Date
سنیتل-۱ Sentinel-1	10 m	04-06-2019
سنیتل-۲ Sentinel-2	20 m	03-06-2019

3. Vertical Horizontal

سطحی، برخوردار می باشد [۵ و ۶].

در تحقیقات یک دهه اخیر، رویکرد استخراج آب های سطحی به سمت ادغام داده های دو تا چند ماهواره بسیار مورد توجه قرار گرفته است [۱۲، ۲۱، ۳۴ و ۳۷].

در این مطالعه سعی شده با ادغام و ترکیب داده های نوری و راداری با یکدیگر، استخراج آب های سطحی با دقت مناسبی صورت پذیرد. از همین رو، به منظور استخراج آب های سطحی، دو رویکرد ادغام داده^۱ و ادغام تصمیم گیری^۲ مورد استفاده قرار گرفته است. برای استخراج آب های سطحی از مجموعه داده های شامل سنیتل-۲ و سنیتل-۱، و شاخص های آب که در یک لایه با یکدیگر ترکیب شده اند، استفاده شده است. علاوه بر این به جهت افزایش دقت نهایی، نتایج بدست آمده از رویکرد ادغام داده ها توسط رویکرد ادغام تصمیم گیری با یکدیگر تلفیق می گردند [۳۸ و ۳۹].

مواد و روش ها

در این مقاله به معرفی رویکرد ادغام داده های سنجنش از راه دور براساس تلفیق و ترکیب داده های راداری و چندطیفی به منظور استخراج آب های سطحی پرداخته شده است. براساس شکل (۱) که به طور کلی ساختار روش پیشنهادی را نمایش می دهد، ترکیب دو مدل از ماهواره های سنجنش از راه دور به منظور بدست آوردن اطلاعات با دقت بیشتر در شناسایی آب های سطحی، صورت پذیرفته است.

بر اساس شکل (۱)، در مرحله ادغام داده ها، ابتدا ماهواره سنیتل-۲ با

1. Data Fusion
2. Decision Fusion

رفته در این روش می باشد [۱۹].

$$MNDWI = (Green - SWIR) / (Green + SWIR) \quad (۳)$$

• AWEI

شاخص استخراج خودکار آب^۲ (AWEI) در سال ۲۰۱۴ توسط فیسا و همکاران معرفی گردید. اساس این شاخص ایجاد تفاوت بین باندهای طیفی است. شاخص AWEI_{sh} قادرست تا در شرایط پیچیده همچون وجود سایه، آب های سطحی را با دقت قابل قبولی متمایز کند [۱۴].

• AWEI_{sh}^۲ این شاخص برای مناطقی که سایه موجود در تصاویر بدلیل اختلاف ارتفاع منطقه مانع از شناسایی آب های سطحی می شود مورد استفاده قرار می گیرد.

$$AWEI_{sh} = Blue + 2.5 * Green - 1.5 * (NIR - SWIR1) - 0.25 * SWIR2 \quad (۴)$$

• AWEI_{nsh}^۴ برای مناطقی که سایه از اهمیت کمتری برخوردار می باشد مورد استفاده قرار می گیرد.

$$AWEI_{nsh} = 4 * (Blue - NIR) - (0.25 * Red + 2.75 * SWIR2) \quad (۵)$$

• WI₂₀₁₅

فیشر و همکاران در سال ۲۰۱۵ با معرفی شاخص آب^۵ (WI₂₀₁₅) با استفاده از تصاویر بازتابی از سطح زمین بجای تصاویر بالای اتمسفر^۶ توانستند شناسایی آب از غیرآب را بهبود بخشند رابطه (۶) نشان دهنده روش کار این شاخص می باشد [۱۵].

$$WI_{2015} = 1.7204 + 171 * Green + 3 * Red - 70 * NIR - 45 * SWIR1 - 71 * SWIR2 \quad (۶)$$

طبقه بندی کننده ها

بعد از جمع آوری مجموعه داده های راداری سنتینل-۱، تصاویر ۱۰ متری سنتینل-۲ و شاخص های آب در یک لایه، نوبت به استخراج آب های سطحی از غیرآب می رسد. مرحله ادغام داده ها توسط سه طبقه بندی کننده نظارت شده صورت می گیرد. سه طبقه بندی کننده بکار رفته در مرحله ادغام داده ها به ترتیب ماشین بردار پشتیبان (SVM)، شبکه عصبی (NN)، و جنگل تصادفی (RF) می باشند.

• ماشین بردار پشتیبان (SVM)

اساس طبقه بندی کننده SVM طبقه بندی خطی داده ها است، به طوری که خط انتخاب شده برای تقسیم داده ها از حاشیه اطمینان بالایی برخوردار باشد و داده ها را به دو یا چند کلاس متفاوت با حاشیه اطمینان مناسب تقسیم کند.

$$f(x) = \sum_{i=1}^L a_i y_i k(x_i, x_j) + Y \quad (۷)$$

مطابق رابطه (۷)، a_i بیانگر متغیرهای ضریب لاگرانژ و y_i برای انتقال ابر صفحه با استفاده از مقادیر آستانه و عملکرد هسته بکار می رود که به صورت $k(x_i, x_j)$ تعریف شده است. محققین بی شماری

سنتینل-۲ دارای ۱۳ باند نوری با توان تفکیک مکانی ۲۰ متر و ۱۰ متر می باشد [۶، ۱۷، ۲۸، ۳۱ و ۳۳]. در ادامه، ماهواره راداری سنتینل-۱ از دو باند قطبی VV و VH به طور جداگانه تشکیل شده. در جدول (۱) به بررسی توان تفکیک مکانی و زمان برداشت تصویر از زمین برای ماهواره های نوری سنتینل-۲ و ماهواره راداری سنتینل-۱ پرداخته شده است.

پن شارپ

به منظور استخراج پدیده های سطح زمین از تصاویر ماهواره ها، علاوه بر اطلاعات طیفی به اطلاعات مکانی با جزییات بالا نیز احتیاج است.

در بین شیوه های پن شارپ الگوریتم متوسط محلی و انطباق واریانس (LMVM)^۱ با ادغام تصاویر پنکروماتیک در دیگر باندها در کنار حفظ کیفیت اطلاعات طیفی، سبب افزایش توان کیفیت مکانی باندها می شود. رابطه (۱) به تشریح الگوریتم استفاده شده در این رویکرد می پردازد [۲۵ و ۳۶].

$$F(c, l) = \frac{(DN_{H(c,l)} - \mu_{H(c,l)})(\sigma_{L(c,l)} + \mu_{L(c,l)})}{\sigma_{H(c,l)}} \quad (۱)$$

در رابطه (۱) $F(c, l)$ مقدار تصویر ادغام شده را در مختصات (c, l) نشان می دهد. همچنین $DN_{H(c, l)}$ مقدار تصویر با دقت تفکیک مکانی بالا را در مختصات (c, l) نشان می دهد. $\mu_{H(c, l)}$ بیانگر مقدار متوسط محلی تصویر با دقت تفکیک مکانی بالا در مرکز مختصات (c, l) می باشد. $\mu_{L(c, l)}$ بیانگر مقدار متوسط محلی تصویر با دقت تفکیک مکانی پایین در مرکز مختصات (c, l) می باشد. $\sigma_{H(c, l)}$ نشان دهنده میانگین محلی تصویر با دقت تفکیک مکانی بالا متمرکز بر مختصات (c, l) است. $\sigma_{L(c, l)}$ مقدار انحراف محلی استاندارد تصویر با دقت تفکیک مکانی پایین متمرکز بر مختصات (c, l) را نشان می دهد.

شاخص های آب

شاخص های آب به عنوان روشی پرکاربرد در ایجاد تمایز بین آب و غیرآب با استفاده از روابط جبری بر روی باندهای ماهواره های نوری مورد استفاده قرار می گیرد. تعدادی از مهم ترین شاخص های بکار رفته در این تحقیق به شرح زیر می باشد.

• NDWI

شاخص تفاوت نرمال شده آب (NDWI) در سال ۱۹۹۶ توسط مک فیتز به منظور ایجاد تمایز بین آب از دیگر عوارض، معرفی شد [۲۴].

$$NDWI = (Green - NIR) / (Green + NIR) \quad (۲)$$

• MNDWI

شاخص اصلاح شده تفاوت نرمال شده آب (MNDWI) در سال ۲۰۰۵ توسط هنگو به منظور کاهش خطا در شناسایی آب های سطحی مورد استفاده قرار گرفت. این شاخص از دقت بالاتری نسبت به (NDWI) برخوردار می باشد. رابطه (۳) نشان دهنده باندهای بکار

1. Local Mean and Variance Matching

2. Automated Water Extraction Index (AWEI)
3. Automated Water Extraction Index_shadow
4. Automated Water Extraction Index_no shadow
5. Water Index (WI₂₀₁₅)
6. Top of Atmospheric (TOA)

[۱۰ و ۳۰] جزییات بیش‌تری در مورد SVM را بررسی کرده‌اند. در این تحقیق از هسته تابع برپایه شعاعی^۱ برای طبقه‌بندی کننده SVM استفاده شده است [۲۰].

$$k(x, x') = \exp(-\lambda \|x - x'\|^2) \quad (۸)$$

بردار ویژگی با x و x' نشان داده شده است. K و λ به ترتیب تابع هسته و متغیرهای هسته می‌باشند. برای مقداردهی به متغیرهای مورد استفاده در این روش تحقیقات گسترده‌ای صورت پذیرفت و سپس اعداد بهینه جایگذاری شد.

• شبکه عصبی (NN)

شبکه عصبی (NN) یک سیستم محاسباتی یادگیری ماشین، نمایش دانش و در نهایت کسب دانش کاربردی برای حداکثر رساندن پاسخ خروجی سیستم‌های پیچیده است. یکی از متداول‌ترین روش‌های حل مسئله بهینه‌سازی، شبکه‌های عصبی پس‌انتشار است [۱۸ و ۲۷].

$$a_c = \sum w_{pc} \times b_{pc} \quad (۹)$$

در معادله (۹)، a_c جمع ضرب ورودی‌ها بر اساس وزن آن‌ها است، w_{pc} وزن این ورودی است و b_{pc} حاوی مقدار نورون‌های c است که از نورون‌های p ورودی می‌گیرد. اگر داده‌ها با نشان $(x_1, y_1), \dots, (x_n, y_n)$ داده شده باشند و تابع هزینه با d هدف دستیابی به عملکرد زیر است:

$$Q(w) = \sum_{i=1}^n l(h_w(x_i), y_i) \quad (۱۰)$$

جایی که x مقدار ورودی، y مقدار خروجی و $h_w(x)$ خروجی شبکه عصبی است.

• جنگل تصادفی (RF)

جنگل تصادفی (RF) به‌طور گسترده‌ای برای طبقه‌بندی و رگرسیون داده‌ها کار می‌کند. جنگل‌های تصادفی برای درختان تصمیم‌گیری که بیش از حد در مجموعه آموزش قرار دارند مناسب است. برای آموزش درختان از تکنیک کلی تجمیع کیسه‌گذاری استفاده می‌شود. مجموعه داده‌ها با $D = (x_1, y_1), \dots, (x_n, y_n)$ نشان داده می‌شوند، کیسه‌بندی منظم (B بار) یک نمونه تصادفی را با جایگزینی مجموعه آموزش انتخاب می‌کند و درختان را متناسب با این نمونه‌ها آموزش می‌دهد. مدل نهایی با میانگین‌گیری یا رأی دادن بین درختان کار می‌کند. در مسئله رگرسیون، مدل نهایی میانگین همه درختان است:

$$f^* = \frac{1}{B} \sum_{b=1}^B f_b(x') \quad (۱۱)$$

در مسئله طبقه‌بندی، پاسخ نهایی با رأی دادن بین درختان بدست می‌آید. روش بالا الگوریتم اصلی کیسه‌گذاری برای درختان را توصیف می‌کند [۸]. تابع فرق‌گذاری در معادله (۱۲) نشان داده شده است:

$$H(x) = \arg \max_y \sum_{i=1}^k I(h_i(x, \theta_k) = y) \quad (۱۲)$$

بدین صورت $(\theta_k): h(x, \theta_k)$ نمودار تصادفی و X به‌عنوان نمودار ورودی نشان داده شده است. I مقدار تابع شاخص، h و Y به ترتیب به‌عنوان درخت تصمیم‌گیری و متغیر خروجی مشخص مشخص شده‌اند. $\arg \max_y$ مقدار Y را هنگامی که تابع $\sum_{i=1}^k I(h_i(x, \theta_k) = y)$ به‌مقدار حداکثر خود رسیده باشد بیان می‌کند [۸ و ۹].

ادغام تصمیم‌گیری

ادغام تصمیم‌گیری، تصمیمات مختلف از روش‌ها یا داده‌های مختلف را باهم تلفیق یا ادغام می‌کند تا سرانجام در مقایسه با نتیجه یک تصمیم فردی، تصمیم دقیق‌تر و قابل اعتمادتری اتخاذ شود. یکی از مهم‌ترین و پرکاربردترین روش‌ها در تلفیق تصمیم‌گیری، روشی مبتنی بر مفهوم رأی‌گیری است که در آن هر نتیجه به‌عنوان یک رأی در نظر گرفته می‌شود [۲۲]. ساده‌ترین شکل این روش رأی‌گیری حداکثری است. در این روش، اگر تمام نتایج از وزن و دقت یکسانی برخوردار باشند، نتیجه همه طبقه‌بندی‌کننده‌ها با یکدیگر تلفیق شده و تصمیم با بالاترین رأی به‌عنوان کلاس برنده معرفی می‌شود (معادله ۱۴).

$$\sum_{i=1}^L d_{i,k} = \max_{j=1}^L d_{i,j} \quad (۱۳)$$


در معادله (۱۳)، d_i به‌ازای $i = 1, \dots, m$ (که در آن m تعداد مجموعه روش‌های تصمیم‌گیری است)، هم‌چنین مقدار d_i می‌تواند ۰ یا ۱ باشد [۲۹].

منطقه مطالعاتی


به‌منظور بررسی و استخراج آب‌های سطحی در استان مازندران دو منطقه انتخاب و مورد مطالعه قرار گرفت. استان مازندران با وسعتی به‌مساحت ۲۳۸۳۳ کیلومتر مربع که در موقعیت جغرافیایی ۳۶/۵۶۵۶ درجه شمالی و ۵۳/۰۵۸۸ درجه شرقی واقع شده و حدود ۱/۵ درصد از مساحت کشور ایران را تشکیل می‌دهد. منطقه مطالعاتی اول در این مطالعه محدوده سد گلوارد و منطقه مطالعاتی دوم محدوده شهر نکا از توابع استان مازندران می‌باشد، که به‌دلیل وجود شرایط پیچیده محیطی هم‌چون وجود جنگل‌های انبوه و متنوع، رودخانه‌های کوچک و گل‌آلود، باتلاق و زمین‌های کشاورزی و مسکونی متعدد مورد مطالعه قرار گرفته‌اند.

اولین منطقه مطالعاتی سد گلوارد در شکل (۲) با مساحتی معادل ۴۲۰ کیلومتر مربع بدلیل وجود جنس خاک متفاوت و رودخانه‌های کوچکی که به سد وارد می‌شوند انتخاب گردیده است.


منطقه مورد مطالعه دوم، شهر نکا در شکل (۳) از توابع استان مازندران به‌مساحت ۴۲۰ کیلومتر مربع انتخاب شده است. این منطقه مطالعاتی به‌دلیل تنوع در پوشش گیاهی، مسکونی و خاک از پیچیده‌ترین شرایط مطالعاتی برخوردار می‌باشد. هم‌چنین بدلیل عبور رودخانه نکارود از مرکز شهر و سابقه سیلابی شدن آن اهمیت



شکل ۳- موقعیت جغرافیایی دومین منطقه جغرافیایی (شهر نکا)
(a) مازندران، ایران، (b) تصویر رنگی ماهواره سنتینل-۲، (c) نقاط آموزش طبقه‌بندی کننده‌ها، (d) تصویر ماهواره سنتینل-۱
Fig 3. The second study area (Neka), (a) Mazandaran Province, Iran, (b) RGB visible of the Sentinel-2, (c) Train point for classifier, (d) Sentinel-1 image



شکل ۲- موقعیت جغرافیایی اولین منطقه جغرافیایی (سد گلوارد)
(a) مازندران، ایران، (b) تصویر رنگی ماهواره سنتینل-۲، (d) نقاط آموزش طبقه‌بندی کننده‌ها، (c) تصویر ماهواره سنتینل-۱
Fig 2. The first study area (Gelevard Dam), (a) Mazandaran Province, Iran, (b) RGB visible of Sentinel-2, (c) Train point for classifier, (d) Sentinel-1 image



شکل ۴- نتایج خروجی یادگیری ماشینی منطقه مطالعاتی اول. (a) طبقه‌بندی کننده ماشین بردار پشتیبان (SVM)، (b) طبقه‌بندی کننده شبکه‌های عصبی (NN)، (c) طبقه‌بندی کننده جنگل تصادفی (RF)، (d) رای گیری حداکثری (MV)
Fig 4. Results of the machine learning method for the first study area. (a) Support Vector Machine (SVM), (b) Neural Network (NN), (c) Random Forest (RF), (d) Majority Voting (MV)

این منطقه مطالعاتی دوچندان می‌کند.

بر اساس رویکرد ادغام داده‌ها، به جهت استفاده از طبقه‌بندی کننده‌های نظارت شده ۵۳۳۴۷ پیکسل به عنوان نقاط آموزش برای منطقه مطالعاتی اول (سد گلوارد) و ۴۰۱۳۸ پیکسل دیگر نیز برای آموزش منطقه مطالعاتی دوم مشخص گردید.

نتایج


با استفاده از دو رویکرد ادغام داده‌ها و ادغام تصمیم‌گیری، آب‌های سطحی با دقت بسیار بالایی از دیگر عوارض سطح زمین متمایز شده‌اند. رویکرد ادغام داده‌ها شامل تصاویر تلفیق شده ۱۰ متری سنتینل-۲، شاخص‌های آب به همراه داده‌های راداری VV و VH، در یک لایه می‌باشند و توسط طبقه‌بندی کننده‌های نظارت شده ماشین بردار پشتیبان (SVM)، شبکه عصبی (NN)، و جنگل تصادفی (RF) طبقه‌بندی می‌شوند. در رویکرد دوم تصاویر خروجی طبقه‌بندی شده با استفاده از شیوه رای‌گیری حداکثری در یک تصویر ادغام شده‌اند. از آنجایی که یادگیری ماشینی از دقت بسیار بالایی برخوردار است، سه طبقه‌بندی کننده پرکاربرد، ماشین بردار پشتیبان (SVM)، شبکه عصبی (NN)، و جنگل تصادفی (RF) به طبقه‌بندی آب‌های سطحی می‌پردازند. نتیجه خروجی برای دو منطقه مطالعاتی نشان داد در شرایط محیطی پیچیده و دشوار، آب‌های سطحی با دقت قابل قبولی استخراج شده‌اند که در شکل (۴) و شکل (۵) بیان شده‌اند.

میان روش‌های دیگر برخوردار بوده است. در ادامه با استفاده از روش رای‌گیری حداکثری و ادغام نتایج، دقت کلی و ضریب کاپا به‌طور چشم‌گیری افزایش یافت.

همان‌گونه که در جدول (۲) نشان داده شده است، با استفاده از رویکرد رای‌گیری حداکثر دقت کلی نتایج خروجی نسبت به روش جنگل تصادفی، ۳/۱۱ درصد بهبود پیدا کرده است. رای‌گیری حداکثری با دقت کلی ۹۸/۳۱ درصد و ضریب کاپا ۰/۹۷۱۱ برای منطقه اول نشان داد که ادغام داده‌های خروجی به‌روش ادغام تصمیم‌گیری باعث بهبود در شناسایی آب‌های سطحی می‌شود. همچنین برای منطقه مطالعاتی دوم رویکرد رای‌گیری حداکثری با دقت کلی ۹۹/۰۷ درصد و ضریب کاپا ۰/۹۸۲۰، نسبت به روش جنگل تصادفی از برتری ۲/۲۸ درصدی برخوردار بود. همان‌طور که انتظار می‌رفت به‌دلیل تلفیق پیکسل به پیکسل نتایج خروجی با وزندهی برابر، پیکسل‌هایی که بیش‌ترین تکرار را در بین هر سه خروجی داشتند به‌عنوان پیکسل صحیح انتخاب و نشان داده شده‌اند، به‌همین علت نتایج تلفیق داده‌های خروجی آب‌های سطحی شناسایی شده، دقت بالاتری نسبت به نتایج حاصل از طبقه‌بندی کننده‌ها را دارا می‌باشد. در رویکرد اول (ادغام داده‌ها) با ترکیب همه پارامترهای موجود از قبیل شاخص‌ها، باندهای نوری، داده‌های راداری و قرار دادن آن‌ها در یک لایه، به طبقه‌بندی آن‌ها پرداخته و نتایج آن در جدول (۲) نشان داده شد.

بحث و نتیجه‌گیری

در این تحقیق سعی شد تا با استفاده از دو رویکرد ادغام داده‌ها و ادغام تصمیم‌گیری به شناسایی آب‌های سطحی بپردازیم. روش اول که توسط سه طبقه‌بندی کننده نظارت‌شده ماشین بردار پشتیبان (SVM)، شبکه عصبی (NN)، و جنگل تصادفی (RF) صورت پذیرفت، سه تصویر به‌عنوان نتایج خروجی بدست آمد. سپس با رویکرد ادغام تصمیم‌گیری، هر سه تصویر به‌شیوه رای‌گیری حداکثری با یکدیگر تلفیق شده و آب‌های سطحی در تصویر نهایی با دقت بالایی از غیرآب شناسایی شده است. استفاده از رویکرد تلفیق نتایج خروجی با یکدیگر به کمک شیوه رای‌گیری حداکثری توانست در عین سادگی، دقت کلی و ضریب کاپا را نسبت به بهترین



شکل ۵- نتایج خروجی یادگیری ماشینی منطقه مطالعاتی دوم. (a) طبقه‌بندی کننده ماشین بردار پشتیبان (SVM)، (b) طبقه‌بندی کننده شبکه‌های عصبی (NN)، (c) طبقه‌بندی کننده جنگل تصادفی (RF)، (d) رای‌گیری حداکثری (MV)

Fig 5. Results of the machine learning method for the second study area. (a) Support Vector Machine (SVM), (b) Neural Network (NN), (c) Random Forest (RF), (d) Majority Voting (MV)

با استفاده از رویکرد ادغام تصمیم‌گیری و تلفیق هر سه نتیجه از طبقه‌بندی کننده‌ها با روش رای‌گیری حداکثری، تصویری منحصربه‌فرد با دقت بسیار بالا بدست آمد که حجم آب شناسایی شده با استفاده از این شیوه بسیار دقیق‌تر و از خطای کم‌تری نسب به رویکرد ادغام داده‌ها برخوردار می‌باشد. نتایج خروجی حاصل از دو رویکرد پیشنهادی برای هر دو منطقه مطالعاتی در شکل (۴) و شکل (۵) قابل مشاهده می‌باشد.

نتایج روش‌های پیشنهادی در جدول (۲) نشان می‌دهد که هر سه طبقه‌بندی کننده ماشین بردار پشتیبان (SVM)، شبکه عصبی (NN)، و جنگل تصادفی (RF) از دقت مناسبی برخوردار هستند، همچنین در بین هر سه طبقه‌بندی کننده، طبقه‌بندی کننده جنگل تصادفی به‌دلیل بهره‌مندی از رای‌گیری در تصمیم، از دقت بالاتری

جدول ۲- نتایج رویکردهای ادغام داده و ادغام تصمیم‌گیری
Table 2. The results of Data Fusion and Decision Fusion

طبقه‌بندی کننده		SVM	NN	RF	MV
منطقه مطالعاتی اول	دقت کلی (OA)	98.31%	95.21%	89.8%	91.38%
Study Area 1	ضریب کاپا (K)	0.9711	0.908	0.800	0.824
(Gelvard Dam)					
منطقه مطالعاتی دوم	دقت کلی (OA)	99.07%	96.79%	90.7%	93.14%
Study Area 2	ضریب کاپا (K)	0.9820	0.920	0.801	0.8259
(Neka city)					

Sanli, FB. Faculty, E. and Faculty, CE. 2018. EXPLOITING MULTI-TEMPORAL SENTINEL-1 SAR DATA FOR FLOOD EXTEND MAPPING. XLII(March):18-21.

7. Bond, NR. Lake, PS. and Arthington, AH. 2008. The impacts of drought on freshwater ecosystems: An Australian perspective. *Hydrobiologia*.

8. Breiman, L. 2001. Random forests. *Machine learning*. Springer 45(1):5-32.

9. Breiman, L. Friedman, J. Stone, CJ. and Olshen, RA. 1984. *Classification and Regression Trees*. Taylor & Francis. Available at: <https://books.google.com/books?id=JwQx-WOmSyQC>.

10. Burges, CJC. 1998. A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*. Springer 2(2):121-167.

11. Chini, M. Pelich, R. Pulvirenti, L. Pierdicca, N. Hostache, R. and Matgen, P. 2019. Sentinel-1 InSAR Coherence to Detect Floodwater in Urban Areas : Houston and Hurricane Harvey as A Test Case. 1-20.

12. Clerici, N. Valbuena Calderón, CA. and Posada, JM. 2017. Fusion of Sentinel-1A and Sentinel-2A data for land cover mapping: a case study in the lower Magdalena region, Colombia. *Journal of Maps*. Taylor & Francis 13(2):718-726.

14. Feyisa, GL. Meilby, H. Fensholt, R. and Proud, SR. 2014. Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment*. Elsevier Inc. 140:23-35. Available at: <http://dx.doi.org/10.1016/j.rse.2013.08.029>.

15. Fisher, A. Flood, N. and Danaher, T. 2016. Comparing Landsat water index methods for automated water classification in eastern Australia. *Remote Sensing of Environment*. Elsevier 175:167-182.

16. Han-Qiu, XU. 2005. A study on information extraction of water body with the modified normalized difference water index (MNDWI). *Journal of remote sensing* 5:589-595.

17. Hostache, R. Chini, M. Giustarini, L. Neal, J. Kavetski, D. Wood, M. Corato, G. Pelich, R. and Matgen, P. 2018. Near-Real-Time Assimilation of SAR-Derived Flood Maps for Improving Flood Forecasts.

18. Huang, C. Chen, Y. Zhang, S. and Wu, J. 2018. Detecting, Extracting, and Monitoring Surface Water From Space Using Optical Sensors: A Review. *Reviews of Geophysics* 56(2):333-360.

19. Huang, G-B. Zhu, Q-Y. and Siew, C-K. 2006. Extreme learning machine: theory and applications. *Neurocomputing*. Elsevier 70(1-3):489-501.

طبقه‌کننده جنگل تصادفی (RF) به‌طور چشمگیری افزایش دهد.

اهمیت این تحقیق عبارت است از :

- افزایش توان تفکیک مکانی از ۲۰ متر به ۱۰ متر، در عین حفظ کیفیت داده‌های طیفی، کیفیت مکانی نیز افزایش پیدا کند.
- استفاده از شاخص‌های آب با متمایز کردن آب از غیرآب سبب بهبود در دقت نتایج طبقه‌بندی شدند.
- استفاده از یادگیری ماشینی در استخراج آب‌های سطحی و پیاده‌سازی آن بر روی مجموعه داده‌هایی شامل تصاویر نوری ۱۰ متری، شاخص‌های آب و داده‌های راداری.
- طبقه‌بندی کننده‌های نظارت‌شده همچون ماشین بردار پشتیبان (SVM)، شبکه عصبی (NN)، و جنگل تصادفی (RF) به‌واسطه رویکرد ادغام داده‌ها، به طبقه‌بندی آب‌های سطحی پرداختند.
- رویکرد ادغام تصمیم‌گیری با استفاده از شیوه رای‌گیری حداکثری سبب شد تا تصاویر خروجی هر سه طبقه‌بندی کننده با یکدیگر ادغام شده و نتیجه خروجی علاوه‌بر دقت کلی بالا، ضریب کاپای بهتری نیز در شناسایی آب‌های سطحی داشته باشند. همان‌طور که در نتایج جدول (۲) می‌توان دید، روش رای‌گیری حداکثری توانست علاوه‌بر افزایش دقت کلی، ضریب کاپا را نیز به‌مقدار چشم‌گیری افزایش دهد. رویکرد ادغام تصمیم‌گیری‌ها نسبت‌به نتایج طبقه‌بندی کننده‌ها در رویکرد ادغام داده، توانست آب‌های سطحی هر دو منطقه مطالعاتی را با دقت مناسبی شناسایی و استخراج کند.

منابع

1. Acharya, TD. Subedi, A. Huang, H. and Lee, DH. 2018. Classification of Surface Water Using Machine Learning Methods from Landsat Data in Nepal. *Proceedings* 4(1):43.
2. Acharya, TD. Subedi, A. and Lee, DH. 2018. Evaluation of water indices for surface water extraction in a landsat 8 scene of Nepal. *Sensors (Switzerland)* 18(8):1-15.
3. Alderman, K. Turner, LR. and Tong, S. 2012. Floods and human health: A systematic review. *Environment International*. Elsevier Ltd, 37-47.
4. Ali, MI. Dirawan, GD. Hasim, AH. and Abidin, MR. 2019. Detection of changes in surface water bodies urban area with NDWI and MNDWI methods. *International Journal on Advanced Science, Engineering and Information Technology* 9(3):946-951.
5. Amitrano, D. Martino, G. Di, Member. S. Iodice. A. Member. S, Riccio D. and Ruello, G. 2018. Unsupervised Rapid Flood Mapping Using. *IEEE Transactions on Geoscience and Remote Sensing*. IEEE 56(6):3290-3299.
6. Bayik, C. Abdikan, S. Ozbulak, G. Alasag, T. Aydemir, S.

32. Sun, F. Sun, W. Chen, J. and Gong, P. 2012. Comparison and improvement of methods for identifying waterbodies in remotely sensed imagery. *International Journal of Remote Sensing*, 6854–6875. Available at: https://www.researchgate.net/publication/254314334_Comparison_and_improvement_of_methods_for_identifying_waterbodies_in_remotely_sensed_imagery.
33. Twele, A. Cao, W. Plank, S. and Martinis, S. 2016. Sentinel-1-based flood mapping: a fully automated processing chain. *International Journal of Remote Sensing*. Taylor & Francis 37(13):2990–3004.
34. Wang, Q. Blackburn, GA. Onojeghuo, AO. Dash, J. Zhou, L. Zhang, Y. and Atkinson, PM. 2017. Fusion of Landsat 8 OLI and Sentinel-2 MSI Data. *IEEE Transactions on Geoscience and Remote Sensing* 55(7):3885–3899.
35. Wang, Z. Liu, J. Li, J. and Zhang, DD. 2018. Multi-Spectral Water Index (MuWI): A Native 10-m Multi-Spectral Water Index for accurate water mapping on sentinel-2. *Remote Sensing* 10(10):1–21.
36. Yves, C. Stanislas, DB. Marc, B. Fabrice, M. and Gauthier, L. 2001. RS Data Fusion by Local Mean and Variance Matching Algorithms : their Respective Efficiency in a Complex Urban Context. (V):105–109.
37. Zoka, M. Psomiadis, E. and Dercas, N. 2018. The Complementary Use of Optical and SAR Data in Monitoring Flood Events and Their Effects †. 2:1–8
38. Bioresita, Filsa. 2019. Fusion of Sentinel-1 and Sentinel-2 Image Time Series for Permanent and Temporary Surface Water Mapping. *International Journal of Remote Sensing*, vol. 40, no, 23. pp. 9026–49.
39. Tavus, B. 2020. A Fusion Approach for Flood Mapping Using Sentinel-1 and Sentinel-2 Datasets. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol: 43. pp. 641–48.
20. Imbault, F. and Lebart, K. 2004. A stochastic optimization approach for parameter tuning of support vector machines. *Proceedings of the 17th International Conference on Pattern Recognition*, 2004. ICPR 2004. IEEE, 597–600.
21. Kaplan, G. and Avdan, U. 2018. SENTINEL-1 AND SENTINEL-2 DATA FUSION FOR WETLANDS MAPPING: BALIKDAMI, TURKEY. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences* 42(3).
22. Kuncheva, LI. Whitaker, CJ. Shipp, CA. and Duin, RPW. 2003. Limits on the majority vote accuracy in classifier fusion. *Pattern Analysis & Applications*. Springer 6(1):22–31.
23. Martinis, S. and Plank, S. 2018. The Use of Sentinel-1 Time-Series Data to Improve Flood Monitoring in Arid Areas. 1.
24. McFeeters, SK. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International journal of remote sensing*. Taylor & Francis 17(7):1425–1432.
25. Mhangara, P. Mapurisa, W. and Mudau, N. 2020. Comparison of Image Fusion Techniques Using Satellite Pour l’Observation de la Terre (SPOT) 6 Satellite Imagery. *Applied Sciences*. Multidisciplinary Digital Publishing Institute 10(5):1881.
26. Naik, BC. and Anuradha, B. 2018. Extraction of Water-body Area from High-resolution Landsat Imagery. *International Journal of Electrical and Computer Engineering (IJECE)* 8(6):4111.
27. Nielsen, MA. 2015. *Neural networks and deep learning*. Determination press San Francisco, CA.
28. Perrou, T. Garioud, A. and Parcharidis, I. 2018. Use of Sentinel-1 imagery for flood management in a reservoir-regulated river basin. *Frontiers of Earth Science*. Springer 12(3):506–520.
29. Ruta, D. and Gabrys, B. 2000. An overview of classifier fusion methods. *Computing and Information systems* 7(1):1–10.
30. Schölkopf, B. and Smola, A. 2005. Support vector machines and kernel algorithms. *Encyclopedia of Biostatistics*. Wiley, 5328–5335.
31. Steinhausen, MJ. Wagner, PD. Narasimhan, B. and Waske, B. 2018. Int J Appl Earth Obs Geoinformation Combining Sentinel-1 and Sentinel-2 data for improved land use and land cover mapping of monsoon regions. *Int J Appl Earth Obs Geoinformation*. Elsevier 73(August):595–604. Available at: <https://doi.org/10.1016/j.jag.2018.08.011>.

Detecting Surface Waters Using Data Fusion of Optical and Radar Remote Sensing Sensor

M. Saghafi¹, A. Ahmadi² and B. Bigdeli³

Received: 04-04-2021 Accepted: 27-09-2021

Abstract

Identification and monitoring of surface water using remote sensing have become very important in recent decades due to its importance in human needs and political decisions. Therefore, surface water has been studied using remote sensing systems and Sentinel-1 and Sentinel-2 sensors in this study. In this paper, two data fusion approaches and decision fusion improve the accuracy of surface water identification for the two study areas in Mazandaran province, Iran, due to dense forests, turbid rivers, and land Agricultural products have been proposed. Data fusion approach by increasing the spatial resolution of Sentinel-2 optical sensor from 20 meters to 10 meters and using radar dataset and water indices in one layer, monitoring surface water with much higher accuracy by classification using supervised classifiers such as Support Vector Machine (SVM), Neural Network (NN), and Random Forest (RF) were performed. Then, by combining the results using the Maximum Voting (MV) method, the accuracy of the results compared to the data fusion approach increased by 4 percent to 5 percent. Since narrow and confused rivers are not easily identifiable and extractable, the proposed approach was able to extract an accurate map of surface water.

Keywords: *Surface water, Remote sensing, Supervised classifier, Majority voting.*

-
1. M.Sc. of Water and Hydraulic Structure Engineering, Department of Water Engineering, Faculty of Civil Engineering, Shahrood University of Technology, Iran.
 2. Associate Professor of Water and Hydraulic Structure Engineering, Department of Water Engineering, Faculty of Civil Engineering, Shahrood University of Technology, Iran.
 3. Corresponding Author and Assistant Professor of Remote Sensing and Photogrammetry, Department of Remote Sensing and photogrammetry, Faculty of Civil Engineering, Shahrood University of Technology, Iran. E-mail: bigdeli@shahroodut.ac.ir