

# Soil moisture mapping using machine learning technique

Undrakhtsetseg Tsogtbaatar<sup>1</sup>, Sainbayar Dalantai<sup>1,\*</sup>, Bayartungalag Batsaikhan<sup>1</sup>

<sup>1</sup>*Division of Environmental and Natural Resource Management, Institute of Geography and Geocology, Mongolian Academy of Sciences, Ulaanbaatar, Mongolia*

\*Corresponding author email: [sainbayard@mas.ac.mn](mailto:sainbayard@mas.ac.mn)

<https://orcid.org/0000-0001-8806-6167>

Received: 30 September 2023 / Accepted: 25 December 2023 / Published online: 28 December 2023

## ABSTRACT

Soil moisture is an essential component in the energy cycle, water resource, hydrological regime, and processes of the land surface. Mapping and monitoring of soil moisture are crucial for the prevention of flood and drought, estimation of evapotranspiration, and water resource management. Using remote sensing to create soil moisture mapping at large scale has become one of the most energy and time-efficient methods in soil study. Thus, we aimed to map the soil moisture for Mongolia based on downscaled Soil Moisture Active Passive (SMAP) data by combining it with the Normalized Difference Vegetation Index (NDVI), Enhanced Vegetation Index (EVI), and Land Surface Temperature (LST) of Moderate Resolution Imaging Spectroradiometer (MODIS) data using the Machine Learning-based Random Forest (RF) approach. The SMAP was positively correlated with NDVI ( $r=0.72$ ,  $p<0.01$ ) and EVI ( $r=0.73$ ,  $p<0.01$ ) but it was negatively correlated with LST ( $r=-0.66$ ,  $p<0.05$ ). The performance of the RF was high, and the correlation was  $r^2=0.7$ . Therefore, our study suggests that the Machine Learning-based RF approach can be used to model soil moisture on a large scale.

**Keywords:** *Soil moisture, machine learning, SMAP*

# Машин сургалтын аргаар хөрсний чийгийг зураглах арга зүй

Ундрахцэцэг Цогтбаатар<sup>1</sup>, Сайнбаяр Далантай<sup>1,\*</sup>, Баяртунгалаг  
Батсайхан<sup>1</sup>

*<sup>1</sup>Хүрээлэн Буй Орчин, Байгалийн Нөөцийн Менежментийн Салбар, Газарзүй,  
Геоэкологийн Хүрээлэн, Шинжлэх Ухааны Академи, Улаанбаатар, Монгол*

*\*Холбоо барих зохиогчийн цахим хаяг: [sainbayard@mas.ac.mn](mailto:sainbayard@mas.ac.mn)*

<https://orcid.org/0000-0001-8806-6167>

Хүлээн авсан: 2023 оны 09 сарын 30 өдөр / Зөвшөөрөгдсөн: 2023 оны 12 сарын 25 өдөр /

Нийтлэгдсэн: 2023 оны 12 сарын 28 өдөр

## ХУРААНГУЙ

Хөрсний чийг нь усны эргэлт, энергийн урсгалд чухал нөлөө үзүүлдгээс гадна, газрын гадаргын нөхцөл болон гадаргын усанд маш чухал нөлөөтэй. Иймд, хөрсний чийгийн зураглал болон мониторингийн судалгаа нь ган, зудын мониторинг, үерийн урьдчилсан сэрэмжлүүлэг болон усны нөөцийн менежментэд чухал үүрэг гүйцэтгэдэг судалгааны нэг юм. Сүүлийн үед, өргөн уудам газар нутагт хөрсний чийгийг зураглахын тулд зайнаас тандан судлалын аргыг ашиглах нь эдийн засаг болон цаг хугацааны хувьд үр ашигтай аргуудын нэг болоод байна. Иймд Монгол орны хэмжээнд хөрсний чийгийг зураглахдаа Soil Moisture Active Passive (SMAP) хиймэл дагуулын бүтээгдэхүүнийг ашиглан машин сургалтын санамсаргүй ой (RF)-н аргаар мэдээний орон зайн шийдийг сайжруулан зураглалаа. Ингэхдээ Moderate Resolution Imaging Spectroradiometer (MODIS) хиймэл дагуулын бүтээгдэхүүнүүдэд (ургамлын нормчилсон ялгаврын индекс (NDVI), ургамлын сайжруулсан индекс (EVI), газрын гадаргын температур (LST) тулгуурлан SMAP хиймэл дагуулын бүтээгдэхүүний орон зайн шийдийг сайжруулан өөрчилсөн, хамаарлыг тооцсон. Ингэхэд NDVI ( $r=0.72$ ,  $p<0.01$ ) болон EVI ( $r=0.73$ ,  $p<0.01$ ) нь SMAP-тай эерэг хамааралтай байсан бол LST ( $r=-0.66$ ,  $p<0.05$ )-тай урвуу хамааралтай байсан. RF-н алгоритмаар машин сургалтын аргыг ашиглан Монгол орны хэмжээнд хөрсний чийгийг зураглахад загварын үр дүн гүйцэтгэл сайтай буюу хамаарал нь  $r^2=0.7$  гарсан. Иймд машин сургалтын санамсаргүй ойн алгоритмаар том хэмжээний газар нутгийг хамруулан хөрсний чийгийг загварчлах боломжтой болох нь судалгааны үр дүнгээс харагдаж байна.

*Түлхүүр үгс: Хөрсний чийг, машин сургалт, SMAP*

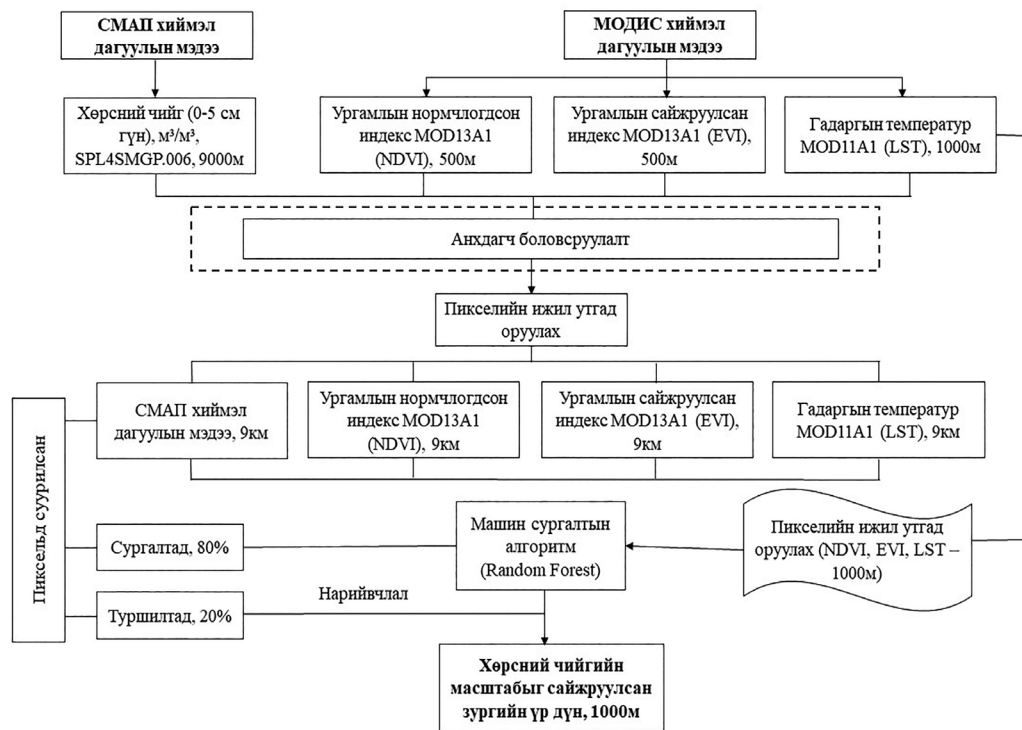
## 1. ОРШИЛ

Хөрсний чийг нь ургамал ургах гол нөхцөл болохоос гадна, гадаргын болон газар доорх усны нөөцөд шууд нөлөөлдөг [1]. Мөн хөрсөнд байгаа шим тэжээлийн бодис, элементүүд нь ургамалд дамжуулах

гол гүүр болохоос гадна хөрсний чийг нь ургамалан бүрхэвч, ган, уур амьсгалын өөрчлөлт, усны баланс, усны менежмент гэх мэт хүчин зүйлсэд голлох үүрэгтэй байдаг [2]. Хөрсний чийгийг тооцоолохдоо шууд болон шууд бус аргыг ашигладаг ба хамгийн тохиромжтой арга нь шууд

хэмжилтийн арга хэдий ч, өртөг өндөртэй байдаг [3]. Өргөн удам нутагт гүйцэтгэж байгаа хээрийн судалгааны хөрсний чийгийн хэмжилтийн үр дүн нь орон зайн тархалтыг нарийн илэрхийлдэггүй [4], [5]. Иймд хөрсний чийгийг тооцоолоход зайнаас тандан судлалын аргыг бүс нутгийн хэмжээнд өргөн хэрэглэсээр байна [6]. Сүүлийн үеийн судалгаануудад хиймэл дагуулын мэдээ ашиглан хөрсний чийгийг тодорхойлохын тулд, дэлхийн хуурай газрыг бүхэлд нь хамарч мэдээлэл цуглуулдаг, Soil Moisture Active Passive (SMAP) хиймэл дагуулын мэдээг өргөнөөр ашиглаж байна [7]. 2015 оны 1 дүгээр сард АНУ эх дэлхийн өнгөн хөрсний ус, чийгийн хэмжээг тодорхойлох, хүйтэн бүс нутгуудын хөрсний хөлдөлт гэсэлтийг хэмжих зорилгоор SMAP дагуулыг хөөргөсөн. Тус дагуул нь АНУ-ын сансар судлалын агентлаг (NASA)-ийн хамгийн

анхны хөрсний чийгийг хэмждэг хиймэл дагуул юм [8]. SMAP хиймэл дагуулын мэдээ нь орон зайн нарийвчлал багатай тул олон судлаачид хөрсний чийгийг зайнаас тандан судлалын аргаар тодорхойлоход, ийм төрлийн хиймэл дагуулын мэдээг Moderate Resolution Imaging Spectroradiometer (MODIS) зэрэг арай илүү нарийвчлал бүхий хиймэл дагуулын мэдээтэй нэгтгэн, машин сургалтын болон бусад өндөр түвшингийн аргуудаар мэдээний нарийвчлалыг сайжруулан зураглажээ [9]-[16]. Энэхүү судалгаанд, Монгол орны хэмжээнд хөрсний чийгийг зураглахдаа SMAP хиймэл дагуулын мэдээг MODIS хиймэл дагуулын мэдээтэй нийлүүлэн, машин сургалтын санамсаргүй ойн (RF) аргыг ашиглан мэдээний орон зайн шийдийг сайжруулан зураглахаар зорилоо.



Зураг 1. Машин сургалтын аргаар хөрсний чийгийг зураглах арга зүй

## 2. СУДАЛГААНЫ МАТЕРИАЛ

2015 оны 1 дүгээр сард АНУ эх дэлхийн өнгөн хөрсний ус, чийгийн хэмжээг тодорхойлох, хүйтэн бүс нутгуудын хөрсний хөлдөлт, гэсэлтийг хэмжих зорилгоор SMAP дагуулыг хөөргөсөн байна. SMAP хиймэл дагуул нь радар болон радиометрийн хэмжилтийг хослуулан 10 км-ийн нарийвчлалтайгаар хөрсний чийгийг хэмждэг. Мөн 1-3 км-ийн нарийвчлалтайгаар газрын хөлдөлт, гэсэлтийг хэмждэг. Газрын гадаргаас агаар мандал руу уурших ууршилтын хэмжээ хөрсний чийгээс ихээхэн хамаардаг тул цаг уур болон уур амьсгалын судалгаанд SMAP хиймэл дагуулын мэдээг өргөнөөр ашигладаг. SMAP хиймэл дагуул нь 4 түвшний нийт 24 бүтээгдэхүүнтэй ба тус бүтээгдэхүүнүүд нь 1-3 км, 9 км, 36 км-ийн нарийвчлалтай байна. Энэхүү судалгаанд, SMAP хиймэл дагуулын SPL4SMGP.006 бүтээгдэхүүний 2021 оны 8 дугаар сарын 1-ээс 31 хүртэлх мэдээг ашигласан бөгөөд SPL4SMGP.006 нь өнгөн хөрсний буюу 0-5 см-ийн гүн дэх өнгөн хөрсний чийгийн 9 км орон зайн шийд бүхий мэдээ юм.

## 3. СУДАЛГААНЫ АРГАЗҮЙ

Тус судалгаанд 2021 оны 8 дугаар сарын MODIS хиймэл дагуулын MOD13A1 бүтээгдэхүүн болох ургамлын нормчилсон ялгаврын индекс (NDVI) ургамлын сайжруулсан индекс (EVI) болон MOD11A1 гадаргын температур (LST)-ын мэдээг ашигласнаас гадна SMAP-хиймэл дагуулын SPL4SMGP.006 өнгөн хөрсний чийгийн мэдээний дунжийг эх буюу анхдагч өгөгдөл болгон ашиглаж машин сургалтын RF-н регрессээр загварчлан орон зайн дунд зэргийн шийд бүхий хөрсний чийгийн зургийг гарган авсан. Тус судалгааг гүйцэтгэхдээ машин сургалтын ерөнхий схемийг баримтлан (Зураг 1) дараах дарааллын дагуу гүйцэтгэлээ. Үүнд:

1. Өгөгдлийг цуглуулах, бэлдэх ажлын

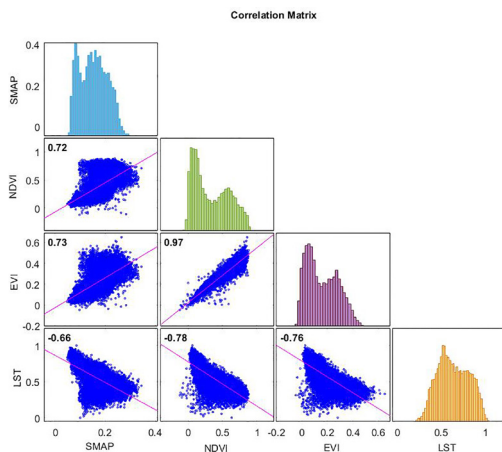
хүрээнд ялгаатай орон зайн шийд бүхий өгөгдлүүдийг “ArcGIS 10.8” программ хангамжийн “Resample” модулийн тусламжтайгаар ижил орон зайн шийд (9 км) бүхий өгөгдөлд шилжүүлсэн. Энд машин сургалтын алгоритмд ашиглагдах судалгааны талбайг хамарсан нийт 17564 пиксел бүр дээрх утгыг (загварт ашиглагдах оролтын шинж чанар/үл хамаарах хувьсагч бүрээр) гарган авсан.

2. Оролтын өгөгдлийг хамаарах хувьсагч (SMAP) болон үл хамаарах хувьсагч бүрийн 17564 пиксел бүр дээрх утгыг санамсаргүй байдлаар сургах өгөгдөл (80%), туршилтын буюу загварын гүйцэтгэлийг үнэлэх өгөгдөлд (20%) хуваасан.
3. Сургалтын өгөгдлөөр python 3.11 болон matlab2018b программ хангамж ашиглан машин сургалтын санамсаргүй ойн алгоритмаар загварчилсан.
4. Загварын гүйцэтгэлийг туршилтын өгөгдлөөр детерминацын коэффициент болон квадрат дундаж алдааг тооцон үнэлсэн.
5. Пикселийн ижил утгад оруулан тооцсон (NDVI, EVI болон LST) өгөгдөлд суурилан 1000 м-ийн нарийвчлалтай өнгөн хөрсний чийгийн зургийг гарган авсан (Зураг 1).

## 4. СУДАЛГААНЫ ҮР ДҮН БА ХЭЛЭЛЦҮҮЛЭГ

### 4.1. Оролтын хувьсагчуудын хамаарал

Хиймэл дагуулын бүтээгдэхүүнийг том масштабаас жижиг масштаб руу шилжүүлж загварчлахад өндөр хамааралтай оролтын хувьсагчдыг сонгох нь загварын гүйцэтгэлд маш чухал нөлөө үзүүлдэг [17]. Иймд хамаарлын матриц нь загварын оролтын өгөгдөл/хувьсагчууд хоорондын хамаарлыг харуулдаг тул тус судалгаанд ашигласан хувьсагчуудын хамаарлыг тооцон Зураг 2-д харууллаа.




**Зураг 2.** Хамаарлын матриц

Хувьсагчдын хамаарлыг үнэлэн NDVI, EVI болон LST-аар хөрсний чийгийн тархалтын зургийн орон зайн шийдийг сайжруулахын тулд RF регрессийн алгоритмыг python дээр ажиллуулан загварчилсан. SMAP болон MODIS хиймэл дагуулын ургамлын бүтээгдэхүүн (NDVI, EVI)-үүд болон LST хоорондын хамаарлыг харьцуулахад NDVI ( $r=0.72$ ,  $p<0.01$ ) болон EVI ( $r=0.73$ ,  $p<0.01$ )-тэй хүчтэй шууд хамааралтай, харин LST ( $r=-0.66$ ,  $p<0.05$ )-тай урвуу хамааралтай байна (Зураг 2). Энэ нь хөрсөнд агуулагдах ус, чийгийн хэмжээ тохиромжтой хэмжээнд буюу чийг их байхад ургамлын фитомасс өсөх таатай нөхцөл бүрддэгтэй холбоотой. Өөрөөр хэлбэл, хөрсний дулаан хангамж нэмэгдэхийн хэрээр хөрсний ууршилт нэмэгдэж, хөрсний чийг буурах онолын үндэслэл харагдаж байна.

#### 4.2. Загварчлахад чухал нөлөө үзүүлсэн шинэ чанар (үл хамаарах хувьсагч)

RF регрессийн алгоритмаар хөрсний чийгийг загварчлахад үл хамаарах хувьсагчид буюу NDVI, EVI болон LST нь загварт хэр зэрэг нөлөө үзүүлж байгааг хувиар илэрхийлэн Зураг 3-д харууллаа.



**Зураг 3.** Загварт үзүүлсэн нөлөөллийн эрэмбэ


Үр дүнгээс харахад, EVI нь загварт бусдаасаа хамгийн өндөр ач холбогдолтой буюу 57% нөлөө үзүүлсэн бол NDVI нь хоёр дугаарт эрэмбэлэгдэж 27%-ийн нөлөө үзүүлсэн байна. Харин LST нь загварт хамгийн бага ач холбогдолтой буюу 19%-ийн нөлөө үзүүлсэн байна. Эндээс харахад, агаарын температур нь хөрсний чийгт нөлөө үзүүлэх хэдий ч гадаргын бүрхэвчийн байдал нь хөрсний чийг, усан хангамжид өндөр нөлөөтэй байна.

Загварт сонгон авсан үл хамаарах хувьсагчид нь тухайн загварт нөлөөллийн эрэмбэд харуулснаар (Зураг 3) нөлөөлж байгаа учир загварчлалыг эцсийн байдлаар гаргах боломжтой гэж үзэн загварчилсан. Хэрэв загварчлалд нөлөө үзүүлэхгүй үл хамаарах хувьсагчид байвал түүнийг хасаж дахин алгоритмыг уншуулах шаардлагатай байдаг.

Бусад ижил төрлийн судалгаанд [18], SMAP хиймэл дагуулын хөрсний чийгийн бүтээгдэхүүний орон зайн шийдийг сайжруулан зураглахад MODIS хиймэл дагуулын ургамлын бүтээгдэхүүн нь хагас хуурай бүс нутагт гүйцэтгэл сайтай байсан бол гадаргын температур нь ургамлан бүрхэвч бага бүс нутагт илүү өндөр ач холбогдолтойг үзүүлсэн байна. Энэ нь радарын өгөгдөл нь (идэвхтэй зайнаас тандалт) гадаргын температурын өгөгдлийн ач холбогдлыг нэмэгдүүлдэг хэмээн тэмдэглэсэн байна [18].

### 4.3. Загварын үнэлгээ

MODIS хиймэл дагуулын MOD13A1 ургамлын бүтээгдэхүүнүүд болох NDVI, EVI болон гадаргын температур (LST), мөн SMAP-хиймэл дагуулын SPL4SMGP.006 өнгөн хөрсний чийгийн мэдээг оролтын өгөгдөл болгон ашиглан, машин сургалтын RF-н регрессээр загварчиллаа. Загварын гүйцэтгэлийг туршилтын өгөгдөл (санамсаргүй байдлаар түүвэрлэн авсан) буюу 3513 (20%) цэг дээрх утгаар детерминацийн коэффициент болон квадрат дундаж алдааг тооцсон. Загварын гүйцэтгэлийг цэгэн диаграммаар **Зураг 4**-т харуулав.



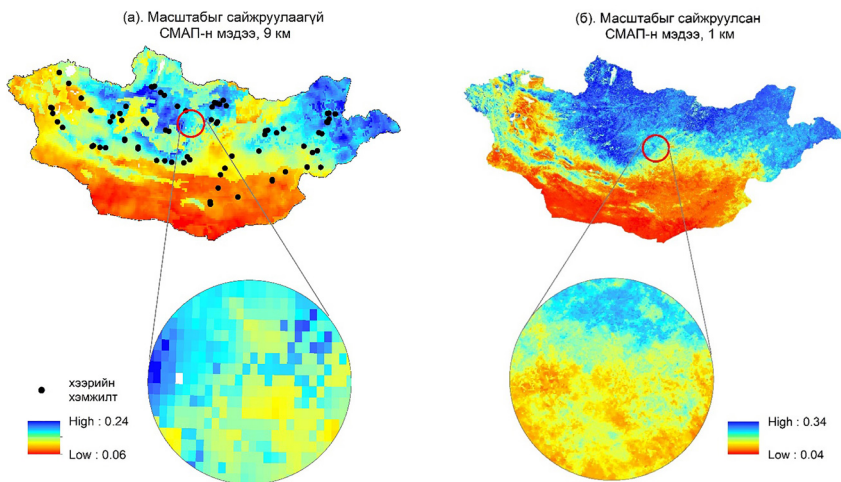
**Зураг 4.** RF загварын үнэлгээ: Загвараар тооцоолсон болон SMAP хиймэл дагуулын хөрсний чийгийн цэгэн диаграм

SMAP хиймэл дагуулын хөрсний чийгийн бүтээгдэхүүнийг MODIS хиймэл дагуулын NDVI, EVI, LST-ийг үл хамааран хувьсагчаар сонгон RF-н регрессээр загварчлахад детерминацийн коэффициент нь 0.73 гарсан ба гүйцэтгэл өндөр байна гэж үзлээ. Мөн квадрат дундаж алдаа нь  $0.03 \text{ м}^3/\text{м}^3$  гарсан. Иймээс уг загварыг ашиглан хөрсний чийгийн 1000 м-ийн орон зайн шийд бүхий Монгол орны хөрсний чийгийн зургийг боловсруулах бүрэн боломжтой гэж үзсэн.

### 4.4. Орон зайн шийдийг сайжруулсан Монгол орны хөрсний чийгийн тархалтын зураг

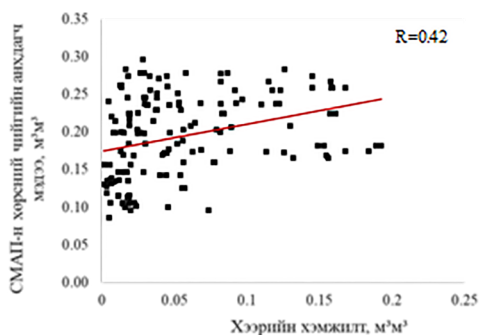
Машин сургалтын алгоритмуудын нэг болох RF-н регрессийн загвараар орон зайн шийд (1 км)-ийг сайжруулсан (**Зураг 5.б**) болон орон зайн шийдийг сайжруулаагүй SMAP хиймэл дагуулын хөрсний чийгийн анхдагч зургийг (**Зураг 5.а**) хооронд нь харьцуулан үзүүлэв.

Зургаас харахад нийт судалгааны талбайд SMAP хиймэл дагуулын хөрсний чийгийн хамгийн их утгыг ( $0.24 \text{ м}^3/\text{м}^3$ )  $0.1 \text{ м}^3/\text{м}^3$ -ээр нэмэгдүүлсэн бол хамгийн

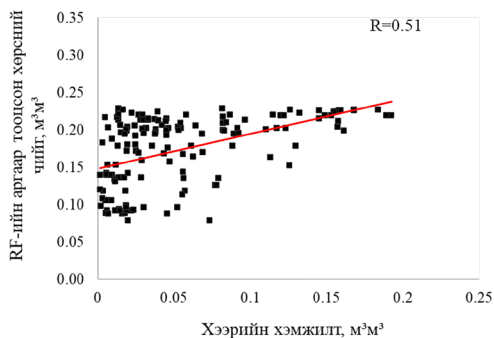


**Зураг 5.** Загварчилаагүй болон загварчилсан сайжруулсан хөрсний чийгийн зургийн харьцуулалт, 2021 оны 8 дугаар сарын дундаж хөрсний чийг

бага утгыг ( $0.06\text{м}^3/\text{м}^3$ )  $0.02\text{м}^3/\text{м}^3$ -ээр бууруулсан байна. Энэ нь загварчилсан ургамлын индексүүд нь Хангай, Хэнтийн уулархаг бүс нутаг болон ойт хээрийн бүсэд голлох нөлөө үзүүлсэн бол говь, цөлийн бүс нутагт гадаргын температур нь чухал нөлөө үзүүлсэн гэсэн Nadeem нар [18]-ын судалгаатай тохирч байна.



**Зураг 6.** СМАП-н хөрсний чийгийн анхдагч мэдээ болон хээрийн хэмжилтээр хэмжсэн хөрсний чийгийн хамаарал



**Зураг 7.** RF-ийн аргаар тооцсон болон хээрийн хэмжилтээр хэмжсэн хөрсний чийгийн хамаарал

Мөн RF регрессийн алгоритмаар загварчлан орон зайн шийдийг сайжруулаагүй хөрсний чийгтэй сул хамааралтай ( $r=0.42$ ) (Зураг 6) байгаа бол орон зайн шийдийг сайжруулсан хөрсний чийг нь хээрийн хэмжилттэй хамааралтай ( $r=0.51$ ) (Зураг 7) байна.

## 4. ДҮГНЭЛТ

Монгол орны хэмжээнд хөрсний чийгийг зураглахад SMAP хиймэл дагуулын хөрсний чийгийн бүтээгдэхүүн болон MODIS хиймэл дагуулын ургамлын бүтээгдэхүүн (NDVI, EVI), гадаргын температур (LST) хоорондын хамаарлыг харьцуулсан. Ингэхэд NDVI ( $r=0.72$ ,  $p<0.01$ ) болон EVI ( $r=0.73$ ,  $p<0.01$ )-тэй хүчтэй шууд хамааралтай харин LST ( $r=-0.66$ ,  $p<0.05$ )-тай буюу урвуу хамааралтай байсан.

SMAP хиймэл дагуулын хөрсний чийгийг MODIS хиймэл дагуулын NDVI, EVI LST-ийг үл хамааран хувьсагчаар сонгон машин сургалтын RF-н алгоритмаар загварчлахад детерминацийн коэффициент нь 0.73 гарсан. Энэ нь хамааран хувьсагчийн 73%-ийг тайлбарлаж байгаа нь гүйцэтгэл өндөр байна гэж үзлээ.

SMAP хиймэл дагуулын хөрсний чийгийн бүтээгдэхүүнийг RF регрессийн алгоритмаар загварчлан орон зайн шийдийг сайжруулсан үр дүн болон орон зайн шийдийг сайжруулаагүй анхдагч бүтээгдэхүүнийг хээрийн хэмжилтийн 153 цэг дээрх хэмжилттэй хамаарал тооцсон. Үүнээс RF регрессийн алгоритмаар загварчлан орон зайн шийдийг сайжруулсан хөрсний чийг нь хээрийн хэмжилттэй хамааралтай ( $r=0.51$ ) байгаа бол орон зайн шийдийг сайжруулаагүй хөрсний чийгтэй сул хамааралтай ( $r=0.42$ ) байна.

Эндээс дүгнэхэд бидний гаргаж авсан загварчлал хөрсний чийгийн орон зайн шийдийг сайжруулсан гэж үзэж болохоор байна.

## АШИГЛАСАН МАТЕРИАЛ

- [1] О. Батхишиг, Хөрсний чийг хангамжийг сайжруулах арга зүй, зөвлөмж, Улаанбаатар, Монгол: Уудам соёл хэвлэлийн газар, 2016.

- [2] X. Wang, B. Wang, X. Xu, T. Liu, Y. Duan, and Y. Zhao, "Spatial and temporal variations in surface soil moisture and vegetation cover in the Loess Plateau from 2000 to 2015," *Ecological Indicators*, vol. 95, pp. 320-330, Dec. 2018, <https://doi.org/10.1016/j.ecolind.2018.07.058>
- [3] E. Natsagdorj et al., "An integrated methodology for soil moisture analysis using multispectral data in Mongolia," *Geo-spatial Information Science*, vol. 20, no. 1, pp. 46-55, Jan. 2017, <https://doi.org/10.1080/10095020.2017.1307666>
- [4] E. T. Engman, "Progress in Microwave Remote Sensing of Soil Moisture," *Canadian Journal of Remote Sensing*, vol. 16, no. 3, pp. 6-14, Oct. 1990, <https://doi.org/10.1080/07038992.1990.11487620>
- [5] Д. Аззаяа, Э. Эрдэнэбат, "Хөрсний чийгийн асуудалд," *Ус Цаг Уурын хүрээлэн, Улаанбаатар, Эрдэм шинжилгээний бүтээл* 26, 2004.
- [6] D. Zhang and G. Zhou, "Estimation of Soil Moisture from Optical and Thermal Remote Sensing: A Review," *Sensors*, vol. 16, no. 8, p. 1308, Aug. 2016, <https://doi.org/10.3390/s16081308>
- [7] D. Entekhabi et al., "The Soil Moisture Active Passive (SMAP) Mission," in *Proceedings of the IEEE*, vol. 98, no. 5, pp. 704-716, May 2010, <https://doi.org/10.1109/JPROC.2010.2043918>
- [8] D. Entekhabi et al., "The Soil Moisture Active Passive (SMAP) Mission," *Proc. IEEE*, vol. 98, no. 5, pp. 704-716, May 2010, <https://doi.org/10.1109/JPROC.2010.2043918>
- [9] J. Im, S. Park, J. Rhee, J. Baik, and M. Choi, "Downscaling of AMSR-E soil moisture with MODIS products using machine learning approaches," *Environ Earth Sci*, vol. 75, no. 15, p. 1120, Aug. 2016, <https://doi.org/10.1007/s12665-016-5917-6>
- [10] J. Peng, A. Loew, O. Merlin, and N. E. C. Verhoest, "A review of spatial downscaling of satellite remotely sensed soil moisture," *Reviews of Geophysics*, vol. 55, no. 2, pp. 341-366, Jun. 2017, <https://doi.org/10.1002/2016RG000543>
- [11] S. Sabaghy, J. P. Walker, L. J. Renzullo, and T. J. Jackson, "Spatially enhanced passive microwave derived soil moisture: Capabilities and opportunities," *Remote Sensing of Environment*, vol. 209, pp. 551-580, May 2018, <https://doi.org/10.1016/j.rse.2018.02.065>
- [12] R. Bindlish and A. P. Barros, "Sub-pixel variability of remotely sensed soil moisture: an inter-comparison study of SAR and ESTAR," in *IEEE 1999 International Geoscience and Remote Sensing Symposium. IGARSS'99 (Cat. No.99CH36293)*, Hamburg, Germany: IEEE, 1999, pp. 1917-1920 vol.4. <https://doi.org/10.1109/IGARSS.1999.774986>
- [13] J. Li, S. Wang, G. Gunn, P. Joosse, and H. A. J. Russell, "A model for downscaling SMOS soil moisture using Sentinel-1 SAR data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 72, pp. 109-121, Oct. 2018, <https://doi.org/10.1016/j.jag.2018.07.012>
- [14] X. Wu, J. P. Walker, C. Rudiger, R. Panciera, and Y. Gao, "Medium-Resolution Soil Moisture Retrieval Using the Bayesian Merging Method," *IEEE Trans. Geosci. Remote Sensing*, vol. 55, no. 11, pp. 6482-6493, Nov. 2017, <https://doi.org/10.1109/TGRS.2017.2728808>
- [15] H. Lievens et al., "Joint Sentinel-1 and SMAP data assimilation to improve



- soil moisture estimates,” *Geophysical Research Letters*, vol. 44, no. 12, pp. 6145-6153, Jun. 2017, <https://doi.org/10.1002/2017GL073904>
- [16] J. Han, K. Mao, T. Xu, J. Guo, Z. Zuo, and C. Gao, “A soil moisture estimation framework based on the CART algorithm and its application in China,” *Journal of Hydrology*, vol. 563, pp. 65-75, Aug. 2018, <https://doi.org/10.1016/j.jhydrol.2018.05.051>
- [17] H. Sun and Y. Cui, “Evaluating Downscaling Factors of Microwave Satellite Soil Moisture Based on Machine Learning Method,” *Remote Sensing*, vol. 13, no. 1, p. 133, Jan. 2021, <https://doi.org/10.3390/rs13010133>
- [18] A. A. Nadeem et al., “Spatial Downscaling and Gap-Filling of SMAP Soil Moisture to High Resolution Using MODIS Surface Variables and Machine Learning Approaches over Shan Dian River Basin, China,” *Remote Sensing*, vol. 15, no. 3, p. 812, Jan. 2023, <https://doi.org/10.3390/rs15030812>