

Soil Moisture Modeling and Spatial Resolution Enhancement of SMAP Satellite Data at the Farm Scale Using Remote Sensing Data

Abstract

Nowadays, soil moisture estimation using SMAP satellite data is feasible at a temporal resolution of less than three days; however, the spatial resolution of these data is relatively coarse. In this study, a downscaling approach was applied to enhance the spatial resolution of SMAP soil moisture by integrating Sentinel-1 SAR and MODIS data. The study focused on estimating soil moisture in maize fields through field measurements collected from five farms at the Megsal Agro-Industrial Complex in the Qazvin Plain during the summer growing season of 2022. A Random Forest (RF) modeling approach was employed to estimate soil moisture, and six scenarios were defined, each representing a different combination of indices derived from Sentinel-1 and MODIS data as inputs to the RF model for SMAP soil moisture downscaling. The results indicate that among the evaluated scenarios, scenario RF6 in Farm 1 (M1) achieved the highest correlation with in-situ soil moisture ($R = 0.97$) and $RMSE = 0.04 \text{ (cm}^3/\text{cm}^3\text{)}$, followed by scenario RF5 with $R = 0.96$. The superior performance of RF5 and RF6 is attributed to the inclusion of the Leaf Area Index (LAI) and land cover maps. Moreover, the correlation between measured soil moisture and LAI was high ($R = 0.88$), highlighting the importance of vegetation indices in soil moisture estimation. Considering the limited availability of point-based soil moisture data and the need for continuous maps to monitor small farms, applying downscaling techniques can significantly improve the accuracy of SMAP data, making it a cost-effective and efficient tool for agricultural management and research.

Keywords:

Downscaling, MODIS, Random Forest, Remote Sensing, SMAP, Soil Moisture

EXTENDED ABSTRACT

Introduction

Soil moisture is one of the primary determinants governing energy exchange between the land surface and atmosphere, influencing plant growth, crop water use, and hydrological responses. In agricultural environments, particularly in semi-arid regions such as the Qazvin Plain of Iran, the precise monitoring of surface soil moisture is fundamental for optimizing irrigation practices and maintaining crop productivity under increasing water stress conditions. Recent advances in satellite remote sensing have enabled large-scale estimation of soil moisture; however, limitations remain regarding the spatial resolution of passive microwave sensors such as the Soil Moisture Active Passive (SMAP) mission. Although SMAP provides soil moisture observations with a revisit frequency of less than three days, its coarse spatial resolution ($\sim 9 \text{ km}$) restricts its applicability for field-scale agricultural monitoring where the spatial variability of soil moisture is significant.

To address this limitation, downscaling methods integrating Synthetic Aperture Radar (SAR) observations and optical vegetation indices have been developed to enhance SMAP spatial resolution without compromising temporal continuity. Sentinel-1 SAR provides backscatter information sensitive to surface roughness and soil moisture, while MODIS products offer vegetation and land surface parameters that characterize canopy cover, evapotranspiration, and water retention. In this study, a multi-sensor data fusion and machine-learning-based downscaling approach was applied to estimate soil moisture at field scale in maize farms within the Megsal agricultural complex. Specifically, the Random Forest (RF) algorithm was used due to its capacity to model nonlinear relationships and its robustness in handling high-dimensional predictor variables.

Materials and Methods

Study Area and Field Data

The study was conducted in five maize fields located in the Megsal agricultural complex in the Qazvin Plain during the 2022 growing season. The region is characterized by a semi-arid climate with warm summers, and irrigation is primarily supplied by groundwater. Soil texture across the fields is predominantly loam. Soil moisture measurements were collected from each field at a depth of 0–30 cm using the HH2 moisture probe. Sampling was repeated throughout the growing season to capture temporal fluctuations associated with irrigation events and plant development.

Remote Sensing Data

Three categories of remotely sensed data were employed:

Data Source	Parameter	Spatial/Temporal Resolution
SMAP L3	Soil moisture	9 km / 2–3 days
Sentinel-1 SAR	σ^0 VV backscatter	$\sim 20 \text{ m}$ / 6–12 days
MODIS	NDVI, EVI, NDWI, LAI, LST, Albedo	250–1000 m / 8–16 days

Additionally, elevation and slope were derived from SRTM DEM to incorporate topographic variation influencing water redistribution.

Downscaling Modeling Scenarios

Six predictive model scenarios (RF1–RF6) were developed based on incremental combinations of remote sensing predictors, ranging from minimal configurations (LST and NDVI) to extended models incorporating vegetation indices, radar backscatter, land cover type, and terrain parameters. The Random Forest algorithm was implemented in the Google Earth Engine cloud environment. Model performance was assessed against ground measurements using:

- Correlation coefficient (R)
- Root Mean Square Error (RMSE)
- Mean Absolute Error (MAE)
- Normalized RMSE (NRMSE)

Results

Model performance varied substantially among the tested scenarios. Scenarios integrating vegetation structural parameters and land cover information (RF5 and RF6) consistently produced the highest accuracy across all fields. In Field M1, RF6 yielded the strongest performance ($R = 0.97$; $RMSE = 0.04 \text{ cm}^3/\text{cm}^3$), indicating near-exact correspondence to measured soil moisture. RF5 followed closely ($R = 0.96$), reflecting the influence of canopy structure on soil moisture retention.

The contribution of LAI was particularly significant, exhibiting a strong relationship with measured soil moisture ($R = 0.88$). This highlights the role of vegetation biomass in regulating canopy shading and transpiration dynamics, which in turn affects surface moisture availability. Scenarios lacking vegetation parameters (RF1–RF3) demonstrated lower accuracy ($R = 0.51\text{--}0.75$), confirming that soil temperature and backscatter alone are insufficient to represent field-scale moisture variability, especially during mid-season crop growth.

Temporal comparisons further revealed that downscaled soil moisture estimates effectively captured the progression of the maize growth cycle, including moisture increases following irrigation and declines during periods of high atmospheric demand. Models performed more consistently in fields with uniform irrigation pressure (linear systems) compared to strip irrigation fields where uneven water distribution increased spatial heterogeneity.

Conclusion

This research demonstrates that integrating Sentinel-1 SAR and MODIS-derived vegetation and surface parameters with SMAP soil moisture significantly improves spatial resolution and estimation accuracy at the field scale. The Random Forest–based downscaling approach produced high agreement with measured soil moisture, particularly when LAI and land cover information were included. The proposed approach offers a cost-effective and operationally feasible framework for precision irrigation planning, crop monitoring, and hydrological assessment in semi-arid agricultural systems. The results underscore the value of multi-sensor data fusion in bridging the gap between regional-scale satellite products and field-level management needs.

Data Availability Statement

Data will be made available on request.

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

مدلسازی رطوبت خاک و بهبود وضوح مکانی داده‌های ماهواره SMAP در مقیاس مزرعه با استفاده از داده‌های سنجش از دور

چکیده

امروزه برآورد رطوبت خاک با استفاده از ماهواره SMAP در مقیاس زمانی کمتر از سه روز امکان‌پذیر شده است اما اندازه پیکسل سایزهای این داده بزرگ است. در این پژوهش رویکردی برای کاهش مقیاس رطوبت خاک SMAP با ترکیب Sentinel-1 SAR و داده‌های MODIS به کارگرفته است لذا با هدف برآورد رطوبت خاک در مزارع ذرت به برداشت نمونه رطوبت خاک گیاه ذرت از ۵ مزرعه در کشت و صنعت مگسال واقع در دشت قزوین در دوره کشت تابستان ۱۴۰۱ پرداخته شد. در این پژوهش از تکنیک جنگل تصادفی برای تخمین رطوبت خاک، استفاده شد. در این پژوهش شش سناریو تعریف شد که هر سناریو بیانگر یک ترکیب متفاوت از شاخص‌های استخراج‌شده از داده‌های Sentinel-1 و MODIS به‌عنوان ورودی مدل جنگل تصادفی برای کاهش مقیاس رطوبت خاک SMAP است. نتایج به دست آمده نشان می‌دهد که در بین سناریوهای مورد بررسی در مزرعه یک (M1)، سناریو RF6 با مقدار $R=0.97$ و $RMSE=0.04 \text{ (cm}^3/\text{cm}^3\text{)}$ بیشترین میزان همبستگی را داشته است. بعد از سناریو RF6، سناریو RF5 با مقدار $R=0.96$ از همبستگی بالایی برخوردار است. از جمله دلایل افزایش میزان همبستگی در سناریوهای RF5 و RF6 را می‌توان به وجود شاخص LAI و نقشه کاربری اراضی اشاره کرد. در بررسی همبستگی میان شاخص سطح برگ و رطوبت خاک اندازه‌گیری شده مشخص شد که این شاخص با مقدار $R=0.88$ میزان همبستگی بالایی را با مقادیر رطوبت خاک دارد. به دلیل محدود بودن داده‌های نقطه‌ای رطوبت خاک و نیاز به تهیه نقشه‌های پیوسته برای پایش مزارع کوچک، به‌کارگیری روش‌های ریزمقیاس‌سازی می‌تواند دقت داده‌های SMAP را به‌طور مؤثری افزایش داده و آن را به‌ارزای کارآمد و مقرون‌به‌صرفه برای مدیریت و پژوهش‌های کشاورزی تبدیل کند.

کلیدواژه: جنگل تصادفی، رطوبت خاک، ریزمقیاس‌سازی، سنجش از دور، SMAP، MODIS

مقدمه:

رطوبت خاک (SM) به عنوان یک عامل کلیدی در چرخه‌های جهانی آب و انرژی اهمیت زیادی دارد و نقش مهمی در مدیریت فرآیندهای هیدرولوژیکی و سطح زمین ایفا می‌کند (Ochsner et al., 2013). تجزیه و تحلیل دقیق رطوبت خاک برای اجرای موثر در برنامه‌های کاربردی هیدرولوژی، باغبانی، کشاورزی و هواشناسی حیاتی است (Ansari & Deshmukh, 2017). پایش رطوبت خاک برای کاربردهایی مانند پیش‌بینی آب و هوا، پیش‌بینی خشکسالی، مدیریت منابع آب، تولید گیاهان کشاورزی، تبخیر و تعرق و پیشگیری از بلایا مهم است (Babaeian et al., 2019). روش‌های مختلفی به منظور برآورد رطوبت خاک وجود دارد. روش‌های بازتاب سنجی دامنه زمانی (TDR) و رادار نفوذی زمین (GPR) روش‌های دقیق و آنی برای تخمین رطوبت خاک هستند که به تخصیص و نگهداری کارآمد منابع آب کمک می‌کنند (Dobriyal et al., 2012). تکنیک‌های مختلفی مانند سنجش از دور و یادگیری ماشین به طور گسترده‌ای در تخمین رطوبت خاک استفاده می‌شوند و الگوریتم جنگل تصادفی به عنوان یکی از پرمصرف‌ترین الگوریتم‌ها در این زمینه شناخته می‌شود (Singh et al., 2023). اگرچه اندازه‌گیری‌های متعدد در بسیاری از نقاط یک منطقه می‌توانند مقدار متوسط رطوبت خاک را برای آن منطقه تعیین کنند، اما استفاده از این روش‌ها در صورت نیاز به اندازه‌گیری‌های زیاد و در مقیاس گسترده، دشوار، پرهزینه و زمان‌بر است و برای دوره‌های طولانی مدت مناسب نیستند. علاوه بر این، توزیع آب در خاک به خواص فیزیکی و هیدرولوژیکی خاک، توپوگرافی و سایر شرایط محیطی وابسته است (Korres et al., 2015).

پیشرفت‌های اخیر در فناوری سنجش از دور به طور قابل توجهی نظارت و برآورد میزان رطوبت خاک (SMC) را بهبود بخشیده است. روش زیرمقیاس‌سازی با استفاده از افق بیزی عمیق (BDIP)، تخمین‌های با وضوح بالا از رطوبت خاک را از محصولات ماهواره‌ای ارائه می‌دهد و اطلاعات ارزشمندی برای پایش محیطی و کشاورزی فراهم می‌کند (Fang et al., 2022). استفاده از داده‌های سنجش از دور به دلیل قابلیت بروزرسانی و در دسترس بودن اطلاعات، امکان نظارت مستمر و سریع را برای اندازه‌گیری رطوبت خاک در

مناطق گسترده فراهم می‌کند و همچنین این روش مقرون به صرفه است (Acharya et al., 2021). مطالعات مختلف نشان داده‌اند که بازتابش انعکاسی خاک، تشعشع حرارتی و پراکنش امواج میکروویو، با رطوبت خاک به طور گسترده‌ای همبستگی دارند. (Araya et al., 2020; Fatholouloumi et al., 2021; et al.) در میان انواع مختلف فناوری‌های سنجش از دور، سنجش از دور میکروویو به دلیل توانایی نفوذ آسان در خاک، به طور مستقیم می‌تواند مقدار رطوبت موجود در سطح خاک را ارزیابی کند. این توانایی به دلیل تفاوت چشم‌گیر در خواص دی‌الکتریکی بین خاک خشک و آب مایع امکان‌پذیر است. توانایی میکروویوهای غیرفعال برای تولید تخمین‌های قابل اعتماد از میزان رطوبت سطح، به دلیل کاهش حساسیت آن‌ها نسبت به گیاهان، ناهمواری سطح خاک، زمین‌شناسی و محتوای آب، برمی‌گردد (Entekhabi et al., 2010; Piles et al., 2014). ماموریت (Soil Moisture Active Passive) SMAP در سال ۲۰۱۵ راه‌اندازی شد. با هدف استفاده از تلفیق دقیق مشاهدات SMAP در یک سیستم جذب داده‌های زمین، نقشه‌برداری دقیق و با کیفیت بالا از تراکم خاک و وضعیت یخ‌زدگی/ذوب شدگی سطحی در سراسر جهان ارائه شده است. این امر با استفاده از تجمع داده‌های SMAP درون یک سیستم جذب داده‌های خاک و محیط ریشه، به نتیجه‌ای به نام محصول داده سطح ۴ تراکم خاک و منطقه ریشه (L4_SM) می‌انجامد (Reichle et al., 2022). این محصول، با اعتبارسنجی بر اساس اندازه‌گیری‌های میدانی، مطابقت با الزامات دقت خود را اثبات کرده است (Reichle et al., 2017). همچنین نسخه بهبود یافته‌ای از محصول استاندارد تراکم خاک غیرفعال با شبکه ۹ کیلومتر نیز توسعه داده شده و اعتبارسنجی شده است (S. Chan et al., 2017). ساختار ابزار SMAP، که شامل رادار و رادیومتر باند L است، امکان تولید نقشه‌های جهانی تراکم خاک با دقت بالا را فراهم می‌کند. همچنین ماموریت ماهواره (SMOS) که در سال ۲۰۰۹ راه‌اندازی شده است، به هدف ارائه نقشه‌های جهانی از رطوبت خاک و شوری سطح دریا می‌پردازد. بار مفید منحصر به فرد این ماموریت، رادیومتر تصویربرداری میکروویو با استفاده از سنتز دهانه (MIRAS) است که یک تداخل‌سنج دوبعدی با فرکانس باند L است (Barré et al., 2008; Font et al., 2013). با این حال، داده‌های غیرفعال میکروویو SMOS و SMAP با وضوح کم قادر به نمایش دقیق توزیع رطوبت خاک سطح نمی‌باشند. به همین دلیل، بسیاری از پژوهشگران برای بهبود داده‌های ماکروویو غیرفعال، از داده‌های جانبی با وضوح بالا استفاده می‌کنند و با ادغام آن‌ها، دقت را افزایش می‌دهند (J. Han et al., 2017; Peng et al., 2018). طیف وسیعی از روش‌های ریزمقیاس برای افزایش وضوح فضایی محصولات رطوبتی خاک ماهواره‌ای پیشنهاد شده‌اند (Zhong et al., 2018). بعضی از روش‌های کاهش مقیاس بر اساس داده‌های ماکروویو فعال یا غیرفعال، شامل کاهش مقیاس داده‌های دمای درخشندگی میکروویو (TB) با رزولوشن خام یا کاهش مقیاس داده‌های رطوبت خاک با رزولوشن خام بر اساس داده‌های بازتاب میکروویو، انجام می‌شوند (Lievens et al., 2017). در مقایسه با تکنیک‌های میکروویو غیرفعال، تکنیک‌های میکروویو فعال دقت مکانی بالاتری ارائه می‌دهند (Guo et al., 2021). به طور معمول، روش‌های کاهش ابعاد بر اساس میکروویو فعال از ارتباط خطی یا نزدیک به خطی بین داده‌های سری زمانی دمای درخشندگی میکروویو (TB) یا رطوبت خاک (SM) و داده‌های بازتاب میکروویو بهره می‌برند (J. Bai et al., 2019). در طول سری‌های طولانی مدت، اغلب تصور می‌شود که پوشش گیاهی و زبری سطح ثابت باقی می‌مانند (He et al., 2018). اما وجود پوشش گیاهی و زبری سطح به شدت بر امواج میکروویو فعال تأثیر می‌گذارد (Millard & Richardson, 2018). داده‌های رادار روزنه مصنوعی (SAR) به طور گسترده برای رسیدگی به موانع و راه‌حل‌های ممکن در بازیابی رطوبت خاک مورد مطالعه قرار گرفته‌اند. با در نظر گرفتن اثرات زبری سطح و پوشش گیاهی، (Kim et al., 2017) ثابت کرد که بازیابی سری زمانی به صورت فیزیکی با داده‌های SAR باند L امکان‌پذیر است. استفاده از یک مدل بازیابی تک‌گذره در ماموریت SMAP قابل مشاهده است (Colliander et al., 2021). طیف وسیعی از مطالعات روش‌هایی را برای افزایش وضوح مکانی محصولات رطوبتی خاک SMAP مورد بررسی قرار داده‌اند. در پژوهش‌هایی که توسط (Long et al., 2017) و (Santi et al., 2021) انجام گرفته است که به افزایش وضوح تصاویر SMAP پرداختند (Santi et al., 2021) به وضوح ۱۰۰ متر از تصاویر رطوبتی دست یافت. در پژوهشی (Wakigari & Leconte, 2022) از مدل‌های جنگلی تصادفی برای

¹ brightness temperature

کاهش مقیاس محصولات SMAP به ۱ کیلومتر استفاده کرد، که داده‌های Sentinel-1 SAR نقش کمتری در این فرآیند داشت. در پژوهشی در مزرعه‌ای در منطقه نیمه‌خشک در جنوب آریزونا ایالات متحده آمریکا به بررسی رطوبت خاک براساس تلفیق تصاویر MODIS و SMAP پرداختند، نتایج به‌دست آمده نشان داد ترکیب داده‌های SMAP و MODIS در این شرایط می‌تواند منجر به یک محصول رطوبت خاک با وضوح بالا با دقت مناسب برای بسیاری از کاربردها شود (Colliander et al., 2017). استفاده از تکنیک‌های مدل‌های یادگیری ماشین برای تخمین رطوبت خاک به دلیل توانایی آنها در مقابله با بسیاری از محدودیت‌ها، توجه بیشتری را به خود جلب کرده است (Fatholoulumi et al., 2020; J. Han et al., 2018). مزیت اصلی مدل‌های یادگیری ماشین توانایی آنها در شناسایی خودکار و کارآمد روابط پیچیده و استخراج ویژگی‌های مکانی-زمانی از انواع مختلف داده‌های خام است که فرصتی برای تخمین دقیق‌تر پروفیل رطوبت خاک فراهم می‌کند (Adab et al., 2020). در تحقیقاتی که توسط (Greifeneder et al., 2021) و (Xing et al., 2017) انجام شده است، کاربرد عملی یادگیری ماشین را در این زمینه بیشتر نشان می‌دهند، (Greifeneder et al., 2021) یک رویکرد نقشه برداری رطوبت خاک با وضوح بالا را معرفی می‌کند. در پژوهشی (Fatholoulumi et al., 2020) رطوبت خاک را با استفاده از شاخص‌های مشتق شده از داده‌های لندست-۸ و مدل‌های یادگیری ماشین (الگوریتم‌های جنگل تصادفی (RF) و رگرسیون خطی چندگانه (MLR)) پیش‌بینی کردند، نتایج آن‌ها نشان داد که الگوریتم RF بیشترین عملکرد را در مدل‌سازی رطوبت خاک داشته است. در پژوهشی (Ge et al., 2019) با استفاده از شاخص‌های نوری حاصل از تصاویر پهپاد در ترکیب با الگوریتم‌های RF و ماشین یادگیری سریع (ELM) به برآورد رطوبت خاک سطحی در مناطقی از شهر فوکاگنج چین پرداختند نتایج بررسی‌ها نشان داد مدل RF نسبت به مدل ELM برتری داشته است همچنین مشخص شد که ترکیب شاخص‌های نوری و الگوریتم RF امکان تخمین رطوبت خاک را با دقت بالا (ضریب تبیین ۰.۹۱ و درصد انحراف نسبی ۳.۳۹) در مقیاس منطقه‌ای فراهم می‌کند. هدف از این پژوهش، بهبود دقت برآورد و پایش زمانی-مکانی رطوبت خاک سطحی در اراضی زیر کشت ذرت با استفاده از ریزمقیاس‌سازی داده‌های ماهواره‌ای SMAP از طریق ترکیب داده‌های Sentinel-1 SAR و MODIS و به‌کارگیری تکنیک یادگیری ماشین جنگل تصادفی (Random Forest) است. در پژوهشی (Yazdani et al., 2023) با استفاده از داده‌های روزانه رطوبت خاک ماهواره SMAP، تغییرات زمانی-مکانی آب موردنیاز عملیات گل‌خرابی در شبکه آبیاری سپیدرود مورد تحلیل قرار گرفته است. نتایج نشان داد رطوبت خاک در طول دوره گل‌خرابی روندی کاهشی داشته و حجم آب ناخالص موردنیاز از سال‌های مرطوب به خشک افزایش می‌یابد، به‌طوری‌که تأخیر در زمان انجام گل‌خرابی موجب افزایش مصرف آب می‌شود. بر این اساس، انجام گل‌خرابی و تأمین آب در اوایل اردیبهشت، به‌ویژه در سال‌های خشک، به‌عنوان راهبردی مؤثر برای کاهش مصرف آب توصیه شده است. در پژوهشی (Jamei et al., 2020) داده‌های رطوبت خاک و دمای درخت‌سندگی ماهواره SMOS در غرب و جنوب غرب ایران با اندازه‌گیری‌های زمینی و مدل L-MEB مورد صحت‌سنجی قرار گرفت. نتایج نشان داد داده‌های رطوبت خاک SMOS از همبستگی مناسب و خطای قابل قبول برخوردار بوده و قابلیت استفاده در مطالعات هیدرولوژیکی، کشاورزی و مدیریت منابع آب در مقیاس منطقه‌ای را دارند. این مطالعه با هدف ارائه رویکردی کارآمد و کم‌هزینه برای برآورد دقیق رطوبت خاک در مقیاس مزرعه‌ای و بررسی نقش شاخص‌های پوشش گیاهی در بهبود همبستگی مدل انجام گرفته است.


مواد و روش‌ها

محدوده مورد مطالعه:

در سال زراعی ۱۴۰۱-۱۴۰۰، این مطالعه بر روی چندین مزرعه‌ی ذرت علوفه‌ای در محدوده استان قزوین انجام شد. مزارع مورد بررسی شامل پنج مزرعه از کشت و صنعت مگسال در دشت قزوین هستند. مساحت کل مزارع مگسال حدود ۹۷۰ هکتار بوده که ۸۶۰

² Multiple linear regression


هکتار آن قابل کشت است و این مزارع در بخش بشاریات (شهر خاکعلی) استان قزوین واقع شده‌اند (شکل ۱). استان قزوین بین ۳۶۰۰۹ درجه عرض شمالی و ۵۰۰۱۰ درجه طول شرقی قرار داشته و در منطقه‌ای نیمه‌کوهستانی و حداقل دو ناحیه اقلیمی مختلف قرار دارد؛ اقلیم منطقه به‌طور کلی سرد و نیمه‌خشک است. به‌منظور اندازه‌گیری رطوبت واقعی خاک و تأمین داده‌های مرجع زمینی، نمونه‌برداری خاک از عمق ۰ تا ۵ سانتی‌متر در پنج مزرعه ذرت واقع در کشت و صنعت مگسال طی دوره کشت تابستان ۱۴۰۱ انجام شد. داده‌های حاصل از این نمونه‌برداری به‌عنوان مرجع برای آموزش، کالیبراسیون و اعتبارسنجی مدل جنگل تصادفی در فرآیند کاهش مقیاس و برآورد رطوبت خاک مورد استفاده قرار گرفت. بر اساس نتایج آزمایش‌های فیزیکی، بافت خاک مزارع مورد مطالعه از نوع لوم گزارش شد. این واحدهای کشاورزی علاوه بر ذرت علوفه‌ای، محصولات زراعی نظیر گندم، جو و کلزا و محصولات باغی مانند پسته و گردو را نیز تولید می‌کنند. آب مورد نیاز مزارع از طریق ۷ حلقه چاه عمیق با دبی کل ۱۵۰ لیتر بر ثانیه تأمین می‌شود. جزئیات مربوط به مدیریت کشاورزی هر یک از مزارع و موقعیت جغرافیایی و نوع سیستم آبیاری آن‌ها در جدول (۱) ارائه شده است.



شکل ۱. موقعیت مکانی محدوده مورد مطالعه کشت و صنعت مگسال در دشت قزوین

یکی از محصولات عمده زراعی در شرکت کشت و صنعت مگسال، ذرت علوفه‌ای است. این محصول در مقایسه با سایر غلات، دارای دوره رشد کوتاه‌تر اما عملکرد بالاتر می‌باشد. کشت ذرت علوفه‌ای در منطقه مورد مطالعه معمولاً از اواخر خردادماه تا حداکثر بیستم تیرماه انجام می‌گیرد و برداشت آن از اواخر مهرماه تا اوایل آبان‌ماه صورت می‌پذیرد. دوره رشد این گیاه بسته به شرایط محیطی و مدیریتی، بین ۷۵ تا ۱۳۰ روز متغیر است (شکل ۲). مراحل فنولوژیکی اصلی رشد ذرت علوفه‌ای شامل ظهور گیاهچه، ساقه‌رفتن، ظهور گل‌نر و ماده، تشکیل دانه و در نهایت رسیدگی فیزیولوژیکی است. در این پژوهش، داده‌ها از پنج مزرعه ذرت علوفه‌ای رقم سینگل کراس ۷۰۴ که موقعیت جغرافیایی آن‌ها در جدول (۱) ارائه شده، جمع‌آوری گردید. کشت محصول در سال زراعی ۱۴۰۱-۱۴۰۰ به‌صورت دو ردیفه با فاصله بین ردیف‌ها ۸۰ سانتی‌متر و فاصله بین دو گیاه بر روی پشته ۲۰ سانتی‌متر انجام شد. کاشت در اوایل تیرماه و

برداشت در مهرماه انجام پذیرفت. برای اندازه‌گیری رطوبت خاک در زمان برداشت، از دستگاه رطوبت‌سنج خاک مدل HH2 استفاده شد. در هر قطعه زراعی، ۹ نمونه رطوبت خاک در عمق پنج سانتی‌متری اندازه‌گیری گردید که در مجموع ۴۵ داده میدانی از رطوبت خاک به‌دست آمد.



شکل ۲. مراحل رشد ذرت علوفه‌ای

جدول ۱. موقعیت جغرافیایی مزارع مورد بررسی و نوع سیستم آبیاری

شیوه آبیاری	عرض جغرافیایی	طول جغرافیایی	نام مزرعه
تیپ	۳۶ ۸ ۸۷۳	۵۰ ۹ ۹۹۵	M1
تیپ	۳۶ ۸ ۸۱۷	۵۰ ۱۰ ۰۲۷	M2
لینیر	۳۶ ۹ ۴۰۳	۵۰ ۱۰ ۱۸۴	M3
تیپ	۳۶ ۹ ۹۶۸	۵۰ ۱۰ ۴۶	M4
تیپ	۳۶ ۱۰ ۱۰۵	۵۰ ۱۰ ۴۲۵	M5

ماهواره SMAP

ماهواره (SMAP (Soil Moisture Active Passive) توسط ناسا در ژانویه ۲۰۱۵ پرتاب شد (Entekhabi et al., 2010) تا رطوبت سطحی خاک و وضعیت یخ‌زدگی یا ذوب سطح زمین را پایش کند. این ماهواره در مدار نزدیک به قطبی با ارتفاع ۶۸۵ کیلومتر قرار دارد و داده‌های جهانی رطوبت خاک را جمع‌آوری می‌کند. SMAP از سنجنده فعال و غیرفعال باند L استفاده می‌کند: رادار فعال برای اندازه‌گیری بازپراکنش سطح زمین و شناسایی ویژگی‌های فیزیکی خاک و رادیومتر غیرفعال برای اندازه‌گیری دمای روشنایی و برآورد رطوبت خاک. ترکیب هم‌زمان این داده‌ها موجب افزایش دقت مکانی و صحت فیزیکی محصولات شد. این محصولات در سه رزولوشن مکانی ۳، ۹ و ۳۶ کیلومتر ارائه می‌شوند و کل زمین را هر ۲-۳ روز پوشش می‌دهند. سطوح محصول شامل L2 داده‌های نیمه مداری، L3 تخمین‌های روزانه و L4 محصولات همسان‌سازی مدل است. پس از توقف رادار فعال در جولای ۲۰۱۵، رادیومتر غیرفعال همچنان

فعال است و داده‌ها را با تفکیک ۳۶ کیلومتر ارائه می‌دهد. دقت اندازه‌گیری رطوبت خاک حدود $\pm 0.4\%$ متر مکعب آب در هر متر مکعب خاک است (S. K. Chan et al., 2016).

تصاویر ماهواره‌ای Sentinel-1 و محصولات MODIS

ماهواره‌های Sentinel-1A و Sentinel-1B بخشی از برنامه Copernicus آژانس فضایی اروپا هستند و از نوع رادار دهانه مصنوعی (SAR) فعال در باند C با فرکانس ۵۰۴۰۵ گیگاهرتز می‌باشند Sentinel-1A در آوریل ۲۰۱۴ پرتاب شد و داده‌های آن از اکتبر ۲۰۱۴ در دسترس قرار گرفت. این دو ماهواره در مدار مشترک و با اختلاف فاز ۱۸۰ درجه قرار دارند تا پوشش زمانی بهتری فراهم شود و در صورت بهره‌برداری هم‌زمان، کل سطح زمین هر ۶ روز یک‌بار تصویربرداری می‌شود. سنجنده SAR قابلیت تصویربرداری در پلاریزاسیون دوگانه HH/HV یا VV/VH را دارد و زاویه تابش امواج بین ۲۹٫۱ تا ۴۶ درجه متغیر است. حالت Interferometric Wide Swath (IW) اصلی‌ترین حالت تصویربرداری است که پهنای تصویر حدود ۲۵۰ کیلومتر و توان تفکیک مکانی ۵ متر در امتداد آزمون و ۲۰ متر در امتداد رنج دارد و برای کاربردهای تداخل سنجی راداری (InSAR) طراحی شده است (Lazecky et al., 2017). در این پژوهش، علاوه بر داده‌های Sentinel-1 و محصولات رطوبت خاک SMAP، از پروداکت‌های متنوع ماهواره MODIS نیز بهره‌گیری شده است. این محصولات شامل شاخص‌های پوشش گیاهی و پارامترهای سطح زمین نظیر NDVI، EVI، LST، NDWI، LAI و آلبدو هستند که در برآورد و مدل‌سازی رطوبت خاک نقش کلیدی دارند. ویژگی‌های فنی و جزئیات هر یک از این محصولات در جدول (۱) ارائه شده است.

جدول ۱. مشخصات سنسور مورد استفاده ورودی به همراه مشخصات هر یک از آن‌ها

سنجنده		قدرت تفکیک مکانی	قدرت تفکیک زمانی (روز)
MODIS	MOD13Q1	۲۵۰ متر	۱۶
	MOD15A2H	۵۰۰ متر	۸
	MOD11A2	۱۰۰۰ متر	روزانه
	MOD09Q1	۵۰۰ متر	۸
	MCD12Q1	۵۰۰ متر	-
	E_P_SM_3L	۹ کیلومتر	۲-۳
SMAP	Pol-Dual - 2LHD-GRD_I	۲۰ متر	۶-۱۲
SRTM	Topographic Data	۳۰ متر	-
نقشه رقم ارتفاعی (DEM)			

روش ریزمقیاس‌سازی مبتنی بر یادگیری ماشین

یکی از کاربردهای مهم سنجش از دور، استفاده از روش‌های طبقه‌بندی برای نقشه‌برداری و نظارت بر پوشش زمین است. دقت تصویر طبقه‌بندی شده را می‌توان به صورت کمی ارزیابی کرد (Congalton & Green, 2019). دقت نتیجه طبقه‌بندی، نه تنها به تصویر یا داده‌های طبقه‌بندی شده بستگی دارد، بلکه به دقت روش طبقه‌بندی اعمال شده نیز وابسته است (Rodriguez-Galiano & Chica-Rivas, 2014). روش جنگل تصادفی (RF) با موفقیت در مطالعات مختلف برای تخمین رطوبت خاک استفاده شده است (Portal et al., 2023). در پژوهشی (Sheng et al., 2019) از رویکرد کاهش مقیاس مبتنی بر RF برای بهبود دقت محصول رطوبت خاک میکروویو غیرفعال، به منظور دستیابی به همبستگی بالا و انحراف کم استفاده کرد. (Park et al., 2015) و (Senanayake et al., 2015).

(2021) هر دو دریافتند که رویکردهای یادگیری ماشین، به ویژه مدل‌های جنگل تصادفی و رگرسیون، از روش‌های سنتی در ریزمقیاس - کردن داده‌های رطوبت خاک بهتر عمل می‌کنند. (Pasolli et al., 2009) به بررسی بیشتری پرداخت و اثبات کرد که روش جنگل تصادفی در تخمین رطوبت خاک از داده‌های حسگری از راه دور مایکروویو، موثر است. (Senyurek et al., 2020) این کار را گسترش داد و از یادگیری ماشینی برای تخمین رطوبت خاک از اندازه‌گیری‌های سنجش از دور مبتنی بر ماهواره استفاده کرد و به دقت رضایت‌بخشی دست یافت. به‌منظور بررسی تأثیر متغیرهای مختلف سنجش از دور و توپوگرافی بر دقت تخمین رطوبت سطح خاک، شش سناریوی مدل‌سازی با استفاده از الگوریتم جنگل تصادفی (Random Forest) طراحی گردید. این سناریوها با هدف مقایسه عملکرد مدل در حضور مجموعه‌های متفاوت از متغیرهای ورودی تدوین شده‌اند. پنج سناریوی نخست مبتنی بر ترکیب‌های ارائه‌شده در پژوهش (Bai et al., 2019) هستند، در حالی که سناریوی ششم، توسعه‌ای از آن‌ها و پیشنهاد پژوهش حاضر است. جزئیات هر سناریو و توجیه استفاده از متغیرهای مستقل در جدول ۲ ارائه شده است. پژوهش انجام شده بر اساس کدنویسی در محیط گوگل ارث انجین انجام گرفته است. گوگل ارث انجین یک پلتفرم قدرتمند مبتنی بر ابر است که امکان پردازش و تحلیل داده‌های بزرگ زمین‌شناسی، آب و هوا و محیط‌زیست را فراهم می‌کند. این محیط، دسترسی سریع به مجموعه‌های داده ماهواره‌ای بلندمدت، ابزارهای پیشرفته تحلیلی و قابلیت اجرای الگوریتم‌های پیچیده بر روی حجم عظیمی از داده‌ها را بدون نیاز به منابع محلی فراهم می‌سازد. استفاده از گوگل ارث انجین در این پژوهش، امکان تحلیل گسترده و دقیق داده‌های مکانی را فراهم کرده و به کدنویسی و اجرای سناریوهای مختلف با دقت و سرعت بالا کمک کرده است. پیش‌پردازش داده‌های ماهواره‌ای شامل حذف پیکسل‌های ابری، اعمال فیلترهای کیفی، تصحیح رادیومتریک و هم‌مکانی مکانی داده‌ها بود. داده‌های دمای سطح زمین (LST) و شاخص‌های پوشش گیاهی شامل NDVI، EVI و LAI از تصاویر اپتیک استخراج شدند. شاخص NDWI و آلبدو سطحی نیز به‌منظور نمایش شرایط رطوبتی و ویژگی‌های بازتاب سطح زمین محاسبه گردید. داده‌های راداری Sentinel-1 (σ^0 vv) پس از کالیبراسیون رادیومتریک مورد استفاده قرار گرفتند. متغیرهای توپوگرافی شامل ارتفاع و شیب از مدل رقومی ارتفاع استخراج شدند. تمامی داده‌ها به یک سیستم مختصات و شبکه مکانی مشترک بازنمونه‌برداری شده و در محیط Google Earth Engine پردازش شدند. از نظر زمانی، به‌منظور کاهش ناهمگنی ناشی از تواتر مشاهداتی متفاوت سنجنده‌های ماهواره‌ای، از رویکرد هم‌زمان‌سازی زمانی استفاده شد. بدین صورت که تمامی متغیرهای ورودی در بازه‌های زمانی مشترک تجمیع شدند. برای داده‌هایی با تواتر زمانی بالاتر، میانگین زمانی محاسبه شد و برای داده‌هایی با تواتر کمتر، نزدیک‌ترین مشاهده زمانی به‌عنوان نماینده آن بازه انتخاب گردید. این روش امکان ادغام مؤثر داده‌های چندمنبعی را فراهم کرده و پایداری مدل‌های یادگیری ماشین را افزایش داد. به‌منظور بررسی تأثیر ترکیب متغیرهای مختلف بر دقت تخمین رطوبت خاک، شش سناریوی مدل‌سازی مبتنی بر الگوریتم جنگل تصادفی طراحی شد. در این سناریوها، رطوبت خاک به‌صورت تابعی از متغیرهای ورودی مختلف مدل‌سازی گردید. مدل جنگل تصادفی با استفاده از نمونه‌برداری تصادفی از داده‌ها و ایجاد مجموعه‌ای از درختان تصمیم‌گیری آموزش داده شد. این ساختار باعث کاهش بیش‌برازش و افزایش قابلیت تعمیم مدل گردید. داده‌ها به دو مجموعه آموزش و اعتبارسنجی تقسیم شدند و عملکرد مدل‌ها با استفاده از شاخص‌های آماری شامل ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) ارزیابی شد. نتایج حاصل از مقایسه سناریوهای مختلف نشان داد که افزودن متغیرهای راداری و توپوگرافی، به‌ویژه در سناریوی RF₆، نقش قابل توجهی در بهبود دقت ریزمقیاس‌سازی رطوبت سطح خاک دارد.


جدول ۲. سناریوهای تعریف شده در این پژوهش

منبع	معادله مدل	سناریو
Bai et al. (2019)	$SM = RF_1(LST, NDVI)$	۱
Bai et al. (2019)	$SM = RF_2(LST, NDVI, \sigma^{0}_{vv})$	۲
Bai et al. (2019)	$SM = RF_3(LST, NDVI, elevation)$	۳
Bai et al. (2019)	$SM = RF_4(LST, NDVI, elevation, \sigma^{0}_{vv})$	۴
Bai et al. (2019)	$SM = RF_5(LST, NDVI, EVI, NDWI, LAI, albedo)$	۵
سناریوی پیشنهادی پژوهش حاضر (ترکیب یافته از Bai et al., 2019; Paloscia et al., 2013; Fang et al., 2022)	$SM = RF_6(LST, NDVI, EVI, NDWI, LAI, Land Cover, elevation, albedo, slope, \sigma^{0}_{vv})$	۶

پنج سناریوی نخست RF_1 تا RF_5 بر اساس ترکیب متغیرهای پیشنهادی در پژوهش Bai et al. (2019) طراحی شده‌اند تا امکان مقایسه مستقیم نتایج و ارزیابی سازگاری مدل در منطقه مورد مطالعه فراهم شود. این سناریوها به صورت مرحله‌ای توسعه یافته‌اند، به طوری که ابتدا متغیرهای پایه شامل دمای سطح زمین (LST) و شاخص پوشش گیاهی NDVI به عنوان نمایانگر فرآیندهای تبخیر و تعرق و وضعیت زیستی پوشش گیاهی در نظر گرفته شده‌اند. سپس با افزودن داده بازپراکنش راداری (σ^{0}_{vv}) و متغیرهای توپوگرافی، نقش ویژگی‌های فیزیکی سطح زمین و ناهمگنی مکانی خاک در بهبود تخمین رطوبت خاک بررسی شده است. در سناریوی RF_5 ، مجموعه‌ای از شاخص‌های تکمیلی پوشش گیاهی و انرژی سطحی به مدل افزوده شده‌اند تا اطلاعات مرتبط با وضعیت آبی گیاه، ظرفیت تبخیر و تعرق و توازن تابشی سطح زمین به صورت جامع‌تری لحاظ شود.

سناریوی ششم (RF_6) به عنوان توسعه‌ای از پژوهش‌های پیشین و پیشنهاد این مطالعه ارائه شده است. در این سناریو، علاوه بر متغیرهای سنجش از دور اپتیکی و حرارتی، داده‌های راداری، متغیرهای توپوگرافی و اطلاعات کاربری/پوشش اراضی نیز در نظر گرفته شده‌اند. هدف از طراحی این سناریو، ارزیابی تأثیر هم‌زمان عوامل زیستی، فیزیکی و توپوگرافی بر رطوبت سطح خاک و دستیابی به بیشینه دقت و پایداری مدل در شرایط مکانی متنوع بوده است.

در شکل ۳ نمایی از مراحل کلی اجرای سناریوهای برآورد رطوبت خاک نمایش داده شده است.




شکل ۳. فلوچارت روند انجام پژوهش

نتایج و بحث

در این قسمت از پژوهش به بررسی مقادیر حاصل از هر سناریو و مقادیر SMAP پرداخته شد. خروجی‌های به دست آمده نشان می‌دهد که میزان همبستگی در سناریو ۱ با مقادیر حاصل از SMAP برابر با $R^2 = 0.51$ است در حالی که در سناریو دوم علاوه بر دو شاخص LST و NDVI، پارامتر σ_{vv}^0 اضافه شده است که موجب افزایش میزان همبستگی مقادیر حاصل سناریو ۲ و مقادیر SMAP شده است. زیرا با اضافه شدن پارامتر شدت بازتاب راداری، اطلاعات بیشتری از ویژگی‌های فیزیکی خاک و رطوبت خاک در دسترس قرار می‌گیرد. زیرا شدت بازتاب راداری معمولاً به میزان بازتابی که سیگنال رادار از سطح زمین دریافت می‌کند، بستگی دارد. این بازتاب در حقیقت به ویژگی‌های سطح زمین مانند ساختار خاک، میزان رطوبت و سایر خصوصیات مربوط به پوشش گیاهی بستگی دارد. با استفاده از پارامتر σ_{vv}^0 ، می‌توان از تغییرات بازتاب راداری در طول زمان و در شرایط مختلف، به عنوان نشانگری برای تغییرات رطوبت خاک استفاده کرد. این معمولاً به دلیل تفاوت‌هایی در خواص الکترومغناطیسی خاک در شرایط مختلف رطوبتی است. در بررسی سناریو ۳ مشخص شد که این سناریو با مقدار $R^2 = 0.62$ همبستگی کمتری به نسبت سناریو ۲ با مقادیر SMAP داشته است. علت این موضوع می‌تواند ناشی از عدم وجود تغییرات ارتفاعی زیاد در سطح منطقه باشد. به‌طوری که براساس نقشه SRTM بخش وسیعی از مرکز دشت را که سطح زیر کشت بالایی را به خود اختصاص داده است محدوده مسطح پوشش داده است. بنابراین یکی از دلایل وجود همبستگی پایین‌تر در این سناریو، تاثیر کم پارامتر ELEVATION در تغییرات رطوبت خاک اشاره کرد. در بررسی تغییرات سایر سناریوها نیز مشخص شد که با اضافه شدن شاخص‌های LAI، EVI و Albedo میزان همبستگی این سناریو افزایش یافته است به


طوری که میزان همبستگی سناریو ۵ در مقایسه با سناریو ۴ به میزان ۳۰ درصد افزایش داشته است. رابطه بین رطوبت خاک و شاخص سطح برگ (LAI) پیچیده است و تحت تأثیر عوامل مختلف قرار می‌گیرد. بررسی‌های مختلف از پژوهش‌های انجام شده نشان داده است که شاخص سطح برگ ارتباط و همبستگی بالایی با مقادیر رطوبت خاک دارد به طوری که (Hoek van Dijke et al., 2020; Rahman et al., 2022) هر دو همبستگی قابل توجهی بین رطوبت خاک و شاخص سطح برگ (LAI) یافتند، که در ابتدا نشان داد که جذب مشترک این متغیرها تخمین پوشش گیاهی زمین و متغیرهای آب را بهبود می‌بخشد. از دیگر پارامترهای موثر در افزایش میزان همبستگی در این سناریو می‌توان به آلبیدو اشاره کرد. زیرا تحقیقات به طور مداوم یک همبستگی منفی بین رطوبت خاک و آلبیدو را نشان می‌دهد، زیرا رطوبت بالاتر خاک منجر به کاهش آلبیدو می‌شود (Yang et al., 2020). این رابطه به ویژه در مناطق خشک، جایی که رطوبت خاک نقش مهمی در آلبیدو طیفی سطحی ایفا می‌کند قوی است (Yang et al., 2020). در نهایت بررسی تمامی سناریوها نشان داد که سناریو ۶ با ضریب همبستگی ۹۸ درصد بیشترین میزان همبستگی را داشته است که اضافه شدن مواردی همچون نقشه کاربری اراضی و پارامتر σ_{vv}^0 به طور همزمان توانسته است میزان همبستگی را افزایش دهد.



شکل ۴. بررسی همبستگی رطوبت خاک SMAP و شش سناریو مورد بررسی در مقیاس ۹ کیلومتر

در ادامه به منظور بررسی و دقت خروجی‌های سناریوهای تعریف شده با داده‌های زمینی به بررسی و مقایسه مقادیر و نمونه‌های برداشت شده از ۵ مزرعه ذرت پرداخته شد. بررسی نمونه‌های برداشت شده نشان می‌دهد که در بین سناریوهای مورد بررسی در مزرعه یک (M1)، سناریو RF6 با مقدار $R=0.97$ و $RMSE=0.04$ بیشترین میزان همبستگی را داشته است. بعد از سناریو RF6، سناریو RF5 با مقدار $R=0.96$ از همبستگی بالایی برخوردار بوده، بررسی شاخص میانگین خطای مطلق نشان می‌دهد که این شاخص در سناریوهای RF1 و RF2 با مقدار $MBE=0.10$ نتایج مشابهی را داشته است. بررسی سایر سناریوها در مزارع مورد بررسی نیز نشان داد که سناریو RF6 در تمامی مزارع بیشترین میزان همبستگی را دارا بوده، در مقابل سناریو RF1 از کمترین میزان همبستگی برخوردار هستند به طوری که در مزرعه ۵ (M5) میزان همبستگی سناریو RF1 برابر با $R=0.40$ است. از جمله دلایل افزایش میزان همبستگی در سناریوهای RF5 و RF6 را می‌توان به وجود شاخص LAI و نقشه کاربری اراضی اشاره کرد. زیرا در پژوهشی (Ines et al., 2013) دریافتند که اندازه‌گیری رطوبت خاک و شاخص سطح برگ با استفاده از نقشه‌های سنجش از دوری، پیش‌بینی عملکرد محصول ذرت را بهبود می‌بخشد. در پژوهشی دریافتند که رطوبت خاک قوی‌ترین همبستگی را با شاخص سطح برگ در یک منطقه از آمازون دارد و همچنین نقشه کاربری اراضی توانسته است دقت داده‌های برآورد شده از سناریو رطوبت خاک را تا حد قابل قبولی افزایش دهد. (Qiu et al., 2001) تاثیر شاخص‌های محیطی، مانند کاربری و توپوگرافی، بر تغییرپذیری مکانی رطوبت خاک را شناسایی کرد. به طوری که دریافت استفاده از نقشه کاربری اراضی در ماه‌های ژوئن و آگوست با تفاوت بیشتر در پوشش گیاهی مطابقت دارد و تاثیر قابل توجهی در برآورد رطوبت خاک دارد. بررسی هر یک از سناریوها در مزارع مورد بررسی نشان که سناریو RF6 در مزرعه ۵ (M5) با ضریب همبستگی $R=0.99$ ، $RMSE=0.05$ و $MBE=-0.03$ بیشترین همبستگی و بالاترین دقت را در میان سناریوها و مزارع مورد بررسی داشته است. همچنین با توجه به نمودار ارائه‌شده در شکل (۵)، مشاهده می‌شود که در مزرعه سوم (M3)، روند تغییرات تمامی سناریوهای ریزمقیاس‌سازی (RF1) تا (RF6) از الگوی مشابهی پیروی می‌کنند، در حالی که در سایر مزارع چنین هم‌جهتی بین سناریوها مشاهده نمی‌شود. این پدیده را می‌توان عمدتاً ناشی از تفاوت در نوع سیستم آبیاری مزرعه سوم نسبت به سایر مزارع دانست. در مزرعه سوم، سیستم آبیاری مورد استفاده از نوع تیپ با الگوی طراحی و فشار کاری متفاوت بوده است که منجر به توزیع یکنواخت‌تر آب در سطح مزرعه و در نتیجه کاهش ناهمگنی مکانی رطوبت خاک گردیده است. کاهش تغییرپذیری مکانی رطوبت، باعث همگرایی در خروجی مدل‌های مختلف و افزایش هم‌جهتی منحنی‌های سناریوهای ریزمقیاس‌سازی در این مزرعه شده است. در مقابل، در سایر مزارع که اگرچه از سیستم آبیاری تیپ استفاده شده، اما به دلیل اختلاف در فشار خطوط، ناهموازی سطح زمین، تفاوت در بافت خاک و مدیریت مزرعه، توزیع آب یکنواخت نبوده و رطوبت خاک در سطح مزرعه با نوسان بیشتری همراه بوده است. این ناهمگنی سبب شده است تا مدل‌ها نسبت به پارامترهای ورودی حساسیت متفاوتی نشان دهند و خروجی سناریوها از هم واگرایی بیشتری داشته باشند. به‌طور کلی، نتایج نشان می‌دهد که نوع سیستم آبیاری و یکنواختی توزیع آب از عوامل کلیدی مؤثر بر همبستگی و دقت مدل‌های برآورد رطوبت خاک در مقیاس مزرعه‌ای است. همچنین تفاوت خروجی سناریوهای مختلف (RF1) تا (RF6) در مزارع مورد بررسی را می‌توان ناشی از تفاوت در ترکیب متغیرهای ورودی هر سناریو و ویژگی‌های محیطی و مدیریتی مزارع دانست. هر یک از سناریوها بر اساس نوع متغیرهای مورد استفاده، حساسیت متفاوتی نسبت به عوامل مؤثر بر رطوبت خاک دارند و این امر سبب تغییر رفتار مدل‌ها در شرایط مکانی مختلف شده است. در سناریوهای اولیه RF1، RF2 و RF3 تنها پارامترهای محدود نظیر دمای سطح زمین (LST)، شاخص پوشش گیاهی (NDVI) و در برخی موارد ارتفاع (Elevation) به کار گرفته شده است. این متغیرها قادرند تغییرات کلی رطوبت خاک را تا حدی توضیح دهند، اما در مزارعی که دارای ناهمگنی مکانی بالا، تغییر در بافت خاک یا تفاوت در شرایط آبیاری هستند، پاسخ دقیقی ارائه نمی‌دهند. از این‌رو در مزارعی نظیر (M1) و (M5) که نوسان رطوبتی بیشتر و شرایط آبیاری کمتر یکنواخت است، اختلاف خروجی بین سناریوها بیشتر مشاهده می‌شود. در مقابل، در سناریوهای پیچیده‌تر مانند RF5 و RF6، از متغیرهای تکمیلی نظیر شاخص‌های طیفی (EVI)، (NDWI)، (LAI)، پارامترهای فیزیوگرافی (شیب و ارتفاع) و نقشه کاربری اراضی Land Cover استفاده شده است. این متغیرها توان مدل را برای شناسایی روابط غیرخطی بین ویژگی‌های سطحی و رطوبت خاک افزایش

می‌دهند. به همین دلیل، در مزارعی مانند M3 که از نظر مدیریت آبیاری (تیپ با فشار یکنواخت‌تر) و شرایط سطحی از پایداری بالاتری برخوردار است، رفتار سناریوها هم‌جهت و با همبستگی بالا مشاهده می‌شود. به طور کلی، اختلاف عملکرد سناریوها در مزارع مختلف ناشی از سه عامل اصلی است: ۱- تفاوت در ورودی‌های مدل و میزان وابستگی آن‌ها به شرایط سطحی و زیستی، ۲- ناهمگنی مکانی رطوبت خاک ناشی از نوع آبیاری و بافت خاک، ۳- تفاوت در پاسخ شاخص‌های پوشش گیاهی به شرایط اقلیمی و مدیریتی هر مزرعه است.



شکل ۵. نمودار پراکندگی رطوبت خاک اندازه‌گیری شده در مزرعه و ریزمقیاس‌سازی تا یک کیلومتر در سناریوهای تعریف شده


جدول ۳. مقایسه نتایج شاخص‌های آماری رطوبت خاک زیرمقیاس شده در پنج مزرعه در سناریوهای RF1-RF6.

		MAE	RMSE	NRMSE	R	MBE			MAE	RMSE	NRMSE	R	MBE
M1	RF6	۰/۰۳	۰/۰۴	۰/۱۵	۰/۹۷	-۰/۰۲	M3	RF6	۰/۰۲	۰/۰۳	۰/۱۴	۰/۹۸	۰/۰۲
	RF5	۰/۰۹	۰/۱۰	۰/۳۰	۰/۹۶	-۰/۰۹		RF5	۰/۰۳	۰/۰۳	۰/۱۴	۰/۹۶	۰/۰۲
	RF4	۰/۰۸	۰/۱۰	۰/۵۴	۰/۸۸	۰/۰۶		RF4	۰/۰۳	۰/۰۴	۰/۱۸	۰/۹۱	۰/۰۲
	RF3	۰/۱۱	۰/۱۲	۰/۴۳	۰/۷۵	-۰/۰۲		RF3	۰/۰۸	۰/۰۹	۰/۳۱	۰/۷۶	-۰/۰۶
	RF2	۰/۱۰	۰/۱۱	۰/۳۷	۰/۷۹	-۰/۰۶		RF2	۰/۰۵	۰/۰۶	۰/۲۳	۰/۸۳	-۰/۰۴
	RF1	۰/۱۰	۰/۱۲	۰/۴۳	۰/۶۶	-۰/۰۲		RF1	۰/۱۰	۰/۱۲	۰/۳۹	۰/۵۶	-۰/۰۷
M2	RF6	۰/۰۶	۰/۰۵	۰/۱۷	۰/۹۷	۰/۰۱	M4	RF6	۰/۰۳	۰/۰۳	۰/۱۶	۰/۹۶	۰/۰۲
	RF5	۰/۰۶	۰/۰۶	۰/۲۴	۰/۹۴	۰/۰۱		RF5	۰/۰۲	۰/۰۳	۰/۱۲	۰/۹۵	۰/۰۱

RF4	۰/۰۶	۰/۰۸	۰/۲۷	۰/۹۰	-۰/۰۴	RF4	۰/۰۴	۰/۰۴	۰/۲۱	۰/۹۵	۰/۰۲
RF3	۰/۰۸	۰/۰۸	۰/۳۲	۰/۸۳	۰/۰۱	RF3	۰/۰۵	۰/۰۶	۰/۲۶	۰/۸۰	۰/۰۱
RF2	۰/۱۲	۰/۱۴	۰/۴۱	۰/۷۶	۰/۰۸	RF2	۰/۰۵	۰/۰۵	۰/۲۱	۰/۸۵	۰
RF1	۰/۱۴	۰/۱۶	۰/۴۱	۰/۶۴	-۰/۱۱	RF1	۰/۰۷	۰/۰۸	۰/۲۹	۰/۷۱	-۰/۰۴
M5						RF6	۰/۰۳	۰/۰۵	۰/۱۶	۰/۹۹	-۰/۰۳
						RF5	۰/۰۳	۰/۰۴	۰/۱۵	۰/۹۶	۰
						RF4	۰/۰۴	۰/۰۵	۰/۹۳	۰/۹۳	-۰/۰۱
						RF3	۰/۰۹	۰/۱۱	۰/۴۵	۰/۷۵	۰/۰۲
						RF2	۰/۰۸	۰/۱۰	۰/۳۱	۰/۸۵	۰/۰۵
						RF1	۰/۱۰	۰/۱۲	۰/۶۹	۰/۴۰	-۰/۰۴

در شکل ۶ سری زمانی رطوبت خاک اندازه‌گیری شده و رطوبت خاک برآورد شده توسط SMAP ریزمقیاس شده را نشان می‌دهد. اندازه‌گیری‌های میدانی رطوبت خاک در هر یک از پنج مزرعه به‌صورت نقطه‌ای و در چندین نقطه نمونه‌برداری انجام شد. به‌منظور تطبیق داده‌های زمینی با داده‌های ماهواره‌ای SMAP با تفکیک مکانی ۱ کیلومتر، میانگین مقادیر رطوبت خاک اندازه‌گیری شده در نقاط نمونه‌برداری هر مزرعه به‌عنوان نماینده رطوبت خاک در پیکسل متناظر در نظر گرفته شد. نمونه‌برداری‌ها به‌صورت دوره‌ای و هم‌زمان با بازه‌های زمانی در دسترس داده‌های SMAP طی ماه‌های جولای، آگوست و سپتامبر انجام شد و سری زمانی حاصل برای مقایسه با رطوبت خاک ریزمقیاس شده مورد استفاده قرار گرفت. در هر مزرعه، رطوبت خاک ۹ نقطه نمونه‌برداری شد که این نقاط به‌صورت یکنواخت در سطح مزرعه توزیع شده بودند. به‌منظور مقایسه با داده‌های SMAP با تفکیک مکانی ۱ کیلومتر، میانگین مقادیر رطوبت خاک اندازه‌گیری شده در هر تاریخ نمونه‌برداری محاسبه و به‌عنوان نماینده رطوبت خاک پیکسل متناظر در نظر گرفته شد. نمونه‌برداری‌ها به‌صورت هفتگی طی دوره رشد ذرت (تابستان ۱۴۰۱) انجام گرفت و با سری زمانی داده‌های ماهواره‌ای تطبیق داده شد.


بررسی‌ها نشان می‌دهد ماهواره SMAP توانسته است تغییرات رطوبتی خاک را تا حد قابل قبولی نمایش دهد. بررسی تغییرات رطوبت خاک در تمامی مزارع نشان می‌دهد که میزان رطوبت خاک با افزایش رشد گیاه، به مرور زمان افزایش یافته است به طوری که در طی ماه‌های مورد بررسی Jul، Aug و Sep به تدریج با افزایش رشد گیاه و افزایش میزان تبخیر و تعرق، میزان رطوبت خاک نیز افزایش یافته است. زیرا در طول فصل رشد، ذرت نیاز به آب برای تبخیر و تعرق دارد. با افزایش رشد ذرت و توسعه سیستم ریشه، نیاز به آب افزایش می‌یابد و در نتیجه رطوبت خاک به تدریج افزایش می‌یابد. بررسی مقادیر برآورد شده توسط SMAP نشان می‌دهد که در تمامی مزارع مورد بررسی، میزان رطوبت سطحی خاک برآورد شده توسط SMAP در ماه Aug در بالاترین مقدار خود قرار دارد. بررسی روند تغییرات رطوبت خاک در مزرعه M1 نشان می‌دهد که SMAP ریزمقیاس شده توانسته است روند تغییرات رطوبت خاک اندازه‌گیری شده را تا حد مطلوبی پوشش دهد به طوری که در ماه Jul، SMAP به میزان ۱۲٪ کم برآوردی داشته است. در بررسی مزارع M3، M4 و M5 نیز مشخص شد که از ابتدای دوره کشت تا اواسط ماه Aug مقادیر برآورد شده توسط SMAP ریزمقیاس شده، با کم برآوردی همراه است. بیشترین میزان اختلاف مربوط در اواخر دوره کشت در مزرعه M3 است به طوری که رطوبت برآورد شده توسط SMAP با مقادیر اندازه‌گیری شده با بیش برآوردی همراه بوده است. در پژوهشی به بررسی اثر استفاده از شاخص NDVI در برآورد میزان رطوبت خاک توسط SMAP در مناطق مختلف از جهان که تراکم پوشش گیاهی مختلفی را دارند انجام شد. بررسی‌های انجام شده نشان داد که استفاده از شاخص NDVI به تنهایی باعث بیش‌برآوردی رطوبت خاک می‌شود، زیرا استفاده از شاخص NDVI به تنهایی تخمین بیش از حد تأثیرات پوشش گیاهی را در نظر می‌گیرد و اثرات زبری سطح را نادیده می‌گیرد (Fan et al., 2020).



شکل ۶. نمودار سری زمانی رطوبت خاک اندازه‌گیری شده در مزارع مورد بررسی و مقایسه آن با مقادیر برآورد شده توسط SMAP 1km ریز مقیاس شده

در شکل ۷ روند تغییرات شاخص‌های NDVI، LAI و LST در طول دوره رشد ذرت نشان داده شده است. بررسی روند تغییرات شاخص NDVI بیانگر آن است که این شاخص توانسته است تغییرات پوشش گیاهی را به خوبی نمایش دهد، به طوری که در ماه July به دلیل کم بودن تراکم پوشش گیاهی، مقادیر NDVI کمتر بوده است. با توجه به اینکه کشت ذرت از ماه May آغاز می‌شود، در ابتدای دوره رشد به دلیل قرارگیری گیاه در مرحله جوانه‌زنی، مقادیر NDVI پایین بوده و با رشد تدریجی گیاه و افزایش سطح برگ، مقدار NDVI تا ماه Sep افزایش یافته است. همزمان با افزایش NDVI، شاخص سطح برگ (LAI) نیز روند افزایشی نشان داده و مقدار آن از حدود ۳٫۱ در ماه اوت به بیش از ۶ در ماه سپتامبر رسیده است که با نتایج گزارش شده در مطالعات میدانی پیشین در منطقه مورد مطالعه مطابقت دارد (Sotoude Nia, 2016). این تغییرات بیانگر توسعه تدریجی پوشش گیاهی بوده و از آنجا که شاخص‌های NDVI و LAI به طور مستقیم بر تبخیر-تعرق و تبادلات انرژی سطح زمین مؤثر هستند، انتظار می‌رود نقش تعیین‌کننده‌ای در بهبود برآورد رطوبت خاک در مدل‌های مبتنی بر یادگیری ماشین داشته باشند.


از سوی دیگر، بررسی تغییرات دمای سطح زمین (LST) در ماه‌های مورد مطالعه نشان می‌دهد که این پارامتر همراه با تغییرات NDVI و LAI تغییر می‌کند. با توجه به اینکه روابط بین NDVI و LST برای توصیف و به‌روزرسانی مدل‌های سطح زمین گزارش شده است (Han et al., 2006)، استفاده همزمان از این شاخص‌ها در توسعه مدل Random Forest امکان‌پذیرتر و شریک فیزیکی-زیستی سطح زمین را فراهم کرده و به بهبود عملکرد مدل در سناریوهای پیشرفته‌تر منجر شده است.



شکل ۷. روند تغییرات شاخص‌های موثر در برآورد رطوبت خاک در محدوده مورد مطالعه


در شکل ۸، تغییرات رطوبت خاک بر اساس روش‌های جنگل تصادفی و ماهواره SMAP نمایش داده شده است. بررسی روند تغییرات رطوبت خاک نشان می‌دهد، که رطوبت خاک بر اساس ماهواره SMAP به دلیل دارا بودن پیکسل سایزهای ۹ کیلومتری امکان نمایش روند تغییرات مزارع کوچک را به تفکیک مکانی مناسب ندارد، لذا سناریوهای تعریف شده می‌تواند تا حدی روند تغییرات را بهتر نمایش دهد، به طوری که بررسی مقادیر حاصل از ماهواره SMAP نشان می‌دهد که میزان رطوبت خاک در تمامی مزارع مورد بررسی مقداری ثابت و یکنواختی را شامل می‌شود. اما در بررسی سناریوهای تعریف شده مشخص شد که این سناریوها می‌تواند تغییرات رطوبت سطحی خاک مزارع مختلف را نمایش دهد. مقایسه و بررسی تغییرات مکانی رطوبت خاک بر اساس SMAP ریزمقیاس شده نشان می‌دهد که SMAP ریزمقیاس شده توانسته است روند تغییرات مکانی رطوبت خاک به خوبی نمایش دهد با توجه به این که تصویر انتخاب شده برای سناریوهای تعریف شده و SMAP ریزمقیاس شده، مربوط به ماه SEP است لذا رشد حداکثری و تراکم پوشش گیاهی سبب افزایش میزان رطوبت خاک می‌شود. بررسی روند تغییرات رطوبت خاک نشان داد که سناریو RF1 گرچه توانسته است روند تغییرات اراضی کشاورزی را به تفکیک جدا کند اما مقادیر حاصل از آن با کم برآوردی همراه بوده و سناریو RF1 در برآورد مقادیر رطوبت خاک

در اراضی مختلف از دقت کمی برخوردار بوده است. این درحالی است که در پژوهشی برآورد رطوبت خاک در عمق (۷۰-۰ سانتی‌متر) در مقیاس منطقه‌ای با استفاده از داده‌های NDVI و LST در بالادست حوضه رودخانه هیله، شمال غربی چین، موفقیت آمیز بوده است (X. Bai et al., 2020). بررسی سناریو RF2 نیز نشان می‌دهد که این سناریو به نسبت سناریو RF1 نتایج نزدیک‌تری را به مقادیر رطوبت خاک حاصل از ماهواره SMAP دارد، زیرا تصاویر رادار Sentinel-1 امکان بازیابی رطوبت خاک سطحی را با وضوح مکانی و زمانی بالا فراهم می‌کند (Gao et al., 2017). سناریو RF3 و RF4 نیز نشان می‌دهد که این دو سناریو نیز توزیع مکانی تغییرات رطوبت خاک را به خوبی نمایش نداده است به طوری که میزان رطوبت برآورد شده در مزرعه (M2) در سناریو RF3 به نسبت RF2 به میزان ۲۳ درصد کمتر است. بررسی توزیع مکانی تغییرات رطوبت خاک بر اساس سناریوهای RF5 و RF6 نشان می‌دهد که این سناریوها در مزارع مورد بررسی، نتایج نزدیک‌تری را به مقادیر ثبت شده توسط SMAP-1km دارد.



شکل ۸. بررسی پراکندگی تغییرات مکانی رطوبت خاک بر اساس سناریوهای تعریف شده و ماهواره SMAP

در شکل ۹. به بررسی همبستگی هر یک از شاخص‌ها و پارامترهای مورد بررسی در برآورد رطوبت خاک پرداخته شد. دمای سطح زمین (LST) یکی از پارامترهای مهم در بررسی رطوبت خاک محسوب می‌شود و به عنوان یک شاخص مفید برای پیش‌بینی رطوبت خاک و تحلیل تغییرات آن در طول زمان می‌شود. دمای سطح زمین می‌تواند تاثیر بسیار زیادی بر رطوبت خاک داشته باشد. زیرا با افزایش دما، تبخیر-تعرق بیشتری از سطح زمین اتفاق می‌افتد و در نتیجه رطوبت خاک کاهش می‌یابد. با کاهش رطوبت خاک گیاهان نمی‌توانند به میزان کافی آب را از خاک جذب کنند. در نتیجه رشد و توسعه آن‌ها کاهش می‌یابد. به همین منظور بررسی‌های انجام شده نشان می‌دهد که شاخص LST با میزان $R = -0.98$ بیشترین همبستگی را داشته است. بررسی میزان همبستگی میان دمای سطح زمین و شاخص‌های پوشش گیاهی NDVI، NDTI و LAI نشان داد که تمامی شاخص‌های بررسی شده همبستگی بالایی را با شاخص LST دارد. یکی از علل همبستگی منفی بین شاخص NDVI و LST تاثیر حرارت بر پوشش گیاهی است. زیرا با افزایش دمای سطح زمین گیاهان در معرض تاثیرات حرارتی قرار می‌گیرند که می‌تواند باعث کاهش رشد و سلامت گیاهی شود. در نتیجه پوشش گیاهی در منطقه کاهش می‌یابد و موجب کاهش مقدار شاخص NDVI می‌شود (Jagadish et al., 2021). همچنین با افزایش دمای سطح زمین تبخیر آب از سطح خاک و گیاهان نیز افزایش پیدا می‌کند و این مساله می‌تواند باعث کاهش NDVI و در نتیجه میزان پوشش گیاهی شود. از دیگر عوامل موثر در میزان همبستگی منفی در بین شاخص‌های پوشش گیاهی و دمای سطح زمین می‌توان به تغییرات فنولوژیکی گیاه اشاره کرد زیرا با افزایش دما تبادلات گازی گیاهان کاهش می‌یابد که باعث کاهش فعالیت فتوسنتزی گیاهان، کاهش رشد و سلامت گیاهی می‌شود (Ruiz - Vera et al., 2015). بعد از شاخص LST، شاخص Albedo با مقدار ضریب همبستگی $R^2 = -0.94$ در جایگاه دوم قرار دارد. شاخص سطح برگ (LAI) نیز با مقدار $R^2 = 0.88$ و $p < 0.05$ همبستگی معناداری را با مقادیر رطوبت خاک دارد. در بین پارامترها و شاخص‌های مورد بررسی، Slope با مقدار $R^2 = -0.20$ میزان همبستگی کمی را با مقادیر رطوبت خاک دارد. که علت این موضوع می‌تواند ناشی از عدم وجود شیب به نسبت زیاد در منطقه مورد مطالعه باشد.



* $p < 0.05$

شکل ۹. همبستگی بین مقدار رطوبت خاک حاصل از SMAP 1km و شاخص‌ها و پارامترهای مورد استفاده

نتیجه گیری:

رطوبت خاک نقش مهمی در مدیریت فرایندهای هیدرولوژیکی و سطح زمین ایفا می کند و برای برنامه های کاربردی هیدرولوژی، باغبانی، کشاورزی و هواشناسی حیاتی است. پایش رطوبت خاک برای پیش بینی آب و هوا، خشکسالی، مدیریت منابع آب، تولید گیاهان کشاورزی، تبخیر و تعرق و پیشگیری از بلایا اهمیت دارد. بنابراین روشی برای تولید داده های SMAP ریزمقیاس شده با ترکیب داده های نوری / مادون قرمز با داده های SAR بر اساس تکنیک RF ارائه شد. لذا در ابتدا به برآورد رطوبت سطحی خاک در محدوده مزارع ذرت کشت و صنعت مگسال براساس ماهواره SMAP در وضوح ۹ کیلومتر پرداخته شد. بررسی خروجی های به دست آمده نشان داد با توجه به اینکه ماهواره SMAP دارای پیکسل سایزهای ۹ کیلومتری می باشد بنابراین به تنهایی دارای دقت کافی برای مناطقی که بررسی رطوبت خاک با جزئیات و تفکیک مکانی دارای اهمیت می باشد مناسب نیست لذا به همین منظور به بررسی رطوبت خاک براساس تعریف سناریوهای مختلف و SMAP ریز مقیاس شده، پرداخته شد. بنابراین در این پژوهش شش سناریو مختلف بر اساس روش جنگل تصادفی (RF) و شاخص های مختلف تعریف شد. بررسی خروجی های به دست آمده نشان می دهد که سناریوهای RF6 و RF5 به ترتیب با میزان همبستگی $R=0.98$ و $R=0.95$ با داده های SMAP بیشترین همبستگی را دارد. پس از بررسی همبستگی پیکسل های SMAP با سناریوهای تعریف شده، به بررسی همبستگی نمونه های برداشت شده از پنج مزرعه مورد بررسی و هریک از سناریوهای تعریف شده پرداخته شد. خروجی های به دست آمده نشان داد که سناریو RF1 از کمترین میزان همبستگی برخوردار هستند به طوری که در مزرعه ۵ (M5) میزان همبستگی سناریو RF1 برابر با $R=0.40$ است. درحالی که سناریو RF6 در مزرعه ۵ (M5) با ضریب همبستگی $R=0.99$ بیشترین میزان همبستگی و دقت را برخوردار است. که علت همبستگی بالای سناریو RF6 به دلیل وجود شاخص های Land Cover، LAI و σ_{vv}^0 به طور همزمان و تاثیر افزایش دقت میزان رطوبت خاک در سناریو تعریف شده است. به طوری که در بررسی همبستگی میزان رطوبت خاک با شاخص LAI مشخص شد که میزان همبستگی رطوبت خاک با شاخص LAI برابر با ۰/۸۸ است که نشان دهنده دقت مناسب و اهمیت بالای این شاخص در برآورد میزان رطوبت خاک در منطقه مورد مطالعه است. بنابراین دو سناریو RF5 و RF6 نسبت به دیگر سناریوها به خوبی تغییرات رطوبت خاک در مقیاس میدانی را بدون نیاز به اطلاعات زمینی نشان دادند. بنابراین استفاده از نتایج پژوهش حاضر می تواند در زمینه رفع چالش پایش بلادرنگ رطوبت خاک و گیاه راهگشا و کاربردی باشد. برای تأیید هرچه بیشتر نتایج این تحقیق، پیشنهاد می شود در مطالعات آینده ارتباط بین رطوبت خاک و داده های سنجش از دور در شرایط محیطی و مدیریتی متفاوت بررسی شود. با وجود نتایج قابل قبول به دست آمده، این پژوهش با برخی چالش ها و محدودیت ها نیز همراه بوده است. از جمله این محدودیت ها می توان به وابستگی نتایج به کیفیت و وضوح زمانی مکانی داده های ورودی، عدم دسترسی به داده های زمینی پیوسته برای اعتبارسنجی گسترده تر، و تاثیر ناهمگنی شرایط مدیریتی و فلولوژیکی مزارع بر دقت برآورد رطوبت خاک اشاره کرد. همچنین، افزایش تعداد متغیرهای ورودی در سناریوهای پیشرفته تر، هرچند منجر به بهبود دقت شد، می تواند پیچیدگی مدل را افزایش دهد که این موضوع نیازمند توجه در تعمیم پذیری مدل به سایر مناطق و شرایط اقلیمی است.

REFERENCE:

- Acharya, U., Daigh, A. L. M., & Oduor, P. G. (2021). Machine learning for predicting field soil moisture using soil, crop, and nearby weather station data in the Red River Valley of the North. *Soil Systems*, 5(4), 57.
- Adab, H., Morbidelli, R., Saltalippi, C., Moradian, M., & Ghalhari, G. A. F. (2020). Machine learning to estimate surface soil moisture from remote sensing data. *Water*, 12(11), 3223.
- Ansari, S., & Deshmukh, R. R. (2017). Estimation of soil moisture content: A review. *International Journal of Theoretical and Applied Mechanics*, 12(3), 571–577.
- Araya, S. N., Fryjoff-Hung, A., Anderson, A., Viers, J. H., & Ghezzehei, T. A. (2021). Advances in soil moisture retrieval from multispectral remote sensing using unoccupied aircraft systems and machine learning techniques.

- Babaeian, E., Sadeghi, M., Jones, S. B., Montzka, C., Vereecken, H., & Tuller, M. (2019). Ground, proximal, and satellite remote sensing of soil moisture. *Reviews of Geophysics*, 57(2), 530–616.
- Bai, J., Cui, Q., Zhang, W., & Meng, L. (2019). An approach for downscaling SMAP soil moisture by combining Sentinel-1 SAR and MODIS data. *Remote Sensing*, 11(23), 2736.
- Bai, X., Zhang, L., He, C., & Zhu, Y. (2020). Estimating regional soil moisture distribution based on NDVI and land surface temperature time series data in the upstream of the Heihe River Watershed, Northwest China. *Remote Sensing*, 12(15), 2414.
- Barré, H. M. J. P., Duesmann, B., & Kerr, Y. H. (2008). SMOS: The mission and the system. *IEEE Transactions on Geoscience and Remote Sensing*, 46(3), 587–593.
- Bollero, G. A., Bullock, D. G., & Hollinger, S. E. (1996). Soil temperature and planting date effects on corn yield, leaf area, and plant development. *Agronomy Journal*, 88(3), 385–390.
- Chan, S., Bindlish, R., O'Neill, P., Jackson, T., Chaubell, J., Piepmeier, J., Dunbar, S., Colliander, A., Chen, F., & Entekhabi, D. (2017). Development and validation of the SMAP enhanced passive soil moisture product. 2017 *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2539–2542.
- Chan, S. K., Bindlish, R., O'Neill, P. E., Njoku, E., Jackson, T., Colliander, A., Chen, F., Burgin, M., Dunbar, S., & Piepmeier, J. (2016). Assessment of the SMAP passive soil moisture product. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8), 4994–5007.
- Colliander, A., Fisher, J. B., Halverson, G., Merlin, O., Misra, S., Bindlish, R., Jackson, T. J., & Yueh, S. (2017). Spatial downscaling of SMAP soil moisture using MODIS land surface temperature and NDVI during SMAPVEX15. *IEEE Geoscience and Remote Sensing Letters*, 14(11), 2107–2111.
- Colliander, A., Reichle, R. H., Crow, W. T., Cosh, M. H., Chen, F., Chan, S., Das, N. N., Bindlish, R., Chaubell, J., & Kim, S. (2021). Validation of soil moisture data products from the NASA SMAP mission. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 364–392.
- Congalton, R. G., & Green, K. (2019). *Assessing the accuracy of remotely sensed data: principles and practices*. CRC press.
- Dobriyal, P., Qureshi, A., Badola, R., & Hussain, S. A. (2012). A review of the methods available for estimating soil moisture and its implications for water resource management. *Journal of Hydrology*, 458, 110–117.
- Entekhabi, D., Njoku, E. G., O'Neill, P. E., Kellogg, K. H., Crow, W. T., Edelstein, W. N., Entin, J. K., Goodman, S. D., Jackson, T. J., & Johnson, J. (2010). The soil moisture active passive (SMAP) mission. *Proceedings of the IEEE*, 98(5), 704–716.
- Fan, X., Liu, Y., Gan, G., & Wu, G. (2020). SMAP underestimates soil moisture in vegetation-disturbed areas primarily as a result of biased surface temperature data. *Remote Sensing of Environment*, 247, 111914.
- Fang, Y., Xu, L., Chen, Y., Zhou, W., Wong, A., & Clausi, D. A. (2022). A Bayesian deep image prior downscaling approach for high-resolution soil moisture estimation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 4571–4582.
- Fang, B., Lakshmi, V., Cosh, M., Liu, P. W., Bindlish, R., & Jackson, T. J. (2022). A global 1- km downscaled SMAP soil moisture product based on thermal inertia theory. *Vadose Zone Journal*, 21(2), e20182.
- Fatholouloumi, S., Vaezi, A. R., Alavipanah, S. K., Ghorbani, A., & Biswas, A. (2020). Comparison of spectral and spatial-based approaches for mapping the local variation of soil moisture in a semi-arid mountainous area. *Science of the Total Environment*, 724, 138319.
- Font, J., Boutin, J., Reul, N., Spurgeon, P., Ballabrera-Poy, J., Chuprin, A., Gabarró, C., Gourrion, J., Guimbard, S., & Hénocq, C. (2013). SMOS first data analysis for sea surface salinity determination. *International Journal of Remote Sensing*, 34(9–10), 3654–3670.

- Gao, Q., Zribi, M., Escorihuela, M. J., & Baghdadi, N. (2017). Synergetic use of Sentinel-1 and Sentinel-2 data for soil moisture mapping at 100 m resolution. *Sensors*, 17(9), 1966.
- Ge, L., Hang, R., & Liu, Q. (2019). Retrieving soil moisture over continental us via multi-view multi-task learning. *IEEE Geoscience and Remote Sensing Letters*, 16(12), 1954–1958.
- Greifeneder, F., Notarnicola, C., & Wagner, W. (2021). A machine learning-based approach for surface soil moisture estimations with google earth engine. *Remote Sensing*, 13(11), 2099.
- Guo, P., Zhao, T., Shi, J., Xu, H., Li, X., & Niu, S. (2021). Assessing the active-passive approach at variant incidence angles for microwave brightness temperature downscaling. *International Journal of Digital Earth*, 14(10), 1273–1293.
- Han, J., Mao, K., Xu, T., Guo, J., Zuo, Z., & Gao, C. (2018). A soil moisture estimation framework based on the CART algorithm and its application in China. *Journal of Hydrology*, 563, 65–75.
- Han, L., Wang, P., Yang, H., Liu, S., & Wang, J. (2006). Study on NDVI-T s space by combining LAI and evapotranspiration. *Science in China Series D*, 49, 747–754.
- He, L., Hong, Y., Wu, X., Ye, N., Walker, J. P., & Chen, X. (2018). Investigation of SMAP active–passive downscaling algorithms using combined sentinel-1 SAR and SMAP radiometer data. *IEEE Transactions on Geoscience and Remote Sensing*, 56(8), 4906–4918.
- Hoek van Dijke, A. J., Mallick, K., Schlerf, M., Machwitz, M., Herold, M., & Teuling, A. J. (2020). Examining the link between vegetation leaf area and land–atmosphere exchange of water, energy, and carbon fluxes using FLUXNET data. *Biogeosciences*, 17(17), 4443–4457.
- Ines, A. V. M., Das, N. N., Hansen, J. W., & Njoku, E. G. (2013). Assimilation of remotely sensed soil moisture and vegetation with a crop simulation model for maize yield prediction. *Remote Sensing of Environment*, 138, 149–164.
- Jagadish, S. V., Way, D. A., & Sharkey, T. D. (2021). Scaling plant responses to high temperature from cell to ecosystem. *Plant, Cell and Environment*, 44(BNL-221830-2021-JAAM).
- Jamei, M., Mousavi Baygi, M., Asadi Oskoue, E., & Lopez-Baeza, E. (2020). Validation of the SMOS Level 1C Brightness Temperature and Level 2 Soil Moisture Data over the West and Southwest of Iran. *Remote Sensing*, 12(17), 2819.
- Kim, S.-B., Van Zyl, J. J., Johnson, J. T., Moghaddam, M., Tsang, L., Colliander, A., Dunbar, R. S., Jackson, T. J., Jaruwatanadilok, S., & West, R. (2017). Surface soil moisture retrieval using the L-band synthetic aperture radar onboard the soil moisture active–passive satellite and evaluation at core validation sites. *IEEE Transactions on Geoscience and Remote Sensing*, 55(4), 1897–1914.
- Korres, W., Reichenau, T. G., Fiener, P., Koyama, C. N., Bogen, H. R., Cornelissen, T., Baatz, R., Herbst, M., Diekkriiger, B., & Vereecken, H. (2015). Spatio-temporal soil moisture patterns—A meta-analysis using plot to catchment scale data. *Journal of Hydrology*, 520, 326–341.
- Lazecky, M., Canaslan Comut, F., Qin, Y., & Perissin, D. (2017). Sentinel-1 interferometry system in the high-performance computing environment. *The Rise of Big Spatial Data*, 131–139.
- Lievens, H., Reichle, R. H., Liu, Q., De Lannoy, G. J. M., Dunbar, R. S., Kim, S. B., Das, N. N., Cosh, M., Walker, J. P., & Wagner, W. (2017). Joint Sentinel- 1 and SMAP data assimilation to improve soil moisture estimates. *Geophysical Research Letters*, 44(12), 6145–6153.
- Long, D. G., Brodzik, M. J., & Hardman, M. (2017). Enhanced-resolution SMAP soil moisture using image reconstruction. *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2499–2502.
- Millard, K., & Richardson, M. (2018). Quantifying the relative contributions of vegetation and soil moisture conditions to polarimetric C-Band SAR response in a temperate peatland. *Remote Sensing of Environment*, 206,

- Ochsner, T. E., Cosh, M. H., Cuenca, R. H., Dorigo, W. A., Draper, C. S., Hagimoto, Y., Kerr, Y. H., Larson, K. M., Njoku, E. G., & Small, E. E. (2013). State of the art in large- scale soil moisture monitoring. *Soil Science Society of America Journal*, 77(6), 1888–1919.
- Park, S., Im, J., Park, S., & Rhee, J. (2015). AMSR2 soil moisture downscaling using multisensor products through machine learning approach. *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 1984–1987.
- Paloscia, S., Pettinato, S., Santi, E., Notarnicola, C., Pasolli, L., & Reppucci, A. J. R. S. O. E. (2013). Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. *Remote Sensing of Environment*, 134, 234–248.
- Pasolli, L., Notarnicola, C., & Bruzzone, L. (2009). Soil moisture estimation from microwave remote sensing data with nonlinear machine learning techniques. *Image and Signal Processing for Remote Sensing XV*, 7477, 382–393.
- Pede, T., Mountrakis, G., & Shaw, S. B. (2019). Improving corn yield prediction across the US Corn Belt by replacing air temperature with daily MODIS land surface temperature. *Agricultural and Forest Meteorology*, 276, 107615.
- Peng, J., Loew, A., Merlin, O., & Verhoest, N. E. C. (2017). A review of spatial downscaling of satellite remotely sensed soil moisture. *Reviews of Geophysics*, 55(2), 341–366.
- Piles, M., Sánchez, N., Vall-llossera, M., Camps, A., Martínez-Fernández, J., Martínez, J., & González-Gambau, V. (2014). A downscaling approach for SMOS land observations: Evaluation of high-resolution soil moisture maps over the Iberian Peninsula. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(9), 3845–3857.
- Portal, G., Vall-Llossera, M., López-Martínez, C., Camps, A., Pablos, M., Chaparro, D., Irawan, A. M., Alonso-González, A., & Jagdhuber, T. (2023). A Random Forest Approach for Soil Moisture Estimation at 60 Meters Spatial Resolution. *IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium*, 2898–2901.
- Qiu, Y., Fu, B., Wang, J., & Chen, L. (2001). Spatial variability of soil moisture content and its relation to environmental indices in a semi-arid gully catchment of the Loess Plateau, China. *Journal of Arid Environments*, 49(4), 723–750.
- Rahman, A., Maggioni, V., Zhang, X., Houser, P., Sauer, T., & Mocko, D. M. (2022). The joint assimilation of remotely sensed leaf area index and surface soil moisture into a land surface model. *Remote Sensing*, 14(3), 437.
- Reichle, R. H., Ardizzone, J. V., Kim, G.-K., Lucchesi, R. A., Smith, E. B., & Weiss, B. H. (2022). *Soil Moisture Active Passive (SMAP) mission level 4 surface and root zone soil moisture (L4_SM) product specification document*.
- Reichle, R. H., De Lannoy, G. J. M., Liu, Q., Ardizzone, J. V., Colliander, A., Conaty, A., Crow, W., Jackson, T. J., Jones, L. A., & Kimball, J. S. (2017). Assessment of the SMAP level-4 surface and root-zone soil moisture product using in situ measurements. *Journal of Hydrometeorology*, 18(10), 2621–2645.
- Rodriguez-Galiano, V. F., & Chica-Rivas, M. (2014). Evaluation of different machine learning methods for land cover mapping of a Mediterranean area using multi-seasonal Landsat images and Digital Terrain Models. *International Journal of Digital Earth*, 7(6), 492–509.
- Ruiz- Vera, U. M., Siebers, M. H., Drag, D. W., Ort, D. R., & Bernacchi, C. J. (2015). Canopy warming caused photosynthetic acclimation and reduced seed yield in maize grown at ambient and elevated [CO₂]. *Global Change Biology*, 21(11), 4237–4249.
- Santi, E., Baroni, F., Fontanelli, G., Lapini, A., Paloscia, S., Pettinato, S., Pilia, S., Ramat, G., Santurri, L., & Cigna, F. (2021). Soil moisture mapping at high resolution by merging SMAP, Sentinel1 and COSMO SkyMed with the support of machine learning. *Microwave Remote Sensing: Data Processing and Applications*, 11861,

- Senanayake, I. P., Yeo, I.-Y., Walker, J. P., & Willgoose, G. R. (2021). Estimating catchment scale soil moisture at a high spatial resolution: Integrating remote sensing and machine learning. *Science of The Total Environment*, 776, 145924.
- Senyurek, V., Lei, F., Boyd, D., Kurum, M., Gurbuz, A. C., & Moorhead, R. (2020). Machine learning-based CYGNSS soil moisture estimates over ISMN sites in CONUS. *Remote Sensing*, 12(7), 1168.
- Sheng, J., Rao, P., & Ma, H. (2019). Spatial downscaling of the fy3b soil moisture using random forest regression. *2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*, 1–6.
- Singh, A., Gaurav, K., Sonkar, G. K., & Lee, C.-C. (2023). Strategies to measure soil moisture using traditional methods, automated sensors, remote sensing, and machine learning techniques: review, bibliometric analysis, applications, research findings, and future directions. *IEEE Access*.
- Sotoude Nia, A. (2016). Estimating dry biomass by leaf area index. *Water and Irrigation Management*, 6(1), 1–13.
- Wakigari, S. A., & Leconte, R. (2022). Enhancing Spatial Resolution of SMAP Soil Moisture Products through Spatial Downscaling over a Large Watershed: A Case Study for the Susquehanna River Basin in the Northeastern United States. *Remote Sensing*, 14(3), 776.
- Xing, C., Chen, N., Zhang, X., & Gong, J. (2017). A machine learning based reconstruction method for satellite remote sensing of soil moisture images with in situ observations. *Remote Sensing*, 9(5), 484.
- Yang, J., Li, Z., Zhai, P., Zhao, Y., & Gao, X. (2020). The influence of soil moisture and solar altitude on surface spectral albedo in arid area. *Environmental Research Letters*, 15(3), 35010.
- Yazdani, M. R., Asadi Oskouei, E., Rahmani, A., Davatgar, N., & Delsouz Khaki, B. (2023). Analysis of temporal and spatial variations of water requirement for puddling in paddy fields of Sefidrood irrigation network using SMAP satellite soil moisture information. *Journal of Water Research in Agriculture*. 37(3), 223-243
- Zhong, A., Wang, A., Li, J., Xu, T., Meng, D., Ke, Y., Li, X., & Chen, Y. (2018). Downscaling of passive microwave soil moisture retrievals based on spectral analysis. *International Journal of Remote Sensing*, 39(1), 50–67.