

AUGALIJOS IR NDWI INDEKSŲ TAIKYMAS NUSTATANT DIRVOŽEMIO DRĖGMĘ NUOTOLINIAIS METODAIS

Miglė MOCKUTĖ, Klaipėdos universitetas, Jūros tyrimų institutas, el. paštas: migle.mockute@ku.lt

Edvinas TIŠKUS, Klaipėdos universitetas, Jūros tyrimų institutas, el. paštas: Edvinas.Tiskus@ku.lt

Santrauka

Dirvožemio drėgmė yra vienas iš svarbiausių veiksnių, turinčių įtakos augalų augimui ir derliui (Zhang ir kt., 2018). Tačiau pigesnės ir patogesnės metodikos, galinčios pakeisti įprastus tiesioginius drėgmės matavimus, vis dar ieškoma. Šiame darbe nagrinėjamas optinių jutiklių pritaikymo dirvožemio drėgmės nustatymui tikslumas, remiantis augalų fiziologiją ir vandens kiekį įvertinančiais indeksais. Tyrimas atliekamas pritaikant „DJI Inspire 2“ droną, „Sentinel-2“ palydovą ir gravimetrinį drėgmės nustatymo metodą. Indeksų tikslumas įvertinamas sudarius linijinės regresijos modelius labiausiai su drėgme koreliuojantiems indeksams. Taip pat nustatomas indeksų patikimumas, kuris atliekamas įvertinant skirtumo tarp šių indeksų gautų drėgmės reikšmių ir *in situ* drėgmės reikšmingumą ir skaičiuojant RMSE.

Tyrimo rezultatai parodė, kad geriausiai dirvožemio drėgmė įvertinama iš NDWI ir GCI indeksų. NDWI tikslumas 35 % iš drono ir 40 % iš palydovinių duomenų. GCI tikslumas nustatant dirvožemio drėgmę siekė 30 % drono ir 36 % palydovo duomenims. Tarp drėgmės reikšmių iš šių indeksų ir *in situ* matavimų nenustatyta reikšmingo skirtumo. Indeksų vidutiniai nuokrypiai nuo tiesioginių matavimų siekė nuo 0,22 % iki 0,83 %. Vešlios augalijos sąlygomis nustatytas didesnis palydovinių indeksų tikslumas – 61 % (NDWI) ir 88 % (GCI), suteikiantis galimybę tobulinti metodiką subrendusios augalijos sąlygomis. Vidutiniai nuokrypiai nuo drėgmės neviršijo 1,10 %.

Reikšminiai žodžiai: dirvožemio drėgmė, dronas, multispektrinė kamera, „Sentinel-2“ palydovas, MSI jutiklis, tikslumas, indeksai, augalija.

Įvadas

Dirvožemio kokybė tiesiogiai veikia kasdienį žmogaus gyvenimą, nes apie 99 % žmonių vartojamo maisto yra gaunama iš žemės (Kopittke ir kt., 2019). Tiesioginiai metodai yra laikomi patikimiausiomis priemonėmis tiksliai nustatyti dirvožemio drėgnumą, tačiau jie reikalauja daug piniginių, laiko ir žmogiškųjų išteklių (Rahimzadeh-Bajgiran ir kt., 2013; Zhang ir kt., 2015). Taip pat jie suteikia tik vietinę informaciją apie drėgmės dinamiką (Petropoulos ir kt., 2013). Dirvožemio drėgmė nuotoliniais metodais pradėta tirti aštuntajame dešimtmetyje (Mu ir kt., 2022). Galimybė pagal poreikį atlikti didelės raiškos laukų atvaizdavimą nepažeidžiant dirvožemio ir augalų yra svarbus dronų privalumas, todėl jie vis plačiau pritaikomi *in situ* ir palydovinių duomenų spragoms užpildyti (Halla ir kt., 2020).

Nors nuotoliniai metodai pasaulyje yra naudojami plačiai, jų pritaikymui nustatyti dirvožemio drėgmę vis dar ieškoma geriausios metodikos. Atsižvelgiant į tai, kad į drėgmės pokyčius greitai reaguoja augalai, populiarėja metodai, įvertinantys drėgmę pagal augalijos fiziologinius pokyčius. Kol kas bendro sutarimo dėl augalijos indekso, kuris tiksliausiai įvertina dirvožemio drėgmę, nėra.

Tyrimo tikslas – įvertinti ir atrinkti tiksliausius drono ir palydovo indeksus dirvožemio drėgmės nustatymui.

Iškeltam tikslui pasiekti sprendžiami šie **uždaviniai**:


1. Įvertinti indeksų koreliacinius ryšius su *in situ* drėgme ir išskirti labiausiai koreliuojančius drono ir palydovo indeksus.
2. Nustatyti kiekybinį išskirtų drono ir palydovo indeksų tikslumą ir vidutinį nuokrypį nuo tiesioginių drėgmės matavimų.

Tyrimų objektas ir metodai

Tyrimo vieta – tyrimas atliktas ūkyje, Tauragės apskrityje, Šilalės raj., Deblių k. Pagal 1999 metų Lietuvos dirvožemių klasifikaciją („LTDK-99“) teritorijoje vyrauja nepasotintieji sekliai glėjiški balkšvažemiai. Nagrinėjamo lauko plotas ~ 2,5 ha (žr. 1 pav.).

Pagrindinis tyrimo objektas – dirvožemio drėgmė, kuri buvo nustatoma trimis skirtingais metodais: tiesioginiu (gravimetriniu) būdu ir nuotoliniais metodais (dronu ir palydovu).

Tiriamas laikotarpis – 2022 metų balandžio ir birželio–rugsėjo mėnesiai. Tiriamuoju laikotarpiu (gegužės mėnesį) pasėtas sideralinis mišinys, kuriame vyrauja garstyčios ir ridikai. Vegetacinės sąlygos tiriamu laikotarpiu kito nuo dangos be augalų iki subrendusios augalijos.



1 pav. Tyrimo vieta (apibrėžta žaliai) ir liepos mėnesio drėgmės matavimo taškai. Žemėlapyje (kairėje viršuje) oranžine spalva paryškintas tyrimo rajonas, žaliai pažymėta tyrimo vieta. Koordinatų sistema: LKS-94.

Fig 1. Study site (outlined in green) and July soil moisture measurement points. On the map (top left), the research district is highlighted in orange, the research site is marked in green. Coordinate system: LKS-94.

Drėgmės nustatymas *in situ* metodu – dirvožemio drėgmė buvo nustatoma svoriniu (gravimetriniu) metodu (žr. 2 pav.). Šį standartinį drėgmės nustatymo būdą sudarė fizinis dirvožemio ėminių paėmimas bei jų svėrimas prieš ir po džiovinimo. Ėminiai džiovinti 60 °C temperatūroje 72 val. Drėgmės kiekis, išgaravęs džiovinimo metu, parodė dirvožemio drėgnumą ėminio paėmimo momentu. Ėminiai imti iš ~ 0–5 cm gylio. Balandį paimti 9 ėminiai, birželį – 17, o kitais mėnesiais – 11 ėminių. Drėgmė apskaičiuota pagal (1) formulę (gautos drėgmės reikšmės išreikštos procentais):

$$\text{drėgmė} = (\text{Svoris}_S - \text{indelio svoris}) - (\text{Svoris}_{60} - \text{indelio svoris})$$

(1)

kur/where: Svoris_S – ėminio svoris (g) prieš džiovinimą / sample weight (g) before drying; Svoris₆₀ – ėminio svoris (g) po džiovinimo 60 °C temperatūroje / sample weight (g) after drying at 60 °C temperature.



2 pav. Drėgmės nustatymas gravimetriniu metodu laboratorijoje.

Fig 2. Moisture determination by gravimetric method in the laboratory.

Palydovas – tyrimui naudoti „Sentinel-2“ „MSI“ jutiklio (multispektrinio instrumento) optiniai vaizdai su 10 m erdvine raiška. Renkantis palydovines nuotraukas buvo atsižvelgiama į debesuotumo faktorių ir iš „Copernicus Open Access Hub“ parsisiųstos artimiausios *in situ* matavimui palydovinės nuotraukos be debesų. Pasirinktos 2 lygio nuotraukos, apdorotos „Sen2Cor“ algoritmu (nuotraukoms atlikta atmosferinė korekcija). Nuotraukoms „SNAP“ programoje buvo atliktas erdvinės raiškos suvienodinimas (angl. resampling). Kiekvieno mėnesio palydovinės nuotraukos apkirptos pagal tyrimo plotą.

Dronas – tyrimui naudotas Klaipėdos universiteto Jūros tyrimų institutui priklausantis „DJI Inspire 2“ dronas su „MicaSense RedEdge-MX“ kamera. Prieš atliekant tyrimą „www.Oran.lt“ įsitikinta, kad teritorijoje nėra draudžiama skraidyti arba skraidymas nėra apribotas. Drono skrydžių planas buvo sudaromas remiantis „Sentinel-2“ palydovo skrydžiais, siekiant gauti kuo mažesnę laiko tarpą tarp šių skrydžių. Dėl saugumo ir galimo poveikio duomenims nebuvo skraidoma esant blogoms oro sąlygoms. Siekiant gauti aukštos kokybės duomenis buvo naudojamos automatinės skrydžių planavimo programos „DJI GO 4“ ir „Pix4DCapture“.

Tyrimo laikotarpiu atlikti 5 skrydžiai dronu. Skrydžių trukmė ~ 10–15 min. Pasirinktas skridimo aukštis – 40 m, nuotraukų persidengimas – 80 %, pasirinktas vertikalus 90 ° nuotraukų fiksavimo režimas. Nustatytas multispektrinės

kameros veikimo diapazonas (\pm) 35 m. Gautos nuotraukos 1 cm erdvine raiška. „ArcGIS PRO“ programoje suvienodintos drono ir palydovo nuotraukų raiškos pritaikant „Fishnet“ funkciją, kuri sukuria langelių tinklą.

Indeksai – kadangi dirvožemio drėgmė ir augalijos būklė yra tarpusavyje susijusios, tyrimui pasirinkta drėgmę vertinti pagal skirtingų indeksų reikšmes. Tam pasirinkti devyni augalijos indeksai ir normalizuotas vandens skirtumo indeksas (NDWI) (žr. 1 lentelę). Indeksai apskaičiuoti ir erdvinė statistika atlikta „QGIS“ programoje.

1 lentelė. Tyrimui naudojami indeksai. „Sentinel-2“ palydovo spektrinės juostos: B_{NIR} – Band 8, B_{Red} – Band 4, $B_{Red\ edge}$ – Band 5, B_{Green} – Band 3 ir B_{Blue} – Band 2.

Table 1. Indexes used for the study. "Sentinel-2" satellite spectral bands: B_{NIR} – Band 8, B_{Red} – Band 4, $B_{Red\ edge}$ – Band 5, B_{Green} – Band 3 ir B_{Blue} – Band 2.

Indeksas Index	Formulė Formula	Indeksas Index	Formulė Formula
NDVI (Normalized difference vegetation index)	$NDVI = \frac{(B_{NIR} - B_{Red})}{(B_{NIR} + B_{Red})}$	ReCI (Red-Edge Chlorophyll Vegetation Index)	$ReCI = \left(\frac{B_{NIR}}{B_{Red}}\right) - 1$
MSAVI (Modified soil-adjusted vegetation index)	$MSAVI = \frac{2B_{NIR} + 1 - \sqrt{(2B_{NIR} + 1)^2 - 8(B_{NIR} - B_{Red})}}{2}$	SIPI (Structure Intensive Pigment Vegetation Index)	$SIPI = \frac{(B_{NIR} - B_{Blue})}{(B_{NIR} - B_{Red})}$
NDRE (Normalized Difference Red Edge Index)	$NDRE = \frac{(B_{NIR} - B_{Red\ edge})}{(B_{NIR} + B_{Red\ edge})}$	GCI (Green Chlorophyll Index)	$GCI = \frac{B_{NIR}}{B_{Green}} - 1$
NDWI (Normalized difference water index)	$NDWI = \frac{B_{Green} - B_{NIR}}{B_{Green} + B_{NIR}}$	OSAVI (Optimized Soil Adjusted Vegetation Index)	$OSAVI = \frac{(B_{NIR} - B_{Red})}{(B_{NIR} + B_{Red} + 0.16)}$
VARI (Visible Atmospherically Resistant Index)	$VARI = \frac{(B_{Green} - B_{Red})}{(B_{Green} + B_{Red} - B_{Blue})}$	SAVI (Soil-adjusted vegetation index)	$SAVI = \frac{(B_{NIR} - B_{Red})}{(B_{NIR} + B_{Red} + L)} (1 + L)$


Statistiniai metodai – Statistinis duomenų vertinimas atliktas naudojantis „R“ programa. Indeksai buvo apskaičiuojami drono ir palydovo nuotraukoms. Naudojant „Fishnet“ funkciją, atrinktos vidutinės 10 x 10 m indekso reikšmės. Ryšiai tarp indeksų ir *in situ* dirvožemio drėgmės įvertinami skaičiuojant Pirsono (angl. Pearson) koreliacijos koeficientus. Stipriausius ryšius su drėgme turintys indeksai buvo atrinkti.

Atrinktų indeksų tikslumui nustatyti pritaikomas tiesinės regresijos metodas. Pagal gautas tiesinės regresijos lygtis buvo apskaičiuojamos drėgmės reikšmės iš indeksų, o patiteltus t-testus, priklausomoms duomenų imtims (angl. paired t-test) ir Vilkoksono ženklų kriterijų (angl. Wilcoxon signed-rank test), įvertinamas jų ryšio su *in situ* drėgme reikšmingumas. Palydovinių indeksų modeliuose išryškėjo klasteriams, įvertintas ir indeksų tikslumas nustatant drėgmę vešlių augalų stadijoje (birželio mėnesis). Indeksų patikimumas buvo įvertinamas apskaičiavus vidutinį kvadratinį nuokrypį RMSE (angl. Root Mean Square Error).

Tyrimų rezultatai

Drėgmės ir indeksų palyginimas – iš drono indeksų labiausiai su drėgme koreliavo NDWI ir GCI indeksai, atitinkamai: $r = -0,54$ ir $0,55$ ($p < 0,05$). Iš palydovinių indeksų stipriausios koreliacijos su drėgme taip pat su NDWI ($r = -0,61$, $p < 0,05$) ir GCI ($r = 0,60$, $p < 0,05$).


Nuotolinių metodų tikslumo įvertinimas – sudarius drėgmės modelius pagal NDWI, gauti $R^2 = 0,35$ (drono) ir $R^2 = 0,40$ (palydovo) (žr. 3 pav.). Abiejuose modeliuose išryškėjo tendencijos kritimas. Modeliai statistiškai reikšmingi: $F = 23,97$, $df = 1$ ir 45 , $p < 0,05$ (drono NDWI) ir $F = 30,09$, $df = 1$ ir 45 , $p < 0,05$ (palydovo NDWI). Drėgmė iš drono apskaičiuojama pagal $y = -21,58x + 7,50$ formulę, o palydovo – pagal $y = -26,36x + 0,47$.



3 pav. Linijinės regresijos modeliai drėgmei iš NDWI_DR ir NDWI_PA indeksų.

Fig 3. Linear regression models for moisture from the NDWI_DR and NDWI_PA indices.

Sudarius linijinės regresijos modelius GCI, gauti $R^2 = 0,30$ (drono) ir $0,36$ (palydovo) (žr. 4 pav.). Abiejuose modeliuose išryškėjo tendencijos kilimas. Modeliai statistškai reikšmingi: $F = 19,67$, $df = 1$ ir 45 , $p < 0,05$ (drono GCI) ir $F = 24,94$, $df = 1$ ir 45 , $p < 0,05$ (palydovo GCI). Drėgmė iš drono apskaičiuojama pagal $y = 10,25x + 7,21$, palydovo $-y = 5,76x + 2,50$.



4 pav. Linijinės regresijos modeliai drėgmei iš GCI_DR ir GCI_PA indeksų.
Fig 4. Linear regression models for moisture from the GCI_DR and GCI_PA indices.

Atlikus modelių validacijas, NDWI_DR ir NDWI_PA modeliams gauti $R^2 = 0,16$ ir $0,06$ atitinkamai. Palyginus skirtumą tarp tiesioginių matavimų ir nuotolinių drėgmės reikšmių paaiškėjo, kad tarp NDWI_DR ir *in situ* matavimų reikšmingo skirtumo nėra ($t = -0,56$, $df = 58$, $p > 0,05$). Tarp NDWI_PA ir *in situ* matavimų reikšmingo skirtumo taip pat nebuvo nustatyta ($V = 771$, $n = 58$, $p > 0,05$). NDWI_DR ir NDWI_PA modeliai patikimai įvertina dirvožemio drėgmę, RMSE atitinkamai $0,50\%$ ir $0,61\%$.

Iš validacijos GCI_DR modeliui gautas $R^2 = 0,31$, o GCI_PA modeliui $R^2 = 0,41$. GCI indekso RMSE iš drono ir palydovo duomenų yra $0,83\%$ ir $0,22\%$ atitinkamai. Tarp drėgmės reikšmių iš indekso ir *in situ* matavimų nebuvo nustatyta reikšmingo skirtumo: GCI_DR ir *in situ* ($t = -0,56$, $df = 58$, $p > 0,05$), GCI_PA ir *in situ* ($V = 951$, $n = 58$, $p > 0,05$).

Sudarius daugianarius modelius palydovinių duomenų klasteriams su vešlia augalija, gautas $R^2 = 0,61$ NDWI ir $0,88$ GCI indeksui. Vidutinis nuokrypis nuo drėgmės – $1,10\%$ ir $0,60\%$ atitinkamai. Drėgmė su NDWI vešlios augalijos sąlygomis apskaičiuojama pagal formulę: $y = 932,57x^2 + 696,17x + 139,4$. Su GCI – pagal: $y = 21,86x^2 - 48,50x + 35,57$. Tarp NDWI ir tiesioginių matavimų nėra reikšmingo skirtumo ($V = 46$, $n = 14$, $p > 0,05$), taip pat ir su GCI ($V = 43$, $n = 14$, $p > 0,05$).

Tyrimų rezultatų aptarimas

Šio tyrimo rezultatai parodė, kad ryšiams tarp indeksų ir tiesioginių drėgmės matavimų įtaką gali daryti žemės dangos nevienalytiškumas. Tailande atliktame tyrime palygintos NDWI indekso reikšmės iš palydovo su kelių skirtingų sensorių išmatuota drėgme, apskaičiavus visų sensorių kombinacijų R^2 , gautas rezultatas, panašus į šio tyrimo, kuriame buvo taikomas tik vienas tiesioginis metodas, rezultatus (Tibkaew ir kt., 2022). Tailando mokslininkų teiginys, kad NDWI indeksas gali būti pritaikytas drėgmės įvertinimui laukuose su skurdžia augalija (kur $NDVI \leq 0,3$) šiame tyrime buvo patvirtintas. Mokslininkai, atlikę panašų tyrimą Kolumbijoje, taip pat gavo rezultatą, kad dirvoje be augalijos dangos geriausiai dirvožemio drėgmės rezultatus atitinkantys indeksai dronui ir palydovui buvo NDWI ir NDVI (Casamitjana ir kt., 2020). Be minėtų indeksų šiame tyrime nustatyta, kad efektyviam drėgmės nustatymui gali būti naudojamas ir GCI indeksas, o atlikus validaciją paaiškėjo, kad jis net pranašesnis už NDWI. Tai galėjo lemti indekso atsparumas aerozolinei atmosferos taršai ir dirvožemio dangos poveikiui (Kurbanov, Zakharova, 2020). Siekiant detaliau įvertinti GCI tikslumą rekomenduotina atlikti papildomus detalius tyrimus. Sudarius tiesinės regresijos modelį drėgmei iš palydovo GCI ir NDWI pastebėta, kad modeliuose išryškėjo du duomenų klasteriai. Visos klasteriuose, esančios reikšmės sutapo su vešlia augalija. Sudarius modelius šiems klasteriams, pastebėtas didelis indeksų tikslumas, todėl siekiant geresnio indeksų pritaikomumo, galima šią metodiką taikyti vešlios augalijos stadijoje. Pagal Babaciaian ir kt. (2019), lyginant tiesioginių ir nuotolinių metodų nustatytą drėgmę reikėtų nepamiršti, kad *in situ* metodai įvertina tik absoliučias drėgmės reikšmes, o nuotoliniai metodai geba nusakyti ir augalams prieinamo vandens kiekį.

Teoriškai, kuo didesnės NDWI reikšmės, tuo teritorija pasižymi didesniu drėgnumu (Gao, 1996). Sudarius NDWI_DR ir NDWI_PA modelius, darbe išryškėjo tendencijos kritimas, rodantis priešingą ryšį. Prie to galėjo prisidėti NDWI taikymas sausumoje, o ne kaip įprasta identifikuoti vandens telkinius. Augalija reaguoja į NIR (artimoji infraraudonoji spinduliuotė) juosta kitaip negu vanduo, o žalios spalvos juosta sausumoje prasiskverbia mažiau negu vandenyje. NIR juosta sausumoje taip pat duoda didelį atspindį (Kilpys ir kt., 2021). Pavyzdžiui, (Hassanpour ir kt., 2020) tyrime buvo nustatinėjama dirvožemio drėgmė ir pastebėta, kad teritorijose su skurdžia augalija dirvožemis yra stipriai veikiamas saulės spinduliuotės, todėl gali būti paveikti NIR ir raudonos juostos atspindžiai. NIR atspindžiams sausumoje įtakos turi vidinė lapų struktūra ir lapų sausųjų medžiagų kiekis, bet ne vandens kiekis (Sow ir kt., 2013). Vadinas, rezultatą galėjo nulemti *in situ* tyrimų tikslumas ir skirtingos vegetacinės sąlygos. Dėl netolygios vegetacinės dangos

indeksui galėjo būti sunkiau įvertinti sveiką ir skurdžią augaliją tais mėnesiais, kai augalija buvo skurdi arba jos visai nebuvo, ir tai sumažino tikslumą.

Išvados

1. Su dirvožemio drėgme visu tiriamu laikotarpiu geriausiai koreliavo palydovo ir drono NDWI ir GCI indeksai.
 2. Palydovo ir drono NDWI indeksų tikslumas nustatant drėgmę atitinkamai siekia 40 % ir 35 %. GCI indekso tikslumas – 30 % ir 36 %. Vidutinis drėgmės nuokrypis naudojant NDWI indeksą neviršija 0,61 %, GCI – 0,83 %.
- Palydovo NDWI ir GCI indeksų tikslumas esant vešliai augalijos dangai – 61 % ir 88 %, o vidutinis nuokrypis nuo drėgmės siekia iki 1,10 %.

Literatūra

1. 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*, Vol. 57(2), p.530–616. <https://doi.org/10.1029/2018rg000618>.
2. Casamitjana M., Torres-Madroño M. C., Bernal-Riobo J., Varga D. 2020. Soil Moisture Analysis by Means of Multispectral Images According to Land Use and Spatial Resolution on Andosols in the Colombian Andes. *Applied Sciences*, Vol. 10(16), p. 5540. <https://doi.org/10.3390/app10165540>.
3. Gao B. 1996. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, Vol. 58(3), p. 257–266. [https://doi.org/10.1016/s0034-4257\(96\)00067-3](https://doi.org/10.1016/s0034-4257(96)00067-3).
4. Halla A., Narra N., Lipping T. 2020. New Developments and Environmental Applications of Drones/Role of Drones in Characterizing Soil Water Content in Open Field Cultivation. *New Developments and Environmental Applications of Drones*, p. 121–137. https://doi.org/10.1007/978-3-030-77860-6_7.
5. Hassanpour R., Zarehaghi D., Neyshabouri M. R., Feizizadeh B., Rahmati M. 2020. Modification on optical trapezoid model for accurate estimation of soil moisture content in a maize growing field. *Journal of Applied Remote Sensing*, Vol. 14(03). <https://doi.org/10.1117/1.jrs.14.034519>.
6. Kilpys J., Jukna L., Stonevičius E., Šimanauskienė R., Bevainis L. 2021. Žemės stebėjimas iš kosmoso. <https://doi.org/10.15388/vup-book-0007>.
7. Kopittke P. M., Menzies N. W., Wang P., McKenna B. A., Lombi E. 2019. Soil and the intensification of agriculture for global food security. *Environment International*, Vol. 132, p. 105078. <https://doi.org/10.1016/j.envint.2019.105078>.
8. Kurbanov R. K., Zakharova N. I. 2020. Application of Vegetation Indexes to Assess the Condition of Crops. *Agricultural Machinery and Technologies*, Vol. 14(4), p.4–11. <https://doi.org/10.22314/2073-7599-2020-14-4-4-11>.
9. Mu T., Liu G., Yang X., Yu Y. 2022. Soil-Moisture estimation based on Multiple-Source Remote-Sensing images. *Remote Sensing*, Vol. 15(1), p. 139. <https://doi.org/10.3390/rs15010139>.
10. Petropoulos G. P., Griffiths H. M., Dorigo W., Xaver A., Gruber A. 2013. Surface soil moisture estimation: Significance, controls and conventional measurement techniques. In G. P. Petropoulos (Ed.), *Remote sensing of energy fluxes and soil moisture content* (Chapter 2, p. 29–48. Taylor and Francis.
11. Rahimzadeh-Bajgiran P., Berg A. A., Champagne C., Omasa K. 2013. Estimation of soil moisture using optical/thermal infrared remote sensing in the Canadian Prairies. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 83, p.94–103. <https://doi.org/10.1016/j.isprsjprs.2013.06.004>.
12. Sow M. L., Mbow C., Hély C., Fensholt R., Sambou B. 2013. Estimation of Herbaceous Fuel Moisture Content Using Vegetation Indices and Land Surface Temperature from MODIS Data. *Remote Sensing*, Vol. 5(6), p. 2617–2638. <https://doi.org/10.3390/rs5062617>.
13. Tibkaew P., Miyai A., Buakhao J., Phonekeo W. 2022. Soil Moisture Sensor Measurement and Vegetation-Soil-Water Related Indices – A Case Study in Mango Plantation, Nakhorn Ratchasima Province, Thailand. *International Journal of Geoinformatics*, Vol. 18(2). <https://doi.org/10.52939/ijg.v18i2.2155>.
14. Zhang Q., Wang J., Zhao L., Wu F., Zhang Z., Torbert, A. H. 2015. Spatial heterogeneity of surface roughness during different erosive stages of tilled loess slopes under a rainfall intensity of 1.5mmmin⁻¹. *Soil and Tillage Research*, Vol. 153, p.95–103. <https://doi.org/10.1016/j.still.2015.05.011>.
15. Zhang X., Yang C., Wang L. 2018. Research and application of a new soil moisture sensor. *MATEC Web of Conferences*, p. 175, 02010. <https://doi.org/10.1051/mateconf/201817502010>.

APPLICATION OF VEGETATION AND NDWI INDICES IN REMOTE SENSING OF SOIL MOISTURE

Summary

Soil moisture is one of the most important factors affecting plant growth and yield (Zhang ir kt., 2018). However, cheaper and more convenient methods that can replace conventional direct moisture measurements are still being sought. This paper examines the accuracy of the application of optical sensors for soil moisture determination based on indices evaluating plant physiology and water content. The research is carried out by applying the "DJI Inspire 2" drone, the "Sentinel-2" satellite, and the gravimetric method of soil moisture determination. The accuracy of the indices is evaluated

by constructing linear regression models for the indices most correlated with soil moisture. The reliability of the indices is also determined, which is done by evaluating the significance of the difference between the moisture values obtained by these indices and the *in situ* moisture and calculating the RMSE.

The results of the study show that soil moisture is best estimated from the NDWI and GCI indices. NDWI accuracy was 35% from drone data and 40% from satellite data. The accuracy of the GCI for determining soil moisture was 30% for drone and 36% for satellite data. No significant difference was found between moisture values from these indices and *in situ* measurements. The average deviations of indices from direct measurements ranged from 0.22% to 0.83%. In the conditions of lush vegetation, a higher accuracy of the satellite indices was found: 61% (NDWI) and 88% (GCI), suggesting an opportunity to improve the methodology in the conditions of mature vegetation. Average deviations from soil moisture did not exceed 1.10%.

Keywords: soil moisture, drone, multispectral camera, "Sentinel-2" satellite, MSI sensor, accuracy, indices, vegetation.