

استفاده از تصاویر سنجش از دور سنتینل ۲ برای بهبود تفکیک پذیری محصولات زراعی با بهره‌گیری از روش‌های هوش مصنوعی به منظور مدیریت بهره‌برداری آب از مخازن سدها

پویا احمدی^۱، حسین عارفی^۲، نازیلا کاردان^{۳*}

۱. دانشجوی کارشناسی ارشد گروه مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران

۲. دانشیار، گروه مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران

۳. استادیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه شهید مدنی آذربایجان، تبریز، ایران

(تاریخ دریافت ۱۳۹۹/۰۱/۲۲، تاریخ تصویب ۱۳۹۹/۰۳/۲۷)

چکیده

محدودیت منابع آبی همواره از موانع اصلی توسعه بخش کشاورزی به‌عنوان بستر اصلی نیل به خودکفایی مواد غذایی مطرح بوده است. یکی از کاربردهای مهم تصاویر سنجش از دور، در حوزه فعالیت‌های کشاورزی است. در تحقیق حاضر از تصاویر ماهواره سنتینل ۲ برای تفکیک محصولات کشاورزی در محدوده شهرستان ارومیه به‌صورت روش‌های مبتنی بر ورودی‌های چندزمانی استفاده شده است. به دلیل تغییرات طیفی محصولات طی دوره رشد، به‌کارگیری تصاویر چندزمانی مطابق با تقویم زراعی محصولات، نقش مهمی در تفکیک این محصولات ایفا می‌کند. در این طبقه‌بندی تمامی ورودی‌ها دارای تأثیر یکسان در طبقه‌بندی در نظر گرفته می‌شوند که این امر خلاف واقعیت است. بنابراین، به منظور افزایش دقت طبقه‌بندی و بهبود نتایج، به هر یک از ورودی‌های چندزمانی، وزن مناسبی باید اختصاص یابد که در پژوهش حاضر انتخاب وزن‌های بهینه برای تمام ورودی‌ها با بهره‌گیری از الگوریتم ژنتیک مورد توجه قرار گرفته است. بهینه کردن طبقه‌بندی تصاویر ماهواره‌ای به روش کمترین فاصله توسط الگوریتم ژنتیک به دو حالت انجام یافته است؛ در حالت نخست تأثیر تعداد نرون‌های لایه میانی و انتخاب پارامترهای بهینه برای شبکه عصبی و در حالت دوم، تأثیر ترتیب معرفی نمونه‌های آزمایشی بررسی شده است. در حالت نخست تعداد ۴ تا ۲۰ نرون برای لایه میانی و مقداری بین صفر و یک برای میزان آموزش و ضریب مومتوم انتخاب و ارزیابی شده و در حالت دوم ترتیب‌های مختلفی از معرفی نمونه‌های آموزشی ارزیابی شده‌اند. نتایج نشان داد بهینه شدن ترتیب معرفی نمونه‌های آموزشی، موجب افزایش ۴/۵ درصدی در دقت محاسبات شده است. بنابراین، ترتیب معرفی نمونه‌های آزمایشی در مقایسه با سایر پارامترها، بیشترین تأثیر را در همگرایی شبکه و حصول به نتایج بهینه داشته است. همچنین، مقایسه دو طبقه‌بندی استاندارد و بهینه‌شده، نشان داد مقدار کاپا از ۸۶ درصد در حالت استاندارد به مقدار ۹۰/۵ درصد در حالتی که ورودی‌ها به صورت بهینه وزندهی شده‌اند، افزایش یافته است.

کلیدواژگان: الگوریتم ژنتیک، بهینه‌سازی، تصاویر سنجش از دور، شبکه عصبی مصنوعی، طبقه‌بندی.

مقدمه

خشکسالی و کمبود آب یکی از عوامل مهم رشد و توسعه کشورهاست. ایران به دلیل کم بودن ریزش‌های جوی و نامناسب بودن پراکنش زمانی و مکانی این ریزش‌ها، در زمره کشورهای خشک و نیمه‌خشک جهان قرار دارد و از طرف دیگر، به دلیل رشد جمعیت، گسترش شهرنشینی و توسعه بخش‌های اقتصادی، روز به روز با افزایش تقاضای آب مواجه است [۱]. با توجه به سهم زیاد مصرف آب در بخش کشاورزی، لزوم بهینه‌سازی الگوی کشت و بیشترین بهره‌برداری از زمین‌های قابل کشت، برای بهینه کردن مصرف آب و مدیریت بهره‌برداری از مخازن سدها، امری اجتناب‌ناپذیر است. یکی از کاربردهای مهم تصاویر سنجنش از دوری در حوزه فعالیت‌های کشاورزی است. در این زمینه، مطالعه روی سطوح زیر کشت، تخمین میزان محصول، شناسایی استرس‌های گیاهی، پیش‌بینی و مدیریت بحران کشاورزی و در نتیجه، تخمین کلی میزان مصرف آب و مدیریت بهره‌برداری از مخازن سدها برای مصارف کشاورزی از جمله مهم‌ترین موارد و موضوعات تحقیقاتی است. شناسایی و تفکیک محصولات کشاورزی اعم از زراعی و باغی و در نتیجه، طبقه‌بندی آنها بر اساس میزان مصرف آب به‌عنوان یکی از فعالیت‌های پایه‌ای این حوزه مطرح است [۲ و ۳]. این امر به‌عنوان مقدمه اصلی در تخمین سطح زیر کشت و میزان قابل برداشت محصولات است که به‌عنوان اطلاعات اصلی مورد نیاز در مدیریت منابع کشاورزی و منابع آبی مطرح می‌شود.

از جمله تحقیقات صورت‌گرفته در زمینه بهره‌گیری از داده‌های طیفی چندزمانی برای تفکیک محصولات کشاورزی می‌توان به مقالات موراکی و همکاران (۲۰۰۱)، کوگان و همکاران (۲۰۰۳)، و روچا و همکاران (۲۰۱۷) اشاره کرد [۴-۶]. در این تحقیقات با استفاده از منحنی طیفی-زمانی محصولات کشاورزی، ابتدا از روش‌های سنتی بهره‌گرفته شده و سپس، بر اساس دقت طبقه‌بندی، میزان تفکیک‌پذیری بین محصولات زراعی مشخص شده است. از مزایای این روش، امکان بهره‌گیری از اطلاعات ناشی از تغییرات رفتارهای گیاهی طی دوره رشد خود است که در تفکیک‌پذیری محصولات زراعی بسیار مؤثر است.

در پژوهش سولبرگ و همکاران (۱۹۹۴) یکی دیگر از روش‌های شناسایی و تفکیک محصولات کشاورزی که در

ده‌های اخیر مطرح شده است و اهمیت دارد، استفاده از تصاویر نوری و راداری به‌طور هم‌زمان است. تلفیق این دو داده سبب افزایش دقت نتایج به‌طور درخور توجهی می‌شود، زیرا از هر دو ویژگی بیولوژیکی و فیزیکی گیاهان استفاده می‌کند [۷]. چن و همکاران (۱۹۹۶) از تصاویر مایکروویو چندفرکانسی و چند پلاریزاسیون برای شناسایی و تفکیک محصولات استفاده کردند. بر این اساس، میزان Backscatter HH برای گیاهانی که به‌صورت قائم رشد می‌کنند همواره بیشتر از Backscatter VV است، ولی در مورد گیاهانی که برگ‌های آنها به‌صورت افقی روی سطح زمین کشیده شده‌اند، Backscatter VV بیشتر از Backscatter HH است. بنابراین، همواره ترکیب پلاریزاسیون‌ها سبب افزایش دقت طبقه‌بندی می‌شود. اگر تصاویر پلاریمتریک باشند یعنی علاوه بر اندازه‌گیری انواع پلاریزاسیون فاز را نیز اندازه‌گیری کنند، می‌توان از اختلاف فاز بین پلاریزاسیون‌ها نیز استفاده کرد. با این‌وجود، امکان تهیه این نوع تصاویر از مناطق مختلف دشوار است. از طرفی، تصاویر رادار اغتشاش‌های بیشتری نسبت به تصاویر نوری دارند [۸]. پانگری و همکاران (۱۹۹۷) نشان دادند شناسایی و تفکیک محصولات کشاورزی بر پایه بهره‌گیری تصاویر چندزمانی مایکروویو استوار است؛ به‌خصوص در مناطقی که امکان استفاده از تصاویر نوری به دلیل شرایط ابری میسر نباشد. این موضوع برای محصول برنج که در مناطق مرطوب و گرمسیر پرورش می‌یابد، بیشتر اتفاق می‌افتد [۹]. گورو و همکاران (۱۹۹۹) شناسایی و تفکیک محصولات کشاورزی مبتنی بر استفاده از شاخص پوشش سطح برگ (LAI) را انجام دادند. ابتدا برای تصویر، شاخص گیاهی NDVI محاسبه شد. سپس، از طریق روابط تجربی برای هر محصول LAI را از روی شاخص گیاهی NDVI به دست آورده و براساس میزان LAI محاسبه‌شده و LAI اندازه‌گیری‌شده از مشاهدات زمینی برای هر محصول و با استفاده از آنالیز رگرسیون یک مدل برازش داده شد. در نهایت، براساس مدل برازش‌شده برای هر محصول، اقدام به شناسایی و تفکیک آن محصول شد [۱۰].

براساس پژوهش اپارکیو و همکاران (۲۰۰۲) یکی از شاخص‌های معروف و پرکاربرد در مسائل شناسایی محصولات کشاورزی، شاخص گیاهی NDVI است. در این

احتمال، ۴ درصد میزان دقت را افزایش می‌دهد [۱۸]. غزالی و همکاران (۲۰۱۵) در مطالعه‌ای به علت توسعه کشاورزی و افزایش تقاضا و رقابت بر سر منابع آب، به بررسی و ارائه سناریوی برتر برای تخصیص آب در حوضه زاینده‌رود پرداختند. آنها برای رتبه‌بندی سناریوهای تخصیص، از چهار تکنیک کارآمد تصمیم‌گیری چندشاخصه AHP, III-ELECTRE, Topsis و CP استفاده کردند [۱۹]. خدادادی و همکاران (۲۰۱۸) عملکرد شبکه آبیاری زینه‌رود را مطالعه کردند. در این بررسی، الگوی توزیع آب در شرایط کشت موجود با استفاده از الگوریتم PSO بهینه‌سازی شده و شاخص عدالت توزیع ۶۰ درصد ارتقا یافت [۲۰]. هیو و همکاران (۲۰۱۹) برای بررسی تخریب منطقه‌ای جنگلی در ایالات متحده در بازه زمانی ۲۰۰۳-۲۰۱۱ از داده‌های ماهواره لندست و روش طبقه‌بندی شی‌گرا استفاده کردند [۲۱].

جمع‌بندی مطالعات انجام‌شده نشان می‌دهد تا کنون پژوهش‌های جامعی در خصوص افزایش دقت طبقه‌بندی محصولات زراعی انجام نیافته است. از این‌رو، با توجه به اهمیت این طبقه‌بندی در تخصیص منابع آب، در پژوهش حاضر سعی شده است با استفاده از تصاویر ماهواره سنتینل ۲، محصولات زراعی در محدوده شهرستان ارومیه به‌صورت روش‌های مبتنی بر ورودی‌های چندزمانی تفکیک یابند. به دلیل تغییرات طیفی محصولات طی دوره رشد، به‌کارگیری تصاویر چندزمانی که بر تقویم زراعی محصولات نیز منطبق باشد، کارکرد زیادی در تفکیک این محصولات دارد. همچنین، به منظور اعمال تأثیر ورودی‌های مختلف، بهینه‌یابی وزن‌های ورودی‌های مختلف با استفاده از الگوریتم ژنتیک انجام یافته است.

مواد و روش‌ها

منطقه مطالعه‌شده

منطقه مطالعه‌شده در تحقیق حاضر، شهرستان ارومیه از شهرهای استان آذربایجان غربی واقع در شمال غربی ایران است که از نظر جغرافیایی در طول و عرض جغرافیایی ۳۳° ۳۷' شمالی و ۴۳° ۴۵' ۰۴' شرقی واقع شده است. این منطقه با مساحت ۳۷,۰۵۹ کیلومتر مربع متوسط بارندگی ۳۵۰ میلی‌متر در سال و مستقر در ارتفاع ۱۳۴۶ متر دارد، که از نظر جغرافیایی جزء مناطق سردسیر به‌شمار می‌رود.

تحقیقات شاخص گیاهی NDVI برای هر مقطع زمانی استخراج شد. سپس، بیشترین مقدار NDVI از بین تمامی مقاطع زمان برای هر پیکسل مشخص شده و همراه با داده‌های طیفی چندزمانی وارد طبقه‌بندی شدند [۱۱]. طبق مطالعات ورهی و ولف (۲۰۰۲) هرگاه تصاویر استفاده‌شده برای شناسایی و تفکیک محصولات کشاورزی دارای قدرت تفکیک مکانی کمی باشند، پدیده تداخل در هر پیکسل رخ می‌دهد. بنابراین، داخل هر پیکسل بیش از یک عارضه وجود خواهد داشت و برای شناسایی و تفکیک هر محصول، باید ابتدا درصد هر محصول در هر پیکسل محاسبه شود [۱۲]. استفاده از شاخص‌های گیاهی به همراه داده‌های طیفی چندزمانی در پژوهش ونگ و تنهون (۲۰۰۴) از دیگر راهکارهای معرفی‌شده برای بهره‌گیری از منابع داده چندزمانی است. با این‌وجود، به دلیل مشابه بودن اغلب شاخص‌های گیاهی، امکان به‌کارگیری چندین شاخص گیاهی به‌طور هم‌زمان میسر نیست. بنابراین، به‌کارگیری این شاخص‌ها با محدودیت‌هایی مواجه است [۱۳]. مک‌نارین و باریسکو (۲۰۰۴) از تصاویر INSAR و از مؤلفه Coherence در بهبود نتایج طبقه‌بندی استفاده کردند که میزان Coherence با ارتفاع گیاهان رابطه خطی معکوس دارد و بر افزایش تفکیک‌پذیری محصولات مؤثر است [۱۴]. تورکر و آریکان (۲۰۰۵) تفکیک محصولات کشاورزی را بر اساس تصاویر چندزمانی به روش ماسکینگ انجام دادند [۱۵]. در پژوهش وربین و همکاران (۲۰۰۸) دو روش برای تشخیص درصد هر محصول در هر پیکسل بیان شده است. روش اول آنالیز خطی اختلاط طیفی و روش دوم استفاده از شبکه‌های عصبی است [۱۶].

گیپل و همکاران (۲۰۱۴) با تلفیق شاخص‌های پوشش گیاهی مختلف و مدل سه‌بعدی سطح محصول، روشی را برای پیش‌بینی محصول ذرت بررسی کردند. با استفاده از رگرسیون خطی ارتفاع میانگین طبقه‌بندی‌نشده، ارتفاع میانگین طبقه محصول و ترکیب ارتفاع میانگین طبقه محصول با پوشش محصول مطابق با آن، از کارایی ترکیب اطلاعات مکانی و طیفی بر مبنای شاخص‌ها و اطلاعات ارتفاع بهره‌جسته‌اند [۱۷]. فنگ و همکاران (۲۰۱۵) به‌منظور بررسی پوشش گیاهی در منطقه شهری، از روش Random Forest و آنالیز بافت استفاده کردند. آنها به این نتیجه رسیدند این روش نسبت به روش سنتی حداکثر

تصاویر برگرفته از ماهواره سنتینل ۲

در پژوهش حاضر از تصاویر ماهواره سنتینل ۲ استفاده شده است. جدول ۲ مشخصات کلی این سنجنده را نشان می‌دهد. تصاویر حاصل از این سنجنده برای مطالعات روی زمین‌های کشاورزی یکپارچه بسیار مناسب است. از جمله مزایای این سنجنده می‌توان به رایگان بودن تصاویر و قدرت تفکیک مکانی مناسب (۱۰ متر) باندهای ماهواره برای تشخیص محصولات کشاورزی اشاره کرد. با توجه به اینکه شهرستان ارومیه در منطقه سردسیر واقع شده و اغلب محصولات در این منطقه در نیمه اول سال رشد می‌کنند، از تصاویر گرفته شده در چهار تاریخ مطابق با

جدول ۳ استفاده شده است. مقاطع زمانی منتخب، مبتنی بر تقویم زراعی محصولات در این شهرستان است. شکل ۲ تصویر برگرفته از Google Earth منطقه مطالعه شده را نشان می‌دهد.

به منظور تأمین داده‌های آموزش و آزمون در ارزیابی نتایج بررسی‌ها، اقدام به مشاهدات میدانی و ثبت موقعیت محصولات موجود توسط گیرنده GPS دستی شده است. به این منظور، نقاط مشاهداتی به همراه نوع محصول در آن منطقه ثبت و پس از انطباق آن با تصاویر ورودی، داده‌های آموزش به شرح جدول ۴ تهیه شده است.

جدول ۲. مشخصات ماهواره سنتینل ۲ [۶]

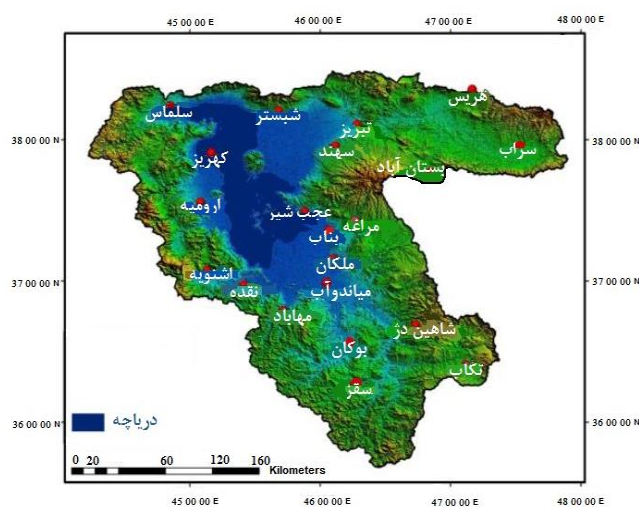
توان تفکیک مکانی (متر)	محدوده طیفی مرکز طول موج (میکرومتر)	توان تفکیک رادیومتریکی	دوره برداشت مجدد (روز)	عرض تصاویر (کیلومتر)
۶۰	Band1- aerosol 0.443			
۱۰	Band2- Blue 0.490			
۱۰	Band3- Green 0.560			
۱۰	Band 4- Red 0.66			
۲۰	Band5- vegetation 0.705			
۲۰	Band6-vegetation 0.740			
۲۰	Band7-vegetation 0.783	۱۲ بیت	۵ روز	۲۹۰ کیلومتر
۱۰	Band8-NIR 0.842			
۲۰	Band8A- vegetation 0.865			
۶۰	Band9-Water vapour 0.945			
۶۰	Band10-SWIR 1.375			
۲۰	Band 11-SWIR 1.610			
۲۰	Band 12- SWIR 2.190			

جدول ۳. تاریخ اخذ تصاویر سنتینل ۲ برای ارومیه


شماره تصویر	۱ (خرداد)	۲ (تیر)	۳ (مرداد)	۴ (شهریور)
تاریخ اخذ تصاویر	۱۳۹۵/۳/۲۵	۱۳۹۵/۴/۱۹	۱۳۹۵/۵/۱۶	۱۳۹۵/۷/۸

جدول ۴. داده‌های آموزش و آزمون برای ارزیابی الگوریتم‌های طبقه‌بندی

کلاس	آفتابگردان	صیفی جات	گندم	سیب‌زمینی	چغندر قند	یونجه	باغ‌ها	جو	شبدر	مجموع
نمونه آزمایش	۷۵	۹۵	۹۵	۹۵	۹۵	۹۵	۹۵	۵۵	۴۵	۸۰۰
نمونه کنترل	۲۳۰	۲۹۶	۲۱۰	۴۱۸	۷۶	۲۱۰	۵۰	۶۳	۳۵	۱۶۵۰



(ب)



(الف)

شکل ۲. الف) تصویر منطقه مطالعه شده، ب) تصویر گوگل ارث شهرستان ارومیه

مدل ارتفاعی Aster (DEM) استفاده شده و به صورت اتوماتیک تصحیح هندسی انجام می‌شود. برای جلوگیری از طولانی شدن فرایند بهینه‌سازی، از باندهای ۳-۴-۸-۱۱ تصاویر سنتینل ۲ بهره گرفته شده و در نهایت، با استفاده از نرم‌افزار ENVI و ابزار Layer Stacking، ۴ تصویر به یک تصویر ۱۶ باندهای تبدیل شده است.

تصحیح اتمسفریک

امواج الکترومغناطیس زمانی که از اتمسفر عبور می‌کنند به علت جذب و پخش اتمسفر به ترتیب سبب کاهش و افزایش بازتابش خواهد شد و برای اینکه بتوان به اطلاعات واقعی سطح زمین دست پیدا کرد، باید تصحیح اتمسفری انجام شود [۲۲]. در پژوهش حاضر هر چهار باند طیفی تصاویر به روش Dark Pixel Subtraction تصحیح اتمسفریک شده‌اند. در این روش برای تمامی باندهای طیفی تصویر، کمترین میزان بازتابش از طریق هیستوگرام تصویر به دست آمده و این مقدار از تمامی پیکسل‌های تصویر کم شده است تا تأثیرات اتمسفر حذف شوند. در پژوهش حاضر مقدار بازتابش برابر با ۳۵ است که بیانگر میزان تأثیر جمعی اتمسفریک است، بنابراین از تمامی مقادیر بازتابش پیکسل‌های تصویر کاسته شده و به این صورت، توسط نرم‌افزار snap تصحیح اتمسفریک انجام شده است.

آماده‌سازی داده‌ها و پارامترهای نرم‌افزاری

پیش‌پردازش داده‌ها

داده‌های سنجنش از دوری خام، در حالت کلی شامل نقایص و عیب‌هایی هستند. تصحیح نقص‌ها و برداشتن عیوب موجود در داده‌ها به عنوان پیش‌پردازش تعریف می‌شود، این کار قبل از آنکه داده‌ها به منظور مشخصی به کار روند، توسط عملگرهای مشخصی انجام می‌شود. هنگامی که سنجندها امواج بازتابی پدیده‌ها را ثبت می‌کنند، ممکن است سه دسته اشتباه رخ دهد. نوع نخست مربوط به خطای سنجندهاست. نوع دوم خطاهای هندسی هستند که مربوط به کروی بودن زمین، چرخش زمین، ارتفاع، موقعیت و وضعیت ماهواره در فضا و غیره هستند و نوع سوم، خطاهای مربوط به عوامل جوی مؤثر در میزان انعکاس رسیده به سنجندهاست. بنابراین، برای استفاده از اطلاعات رقمی ثبت شده توسط سنجندها، تصحیح‌های زیر ضروری است؛ اصلاح خطاهای دستگاهی، تصحیح هندسی و تصحیح رادیومتریک (اتمسفری). در پژوهش حاضر پیش‌پردازش تصاویر شامل تصحیح هندسی، ثبت کردن تصاویر و تصحیح اتمسفری انجام شده است.


تصحیح هندسی

در این مرحله کلیه تصاویر سنتینل ۲ با استفاده از نرم‌افزار Snap زمین‌مرج خواهند شد. برای این کار در نرم‌افزار از

حذف عوارض غیرگیاهی

از آنجا که هدف پژوهش حاضر، بررسی پوشش‌های گیاهی است، عوارض گیاهی و غیرگیاهی باید از هم تفکیک شوند. برای این کار از روش‌های مختلفی می‌توان استفاده کرد. از معمول‌ترین روش‌ها، استفاده از شاخص NDVI است؛ به این صورت که ابتدا بیشترین NDVI از بین تمامی مقاطع زمانی استخراج شده و سپس، بر اساس هیستوگرام پیکسل‌های آموزشی در باند Max NDVI، حد پایین هیستوگرام به‌عنوان یک مرز تصمیم‌گیری بین عوارض کشاورزی از غیرکشاورزی انتخاب می‌شود [۲۳]. سپس، بر اساس تصویر باینری تولیدشده، پیکسل‌های غیرگیاهی، ماسک شده (شکل ۳) و از پردازش‌های بعدی کنار گذاشته می‌شوند.

با توجه به اینکه محصولات کشاورزی هر یک تقویم زراعی خاص خود دارند، همواره نمی‌توان در یک مقطع زمانی خاص، تمامی محصولات کشاورزی را در دوره بلوغ خود داشت. از این‌رو، پردازش داده‌های تک‌زمانی اغلب با تداخل محصولات مختلف و یا تداخل با کلاس خاک مواجه می‌شوند. بنابراین، استفاده از تصاویر چندزمانی مناسب با تقویم زراعی محصولات، راهکار مناسبی برای حل مشکل یادشده است. بنابراین، امکان افزایش میزان همبستگی بین ویژگی‌های مقاطع زمانی به وجود خواهد آمد.



شکل ۳. تصویر باینری برای ماسک عوارض غیرکشاورزی

طبقه‌بندی تصاویر ماهواره‌ای

محصولات کشاورزی هر یک تقویم زراعی خاص خود دارند، از این‌رو همواره نمی‌توان در یک مقطع زمانی خاص، تمامی محصولات کشاورزی را در دوره بلوغ خود داشت. پردازش داده‌های تک‌زمانی اغلب با تداخل محصولات مختلف و یا تداخل با کلاس خاک مواجه می‌شوند. بنابراین، استفاده از تصاویر چندزمانی مناسب با تقویم زراعی محصولات، راهکار مناسبی برای حل مشکل یادشده است و امکان افزایش میزان همبستگی بین ویژگی‌های مقاطع زمانی به وجود خواهد آمد.


عوامل متعددی مانند نوع پوشش زمین، تفکیک مکانی تصویر و منابع مختلف داده‌ها در انتخاب روش طبقه‌بندی مؤثرند. دو روش کمترین فاصله^۱ و بیشترین شباهت^۲ از رایج‌ترین روش‌های استفاده‌شده در طبقه‌بندی تصاویر ماهواره‌ای هستند که در پژوهش حاضر روش کمترین فاصله به دلیل سرعت پردازش زیاد و زمان محاسبه کم مورد توجه قرار گرفته است. همچنین، زمانی که هیستوگرام‌های کلاس‌ها در هر باند واریانس تقریباً مشابهی داشته و کمترین ورودی را داشته باشند، این روش منجر به حصول نتایج مناسبی خواهد شد. اساس طبقه‌بندی کمترین فاصله آن است که ابتدا میانگین کلاس‌ها در هر باند محاسبه شده و سپس، فاصله بین بردار ورودی که همان بردار ویژگی برای هر پیکسل است و بردار میانگین هر کلاس محاسبه می‌شود. کلاسی که کمترین فاصله طیفی را با بردار ورودی داشته باشد، به عنوان کلاس بردار ورودی انتخاب می‌شود.

مبانی شبکه عصبی مصنوعی

یک شبکه عصبی انتشار به جلو چندلایه از مجموعه‌ای از نرون‌ها که با یک روش منطقی به هم متصل شده‌اند و شامل چندین لایه هستند، ساخته می‌شود. شبکه عصبی انتشار به جلو شامل سه لایه است. لایه ورودی شامل مجموعه‌ای ساده از نرون‌ها است که به عنوان گره‌های مبدأ عمل می‌کنند و مؤلفه‌های بردار ویژگی ورودی را برای لایه دوم فراهم می‌آورند. تعداد نرون‌های لایه ورودی برابر با بعد بردار ویژگی ورودی است. لایه دوم، لایه پنهان است که یک یا چند لایه را شامل می‌شود. لایه سوم لایه

1. Minimum Distance
2. Maximum Likelihood

یادگیری ضعیف منجر می‌شود. از سویی دیگر، افزایش تعداد آنها موجب افزایش شدید زمان یادگیری می‌شود. به علاوه، در استفاده از تعداد زیاد نرون، خطر Fitting Over وجود دارد، در شکل ۴ این مسئله برای تعداد ۵ و ۲۰ نرون نشان داده شده است.



شکل ۴. تأثیر تعداد نرون‌های لایه پنهان برای یک نمونه بررسی شده با (الف) ۵ نرون، (ب) ۱۲ نرون و (پ) ۲۰ نرون

معیار کاپا به تعداد نمونه‌های آموزشی حساس است و بیشتر تحت تأثیر کلاسی که بیشترین نمونه‌های آموزشی را دارد، قرار می‌گیرد. از سویی دیگر، به دلیل اینکه محصولات کشاورزی در منطقه مطالعه شده فراوانی‌های متفاوتی دارند، امکان فراهم کردن نمونه‌های آموزشی با تعداد برابر میسر نیست. بنابراین، برای کاهش حساسیت معیار کاپا به تعداد نمونه‌ها، ماتریس ابهام بر اساس تعداد نمونه‌های هر کلاس نرمالیزه شده و سپس، بر اساس ماتریس ابهام نرمالیزه شده معیار کاپا محاسبه می‌شود. بنابراین، در تحقیق حاضر از معیار کاپای نرمال شده برای تفکیک محصولات کشاورزی استفاده شده است.

بهینه‌سازی شبکه عصبی برای تفکیک محصولات کشاورزی در طبقه‌بندی چندزمانی

از جمله پارامترهای مؤثر در همگرایی ناقص شبکه‌های عصبی تعداد نرون‌های لایه ورودی، لایه میانی، میزان آموزش^۳ و ضریب مومنتوم^۴ هستند. همچنین، بررسی‌ها نشان داده است ترتیب معرفی نمونه‌های آموزش برای برآورد پارامترهای وزن شبکه در نتایج نهایی تأثیرگذار است؛ بنابراین چندین ترتیب مختلف برای نمونه‌های آموزشی ارزیابی و مقادیر کاپا برای شبکه عصبی با ورودی‌های تمامی مقاطع زمانی (۱۶ باند طیفی) بین بازه

خروجی است که پاسخ شبکه عصبی به بردار الگوی ورودی را فراهم می‌کند. تعداد نرون‌ها در این لایه متناظر با تعداد کلاس‌هایی است که توسط شبکه عصبی باید متمایز شوند [۲۴]. تعداد نرون‌های لایه پنهان برای انجام چگونگی یادگیری بسیار مهم است؛ تعداد نرون‌های بسیار کم به

مشکل اصل در شبکه عصبی، گرفتار شدن در نقاط مینیمم‌های محلی است که در برخی از موارد، همگرایی شبکه‌های عصبی به نتایج ضعیفی خواهد رسید. بنابراین، پارامترهای شبکه عصبی باید طوری تعیین شوند که تا حدود زیادی از این مشکل پرهیز شود [۲۴].

استفاده از ماتریس ابهام^۱ (CM) برای ارزیابی دقت طبقه‌بندی تصاویر ماهواره‌ای

ماتریس ابهام که با عنوان ماتریس خطا نیز شناخته می‌شود، روش مناسبی برای ارزیابی طبقه‌بندی به شمار می‌رود. این ماتریس، پیکسل‌های معلوم در واقعیت زمینی را با پیکسل‌های متناظر در نتایج طبقه‌بندی مقایسه می‌کند. به این صورت که برچسب هر پیکسل معلوم با برچسب پیکسل متناظر مقایسه شده و در نهایت، نتایج یکسان جمع و تعداد برچسب‌هایی که با همدیگر همخوانی ندارند نیز محاسبه می‌شود. پس از محاسبه ماتریس ابهام، مقدار کاپا قابل محاسبه خواهد بود.

مقدار کاپا دقت طبقه‌بندی را نسبت به یک طبقه‌بندی کاملاً تصادفی محاسبه می‌کند [۲۶]. رابطه ۱ چگونگی محاسبه کاپا را نشان می‌دهد.

$$\kappa = \frac{N \sum_{i=1}^r X_{ii} - \sum_{i=1}^r (X_{i+} X_{+i})}{N^2 - \sum_{i=1}^r (X_{i+} X_{+i})} \quad (1)$$

هر کروموزوم الگوریتم ژنتیک ۱۹ ژن است که ۳ ژن برای مقادیر تعداد نرون‌های لایه میانی، میزان آموزش و ضریب مومنتوم و ۱۶ ژن معرف ۱۶ باند طیفی بوده که به عنوان نرون‌های لایه ورودی انتخاب شده‌اند. تعداد اعضای جامعه اولیه برابر ۲۰ عضو و شرط توقف الگوریتم ۷۰ تکرار در نظر گرفته شده است. در ایجاد جامعه اولیه، تغییرات مجاز برای تعداد نرون‌های لایه میانی بین ۴ تا ۲۰ نرون و بازه (صفر و یک) به عنوان بازه مجاز برای مقادیر میزان آموزش و ضریب مومنتوم در نظر گرفته شده است.

به منظور محاسبه میزان برازندگی^۱ اعضا، شبکه عصبی متناظر با هر عضو جامعه با مقادیر اولیه وزن برابر ۰/۱ ایجاد و با حداکثر ۱۰۰ تکرار بر اساس ۱۱۴۸ نمونه آموزشی آموزش شد. پس از تکمیل آموزش شبکه عصبی، قابلیت طبقه‌بندی توسط ۹۱۵ نمونه تست ارزیابی و مقدار کاپای نرمال به عنوان معیار برازندگی آن عضو برآورد شد. در شکل ۵ متوسط کاپای نرمال و همچنین، کاپای بهترین عضو جامعه طی مراحل مختلف تکرار الگوریتم ژنتیک نشان داده شده است. روند صعودی متوسط کاپای اعضا جامعه بیانگر همگرایی اعضای جامعه به پاسخ بهینه است. بر اساس نتایج به دست آمده از اجرای الگوریتم ژنتیک به ازای مقادیر مختلف متغیرهای بررسی شده، شبکه عصبی با ساختار بهینه شامل ۱۶ نرون در لایه میانی، میزان آموزش برابر ۱ و ضریب مومنتوم برابر ۰/۲ تشکیل شده است. باندهای طیفی منتخب [۱، ۲، ۳، ۴، ۵، ۶، ۷، ۱۰، ۱۱، ۱۲، ۱۵ و ۱۶] در مجموع با ۱۰ باند به عنوان تعداد نرون‌های لایه ورودی انتخاب شده‌اند.

میزان کاپای نرمالیزه شده برای شبکه عصبی بهینه برابر ۸۹ درصد است که نتیجه بهتری نسبت به شبکه عصبی استاندارد با کاپای ۸۶ درصد دارد. شکل ۶ ساختار شبکه عصبی بهینه را نمایش می‌دهد.

در این حالت با بهینه شدن تعداد نرون‌های لایه ورودی و میانی و پارامترهای شبکه عصبی، دقت طبقه‌بندی با شبکه عصبی بهینه نسبت به شبکه عصبی استاندارد فقط ۲ درصد افزایش یافته است که به دلیل زمان بر بودن اجرای بهینه‌سازی شبکه عصبی همراه با الگوریتم ژنتیک، افزایش درخور توجهی در دقت محاسبات به شمار نمی‌رود.

۰/۸ - ۰/۹ قرار گرفته که این موضوع وابستگی شبکه عصبی به ترتیب معرفی نمونه‌های آموزشی را بیان می‌کند. بنابراین، برای حصول به بیشترین دقت شبکه عصبی، باید علاوه بر پارامترهای تعداد نرون‌های لایه ورودی، لایه میانی، میزان آموزش و ضریب مومنتوم، ترتیب مناسبی برای معرفی نمونه‌های آموزشی تعیین شود. برای این منظور، استفاده از الگوریتم ژنتیک به عنوان یکی از روش‌های موفق بهینه‌سازی استفاده شده است.

ساختاردهی الگوریتم ژنتیک


در هر کروموزوم الگوریتم ژنتیک، مقدار ژن اول بیانگر تعداد نرون در لایه میانی، مقدار ژن دوم بیانگر میزان آموزش و مقدار ژن سوم بیانگر ضریب مومنتوم در نظر گرفته شده است. باقی ژن‌ها (S_1, S_2, \dots, S_n) که برابر تعداد کل باندهای طیفی داده‌های چندزمانی است، مقادیر صفر یا یک را به خود می‌گیرند که بیانگر حضور داشتن و نداشتن هر باند طیفی به عنوان یک نرون در لایه اول شبکه عصبی است [۲۵]. پس از تشکیل جامعه اولیه و براساس نمونه‌های آموزشی، شبکه عصبی آموزش داده شده و سپس، با استفاده از نمونه‌های آزمون میزان کاپای نرمال به عنوان میزان شایستگی برای هر عضو در نظر گرفته شده است.

نتایج و بحث


بهینه کردن طبقه‌بندی تصاویر ماهواره‌ای به روش کمترین فاصله توسط الگوریتم ژنتیک به ۲ صورت انجام یافته است؛ در حالت نخست تأثیر تعداد نرون‌های لایه میانی و انتخاب مناسب پارامترهای بهینه شبکه عصبی و در حالت دوم تأثیر ترتیب معرفی نمونه‌های آزمایشی بررسی شده است. در حالت نخست تعداد ۴ تا ۲۰ نرون برای لایه میانی و مقداری بین صفر و یک برای میزان آموزش و ضریب مومنتوم انتخاب و ارزیابی شد. در حالت دوم ترتیب‌های مختلفی از معرفی نمونه‌های آموزشی ارزیابی شده است.

بهینه‌سازی تعداد نرون‌های لایه ورودی و پارامترهای شبکه عصبی

تعداد مقاطع زمانی استفاده شده برای تحلیل، چهار مقطع زمانی و در مجموع ۱۶ باند طیفی است. بنابراین، در طول



شکل ۵. روند همگرایی الگوریتم ژنتیک برای حالت اولیه بهینه‌سازی در ۷۰ تکرار



شکل ۶. ساختار شبکه عصبی بهینه در حالت اول برای طبقه‌بندی چندزمانی محصولات با چهار تصویر

(R_1, R_2, \dots, R_n) ، که بیانگر شماره نمونه آموزشی بوده و جایگاه آن ژن در کروموزوم بیانگر ترتیب معرفی آن نمونه آموزشی است.

برای ایجاد جامعه اولیه، مقادیر ژن‌های بخش (الف) کروموزومی، همانند حالت اول بهینه‌سازی، مقداردهی شده‌اند. برای ژن‌های بخش (ب)، یک ترتیب تصادفی از تعداد نمونه‌ها ایجاد شده است، به این منظور یک نمونه آموزشی ممکن است چندین بار استفاده شود و برخی نمونه‌ها ممکن است هرگز استفاده نشوند؛ این موضوع به کیفیت هر نمونه آموزشی در همگرایی شبکه عصبی بستگی دارد. پس از ایجاد جامعه اولیه بر اساس پارامترهای بخش (الف)، هر عضو جامعه یک شبکه عصبی

بهینه‌سازی ترتیب معرفی نمونه‌های آموزشی

در این حالت پارامتر ترتیب معرفی نمونه‌های آموزشی بررسی شده است، به این صورت که تعداد نرون‌ها در لایه ورودی شبکه عصبی ثابت و برابر با تعداد ورودی‌های طبقه‌بندی‌کننده در نظر گرفته شده ولی ترتیب معرفی کل نمونه‌های آموزشی بررسی بیشتر شده است. هر کروموزوم در جامعه اولیه بیانگر یک ترتیب از معرفی کل نمونه‌های آموزشی، تعداد نرون در لایه میانی، میزان آموزش و ضریب مومنتوم است. بر این اساس، در هر کروموزوم مقدار ژن‌های اول تا سوم همانند روش قبل (بخش الف) و مقدار ژن‌های چهارم (بخش ب) تا آخر هر کروموزوم عددی است بین یک تا تعداد نمونه‌های آموزشی

نرمال به عنوان معیار برازندگی آن عضو برآورد شد. در شکل ۷ متوسط کاپای نرمال و همچنین، کاپای بهترین عضو جامعه طی مراحل مختلف تکرار الگوریتم ژنتیک نشان داده شده است. روند صعودی متوسط کاپای اعضای جامعه بیانگر همگرایی اعضای جامعه به پاسخ بهینه است. براساس نتایج به دست آمده از اجرای الگوریتم در حالت دوم بهینه سازی، شبکه عصبی با ساختار بهینه، ۱۴ نرون در لایه میانی و میزان آموزش ۰/۴ دارد و ضریب مومنتوم برابر صفر است. در این حالت، با حصول مقدار ۹۰/۵ درصد برای کاپای نرمالیزه شده برای شبکه عصبی بهینه شده، بهترین نتیجه تفکیک محصولات کشاورزی با داده های چندزمانی ایجاد شده است.


در این حالت بهینه شدن ترتیب معرفی نمونه های آموزشی، موجب افزایش ۴/۵ درصدی در دقت محاسبات شده است. بنابراین، می توان گفت که ترتیب معرفی نمونه های آزمایشی در مقایسه با پارامترهای تعداد نرون های لایه ورودی، میزان آموزش و ضریب مومنتوم، بیشترین تأثیر را به همراه تعداد نرون های لایه میانی در همگرایی شبکه دارد. با این حال، زمان زیاد اجرای برنامه، مشکل اصلی این روش است.

شکل ۹ میزان درصد تداخل بین هر جفت کلاس طبقه بندی برای ۲ حالت شبکه عصبی استاندارد و شبکه عصبی بهینه، با ورودی های تمامی مقاطع زمانی (۴ مقطع زمانی) را نمایش می دهد که میزان تداخل برای هر جفت کلاس براساس ماتریس ابهام برابر با مجموع درصد پیکسل های جابه جاشده بین دو کلاس است.


را تشکیل داده و با ترتیب مشخص شده در بخش (ب)، نمونه های آموزشی برای تعیین پارامترهای وزن شبکه در مرحله آموزش معرفی شده اند. سپس، با استفاده از نمونه های تست، ماتریس ابهام برای نتایج حاصل از طبقه بندی با شبکه عصبی بهینه تشکیل و مشابه حالت اول بهینه سازی، میزان کاپای نرمالیزه شده به عنوان معیار برازندگی برای عضو در نظر گرفته شده است.

در این حالت، تعداد نمونه های آموزشی استفاده شده برابر با ۱۱۴۸ نمونه از محصولات مختلف است. از این رو، طول کروموزوم الگوریتم ژنتیک برابر ۱۱۴۸ است که شامل ۳ ژن برای مقادیر تعداد نرون ها در لایه میانی، میزان یادگیری و ضریب مومنتوم بوده و سایر ژن ها برای معرفی نمونه های آزمایشی است. بدیهی است ۱۱۴۸ فاکتوریل تعداد حالت های مختلف برای ترتیب معرفی نمونه های آزمایشی وجود خواهد داشت که الگوریتم ژنتیک ترتیب بهینه را از میان آنها مشخص کرده است.


مشابه حالت اول بهینه سازی، تعداد اعضای جامعه اولیه برابر ۲۰ عضو، شرط توقف الگوریتم ۷۰ تکرار، محدوده مجاز برای تعداد نرون های لایه میانی بین ۴ تا ۲۰ نرون و بازه (صفر و یک) به عنوان بازه مجاز برای مقادیر مقدار آموزش و ضریب مومنتوم در نظر گرفته شده است. میزان برازندگی اعضا نیز با مقادیر اولیه وزن برابر ۰/۱ ایجاد شده و با حداکثر ۱۰۰ تکرار بر اساس ۱۱۴۸ نمونه آموزشی آموزش شد. ترتیب معرفی نمونه های آموزشی نیز بر اساس الگوی ژن ها در بخش (ب) کروموزومی مشخص خواهد شد. پس از تکمیل آموزش شبکه عصبی، قابلیت طبقه بندی توسط ۹۱۵ نمونه تست ارزیابی و مقدار کاپای



شکل ۷. روند مربوط به همگرایی الگوریتم ژنتیک برای حالت دوم بهینه سازی در ۷۰ تکرار




شکل ۸. ساختار شبکه عصبی بهینه در حالت دوم برای طبقه‌بندی چندزمانی محصولات با چهار تصویر



GNN (KAPPA =90.5)

(الف)



NN (KAPPA =86)

(ب)

شکل ۹. الف) میزان تداخل بین هر جفت کلاس بر اساس شبکه عصبی بهینه؛ ب) شبکه عصبی استاندارد با ورودی‌های تمامی مقاطع زمانی تمام محصولات طبقه‌بندی شده

نشان می‌دهد. با توجه به طبقه‌بندی انجام‌شده برای گیاهان زراعی مورد کاشت در شکل ۱۰ که با دقت بسیار زیادی انجام یافته است و بر حسب داده‌های موجود در جدول ۶، مشاهده می‌شود دو محصول یونجه و گندم به ترتیب بیشترین سطح کشت را دارند؛ این در حالی است که یونجه بعد از شبدر بیشترین میزان مصرف آب را در بین محصولات یادشده دارد و به لحاظ نوع مصرف نیز جزء محصولات با تقاضای زیاد نیست. از سویی دیگر، دو محصول یونجه و شبدر به شدت با همدیگر تداخل دارند، به دلیل اینکه هر دوی این محصولات از نظر رفتارهای طیفی و تغییرات زمانی شرایط یکسان ندارند و کاشت هم‌زمان آنها به شدت بر میزان آب برداشتی از مخزن مؤثر خواهد بود. در مقابل، دو محصول گندم و جو که جزء محصولات با تقاضای زیاد هستند، سطح کشت بسیار کم دارند. این در حالی است که میزان مصرف آب این دو محصول نیز بسیار کم است.

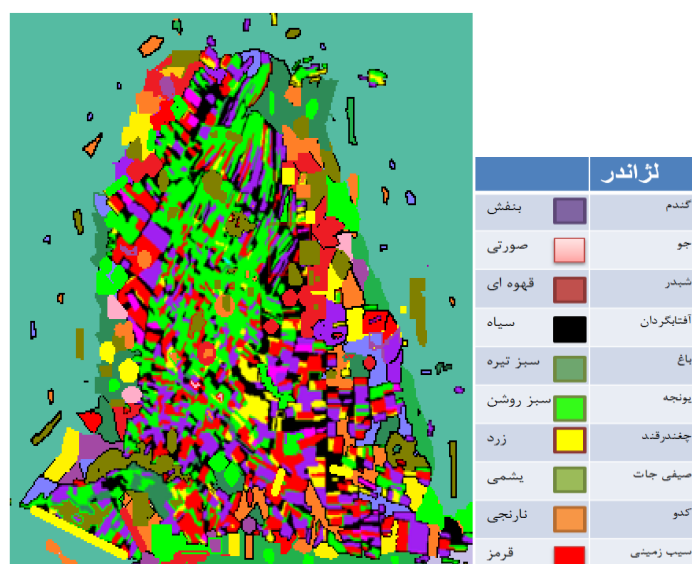
همان‌طور که مشاهده می‌شود، در بیشتر ترکیبات دوتایی از کلاس‌ها، میزان تداخل بین کلاسی در شبکه عصبی بهینه نسبت به شبکه عصبی استاندارد با کاهش روبه‌رو شده است و یا به بیانی، میزان تفکیک‌پذیری بین کلاس‌ها افزایش یافته است. با این‌وجود، در شبکه عصبی بهینه همچنان دو محصول یونجه و شبدر به شدت با همدیگر تداخل دارند. به دلیل اینکه هر دوی این محصولات از نظر رفتارهای طیفی و تغییرات زمانی شرایط یکسانی دارند و کاشت هم‌زمان این دو محصول به شدت بر میزان آب برداشتی از مخزن مؤثر خواهد بود.

نتایج طبقه‌بندی

شکل ۱۰ نتایج حاصل از طبقه‌بندی شبکه عصبی بهینه را برای منطقه مطالعه‌شده نشان می‌دهد. در جدول ۵ نتایج حاصل از طبقه‌بندی به روش شبکه عصبی استاندارد و شبکه عصبی بهینه‌شده نشان داده شده است. جدول ۶ میزان مصرف هر یک از گیاهان یادشده را

جدول ۵. مقایسه نتایج حاصل از شبکه عصبی استاندارد و شبکه عصبی بهینه

ورودی‌های تمام مقاطع زمانی		ورودی‌های بهینه‌شده		روش استفاده‌شده
تعداد باند	کاپا	تعداد باند	کاپا	شبکه عصبی
۱۶	۰/۸۶	۱۰	۰/۹۰۵	



شکل ۱۰. بخشی از طبقه‌بندی محصولات با شبکه عصبی بهینه

جدول ۶. طبقه‌بندی گیاهان زراعی بر حسب میزان مصرف آب

نام گیاه	یونجه	شبدر	سیب‌زمینی	چغندر قند	گندم	جو
میزان مصرف در هر دوره از کشت (هزار مترمکعب)	۱۸-۱۲	بسیار بیشتر از یونجه	۱۶-۱۲	۷	۸-۴	۵-۳

ورودی‌های چندزمانی، کاهش عملکرد طبقه‌بندی‌کننده‌ها به دلیل افزایش وابستگی بین ویژگی‌های مقاطع زمانی و کاهش عملکرد طبقه‌بندی‌کننده‌ها به دلیل افزایش وابستگی بین ویژگی‌های مقاطع زمانی در تحقیق حاضر است.

- تفکیک محصولات کشاورزی با باندهای طیفی بهینه برای هر طبقه‌بندی‌کننده، نتایج بهتری را نسبت به طبقه‌بندی با تمامی باندهای طیفی در بر دارد.

- بر حسب طبقه‌بندی انجام‌شده، دو محصول یونجه و گندم بیشترین سطح کشت را دارند؛ این در حالی است که یونجه بعد از شبدر بیشترین میزان مصرف آب را دارد و به لحاظ نوع مصرف نیز جزء محصولات با تقاضای زیاد نیست. از سویی دیگر، کاشت هم‌زمان این دو محصول به دلیل تداخل دوره رشد آنها به شدت بر میزان آب برداشتی از مخزن مؤثر است.

- دو محصول گندم و جو که جزء محصولات با تقاضای زیاد هستند، سطح کشت بسیار کم دارند. این در حالی است که میزان مصرف آب این دو محصول نیز بسیار کم است. بنابراین، به لحاظ اولویت تقاضای جامعه و میزان مصرف آب، سه محصول گندم، جو و سیب‌زمینی باید بیشترین سطح کشت را داشته باشند و باید در نزدیک‌ترین فاصله به مسیر اصلی آب انشعابی از مخزن سد شهرچای قرار گیرند. از این‌رو، کلیه مناطقی که در حال حاضر به کشت یونجه اختصاص داده شده است، باید به کشت سه محصول یادشده اختصاص یابند. درخور یادآوری است دو محصول گندم و جو در اغلب شرایط آب‌وهوایی قابل رشد بوده و نسبت به خشکی و گرما مقاوم هستند؛ بنابراین می‌توان این دو محصول را در فصول سرد که میزان بارش زیاد است و به بهره‌برداری کمی از مخزن سد نیاز دارد، کاشت و برداشت کرد.

می‌توان بیان کرد به لحاظ اولویت تقاضای جامعه و میزان مصرف آب، سه محصول گندم، جو و سیب‌زمینی باید بیشترین سطح کشت را داشت و باید در نزدیک‌ترین فاصله به مسیر اصلی آب انشعابی از مخزن سد قرار گیرند تا کمترین میزان هدررفت آب در مسیرهای منتهی به زمین‌های زراعی وجود داشته باشد. بنابراین، کلیه مناطقی که در حال حاضر به کشت یونجه اختصاص داده شده است، باید به کشت سه محصول یادشده اختصاص یابند. درخور یادآوری است دو محصول گندم و جو در اغلب شرایط آب‌وهوایی قابل رشد بوده و نسبت به خشکی و گرما مقاوم هستند؛ بنابراین می‌توان این دو محصول را در فصول سرد که میزان بارش زیاد بوده و نیاز به بهره‌برداری کمی از مخزن سد است، کاشت و برداشت کرد.

نتیجه‌گیری

در پژوهش حاضر تفکیک محصولات کشاورزی با استفاده از تصاویر ماهواره سنتینل ۲ به روش‌های مبتنی بر ورودی‌های چندزمانی و روش‌های مبتنی بر ورودی‌های بهینه چندزمانی انجام یافته است. به این منظور، از شبکه عصبی مصنوعی برای پیش‌بینی و از الگوریتم ژنتیک برای بهینه‌سازی پارامترهای الگوریتم شبکه عصبی مصنوعی بهره گرفته شده است. در نهایت، بر مبنای طبقه‌بندی محصولات ارائه‌شده برای سطح زیر کشت چندین نوع محصول، الگوی بهره‌برداری از مخزن بر حسب تقاضا و میزان مصرف ارائه شده است.

- تفکیک محصولات کشاورزی با ورودی‌های چندزمانی مطابق با تقویم زراعی محصولات مد نظر به دلیل استفاده از قابلیت تغییرات طیفی محصولات طی دوره رشد، برای بیشتر طبقه‌بندی‌کننده‌های آماری و غیرآماري نتایج بهتری نسبت به ورودی‌های تک‌زمانی در تحقیق حاضر دارد.
- مشکل اصلی در طبقه‌بندی‌کننده‌های آماری با

- Gujarat. Journal of agrometeorology, 2017; 19(Special Issue): 171-178.
- [7]. Solberg AHS, Jain AK, Taxt T. Multisource classification of remotely sensed data: fusion of Landsat TM and SAR images. IEEE Transactions on Geoscience and Remote Sensing, 1994; 32(4): 768-778.
- [8]. Chen KSH, Huang WP, Tsay DH, Amar F. Classification of multi frequency polarimetric SAR imagery using a dynamic learning neural network. IEEE Transactions on Geosciences and Remote Sensing, 1996; 34(3): 814-820.
- [9]. Panigrahy S, Chakraborty M, Sharma SA, Kundu N, Ghose SC, Pal M. Early estimation of rice area using temporal ERS-1 synthetic aperture radar data: a case study for the Howrah and Hugly districts of West Bengal, India. International journal of remote sensing, 1997; 18(8): 1827-1833.
- [10]. Gower ST, Kucharik CJ, Norman JM. Direct and indirect estimation of leaf area index, f (APAR), and net primary production of terrestrial ecosystems. Remote Sensing of Environment, 1999; 70(1): 29-51.
- [11]. Aparicio N, Villegas D, Araus JL, Casadesús J, Royo C. Relationship between Growth Traits and Spectral Vegetation Indices in Durum Wheat. Crop Science, 2012; 42(5): 1547-1555.
- [12]. Verhoeve J, Wulf RD. Land cover mapping at sub-pixel scales using linear optimization techniques. Remote Sensing of Environment, 2002; 79(1): 96-104.
- [13]. Wang Q, Tenhunen JD. Vegetation mapping with multitemporal NDVI in North Eastern China transect (NECT). International Journal of Applied Earth Observation and Geoinformation, 2004; 6(1): 17-31.
- [14]. McNairn H, Brisco B. The application of C-band polarimetric SAR for agriculture: a review. Canadian Journal of Remote Sensing, 2004; 30(3): 525-542.
- [15]. Turker M, Arıkan M. Sequential masking classification of multi-temporal Landsat 7 ETM+ images for field-based crop mapping in Karacabey, Turkey. International journal of remote sensing, 2005; 26(17): 3813-3830.
- [16]. Verbeiren S, Eerens H, Piccard I, Bauwens I, Orshoven JV. Sub-pixel classification of SPOT-VEGETATION time series for the assessment of regional crop areas in Belgium. International Journal of Applied Earth Observation and Geoinformation, 2008; 10(4): 486-497.
- مقایسه نتایج حاصل از تحقیق یادشده با نتایج به دست آمده از پژوهش‌های سایر محققان نشان می‌دهد تفکیک با دقت زیاد برای محصولات کشاورزی فقط با تکیه بر داده‌های طیفی امکان پذیر نیست. بنابراین باید از ویژگی‌های دیگری مانند شاخص‌های گیاهی و مؤلفه‌های اصلی استفاده شود که در پژوهش حاضر نیز این مسئله مورد توجه قرار گرفته است. پژوهش حاضر نیز نشان داده است طبقه‌بندی با ویژگی‌های بهینه برای تمامی کلاس‌ها، در مقایسه با طبقه‌بندی فازی، افزایش دقت درخور توجهی دارد که در نتیجه، میزان تفکیک‌پذیری محصولات را به شدت افزایش می‌دهد.
 - طبق ارزیابی‌های آماری سایر پژوهش‌ها نیز انتخاب بهینه باندها سبب افزایشی حدود ۴ درصد در دقت نتایج می‌شود.

منابع

- [1]. Boustani F, Mohammadi H. Studying productivity of and demand for water in sugar beet production in Eqlid district. Journal of Sugar Beet, 2007; 23(2): 185-196 (In Persian).
- [2]. Chizari A, Ghasemi A. Application of mathematical programming in determining the optimal pattern of crop cultivation. Agriculture Economic and Development, 2009; 28(7): 61-76 (In Persian).
- [3]. Feizizadeh B, Khedmatzadeh A, Nikjou MR. Micro-classification of orchards and agricultural croplands by applying object based image analysis and fuzzy algorithms for estimating the area under cultivation. Journal of Applied Researches in Geographical Sciences, 2020; 18(48): 201-216.
- [4]. Murakami T, Ogawa S, Ishitsuka N, Kumagai K, Saito G. Crop discrimination with multitemporal SPOT/HRV data in the Saga Plains, Japan. International journal of remote sensing, 2001; 22(7): 1335-1348.
- [5]. Quegan S, Thuy LT, Skriver H, Gomez-Dans J, Gonzalez-Sampedro MC, Hoekman DH. Crop classification with multi temporal polarimetric SAR data. Citeseer, 2003.
- [6]. Rucha D, Dipanwita H, Viral AD, Manjunath KR, Vyas P. Crop monitoring and classification using multi temporal polarimetric SAR (RISAT-1) data for cotton and groundnut crops of

- [17]. Geipel J, Link J, Claupein W. Combined Spectral and Spatial Modeling of Corn Yield Based on Aerial Images and Crop Surface Models Acquired with an Unmanned Aircraft System. *Remote Sens*, 2014; 6(11): 10335-10355.
- [18]. Feng Q, Liu J, Gong J. UAV Remote Sensing for Urban Vegetation Mapping Using Random Forest and Texture Analysis. *Remote Sens*, 2015; 7: 1074-1094.
- [19]. Ghazali M, Roozbahani A, Honar T, Mohammadi F. Ranking of scenarios for water allocation of Zayandeh Rud dam to different users using the expert multi attribute decision making models. *Journal of Water and Irrigation Management*, 2015; 5(1): 97-113.
- [20]. Khodadadi SA, Yasi M, Monem MJ. Performance evaluation and optimization of water delivery schedule in the Zarinehroud irrigation network. *Journal of Water and Irrigation Management*, 2018; 7(1): 105-120.
- [21]. Huo LZ, Boschetti L, Sparks AM. Object Based Classification of Forest Disturbance Types in the Conterminous United States. *Remote Sensing*, 2019; 11(5): 477-498.
- [22]. Beisl U, Telaar J, Schonemrak MV. Atmospheric correction, Reflectance calibration and BRDF correction for ADS40 image data. *The international archives of photogrammetric, Remote Sensing and information Sciences*. Vol. XXXVII. Part B7, 2008.
- [23]. Solaimani K, Shokrian F, Tamartash R, Banihashemi M. Landsat ETM+ based assessment of vegetation indices in highland environment. *Journal of Advances in Developmental Research*, 2011; 2(1): 5-13.
- [24]. Prost C, Zerger A, Dare P. A multilayer feed-forward neural network for automatic classification of eucalyptus forests in airborne video imagery. *International journal of remote sensing*, 2005; 26(15): 3275-3293.
- [25]. Zhuang X, Engel BA, Lozano-Garcia DF, Fernandez RN, Johannsen CJ. Optimization of training data required for neuro-classification. *International journal of remote sensing*, 1994; 15(16): 3271-3277.
- [26]. Congalton RG. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 1991; 37(1): 35-46.