

Estimation and mapping of vegetation biomass in forest-steppe and steppe zones of Mongolia using MODIS data

Byambadolgor Batdorj^{1,*}, Amarsaikhan Damdinsuren¹, Nyamjargal Erdenebaatar¹

¹*Division of GIS and Remote Sensing, Institute of Geography and Geoecology, Mongolian Academy of Sciences, Ulaanbaatar, Mongolia*

*Corresponding author email: = byambadolgorb@mas.ac.mn =

<https://orcid.org/0000-0002-9017-0729>

Received: 30 September 2023 / Accepted: 07 December 2023 / Published online: 28 December 2023

ABSTRACT

In recent years, digital remote sensing optical datasets and various indices calculated by using them have been intensively applied for green vegetation biomass evaluation and other thematic studies. The main goals of this study were to evaluate the vegetation biomass in the forest-steppe and steppe zones of Mongolia using the indices calculated from medium-resolution satellite data and map the biomass distribution. Indices were calculated from different visible, near, and mid-infrared bands of MODIS data acquired on August 21, 2016, and then classified and compared using machine learning methods such as random forest (RF), support vector machine (SVM), and partial least square regression (PLSR). Among the selected methods for biomass mapping in the forest-steppe and steppe areas, the RF method demonstrated the highest accuracy with a coefficient of determination (R^2) of 0.889, and a root mean square error (RMSE) of 0.713 c/ha. The PLSR method had an R^2 of 0.296 and an RMSE of 1.854 c/ha, while the SVM method showed the lowest accuracy with an R^2 of 0.273 and an RMSE of 1.889 c/ha. Our finding indicates that the RF is a more applicable approach for assessing and mapping the vegetation biomass in the forest-steppe and steppe zones of Mongolia.

Keywords: Vegetation index, RF, SVM, PLSR, Biomass

MODIS дагуулын мэдээ ашиглан Монгол орны ойт хээр болон хээрийн бүсийн ургамлын биомассыг үнэлэн зураглах нь

Бямбадолгор Батдорж^{1,*}, Амарсайхан Дамдинсүрэн¹,
Нямжаргал Эрдэнэбаатар¹

¹Газарзүй мэдээллийн систем, зайнаас тандан судлалын салбар, Газарзүй, геоэкологийн хүүрээлэн, Шинжлэх ухааны академи, Улаанбаатар, Монгол

*Corresponding author email: byambadolgorb@mas.ac.mn

<https://orcid.org/0000-0002-9017-0729>

Хүлээн авсан: 2023 оны 09 сарын 30 өдөр / Зөвшөөрөгдсөн: 2023 оны 12 сарын 07 өдөр

/ Нийтлэгдсэн: 2023 оны 12 сарын 28 өдөр

ХУРААНГУЙ

Сүүлийн үед зайнаас тандсан оптикийн тоон өгөгдлүүд, тэдгээр дээр суурилан тооцоолсон төрөл бүрийн индексүүдийг ногоон ургамлын биомассын үнэлгээ болон бусад сэдэвчилсэн судалгаанд эрчимтэй ашиглаж байна. Судалгааны ажлын үндсэн зорилго нь Монгол орны ойт хээрийн ба хээрийн бүсийн ургамлын биомассыг дунд нарийвчлал бүхий хиймэл дагуулын мэдээг ашиглан тооцоолсон индексүүдийн тусламжтайгаар үнэлэх, улмаар биомассын тархалтыг зураглахад оршино. Энэ зорилгоор 2016 оны 8 дугаар сарын 21-ний өдрийн MODIS хиймэл дагуулын үзэгдэх гэрэл, ойрын болон дундын нэл улаан туяаны мужийн сувгуудын мэдээг ашиглан индексүүдийг тооцоолж, дараа нь санамсаргүй форестын арга (RF), тулах векторын арга (SVM), хэсэгчилсэн хамгийн бага квадратын регресс (PLSR)-ийн арга зэрэг машин сургалтын аргуудыг ашиглан уг индексүүдийг ангилж, харьцуулсан дүн шинжилгээг хийж гүйцэтгэлээ. Ойт хээрийн ба хээрийн бүсийн биомассыг зураглах аргуудаас RF аргын детерминацийн коэффициент (R^2) 0.889, дундаж квадратын алдаа (RMSE) 0.713 ц/га буюу хамгийн өндөр нарийвчлалыг харуулсан бол PLSR аргын R^2 нь 0.296, RMSE 1.854 ц/га, харин SVM аргын R^2 0.273, RMSE 1.889 ц/га буюу хамгийн бага нарийвчлалтайгаар үнэлсэн байлаа. Энэхүү судалгааны үр дүнд RF арга нь Монгол орны ойт хээрийн ба хээрийн бүсийн ургамлын биомассыг үнэлэх, зураглахад илүү тохиромжтой болохыг харуулж байна.

Түлхүүр үгс: Ургамлын индекс, RF, SVM, PLSR, Биомасс

1. ОРШИЛ

Биомасс нь ургамлын тухайн жилд бий болсон газрын дээрх ногоон массын хэмжээг илэрхийлэх бөгөөд биомассын үнэн зөв хэмжилт болон зураглал нь нүүрстөрөгчийн нөөцийг тодорхойлох,

бэлчээрийн нөөцийг тооцох, газрын доройтол, талхагдлыг үнэлэхэд чухал үүрэгтэй байдаг.

2022 оны байдлаар Монгол улсын нийт нутаг дэвсгэрийн 70.2% буюу 109767.3 мянган га газрыг бэлчээрийн газар эзэлж

байна [1]. Бэлчээрийн зориулалттай газрын нөөц багасахын хэрээр бэлчээрийн чадавхын үнэлгээ буурч байгаа бөгөөд энэ нь бэлчээрийн гол нөөцийг бүрдүүлж байгаа ойт хээр болон хээрийн бүсэд илүү эрчимтэй ажиглагдах хандлагатай байна.

Ойт хээр ба хээрийн бүс нь бэлчээрийн нийт талбайн 49.1%-ийг (22.2% болон 26.9%) эзэлдэг тул эдгээр бүсийн биомассыг тооцоолох нь нийгэм, эдийн засаг болон хүрээлэн буй орчинд их чухал юм [2].

Сүүлийн жилүүдэд, бэлчээрийн газар ашиглалт эрчимжиж, малчид малын тоо, толгойн өсөлтөд хэт их анхаарснаас үүдэн, бэлчээрийн ургац буурч, бэлчээр ихээхэн талхлагдах байдал ажиглагдах боллоо. Мөн даян дэлхийн дулаарал, хуурайшил зэрэг нь манай орны байгаль орчин, ялангуяа бэлчээрийн экосистемд ихээхэн сөрөг нөлөө үзүүлж байгаа тул биомассын үнэлгээг зайлшгүй хийх шаардлага тулгарч байгаа юм.

Орчин үед зайнаас тандсан мэдээг ашиглан газрын гадаргын өөрчлөлт, биомассын үнэлгээ, ой, усны нөөцийн судалгаа, хөрсний чийгийн үнэлгээ, газар тариалан, газрын доройтол, цөлжилтийн мониторинг, цаг уурын өөрчлөлт, байгаль орчны төлөвлөлт зэрэг олон салбарт өргөнөөр ашиглаж байна [3].

Биомассыг үнэлэх уламжлалт арга нь хээрийн хэмжилт дээр үндэслэсэн, үнэн зөв мэдээллийг бий болгодог ч, том хэмжээний талбайд ашиглахад хүндрэлтэй бөгөөд маш их зардал, хөдөлмөр, цаг хугацаа шаарддаг. Харин зайнаас тандсан мэдээг ашиглах нь оронзай, цаг хугацаанаас үл хамааран биомассаас гадна, байгаль дээрх биетийн төлөв байдлыг зураглах боломжийг олгодог.

Сүүлийн үед их хэмжээний тоон өгөгдлийг шинжлэхэд машин сургалтын алгоритмууд ихээхэн ашиглагдаж байгаа

бөгөөд уг аргууд нь өгөгдлийг өөрөө боловсруулж, дахин боловсруулан сайжруулж дүн шинжилгээ хийснээр оновчтой, өндөр нарийвчлалтай үр дүнг гаргадгаараа онцлог [4], [5]. Аливаа биомассын тооцоололд, тулах векторын арга (SVM) [6], [7] хэсэгчилсэн хамгийн бага квадратын регрессийн арга (PLSR) [8], [9], санамсаргүй форестын арга (RF) [10], [11], хиймэл нейрон сүлжээ (ANN) зэрэг машин сургалтын аргуудыг [12] ихээхэн ашиглаж байна. Мөн төрөл бүрийн ургамлын спектрийн индексүүдийг ашиглан урт хугацааны бэлчээрийн биомассыг зураглах [13], [14] үнэлэх, урьдчилан таамаглах болон байгаль цаг уур [15], хүрээлэн буй орчны хүчин зүйлс хэрхэн нөлөөлж [16], [17] буйг эрдэмтэн судлаачид судалсаар байна. Түүнчлэн биомассын судалгаанд, хиймэл дагуулын уламжлалт мэдээнээс гадна, NDVI [18], [19] LAI [6], EVI [8], зэрэг олон төрлийн ургамлын индексийг ихээхэн ашиглаж байгаа ба тэдгээрийг ургамлын спектрийн ойлтын шинж чанар дээр тулгуурлан тодорхойлдог [20].

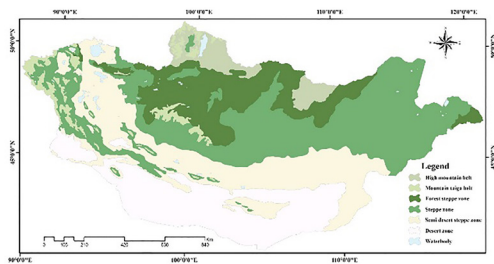
Энэхүү судалгааны зорилго нь хээрийн хэмжилтээр тодорхойлсон биомасс болон ургамлын индексүүд хоорондын хамаарлыг илрүүлэн, машин сургалтын алгоритмуудыг ашиглан бэлчээрийн биомассыг тооцоолж, зураглахад оршино.

2. СУДАЛГААНЫ МАТЕРИАЛ, АРГАЗҮЙ

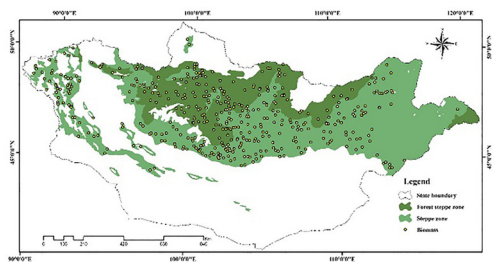
2.1. Судалгааны талбай

Манай орны нийт газар нутгийн тал орчим хувийг эзэлж буй ойт хээрийн болон хээрийн бүс нь Ази тивийн төв хэсэгт хойд хэсгээрээ Сибирийн их тайгын төгсгөл болж, урд хэсгээрээ Төв Азийн хээр цөлийн эхлэл болдог хамгийн нарийн төвөгтэй экосистемүүдийн нэг бөгөөд экологи, эдийн засаг, хүрээлэн буй орчинд онцгой ач холбогдолтой юм. Ойт хээрийн

бүсэд мануул, тоодог, хур зэрэг ховор амьтан, монгол хундага, вансэмбэрүү зэрэг дэлхийд ховордсон ургамал ургадаг. Хээрийн бүс нь Дорнод Монгол, Дундад Халхын тэгш өндөрлөгийн уудам тал газрыг хамарч баруун тийш нарийссаар Ханхөхийн нурууны өмнөд бэл хүртэлх газар нутгийг хамардаг ба түүний 4.3% нь нугат хээрт, 10.1% нь жинхэнэ хээрт, 14.3% нь хуурай хээрт, 5.5% нь уулын хээрт тус тус хуваагддаг (Зураг 1а) [21]. Эдгээр бүс нутгуудад жилд орох хур тунадасны нийт хэмжээ нь уул нуруудын байршил, тэдгээрийн өндөршил зэрэгтэй уялдан харилцан адилгүй байна. Хангай, Хөвсгөл, Хэнтийн уулархаг нутаг, томоохон голын хөндий нутгаар жилдээ 250-390мм тунадас ордог бол Алтайн уулархаг нутгаар 90-130мм болон тал хээрийн нутгаар 180-280мм орчим тунадас ордог байна [22].



Зураг 1а. Монгол орны байгалийн бүс бүслүүр



Зураг 1б. Ойт хээр болон хээрийн бүс, Түүврийн дээж авсан цэгийн байршлын зураг

2.2. Ашигласан мэдээ

Энэхүү судалгаанд бэлчээрийн биомассыг тооцоолохын тулд MODIS хиймэл дагуулын 2016 оны 8 дугаар сарын 21-ны өдрийн 13 давхарга бүхий MOD09A1 бүтээгдэхүүнийг (<https://ladsweb.modaps.eosdis.nasa.gov/>) татан авч, боловсруулан ашиглалаа. Татаж авсан өгөгдлийг ENVI программын MRT хэрэгслийг ашиглан WGS84/UTM солбицлын системд холбосон болно. Мөн тухайн сард хийгдсэн 430 цэгийн газрын хэмжилтийн биомассын мэдээг тулгуур өгөгдөл болгон ашигласан ба байршлыг Зураг 1б-д үзүүлэв. Энэхүү мэдээний хувьд 2016 оны 8-р сарын 22-нд талбайд хэмжсэн биомассыг сонгосон ба Ус, цаг уур, орчны мэдээлэл, судалгааны хүрээлэнгийн мэдээллийн сангаас авсан болно.

MODIS хиймэл дагуулын мэдээн хувьд ургамалжилтын дүн шинжилгээнд өргөн хэрэглэгддэг 30 индексийг (BWDRVI, CAI, DEI, EV22, GBNDVI, GDVI, GLI, GOSAVI, GRNDVI, GRVI, LogR, MNDVI2, MNDVIRV, MSR2, NDLI, NDVI, NDVIg, NDVLI, NGRDI, NNIR, OSAVI, OSAVI16, OSAVI23, RDVI2, RI, RVI, TCARI, TDVI, TGI, TVI3) сонгон авч тооцоолсон бөгөөд тухайн мэдээний b1-b7 сувгуудыг (цахилгаан соронзон долгионы үзэгдэх гэрэл, ойрын нэл улаан туяа (NIR), дундын нэл улаан туяа (SWIR) мужуудын мэдээ) ашигласан ба тэдгээрийн жагсаалтыг Хүснэгт 1-д үзүүлэв.

Хүснэгт 1. Судалгаанд ашигласан ургамлын индекс

| № | Товчилсон ҮГ | Ургамлын индекс | Томьёо |
|----|-----------------|---|---|
| 1 | BWDRVI | Blue-wide dynamic range vegetation index | $\frac{0.1 * NIR - Blue}{0.1 * NIR + Blue}$ |
| 2 | CAI | Cellulose absorption index | $0.5 * (SWIR1 + SWIR3) - SWIR2$ |
| 3 | DEI | Dead Fuel Index | $100 * \left(1 - \frac{SWIR1}{SWIR2}\right) * \left(\frac{Red}{NIR}\right)$ |
| 4 | EV22 | Enhanced Vegetation Index 22 | $2.5 * \frac{(NIR - Red)}{(NIR + 2.4 * Red + 1)}$ |
| 5 | GBNDVI | Green-Blue NDVI | $\frac{NIR - (Green - Blue)}{NIR + (Green + Blue)}$ |
| 6 | GDVI | Green Green Difference Vegetation Index | $NIR - Blue$ |
| 7 | GLI | Green leaf index | $\frac{2 * Green - Red - Blue}{2 * Green + Red + Blue}$ |
| 8 | GOSAVI | Green Optimized Soil Adjusted Vegetation Index | $\frac{NIR - Green}{NIR + Green + 0.16}$ |
| 9 | GRNDVI | Green-Red NDVI | $\frac{NIR - (Green + Red)}{NIR + (Green + Red)}$ |
| 10 | GRVI | Green Ratio Vegetation Index | $\frac{NIR}{Green}$ |
| 11 | LogR | Log Ratio | $\log * \frac{NIR}{Red}$ |
| 12 | MNDVI2 | Modified NDVI2 | $\frac{\sqrt{(NIR - SWIR1)}}{\sqrt{(NIR + SWIR1)}}$ |
| 13 | MNDVIRV | Modified Normalized Difference Vegetation Index RVI | $\left(\frac{Red}{NIR} - 1\right) / \left(\frac{Red}{NIR} + 1\right)$ |
| 14 | MSR2 | Modified Simple Ratio2 | $\left(\frac{NIR}{Red} - 1\right) / \left(\frac{NIR}{Red} + 1\right)$ |
| 15 | NDLI | Normalized Difference Lignin Index | $\frac{\left(\left(\log \frac{1}{SWIR2}\right) - \left(\log \frac{1}{SWIR1}\right)\right)}{\left(\left(\log \frac{1}{SWIR2}\right) + \left(\log \frac{1}{SWIR1}\right)\right)}$ |
| 16 | NDVI | Normalized Difference Vegetation Index (NDVI) | $\frac{(NIR - Red)}{(NIR + Red)}$ |

| | | | |
|----|-------------------|---|---|
| 17 | NDVI _g | Green Normalized Difference Vegetation Index (NDVI _{green}) | $\frac{(NIR - Green)}{(NIR + Green)}$ |
| 18 | NDVLI | Red and SWIR NDVI | $\frac{NIR - (0.4 * Red + 0.6 * SWIR1)}{NIR + (0.4 * Red + 0.6 * SWIR1)}$ |
| 19 | NGRDI | Normalized Green Red Difference Index | $\frac{(Green - Red)}{(Green + Red)}$ |
| 20 | NNIR | Norm NIR | $\frac{NIR}{(NIR + Red + Blue)}$ |
| 21 | OSAVI | Optimized Soil Adjusted Vegetation Index | $(1 + 0.16) * \frac{(NIR - Red)}{(NIR + Red + 0.16)}$ |
| 22 | OSAVI16 | Optimized Soil Adjusted Vegetation Index1628 | $(1 + 0.16) * \frac{(NIR - SWIR2)}{(NIR + SWIR2 + 0.16)}$ |
| 23 | OSAVI23 | Optimized Soil Adjusted Vegetation Index 2 | $(1 + 0.16) * \frac{(NIR - SWIR1)}{(NIR + SWIR1 + 0.16)}$ |
| 24 | RDVI2 | Renormalized Difference Vegetation Index | $\frac{NIR - Red}{\sqrt{(NIR + Red)}}$ |
| 25 | RI | Green Redness Index | $\frac{(Red - Green)}{(Red + Green)}$ |
| 26 | RVI | Simple Ratio 800/670 Ratio Vegetation Index | $\frac{Red}{NIR}$ |
| 27 | TCARI | Transformed Chlorophyll Absorption Ratio | $3 * \left((NIR - Red) - (0.2 * (NIR - Red)) \right) * \left(\frac{NIR}{Red} \right)$ |
| 28 | TDVI1 | Transformed Difference Vegetation Index | $\frac{\sqrt{NIR} - Red}{\sqrt{NIR + Red}}$ |
| 23 | TGI | Triangular greenness index | $Blue - 0.9 * Red - 0.61 * Green$ |
| 30 | TVI3 | Triangular Vegetation Index 3 | $0.5 * \left(120 * \frac{(NIR - Blue)}{NIR} + Blue \right)$ |

2.3. Аргагүй

Судалгааны ажлын хүрээнд SVM, RF болон PLSR зэрэг аргуудыг ашиглан ойт хээр ба хээрийн бүсийн биомассыг тооцооллоо.

SVM нь ангилал нь машин сургалтын алгоритм арга бөгөөд гол зорилго нь N хэмжээст огторгуйд өгөгдлийн цэгүүдийг өөр өөр ялгаатай бүлгүүдэд ангилж чадах оновчтой гипер-хавтгайг байгуулах явдал байдаг [23]. Гипер-хавтгай нь өөр өөр ялгаатай ангиудын хамгийн ойр цэгүүдийн хоорондох зайг аль болох их байлгахыг хичээдэг. Гипер-хавтгайн хэмжээ нь тухайн өгөгдлийн шинж чанаруудаас хамаардаг байна [6].

RF алгоритм нь ангиллын модны алгоритм [24] дээр суурилдаг бөгөөд ангилал болон регрессийн аль алинд нь ашиглагддаг орчин үеийн өндөр түвшний машин сургалтын арга юм. Энэхүү арга нь өгөгдлүүдээс сонгогдож байгуулагддаг шийдвэрийн модыг олноор байгуулж багцлан дүн шинжилгээ хийдэг бөгөөд мод бүрийн хувьд таамагласан үр дүнгүүдийн дунжийг бий болгодог. RF-ийн аргын давуу тал нь өгөгдлийн тодорхой хэсэг нь байхгүй үед үр дүнг гаргадаг явдал юм [6].

PLSR нь гол компонентийн шинжилгээ болон регрессийн шинж чанаруудыг нэгтгэдэг арга юм. Энэхүү арга нь эхлээд үл хамаарах болон хамаарах хувьсагчдын хоорондын хамаарал дээр тулгуурлан олон тооны компонентийг гарган авсны дараа цөөн тооны хувьсагчдын утгыг таамагладаг [25].

Судалгаанд өгөгдлийг боловсруулахдаа статистикийн R.3.5.2 болон RStudio 1.3 программ хангамжийн randomforest болон svm гэсэн алгоритмуудыг ашигласан ба PLS-ийг тооцоолохдоо, XLSTAT-ийг MS Excel программ дээр нэмэлтээр суулган ашиглалаа.

3. СУДАЛГААНЫ ҮР ДҮН

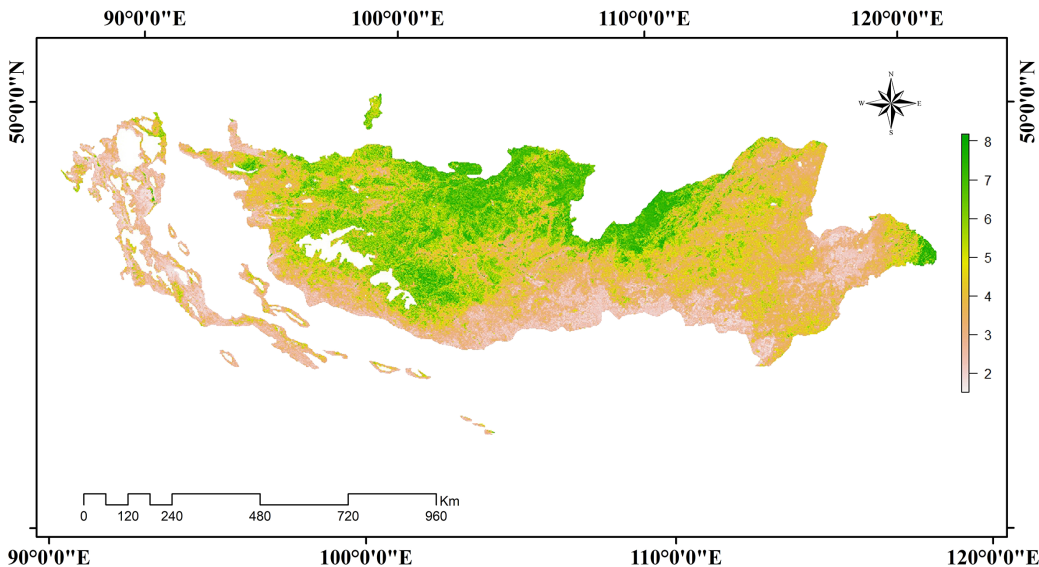
Энэхүү судалгаанд, МОДИС хиймэл дагуулын 500м-ийн оронзайн нарийвчлалтай мэдээг ашиглан ургамалжилтын 30 индексийг тодорхойлсон ба газар дээр хэмжсэн бодит биомасс болон таамагласан биомасс хоорондын хамааралд, корреляцийн коэффициент (r), детерминацийн коэффициент (r^2), дундаж квадрат алдаа (RMSE) зэрэг аргуудыг ашигласан болно. Сонгосон 30 индексээс өндөр хамааралтай буюу $r \geq 0.55$ -аас их утгатай, ач холбогдлын түвшин $P=0.00$ буюу статистикийн хувьд ач холбогдолтой 17 индекс сонгон бөгөөд RF, SVM болон PLS аргуудыг ашиглан ангилсан ба биомасс болон индексийн ерөнхий мэдээллийг Хүснэгт 2-т үзүүлэв. Харин ангиллын үр дүнг (жишээ нь биомассын зураг) Зураг 2, 3, 4-т харуулав. Үүссэн корреляцийн коэффициентын матрицыг Хүснэгт 3-т харууллаа. Хүснэгт 3-аас харахад, $r \leq 0.60$ хүртэлх 6 индекс (EV22, GLI, GOSAVI, GRNDVI, NGRDI болон OSAVI) байв. Бусад 11 индексүүд нь $r \geq 0.60$ -аас их утгатай (BWDRVI, GBNDVI, GRNDVI, LogR, NDVI, NDVIg, NNIR, OSAVI23, RDVI2, TDVI1 болон TGI) байлаа. Мөн эдгээр индексүүд нь үзэгдэх гэрлийн муж ба ойрын нэл улаан туяаны сувгийн тусламжтайгаар тооцоолсон бол OSAVI23 индексийг ойрын нэл улаан туяаны сувгуудыг ашиглан тус тус тооцоолсон болно. Өндөр хамааралтай ургамлын индексүүдийн дотроос GRNDVI, NNIR ($r = 0.641$) болон NDVI ($r = 0.639$) нь газрын биомассыг тайлбарлахад чухал индексүүд байлаа.

Хүснэгт 2. Ургамлын индекс болон биомассын ерөнхий мэдээлэл.

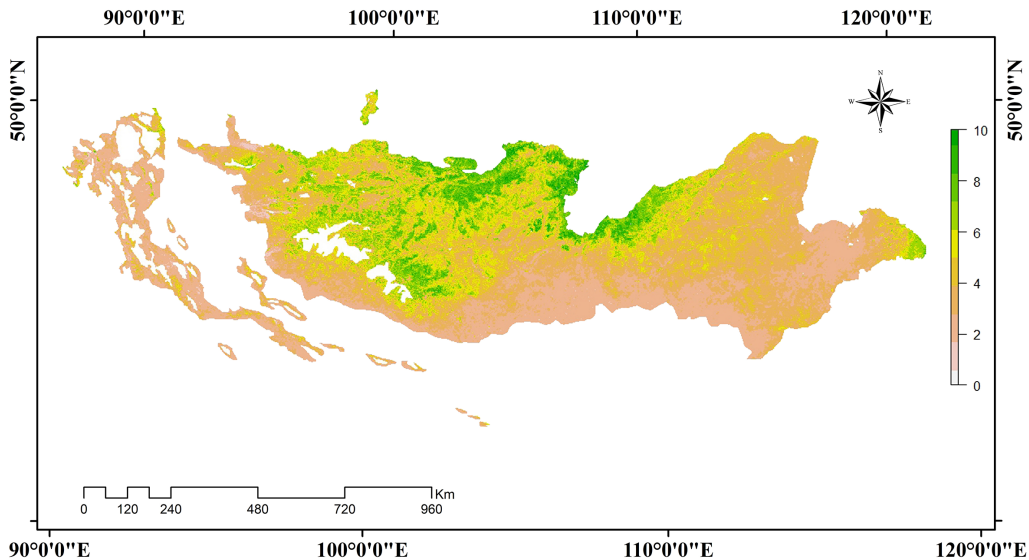
| Индекс | Дээжийн тоо | Хамгийн бага утга (ц/га) | Хамгийн их утга (ц/га) | Дундаж утга (ц/га) | Std. хазайлт утга (ц/га) |
|---------|-------------|--------------------------|------------------------|--------------------|--------------------------|
| Биомасс | 430 | 0.8 | 9.6 | 4.028 | 2.1274 |
| Индекс | Дээжийн тоо | Хамгийн бага | Хамгийн их утга | Дундаж утга | Std. хазайлт |
| BWDRVI | 430 | -0.651 | 0.175 | -0.338 | 0.160 |
| EV22 | 430 | 0.046 | 0.465 | 0.230 | 0.081 |
| GBNDVI | 430 | -0.095 | 0.5902 | 0.260 | 0.138 |
| GLI | 430 | -0.0806 | -0.0004 | -0.022 | 0.017 |
| GOSAVI | 430 | 0.093 | 0.474 | 0.306 | 0.068 |
| GRNDVI | 430 | -0.218 | 0.511 | 0.109 | 0.153 |
| GRVI | 430 | -0.0607 | 0.015 | -0.017 | 0.016 |
| LogR | 430 | 0.189 | 1.986 | 0.856 | 0.368 |
| NDVI | 430 | 0.094 | 0.759 | 0.393 | 0.147 |
| NDVIg | 430 | 0.152 | 0.685 | 0.451 | 0.106 |
| NGRDI | 430 | -0.189 | 0.153 | -0.065 | 0.061 |
| NNIR | 430 | 0.391 | 0.756 | 0.555 | 0.077 |
| OSAVI | 430 | 0.072 | 0.599 | 0.311 | 0.109 |
| OSAVI23 | 430 | -0.157 | 0.467 | 0.0943 | 0.117 |
| RDVI2 | 430 | 0.3067 | 0.871 | 0.615 | 0.121 |
| TDVI1 | 430 | 1.096 | 2.145 | 1.584 | 0.193 |
| TGI | 430 | -0.095 | 0.006 | -0.039 | 0.022 |

Хүснэгт 3. Биомасс болон индекс хоорондын хамаарал

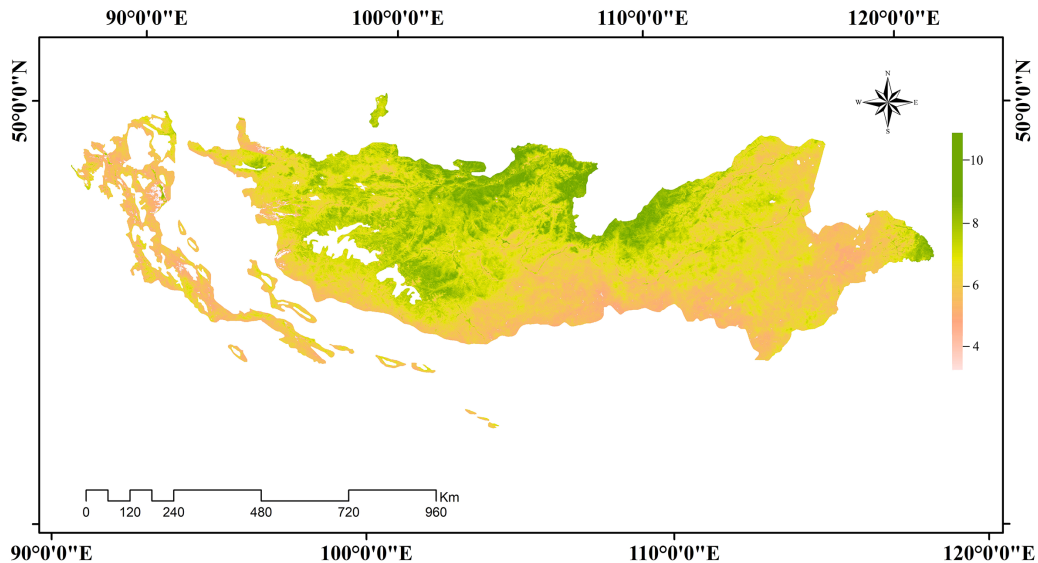
| | BIOMASS | BWDRVI | EV22 | GBNDVI | GLI | GOSAVI | GRNDVI | GRVI | LogR | NDVI | NDVIg | NGRDI | NNIR | OSAVI | OSAVI23 | RDVI2 | TDVI1 | TGI | |
|---------|---------|--------|-------|--------|-------|--------|--------|-------|-------|-------|-------|-------|-------|-------|---------|-------|-------|-------|--|
| BIOMASS | 1.000 | | | | | | | | | | | | | | | | | | |
| BWDRVI | 0.611 | 1.000 | | | | | | | | | | | | | | | | | |
| EV22 | 0.590 | 0.945 | 1.000 | | | | | | | | | | | | | | | | |
| GBNDVI | 0.624 | 0.983 | 0.953 | 1.000 | | | | | | | | | | | | | | | |
| GLI | 0.571 | 0.799 | 0.769 | 0.833 | 1.000 | | | | | | | | | | | | | | |
| GOSAVI | 0.589 | 0.950 | 0.972 | 0.979 | 0.755 | 1.000 | | | | | | | | | | | | | |
| GRNDVI | 0.641 | 0.978 | 0.967 | 0.987 | 0.849 | 0.960 | 1.000 | | | | | | | | | | | | |
| GRVI | 0.557 | 0.760 | 0.787 | 0.746 | 0.875 | 0.675 | 0.829 | 1.000 | | | | | | | | | | | |
| LogR | 0.637 | 0.972 | 0.962 | 0.966 | 0.837 | 0.933 | 0.994 | 0.861 | 1.000 | | | | | | | | | | |
| NDVI | 0.639 | 0.967 | 0.966 | 0.975 | 0.862 | 0.945 | 0.997 | 0.864 | 0.995 | 1.000 | | | | | | | | | |
| NDVIg | 0.628 | 0.967 | 0.950 | 0.997 | 0.837 | 0.981 | 0.984 | 0.741 | 0.960 | 0.972 | 1.000 | | | | | | | | |
| NGRDI | 0.520 | 0.769 | 0.788 | 0.709 | 0.687 | 0.654 | 0.806 | 0.919 | 0.864 | 0.836 | 0.690 | 1.000 | | | | | | | |
| NNIR | 0.641 | 0.978 | 0.967 | 0.987 | 0.849 | 0.960 | 1.000 | 0.829 | 0.994 | 0.997 | 0.984 | 0.806 | 1.000 | | | | | | |
| OSAVI | 0.621 | 0.963 | 0.990 | 0.973 | 0.829 | 0.967 | 0.991 | 0.835 | 0.987 | 0.992 | 0.971 | 0.816 | 0.991 | 1.000 | | | | | |
| OSAVI23 | 0.557 | 0.869 | 0.888 | 0.845 | 0.708 | 0.826 | 0.888 | 0.805 | 0.908 | 0.897 | 0.834 | 0.854 | 0.888 | 0.897 | 1.000 | | | | |
| RDVI2 | 0.633 | 0.953 | 0.962 | 0.978 | 0.880 | 0.954 | 0.991 | 0.847 | 0.980 | 0.994 | 0.980 | 0.790 | 0.991 | 0.988 | 0.873 | 1.000 | | | |
| TDVI1 | 0.600 | 0.806 | 0.741 | 0.850 | 0.936 | 0.756 | 0.864 | 0.829 | 0.849 | 0.875 | 0.861 | 0.677 | 0.864 | 0.821 | 0.710 | 0.894 | 1.000 | | |
| TGI | 0.605 | 0.864 | 0.844 | 0.864 | 0.958 | 0.785 | 0.908 | 0.964 | 0.919 | 0.928 | 0.857 | 0.857 | 0.908 | 0.897 | 0.823 | 0.923 | 0.920 | 1.000 | |



Зураг 2. RF аргын дүнд таамагласан биомассын зураг (ц/га)




Зураг 3. SVM аргын дүнд таамагласан биомассын зураг (ц/га)



Зураг 4. PLSR аргын дүнд таамагласан биомассын зураг (ц/га)

Бодит болон таамагласан биомасс хоорондын хамаарлыг баталгаажуулах үүднээс, график дүрслэл дээр тулгуурлан харьцуулсан судалгааг хийсэн (Зураг 5). Зураг 5-аас харахад, нийт хэмжсэн 430 түүврийн талбайгаас 140 түүврийн талбайн

бодит болон таамагласан биомасс нь маш сайн тохирч байгаа бол 125 түүврийн талбай дээрх хэмжилт сайн тохирч байв. Харин 52 түүврийн талбайн бодит болон таамагласан биомасс хооронд өндөр зөрүүтэй байлаа.



Зураг 5. Гурван ангилал дахь бодит болон таамагласан биомассын утгуудын харьцуулалт.

Үр дүнгээс харахад ойт хээр ба хээрийн бүсийн биомассыг SVM, RF, PLSR аргуудаар үнэлэхэд тэдгээрийн детерминацын коэффициент (r^2) нь 0.27, 0.89 болон 0.30 ба дундаж квадрат алдаа (RMSE) нь 1.889ц/га, 0.713ц/га болон 1.854ц/га байлаа. Ойт хээр ба хээрийн бүс нь газарзүйн байрлал, өндөршил, ургамлын төрөл зүйл, уур амьсгалын нөхцөл, ялангуяа хур тунадасны хуваарилалт, дулааны хэлбэлзлийн хувьд харилцан адилгүй бүсүүд тул бүс тус бүрээр нь чанарын үнэлгээг хийж гүйцэтгэв. Ойт хээрийн бүсийн хувьд SVM, RF, PLSR аргын r^2 нь 0.887, 0.886 болон 0.158 ба RMSE нь 0.726 ц/га, 0.728 ц/га болон 1.972ц/га байв. Харин хээрийн бүсийн SVM, RF, PLSR аргын r^2 нь 0.870, 0.870 болон 0.311 ба RMSE нь 0.605 ц/га, 0.607 ц/га болон 1.386ц/га байв (Хүснэгт 4). Энэхүү үр дүнгээс ажиглавал ойт хээр болон хээрийн бүсийн биомассын зураглахад RF арга нь илүү үр дүнтэй нь ажиглагдсан бол бүс тус бүрээр биомассыг зураглахад RF болон SVM аргууд илүү өндөр дүнг үзүүллээ. Тиймээс сонгосон туршилтын талбайн хувьд RF аргын үр дүн нь SVM техникээс давуу бөгөөд эцсийн гаралтын биомассын зургийг бэлчээрийн төлөвлөлт, менежментэд үнэн зөв ашиглах бүрэн боломжтойг харууллаа.

Хүснэгт 4. Бодит болон таамагласан биомасс хоорондын хураангуй статистик (r^2 ба RMSE)

| <i>Ойт хээр болон хээрийн бүс</i> | | | |
|-----------------------------------|---------------|-------------|---------------|
| | SVM 17 | RF17 | PLSR17 |
| R^2 | 0.273 | 0.889 | 0.296 |
| RMSE | 1.889 | 0.713 | 1.854 |
| <i>Ойт хээрийн бүс</i> | | | |
| | SVM 17 | RF17 | PLSR17 |
| R^2 | 0.887 | 0.886 | 0.158 |
| RMSE | 0.726 | 0.728 | 1.972 |
| <i>Хээрийн бүс</i> | | | |
| | SVM 17 | RF17 | PLSR17 |
| R^2 | 0.870 | 0.870 | 0.311 |
| RMSE | 0.605 | 0.607 | 1.386 |

4. ХЭЛЭЛЦҮҮЛЭГ

Орчин үед дэлхийн улс орнуудын шинжлэх ухаан, техник технологийн үсрэнгүй хөгжил даяаршиж буй өнөө үед хиймэл оюуны болон машин сургалтын аргуудын хэрэглээ эрчимтэй нэмэгдэж байна. Сүүлийн жилүүдэд биомасс болон ургамлын спектрийн индекс хоорондын хамаарлын талаарх манай орны хэмжээнд хэд хэдэн судалгаа хийгдсэн байна. Үүнд:

- Kogan нар (2004) хэт өндөр нарийвчлалтай хиймэл AVHRR (Advanced Very High Resolution Radiometer) дагуулын мэдээг ашиглан манай орны урт хугацааны бэлчээрийн биомассыг ургамлын хэд хэдэн индекс ашиглан үнэлсэн байна [13].
- Жавзандулам нар (2005) SPOT-4 хиймэл дагуулын мэдээ ашиглан монгол орны биомасс болон ургамлын индекс хоорондын хамаарлын илрүүлсэн бөгөөд цөлийн болон говийн бүсэд MSAVI2 индекс харин ойт хээрийн бүсэд EVI индексүүд нь өндөр хамаарлыг тус тус үзүүлсэн байна [26].
- Батбилэг нар (2010) Төв аймгийн Борнуур сумын зуны биомассыг MODIS болон FORMOSAT-2 хиймэл дагуулын мэдээ ашиглан харьцуулан судалсан [14].
- Нарангарав нар (2011) хур тунадас, температур болон ургамал ургах үеийн NDVI хоорондын хамаарал судалсан ба ургамал ургалтын үеийн NDVI болон хур тунадас хоорондын хамаарал нь $r^2=0.92$, $p=0.000$ харин NDVI болон температур хоорондын хамаарал нь $r^2=0.55$, $p=0.013$ байлаа [27].
- Hilker нар (2014) NDVI дээр тулгуурлан ургамлын ирээдүйн чиг хандлагыг тогтоох болон бэлчээрийн талхагдалд нөлөөлөх хүчин зүйлийн судалгааг монгол орны хэмжээнд

хийж гүйцэтгэсэн ба малын тоо толгойн өсөлт ургамлын бүрхэвч багасахтай хамааралтай илрүүлсэн байна [28].

- Мөнхдулам (2019). Landsat 8, MODIS хиймэл дагуулын мэдээг ашиглан RF болон PLS-ийн аргыг ашиглан Монгол орны бэлчээрийн биомассыг үнэлэхдээ олон хувьсагчийн регрессийн шинжилгээний аргыг ашигласан ба $r^2=0.68$, харин $RMSE=24.5$ гр/м² байв [9].
- Нямжаргал (2023) Хэт өндөр нарийвчлалтай Sentinel дагуулын мэдээг ашиглан Төв аймгийн Борнуур сумын биомассыг машин сургалтын хэд хэдэн алгоритмуудыг ашиглан үнэлсэн ба биомасс ба ургамлын спектр хоорондын хамаарлыг харьцуулан харуулсан байлаа. 20 ургамлын индексээс GRVI болон MSR индексүүд өндөр хамаарлыг үзүүлсэн байна. Тэдгээрийн тодорхойлох коэффициент нь PLSR-ийн $r^2=0.899$, $RMSE=10.560$ гр/м², SVM-ийн $r^2=0.837$, $RMSE=12.881$ гр/м² харин RF-ийн $r^2=0.823$, $RMSE=13.430$ гр/м² байв [29].
- Амарсайхан нар (2023) дунд зэргийн нарийвчлалтай MODIS хиймэл дагуулын мэдээ ашиглан Дорнод, Сүхбаатар аймгуудын ургамлын биомассыг машин сургалтын RF, SVM аргуудыг ашиглан биомассыг тооцоолсон ба тэдгээрийн $r^2=0.77$ болон $RMSE=0.82$ ц/га харин SVM нь $r^2=0.22$ болон $RMSE=1.58$ ц/га байлаа [30].

Дээрх судалгааны ажлуудаас харахад хиймэл дагуулын мэдээг ашиглан ургамлын спектрийн ойлтын утгуудыг ашиглан бэлчээрийн биомассыг зураглах, үнэлэх боломжтойгоос гадна, гарган авсан сэдэвчилсэн үр дүнгүүдийг тухайн зорилго зорилтоос нь хамаарч төрөл бүрийн судалгаанд өргөнөөр ашиглаж болох нь

харагдаж байна. Өнөө үед, оптикийн, радарын болон хайперспектрийн сансрын мэдээнд тайлал, дүн шинжилгээ хийж сэдэвчилсэн мэдээлэл гарган авах нь уламжлалт аргуудтай харьцуулахад цаг хугацаа, төсөв, зардлыг хэмнэсэн олон талын давуу талтай орчин үеийн ахисан түвшний аргад тооцогддог байна. Энэхүү судалгаанд бид ургамлын спектрийн ойлтын утгыг ашиглан байгаль цаг уурын ялгаатай бүс нутгуудыг хамарсан ойт хээр болон хээрийн бүсүүдийн биомассыг ахисан түвшний машин сургалтын арга болох RF, SVM болон PLS аргуудыг харьцуулан монгол орны биомассын оронзайн тархалтын зургийг боловсруулсан.

5. ДҮГНЭЛТ

Энэхүү судалгааны хүрээнд, Монгол орны ойт хээр ба хээрийн бүсийн бэлчээрийн биомассыг, хээрийн хэмжилтийн мэдээ болон SVM, RF, PLSR зэрэг аргуудыг ашиглан тодорхойлж, харьцуулсан дүн шинжилгээг хийсэн болно. MODIS хиймэл дагуулын мэдээн хувьд ургамалжилтын дүн шинжилгээнд хэрэглэгддэг 30 спектрийн индексийг тооцоолохдоо, цахилгаан соронзон долгионы үзэгдэх гэрлийн болон ойрын нэл улаан туяа (NIR), дундын нэл улаан туяа (SWIR)-ний мужуудын мэдээг ашиглан тооцоолсон болно. Эдгээр ургамлын индексүүдээс GRNDVI, NNIR, NDVI, LogR, RDVI2 болон GBNDVI зэрэг нь газрын биомассыг үнэн зөв тайлбарлахад чухал индексүүд байлаа. Ойт хээр ба хээрийн бүсийн бэлчээрийн биомассыг сонгосон аргуудаар тодорхойлон гарсан үр дүнгүүдийг үнэлэхэд, детерминацын коэффициент (r^2) нь 0.27, 0.89 болон 0.30 байсан бол $RMSE$ нь 1.889ц/га, 0.713ц/га болон 1.854ц/га байлаа. Ойт хээр ба хээрийн бүсийн биомассыг бүс тус бүрээр нь зураглахад RF болон SVM аргууд илүү өндөр дүнг үзүүлэв. Иймд Монгол орны ойт хээр ба хээрийн бүсийн бэлчээрийн

биомассын тооцоолол, зураглал хийхэд RF арга нь илүү үр дүнтэй болох нь харагдлаа.

АШИГЛАСАН МАТЕРИАЛ

- [1]. “Газрын нэгдмэл сангийн улсын нэгдсэн тайлан,” Улаанбаатар, Монгол, 2022.
- [2]. “Монголын бэлчээрийн менежментийн холбоо,” Улаанбаатар, Монгол, Гар бичмэл, 2008.
- [3]. Д. Амарсайхан, ба М.Ганзориг, “Газарзүйн мэдээллийн системийг байгалийн нөөцийн менежментэд ашиглах зарчмууд”, Улаанбаатар, Монгол, 2010.
- [4]. P. Du et al., “Advances of four machine learning methods for spatial data handling: A review,” *J. Geovisualization Spat. Anal.*, vol. 4, p. 13, 2020. <https://doi.org/10.1007/s41651-020-00048-5>
- [5]. A. Sharifi, “Estimation of biophysical parameters in wheat crops in Golestan province using ultra-high resolution images,” *Remote Sens. Lett.*, vol. 9, no. 6, pp. 559-568, Jun. 2018, <https://doi.org/10.1080/2150704X.2018.1452058>
- [6]. Z.Y. Han et al., “Hyperspectral estimation of apple tree canopy LAI based on SVM and RF regression,” *Spectrosc. Spectr. Anal.*, vol. 36, pp. 800-805, 2016.
- [7]. B. Duan, et al., “Remote estimation of rice LAI based on Fourier spectrum texture from UAV image,” *Plant Methods*, vol. 15, no. 1, p. 124, 2019. <https://doi.org/10.1186/s13007-019-0507-8>
- [8]. M. Otgonbayar, C. Atzberger, J. Chambers, and A. Damdinsuren, “Mapping pasture biomass in Mongolia using Partial Least Squares, Random Forest regression and Landsat 8 imagery,” *Int. J. Remote Sens.*, vol. 40, no. 8, pp. 3204-3226, Apr. 2019, <https://doi.org/10.1080/01431161.2018.1541110>
- [9]. F. Wang et al., “Estimation of Above-Ground Biomass of Winter Wheat Based on Consumer-Grade Multi-Spectral UAV,” *Remote Sens.*, vol. 14, no. 5, p. 1251, Mar. 2022, <https://doi.org/10.3390/rs14051251>
- [10]. N. Viljanen et al., “A Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone,” *Agriculture*, vol. 8, no. 5, p. 70, May 2018, <https://doi.org/10.3390/agriculture8050070>
- [11]. L. Guo, X. Xi, W. Yang, and L. Liang, “Monitoring Land Use/Cover Change Using Remotely Sensed Data in Guangzhou of China,” *Sustainability*, vol. 13, no. 5, p. 2944, Mar. 2021, <https://doi.org/10.3390/su13052944>
- [12]. S. Yang et al., “Modeling grassland above-ground biomass based on artificial neural network and remote sensing in the Three-River Headwaters Region,” *Remote Sens. Environ.*, vol. 204, pp. 448-455, 2018. <https://doi.org/10.1016/j.rse.2017.10.011>
- [13]. F. Kogan et al., “Derivation of pasture biomass in Mongolia from AVHRR-based vegetation health indices,” *Int. J. Remote Sens.*, vol. 25, no. 14, pp. 2889-2896, Jul. 2004, <https://doi.org/10.1080/01431160410001697619>
- [14]. B. Batbileg, A. Hirano, and O. Nyamsuren, “Mapping summer time pasture amount in north-central mongolia,” in *Aiming Smart Space Sensing*, Pattaya, Thailand, Nov. 2012.
- [15]. Y. Xie, Z. Sha, M. Yu, Y. Bai, and L. Zhang, “A comparison of two models with Landsat data for estimating above ground grassland biomass in Inner Mongolia, China,” *Ecol. Model.*, vol. 220, no. 15, pp. 1810-1818, 2009. <https://doi.org/10.1016/j.ecolmodel.2009.04.025>

- [16]. M. Liu, G. Liu, L. Gong, D. Wang, and J. Sun, "Relationships of biomass with environmental factors in the grassland area of Hulunbair, China," *PLoS One*, vol. 9, no. 7, p. e102344, 2014. <https://doi.org/10.1371/journal.pone.0102344>
- [17]. X. Wang, H. Yang, X. Liu, and Y. Su, "Effects of biomass and environmental factors on nitrogen removal performance and community structure of an anammox immobilized filler," *Sci. Total Environ.*, vol. 710, p. 135258, 2020. <https://doi.org/10.1016/j.scitotenv.2019.135258>
- [18]. M. Klinge et al., "Geoecological parameters indicate discrepancies between potential and actual forest area in the forest-steppe of Central Mongolia," *For. Ecosyst.*, vol. 8, no. 1, p. 55, Aug. 2021, <https://doi.org/10.1186/s40663-021-00333-9>
- [19]. M. Lumbierres, P. Méndez, J. Bustamante, R. Soriguer, and L. Santamaría, "Modeling Biomass Production in Seasonal Wetlands Using MODIS NDVI Land Surface Phenology," *Remote Sens.*, vol. 9, no. 4, p. 392, Apr. 2017, <https://doi.org/10.3390/rs9040392>
- [20]. D. Zianis and M. Mencuccini, "Aboveground net primary productivity of a beech (*Fagus moesiaca*) forest: a case study of Naousa forest, northern Greece," *Tree Physiol.*, vol. 25, no. 6, pp. 713-722, Jun. 2005, <https://doi.org/10.1093/treephys/25.6.713>
- [21]. Д. Даш. Монгол орны ландшафт экологийн асуудлууд. Улаанбаатар, Монгол, 2010. <http://w.tsag-agaar.gov.mn/>
- [22]. S. Amari, S.I W., "Conformal transformation of Kernel functions: A data-dependent way to improve support vector machine classifier," *Neural Process. Lett.*, vol. 15, pp. 59-67, 2002.
- [23]. L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, pp. 5-32, 2001. <https://doi.org/10.1023/A:1010933404324>
- [24]. P.T. Wolter, P.A. Townsend, B.R. Sturtevant, and C.C. Kingdon, "Remote sensing of the distribution and abundance of host species for spruce budworm in Northern Minnesota and Ontario," *Remote Sens. Environ.*, no. 112, pp. 3971-3982, 2008. <https://doi.org/10.1016/j.rse.2008.07.005>
- [25]. T. Javzandulam, R. Tateishi, and T. Sanjaa, "Analysis of vegetation indices for monitoring vegetation degradation in semi-arid and arid areas of Mongolia," *Int. J. Environ. Stud.*, vol. 62, no. 2, pp. 215-225, Apr. 2005, <https://doi.org/10.1080/00207230500034123>
- [26]. D. Narangarav and Ch.Lin, "Investigation of Vegetation Dynamics of Mongolia Using Time Series of NDVI in Response to Temperature and Precipitation," *Mong. J. Biol. Sci.*, vol. 9, no. 1-2, pp. 9-17, Jan. 2017.
- [27]. T. Hilker, E. Natsagdorj, R. H. Waring, A. Lyapustin, and Y. Wang, "Satellite observed widespread decline in Mongolian grasslands largely due to overgrazing," *Glob. Change Biol.*, vol. 20, no. 2, pp. 418-428, Feb. 2014, <https://doi.org/10.1111/gcb.12365>
- [28]. A. Enkhmanlai, E. Nyamjargal, D. Amarsaikhan, O. Munkhdulam and B. Batbileg, "Estimation and mapping of pasture biomass in Mongolia using machine learning methods," *Geocarto Int.*, vol. 38, no. 1, p. 2195824, 2023. <https://doi.org/10.1080/10106049.2023.2195824>
- [29]. D. Amarsaikhan et al., "Estimation of Grassland Biomass in Eastern Mongolia RS-based Vegetation Indices Title," in *Environmental Science and Technology*, Ulaanbaatar, Mongolia, 2023.