شربه علمی بژو^مشی مهندسی فناوری اطلاعات مکانی

سال هفتم، شماره چهارم، زمستان ۱۳۹۸ Vol.7, No.4, Winter 2020 ۲۱۰ – ۲۳۲ مقاله پژوهشی



بر آورد رطوبت سطح خاک با استفاده از روش های SVR و ANN در تصاویر ماهوارههای سنتینل ۱ و ۲

صادق رنجبر'، 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 نقشه¬برداری و اطلاعات مکانی، پردیس دانشکده¬های فنی، دانشگاه تهران

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

چکیدہ

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 سنتینل ۱ و سنتینل ۲ انجام شده است؛ که باندهای بهینه تصویر سنتینل ۲ با استفاده از الگوریتم بهینهسازی ژنتیک مشخص شدهاند. پس از برآورد نقشه رطوبت حجمی سطح خاک از دو روش با استفاده از تصاویر سنتینل ۱ و سنتینل ۲، چهار خروجی با یکدیگر مقایسه شدهاند. بس از برآورد رطوبت حجمی سطح خاک از دو روش با استفاده از تصویر سنتینل ۲، چهار خروجی با یکدیگر مقایسه شدهاند. بس از برآورد رطوبت حجمی سطح خاک با روش رگرسیون بردار پشتیبان با استفاده از سنتینل ۲، چهار خروجی با یکدیگر مقایسه شدهاند. بس از مرفوبت حجمی سطح خاک با روش رگرسیون بردار پشتیبان با استفاده از سنتینل ۱ بهترین دقت و برآورد این پارامتر با روش شبکه عصبی مصنوعی چندلایه پرسپترون با استفاده از تصویر سنتینل ۲ بو داشته است. دقت در این پژوهش با استفاده از مربع ضریب همبستگی رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه گیری شده (²R) محاسبه شده است که بهترین و بدترین ضریب همبستگی به ترتیب، ۱۵۶۹ برای تروی شده و رطوبت حجمی سطح خاک بردار پشتیبان و ۴۰۹٫۰ برای تصویر سنتینل ۲ با روش شبکه عصبی مصنوعی چند لایه پرسپترون بدست آمده است. دریشه میانگین مربع خطا برای ارزیابی روش ها استفاده شده است که کمترین و بیشترین خطا به ترتیب ($\frac{m_3}{m}$) ۱۲۹۱٬ برای روش رگرسیون بردار پشتیبان با روش رگرسیون بردار پشتیبان با مروش رگرسیون بردار پشتیبان با مویر سنتینل ۱ و ($\frac{m_3}{m}$) ۲۹۱٬ برای روش شبکه عصبی مصنوعی چند لایه پرسپترون بدست آمده است. در میه میانگین مربع

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

["] نویسنده مکاتبه کننده: تهران-خیابان کارگر شمالی-بالاتر از تقاطع جلال آل احمد-دانشکده فنی دانشگاه تهران-دانشکده مهندسی نقشه برداری و اطلاعات مکانی. تلفن: ۲۱۶۱۱۱۴۵۲۲

سال هفتم • شماره چهارم • زمستان ۱۳۹۸

۱– مقدمه

رطوبت خاک، به ویـژه رطوبت سـطحی خـاک^۱ نقـش ببسـیار مهمـی در مـدیریت منـابع آب و خـاک دارد. بنـابراین بررسـی وضـعیت پارامترهـای خـاک بـرای هیـدرولوژی، هواشناسـی، اقلـیمشناسـی، کشـاورزی و بسیاری از علوم زمینی مناسب است [۱]. برآورد دقیـق رطوبت خاک عامل مهمی در این مطالعات است. تنـوع در عواملی همچون بافت خـاک، زبـری سـطح خـاک و پوشش گیاهی باعث تغییر رطوبت خاک مـیشـود [۲ و شود. جستجو برای یافتن روش های نوین و سریع بـرای برآورد رطوبت سطحی خـاک باعـث افـزایش تحقیقـات انـدازه گیـری و نظـارت بـر رطوبت سطحی خـاک در مقیاس بزرگ شده است [۴]، ۵ و ۶].

ضریب پس پراکنش راداری (σ°) به ثابت دیالکتریک حساس است، اختلاف ثابت دىالكتريك خاك خشک (< 5) و آب (≈ 80) نشاندهنده حساسیت ثابت دی-الکتریک 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 اندازه گیریشده، زمینه تحقیقاتی برای برآورد این پارامتر میباشد. مدلهای تئوری و تجربی مختلفی برای برآورد رطوبت سطحی خاک از داده های سنجش از دور فعال و غیرفعال طراحی شدهاند (۱۰، ۱۱، ۱۲، ۱۳، ۱۴ و ۱۵]. مدل-های تئوری، پارامترهای پیچیدهای از مدلهای احتمالی برای خاک، گیاهان و زمین را شامل می شوند؛ در حالى كه مدلهاى تجربى رابطهاى ميان متغيرهاى اندازہ گیریشدہ برای اندازہ گیری پارامترھا برقـرار مـی-کنند. 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 پس پراکنش، مشکل اساسی برای کاربرد این مدل ها است [۱۶]. پوشش گیاهی باعث کاهش حساسیت ضریب پس پراکنش به رطوبت خاک می شود، از این رو نیاز به مدل های داده محور که می توانند داده های ورودی را به صورت مؤثری به خروجی موردنظر مرتبط کند، احساس می شود [۱۷].

شبکههای عصبی مصنوعی (ANN)^۳ و رگرسیون بردار پشتیبان (SVR⁾ مدلهایی هستند که می توانند داده-های 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 می کنند (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 شبکه های عصبی مصنوعی توسط محققین مختلفی بحث شده است (۱۸، ۱۹، ۲۰، ۲۲ و ۲۳]. ماشین بردار پشتیان 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^۴۶ و تصویر سنتینل۲ رطوبت خاک را با توان تفکیک مکانی ۱۰۰ متر و با ریشه میانگین مربع خطا در رطوبت حجمی، ^{m3} ۸۷ ۲۰ برآورد کردند [۲۵]. جیانگ و همکاران با استفاده از الگوریتمهای ماشین بردار پشتیبان و شبکه عصبی

[\] Surface soil moisture

^r Radar Cross Section (Backscatter)

^{*} Artificial Neural Networks

^{*} Support Vector Regression

^a Structural risk

[°] Sentinel

مصنوعی و با دادههای سنجش از دوری، شوری خاک را بررسى كردند كه الگوريتم ماشين بردار پشتيبان نتيجه و دقت بهتری نسبت به شبکه عصبی مصنوعی داشته است [۲۶]. گیل و همکاران با استفاده از ماشین بردار پشتیان، رطوبت خاک را برای چهار روز و هفت روز بعد پیشبینی کرده و نتیجه را با شبکههای عصبی مصنوعی مقایسه نمودند [۲۷]. گتاکو آیهو و همکاران با استفاده از ماشین بردار پشتیبان و با دادهی سنتینل ۱ رطوبت خاک را برآورد کردند و نشان دادند با ترکیب داده سنتینل ۱ با محصولات جانبی سنجش از دور، می توان با دقت بهتری، رطوبت خاک را بر آورد کرد [۲۸]. در بسیاری از تحقیقها مزایایی از ماشین بردار پشتیان نسبت به شبکههای عصبی مصنوعی بدست آمده و نظر بسیاری از محققان را به خود جلب کرده است (۲۶، ۲۹، ۳۱، ۳۱، ۳۲، ۳۳ و ۳۴]. سے اختار و عملكرد ماشين بردار پشتيان توسط محققين مختلفي بحث شده است (۴، ۲۷، ۳۵، ۳۶ و ۳۷].

مدف این پژوهش، مقایسه توانایی تصاویر سنتینل ۱ و سنتینل ۲ در برآورد رطوبت حجمی سطح خاک با استفاده از روشهای دادهمحور شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP)^۱ و رگرسیون بردار پشتیبان (SVR) بوده است. در بخش نتیجهگیری، دقت و خطای محاسبهشده از دو روش با استفاده از تصاویر سنتینل ۱ و ۲ مقایسه و مورد بحث قرارگرفته است. برای بهینهسازی 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 دادههای 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

با یکدیگر مقایسه و بحث گردیده است و در نهایت در بخش پنجم نتیجهگیری کلی پژوهش آورده شده است. ۲- منطقه و دادههای تحقیق

در این بخش ابتدا منطقه مورد مطالعه، خصوصیات و دلیل انتخاب این منطقه توضیح داده شده است سپس دادههای 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 میشود. محصولات عمده این منطقه کلزا، سویا، گندم، ذرت، جو میباشد. علت اصلی انتخاب این منطقه، وجود نمونهبرداریهای میدانی و وجود ایستگاه-های مختلف هواشناسی و هیدرولوژی است.

۲-۲-دادههای 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 ماهوارهای

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 ^۳ GRD در مد [†]WI 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

[\] Artificial Neural Networks Multi Layer Perceptron

^v Genetic Optimization Algorithm

^r Ground Range Detected

^{*} Interferometry Wide

^a Polarization

سال هفتم ● شماره چهارم ● زمستان ۱۳۹۸





شکل۱: 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 میـدانی مـورد اسـتفاده در ایـن تحقیـق، داده *SMAPVEX16*^۴ انـدازه گیـریشـده در تـاریخ ۲۴ مـی *SMAPVEX16*^۴ انـدازه گیـریشـده در تـاریخ ۲۴ مـی جنوب به عرض جغرافیایی ۲۰۱۸٬۳۸ ، از شمال بـه عـرض جغرافیایی ۴۹٬۷۶ ، از شرق به طول جغرافیایی ۹۷٬۷۵– میباشـد و در و از غرب به طـول جغرافیایی ۱۰/۸۹– میباشـد و در بـیش از ۵۰ مزرعـه کشـاورزی جمـعآوری شـده است(شکل (۱)). در این پژوهش از اطلاعات ۴۶ سـایت اسـتفاده شـده اسـت کـه در ایـن ۴۶ سـایت، رطوبـت اسـتفاده شـده اسـت کـه در ایـن ۴۶ سـایت، رطوبـت ماستیمتر اندازه گیری و جمعآوری شـده اسـت. در ایـن داده GRD، دامنه ضریب پس پراکنش راداری را به عنوان پارامتر اصلی دارا می باشد که این پارامتر بسیار به ثابت دیالکتریک سطح حساس است. ماهواره سنتینل ۲ در محدوده اپتیک، در سیزده باند تصویربرداری انجام می دهد. 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 می گیرند. توان تفکیک مکانی این باندها متغیر می باشد و به سه صورت ۱۰، ۲۰ و ۶۰ متر می باشند و توان تفکیک رادیومتریک ۲۲ بیتی می باشد؛ یعنی قادر است انرژی دریافتی را بین ۰ تا ۴۰۹۵ ثبت کند. جدول (۱) داده های مورد استفاده در تحقیق را بیان می کند. هدف از انتخاب این دو ماهواره مقایسه توانایی

^{*} Soil Moisture Active Passive Validation Experiment 2016

[`] Visible

^v Near-Infrared

^{*} Short Wave Infrared

بـرآورد رطوبـت سـطح خـاک بـا اسـتفاده از روش هـای ... صادق رنجبر ، مهدی آخوندزاده هنزائی

۳۹]. نحوه توزيع نقاط ميداني استفاده شده در

شکل(۱) مشخص شده است.

پژوهش از رطوبت حجمی سطح تا عمق پنج سانتیمتر استفاده شده است. در طول این دوره، بیشتر محصولات از مرحله رشد تا مرحله سن بلوغ رشد میکنند (۳۸ و

جعاول، تصاوير استعاده سماه				
نام سنسور	تاريخ اخذ	گذر ماهواره		
سنتينل ۱	T • 18/• V/• V	بالا گذر		
سینتینل۲	۲・۱۶/・۶/۱・	پايين گذر		

جدول۱: تصاویر استفاده شده





 $\sigma_{\it VV}^{
m `}(db)$ ب-تصویر ضریب پس پراکنش

شکل۲: تصاویر سنتینل۱ و ۲ از منطقه مورد مطالعه

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 بهینهسازی ژنتیک بهینهسازی شدهاند. همچنین برای مقایسه توانایی تصویر سنتینل ۱ و تصویر سنتینل ۲ در برآورد رطوبت حجمی سطح خاک، این

تصاویر در هر دو روش استفاده شده است که بانـدهـای بهینـه تصـویر چنـد طیفـی سـنتینل ۲ بـا اسـتفاده از الگوریتم بهینهسازی ژنتیک انتخـاب گردیـده اسـت. در شکل (۳) الگوریتم استفاده شده در پژوهش نشـان داده شده است.

۳-۱-پیش پردازش و آمادهسازی داده این مرحله شامل دو بخش آمادهسازی داده آموزشی و پردازش های لازم روی تصاویر خام است. دادههای

سال هفتم • شماره چهارم • زمستان ۱۳۹۸

اندازه گیری شده زمینی در قالب ماتریس های 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٪

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



شکل ۳: الگوریتم استفاده شده در پژوهش

۳–۱–۱–پیش پردازش تصویر سنتینل ۲ تصویر سنتینل ۲ در مرحله اول، تصحیحات رادیومتریکی و هندستی شده است. تصحیح رادیومتریکی به منظور حذف و نرمال سازی عواملی که بر روی امواج الکترومغناطیسی رسیده به سنجنده اثر منفی گذاشته بر تصویر اعمال می شود، و تصحیح هندسی به منظور حذف و نرمال سازی عواملی است که

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

^{&#}x27; Gaussian

^{*}Reflectance

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

۲-۱-۳-پیشپردازش تصویر سنتینل۱

بر روی تصویر سنتینل ۱ نیز ابتدا تصحیحات رادیومتریکی و هندسی اعمال شده است. تصحیح هندسی به منظور از بین بردن اعوجاجات هندسی موجـود در تصاویر اعمـال مـیشـود کـه دو نـوع از تصحيحات مهم، يكي تبديل برد مايل به برد زميني و دیگری ترمیم هندسی میباشد و تصحیح رادیومتریکی به منظور کاهش اثرات اتمسفر بر امواج ثبتشده اعمال می شود. سپس با استفاده از فیلتر لی، نویز اسـپکیولار^۲ تصویر کاهش یافته و در نهایت مقادیر ضریب پس-یراکنش با واحد دسیبل محاسبه شده است. از ضریب پس پراکنش در پلاریزه های عمودی_عمودی و عمودی-افقی ($\sigma^{\circ}_{VV}, \sigma^{\circ}_{VU}$) و زاویه برخورد (θ) برای ورودی_ دو روش استفاده می شود. زاویه بر خورد به دلیل تأثیر این پارامتر بر مقدار ضریب پس پاکنش راداری ثبت-شده در زوایای مختلف، به عنوان پارامتر ورودی استفاده شده است.

۲-۲-برآورد نقشه رطوبت حجمي سطح خاک

در مرحله پیش پردازش و در قسمت آمادهسازی 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 آموزشی استفاده شدند. در تمامی مراحل بعدی به دلیل 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

شبكه عصبى مصنوعي چندلايه پرسيترون آموزش داده می شوند که پارامترهای این مدلها با استفاده از الگوريتم بهينهسازي ژنتيک بهينه ميشوند. الگوريتم بهينهسازي ژنتيک يک الگوريتم کارا براي پيدا کردن بهینه سراسری است. این الگوریتم با بهرهوری 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 برازش⁴ مهمترین بخش الگوریتم ژنتیک میباشد که در این پژوهش از مدل های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی چندلایه پرسپترون به عنوان تابع برازش استفاده مي شود [۴۰]. اين الگوريتم افراد موجود در جمعیت را بر اساس میزان شایستگیشان مرتب کرده و با استفاده از عملگرهایش جمعیت جدیدی تولید میکند، 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 ضريب تعيين رطوبت حجمي سطح خاك برآورد شده و رطوبت حجمی سطح خاک اندازه گیری شده محاسبه شده است. ضریب تعیین نشان میدهد که چند درصد تغییرات متغیر وابسته به وسیله متغیر مستقل تبیین می شود که این ضریب پس از هر بار تكرار الگوريتم به عنوان پارامتر خروجي از تابع برازش برای هر جواب میاشد که نشاندهنده شایستگی جواب مىباشد. ساختار و كارايى اين الگوريتم بهينه-سازی در تحقیقاتی مورد بحث و ارزیابی قرارگرفته است (۴۰، ۴۱ و ۴۲].

برای آموزش شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP)، به منظور بهینهسازی تعداد لایهها، ایـن مدل در الگوریتم ژنتیک به عنوان تابع بـرازش اسـتفاده

^{&#}x27; Geometric rectification

^{*} Specular

^r Crossover

^{*} Mutation

 $^{^{\}diamond}Fitness$ function

سال هفتم ● شماره چهارم ● زمستان ۱۳۹۸

شده است. در روش ANN-MLP از تابع فعالساز تانژانت هایپربولیک سیگموید استفاده گردیده و برای آموزش شبکه از روش پسانتشار خطا^۲ استفاده شده است. شبکه عصبی مصنوعی به تعداد لایه های مخفی حساس است به طوری که با زیاد شدن لایهها، بیش-برازش رخ داده و باعث کم شدن دقت مقدار بر آورد شده، می شود. تعداد لایهها در این پژوهش با استفاده از الگوريتم بهينهسازي ژنتيک بهينه شده است که رمز گذاری 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 قـرار گرفته است (۱۸، ۱۹، ۲۰، ۲۲، ۲۳ و ۲۴]. شکل(۴) شمای کلی شبکههای عصبی مصنوعی چندلایه پرسیترون را نشان میدهد که از سه بخش اصلی، لایهی ویژگیهای ورودی، لایه پنهان و لایه خروجی تشکیل می شود. وزن و بایاس^۳ در شبکه های 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

تنظیم ۲ (*C*)، ۹^۵ و پارامترهای هسته است. در این پژوهش از هســته تــابع پايــه شــعاعى (*RBF)⁶* اســتفاده شده است که این هسته شامل پارامتر گاما (γ) است. یارامترهای 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 معمولا در مرحله تست دقت پایین میآید. اگر پارامتر C مقدار کوچک باشد، دقت نامطلوب است و مدل را بیفایده می کند. یارامتر 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، Ρ، C و γ با استفاده از الگوریتم بهینهسازی ژنتیک بهینه شده است. رمزگذاری این پارامترها برای ورود به الگوریتم بهینه-سازی ژنتیک، اعداد حقیقی بوده و از روشهای صـاف^۷ و گاوسین^ به ترتیب برای عملگرهای آمیزش و جهـش 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 یشتیبان در شکل(۵) آورده شده به طوری که خط-چینها، بردارهای پشتیبان می باشند 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 می شود. در شکل(۵)، دادهها از فضای حقیقی ویژگیهای ورودی به فضای هسته (φ) به ابعاد بالاتر رفته و مدلسازی صورت گرفته است.

[^] Gaussian-mutation

Sigmoid hyperbolic tangent

^rBackpropagation

[&]quot; Bias

^{*} Penalty

[∆] Loss function parameter

^{*} Radial Basis Function

^v Flat-crossover



شکل۵: شمای کلی رگرسیون بردار پشتیبان

آماری ضریب تعیین (R²) و جذر میانگین مربع خطا (RMSE) استفاده شده است. روابط پارامترهای R² و RMSE بترتیب در رابطه (۱) و (۲) آورده شده است.

$$R^{2} = \frac{SSR}{SST} = \frac{SST-SSE}{SST} = 1 - \frac{SSE}{SST} = 1 - \frac{\sum_{i=1}^{n} (y_{i} - O_{i})^{2}}{\sum_{i=1}^{n} (O_{i} - \mu_{o})^{2}}$$

$$RMSE = \sqrt{\sum_{i=1}^{n} \frac{(y_i - O_i)^2}{n - 1}}$$
Junction of the second state of th

۴- نتایج و بحث

در این بخش ابتدا نمودارهای الگوریتم ژنتیک به همراه بهترین جواب پارامترهای بهینهشده 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 نسلها انتخاب گردیده است. همچنین از ضریب تعیین (R²) 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 R² به عنوان دقت تابع برازش میباشد، از کمینه کردن ۳-۳- اعتبارسنجی روشها برای برآورد رطوبت حجمی سطح خاک برای اعتبارسنجی نقشههای تولیدشده، از پـارامترهـای

رابطه (۱)

رابطه (۲)

نشریه علمی پژوهشی – مهندسی فناوری اطلاعات مکانی ———————————————————

سال هفتم • شماره چهارم • زمستان ۱۳۹۸

RMSE و RMSE برای شروط الگوریتم ژنتیک استفاده شد. در بخش بعدی نتایج روش های رگرسیون بردار پشتیبان (SVR) و شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP) با استفاده از تصاویر سنتینل 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 بهینه-سازی 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 افقے نمودارها، نسلها و محور عمودی نمودارها، دقت هر روش برای هر تصویر را برحسب ضریب تعیین ، رمزگذاری (((R^2)) نمایش می دهد (شکل ((R))). رمزگذاری (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 سنتینل۲ و سنتینل۱ به ترتیب ۳ و ۵ برآورد شده است(جدول (۲)). رمز گذاری پارامترهای روش SVR، اعداد حقیقی بوده است که با توجه به $(g) \gamma$ و شکل ($(\beta - \beta)$ و شکل ($(\beta - \beta)$) پارامترهای $(\beta - \beta)$ برای تصاویر سنتینل۲ و سنتینل۱ در جدول (۲) آورده شده است. در شکل (۷) نمودار بهینهسازی انتخاب باند تصویر سنتینل۲ در ۵۵ نسل و همچنین بهترین جواب برای آن آورده شده است که محور افقی، شماره بانـد را نشان میدهد. انتخاب باندهای بهینه تصویر سنتینل۲ 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. رمز گزاری در انتخاب باندهای بهینه به صورت صفر و یکی انجام میشود. باندهای ۲، ۴، ۷، ۸۸، ۱۱و ۱۲ به عنوان باندهای بهینه انتخاب شده اند که به ترتیب دارای طول موج ۴۹۰،

۶۶۵، ۷۸۳، ۸۶۵، ۱۶۱۰ و ۲۱۹۰ نانومتر میباشند و توان تفکیک مکانی باندهای ۲ و ۴ ده متر و باندهای ۲، ۸۸، 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 اندازه گیریشده (R²) و جذر میانگین مربعات خطا^۳ (RMSE) بیان شده است.

۴-۲-۱-نقشههای رطوبت حجمـی سـطح خـاک بر آورد شده با استفاده از شبکه عصبی مصـنوعی چندلایه پرسپترون(ANN-MLP)

نقشه رطوبت حجمی سطح خاک از روش شبکه عصبی مصنوعی چندلایه پرسپترون (ANN-MLP) با استفاده از تصاویر سنتینل ۱ و سنتینل ۲، برآورد شده است (شــكل (٨-الـف و ٨-ب)). مربع ضـريب همبسـتگي رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه گیری شده در این روش (R²) برای تصاویر سنتینل ۱ و سنتینل ۲ به ترتیب ۶۱۸ و ۴۰۹ بدست آمده است. این مقادیر نشان میدهند در روش ANN-MLP وابســـتگی تصــاویر ســنتینل ۱ و سنتینل۲ به رطوبت حجمی سطح خاک به ترتیب ۶۲٪ و ۴۱٪ میباشد. تصویر سنتینل۱ دقت بهتری در برآورد رطوبت حجمى سطح داشته است كه نشان دهنده وابستگی بیشتر اطلاعات و ویژگیهای تصویر سنتینل ۱ به پارامتر رطوبت حجمی سطح خاک است. جذر میانگین مربع خطا (RMSE) نیز در این روش برای تصاویر سنیتنل۱ و سنتینل۲ به ترتیب ۰٬۱۴۴۹ و ۳۶۱۲ برآورد شده است (جدول (۳)).

Downloaded from jgit.kntu.ac.ir on 2025-07-04

[\]Encoding

^v Binary string

[&]quot; Root Mean Square Error



بـر آورد رطوبـت سـطح خـاک بـا اسـتفاده از روش هـای ...

صادق رنجبر ، مهدی آخوندزاده هنزائی

















شكل 6: نمودارهای الگوریتم ژنتیک به منظور بهینهسازی (محور افقی نمودارهای الگوریتم ژنتیک، تعداد نسلها و محور عمودی نمودارها دقت میباشد و زیر نمودارهای الف و ب بهترین تعداد لایه بهینه شده روش ANN-MLP میباشد که رمزگزاری آن به صورت رشتهای از صفر و یک می باشد و زیر نمودارهای ج و د بهترین مقدار پارامترهای بهینه شده روش SVR است که رمزگذاری آن به صورت اعداد حقیقی میباشد.)

سال هفتم • شماره چهارم • زمستان ۱۳۹۸

الكوريتم	پارامترها	سنتينل٢	سنتينل۱	
SVR	С	ነ የአኖ ጵዮሃ	۱۰۷۹۱٫۱۱	
	Р	•,• 1808	•,• ١••٩	
	γ	+,+ + TDDT9F	+,+ + DOTVFY	
ANN-MLP	تعداد لایههای بهینه	٣	۵	
SVR	شماره باندهای بهینه	17.11. AA .Y.F.T	-	

جدول۲: پارامترهای بهینهسازی شده با استفاده از الگوریتم ژنتیک



شکل۷: نمودار بهینهسازی انتخاب باند سنتینل۲ –(محور افقی نمودار الگوریتم ژنتیک، تعداد نسلها و محور عمودی دقت برحسب ضریب تعیین میباشد. – محور افقی بهترین جواب شماره باند سنجنده را نشان میدهد.)

> ۲-۲-۲-۲-نقشههای رطوبت حجمـی سـطح خـاک بـر آورد شـده بـا اسـتفاده از رگرسـیون بـردار پشتیبان (SVR)

> در شـکل (۸-ج) و شـکل (۸-د)، نقشـه بـرآورد شـده رطوبت حجمی سطح خـاک تـا عمـق ۵ سـانتیمتـر از روش رگرسـیون بـردار پشـتیبان (SVR) بـا اسـتفاده از تصاویر سنتینل ۱ و سـنتینل ۲ نشـان داده شـده اسـت. ضریب تعیین (R²) برای تصاویر سنتینل ۱ و سـنتینل ۲ ضریب ۹۵۹٫۰ و ۲۳۳٫۰ بدست آمده است. با توجـه بـه این مقادیر، روش SVR، وابستگی اطلاعات و ویژگیهای تصاویر سـنتینل ۱ و سـنتینل ۲ را بـه رطوبـت حجمـی

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 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 صادق رنجبر ، مهدی آخوندزاده هنزائی

آورده شده است.

روش	تصوير	R ²	$RMSE(\frac{m^3}{m^3})$
ANN-MLP	سنتينل١	•,۶۱۸	•,٣• ١
	سئتينل٢	۰٫۴۰۹	•,4814
SVR	سنتينل١	₁ 809	•,۲۹١
	سنتينل٢	•/477	•,18711

جدول۳: اعتبارسنجی نقشههای رطوبت

۴-۳-بحث و گفتگو

هدف اصلی پژوهش بر آورد 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 سنتینل۲ و سنتینل۱ استفاده شده است. با توجه به ضریب تعیین (R) بدست آمده (شکل (۸))، روش SVR در هر دو تصویر سنتینل۲ و سنتینل۱ دقت بهتری نسبت به روش ANN-MLP داشته است. در هر دو روش تصویر سنتینل۱ دقت بالاتری نسبت به تصویر سنتینل۲ داشته است که این نشانگر آن است که

تصاویر سنیتنل ۱ و سنتینل ۲ محاسبه و در جـدول (۳)

ویژگیهای تصویر سنیتنل ۱ نسبت به ویژگیهای تصویر سنتینل ۲، رابطه معنادارتری نسبت به رطوبت سطح خاک دارد. این نتیجه نشان میدهد که اطلاعات موجود در تصویر راداری به رطوبت حجمی سطح خاک بیشتر حساس میباشد؛ البته این موضوع را باید در نظر بیشتر حساس میباشد؛ البته این موضوع را باید در نظر بیشتر حساس میباشد؛ البته این موضوع را باید در نظر بیشتر حساس میباشد؛ البته این باند حرارتی یکی از حساسترین باندهای ماهوارههای باند حرارتی یکی از حساسترین باندهای ماهوارههای باند روش هایی از ساخص خاک با استفاده از شاخص-های پوشش گیاهی و باندهای حرارتی ارائه شده است.



شکل۸: نقشههای رطوبت حجمی سطح خاک بر آورد شده

سال هفتم • شماره چهارم • زمستان ۱۳۹۸

۵- نتیجهگیری

با توجه به نتایج و مقایسه دقتهای محاسبه شده در این پژوهش می توان گفت، دقت روش رگرسیون بردار پشــتيبان (SVR) از روش شــبکه عصـبی مصـنوعی چندلایه پرسپترون (ANN-MLP) برای برآورد رطوبت حجمی سطح خاک برای هر دو تصویر سنتینل ۱ و سنتینل۲ بهتر بوده است. تصویر سنتینل۱ با توجه به حساسیت بالای ضریب پس پراکنش راداری به تغییرات ثابت دیالکتریک، و همچنین حساسیت بالای ثابت دیالکتریک به رطوبت، نسبت به تصویر سنتینل۲ برای برآورد رطوبت حجمی سطح خاک دارای دقت بهتـری می باشد. 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 پـژوهش 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 سنتینل۲، 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 می گیرد. یکی از باندهای بسیار کارا و حساس به رطوبت سطح خاک در سنجندههای غیرفعال، باندهای حرارتی بودہ که با کمک شاخص های گیاهی برای برآورد رطوبت استفاده می شوند. در نهایت پیشنهاد می-شود از تصویر سنتینل۲ به تنهایی برای برآورد رطوبت حجمی سطح استفادہ نشود ولے با توجه به ویژگی ماهواره سنتینل۲ در برآورد دقیق نوع پوشش زمین با توان تفکیک مکانی مناسب، می توان از ویژگیهای این ماهواره به عنوان داده کمکی در کنار تصاویر رادار بـرای بهبود دقت استفاده کرد.

با مقایسه نمودارهای الگوریتم ژنتیک شکل (۶) بین دو روش می توان نتیجه گرفت که روش SVR زودتر به دقتهای بهتر همگرا می شود. این روش پس از گذشت تقريباً 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 سنتینل۲ نشان میدهند که بیانگر حساسیت بالای ضریب پس پراکنش راداری به رطوبت حجمی سطح خـاک مـیباشـد (شـکل (۶)). بـا توجـه بـه نقشـههـای رطوبـت حجمـی سـطح خـاک (شکل(۸)) و نمودار همبستگی رطوبت حجمی سطح خاک برآورد شده و رطوبت حجمی سطح خاک اندازه-گیریشده (شکل (۹)) می توان گفت که روش -ANN MLP مقادیر رطوبت حجمی سطح خاک تا عمق ۵ سانتیمتر را بیشتر از مقادیر حقیقی و اندازه گیریشده برآورد می کند، در صورتی که روش SVR مقادیر برآورد شده را کمتر از مقادیر حقیقی و اندازه گیری شده بر آورد کـرده اسـت. در روش SVR بـا اسـتفاده از تصـویر سنتينل ١، ضريب تعيين ٢،۶۵٩ و با استفاده از تصوير سنتينل٢، ضريب تعيين ٢/٢٣٣ محاسبه شده است. این ضریب نشان میدهد که چند درصد تغییرات اطلاعات موجود در تصاویر به وسیله رطوبت حجمی سطح خاک تبیین می شود 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 مابقى تغييرات متغير وابسته مربوط به ساير عوامل مى-باشد. ضریب تعیین در روش ANN-MLP با استفاده از تصویر سنتینل ۱ ۰٬۶۱۸ و با استفاده از تصویر سنتینل ۲ ۴۰۹/۰ 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 سنتینل۲ دارد.



شکل۹: نمودارهای همبستگی رطوبت حجمی سطح خاک بر آورد شده و رطوبت حجمی سطح خاک اندازه گیریشده (محور افقی نمودارها رطوبت اندازه گیری شده در سطح زمین و نمودار عمودی رطوبت بر آورد شده از روشها میباشد.)

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

[Downloaded from jgit.kntu.ac.ir on 2025-07-04]

سال هفتم ● شماره چهارم ● زمستان ۱۳۹۸

Resources Research, 34(10):2765-8, 1998.

- [3] Lunt IA, Hubbard SS, Rubin Y, "Soil moisture content estimation using groundpenetrating 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,

٥٣٩

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 modelbased 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

بـرآورد رطوبـت سـطح خـاک بـا اسـتفاده از روش هـای...

صادق رنجبر ، مهدی آخوندز اده هنز ائی

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 1". 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]Raczko 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 (UAV) aerial vehicle unmanned multispectral imagery. InAutonomous Air Ground Sensing and 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

سال هفتم • شماره چهارم • زمستان ۱۳۹۸

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.



Research Paper

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- Assisstant 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 Sentinell 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.

Correspondence Address. Remote Sensing Division, Faculty of Surveying and Geospatial Engineering, University of Tehran, Tehran, Iran. Tel: +98 21 61114522. Email: makhonz@ut.ac.ir