

برآورد رطوبت سطح خاک با استفاده از روش های ANN و SVR در تصاویر ماهواره‌های سنیتینل ۱ و ۲

صادق رنجبر^۱، مهدی آخوندزاده هنزائی^{۲*}

۱- دانشجوی کارشناسی ارشد سنجش از دور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران
۲- استادیار گرایش سنجش از دور دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

تاریخ دریافت مقاله: ۱۳۹۸/۰۴/۲۹ تاریخ پذیرش مقاله: ۱۳۹۸/۰۹/۱۹

چکیده

رطوبت سطحی خاک متغیر مهمی است که نقش حیاتی در مدیریت منابع آب و خاک دارد. برآورد این پارامتر یکی از کاربردهای مهم سنجش از دور به حساب می‌آید. یکی از تکنیک‌های سنجش از دور برای برآورد دقیق این پارامتر، مدل‌های داده‌محور است. در این پژوهش رطوبت حجمی سطح خاک با استفاده از مدل‌های داده‌محور، روش رگرسیون بردار پشتیبان (SVR) و روش شبکه عصبی مصنوعی چندلایه پرسپترون ($ANN-MLP$)، برآورد شده است. پارامترهای دو مدل با استفاده از الگوریتم بهینه‌سازی ژنتیک بهینه شده است. برآورد رطوبت حجمی سطح خاک با دو مدل بالا با استفاده از دو نوع تصویر سنیتینل ۱ و سنیتینل ۲ انجام شده است؛ که باندهای بهینه تصویر سنیتینل ۲ با استفاده از الگوریتم بهینه‌سازی ژنتیک مشخص شده‌اند. پس از برآورد نقشه رطوبت حجمی سطح خاک از دو روش با استفاده از تصاویر سنیتینل ۱ و سنیتینل ۲، چهار خروجی با یکدیگر مقایسه شده‌اند. برآورد رطوبت حجمی سطح خاک با روش رگرسیون بردار پشتیبان با استفاده از تصویر سنیتینل ۱ بهترین دقت و برآورد این پارامتر با روش شبکه عصبی مصنوعی چندلایه پرسپترون با استفاده از تصویر سنیتینل ۲ بدترین دقت را داشته است. دقت در این پژوهش با استفاده از مربع ضریب همبستگی رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه‌گیری شده (R^2) محاسبه شده است که بهترین و بدترین ضریب همبستگی به ترتیب، ۰/۶۵۹ برای تصویر سنیتینل ۱ با روش رگرسیون بردار پشتیبان و ۰/۴۰۹ برای تصویر سنیتینل ۲ با روش شبکه عصبی مصنوعی چندلایه پرسپترون بدست آمده است. ریشه میانگین مربع خطا برای ارزیابی روش‌ها استفاده شده است که کمترین و بیشترین خطا به ترتیب $0.291 \left(\frac{m^3}{m^3}\right)$ برای روش رگرسیون بردار پشتیبان با تصویر سنیتینل ۱ و $0.4612 \left(\frac{m^3}{m^3}\right)$ برای روش شبکه عصبی مصنوعی چندلایه پرسپترون با تصویر سنیتینل ۲ محاسبه گردیده است.

کلید واژه‌ها: رطوبت خاک، سنیتینل ۱ و ۲، شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان، الگوریتم ژنتیک.

* نویسنده مکاتبه کننده: تهران-خیابان کارگر شمالی-بالا تر از تقاطع جلال آل احمد-دانشکده فنی دانشگاه تهران-دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی.

تلفن: ۰۲۱۶۱۱۱۴۵۲۲

Email: makhonz@ut.ac.ir

۱- مقدمه

رطوبت خاک، به ویژه رطوبت سطحی خاک^۱ نقش بسیار مهمی در مدیریت منابع آب و خاک دارد. بنابراین بررسی وضعیت پارامترهای خاک برای هیدرولوژی، هواشناسی، اقلیم‌شناسی، کشاورزی و بسیاری از علوم زمینی مناسب است [۱]. برآورد دقیق رطوبت خاک عامل مهمی در این مطالعات است. تنوع در عواملی همچون بافت خاک، زبری سطح خاک و پوشش گیاهی باعث تغییر رطوبت خاک می‌شود [۲ و ۳]. رطوبت خاک از شیوه‌های مختلفی محاسبه می‌شود. جستجو برای یافتن روش‌های نوین و سریع برای برآورد رطوبت سطحی خاک باعث افزایش تحقیقات اخیر در استفاده از تکنیک‌های سنجش از دور برای اندازه‌گیری و نظارت بر رطوبت سطحی خاک در مقیاس بزرگ شده است [۴، ۵ و ۶].

ضریب پس‌پراکنش راداری^۲ (σ^0) به ثابت دی‌الکتریک حساس است، اختلاف ثابت دی‌الکتریک خاک خشک (> 5) و آب (≈ 80) نشان‌دهنده حساسیت ثابت دی‌الکتریک به رطوبت می‌باشد و این پارامتر برای تهیه نقشه رطوبت سطحی خاک مفید است [۷، ۸، ۹ و ۱۰]. از این رو، برآورد رطوبت خاک با استفاده از داده‌های سنجش از دوری راداری اندازه‌گیری‌شده، زمینه تحقیقاتی برای برآورد این پارامتر می‌باشد. مدل‌های تئوری و تجربی مختلفی برای برآورد رطوبت سطحی خاک از داده‌های سنجش از دور فعال و غیرفعال طراحی شده‌اند [۱۰، ۱۱، ۱۲، ۱۳، ۱۴ و ۱۵]. مدل‌های تئوری، پارامترهای پیچیده‌ای از مدل‌های احتمالی برای خاک، گیاهان و زمین را شامل می‌شوند؛ در حالی که مدل‌های تجربی رابطه‌ای میان متغیرهای اندازه‌گیری‌شده برای اندازه‌گیری پارامترها برقرار می‌کنند. برای کالیبره کردن مدل‌های تئوری به داده‌های

میدانی نیاز است. علاوه بر محدودیت داده میدانی رطوبت سطحی خاک، جدا کردن تأثیر پوشش گیاهی و خاک زیر پوشش گیاهی بر ضریب پس‌پراکنش، مشکل اساسی برای کاربرد این مدل‌ها است [۱۶]. پوشش گیاهی باعث کاهش حساسیت ضریب پس‌پراکنش به رطوبت خاک می‌شود، از این رو نیاز به مدل‌های داده محور که می‌توانند داده‌های ورودی را به صورت مؤثری به خروجی موردنظر مرتبط کند، احساس می‌شود [۱۷].

شبکه‌های عصبی مصنوعی (ANN)^۳ و رگرسیون بردار پشتیبان (SVR)^۴ مدل‌هایی هستند که می‌توانند داده‌های ورودی را به صورت مؤثری به خروجی موردنظر مرتبط سازند. شبکه‌های عصبی مصنوعی، مدل‌هایی هستند که از مجموعه داده‌های آموزشی برای یادگیری استفاده می‌کنند و روابط غیرخطی و پیچیده میان متغیرها برقرار می‌کنند [۱۷]. شبکه‌های عصبی مصنوعی برای طیف گسترده‌ای از کاربردهای مختلف یادگیری از داده، و ارتباط غیرخطی ورودی و خروجی در منابع آب و هیدرولوژی استفاده شده است [۱۷، ۱۸، ۱۹، ۲۰ و ۲۱]. ساختار و عملکرد شبکه‌های عصبی مصنوعی توسط محققین مختلفی بحث شده است [۱۸، ۱۹، ۲۰، ۲۲ و ۲۳]. ماشین بردار پشتیبان به عنوان یک سیستم یادگیری هسته‌مبنا است که بر اساس تئوری یادگیری آماری و به حداقل رساندن خطر ساختاری^۵ عمل میکند [۲۴]. چی گائو و همکاران با تلفیق اطلاعات تصویر سنتینل^۶ و تصویر سنتینل^۲ رطوبت خاک را با توان تفکیک مکانی ۱۰۰ متر و با ریشه میانگین مربع خطا در رطوبت حجمی، $0.087 \frac{m^3}{m^3}$ برآورد کردند [۲۵]. جیانگ و همکاران با استفاده از الگوریتم‌های ماشین بردار پشتیبان و شبکه عصبی

^۳ Artificial Neural Networks^۴ Support Vector Regression^۵ Structural risk^۶ Sentinel^۱ Surface soil moisture^۲ Radar Cross Section (Backscatter)

با یکدیگر مقایسه و بحث گردیده است و در نهایت در بخش پنجم نتیجه گیری کلی پژوهش آورده شده است.

۲- منطقه و داده های تحقیق

در این بخش ابتدا منطقه مورد مطالعه، خصوصیات و دلیل انتخاب این منطقه توضیح داده شده است سپس داده های مورد استفاده و دلیل استفاده از آنها در این پژوهش، بیان شده است.

۲-۱- منطقه مورد مطالعه

منطقه مطالعاتی این تحقیق در ایالت مانیتوبا کانادا، در جنوب غربی وینینگ در طول و عرض جغرافیایی ۹۷/۸۸- و ۴۹/۵۸ قرار گرفته است (شکل (۱)). مساحت این منطقه ۲۶ کیلومتر در ۴۸ کیلومتر را شامل می شود. محصولات عمده این منطقه کلزا، سویا، گندم، ذرت، جو می باشد. علت اصلی انتخاب این منطقه، وجود نمونه برداری های میدانی و وجود ایستگاه های مختلف هواشناسی و هیدرولوژی است.

۲-۲- داده های تحقیق

در این پژوهش از تصاویر سنتینل ۱ و سنتینل ۲ استفاده شده است. در این بخش ابتدا تصاویر مورد استفاده و خصوصیات آنها بیان شده است، سپس داده میدانی مورد استفاده، خصوصیات آن، تعداد و همچنین زمان برداشت داده بیان گردیده است.

۲-۲-۱- تصاویر ماهواره ای

در این پژوهش از دو نوع داده اپتیک و رادار استفاده شده که بدین منظور از تصاویر سنتینل ۱ و ۲ به ترتیب برای داده های راداری و اپتیک استفاده شده است (شکل (۲)). از داده GRD^3 در مد IW^4 ماهواره سنتینل ۱ استفاده شده که این داده در دو پلاریزاسیون^۵ عمودی-عمودی و عمودی-افقی و در باند C برداشت می شود. توان تفکیک مکانی این داده ده متر در ده متر در هر دو پلاریزاسیون می باشد و توان

مصنوعی و با داده های سنجنش از دوری، شوری خاک را بررسی کردند که الگوریتم ماشین بردار پشتیبان نتیجه و دقت بهتری نسبت به شبکه عصبی مصنوعی داشته است [۲۶]. گیل و همکاران با استفاده از ماشین بردار پشتیبان، رطوبت خاک را برای چهار روز و هفت روز بعد پیش بینی کرده و نتیجه را با شبکه های عصبی مصنوعی مقایسه نمودند [۲۷]. گتاکو آیهو و همکاران با استفاده از ماشین بردار پشتیبان و با داده ی سنتینل ۱ رطوبت خاک را برآورد کردند و نشان دادند با ترکیب داده سنتینل ۱ با محصولات جانبی سنجنش از دور، می توان با دقت بهتری، رطوبت خاک را برآورد کرد [۲۸]. در بسیاری از تحقیق ها مزایایی از ماشین بردار پشتیبان نسبت به شبکه های عصبی مصنوعی بدست آمده و نظر بسیاری از محققان را به خود جلب کرده است [۲۶، ۲۹، ۳۰، ۳۱، ۳۲، ۳۳ و ۳۴]. ساختار و عملکرد ماشین بردار پشتیبان توسط محققین مختلفی بحث شده است [۴، ۲۷، ۳۵، ۳۶ و ۳۷].

هدف این پژوهش، مقایسه توانایی تصاویر سنتینل ۱ و سنتینل ۲ در برآورد رطوبت حجمی سطح خاک با استفاده از روش های داده محور شبکه عصبی مصنوعی چندلایه پرسپترون ($ANN-MLP$)^۱ و رگرسیون بردار پشتیبان (SVR)^۲ بوده است. در بخش نتیجه گیری، دقت و خطای محاسبه شده از دو روش با استفاده از تصاویر سنتینل ۱ و ۲ مقایسه و مورد بحث قرار گرفته است. برای بهینه سازی پارامترهای دو روش، از الگوریتم بهینه سازی ژنتیک^۲ استفاده شده است. این پژوهش شامل مراحل زیر است: در بخش اول مقدمه ارائه شده است. در بخش دوم منطقه مورد مطالعه و داده های مورد استفاده ارائه شده است. بخش سوم روش مورد استفاده در پژوهش، برای برآورد رطوبت سطحی خاک بیان شده است و سپس در بخش چهارم نتایج بدست آمده از دو روش و با استفاده از دو تصویر، آورده شده و نتایج

^۳ Ground Range Detected


^۴ Interferometry Wide

^۵ Polarization

^۱ Artificial Neural Networks Multi Layer Perceptron

^۲ Genetic Optimization Algorithm

تفکیک زمانی این داده، دوازده روز است.



شکل ۱: منطقه مورد مطالعه و نوع پوشش زمین [۳۸]

آنها در برآورد رطوبت حجمی سطح خاک با استفاده از روش‌های داده‌محور بوده است.

۲-۲-۲- داده میدانی

داده میدانی مورد استفاده در این تحقیق، داده SMAPVEX16^۴ اندازه‌گیری شده در تاریخ ۲۴ می ۲۰۱۶ تا ۲۲ جولای ۲۰۱۶ میلادی است. این داده از جنوب به عرض جغرافیایی ۴۹/۳۸، از شرق به طول جغرافیایی ۹۷/۷۵- و از غرب به طول جغرافیایی ۹۸/۱۰- می‌باشد و در بیش از ۵۰ مزرعه کشاورزی جمع‌آوری شده است (شکل (۱)). در این پژوهش از اطلاعات ۴۶ سایت استفاده شده است که در این ۴۶ سایت، رطوبت حجمی سطح خاک در عمق‌های پنج، ده و بیست سانتیمتر اندازه‌گیری و جمع‌آوری شده است. در این

داده GRD، دامنه ضریب پس‌پراکنش راداری را به عنوان پارامتر اصلی دارا می‌باشد که این پارامتر بسیار به ثابت دی‌الکتریک سطح حساس است. ماهواره سنسینل ۲ در محدوده اپتیک، در سیزده باند تصویربرداری انجام می‌دهد. توان تفکیک طیفی این داده از محدوده طیفی مرئی^۱ (VIS) و مادون قرمز نزدیک^۲ (NIR) تا مادون قرمز موج کوتاه^۳ (SWIR) را در بر می‌گیرند. توان تفکیک مکانی این باندها متغیر می‌باشد و به سه صورت ۱۰، ۲۰ و ۶۰ متر می‌باشند و توان تفکیک رادیومتری ۱۲ بیتی می‌باشد؛ یعنی قادر است انرژی دریافتی را بین ۰ تا ۴۰۹۵ ثبت کند.

جدول (۱) داده‌های مورد استفاده در تحقیق را بیان می‌کند. هدف از انتخاب این دو ماهواره مقایسه توانایی

^۱ Visible

^۲ Near-Infrared

^۳ Short Wave Infrared


^۴ Soil Moisture Active Passive Validation Experiment 2016

[۳۹]. نحوه توزیع نقاط میدانی استفاده شده در شکل (۱) مشخص شده است.

پژوهش از رطوبت حجمی سطح تا عمق پنج سانتی متر استفاده شده است. در طول این دوره، بیشتر محصولات از مرحله رشد تا مرحله سن بلوغ رشد می کنند [۳۸] و

جدول ۱: تصاویر استفاده شده

نام سنسور	تاریخ اخذ	گذر ماهواره
سنتینل ۱	۲۰۱۶/۰۷/۰۷	بالا گذر
سنتینل ۲	۲۰۱۶/۰۶/۱۰	پایین گذر



ب- تصویر ضریب پس پراکشت $\sigma_{VV}^{*}(db)$



الف- تصویر رنگی سنتینل ۲

شکل ۲: تصاویر سنتینل ۱ و ۲ از منطقه مورد مطالعه

تصاویر در هر دو روش استفاده شده است که باندهای بهینه تصویر چند طیفی سنتینل ۲ با استفاده از الگوریتم بهینه سازی ژنتیک انتخاب گردیده است. در شکل (۳) الگوریتم استفاده شده در پژوهش نشان داده شده است.

۳-۱- پیش پردازش و آماده سازی داده


این مرحله شامل دو بخش آماده سازی داده آموزشی و پردازش های لازم روی تصاویر خام است. داده های

۳- روش پیشنهادی

در این پژوهش رطوبت حجمی سطح خاک، با استفاده از دو روش شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP) و رگرسیون بردار پشتیبان (SVR) برآورد شده است که پارامترهای دو روش با استفاده از الگوریتم بهینه سازی ژنتیک بهینه سازی شده اند. همچنین برای مقایسه توانایی تصویر سنتینل ۱ و تصویر سنتینل ۲ در برآورد رطوبت حجمی سطح خاک، این

داده‌ها به تعداد ۳۰ نمونه به عنوان داده آموزشی استفاده شده است. در دو زیربخش بعدی پیش‌پردازش-های انجام گرفته بر تصاویر سنتینل ۱ و ۲ جهت آماده-سازی داده، آورده شده است.

اندازه‌گیری شده زمینی در قالب ماتریس‌های بردار ورودی و تارگت، ابتدا به صورت تصادفی به دو بخش داده آموزشی و تست جدا شده و در تمامی مراحل بعدی داده آموزشی و تست ثابت بوده است که ۳۵٪ داده‌ها به تعداد ۱۶ نمونه به عنوان داده تست و ۶۵٪



شکل ۳: الگوریتم استفاده شده در پژوهش

هندسه تصاویر را دچار اعوجاج می‌کنند، اعمال می-گردند. با استفاده از فیلتر گوسین^۱ نویز تصویر کاهش یافته است و مقادیر رفلکتانس^۲ نهایی برای ورودی دو روش آماده شده است. در نهایت باندهای بهینه برای

۳-۱-۱- پیش‌پردازش تصویر سنتینل ۲

تصویر سنتینل ۲ در مرحله اول، تصحیحات رادیومترکی و هندسی شده است. تصحیح رادیومترکی به منظور حذف و نرمال سازی عواملی که بر روی امواج الکترومغناطیسی رسیده به سنجنده اثر منفی گذاشته بر تصویر اعمال می‌شود، و تصحیح هندسی به منظور حذف و نرمال سازی عواملی است که

^۱ Gaussian

^۲ Reflectance

شبکه عصبی مصنوعی چندلایه پرسپترون آموزش داده می شوند که پارامترهای این مدل ها با استفاده از الگوریتم بهینه سازی ژنتیک بهینه می شوند.

الگوریتم بهینه سازی ژنتیک یک الگوریتم کارا برای پیدا کردن بهینه سراسری است. این الگوریتم با بهره وری از دو عملگر آمیزش^۳ و جهش^۴ با انتخاب مناسب ضرایب این عملگرها یک الگوریتم مناسب در پیدا کردن بهینه سراسری می باشد، که در صورت انتخاب نامناسب ضرایب ممکن است در بهینه محلی گیر کند. تابع برازش^۵ مهمترین بخش الگوریتم ژنتیک می باشد که در این پژوهش از مدل های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی چندلایه پرسپترون به عنوان تابع برازش استفاده می شود [۴۰]. این الگوریتم افراد موجود در جمعیت را بر اساس میزان شایستگی شان مرتب کرده و با استفاده از عملگرهایش جمعیت جدیدی تولید می کند، سپس با رویه تکراری تا برقرار شدن شرط الگوریتم این رویه ادامه خواهد داشت. در این پژوهش میزان شایستگی هر جواب، با استفاده از مقدار ضریب تعیین رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه گیری شده محاسبه شده است. ضریب تعیین نشان می دهد که چند درصد تغییرات متغیر وابسته به وسیله متغیر مستقل تبیین می شود که این ضریب پس از هر بار تکرار الگوریتم به عنوان پارامتر خروجی از تابع برازش برای هر جواب می باشد که نشان دهنده شایستگی جواب می باشد. ساختار و کارایی این الگوریتم بهینه سازی در تحقیقاتی مورد بحث و ارزیابی قرار گرفته است [۴۰، ۴۱ و ۴۲].

برای آموزش شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP)، به منظور بهینه سازی تعداد لایه ها، این مدل در الگوریتم ژنتیک به عنوان تابع برازش استفاده

استفاده در دو روش با استفاده از الگوریتم بهینه سازی ژنتیک انتخاب شده است.

۳-۱-۲- پیش پردازش تصویر سنتینل ۱

بر روی تصویر سنتینل ۱ نیز ابتدا تصحیحات رادیومتریکی و هندسی اعمال شده است. تصحیح هندسی به منظور از بین بردن اعوجاجات هندسی موجود در تصاویر اعمال می شود که دو نوع از تصحیحات مهم، یکی تبدیل برد مایل به برد زمینی و دیگری ترمیم هندسی^۱ می باشد و تصحیح رادیومتریکی به منظور کاهش اثرات اتمسفر بر امواج ثبت شده اعمال می شود. سپس با استفاده از فیلتر لی، نویز اسپکیولار^۲ تصویر کاهش یافته و در نهایت مقادیر ضریب پس-پراکنش با واحد دسی بل محاسبه شده است. از ضریب پس-پراکنش در پلاریزه های عمودی-عمودی و عمودی-افقی ($\sigma_{VV}^0, \sigma_{VH}^0$) و زاویه برخورد (θ) برای ورودی دو روش استفاده می شود. زاویه برخورد به دلیل تأثیر این پارامتر بر مقدار ضریب پس-پراکنش راداری ثبت شده در زوایای مختلف، به عنوان پارامتر ورودی استفاده شده است.

۳-۲- برآورد نقشه رطوبت حجمی سطح خاک

در مرحله پیش پردازش و در قسمت آماده سازی داده های اندازه گیری شده زمینی، ابتدا نمونه ها به صورت تصادفی به دو بخش داده آموزشی و تست جدا شده است که ۳۵٪ داده ها به تعداد ۱۶ نمونه به عنوان داده تست و ۶۵٪ داده ها به تعداد ۳۰ نمونه به عنوان داده آموزشی استفاده شدند. در تمامی مراحل بعدی به دلیل یکسان سازی شرایط برای دو روش و دو تصویر، داده آموزشی و تست ثابت بوده است؛ تا به صورت عادلانه توانایی روش ها و تصاویر در برآورد رطوبت حجمی سطح، مقایسه شوند. در این مرحله ابتدا با استفاده از داده های آموزشی، مدل های رگرسیون بردار پشتیبان و

^۳ Crossover

^۴ Mutation

^۵ Fitness function

^۱ Geometric rectification


^۲ Specular

تنظیم^۴ (C) ، P و پارامترهای هسته است. در این پژوهش از هسته تابع پایه شعاعی (RBF) ^۶ استفاده شده است که این هسته شامل پارامتر گاما (γ) است. پارامترهای رگرسیون بردار پشتیبان و هسته مورد استفاده باید بهینه شود در غیر اینصورت به دقت مطلوب نمی‌رسیم. اگر پارامتر C مقدار بزرگی باشد، دقت، در مرحله آموزش بالاست در حالی که معمولاً در مرحله تست دقت پایین می‌آید. اگر پارامتر C مقدار کوچک باشد، دقت نامطلوب است و مدل را بی‌فایده می‌کند. پارامتر هسته (γ) معمولاً تأثیر بیشتری نسبت به پارامتر C روی نتیجه کار دارد. اگر مقدار این پارامتر بزرگ انتخاب شود منجر به بیش‌برازش می‌شود، در حالی که مقدار کوچک آن منجر به کم‌برازش می‌شود. پارامترهای رگرسیون بردار پشتیبان، C ، P و γ با استفاده از الگوریتم بهینه‌سازی ژنتیک بهینه شده است. رمزگذاری این پارامترها برای ورود به الگوریتم بهینه‌سازی ژنتیک، اعداد حقیقی بوده و از روش‌های صاف^۷ و گاوسین^۸ به ترتیب برای عملگرهای آمیزش و جهش استفاده شده است. ساختار و کارایی رگرسیون بردار پشتیبان در تحقیقات گذشته بحث و ارزیابی شده است [۴، ۲۷، ۳۵، ۳۶ و ۳۷]. شمای کلی رگرسیون بردار پشتیبان در شکل (۵) آورده شده به طوری که خط-چین‌ها، بردارهای پشتیبان می‌باشند و فاصله بین خط-چین‌ها و خط قرمز با استفاده از پارامتر تنظیم و میزان تغییر ابعاد ویژگی‌ها به فضای هسته، توسط پارامتر هسته مشخص می‌شود. در شکل (۵)، داده‌ها از فضای حقیقی ویژگی‌های ورودی به فضای هسته (φ) به ابعاد بالاتر رفته و مدل‌سازی صورت گرفته است.


شده است. در روش $ANN-MLP$ از تابع فعال‌ساز تانژانت هایپربولیک سیگموئید^۱ استفاده گردیده و برای آموزش شبکه از روش پس‌انتشار خطا^۲ استفاده شده است. شبکه عصبی مصنوعی به تعداد لایه‌های مخفی حساس است به طوری که با زیاد شدن لایه‌ها، بیش-برازش رخ داده و باعث کم شدن دقت مقدار برآورد شده، می‌شود. تعداد لایه‌ها در این پژوهش با استفاده از الگوریتم بهینه‌سازی ژنتیک بهینه شده است که رمزگذاری تعداد لایه‌ها به صورت رشته‌ای از صفر و یک صورت گرفته است و بهترین جواب بدست آمده برای دو تصویر در بخش نتایج و بحث آورده شده است. ساختار دقیق و کارایی شبکه عصبی مصنوعی چندلایه پرسپترون توسط محققان زیادی مورد بحث و ارزیابی قرار گرفته است [۱۸، ۱۹، ۲۰، ۲۲، ۲۳ و ۲۴]. شکل (۴) شمای کلی شبکه‌های عصبی مصنوعی چندلایه پرسپترون را نشان می‌دهد که از سه بخش اصلی، لایه‌ی ویژگی‌های ورودی، لایه پنهان و لایه خروجی تشکیل می‌شود. وزن و بایاس^۳ در شبکه‌های عصبی مصنوعی باید آموزش داده شوند که در این پژوهش از روش پس‌انتشار خطا برای آموزش وزن و بایاس شبکه استفاده شده است.

رگرسیون بردار پشتیبان، مدل بسیار کارا و مفید برای حل مسائل داده‌مبنا است که رابطه‌ای میان بردار ورودی و خروجی برقرار می‌کند [۲۷]. این مدل از بردارهای پشتیبان استفاده می‌کند و برای حل مسائل غیرخطی و پیچیده از فضای هسته برای جداسازی و برازش بهتر استفاده می‌کند؛ بدین ترتیب که داده را با استفاده از تابع هسته به ابعاد بزرگتر (فضای هیلبرت) برده و با استفاده از بردارهای پشتیبان برازش انجام می‌شود. رگرسیون بردار پشتیبان دارای پارامترهای

^۴ Penalty^۵ Loss function parameter^۶ Radial Basis Function^۷ Flat-crossover^۸ Gaussian-mutation^۱ Sigmoid hyperbolic tangent^۲ Backpropagation^۳ Bias



شکل ۴: شمای کلی شبکه های عصبی مصنوعی چندلایه پرسپترون



شکل ۵: شمای کلی رگرسیون بردار پشتیبان

۳-۳- اعتبارسنجی روش ها برای برآورد رطوبت

حجمی سطح خاک

برای اعتبارسنجی نقشه های تولیدشده، از پارامترهای

آماري ضريب تعيين (R^2) و جذر میانگین مربع خطا ($RMSE$) استفاده شده است. روابط پارامترهای R^2 و $RMSE$ بترتیب در رابطه (۱) و (۲) آورده شده است.

$$R^2 = \frac{SSR}{SST} = \frac{SST - SSE}{SST} = 1 - \frac{SSE}{SST} = 1 - \frac{\sum_{i=1}^n (y_i - O_i)^2}{\sum_{i=1}^n (O_i - \mu_o)^2} \quad \text{رابطه (۱)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - O_i)^2}{n-1}} \quad \text{رابطه (۲)}$$

پارامتر مستقل را نشان می دهد.

۴- نتایج و بحث

در این بخش ابتدا نمودارهای الگوریتم ژنتیک به همراه بهترین جواب پارامترهای بهینه شده در شکل (۶) آورده شده است. تمام نمودارها با شرط حداکثر ۵۵ نسل اجرا شده است که در این ۵۵ نسل بهترین جواب از کل نسل ها انتخاب گردیده است. همچنین از ضریب تعیین (R^2) و جذر میانگین مربع خطا ($RMSE$) به عنوان شروط استفاده شده است. چون الگوریتم ژنتیک با شرط کمینه کردن شروط تابع برازش اجرا گردیده و R^2 به عنوان دقت تابع برازش می باشد، از کمینه کردن

پارامتر SST مجموع توان دوم خطا می باشد زمانی که از متغیر مستقل استفاده نشود و پارامتر SSE مجموع توان دوم خطا می باشد زمانی که از متغیرهای مستقل استفاده شود. پارامتر SSR مجموع توان دوم رگرسیون می باشد و کاهش در مجموع توان دوم، خطا به دلیل استفاده از متغیرهای مستقل را نشان می دهد. هر چه SSR بزرگتر باشد بهتر است و اگر $SSR = 0$ باشد رابطه رگرسیونی اصلاً کاربرد نداشته است. ضریب تعیین نشان می دهد که چند درصد تغییرات متغیر وابسته به وسیله متغیر مستقل تبیین می شود و جذر میانگین مربع خطا، میانگین اختلاف پارامتر وابسته با

۶۶۵، ۷۸۳، ۸۶۵، ۱۶۱۰ و ۲۱۹۰ نانومتر می‌باشند و توان تفکیک مکانی باندهای ۲ و ۴ ده متر و باندهای ۷، ۸A، ۱۱ و ۱۲ بیست متر می‌باشد (جدول (۲)).

۴-۲- نقشه‌های رطوبت حجمی سطح خاک

در شکل (۸) نقشه‌های رطوبت حجمی سطح خاک برآورد شده با استفاده از رگرسیون بردار پشتیبان (SVR) و شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP)، برای دو نوع داده آورده شده است. دقت هر نقشه با مربع ضریب همبستگی رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه‌گیری شده (R^2) و جذر میانگین مربعات خطا^۳ (RMSE) بیان شده است.

۴-۲-۱- نقشه‌های رطوبت حجمی سطح خاک برآورد شده با استفاده از شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP)

نقشه رطوبت حجمی سطح خاک از روش شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP) با استفاده از تصاویر سنیتیل ۱ و سنیتیل ۲، برآورد شده است (شکل (۸-الف و ۸-ب)). مربع ضریب همبستگی رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه‌گیری شده در این روش (R^2) برای تصاویر سنیتیل ۱ و سنیتیل ۲ به ترتیب ۰/۶۱۸ و ۰/۴۰۹ بدست آمده است. این مقادیر نشان می‌دهند در روش ANN-MLP وابستگی تصاویر سنیتیل ۱ و سنیتیل ۲ به رطوبت حجمی سطح خاک به ترتیب ۶۲٪ و ۴۱٪ می‌باشد. تصویر سنیتیل ۱ دقت بهتری در برآورد رطوبت حجمی سطح داشته است که نشان‌دهنده وابستگی بیشتر اطلاعات و ویژگی‌های تصویر سنیتیل ۱ به پارامتر رطوبت حجمی سطح خاک است. جذر میانگین مربع خطا (RMSE) نیز در این روش برای تصاویر سنیتیل ۱ و سنیتیل ۲ به ترتیب ۰/۱۴۴۹ و ۰/۳۶۱۲ برآورد شده است (جدول (۳)).

$1 - R^2$ و RMSE برای شروط الگوریتم ژنتیک استفاده شد. در بخش بعدی نتایج روش‌های رگرسیون بردار پشتیبان (SVR) و شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP) با استفاده از تصاویر سنیتیل ۱ و ۲ آورده شده است و در بخش آخر نتایج مورد بحث و ارزیابی قرار گرفته است.



۴-۱- نمودارهای الگوریتم ژنتیک به منظور بهینه‌سازی پارامترها و آموزش مدل‌ها

در این بخش نمودارهای الگوریتم ژنتیک که به منظور بهینه‌سازی پارامترهای روش‌های ANN-MLP و SVR مورد استفاده قرار گرفته؛ آورده شده است. محور افقی نمودارها، نسل‌ها و محور عمودی نمودارها، دقت هر روش برای هر تصویر را برحسب ضریب تعیین ($1 - R^2$) نمایش می‌دهد (شکل (۶)). رمزگذاری^۱ تعداد لایه‌های روش ANN-MLP، با استفاده از رشته صفر و یک^۲ انجام شده است که با توجه به شکل (۶-الف) و شکل (۶-ب) تعداد لایه‌های مخفی ANN-MLP برای تصویر سنیتیل ۲ و سنیتیل ۱ به ترتیب ۳ و ۵ برآورد شده است (جدول (۲)). رمزگذاری پارامترهای روش SVR، اعداد حقیقی بوده است که با توجه به شکل (۶-ج) و شکل (۶-د) پارامترهای P ، C و γ (g) برای تصاویر سنیتیل ۲ و سنیتیل ۱ در جدول (۲) آورده شده است. در شکل (۷) نمودار بهینه‌سازی انتخاب باند تصویر سنیتیل ۲ در ۵۵ نسل و همچنین بهترین جواب برای آن آورده شده است که محور افقی، شماره باند را نشان می‌دهد. انتخاب باندهای بهینه تصویر سنیتیل ۲ ابتدا با استفاده از روش SVR انجام و سپس از باندهای بهینه در دو روش برای بهینه‌سازی پارامترها و برآورد نقشه رطوبت استفاده شده است. رمزگذاری در انتخاب باندهای بهینه به صورت صفر و یکی انجام می‌شود. باندهای ۲، ۴، ۷، ۸A، ۱۱ و ۱۲ به عنوان باندهای بهینه انتخاب شده اند که به ترتیب دارای طول موج ۴۹۰،



^۱ Encoding

^۲ Binary string



^۳ Root Mean Square Error





ب- نمودار بهینه‌سازی تعداد لایه ANN-MLP برای تصویر سنتینل ۱



الف- نمودار بهینه‌سازی تعداد لایه ANN-MLP برای تصویر سنتینل ۲



د- نمودار بهینه‌سازی پارامترهای SVR برای تصویر سنتینل ۱




ج- نمودار بهینه‌سازی پارامترهای SVR برای تصویر سنتینل ۲

شکل ۶: نمودارهای الگوریتم ژنتیک به منظور بهینه‌سازی (محور افقی نمودارهای الگوریتم ژنتیک، تعداد نسل ها و محور عمودی نمودارها دقت می‌باشد و زیر نمودارهای الف و ب بهترین تعداد لایه بهینه شده روش ANN-MLP می‌باشد که رمزگذاری آن به صورت رشته‌ای از صفر و یک می‌باشد و زیر نمودارهای ج و د بهترین مقدار پارامترهای بهینه شده روش SVR است که رمزگذاری آن به صورت اعداد حقیقی می‌باشد.)

جدول ۲: پارامترهای بهینه‌سازی شده با استفاده از الگوریتم ژنتیک

الگوریتم	پارامترها	سنتینل ۲	سنتینل ۱
SVR	C	۱۳۸۳۶۲۷	۱۰۷۹۱۱۱
	P	۰٫۰۱۶۵۲	۰٫۰۱۰۰۹
	γ	۰٫۰۰۲۵۵۳۶۴	۰٫۰۰۵۵۲۷۶۷
ANN-MLP	تعداد لایه‌های بهینه	۳	۵
SVR	شماره باندهای بهینه	۱۲، ۱۱، ۸، ۷، ۴، ۲	-



شکل ۷: نمودار بهینه‌سازی انتخاب باند سنتینل ۲ - (محور افقی نمودار الگوریتم ژنتیک، تعداد نسل‌ها و محور عمودی دقت بر حسب ضریب تعیین می‌باشد. - محور افقی بهترین جواب شماره باند سنجنده را نشان می‌دهد.)

سطح خاک، به ترتیب ۶۶٪ و ۴۳٪ برآورد کرده است. در این روش نیز همانند روش شبکه عصبی مصنوعی چندلایه پرسپترون، تصویر سنتینل ۱ دقت بهتری در برآورد رطوبت حجمی سطح داشته است که نشان‌دهنده وابستگی بیشتر اطلاعات و ویژگی‌های تصویر سنتینل ۱ به پارامتر رطوبت حجمی سطح خاک است. با توجه به ماهیت راداری تصویر سنتینل ۱ و حساسیت بالای پراکنش راداری به ثابت دی‌الکتریک و در نتیجه آن به رطوبت سطحی خاک، در هر دو روش تصویر سنتینل ۱ دقت بهتری داشته است. جذر میانگین مربعات خطا (RMSE) در این روش برای

۴-۲-۲- نقشه‌های رطوبت حجمی سطح خاک برآورد شده با استفاده از رگرسیون بردار پشتیبان (SVR)

در شکل (۸-ج) و شکل (۸-د)، نقشه برآورد شده رطوبت حجمی سطح خاک تا عمق ۵ سانتی‌متر از روش رگرسیون بردار پشتیبان (SVR) با استفاده از تصاویر سنتینل ۱ و سنتینل ۲ نشان داده شده است. ضریب تعیین (R^2) برای تصاویر سنتینل ۱ و سنتینل ۲ به ترتیب ۶۵۹٪ و ۴۳۳٪ بدست آمده است. با توجه به این مقادیر، روش SVR، وابستگی اطلاعات و ویژگی‌های تصاویر سنتینل ۱ و سنتینل ۲ را به رطوبت حجمی

تصاویر سنیتل ۱ و سنیتل ۲ محاسبه و در جدول (۳) آورده شده است.


جدول ۳: اعتبارسنجی نقشه های رطوبت

روش	تصویر	R^2	$RMSE(\frac{m^3}{m^3})$
ANN-MLP	سنیتل ۱	۰/۶۱۸	۰/۳۰۱
	سنیتل ۲	۰/۴۰۹	۰/۴۶۱۲
SVR	سنیتل ۱	۰/۶۵۹	۰/۲۹۱
	سنیتل ۲	۰/۴۳۳	۰/۴۲۱۱

۳-۴- بحث و گفتگو

هدف اصلی پژوهش برآورد نقشه رطوبت سطح خاک تا عمق ۵ سانتی متر از دو روش شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP) و رگرسیون بردار پشتیبان (SVR) بوده است که بدین منظور از تصاویر سنیتل ۱ و سنیتل ۲ استفاده شده است. با توجه به ضریب تعیین (R^2) بدست آمده (شکل ۸)، روش SVR در هر دو تصویر سنیتل ۱ و سنیتل ۲ دقت بهتری نسبت به روش ANN-MLP داشته است. در هر دو روش تصویر سنیتل ۱ دقت بالاتری نسبت به تصویر سنیتل ۲ داشته است که این نشانگر آن است که

ویژگی های تصویر سنیتل ۱ نسبت به ویژگی های تصویر سنیتل ۲، رابطه معنادارتری نسبت به رطوبت سطح خاک دارد. این نتیجه نشان می دهد که اطلاعات موجود در تصویر راداری به رطوبت حجمی سطح خاک بیشتر حساس می باشد؛ البته این موضوع را باید در نظر بگیریم که ماهواره سنیتل ۲ فاقد باند حرارتی است. باند حرارتی یکی از حساس ترین باندهای ماهواره های غیرفعال به رطوبت سطح خاک می باشد. روش هایی برای برآورد رطوبت سطح خاک با استفاده از شاخص های پوشش گیاهی و باندهای حرارتی ارائه شده است.




شکل ۸: نقشه های رطوبت حجمی سطح خاک برآورد شده


۵- نتیجه گیری

با توجه به نتایج و مقایسه دقت‌های محاسبه شده در این پژوهش می‌توان گفت، دقت روش رگرسیون بردار پشتیبان (SVR) از روش شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP) برای برآورد رطوبت حجمی سطح خاک برای هر دو تصویر سنتینل ۱ و سنتینل ۲ بهتر بوده است. تصویر سنتینل ۱ با توجه به حساسیت بالای ضریب پس‌پراکنش راداری به تغییرات ثابت دی‌الکتریک، و همچنین حساسیت بالای ثابت دی‌الکتریک به رطوبت، نسبت به تصویر سنتینل ۲ برای برآورد رطوبت حجمی سطح خاک دارای دقت بهتری می‌باشد. در کل با توجه به بخش نتایج و بحث و با مقایسه چهار خروجی بدست آمده و دقت‌های محاسبه شده از آنها، بهترین دقت در این پژوهش از روش SVR با استفاده از تصویر سنتینل ۱ و بدترین دقت از روش ANN-MLP با استفاده از تصویر سنتینل ۲ بدست آمده است. یکی از دلایل دقت‌های پایین تصویر سنتینل ۲، نداشتن باند حرارتی است. توان تفکیک طیفی این سنجنده از محدوده طیفی مرئی (VIS) و مادون قرمز نزدیک (NIR) تا مادون قرمز موج کوتاه (SWIR) را در بر می‌گیرد. یکی از باندهای بسیار کارا و حساس به رطوبت سطح خاک در سنجنده‌های غیرفعال، باندهای حرارتی بوده که با کمک شاخص‌های گیاهی برای برآورد رطوبت استفاده می‌شوند. در نهایت پیشنهاد می‌شود از تصویر سنتینل ۲ به تنهایی برای برآورد رطوبت حجمی سطح استفاده نشود ولی با توجه به ویژگی ماهواره سنتینل ۲ در برآورد دقیق نوع پوشش زمین با توان تفکیک مکانی مناسب، می‌توان از ویژگی‌های این ماهواره به عنوان داده کمکی در کنار تصاویر رادار برای بهبود دقت استفاده کرد.


با مقایسه نمودارهای الگوریتم ژنتیک شکل (۶) بین دو روش می‌توان نتیجه گرفت که روش SVR زودتر به دقت‌های بهتر همگرا می‌شود. این روش پس از گذشت تقریباً ۴۰ الی ۴۵ نسل تقریباً به بهترین دقت رسیده است و همچنین مقایسه نمودارهای بین دو تصویر، همگرایی بهتر و زودتر تصویر سنتینل ۱ به دقت‌های بهتر را نسبت به تصویر سنتینل ۲ نشان می‌دهند که بیانگر حساسیت بالای ضریب پس‌پراکنش راداری به رطوبت حجمی سطح خاک می‌باشد (شکل (۶)). با توجه به نقشه‌های رطوبت حجمی سطح خاک (شکل (۸)) و نمودار همبستگی رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه‌گیری شده (شکل (۹)) می‌توان گفت که روش ANN-MLP مقادیر رطوبت حجمی سطح خاک تا عمق ۵ سانتی‌متر را بیشتر از مقادیر حقیقی و اندازه‌گیری شده برآورد می‌کند، در صورتی که روش SVR مقادیر برآورد شده را کمتر از مقادیر حقیقی و اندازه‌گیری شده برآورد کرده است. در روش SVR با استفاده از تصویر سنتینل ۱، ضریب تعیین ۰/۶۵۹ و با استفاده از تصویر سنتینل ۲، ضریب تعیین ۰/۴۳۳ محاسبه شده است. این ضریب نشان می‌دهد که چند درصد تغییرات اطلاعات موجود در تصاویر به وسیله رطوبت حجمی سطح خاک تبیین می‌شود یا به عبارت دیگر ضریب تعیین نشانگر این است که چه مقدار از تغییرات متغیر وابسته (اطلاعات موجود در تصاویر) تحت تأثیر متغیر مستقل مربوطه (رطوبت حجمی سطح خاک) بوده و مابقی تغییرات متغیر وابسته مربوط به سایر عوامل می‌باشد. ضریب تعیین در روش ANN-MLP با استفاده از تصویر سنتینل ۱ ۰/۶۱۸ و با استفاده از تصویر سنتینل ۲ ۰/۴۰۹ محاسبه شده است. با توجه به دقت‌های محاسبه شده، اطلاعات موجود در تصویر سنتینل ۱، وابستگی بیشتری به رطوبت حجمی سطح خاک نسبت به تصویر سنتینل ۲ دارد.




ب- نمودار همبستگی روش ANN-MLP برای تصویر سنتینل ۱



الف- نمودار همبستگی روش ANN-MLP برای تصویر سنتینل ۲



د- نمودار همبستگی روش SVR برای تصویر سنتینل ۱



ج- نمودار همبستگی روش SVR برای تصویر سنتینل ۲

شکل ۹: نمودارهای همبستگی رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه گیری شده (محور افقی نمودارها رطوبت اندازه گیری شده در سطح زمین و نمودار عمودی رطوبت برآورد شده از روش های می باشد).

مراجع

- [1] Pathe C, Wagner W, Sabel D, Doubkova M, Basara JB, "Using ENVISAT ASAR global mode data for surface soil moisture retrieval over Oklahoma, USA", *IEEE Transactions on Geoscience and Remote*

Sensing, 3;47(2):468-80, 2009.

- [2] Western AW, Grayson RB, "The Tarrawarra data set: Soil moisture patterns, soil characteristics, and hydrological flux measurements", *Water*

- Resources Research, 34(10):2765-8, 1998.
- [3] Lunt IA, Hubbard SS, Rubin Y, "Soil moisture content estimation using ground-penetrating radar reflection data", *Journal of hydrology*, 9;307(1-4):254-69, 2005.
- [4] Narayan U, Lakshmi V, "High resolution change detection using TMI-PR and AMSR-E soil moisture data", *Water Resources Res*, 44: W06425, 2008.
- [5] Njoku EG, Jackson TJ, Lakshmi V, Chan TK, Nghiem SV, "Soil moisture retrieval from AMSR-E", *IEEE transactions on Geoscience and remote sensing*, 41(2):215-29, 2003.
- [6] Baup F, Mougin E, De Rosnay P, Timouk F, Chênerie I. Surface soil moisture estimation over the AMMA Sahelian site in Mali using ENVISAT/ASAR data. *Remote Sensing of Environment*, 109(4):473-81, 2007.
- [7] Behari J. "Microwave dielectric behaviour of wet soils", *Springer Science & Business Media*; 2006.
- [8] Zhuo, L.; Han, D, "The relevance of soil moisture by remote sensing and hydrological modelling", *Procedia Eng*, 154, 1368-1375, 2016.
- [9] Schmugge TJ. "Remote sensing of soil moisture: Recent advances. *IEEE Transactions on Geoscience and Remote Sensing*, (3):336-44, 1983.
- [10] Rawat KS, Sehgal VK, Pradhan S, Ray SS, "Semi-empirical model for retrieval of soil moisture using RISAT-1 C-Band SAR data over a sub-tropical semi-arid area of Rewari district, Haryana (India)", *Journal of Earth System Science*, 1;127(2):18, 2018.
- [11] Das NN, Mohanty BP, Cosh MH, Jackson TJ, "Modeling and assimilation of root zone soil moisture using remote sensing observations in Walnut Gulch Watershed during SMEX04", *Remote Sensing of Environment*, 15;112(2):415-29, 2008.
- [12] Zhang T, Jiang L, Zhao S, Chai L, Li Y, Pan Y, "Development of a Parameterized Model to Estimate Microwave Radiation Response Depth of Frozen Soil", *Remote Sensing*, 11(17):2028, 2019.
- [13] Shi J, Wang J, Hsu AY, O'Neill PE, Engman ET, "Estimation of bare surface soil moisture and surface roughness parameter using L-band SAR image data", *IEEE Transactions on Geoscience and Remote Sensing*, 35(5):1254-66, 1997.
- [14] Li J, Wang S. "Using SAR-Derived Vegetation Descriptors in a Water Cloud Model to Improve Soil Moisture Retrieval". *Remote Sensing*. 10(9):1370, 2018.
- [15] Baghdadi N, Choker M, Zribi M, Hajj M, Paloscia S, Verhoest N, Lievens H, Baup F, Mattia F. "A new empirical model for radar scattering from bare soil surfaces". *Remote Sensing*. 8(11):920, 2016.
- [16] Woodhouse IH, Hoekman DH. "A model-based determination of soil moisture trends in Spain with the ERS-scatterometer". *IEEE transactions on geoscience and remote sensing*. 38(4):1783-93, 2000.
- [17] Adeyemi O, Grove I, Peets S, Domun Y, Norton T. "Dynamic neural network modelling of soil moisture content for predictive irrigation scheduling". *Sensors*. 18(10):3408, 2018.
- [18] Hsu KL, Gupta HV, Sorooshian S. "Artificial neural network modeling of the rainfall - runoff process". *Water resources research*. 31(10):2517-30, 1995.
- [19] Sharaf El Din E, Zhang Y, Suliman A. "Mapping concentrations of surface water quality parameters using a novel remote sensing and artificial intelligence framework". *International journal of remote sensing*. 38(4):1023-42, 2017.
- [20] Feng Y, Cui N, Hao W, Gao L, Gong D. "Estimation of soil temperature from meteorological data using different machine learning models". *Geoderma*. 338:67-77, 2019.
- [21] Chang FJ, Chen YC. "A

- counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction". *Journal of hydrology*. 245(1-4):153-64, 2001.
- [22] Abu Qdais H, Shatnawi N. "Assessing and predicting landfill surface temperatura using remote sensing and an artificial neural network". *International Journal of Remote Sensing*. 2019.
- [23] Holloway J, Mengersen K. "Statistical machine learning methods and remote sensing for sustainable development goals: A review". *Remote Sensing*. 10(9):1365, 2018.
- [24] Haykin S. "Neural networks: a comprehensive foundation. Prentice" Hall PTR, 1994.
- [25] Gao Q, Zribi M, Escorihuela M, Baghdadi N. "Synergetic use of Sentinel-1 and Sentinel-2 data for soil moisture mapping at 100 m resolution". *Sensors*. Sep;17(9):1966.
- [26] Jiang H, Rusuli Y, Amuti T, He Q, "Quantitative assessment of soil salinity using multi-source remote sensing data based on the support vector machine and artificial neural network", *International journal of remote sensing*, 40(1):284-306, 2019.
- [27] Gill MK, Asefa T, Kemblowski MW, McKee M. "Soil moisture prediction using support vector machines I". *JAWRA Journal of the American Water Resources Association*. Aug;42(4):1033-46, 2006.
- [28] Ayehu G, Tadesse T, Gessesse B, Yigrem Y. "Soil Moisture Monitoring Using Remote Sensing Data and a Stepwise-Cluster Prediction Model: The Case of Upper Blue Nile Basin, Ethiopia". *Remote Sensing*. Jan;11(2):125, 2019.
- [29] Kalra A, Ahmad S. "Using oceanic - atmospheric oscillations for long lead time streamflow forecasting". *Water Resources Research*. Mar;45(3), 2009.
- [30] Khalil AF, McKee M, Kemblowski M, Asefa T, Bastidas L. "Multiobjective analysis of chaotic dynamic systems with sparse learning machines". *Advances in Water Resources*. Jan 1;29(1):72-88, 2006.
- [31] Raczek E, Zagajewski B. "Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images". *European Journal of Remote Sensing*. Jan 1;50(1):144-54, 2017.
- [32] Tripathi S, Srinivas VV, Nanjundiah RS. "Downscaling of precipitation for climate change scenarios: a support vector machine approach", *Journal of hydrology*. Nov 15;330(3-4):621-40, 2006.
- [33] Zeng W, Zhang D, Fang Y, Wu J, Huang J. "Comparison of partial least square regression, support vector machine, and deep-learning techniques for estimating soil salinity from hyperspectral data", *Journal of Applied Remote Sensing*. Jan;12(2):022204, 2018.
- [34] Aboutalebi M, Allen LN, Torres-Rua AF, McKee M, Coopmans C. "Estimation of soil moisture at different soil levels using machine learning techniques and unmanned aerial vehicle (UAV) multispectral imagery. In Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping", *International Society for Optics and Photonics IV*, (Vol. 11008, p. 110080S), 2019.
- [35] Lin JY, Cheng CT, Chau KW. "Using support vector machines for long-term discharge prediction", *Hydrological Sciences Journal*. 51(4):599-612, 2006.
- [36] Roodposhti MS, Safarrad T, Shahabi H. "Drought sensitivity mapping using two one-class support vector machine algorithms". *Atmospheric research*, 193:73-82, 2017.
- [37] Were K, Bui DT, Dick ØB, Singh BR. "A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping

soil organic carbon stocks across an Afromontane landscape". *Ecological Indicators*. 52:394-403, 2015.

[38] Wang H, Magagi R, Goïta K, Trudel M, McNairn H, Powers J. "Crop phenology retrieval via polarimetric SAR decomposition and Random Forest algorithm". *Remote Sensing of Environment*. Sep 15; 231:111234, 2019.

[39] McNairn, H., K. Gottfried, and J. Powers. SMAPVEX16 Manitoba Core-Based in Situ Soil Moisture Data, Version 1. [Indicate subset used]. Boulder, Colorado USA. NASA National Snow and Ice Data Center Distributed Active Archive Center. 2018. doi: <https://doi.org/10.5067/D4YA3124Y3BR>. [Date Accessed].

[40] Holland JH. *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. MIT press; 1992.

[41] Bandyopadhyay S, Maulik U, Mukhopadhyay A, "Multiobjective genetic clustering for pixel classification in remote sensing imagery", *IEEE transactions on Geoscience and Remote Sensing*, 45(5):1506-11, 2007.

[42] Ghamisi P, Benediktsson JA. Feature selection based on hybridization of genetic algorithm and particle swarm optimization. *IEEE Geoscience and remote sensing letters*, 12(2):309-13, 2014.

[43] Ulaby, F. T., Batlivala, P. P., & Dobson, M. C. "Microwave backscatter dependence on surface roughness, soil moisture, and soil texture: part I-bare soil", *IEEE Transactions on Geoscience Electronics*, 16(4), 286-295, 1978.



Volumetric soil moisture estimation using Sentinel 1 and 2 satellite images

Sadegh Ranjbar¹, Mahdi Akhoondzadeh^{2*}

- 1- MS.c student, Remote Sensing Division, Faculty of Surveying and Geospatial Engineering, College of Engineering, University of Tehran.
- 2- Assistant Professor, Remote Sensing Division, Faculty of Surveying and Geospatial Engineering, College of Engineering, University of Tehran.

Abstract

Surface soil moisture is an important variable that plays a crucial role in the management of water and soil resources. Estimating this parameter is one of the important applications of remote sensing. One of the remote sensing techniques for precise estimation of this parameter is data-driven models. In this study, volumetric soil moisture content was estimated using data-driven models, support vector regression (SVR) and multi-layer perceptron artificial neural network (ANN-MLP) method. The parameters of the two models are optimized by the Genetic optimization algorithm. Estimation of volumetric soil moisture content with the two top models was performed using two types of radar image (Sentinel 1) and optics image (Sentinel 2), in which optimized optics image bands were identified by the Genetic optimization algorithm. After estimating the volumetric soil moisture map, four outputs of the two methods are compared. The best estimate of the volumetric soil moisture content has been achieved by the support vector regression (SVR) method with the Sentinel 1 image. The worst estimate of the volumetric soil moisture content has been achieved by the multi-layer perceptron artificial neural network (ANN-MLP) method with the Sentinel 2 image. The accuracy of this study was calculated by the square of correlation coefficient of the measured volumetric soil moisture content and the estimated volumetric soil moisture content, which the best and worst correlation coefficients, respectively, 0.659 for Sentinel1 image using support vector regression method and 0.409 for Sentinel2 image using multilayer perceptron neural network method have been calculated. The root mean square error (RMSE) is also used to calculate the error of the methods. The lowest and highest errors were calculated by $0.291(\frac{m^3}{m^3})$ for Sentinel1 image with support vector regression and $0.4612(\frac{m^3}{m^3})$ for Sentinel2 image with Multilayer Perceptron Artificial Neural Network.

Key words: Soil Moisture, Sentinel 1 & 2, Artificial Neural Network, Support Vector Regression, Genetic Optimization Algorithm.