

Rice Paddies Mapping and Yield Estimating using Satellite Images and Remote Sensing Techniques (Case study: Kunduz province, Afghanistan)

Hamidreza Ghafarian Malmiri^{1✉}, Mohammad Arif Saberi², Gholamali Mozafari³, Fahime Arabi Aliabad⁴

1. Associate Professor of Geography, University of Yazd, Yazd, Iran
✉ E-mail: hrghafarian@yazd.ac.ir
2. M. Sc of Remote Sensing and GIS, Department of Geography, University of Yazd, Yazd, Iran
E-mail: arifsadid94@gmail.com
3. Professor of Geography, University of Yazd, Yazd, Iran
E-mail: gmozafari@yazd.ac.ir
4. Ph.D of Management of Dry and Desert Areas, University of Yazd, Yazd, Iran
E-mail: Fahimearabi1993@gmail.com



Ghafarian Malmiri, H. R; Saberi, M. A; Mozafari, Gh. A; & Arabi Aliabad, F. (2024). Rice Paddies Mapping and Yield Estimating using Satellite Images and Remote Sensing Techniques (Case study: Kunduz province, Afghanistan) *Geography and Development*, 22 (74),187-218.

DOI: <http://dx.doi.org/10.22111/GDIJ.2024.8177>

Received:

30 April 2023

Received in revised form:

30 November 2023

Accepted:

29 December 2023

Published online:

20 January 2024

ABSTRACT

Investigating the area under cultivation and yield estimation of agricultural products like rice; can greatly ensure food security, analyze the status of agricultural products and, finally, sustainable development of developing countries. This study used Sentinel-2 satellite images, to estimate the area under cultivation and the yield of rice paddies in Kunduz province, Afghanistan in the 2020 crop year. Using the time series of NDVI index, the phenology stages of rice plants were obtained and the phenology parameters (SoS and EoS) were extracted using the maximum resolution method. Then, object-oriented classification method based on phenology was used to identify and determine the under-cultivated area of rice fields. In this method, three types of data of reflectivity of reflective bands, NDVI vegetation index and phenology parameters were used as auxiliary data. Yield estimation was done using the experimental method of regression analysis between remote sensing plant indices and the data obtained from ground harvesting. Also, the experimental method based on the regression analysis of ground data and distance measurement with the coefficient of determination of 0.86 and the Pearson correlation coefficient of 0.92 showed its high accuracy in estimating the yield of rice fields. The accuracy of the estimated performance in this research was evaluated by comparing the actual performance (field harvest data) in 27 control points. For this purpose, Pearson's correlation test was used. This test showed that there is a positive and very strong relationship between actual performance and estimated performance ($P=0.000$, $N=27$ and $R^2=0.929$).

Keywords:

Sentinel 2,
Object-Based
Classification,
Phenology,
Regression Analysis
Vegetation Indices.



© the Author(s).

Publisher: University of Sistan and Baluchestan

Extended Abstract

1. Introduction

This study explores the significance of rice as a staple grain globally, demonstrating its crucial role in improving food security for communities. Global consumption statistics for 2022 highlight the pivotal role of rice among consumable grains, emphasizing

the need to increase its production. Despite rice cultivation in some regions of Afghanistan, the country still faces shortages of this vital crop, as discussed in the Afghan rice production crisis. Traditional ground-based performance assessment methods are time-consuming, expensive, and often

lack comprehensive coverage. To address these challenges, this study employs satellite data as a rapid and cost-effective solution to assess rice cultivation status and estimate crop yield. Moreover, the research underscores the importance of rice phenological and physiological features in satellite-based investigations, showing their effectiveness as indicators for identifying and evaluating rice fields.

2. Methods and Material

The study utilizes Sentinel-2 and Google Earth satellite data to assess rice field performance, complemented by ground truth data for final accuracy evaluation. In the initial phase, time series of Normalized Difference Vegetation Index (NDVI) are computed. NDVI is calculated for each image during the rice growth period (from June to October) and presented as a multi-temporal layer. The NDVI temporal changes graph serves as an indicator of rice phenology. The rising phase of the NDVI graph signifies the beginning of the growth season, the peak represents the growth climax, and the descending phase indicates the end of the growth period. Subsequently, object-based classification is employed to identify rice fields.

3. Results and Discussion

Based on the rice cultivation schedule in Kandahar province, rice cultivation begins after wheat harvest, starting in May and reaching its maximum growth in June, with harvesting taking place in October. The NDVI time series from June to October 2020 reveals an ascending trend starting in June, peaking in August and partially in July and September, indicating the growth climax of rice. Afterwards, the graphs exhibit a descending trend, approaching the lowest point in October, indicating the time of rice field harvesting. Using a Phenology-based Object Classification method, rice fields in

Kunduz province are identified, resulting in three classes: "Rice fields," "Other Vegetation excluding Rice," and "Non-vegetation cover." The final accuracy, with 91.5%, and the Kappa coefficient of 0.87, demonstrate high and acceptable classification precision. The relationship between ground-based yield measurements and remote sensing indices, including NDVI and LAI, is then established, achieving a correlation coefficient of 0.73.

4. Conclusion

This research employs novel remote sensing methods to estimate the rice cultivation area and performance in Kandahar province, Afghanistan, in 2020. Two different approaches (Phenology-based Object Classification and Empirical Regression based on ground and remote sensing data) are investigated and evaluated. The results indicate that the Phenology-based Object Classification method provides the best accuracy in identifying rice fields, with a final accuracy of 91.5% and a Kappa coefficient of 0.87. Additionally, the empirical method, based on ground data regression analysis and remote sensing, demonstrates high precision in estimating rice field performance. The study's findings are valuable for organizations involved in agricultural product planning and food demand in Afghanistan. While acknowledging limitations regarding future model use, it is recommended to repeat this study in subsequent years, comparing results with previous research to enhance predictive accuracy for future years. Furthermore, the utilization of estimated data on actual rice plant evapotranspiration during the growth season could serve as auxiliary data to improve the regression model. This approach could contribute to calculating water productivity, a crucial indicator for water resource management and planning.

Keywords: Sentinel 2, Object-oriented classification methods, Vegetation indices, Land cover.

5. References

- Arez, Gholam Jilani (1959). The climate of Afghanistan. Kabul: Kabul University.
<https://noo.rs/WX7JR>
- Najmi, Hamzeh (2019). Preparation of rice production rate map using radar remote sensing data. Khaje Nasirodin Tosi University. Faculty of Mapping Engineering. Master's thesis.
<https://ganj.irandoc.ac.ir/#/search?keywords=%D8%AD%D9%85%D8%B2%D9%87%20%D9%86%D8%AC%D9%85%DB%8C&basicscope=1>
- Ministry of Agriculture, Irrigation and Livestock (2018 A). Annual agricultural report of 2018.
<https://www.mail.gov.af/sites/default/files/2019-12/Rice%20Report%2007.pdf>

- Ministry of Agriculture, Irrigation and Livestock (2018b). Report on rice production in 2018. <https://www.mail.gov.af/sites/default/files/2020-08/Agricultural%20Annual%20Report%2098.pdf>
- Ali, A. M., Savin, I., Poddubskiy, A., Abouelghar, M., Saleh, N., Abutaleb, K., ... & Dokukin, P (2021). Integrated method for rice cultivation monitoring using Sentinel-2 data and Leaf Area Index. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3), 431-441. <https://www.sciencedirect.com/science/article/pii/S1110982320301666>
- Arham, N. A (2020). Object based image analysis of support vector machine and rule based image classification for building extraction (Doctoral dissertation, Universiti Teknologi MARA, Shah Alam). <https://ir.uitm.edu.my/id/eprint/34565/1/34565.pdf>
- Aschbacher, J., Pongsrihadulchai, A., Karnchanasutham, S., Rodprom, C., Paudyal, D. R., & Le Toan, T (1995, July). Assessment of ERS-1 SAR data for rice crop mapping and monitoring. In 1995 International Geoscience and Remote Sensing Symposium, IGARSS'95. Quantitative Remote Sensing for Science and Applications (Vol. 3, 2183-2185). IEEE. <https://ieeexplore.ieee.org/document/524142?arnumber=524142>
- Baatz, M., & Schäpe, A (2000). Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. *Proceedings of Angewandte Geographische Informationsverarbeitung XII*, 12-23. <https://www.semanticscholar.org/paper/Multiresolution-Segmentation-%3A-an-optimization-for-Baatz-Sch%C3%A4pe/364cc1ff514a2e11d21a101dc072575e5487d17e>
- Bach, H (1998). Yield estimation of corn based on multitemporal LANDSAT-TM data as input for an agrometeorological model. *Pure and Applied Optics: Journal of the European Optical Society Part A*, 7(4), 809. <https://iopscience.iop.org/article/10.1088/0963-9659/7/4/017>
- Baidar, T (2020). Rice crop classification and yield estimation using multi-temporal sentinel-2 data: a case study of terai districts of Nepal. *Universitat Jaume*. 1–79. <https://repositori.uji.es/xmlui/handle/10234/187006?locale-attribute=en>
- Benz, U., & Schreier, G (2001). Definiens Imaging GmbH: Object oriented classification and feature detection. *IEEE Geoscience and Remote Sensing Society Newsletter*, 9, 16-20.
- Blaschke, T (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 65(1), 2-16. <https://www.sciencedirect.com/science/article/pii/S0924271609000884>
- Blaschke, T., & Strobl, J (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *Zeitschrift für Geoinformationssysteme*, 12-17. <https://www.semanticscholar.org/paper/What%E2%80%99s-wrong-with-pixels-Some-recent-developments-Blaschke-Strobl/51b65077ce150e717f21ee8ce1d96e4790d5779c>
- Boegh, E., Soegaard, H., Broge, N., Hasager, C. B., Jensen, N. O., Schelde, K., & Thomsen, A (2002). Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture. *Remote sensing of Environment*, 81(2-3), 179-193. <https://www.sciencedirect.com/science/article/abs/pii/S003442570100342X?via%3Dihub>
- Boori, M. S., Choudhary, K., Paringer, R., Sharma, A. K., Kupriyanov, A., & Corgne, S (2019, September). Monitoring crop phenology using NDVI time series from Sentinel 2 satellite data. In 2019 5th International Conference on Frontiers of Signal Processing (ICFSP) (62-66). IEEE. <https://ieeexplore.ieee.org/document/8938078>
- Cai, Y., Lin, H., & Zhang, M (2019). Mapping paddy rice by the object-based random forest method using time series Sentinel-1/Sentinel-2 data. *Advances in Space Research*, 64(11), 2233–2244. <https://www.sciencedirect.com/science/article/abs/pii/S0273117719306258>
- Chen, C., & McNairn, H (2006). A neural network integrated approach for rice crop monitoring. *International Journal of Remote Sensing*, 27(7), 1367-1393. <https://www.tandfonline.com/doi/full/10.1080/01431160500421507>
- Chen, N., Yu, L., Zhang, X., Shen, Y., Zeng, L., Hu, Q., & Niyogi, D (2020). Mapping paddy rice fields by combining multi-temporal vegetation index and synthetic aperture radar remote sensing data using Google Earth Engine machine learning platform. *Remote Sensing*, 12(18). <https://www.mdpi.com/2072-4292/12/18/2992>

- Deering, D. W (1975). Measuring " forage production" of grazing units from Landsat MSS data. In Proceedings of the Tenth International Symposium of Remote Sensing of the Environment (1169-1198).
- dela Torre, D. M. G., Gao, J., Macinnis-Ng, C., & Shi, Y. (2021). Phenology-based delineation of irrigated and rain-fed paddy fields with Sentinel-2 imagery in Google Earth Engine. *Geo-spatial Information Science*, 24(4), 695-710. [10.1080/10095020.2021.1984183](https://doi.org/10.1080/10095020.2021.1984183)
- Desclée, B., Bogaert, P., & Defourny, P (2006). Forest change detection by statistical object-based method. *Remote Sensing of Environment*, 102(1-2), 1-11. <https://www.sciencedirect.com/science/article/abs/pii/S0034425706000344>
- Dong, J., & Xiao, X (2016). Evolution of regional to global paddy rice mapping methods: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 119, 214-227. <https://www.sciencedirect.com/science/article/abs/pii/S0924271616300995>
- Dong, J., Xiao, X., Kou, W., Qin, Y., Zhang, G., Li, L., Jin, C., Zhou, Y., Wang, J., Biradar, C., Liu, J., & Moore, B (2015). Tracking the dynamics of paddy rice planting area in 1986-2010 through time series Landsat images and phenology-based algorithms. *Remote Sensing of Environment*, 160, 99-113. <https://www.sciencedirect.com/science/article/abs/pii/S0034425715000139>
- FAO (2017) Afghanistan: Monitoring of Rice Crop using Satellite Remote Sensing and GIS Technologies. FAO Publication: Rome. <https://www.fao.org/geospatial/resources/detail/zh/c/1024575/>
- FAO (2022) Crop Prospects and Food Situation-Quarterly Global Report No. 2, July 2022. Rome. <https://www.fao.org/documents/card/en/c/cc0868en/>
- Frohn, R. C., & Hao, Y (2006). Landscape metric performance in analyzing two decades of deforestation in the Amazon Basin of Rondonia, Brazil. *Remote sensing of Environment*, 100(2), 237-251. <https://www.sciencedirect.com/science/article/abs/pii/S0034425705003573>
- Guan, K., Li, Z., Rao, L. N., Gao, F., Xie, D., Hien, N. T., & Zeng, Z (2018). Mapping paddy rice area and yields over Thai Binh Province in Viet Nam from MODIS, Landsat, and ALOS-2/PALSAR-2. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(7), 2238-2252. <https://ieeexplore.ieee.org/document/8375090>
- Huete, A. R., Liu, H. Q., Batchily, K. V., & Van Leeuwen, W. J. D. A (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote sensing of environment*, 59(3), 440-451. <https://www.sciencedirect.com/science/article/abs/pii/S0034425796001125>
- Lestari, E. A. P., Supriatna, & Damayanti, A (2020). Model of paddy rice phenology using Sentinel 2-A imagery with NDVI algorithm in Subang Regency. *IOP Conference Series: Earth and Environmental Science*, 481(1). <https://iopscience.iop.org/article/10.1088/1755-1315/481/1/012069>
- Maki, M., & Homma, K (2014). Empirical regression models for estimating multiyear leaf area index of rice from several vegetation indices at the field scale. *Remote Sensing*, 6(6), 4764-4779. <https://www.mdpi.com/2072-4292/6/6/4764>
- Menenti, M., Azzali, S., Verhoef, W., and van Swol, R (1993). Mapping agroecological zones and time lag in vegetation growth by means of fourier analysis of time series of NDVI images. *Adv. Space Res.* 13, 233-237. <https://www.sciencedirect.com/science/article/abs/pii/027311779390550U>
- Noureldin, N. A., Aboelghar, M. A., Saady, H. S., & Ali, A. M (2013). Rice yield forecasting models using satellite imagery in Egypt. *The Egyptian Journal of Remote Sensing and Space Science*, 16(1), 125-131. <https://www.sciencedirect.com/science/article/pii/S1110982313000094>
- Prasad, A.K.; Chai, L.; Singh, R.P.; Kafatos, M (2006). Crop yield estimation model for Iowa using remote sensing and surface parameters. *International Journal of Applied earth observation and geoinformation*, 8: 26-33. <https://www.sciencedirect.com/science/article/abs/pii/S0303243405000553>
- Prasetyo, Y., Sukmono, A., Aziz, K. W., & Aji, B. J. P. S (2018, June). Rice productivity prediction model design based on linear regression of spectral value using NDVI and LSWI combination on landsat-8 imagery. In *IOP Conference Series: Earth and Environmental Science* (Vol. 165, No. 1, 012002). IOP Publishing. <https://iopscience.iop.org/article/10.1088/1755-1315/165/1/012002>

- Pringle, M. J., Denham, R. J., & Devadas, R (2012). Identification of cropping activity in central and southern Queensland, Australia, with the aid of MODIS MOD13Q1 imagery. *International Journal of Applied Earth Observation and Geoinformation*, 19(1), 276-285.
<https://www.sciencedirect.com/science/article/abs/pii/S0303243412001250>
- Qian, Y., Zhou, W., Yan, J., Li, W., & Han, L (2014). Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery. *Remote Sensing*, 7(1), 153-168.
<https://www.mdpi.com/2072-4292/7/1/153>
- Qiu, B., Li, W., Tang, Z., Chen, C., & Qi, W (2015). Mapping paddy rice areas based on vegetation phenology and surface moisture conditions. *Ecological Indicators*, 56, 79–86.
<https://www.sciencedirect.com/science/article/abs/pii/S1470160X15001697>
- Raksapatcharawong, M., Veerakachen, W., Homma, K., Maki, M., & Oki, K (2020). Satellite-based drought impact assessment on rice yield in Thailand with SIMRIW– RS. *Remote Sensing*, 12(13), 2099.
<https://www.mdpi.com/2072-4292/12/13/2099>
- Rasmussen, M. S (1997). Operational yield forecast using AVHRR NDVI data: reduction of environmental and inter-annual variability. *International Journal of Remote Sensing*, 18(5), 1059-1077.
<https://www.tandfonline.com/doi/abs/10.1080/014311697218575>
- Raza, S. M. H., Mahmood, S. A., Gillani, S. A., Hassan, S. S., Aamir, M., Saifullah, M., ... & Ali, T (2019). Estimation of net rice production by remote sensing and multi source datasets. *Sarhad Journal of Agriculture*, 35(3), 955-965.
<https://researcherlinks.com/current-issues/Estimation-of-Net-Rice-Production-by-Remote-Sensing-and-Multi-Source-Datasets/14/1/2455>
- Sibaruddin, H. I., Shafri, H. Z. M., Pradhan, B., & Haron, N. A (2018, June). Comparison of pixel-based and object-based image classification techniques in extracting information from UAV imagery data. In *IOP conference series: earth and environmental science* (Vol. 169, No. 1, p. 012098). IOP Publishing.
<https://iopscience.iop.org/article/10.1088/1755-1315/169/1/012098>
- Singha, M., Wu, B., & Zhang, M (2016). Object-based paddy rice mapping using HJ-1A/B data and temporal features extracted from time series MODIS NDVI data. *Sensors*, 17(1), 10.
<https://www.mdpi.com/1424-8220/17/1/10>
- Sisheber, B., Marshall, M., Ayalew, D., & Nelson, A (2022). Tracking crop phenology in a highly dynamic landscape with knowledge-based Landsat–MODIS data fusion. *International Journal of Applied Earth Observation and Geoinformation*, 106, 102670.
<https://www.sciencedirect.com/science/article/pii/S0303243421003779>
- Son, N. T., Chen, C. F., Chen, C. R., Guo, H. Y., Cheng, Y. S., Chen, S. L., ... & Chen, S. H (2020). Machine learning approaches for rice crop yield predictions using time-series satellite data in Taiwan. *International Journal of Remote Sensing*, 41(20), 7868-7888.
<https://www.tandfonline.com/doi/abs/10.1080/01431161.2020.1766148>
- Son, N. T., Chen, C. F., Chen, C. R., Toscano, P., Cheng, Y. S., Guo, H. Y., & Syu, C. H (2021). A phenological object-based approach for rice crop classification using time-series Sentinel-1 Synthetic Aperture Radar (SAR) data in Taiwan. *International Journal of Remote Sensing*, 42(7), 2722-2739.
<https://www.tandfonline.com/doi/abs/10.1080/01431161.2020.1862440>
- Su, T (2017). Efficient paddy field mapping using Landsat-8 imagery and object-based image analysis based on advanced fractal net evolution approach. *GIScience & Remote Sensing*, 54(3), 354-380.
<https://www.tandfonline.com/doi/full/10.1080/15481603.2016.1273438>
- Teluguntla, P., Ryu, D., George, B., Walker, J. P., & Malano, H. M (2015). Mapping flooded rice paddies using time series of MODIS imagery in the Krishna River Basin, India. *Remote Sensing*, 7(7), 8858–8882.
<https://www.mdpi.com/2072-4292/7/7/8858>
- Trimble (2014). *eCognition Developer 9.0. 1 Reference Book*.
<https://ecognition-developer.software.informer.com/9.0/>
- Tzotso, A (2006). A support vector machine approach for object based image analysis. *Proceedings of OBIA*.
<https://www.academia.edu/3098178/>

- Wiegand, C. L., Richardson, A. J., Escobar, D. E., & Gerbermann, A. H (1991). Vegetation indices in crop assessments. *Remote sensing of Environment*, 35(2-3), 105-119.
<https://www.sciencedirect.com/science/article/abs/pii/003442579190004P>
- Xiao, W., Xu, S., & He, T (2021). Mapping paddy rice with sentinel-1/2 and phenology-, object-based algorithm-A implementation in Hangjiahu plain in China using gee platform. *Remote Sensing*, 13(5), 990.
<https://www.mdpi.com/2072-4292/13/5/990>
- Xiao, X., Boles, S., Froking, S., Salas, W., Moore, I., Li, C., He, L., & Zhao, R (2002). Observation of flooding and rice transplanting of paddy rice fields at the site to landscape scales in China using VEGETATION sensor data. *International Journal of Remote Sensing*, 23(15), 3009-3022.
<https://www.tandfonline.com/doi/abs/10.1080/01431160110107734>
- Xiao, Xiangming, Boles, S., Froking, S., Li, C., Babu, J. Y., Salas, W., & Moore, B (2006). Mapping paddy rice agriculture in South and Southeast Asia using multi-temporal MODIS images. *Remote Sensing of Environment*, 100(1), 95-113.
<https://www.tandfonline.com/doi/citedby/10.1080/01431160110107734?scroll=top&needAccess=true>
- Xiao, Xiangming, Boles, S., Liu, J., Zhuang, D., Froking, S., Li, C., Salas, W., & Moore, B (2005). Mapping paddy rice agriculture in southern China using multi-temporal MODIS images. *Remote Sensing of Environment*, 95(4), 480-492.
<https://www.sciencedirect.com/science/article/abs/pii/S0034425705000209>
- Yan, L., & Roy, D. P (2015). Improved time series land cover classification by missing-observation-adaptive nonlinear dimensionality reduction. *Remote Sensing of Environment*, 158, 478-491.
<https://www.sciencedirect.com/science/article/pii/S0034425714004763>
- Yang, S., Shen, S., Li, B., Le Toan, T., & He, W (2008). Rice mapping and monitoring using ENVISAT ASAR data. *IEEE Geoscience and Remote Sensing Letters*, 5(1), 108-112.
<https://ieeexplore.ieee.org/document/4432591>
- You, J., Li, X., Low, M., Lobell, D., & Ermon, S (2017). Deep Gaussian process for crop yield prediction based on remote sensing data. 31st AAAI Conference on Artificial Intelligence, AAAI 2017, 4559-4565.
<https://ojs.aaai.org/index.php/AAAI/article/view/11172>
- Zhang, G., Xiao, X., Dong, J., Kou, W., Jin, C., Qin, Y., Zhou, Y., Wang, J., Menarguez, M. A., & Biradar, C (2015). Mapping paddy rice planting areas through time series analysis of MODIS land surface temperature and vegetation index data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 106, 157-171.
<https://www.sciencedirect.com/science/article/abs/pii/S0924271615001483>
- Zhang, M., & Lin, H (2019). Object-based rice mapping using time-series and phenological data. *Advances in Space Research*, 63(1), 190-202.
<https://www.sciencedirect.com/science/article/abs/pii/S0273117718307142>
- Zhao, R., Li, Y., & Ma, M (2021). Mapping paddy rice with satellite remote sensing: a review. *Sustainability*, 13(2), 503.
<https://www.mdpi.com/2071-1050/13/2/503>



شناسایی و برآورد عملکرد مزارع برنج با استفاده از تصاویر ماهواره‌ای و تکنیک‌های


سنجش از دور (مطالعه موردی: استان کندز، افغانستان)

دکتر حمیدرضا غفاریان مالگیری^{۱*}، محمدعارف صابری^۲

غلامعلی مظفری^۳، فهیمه عربی علی‌آباد^۴

مقاله پژوهشی

جغرافیا و توسعه، شماره ۷۴، بهار ۱۴۰۳
تاریخ دریافت: ۱۴۰۲/۰۲/۱۰
تاریخ بازنگری: ۱۴۰۲/۰۹/۰۹
تاریخ پذیرش: ۱۴۰۲/۱۰/۰۸
صفحات: ۲۱۸-۱۸۷



واژه‌های کلیدی:

سنجش از دور، طبقه‌بندی شیء‌گرا، فنولوژی، تحلیل رگرسیون، شاخص‌های گیاهی.

چکیده

بررسی سطح زیر کشت و برآورد میزان تولید محصولات کشاورزی، از جمله برنج، تا حد زیادی می‌تواند باعث تأمین امنیت غذایی، تحلیل وضعیت محصولات کشاورزی و در نتیجه توسعه پایدار کشورهای در حال توسعه شود. در این پژوهش، با استفاده از تصاویر ماهواره سنجنیل-۲، به برآورد سطح زیر کشت و عملکرد برنج در استان کندز، کشور افغانستان در سال زراعی ۲۰۲۰ پرداخته شد. با به‌کارگیری سری زمانی شاخص NDVI، مراحل فنولوژی گیاه برنج به‌دست آمد و پارامترهای فنولوژی (EoS و SoS) با استفاده از روش حداکثر تفکیک استخراج شد. سپس برای شناسایی و تعیین سطح زیر کشت مزارع برنج از روش طبقه‌بندی شیء‌گرای مبتنی بر فنولوژی استفاده شد. در این روش از سه نوع داده میزان بازتابش باندهای انعکاسی، شاخص پوشش گیاهی NDVI و پارامترهای فنولوژی به‌عنوان داده‌های کمکی استفاده شد. برآورد عملکرد با استفاده از روش تجربی تحلیل رگرسیون بین شاخص‌های گیاهی سنجش از دوری (مانند: NDVI و LAI) و داده‌های حاصل از برداشت زمینی انجام گرفت. برای ارزیابی صحت طبقه‌بندی و میزان عملکرد برآوردشده، از داده‌های مرجع، مانند نقاط برداشت میدانی و نقشه‌های پوشش اراضی سال‌های قبل استفاده شد. نتایج این تحقیق نشان داد که روش طبقه‌بندی شیء‌گرای مبتنی بر فنولوژی با دقت کلی ۹۱/۵ درصد و ضریب کاپا ۰/۸۷، روش دقیقی برای شناسایی مزارع برنج به‌شمار می‌رود. همچنان روش تجربی مبتنی بر تحلیل رگرسیون داده‌های زمینی و سنجش از دوری با ضریب تعیین ۰/۸۶ و ضریب همبستگی پیرسون برابر با ۰/۹۲ دقت بالای آن را در برآورد عملکرد مزارع برنج نشان داد. صحت عملکرد برآوردشده در این پژوهش با مقایسه عملکرد واقعی (داده‌های برداشت میدانی) در ۲۷ نقطه کنترلی ارزیابی شد. برای این کار از آزمون همبستگی پیرسون استفاده شد. این آزمون نشان داد بین عملکرد واقعی و عملکرد برآوردشده رابطه مثبت و بسیار قوی وجود دارد ($R^2=0/929$ و $N=27$ ، $P=0/000$).

مقدمه

بالایی برخوردار است. روش‌های سنتی برآورد سطح زیر کشت که براساس اندازه‌گیری‌های میدانی استوار است، موجب صرف زمان و هزینه زیاد می‌شود (You et al, 2017:2). استفاده از روش‌های سنجش از دوری، با کمترین نیاز به داده‌های زمینی، هزینه اندک و سرعت بالا برای برآورد سطح زیر کشت و میزان عملکرد محصولات کشاورزی از جمله برنج قابل اجرا است (Parasad et al, 2006: 1).

برنج یکی از غلات مهم و استراتژیک است که نقش عمده‌ای در تأمین امنیت غذایی مردم دارد (FAO, 2022: 3). با وجود کشت برنج در برخی از مناطق کشور افغانستان، همچنان مشکل کمبود برنج در این کشور وجود دارد (وزارت زراعت، آبیاری و مالداري، ۱۳۹۸/ف)؛ بنابراین برآورد سطح زیر کشت و تخمین عملکرد آن به‌منظور مدیریت و برنامه‌ریزی‌های غذایی از اهمیت

hrghafarian@yazd.ac.ir

arifsadid94@gmail.com

gmozafari@yazd.ac.ir

Fahimearabi1993@gmail.com

۱. دانشیار گروه جغرافیا، دانشگاه یزد، یزد، ایران (نویسنده مسئول)

۲. کارشناس ارشد سنجش از دور و GIS، گروه جغرافیا، دانشگاه یزد، یزد، ایران

۳. استاد گروه جغرافیا، دانشگاه یزد، یزد، ایران

۴. دکتری مدیریت مناطق خشک و بیابانی، دانشگاه یزد، یزد، ایران

مبتنی بر داده‌های راداری، از تصاویر راداری ماهواره‌های سنتینل-۱، اینویست^۶، رادارست^۷ و... استفاده شده است که اکثراً در مناطق با پوشش ابری فراوان تطبیق شده‌اند مانند (نجمی و همکاران، ۱۳۹۱: ۳۱) و (Yang et al, 2008: 5). همچنین در روش‌های مبتنی بر داده‌های ترکیبی رادار و اپتیک، برای جبران مشکل از دست رفتن داده‌های اپتیکی به دلیل موجودیت ابر و ناپیوستگی‌های زمانی-مکانی از تصاویر راداری استفاده شده است (Chen et al, 2020: 5; Cai et al, 2019: 7). در روش‌های مبتنی بر داده‌های اپتیکی نیز از تصاویر اپتیکی ماهواره‌های مختلف از جمله لندست، سنتینل-۲، مودیس و... به شیوه‌های گوناگون استفاده شده است که این روش نسبت به روش‌های دیگر بیشتر مورد استفاده بوده و نتایج بهتری را نیز به دست می‌دهد (Zhao et al, 2021: 2). در این رویکردها، از روش‌ها و الگوریتم‌های مختلف طبقه‌بندی شامل (یادگیری ماشین، تشابه سری زمانی، مبتنی بر ویژگی شاخص‌های گیاهی و تجزیه و تحلیل شیء‌گرا) برای شناسایی مزارع برنج استفاده شده است (Zhao et al, 2021: 2). در روش یادگیری ماشین از الگوریتم‌های مختلف طبقه‌بندی عادی و یادگیری عمیق برای طبقه‌بندی تصاویر استفاده می‌شود مانند (Baidar et al, 2020: 8). در روش‌های مبتنی بر تشابه سری زمانی، معمولاً ابتدا یک سری زمانی از تصاویر ماهواره‌ای در دوره رشد برنج تهیه می‌شود و با استفاده از روش‌هایی مانند تعیین حد آستانه بر روند تغییرات زمانی داده‌ها به شناسایی مزارع برنج پرداخته می‌شود مانند (Guan et al, 2018: 15). روش‌های مبتنی بر ویژگی شاخص‌های گیاهی با استخراج برخی از ویژگی‌های برنج به این شاخص‌ها به شناسایی مزارع برنج می‌پردازند.

به منظور بررسی وضعیت کشت برنج در جهان صورت گرفته است؛ برای مثال می‌توان به کاربرد تصاویر لندست^۱ (Yan & Roy: 2)، مودیس^۲ (Pringle et al, 2012: 4)، اسپات^۳ (Desclée et al, 2006: 3) و همچنین در این اواخر از ماهواره‌های سنتینل^۴ ۱ و ۲ (Lestari et al, 2020: 4; Chen et al, 2020: 3) برای بررسی و شناخت مزارع برنج و عملکرد آن اشاره کرد. همانند گیاهان دیگر، برنج نیز دارای ویژگی‌های منحصربه‌فردی است و نیاز به آب فراوان دارد و غرقاب کردن سطح مزرعه برای نشاءکاری الزامی است. روند رشد برنج (فنولوژی) در چهار مرحله نهال پروری، رشد رویشی، رشد زایشی و مرحله رسیدن تقسیم می‌شود (Dong & Xiao, 2016: 2). بنابراین در بسیاری از تحقیقات علاوه بر ویژگی‌های طیفی، از ویژگی فنولوژی آن نیز برای شناسایی استفاده شده که نتایج بهتری را نشان داده است (Dong & Xiao, 2016: 12; Zhao et al, 2021: 9; Wiegand et al, 1991: 11; Rasmussen et al, 1997: 7; Bach, 1998: 11).

استخراج سطح زیر کشت برنج در سال ۲۰۱۷ در سطح کشور افغانستان با استفاده از تصاویر ماهواره‌های لندست-۸، سنتینل-۱ و ۲، مودیس و... گزارش‌های سالانه وضعیت کشت و تولید برنج در سطح افغانستان با استفاده از تشابه سری زمانی شاخص NDVI^۵ حاصل از تصاویر سنتینل-۲ تهیه می‌شوند (وزارت زراعت، آبیاری و مالداري افغانستان، ۱۳۹۸ ب). در مطالعاتی که برای شناسایی و استخراج سطح زیر کشت برنج انجام شده است، از داده‌های مختلف راداری، اپتیکی و ترکیبی از رادار و اپتیک به شیوه‌های گوناگون استفاده شده است (Zhao et al, 2021: 2). در روش‌های

1 Landsat
2 MODIS
3 SPOT
4 Sentinel
5 Normalized Difference Vegetation Index

6 EnviSat
7 RADARSAT

مانند (Singha et al, 2016: 15; Zhang & Lin, 2019: 14; Sisheber et al, 2022: 18).

در رابطه با برآورد عملکرد برنج، روش‌های گوناگون سنجش‌ازدوری از جمله روش‌های تجربی، نیمه‌تجربی و فرایندمحور (مبتنی بر فرایند رشد برنج) ایجاد شده است (Dela Torre et al, 2021: 2). در روش‌های مبتنی بر فرایند رشد برنج، عملکرد برنج از طریق شبیه‌سازی متغیرهای وابسته به عملکرد مانند آب‌وهوا، خاک، آب، تنش و مدیریت کشاورزی، به‌دست می‌آید مانند (Raksapatcharawong et al, 2020: 11). روش‌های نیمه‌تجربی از هردو روش فرایندمحور و تجربی استفاده می‌کنند. روش‌های تجربی یا آماری با استفاده از تعیین رابطه بین متغیرهای سنجش‌ازدوری و برداشت‌های زمینی، عملکرد برنج را برآورد می‌کنند که در اکثر مناطق قابل تطبیق است. در این روش ابتدا تصاویر انعکاسی یا شاخص‌های تعیین‌کننده فیزیولوژی برنج مانند GVI^5 ، DVI^6 ، $IPVI^7$ ، RVI^8 ، $SAVI^9$ و $NDVI$ برای مزارع برنج تهیه می‌شود و سپس رابطه آن‌ها با داده‌های عملکرد برداشت زمینی از طریق روش‌های آماری مثل رگرسیون خطی سنجیده می‌شود. درنهایت با استفاده از رابطه به‌دست‌آمده عملکرد مزارع برنج برآورد می‌شود که در تحقیقات زیر از آن استفاده شده (Aschbacher et al, 1995: 7; Chen & Mcnairn, 2006: 4; Noureldin et al, 2013: 6; Raza et al, 2019: 15).

با توجه به مطالعات انجام‌شده، استفاده از فنولوژی و طبقه‌بندی شیء‌گرا برای شناسایی مزارع برنج و همچنین روش تجربی برای برآورد عملکرد مزارع در مناطق کمتر توسعه‌یافته، از اهمیت بالایی برخوردار است؛ از اینرو در این مطالعه با هدف شناسایی و

معروف‌ترین روش آن الگوریتم فنولوژی است که در پژوهش (Xiao et al, 2002: 9) براساس بیشتربودن موقت سیگنال شاخص آب سطحی $LSWI^1$ نسبت به شاخص‌های گیاهی ($NDVI$ یا EVI^2) در زمان غرقابی شالیزار، پایه‌گذاری شد. بعد از آن مطالعات زیادی بر پایه الگوریتم‌های فنولوژی انجام شده است که نتایج دقیقی را ارائه داده‌اند مانند (Xiao et al, 2005: 4; Dong et al, 2015: 15; Zhang et al, 2015: 7; Qiu et al 2015: 12; Teluguntla et al, 2015: 9; Chen et al, 2015: 7). روش‌های تحلیل شیء‌گرا با استفاده از داده‌های مختلف، مزارع برنج را با توجه به ویژگی‌های طیفی و مکانی آن شناسایی می‌کنند. این روش در سه مرحله (قطعه‌بندی و ایجاد شیء تصویر، تعیین نمونه‌های آموزشی از اشیا و طبقه‌بندی اشیا تصویر با الگوریتم‌های مختلف) اجرا می‌شود (Zhang & Lin, 2019: 4; Su, 2017: 2).

از میان روش‌های فوق، روش‌های مبتنی بر فنولوژی و روش تجزیه و تحلیل شیء‌گرا بیشتر برای شناسایی مزارع برنج استفاده شده‌اند و از دقت بالایی برخوردار هستند که در تحقیقات (Dong & Xiao, 2016: 16; Sibaruddin et al, 2018: 8; Zhao et al, 2021: 14) ثابت شده است. از اینرو تعداد زیادی از تحقیقات مانند (Xiao et al, 2021: 18; Son et al, 2021: 11) بر پایه فنولوژی برنج و تجزیه و تحلیل شیء‌گرا با شیوه‌های گوناگون انجام شده است. یکی از شیوه‌های استفاده از فنولوژی در شناسایی برنج، به‌کارگیری متغیرها یا پارامترهای فنولوژی، مانند شروع و پایان فصل رشد (SOS^3 و EOS^4) در کنار سری زمانی باندهای انعکاسی و شاخص‌های گیاهی مانند $NDVI$ است. در این رویکرد داده‌های اشاره‌شده با یکدیگر ادغام شده و به روش‌های پیکسل مبنا یا شیء‌گرا در طبقه‌بندی مزارع برنج کمک می‌کنند

5 Green Vegetation Index
6 Difference Vegetation Index
7 Infrared Percentage Vegetation Index
8 Ratio Vegetation Index
9 Soil Adjusted Vegetation Index

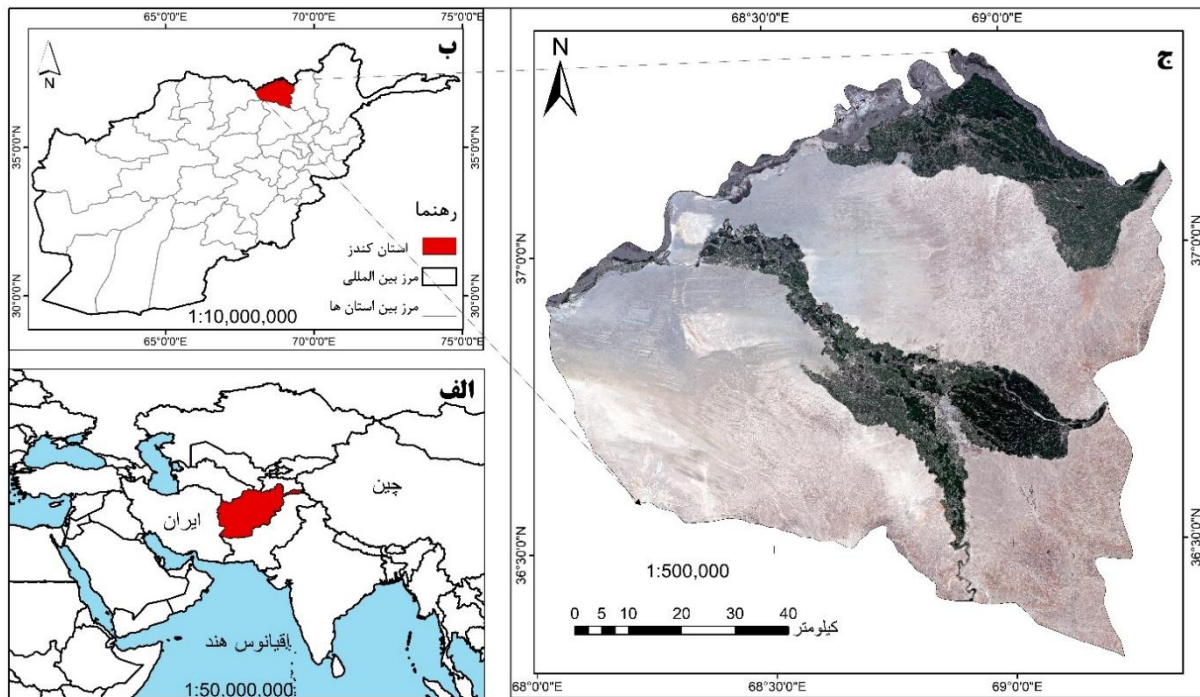
1 Land Surface Water Index
2 Enhanced Vegetation Index
3 Start Of Season
4 End Of Season

داده‌ها و روش‌شناسی

منطقه مورد مطالعه

منطقه مورد مطالعه در این تحقیق استان کندز است که در شمال کشور افغانستان واقع شده است. موقعیت جغرافیایی منطقه مورد مطالعه در بین طول ۶۸ درجه و ۲ دقیقه تا ۶۹ درجه و ۲۱ دقیقه شرقی و عرض ۳۶ درجه و ۱۸ دقیقه تا ۳۷ درجه و ۲۰ دقیقه شمالی است. مساحت منطقه ۸۰۴۰ کیلومتر مربع و ارتفاع متوسط آن ۴۳۰ متر از سطح دریا است. این منطقه دارای اقلیم استپی بوده و میزان بارندگی سالانه آن به‌طور میانگین بین ۲۵۰ تا ۳۰۰ میلی‌متر است.

تعیین سطح زیرکشت برنج، مقایسه روش‌های طبقه‌بندی شیء‌گرا و پیسکل مبنا در جهت طبقه‌بندی، استفاده از شاخص‌های پوشش گیاهی و پایش الگوی فنولوژی این گیاهان در جهت شناسایی بهتر این گیاه از روش طبقه‌بندی شیء‌گرا مبتنی بر فنولوژی استفاده شد. همچنان جهت برآورد عملکرد برنج از روش تجربی مبتنی بر تحلیل رگرسیون داده‌های زمینی و سنجش‌ازدوری استفاده شد. نتایج و داده‌های این تحقیق می‌تواند برای تصمیم‌گیران و مدیران وزارت کشاورزی افغانستان برای پیش‌بینی میزان عملکرد و کمبودهای احتمالی مورد استفاده قرار گیرد.



شکل ۱: الف: موقعیت جغرافیایی کشور افغانستان در منطقه جنوب آسیا. ب: استان‌های افغانستان و استان کندز
ج: تصویر RGB حاصل از ماهواره سنتینل-۲ از منطقه مورد مطالعه (استان کندز)

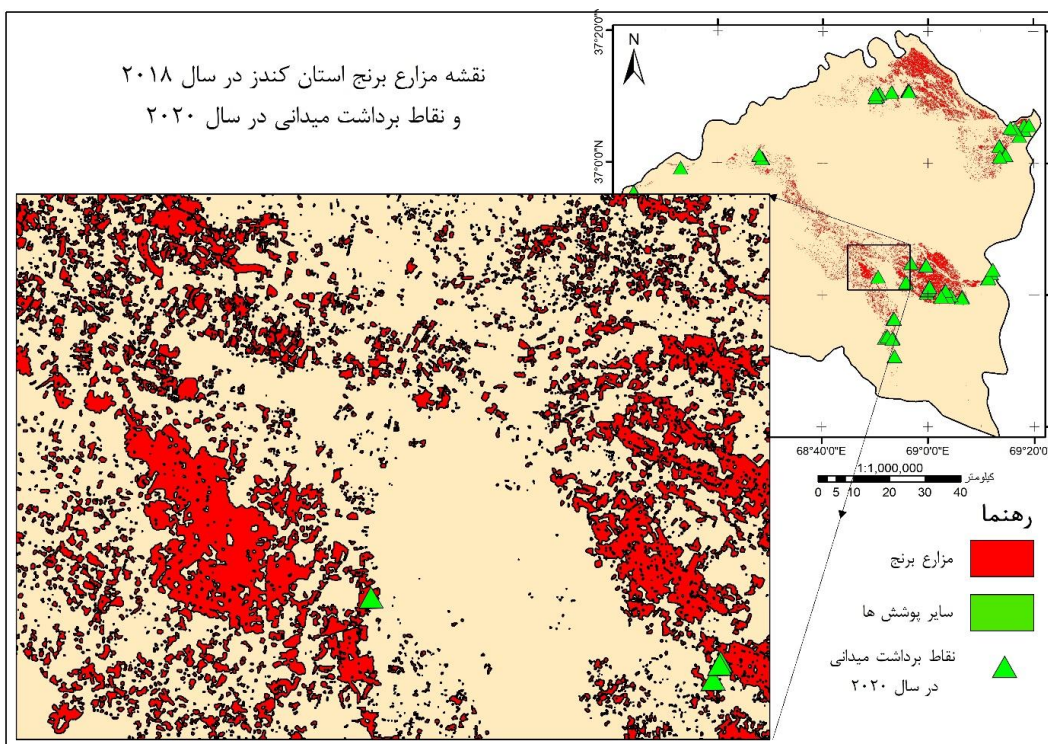
تهیه و ترسیم: نگارندگان، ۱۴۰۲

جدول ۱: داده‌های مورد استفاده به‌عنوان مرجع.

نوع داده	توضیحات	موارد استفاده
نقاط برداشت میدانی	۷۱ نقطه که در اکتبر ۲۰۲۰ از مزارع برنج استان کندز برداشت شده است (اداره احصائیه و معلومات، ۲۰۲۰).	تعیین نقاط آموزشی و کنترلی به‌عنوان مزارع برنج برای طبقه‌بندی
نقشه‌های مزارع برنج	نقشه مزارع برنج سال ۲۰۱۸ که توسط سازمان فائو ترسیم شده است (اداره احصائیه و معلومات، ۲۰۱۸).	تعیین نقاط آموزشی و کنترلی به‌عنوان مزارع برنج برای طبقه‌بندی
نقشه پوشش اراضی	نقشه جهانی پوشش اراضی با وضوح ۱۰ متر برای سال ۲۰۲۰ (سازمان فضایی اتحادیه اروپا، ۲۰۲۰).	تعیین نقاط آموزشی و کنترلی
جدول کشت برنج	زمان کاشت و برداشت برنج (فائو، ۲۰۱۷).	تعیین زمان استفاده از تصاویر و بررسی فنولوژی برنج
داده‌های عملکرد برنج	داده‌های واقعی عملکرد برنج که به روش زمینی قطع نبات محاسبه شده است (اداره احصائیه و معلومات، ۲۰۲۰).	داده‌های آموزش و کنترلی برای محاسبه عملکرد
تصاویر گوگل ارث		تعیین نقاط آموزشی و کنترلی، و بررسی صحت نقاط میدانی

مأخذ: نگارندگان، ۱۴۰۲

نقشه مزارع برنج استان کندز در سال ۲۰۱۸ و نقاط برداشت میدانی از مزارع برنج در سال ۲۰۲۰ که به‌عنوان مرجع در این پژوهش استفاده شده، در شکل ۲ آورده شده است.



شکل ۲: نقشه مزارع برنج استان کندز در سال ۲۰۱۸ و نقاط برداشت میدانی از مزارع برنج در سال ۲۰۲۰ تهیه و ترسیم: نویسندگان با استفاده از داده‌های (اداره احصائیه و معلومات، ۲۰۱۸)

- داده‌های سنجش‌ازدوری:

در این پژوهش از تصاویر پردازش سطح دوم ماهواره سنتینل-۲^۱ استفاده شد. این ماهواره دارای قدرت تفکیک زمانی ۵ روز و دارای ۱۳ باندطیفی است که مشخصات آن در جدول ۲ آورده شده است. از آنجایی که این تصاویر با پردازش سطح دو هستند، نیازی به تصحیحات رادیومتریکی، هندسی و اتمسفری ندارد.

در این پژوهش مطابق با جدول کشت برنج، ۱۸۷ تصویر مربوط به ماه‌های ژوئن تا اکتبر ۲۰۲۰ در سامانه گوگل‌ارث‌انجین فراخوانی شدند. سپس از تصاویر با بیشتر از ۱۰ درصد پوشش ابر، صرف نظر شد که از ۱۳۹ تصویر باقی‌مانده برای محاسبه NDVI استفاده شد.

جدول ۲: مشخصات باندی تصاویر سنتینل-۲

نام باند	میانگین طول موج (میکرومتر)	توان تفکیک مکانی (متر)
Coastal aerosol	۰/۴۳	۶۰
Blue	۰/۴۹	۱۰
Green	۰/۵۶	۱۰
Red	۰/۶۵	۱۰
Vegetation Red Edge	۰/۷۰	۲۰
Vegetation Red Edge	۰/۷۴	۲۰
Vegetation Red Edge	۰/۷۸	۲۰
NIR	۰/۸۴	۱۰
Narrow NIR	۰/۸۶	۲۰
Water vapour	۰/۹۴	۶۰
SWIR – Cirrus	۱/۳۷	۶۰
SWIR	۱/۶۱	۲۰
SWIR	۲/۱۹	۲۰

مأخذ: <https://sentinel.esa.int/web/sentinel/copernicus/sentinel-2>


تهیه سری زمانی شاخص NDVI و آشکارسازی مراحل فنولوژی برنج

شاخص NDVI یکی از مهم‌ترین شاخص‌های نشان‌دهنده وضعیت پوشش گیاهی و همچنین عامل تشخیص خصوصیات فنولوژی گیاه است (Menenti et al, 1993: 4). سری زمانی شاخص NDVI با استفاده از سامانه گوگل‌ارث انجین و بازتابش باندهای ۱۰ متری قرمز و مادون قرمز تصاویر سنتینل-۲ از فرمول (Deering, 1975: 5) محاسبه شد.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

که در آن RED و NIR به ترتیب میزان بازتابش باندهای قرمز و مادون قرمز نزدیک هستند. این

شاخص برای هر یک از تصاویر برداشت‌شده در دوره رشد برنج (ژوئن تا اکتبر) محاسبه شد و به صورت یک لایه چند زمانی درآمدند. به این ترتیب تغییرات زمانی مقادیر NDVI برای هر پیکسل در طول دوره رشد برنج دریافت شد. نمودار تغییرات شاخص NDVI در طول زمان، نشان‌دهنده فنولوژی برنج است (Ali et al, 2021: 4; Boori et al, 2019: 5). در این نمودار زمان شروع سیر صعودی این شاخص، به عنوان آغاز فصل رشد، بلندترین نقطه نمودار به عنوان زمان اوج رشد و سقوط دوباره نمودار به عنوان پایان دوره رشد شناخته می‌شود. برای توضیح بیشتر، نمودار سری زمانی NDVI مزارع برنج استان کندز برای سال ۲۰۱۸ که توسط سازمان FAO تهیه شده، در شکل ۳ آورده شده است.



شکل ۳: نمودار سری زمانی NDVI ماهانه مزارع برنج استان کندز. A: آغاز فصل رشد، B: اوج رشد، C: پایان فصل رشد

تهیه و ترسیم: اداره احصائیه و معلومات افغانستان، ۲۰۲۰

قرمز (باند ۸) سنتینل-۲ برای شناسایی برنج استفاده شد. به طوری که هریک از این باندها در بازه یک ماه از دوره اوج رشد برنج به روش MVC ترکیب شده و در طبقه بندی استفاده شدند.

شاخص NDVI: شاخص NDVI نیز یکی از عوامل مهم تشخیص گیاهان است که در این پژوهش روی هریک از تصاویر سنتینل-۲ در مراحل کلیدی رشد برنج یعنی سه بازه یک ماهه مربوط به آغاز، اوج و پایان دوره رشد برنج محاسبه شدند و به روش MVC ترکیب شدند، سپس هریک از ترکیبها در طبقه بندی استفاده شد.

پارامترهای فنولوژی: پارامترهای فنولوژی که مهم ترین آنها زمان آغاز دوره رشد (SOS) و پایان دوره رشد (EOS) هستند، یکی از عوامل کلیدی شناسایی برنج به شمار می روند (Zhang & Lin, 2019: 8; Sisheber et al, 2022: 12) در این پژوهش از دو پارامتر SOS و EOS برای شناسایی برنج استفاده

از آنجایی که دوره رشد همه مزارع یکسان نیست، بازه زمانی یک ماهه به عنوان شروع، اوج و پایان دوره رشد برنج در نظر گرفته شد که بعداً داده های ماه های تعیین شده به روش MVC¹ با هم ترکیب شدند. این روش از مقادیر متفاوت هر پیکسل در یک بازه زمانی یک ماه، بزرگ ترین مقدار را انتخاب می کند که باعث حذف اثر ابر و ثبات مقادیر خواهد شد.

بازسازی داده ها در جهت طبقه بندی

پس از تهیه سری زمانی NDVI و تعیین فنولوژی برنج، برای شناسایی مزارع برنج از سه نوع داده یا شاخص استفاده شد. این داده ها با توجه به ویژگی فنولوژی برنج انتخاب شدند که از قرار زیر هستند.

باندهای طیفی: باندهای طیفی به ویژه باندهای مرئی و مادون قرمز عامل اصلی تشخیص پدیده ها از طریق سنجش از دور به شمار می روند؛ از این رو در این پژوهش از باندهای مرئی (باندهای ۲، ۳ و ۴) و باند مادون

1 Maximum Value Composite

الگوریتم‌ها با توجه به خصوصیات طیفی و مکانی یک پیکسل و پیکسل‌های مجاور آن نواحی همگن را شناسایی می‌کنند (Frohn & Hao, 2006: 7). در این پژوهش ابتدا داده‌های موجود (باندهای طیفی، شاخص NDVI و پارامترهای فنولوژی) با هم ترکیب^۴ شده و به کمک الگوریتم چندمقیاسه‌ای^۵ قطعه‌بندی شدند (Trimble, 2014: 142). این الگوریتم، اشیای تصویری بسیار همگن را با مقیاس دلخواه تولید کرده و از دقت خوبی برخوردار است (Batz & Schäpe, 2000: 6). در اینجا پس از یک سری تست‌ها، با در نظر داشت دقت کار و مساحت منطقه مطالعاتی مقیاس قطعه‌بندی ۱۰ در نظر گرفته شد که نتیجه قطعه‌بندی با این مقیاس با توجه به تفسیر بصری هماهنگی خوبی با پدیده‌های روی زمین داشت. دو پارامتر دیگر تأثیرگذار در قطعه‌بندی یعنی شکل و فشردگی به ترتیب در مقادیر ثابت ۰/۱ و ۰/۵ تنظیم شدند.

ب: انتخاب نمونه‌های تعلیمی و اعتبارسنجی

در طبقه‌بندی شیء‌گرا، نمونه‌های آموزشی و اعتبارسنجی از میان اشیای (objects) تصویر ایجاد شده انتخاب می‌شوند. در این پژوهش، این نمونه‌ها در نرم‌افزار ایکاگنیشن و به کمک داده‌های زمینی و مرجع به شکل تصادفی انتخاب شد. در مجموع ۱۵۷۰ آبجکت تصویر مستقل به‌عنوان نمونه آموزشی و ۵۱۸ آبجکت مستقل به‌عنوان نمونه اعتبارسنجی به کمک نقاط (GPS) حاصل از بازدید میدانی، نقشه‌های سال‌های قبلی و نقشه پوشش زمین انتخاب شدند. این نمونه‌ها از سه نوع پوشش مزارع برنج، سایر پوشش‌های گیاهی شامل مزارع باغی و سایر محصولات کشاورزی و پوشش‌های غیرگیاهی شامل آب، مناطق شهری و مراتع انتخاب شدند.

شد. این پارامترها به کمک سری زمانی NDVI و با روش حداکثر تفکیک محاسبه شدند.

روش حداکثر تفکیک برای استخراج پارامترهای فنولوژی روش حداکثر تفکیک (MS^۱) توسط دیسکالس^۲ و همکاران در سال ۲۰۲۰، به‌منظور استخراج پارامترهای فنولوژی مزارع کشاورزی ایجاد شد که در آن SOS و EOS با استفاده از سری زمانی شاخص NDVI محاسبه می‌شوند. این روش درحقیقت یک روش آستانه‌گذاری است که با مقایسه تغییرات مقادیر NDVI نسبت به زمان، میزان فعالیت گیاه نسبت به زمان را دریافت می‌کند، سپس زمان افزایش شدید فعالیت گیاه را به‌عنوان SOS و زمان کاهش شدید فعالیت گیاه را به‌عنوان EOS تعیین می‌کند (Descals et al, 2020:8). در این پژوهش از سامانه گوگل‌ارث انجین برای محاسبه این پارامترها استفاده شد.

شناسایی مزارع برنج با روش طبقه‌بندی شیء‌گرا

طبقه‌بندی شیء‌گرا یکی از روش‌های طبقه‌بندی در سنجش‌ازدور است که برای شناسایی پدیده‌ها علاوه بر خصوصیات طیفی، خصوصیات مکانی (شکل، بُعد، مرز، تفاوت با پدیده‌های مجاور و...) آن‌ها را نیز در نظر می‌گیرد (Benz et al, 2001: 6; Blaschke, 2010: 10). این روش در سه مرحله زیر و با استفاده از نرم‌افزار ایکاگنیشن^۳ اجرا می‌شود.

الف: قطعه‌بندی

در فرایند قطعه‌بندی، پیکسل‌هایی که از نظر ویژگی‌های طیفی و مکانی همگن هستند، با هم ترکیب شده و اشیای تصویری را می‌سازند (Blaschke & Strobl, 2001: 5). درحقیقت در این مرحله

1 Maximum Separation
2 Descals
3 Ecognition

ج: طبقه‌بندی و ارزیابی صحت آن

طبقه‌بندی در روش شیء‌گرا در سطح شیء صورت می‌گیرد. یعنی چندضلعی‌ها^۱ به کمک الگوریتم‌های سنتی مانند درخت تصمیم‌گیری^۲، درخت تصادفی^۳ و SVM^۴ طبقه‌بندی می‌شوند. در این تحقیق پس از انجام یک سری تست‌ها (به دلیل محدودیت در صفحات در اینجا آورده نشده است) از الگوریتم SVM استفاده شد، علاوه بر آن برخی از مطالعات دقت بهتر SVM را نسبت به الگوریتم‌های دیگر ثابت ساخته است (Tzotso, 2006: 6; Qian et al, 2014: 9; Arham, 2020: 19). سپس دقت و صحت نتایج به دست آمده با استفاده از ماتریس خطا ارزیابی شد. معیارهایی مانند دقت کلی، ضریب کاپا، کاپا در هر کلاس، دقت تولیدکننده و دقت کاربر محاسبه شدند.

- حذف نواحی غیرکشت در سطح پیکسل و تولید نقشه نهایی

فرایند طبقه‌بندی به روش شیء‌گرا، در سطح اشیای تصویر انجام می‌شود؛ بنابراین برای تولید نقشه نهایی دقیق‌تر طی فرایندی در سطح پیکسل (۱۰×۱۰ متر) نواحی کشت نشده از مزارع برنج حذف شدند. از آنجایی که در طول دوره کشت برنج، سایر مناطق غیرکشت شامل زمین‌های بایر، درختان، جنگل، مرداب‌ها و... هیچ نوع تغییرات سبزی‌نگی محسوسی ندارد (عدم تغییر شاخص NDVI)، از سری زمانی NDVI در طول دوره کشت برنج، برای حذف مناطق غیر کشت در طبقه‌بندی استفاده شد. بدین منظور برای مقادیر حداکثر و انحراف معیار NDVI حد آستانه تعیین شد. به طوری که پیکسل‌هایی با حداکثر و انحراف معیار مقدار NDVI کمتر از ۰/۲ به عنوان مناطق کشت نشده شناسایی شده و از نقشه نهایی حذف شدند (Ali et al, 2021: 6).

- برآورد عملکرد

پس از تخمین سطح زیر کشت برنج در استان کندز، برای برآورد عملکرد این مزارع از روش تجربی استفاده شد. این روش برای مناطقی که داده‌های عملکرد زمینی برداشت شده باشند، قابل اجرا است (Dela Torre, 2021: 8). در این روش ابتدا با انجام تحلیل‌های آماری، رابطه بین متغیر وابسته برداشت زمینی و متغیرهای مستقل سنجش‌ازدوری در پیکسل‌های مشخص به دست می‌آید و مدل عملکرد را ایجاد می‌کند. سپس با تطبیق این مدل روی باقی پیکسل‌ها به تخمین عملکرد برنج می‌پردازد. در این پژوهش برای تعیین رابطه، از رگرسیون خطی چند متغیره استفاده شد که متغیرهای آن در ادامه توضیح داده خواهند شد.

- بازسازی داده‌ها در جهت برآورد عملکرد داده زمینی

داده‌های عملکرد برداشت زمینی به عنوان متغیر وابسته در تحلیل رگرسیون استفاده شد که این داده‌ها از ۵۷ نقطه منطقه مورد مطالعه برداشت شدند. این داده‌ها نشان‌دهنده مقدار عملکرد برنج براساس واحد تن در هر هکتار هستند که در زمان برداشت محصول محاسبه شدند. ۵۵ درصد از این داده‌ها برای تجزیه و تحلیل و ۴۵ درصد آن برای ارزیابی دقت مدل استفاده شدند.

داده‌های سنجش‌ازدوری

برخی از شاخص‌های گیاهی مانند NDVI و LAI به عنوان پارامترهای بیوفیزیکی با شرایط فیزیولوژی آنها مانند زیست‌توده، سطح برگ، تراکم، ظرفیت‌های فتوسنتز و تبخیر و تعرق رابطه مستقیم دارند (Wiegand et al, 1991: 6; Rasmussen et al, 1997: 4; Bach, 1998: 5; Boegh, 2002: 6). این شاخص‌ها می‌توانند در تعیین میزان عملکرد

1 Polygon
2 Decision Tree
3 Random Tree
4 Support Vector Machine

این پژوهش از دو شاخص NDVI و LAI به عنوان متغیر مستقل سنجش از دوری برای تحلیل رگرسیون استفاده شدند. این شاخص‌ها برای تاریخ اوج رشد برنج محاسبه شدند، به طوری که ابتدا هر کدام برای یک ماه از اوج رشد محاسبه شدند، سپس به روش MVC ترکیب شدند. شاخص NDVI قبلاً محاسبه شده بود، اما شاخص LAI با استفاده از سامانه گوگل ارث انجین و فرمول ۲ (Boegh, 2002: 7) محاسبه شد.

$$LAI = (3.618 \times EVI - 0.118) \quad (2)$$

پخش اتمسفری حذف یا تعدیل می‌شود. شاخص EVI براساس فرمول ۳ (Huete et al, 1997:8) محاسبه شد.

$$EVI = 2.5 \times \left(\frac{NIR - RED}{NIR + C_1 \times RED - C_2 \times BLUE + L} \right) \quad (3)$$

کمبود داده‌های زمینی و داده‌های سنجش از دوری، روش رگرسیون خطی چندمتغیره مورد استفاده قرار گرفت.

ارزیابی دقت

برای ارزیابی دقت عملکرد برآورد شده، از تحلیل همبستگی بین داده‌های کنترلی برداشت زمینی (مقدار عملکرد) و میزان عملکرد تخمین زده شده با استفاده از داده‌های سنجش از دوری استفاده شد که برای این کار از دو معیار ضریب همبستگی خطی (ضریب همبستگی پیرسون) و ضریب تعیین (R^2) کار گرفته شد. روند کلی روش تحقیق در این پژوهش در شکل ۴ آورده شده است.

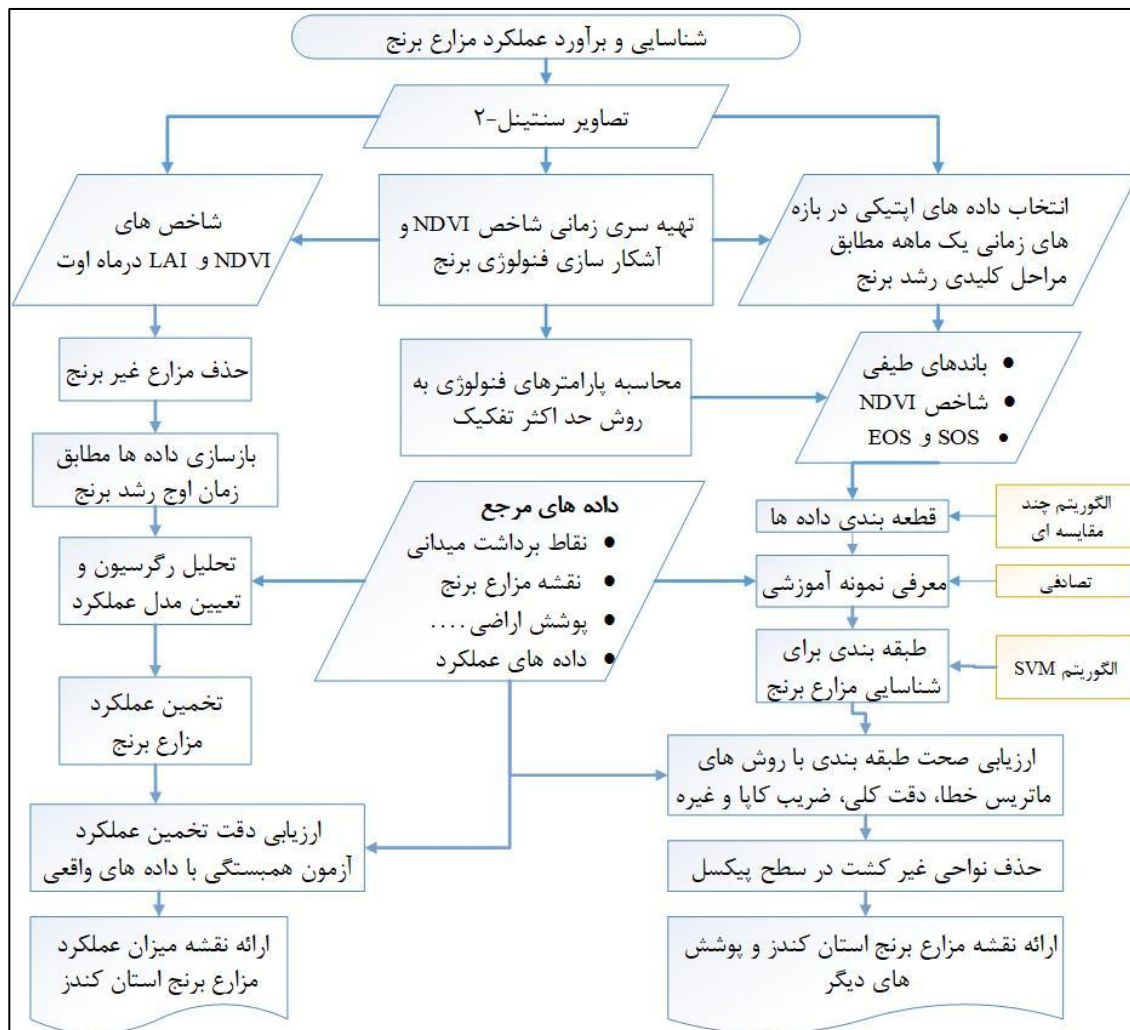
محصولاتی مانند برنج نیز مؤثر واقع شوند که در تحقیقات مختلفی از این شاخص‌ها برای برآورد عملکرد برنج به روش تجربی استفاده شده است (Son et al, 2020: 19; Ali et al, 2021: 15; Noureldin et al, 2013: 6). از آن جمله نورالدین و همکاران (۲۰۱۳) ثابت کردند که استفاده ترکیبی از شاخص‌های NDVI و LAI نسبت به دیگر شاخص‌ها، بهتر می‌تواند عملکرد مزارع برنج را در روش تجربی تعیین کند؛ بنابراین در

در اینجا LAI شاخص سطح برگ و EVI شاخص پوشش گیاهی بهبودیافته است که در واقع همانند شاخص NDVI عمل می‌کند، اما در محاسبه آن، اثرات

در اینجا EVI شاخص پوشش گیاهی بهبودیافته، NIR میزان بازتابش باند مادون قرمز، Red میزان بازتابش باند قرمز و Blue میزان بازتابش باند آبی و L = 1 تعدیل پس‌زمینه تاج پوشش، C_1 و C_2 ضرایب آتروسول هستند که به ترتیب ۶ و ۷/۵ در نظر گرفته می‌شوند (Huete et al, 1997:8).

تحلیل رگرسیون و ایجاد مدل عملکرد

تعیین مدل عملکرد در روش تجربی به واسطه روش‌ها و الگوریتم‌های مختلف صورت می‌گیرد که از آن جمله می‌توان از الگوریتم‌های جنگل تصادفی و SVM در پژوهش (Son et al, 2020:7)، رگرسیون خطی ساده در (Maki & Homma, 2014: 5) و رگرسیون خطی چندمتغیره در مطالعه (Prasetyo et al, 2018: 11) نام برد؛ اما در این پژوهش به دلیل



شکل ۴: روند کلی روش تحقیق در این پژوهش


تهیه و ترسیم: نگارندگان، ۱۴۰۲

نتایج

– سری زمانی شاخص NDVI

مطابق با جدول کاشت برنج استان کندز، کاشت برنج بعد از برداشت گندم و در ماه مه آغاز می شود و حداکثر رشد برنج در ماه ژوئن اتفاق می افتد و در نهایت برداشت آن در ماه اکتبر صورت می گیرد (FAO, 2017: 42)؛ از این رو سری زمانی NDVI با استفاده از ۱۳۹ تصویر با فواصل زمانی ۵ روز از ماه ژوئن تا اکتبر ۲۰۲۰ تهیه شد. شکل ۵ روند تغییرات

زمانی شاخص NDVI را در طول دوره کشت برای ۶ پیکسل (به صورت تصادفی) از ۶ مزرعه مختلف برنج، نشان می دهد. نمودارها به طور کلی از ماه ژوئن روند صعودی را آغاز کرده که نشان دهنده آغاز فصل رشد است. این روند در ماه اوت و تاحدی ماه های ژوئیه و سپتامبر به اوج رسیده و نشان دهنده اوج رشد برنج است. بعد از آن نمودارها دوباره روند نزولی داشته و در ماه اکتبر به پایین ترین حد نزدیک می شود که نشان دهنده زمان برداشت مزارع است.



شکل ۵: نمودار سری زمانی شاخص NDVI در مزارع مختلف برنج در استان کندز،

A: آغاز فصل رشد، B: اوج فصل رشد، C: پایان فصل رشد

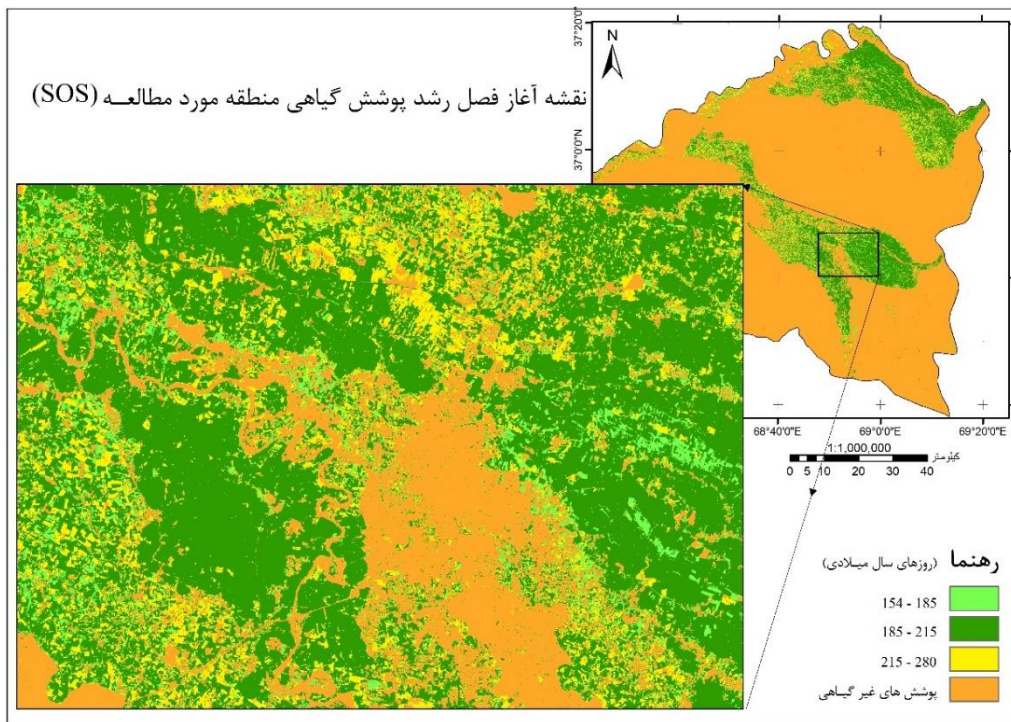
تهیه و ترسیم: نگارندگان، ۱۴۰۲

شاخص NDVI: سری زمانی این شاخص در سه ماه ژوئن، اوت و اکتبر به روش MVC ترکیب شدند. پارامترهای فنولوژی: پارامترهای فنولوژی شامل زمان شروع رشد (SOS) و پایان فصل رشد (EOS) با استفاده از سری زمانی شاخص NDVI به روش حداکثر تفکیک محاسبه شدند (شکل ۶ و ۷). از آنجایی که مطابق با روند فنولوژیکی، رشد برنج از ماه ژوئن آغاز می‌شود، در روش حداکثر تفکیک نیز این پارامترها تنها برای نیمه دوم سال میلادی محاسبه شدند. نتایج SOS به دست آمده نشان داد که آغاز روند رشد در مناطق مختلف از روز ۱۸۵ تا ۲۱۵ ام سال^۱ (ماه ژوئن) متغیر است (شکل ۶). نتایج EOS نیز نشان داد که پایان دوره یا برداشت محصول در مناطق با احتمال پوشش برنج روزهای ۲۵۵ تا ۲۸۵ ام سال اتفاق افتاده است (شکل ۷). این نتایج با اطلاعات زمینی همخوانی داشت.

بازسازی داده‌ها در جهت طبقه‌بندی

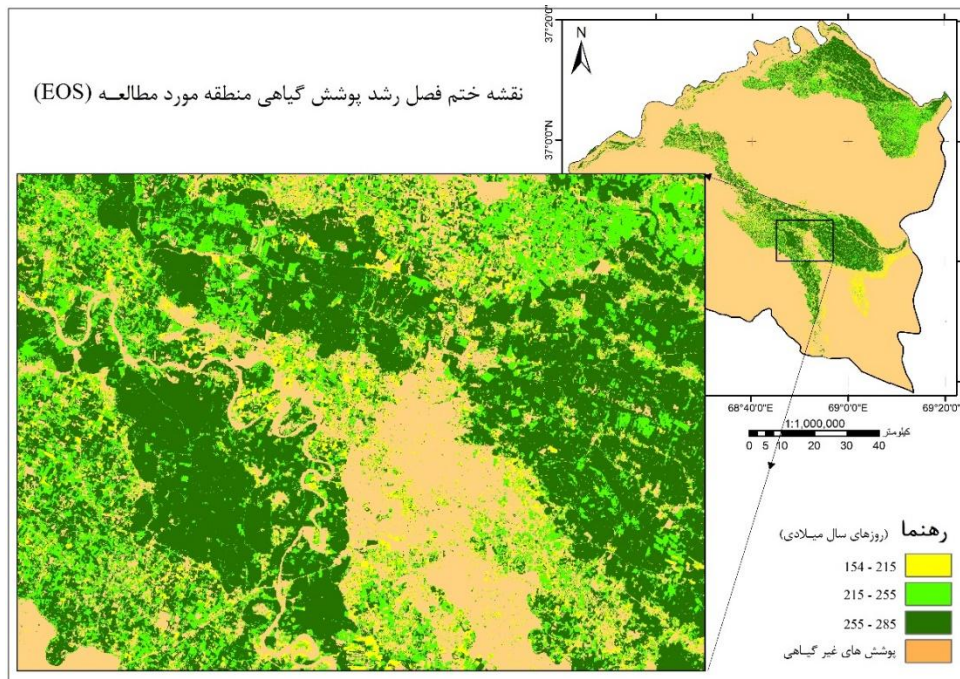
همان‌طور که در شکل ۵ نشان داده شد، فنولوژی برنج توسط نمودار سری زمانی NDVI نشان داده می‌شود؛ اما تغییرات فنولوژیکی مزارع مختلف با یکدیگر متفاوت بوده و مراحل کلیدی رشد تا نزدیک به یک ماه به هم تفاوت را نشان می‌دهد؛ از این رو، در این پژوهش برای هر مرحله کلیدی رشد، بازه زمانی یک‌ماهه در نظر گرفته شد. سپس سری زمانی داده‌های مورد استفاده در این ماه به روش MVC باهم ترکیب شدند. این ترکیب از یک جهت باعث کاهش اثر ابر (داده‌های ازدست‌رفته) و از جهت دیگر باعث ثبات مقادیر خواهد شد؛ زیرا این روش بزرگ‌ترین مقدار هر پیکسل در بازه زمانی یک ماه را انتخاب می‌کند. به این ترتیب داده‌های مورد استفاده در جهت طبقه‌بندی به شکل زیر بازسازی شدند.

باند‌های انعکاسی: سری زمانی باندهای مرئی و مادون قرمز مربوط به ماه اوت (حداکثر رشد گیاه) به روش MVC باهم ترکیب شدند.



شکل ۶: نقشه آغاز فصل رشد در منطقه مطالعاتی

تهیه و ترسیم: نگارندگان، ۱۴۰۲



شکل ۷: نقشه پایان دوره رشد در منطقه مطالعاتی

تهیه و ترسیم: نگارندگان، ۱۴۰۲

به این ترتیب، در این پژوهش عوامل و داده‌های مشخص‌کننده مزارع برنج با توجه به ویژگی فنولوژی آن انتخاب شدند که در جدول ۳ بیان شده‌اند.

جدول ۳: داده‌های مورد استفاده در طبقه‌بندی

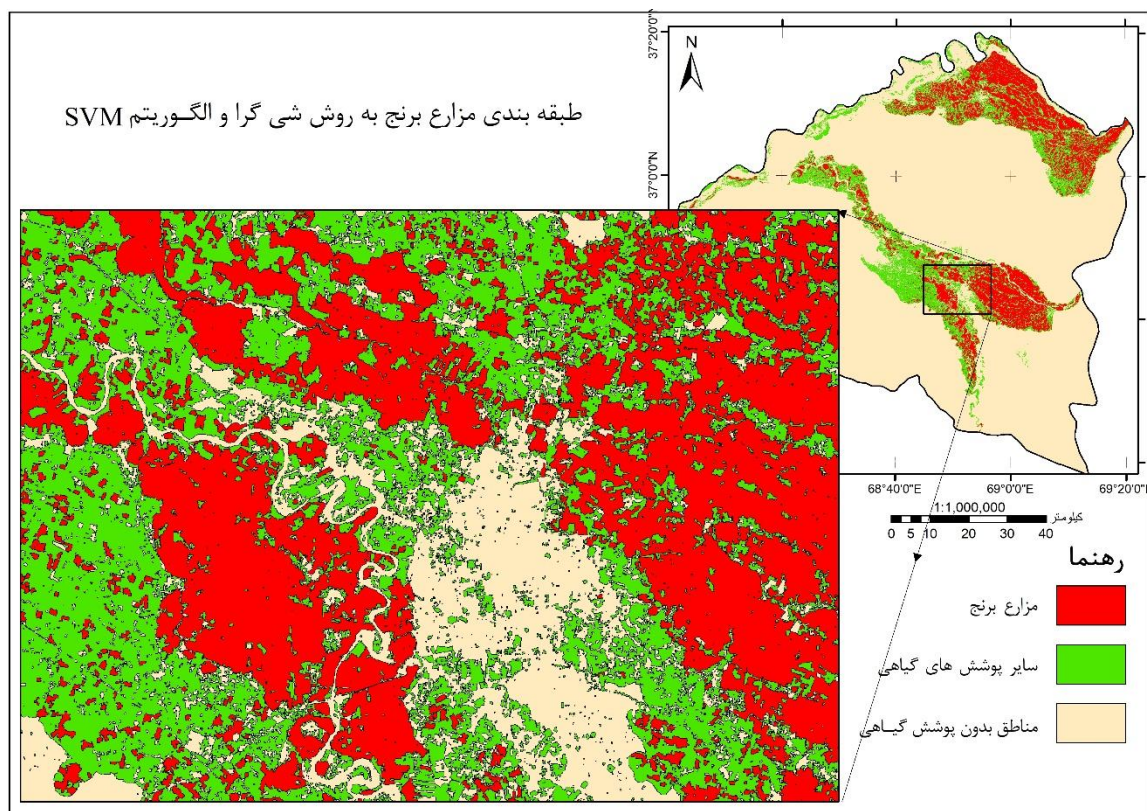
شماره	ویژگی طیفی	زمان برداشت
۱	باند آبی	ترکیب MVC ماه اوت
۲	باند سبز	ترکیب MVC ماه اوت
۳	باند قرمز	ترکیب MVC ماه اوت
۴	باند مادون قرمز	ترکیب MVC ماه اوت
۵	NDVI ماه ژوئن	ترکیب MVC ماه ژوئن
۶	NDVI ماه اوت	ترکیب MVC ماه اوت
۷	NDVI ماه اکتبر	ترکیب MVC ماه اکتبر
ویژگی فنولوژی		
۸	آغاز فصل رشد (SOS)	
۹	پایان فصل رشد (EOS)	

مأخذ: نگارندگان، ۱۴۰۲

نتایج طبقه‌بندی و ارزیابی دقت طبقه‌بندی

در نهایت مزارع برنج استان کندز با استفاده از روش طبقه‌بندی شیء‌گرای مبتنی بر فنولوژی شناسایی شدند که در نتیجه سه کلاس «مزارع برنج، سایر پوشش گیاهی غیر از برنج و پوشش‌های غیر گیاهی»

از هم تفکیک شدند. شکل ۸ نتیجه حاصل از طبقه‌بندی را نشان می‌دهد که در آن حدود ۶۲۴۰۰ هکتار از مساحت منطقه مطالعاتی را مزارع کشت برنج تشکیل دادند.



شکل ۸: نتیجه طبقه‌بندی و نقشه مزارع برنج در منطقه مطالعاتی

تهیه و ترسیم: نگارندگان، ۱۴۰۲

ارزیابی دقت طبقه‌بندی با استفاده از ماتریس خطا^۱ کنترلی (۵۱۷ شیء تصویری) در نرم‌افزار ایکاگنیشن انجام شد (جدول ۴). این ماتریس با توجه به نمونه‌های محاسبه شد.

جدول ۴: ماتریس خطای نتایج طبقه‌بندی

مجموع	مناطق غیر پوشش گیاهی	مزارع برنج	سایر پوشش‌های گیاهی	ماتریس خطا
۱۸۴	۲	۳	۱۷۹	سایر پوشش‌های گیاهی
۱۸۴	۰	۱۵۲	۳۲	مزارع برنج
۱۴۹	۱۴۳	۰	۶	مناطق غیر پوشش گیاهی
	۱۴۵	۱۵۵	۲۱۷	مجموع

مأخذ: نگارندگان، ۱۴۰۲

با توجه به ماتریس خطا، معیارهای تعیین‌کننده صحت طبقه‌بندی محاسبه شدند (جدول ۵). دقت نهایی با ۹۱/۵ درصد و ضریب کاپای ۰/۸۷۲ نشان‌دهنده دقت بالا و قابل‌قبول طبقه‌بندی هستند.

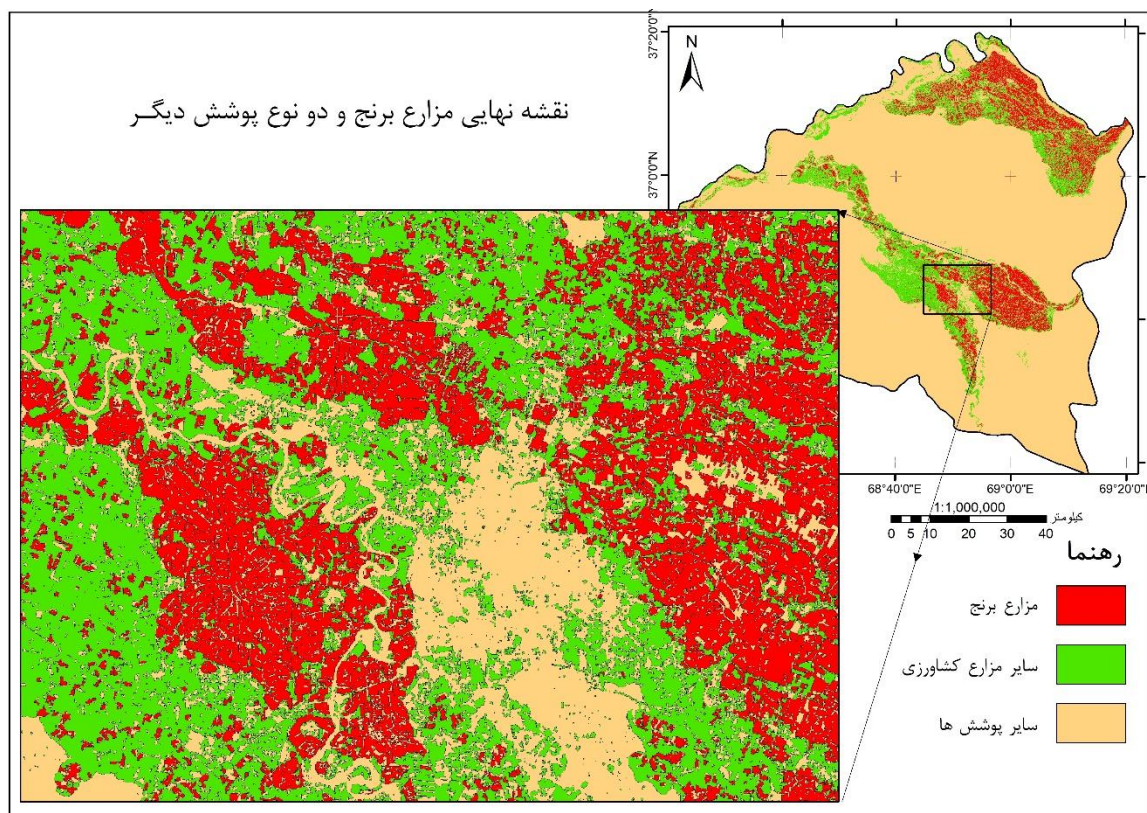
جدول ۵: نتایج معیارهای ارزیابی صحت

مناطق غیرپوشش گیاهی	مزارع برنج	سایر پوشش‌های گیاهی	
۰/۹۸	۰/۹۸	۰/۸۲	دقت تولیدکننده
۰/۹۵	۰/۸۲	۰/۹۷	دقت کاربر
۰/۹۸	۰/۹۷	۰/۷۲	ضریب کاپا در هرکلاس
معیارهای کلی			
	۹۱/۵		دقت کلی
	۰/۸۷۲		ضریب کاپا

مأخذ: نگارندگان، ۱۴۰۳

سطح پیکسل انجام شد، به طوری که پیکسل‌های بدون تغییرات NDVI در دوره طولانی کشت برنج از نقشه حذف شدند. در نهایت نقشه نهایی با سه کلاس مزارع برنج، سایر مزارع کشاورزی و سایر پوشش‌ها تولید شد. شکل ۹ نقشه نهایی را نشان می‌دهد که در آن حدود ۶۲۴۰۰ هکتار زمین به‌عنوان مزارع برنج شناسایی شدند.

نتایج حذف نواحی غیرکشت و تولید نقشه نهایی
همان‌طور که از نتایج ارزیابی دقت طبقه‌بندی دیده شد، نقشه طبقه‌بندی ایجاد شده برای شناسایی مزارع برنج از دقت بالایی برخوردار بوده و قابل‌قبول است؛ اما برای تهیه نقشه دقیق‌تر، نواحی کشت‌نشده مانند ردیف‌های درختان و تالاب‌ها که عمدتاً در مجاورت با مزارع برنج قرار دارند، از نقشه نهایی حذف و در کلاس سایر پوشش‌ها قرار گرفتند. این فرایند در



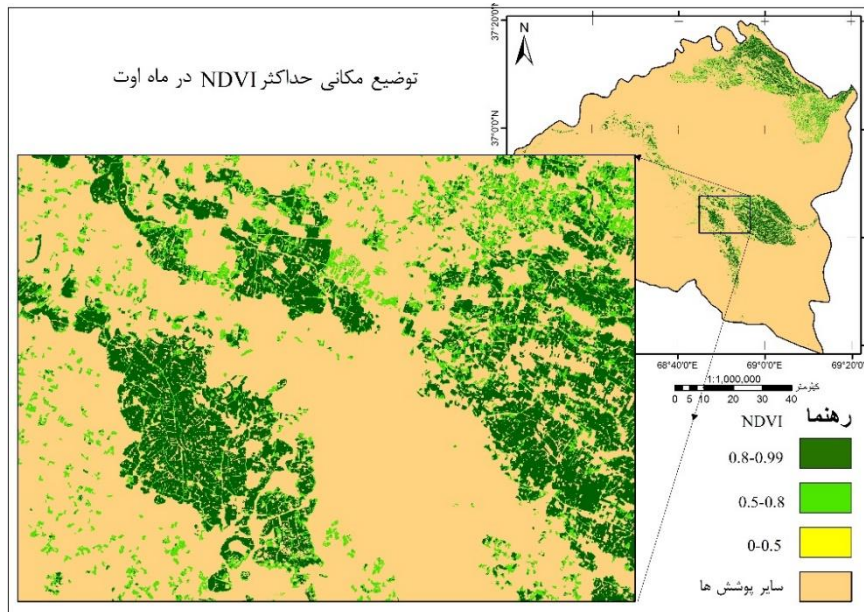
شکل ۹: نتیجه طبقه‌بندی و نقشه نهایی مزارع برنج در منطقه مطالعاتی

تهیه و ترسیم: نگارندگان، ۱۴۰۲

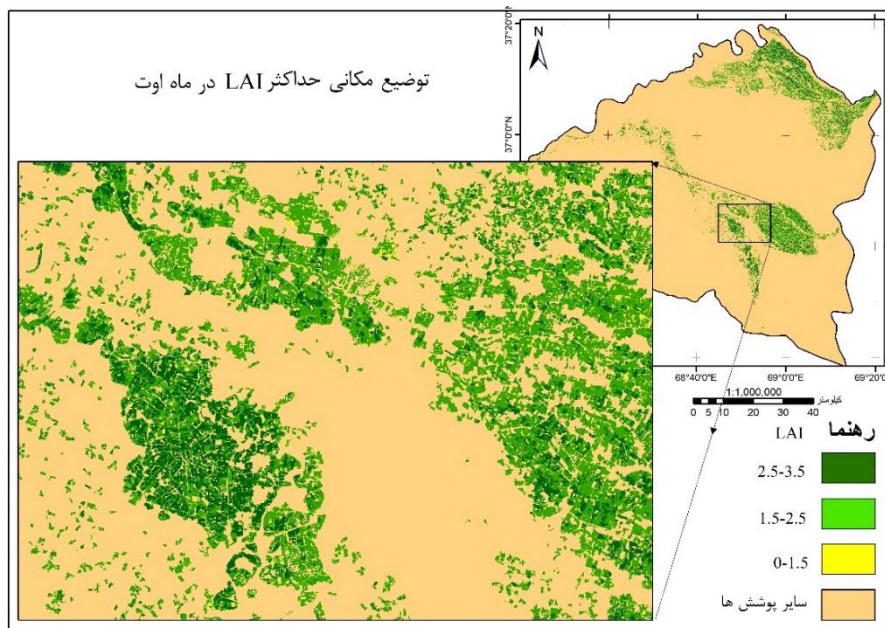
تخمین عملکرد مزارع برنج

پس از محاسبه سطح زیر کشت برنج، عملکرد مزارع با استفاده از روش تجربی محاسبه شد. بدین‌منظور، ابتدا سری‌زمانی تصاویر سنتینل-۲ برای ماه اوت که زمان اوج رشد برنج است، تهیه شد. سپس شاخص‌های LAI و NDVI آن‌ها محاسبه شدند؛ اما از

آنجایی که زمان دقیق اوج رشد در مزارع مختلف از هم متفاوت است، این شاخص‌ها به روش MVC ترکیب شدند. این ترکیب باعث شد تا شاخص‌ها مطابق با زمان اوج رشد هر مزرعه در محاسبات استفاده شوند.



شکل ۱۰: گستره شاخص NDVI مزارع برنج منطقه مطالعاتی در ۱۴ اوت ۲۰۲۰

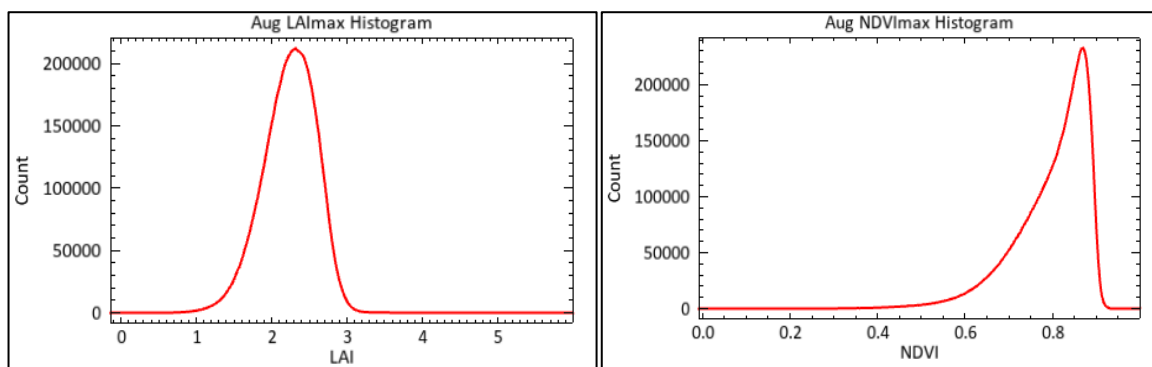


شکل ۱۱: گستره شاخص LAI در مزارع برنج منطقه مطالعاتی در ۱۴ اوت ۲۰۲۰

تهیه و ترسیم: نگارندگان، ۱۴۰۲

LAI از $1/2$ تا ۳ با میانگین $2/25$ متغیر هستند. از آنجایی که این شاخص‌ها نشان‌دهنده فیزیولوژی گیاه هستند، می‌توانند در برآورد عملکرد مزارع برنج مؤثر باشند.

به‌طوری‌که در شکل‌های ۱۰ و ۱۱ دیده می‌شود، مقادیر به‌دست‌آمده در زمان اوج رشد برنج در مزارع مختلف باهم متفاوت هستند. همچنین با توجه به هیستوگرام تصویر این شاخص‌ها (شکل ۱۲) مقادیر NDVI از $0/5$ تا $0/99$ با میانگین $0/79$ و مقادیر



هیستوگرام حداکثر LAI در ماه اوت

هیستوگرام حداکثر NDVI در ماه اوت

شکل ۱۲: هیستوگرام شاخص‌های LAI و NDVI در زمان اوج رشد برنج

تهیه و ترسیم: نگارندگان، ۱۴۰۲

مدل تخمین عملکرد

با استفاده از تحلیل رگرسیون، متغیر مستقل، عملکرد واقعی و متغیرهای وابسته LAI و NDVI مدل

تخمین عملکرد به دست آمدند. این مدل با استفاده از تخمین رگرسیون خطی چندمتغیره توسط نرم‌افزار (R) محاسبه شد که نتایج آن در جدول ۶ آمده است.

جدول ۶: نتایج تخمین رگرسیون داده‌های سنجش‌ازدوری و عملکرد برداشت زمینی

پارامترها	برآوردها	خطای معیار	مقدار t	مقدار احتمال
عرض از مبدأ	-۴/۴۳۹۴	۱/۴۲۶۳	-۳/۱۰۹	۰/۰۰۴۷۸
LAI	۱/۰۴۱۶	۰/۴۰۶۹	۲/۵۶۰	۰/۰۱۷۲۰
NDVI	۶/۲۹۶۶	۲/۵۰۳۹	۲/۵۱۵	۰/۰۱۹۰۲
خطای معیار باقیمانده: ۰/۴۳۳۱		درجه آزادی: ۲۴		
ضریب تعیین: ۰/۷۳۶۷		ضریب تعیین تعدیل‌شده: ۰/۷۱۴۸		
آماره-F: ۳۲/۵۸	درجه آزادی: ۲ و ۲۴		مقدار-p: ۱/۱۱e ⁻⁰⁷	

مأخذ: نگارندگان، ۱۴۰۲

نتایج تخمین رگرسیون نشان داد که ضرایب به دست آمده برای مدل از سطح معنی‌داری ۰/۰۰۱ (عرض از مبدأ) و ۰/۰۱ (شیب داده‌های NDVI و LAI) برخوردار هستند. همچنین ضریب تعیین نشان می‌دهد که ۷۳ درصد از تغییرات توسط متغیرهای

تعیین شده برآورد می‌شوند؛ بنابراین مدل تخمین عملکرد مزارع برنج براساس فرمول ۴ تعیین شد که در آن Y عملکرد تخمین زده شده و LAI و NDVI شاخص‌های سنجش‌ازدوری حاصل از تصاویر برداشت شده در زمان اوج رشد شالیزار هستند.

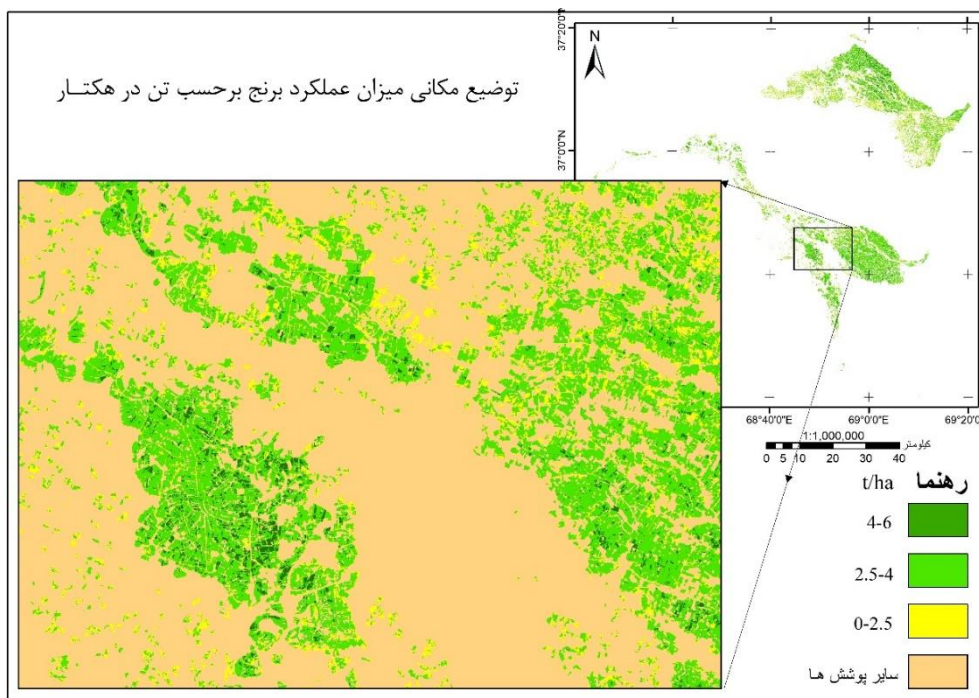
$$Y = -1.466 + 1.285 \times LAI + 2.306 \times NDVI \quad (۴)$$

برنج در اکثر مزارع بین ۲/۵ تا ۴ تن در هکتار بوده است. برخی مزارع، دارای عملکرد کمتر از ۲/۵ تن در هکتار را نشان داده‌اند که این کاهش عملکرد می‌تواند

با توجه به مدل به دست آمده، میزان عملکرد مزارع برنج استان کندز در سال ۲۰۲۰ محاسبه شد. شکل‌های ۱۳ و ۱۴ نشان می‌دهند که میزان عملکرد


از این رو می‌توان دلیل افزایش عملکرد آن‌ها را دسترسی بیشتر به منابع آبی عنوان کرد. دلایل دیگری نیز در میزان عملکرد مزارع تأثیر دارد که با توجه به اطلاعات میدانی (وزارت زراعت افغانستان) می‌توان به نوع برنج، نوع و مقدار کود مورد استفاده (شیمیایی و حیوانی) اشاره کرد.

به دلیل شرایط نامناسب آن‌ها اتفاق افتاده باشد؛ برای مثال، دوری این مزارع، که اکثراً در نواحی مرتفع‌تر واقع شده‌اند، از رودخانه‌ها، می‌تواند بیانگر دسترسی کمتر به منابع آبی باشد. مزارع با عملکرد بالاتر از ۴ تن در هکتار اکثراً در نواحی پست‌تر و نزدیک‌تر به رودخانه‌ها واقع شده‌اند و بافت متراکم‌تری دارند؛



شکل ۱۳: نقشه میزان عملکرد مزارع برنج منطقه مطالعاتی (تن در هکتار)

تهیه و ترسیم: نگارندگان، ۱۴۰۲




شکل ۱۴: هیستوگرام عملکرد برآورد شده

تهیه و ترسیم: نگارندگان، ۱۴۰۲

ارزیابی صحت عملکرد برآوردشده

صحت عملکرد برآوردشده در این پژوهش با مقایسه عملکرد واقعی (داده‌های برداشت میدانی) در ۲۷ نقطه کنترلی ارزیابی شد. برای این کار از آزمون

همبستگی پیرسون استفاده شد (جدول ۷). این آزمون نشان داد بین عملکرد واقعی و عملکرد برآوردشده رابطه مثبت و بسیار قوی وجود دارد ($R^2=0/929$ و $N=27$, $P=0/000$). (شکل ۱۵).



شکل ۱۵: پراکندگی و ارتباط بین عملکرد واقعی و عملکرد تخمین شده

تهیه و ترسیم: نگارندگان، ۱۴۰۲

برآورد عملکرد مزارع برنج از دقت بالایی برخوردار است.

با توجه به همبستگی بسیار قوی که بین داده‌های عملکرد واقعی و عملکرد تخمین شده وجود دارد، نتیجه می‌گیریم که روش تجربی استفاده شده برای

جدول ۷: آزمون ضریب همبستگی بین عملکرد تخمین شده و عملکرد واقعی.

عملکرد تخمین شده	عملکرد واقعی	ضریب همبستگی پیرسون	عملکرد واقعی
۰/۹۲۹**	۱	سطح معنی داری	
۰/۰۰۰		تعداد	
۲۷	۲۷		
عملکرد تخمین شده	عملکرد واقعی	ضریب همبستگی پیرسون	عملکرد تخمین شده
۱	۰/۹۲۹**	سطح معنی داری	
	۰/۰۰۰	تعداد	
۲۷	۲۷		

مأخذ: نگارندگان، ۱۴۰۲

در حال توسعه مثل افغانستان بود که با کمبود و پراکندگی داده‌های زمینی مواجه هستند. نتایج این تحقیق نشان داد که روش طبقه‌بندی شیء‌گرایی مبتنی بر فنولوژی با دقت کلی ۹۱/۵ درصد و ضریب کاپای ۰/۸۷، روش دقیقی برای شناسایی مزارع برنج به شمار می‌رود. همچنان روش تجربی مبتنی بر تحلیل

نتیجه

این پژوهش به منظور برآورد سطح زیرکشت و عملکرد مزارع برنج استان کندز افغانستان در سال ۲۰۲۰ اجرا شد. هدف اصلی آن تطبیق و ارزیابی روش‌های جدید سنجش‌ازدوری برای شناسایی مزارع برنج و برآورد عملکرد این مزارع در کشورهای

شد. نتایج این تحقیق می‌تواند برای ادارات و سازمان‌هایی که درباره محصولات کشاورزی و نیاز غذایی کشور افغانستان برنامه‌ریزی می‌کنند، کاربرد داشته باشد. از نقاط ضعف این تحقیق می‌توان به عدم امکان استفاده از این مدل در سال‌های آینده اشاره کرد. گرچه پیشنهاد می‌شود این تحقیق در سال‌های متوالی دیگری (به شرط داشتن داده‌های زمینی میزان عملکرد) نیز انجام شود و نتایج آن با این تحقیق مقایسه شود. بدین وسیله می‌توان به مدلی با میزان اعتمادپذیری بیشتر برای پیش‌بینی میزان عملکرد در سال‌های آینده رسید. همچنین می‌توان از داده‌های برآوردشده میزان تبخیر و تعرق واقعی گیاه برنج در طول فصل رشد به‌عنوان داده کمکی برای بهبود میزان عملکرد در مدل رگرسیونی استفاده کرد. چون میزان تبخیر و تعرق می‌تواند به‌عنوان شاخصی برای تعیین میزان آب مصرفی و اثرگذار در میزان عملکرد اشاره کرد. با این روش می‌توان به شاخص بهره‌وری آب (water productivity) به‌عنوان میزان بازده محصول به‌ازای مصرف هر متر مکعب مصرف آب دست یافت که در مدیریت و برنامه‌ریزی منابع آب بسیار مهم است.

رگرسیون داده‌های زمینی و سنجش‌ازدوری با ضریب تعیین ۰/۸۶ و ضریب همبستگی پیرسون برابر با ۰/۹۲ دقت بالای آن را در برآورد عملکرد مزارع برنج نشان داد. این نتایج با استفاده از تصاویر اپتیکی سنتینل-۲ به‌دست آمد که در آن ابتدا یک سری زمانی NDVI با فاصله زمانی ۵ روز برای دوره رشد برنج تهیه شد و بازه‌های زمانی یک‌ماهه به‌عنوان مراحل کلیدی رشد برنج تعیین شد. سپس با استفاده از این داده‌ها پارامترهای فنولوژی برنج (SOS و EOS) محاسبه شد و داده‌های اپتیکی و شاخص‌های NDVI و باندهای انعکاسی نیز متناسب با مراحل کلیدی رشد برنج به روش MVC باهم ترکیب شدند. در مرحله بعد این سه نوع داده با الگوریتم چندمقایسه‌ای قطعه‌بندی شده و با استفاده از الگوریتم SVM طبقه‌بندی انجام شد. پس از شناسایی مزارع برنج، برای برآورد عملکرد آن شاخص‌های NDVI و LAI برای تاریخ اوج رشد برنج محاسبه شد و با استفاده از تحلیل رگرسیون آن‌ها با داده‌های عملکرد نقطه‌ای زمینی، یک مدل عملکرد ایجاد شد. درنهایت این مدل عملکرد، برای هریک از پیکسل‌های مزارع برنج تطبیق داده شد و نقشه عملکرد محصول برنج برای سال ۲۰۲۰ تهیه

منابع

نجمی، حمزه (۱۳۹۱). تهیه نقشه میزان تولید محصول برنج با استفاده از داده‌های سنجنش‌ازدور راداری، دانشگاه خواجه نصیرالدین طوسی. دانشکده مهندسی نقشه‌برداری. پایان‌نامه کارشناسی ارشد.

<https://ganj.irandoc.ac.ir/#/search?keywords=%D8%AD%D9%85%D8%B2%D9%87%20%D9%86%D8%AC%D9%85%DB%8C&basicscope=1>

وزارت زراعت، آبیاری و مالداری (۱۳۹۸ الف). گزارش سالانه زراعتی سال ۱۳۹۸.

<https://www.mail.gov.af/sites/default/files/2019-12/Rice%20Report%2007.pdf>

وزارت زراعت، آبیاری و مالداری (۱۳۹۸ ب). گزارش تولیدات برنج سال ۱۳۹۸.

<https://www.mail.gov.af/sites/default/files/2020-08/Agricultural%20Annual%20Report%2098.pdf>

References

- Ali, A. M., Savin, I., Poddubskiy, A., Abouelghar, M., Saleh, N., Abutaleb, K., ... & Dokukin, P (2021). Integrated method for rice cultivation monitoring using Sentinel-2 data and Leaf Area Index. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3), 431-441.
<https://www.sciencedirect.com/science/article/pii/S1110982320301666>
- Arham, N. A (2020). Object based image analysis of support vector machine and rule based image classification for building extraction (Doctoral dissertation, Universiti Teknologi MARA, Shah Alam).
<https://ir.uitm.edu.my/id/eprint/34565/1/34565.pdf>
- Aschbacher, J., Pongsrihadulchai, A., Karnchanasutham, S., Rodprom, C., Paudyal, D. R., & Le Toan, T (1995, July). Assessment of ERS-1 SAR data for rice crop mapping and monitoring. In 1995 International Geoscience and Remote Sensing Symposium, IGARSS'95. Quantitative Remote Sensing for Science and Applications (Vol. 3, 2183-2185). IEEE.
<https://ieeexplore.ieee.org/document/524142?arnumber=524142>
- Baatz, M., & Schäpe, A (2000). Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. *Proceedings of Angewandte Geographische Informationsverarbeitung XII*, 12-23.
<https://www.semanticscholar.org/paper/Multiresolution-Segmentation-%3A-an-optimization-for-Baatz-Sch%C3%A4pe/364cc1ff514a2e11d21a101dc072575e5487d17e>
- Bach, H (1998). Yield estimation of corn based on multitemporal LANDSAT-TM data as input for an agrometeorological model. *Pure and Applied Optics: Journal of the European Optical Society Part A*, 7(4), 809.
<https://iopscience.iop.org/article/10.1088/0963-9659/7/4/017>
- Baidar, T (2020). Rice crop classification and yield estimation using multi-temporal sentinel-2 data: a case study of terai districts of Nepal. *Universitat Jaume*. 1-79.
<https://repositori.uji.es/xmlui/handle/10234/187006?locale-attribute=en>
- Benz, U., & Schreier, G (2001). Definiens Imaging GmbH: Object oriented classification and feature detection. *IEEE Geoscience and Remote Sensing Society Newsletter*, 9, 16-20.
- Blaschke, T (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 65(1), 2-16.
<https://www.sciencedirect.com/science/article/pii/S0924271609000884>
- Blaschke, T., & Strobl, J (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *Zeitschrift für Geoinformationssysteme*, 12-17.
<https://www.semanticscholar.org/paper/What%E2%80%99s-wrong-with-pixels-Some-recent-developments-Blaschke-Strobl/51b65077ce150e717f21ee8ce1d96e4790d5779c>
- Boegh, E., Soegaard, H., Broge, N., Hasager, C. B., Jensen, N. O., Schelde, K., & Thomsen, A (2002). Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture. *Remote sensing of Environment*, 81(2-3), 179-193.
<https://www.sciencedirect.com/science/article/abs/pii/S003442570100342X?via%3Dihub>

- Boori, M. S., Choudhary, K., Paringer, R., Sharma, A. K., Kupriyanov, A., & Corgne, S (2019, September). Monitoring crop phenology using NDVI time series from Sentinel 2 satellite data. In 2019 5th International Conference on Frontiers of Signal Processing (ICFSP) (62-66). IEEE.
<https://ieeexplore.ieee.org/document/8938078>
- Cai, Y., Lin, H., & Zhang, M (2019). Mapping paddy rice by the object-based random forest method using time series Sentinel-1/Sentinel-2 data. *Advances in Space Research*, 64(11), 2233–2244.
<https://www.sciencedirect.com/science/article/abs/pii/S0273117719306258>
- Chen, C., & McNairn, H (2006). A neural network integrated approach for rice crop monitoring. *International Journal of Remote Sensing*, 27(7), 1367-1393.
<https://www.tandfonline.com/doi/full/10.1080/01431160500421507>
- Chen, N., Yu, L., Zhang, X., Shen, Y., Zeng, L., Hu, Q., & Niyogi, D (2020). Mapping paddy rice fields by combining multi-temporal vegetation index and synthetic aperture radar remote sensing data using Google Earth Engine machine learning platform. *Remote Sensing*, 12(18).
<https://www.mdpi.com/2072-4292/12/18/2992>
- Deering, D. W (1975). Measuring " forage production" of grazing units from Landsat MSS data. In *Proceedings of the Tenth International Symposium of Remote Sensing of the Environment* (1169-1198).
- dela Torre, D. M. G., Gao, J., Macinnis-Ng, C., & Shi, Y. (2021). Phenology-based delineation of irrigated and rain-fed paddy fields with Sentinel-2 imagery in Google Earth Engine. *Geo-spatial Information Science*, 24(4), 695-710.
[10.1080/10095020.2021.1984183](https://doi.org/10.1080/10095020.2021.1984183)
- Desclée, B., Bogaert, P., & Defourny, P (2006). Forest change detection by statistical object-based method. *Remote Sensing of Environment*, 102(1-2), 1-11.
<https://www.sciencedirect.com/science/article/abs/pii/S0034425706000344>
- Dong, J., & Xiao, X (2016). Evolution of regional to global paddy rice mapping methods: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 119, 214-227.
<https://www.sciencedirect.com/science/article/abs/pii/S0924271616300995>
- Dong, J., Xiao, X., Kou, W., Qin, Y., Zhang, G., Li, L., Jin, C., Zhou, Y., Wang, J., Biradar, C., Liu, J., & Moore, B (2015). Tracking the dynamics of paddy rice planting area in 1986-2010 through time series Landsat images and phenology-based algorithms. *Remote Sensing of Environment*, 160, 99-113.
<https://www.sciencedirect.com/science/article/abs/pii/S0034425715000139>
- FAO (2017) *Afghanistan: Monitoring of Rice Crop using Satellite Remote Sensing and GIS Technologies*. FAO Publication: Rome.
<https://www.fao.org/geospatial/resources/detail/zh/c/1024575/>
- FAO (2022) *Crop Prospects and Food Situation-Quarterly Global Report No. 2, July 2022*. Rome.
<https://www.fao.org/documents/card/en/c/cc0868en/>
- Frohn, R. C., & Hao, Y (2006). Landscape metric performance in analyzing two decades of deforestation in the Amazon Basin of Rondonia, Brazil. *Remote sensing of Environment*, 100(2), 237-251.
<https://www.sciencedirect.com/science/article/abs/pii/S0034425705003573>
- Guan, K., Li, Z., Rao, L. N., Gao, F., Xie, D., Hien, N. T., & Zeng, Z (2018). Mapping paddy rice area and yields over Thai Binh Province in Viet Nam from MODIS, Landsat, and ALOS-2/PALSAR-2. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(7), 2238-2252.
<https://ieeexplore.ieee.org/document/8375090>
- Huete, A. R., Liu, H. Q., Batchily, K. V., & Van Leeuwen, W. J. D. A (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote sensing of environment*, 59(3), 440-451.
<https://www.sciencedirect.com/science/article/abs/pii/S0034425796001125>
- Lestari, E. A. P., Supriatna, & Damayanti, A (2020). Model of paddy rice phenology using Sentinel 2-A imagery with NDVI algorithm in Subang Regency. *IOP Conference Series: Earth and Environmental Science*, 481(1).
<https://iopscience.iop.org/article/10.1088/1755-1315/481/1/012069>
- Maki, M., & Homma, K (2014). Empirical regression models for estimating multiyear leaf area index of rice from several vegetation indices at the field scale. *Remote Sensing*, 6(6), 4764-4779.
<https://www.mdpi.com/2072-4292/6/6/4764>

- Menenti, M., Azzali, S., Verhoef, W., and van Swol, R (1993). Mapping agroecological zones and time lag in vegetation growth by means of fourier analysis of time series of NDVI images. *Adv. Space Res.* 13, 233-237.
<https://www.sciencedirect.com/science/article/abs/pii/027311779390550U>
- Noureldin, N. A., Aboelghar, M. A., Saady, H. S., & Ali, A. M (2013). Rice yield forecasting models using satellite imagery in Egypt. *The Egyptian Journal of Remote Sensing and Space Science*, 16(1), 125-131.
<https://www.sciencedirect.com/science/article/pii/S1110982313000094>
- Prasad, A.K.; Chai, L.; Singh, R.P.; Kafatos, M (2006). Crop yield estimation model for Iowa using remote sensing and surface parameters. *International Journal of Applied earth observation and geoinformation*, 8: 26-33.
<https://www.sciencedirect.com/science/article/abs/pii/S0303243405000553>
- Prasetyo, Y., Sukmono, A., Aziz, K. W., & Aji, B. J. P. S (2018, June). Rice productivity prediction model design based on linear regression of spectral value using NDVI and LSWI combination on landsat-8 imagery. In *IOP Conference Series: Earth and Environmental Science* (Vol. 165, No. 1, 012002). IOP Publishing.
<https://iopscience.iop.org/article/10.1088/1755-1315/165/1/012002>
- Pringle, M. J., Denham, R. J., & Devadas, R (2012). Identification of cropping activity in central and southern Queensland, Australia, with the aid of MODIS MOD13Q1 imagery. *International Journal of Applied Earth Observation and Geoinformation*, 19(1), 276-285.
<https://www.sciencedirect.com/science/article/abs/pii/S0303243412001250>
- Qian, Y., Zhou, W., Yan, J., Li, W., & Han, L (2014). Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery. *Remote Sensing*, 7(1), 153-168.
<https://www.mdpi.com/2072-4292/7/1/153>
- Qiu, B., Li, W., Tang, Z., Chen, C., & Qi, W (2015). Mapping paddy rice areas based on vegetation phenology and surface moisture conditions. *Ecological Indicators*, 56, 79–86.
<https://www.sciencedirect.com/science/article/abs/pii/S1470160X15001697>
- Raksapatcharawong, M., Veerakachen, W., Homma, K., Maki, M., & Oki, K (2020). Satellite-based drought impact assessment on rice yield in Thailand with SIMRIW– RS. *Remote Sensing*, 12(13), 2099.
<https://www.mdpi.com/2072-4292/12/13/2099>
- Rasmussen, M. S (1997). Operational yield forecast using AVHRR NDVI data: reduction of environmental and inter-annual variability. *International Journal of Remote Sensing*, 18(5), 1059-1077.
<https://www.tandfonline.com/doi/abs/10.1080/014311697218575>
- Raza, S. M. H., Mahmood, S. A., Gillani, S. A., Hassan, S. S., Aamir, M., Saifullah, M., ... & Ali, T (2019). Estimation of net rice production by remote sensing and multi source datasets. *Sarhad Journal of Agriculture*, 35(3), 955-965.
<https://researcherslinks.com/current-issues/Estimation-of-Net-Rice-Production-by-Remote-Sensing-and-Multi-Source-Datasets/14/1/2455>
- Sibaruddin, H. I., Shafri, H. Z. M., Pradhan, B., & Haron, N. A (2018, June). Comparison of pixel-based and object-based image classification techniques in extracting information from UAV imagery data. In *IOP conference series: earth and environmental science* (Vol. 169, No. 1, p. 012098). IOP Publishing.
<https://iopscience.iop.org/article/10.1088/1755-1315/169/1/012098>
- Singha, M., Wu, B., & Zhang, M (2016). Object-based paddy rice mapping using HJ-1A/B data and temporal features extracted from time series MODIS NDVI data. *Sensors*, 17(1), 10.
<https://www.mdpi.com/1424-8220/17/1/10>
- Sisheber, B., Marshall, M., Ayalew, D., & Nelson, A (2022). Tracking crop phenology in a highly dynamic landscape with knowledge-based Landsat–MODIS data fusion. *International Journal of Applied Earth Observation and Geoinformation*, 106, 102670.
<https://www.sciencedirect.com/science/article/pii/S0303243421003779>
- Son, N. T., Chen, C. F., Chen, C. R., Guo, H. Y., Cheng, Y. S., Chen, S. L., ... & Chen, S. H (2020). Machine learning approaches for rice crop yield predictions using time-series satellite data in Taiwan. *International Journal of Remote Sensing*, 41(20), 7868-7888.
<https://www.tandfonline.com/doi/abs/10.1080/01431161.2020.1766148>

- Son, N. T., Chen, C. F., Chen, C. R., Toscano, P., Cheng, Y. S., Guo, H. Y., & Syu, C. H (2021). A phenological object-based approach for rice crop classification using time-series Sentinel-1 Synthetic Aperture Radar (SAR) data in Taiwan. *International Journal of Remote Sensing*, 42(7), 2722-2739.
<https://www.tandfonline.com/doi/abs/10.1080/01431161.2020.1862440>
- Su, T (2017). Efficient paddy field mapping using Landsat-8 imagery and object-based image analysis based on advanced fractal net evolution approach. *GIScience & Remote Sensing*, 54(3), 354-380.
<https://www.tandfonline.com/doi/full/10.1080/15481603.2016.1273438>
- Teluguntla, P., Ryu, D., George, B., Walker, J. P., & Malano, H. M (2015). Mapping flooded rice paddies using time series of MODIS imagery in the Krishna River Basin, India. *Remote Sensing*, 7(7), 8858-8882.
<https://www.mdpi.com/2072-4292/7/7/8858>
- Trimble (2014). *eCognition Developer 9.0. 1 Reference Book*.
<https://ecognition-developer.software.informer.com/9.0/>
- Tzotso, A (2006). A support vector machine approach for object based image analysis. *Proceedings of OBIA*.
<https://www.academia.edu/3098178/>
- Wiegand, C. L., Richardson, A. J., Escobar, D. E., & Gerbermann, A. H (1991). Vegetation indices in crop assessments. *Remote sensing of Environment*, 35(2-3), 105-119.
<https://www.sciencedirect.com/science/article/abs/pii/003442579190004P>
- Xiao, W., Xu, S., & He, T (2021). Mapping paddy rice with sentinel-1/2 and phenology-, object-based algorithm-A implementation in Hangjiahu plain in China using gee platform. *Remote Sensing*, 13(5), 990.
<https://www.mdpi.com/2072-4292/13/5/990>
- Xiao, X., Boles, S., Froking, S., Salas, W., Moore, I., Li, C., He, L., & Zhao, R (2002). Observation of flooding and rice transplanting of paddy rice fields at the site to landscape scales in China using VEGETATION sensor data. *International Journal of Remote Sensing*, 23(15), 3009-3022.
<https://www.tandfonline.com/doi/abs/10.1080/01431160110107734>
- Xiao, Xiangming, Boles, S., Froking, S., Li, C., Babu, J. Y., Salas, W., & Moore, B (2006). Mapping paddy rice agriculture in South and Southeast Asia using multi-temporal MODIS images. *Remote Sensing of Environment*, 100(1), 95-113.
<https://www.tandfonline.com/doi/citedby/10.1080/01431160110107734?scroll=top&needAccess=true>
- Xiao, Xiangming, Boles, S., Liu, J., Zhuang, D., Froking, S., Li, C., Salas, W., & Moore, B (2005). Mapping paddy rice agriculture in southern China using multi-temporal MODIS images. *Remote Sensing of Environment*, 95(4), 480-492.
<https://www.sciencedirect.com/science/article/abs/pii/S0034425705000209>
- Yan, L., & Roy, D. P (2015). Improved time series land cover classification by missing-observation-adaptive nonlinear dimensionality reduction. *Remote Sensing of Environment*, 158, 478-491.
<https://www.sciencedirect.com/science/article/pii/S0034425714004763>
- Yang, S., Shen, S., Li, B., Le Toan, T., & He, W (2008). Rice mapping and monitoring using ENVISAT ASAR data. *IEEE Geoscience and Remote Sensing Letters*, 5(1), 108-112.
<https://ieeexplore.ieee.org/document/4432591>
- You, J., Li, X., Low, M., Lobell, D., & Ermon, S (2017). Deep Gaussian process for crop yield prediction based on remote sensing data. 31st AAAI Conference on Artificial Intelligence, AAAI 2017, 4559-4565.
<https://ojs.aaai.org/index.php/AAAI/article/view/11172>
- Zhang, G., Xiao, X., Dong, J., Kou, W., Jin, C., Qin, Y., Zhou, Y., Wang, J., Menarguez, M. A., & Biradar, C (2015). Mapping paddy rice planting areas through time series analysis of MODIS land surface temperature and vegetation index data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 106, 157-171.
<https://www.sciencedirect.com/science/article/abs/pii/S0924271615001483>
- Zhang, M., & Lin, H (2019). Object-based rice mapping using time-series and phenological data. *Advances in Space Research*, 63(1), 190-202.
<https://www.sciencedirect.com/science/article/abs/pii/S0273117718307142>
- Zhao, R., Li, Y., & Ma, M (2021). Mapping paddy rice with satellite remote sensing:a review. *Sustainability*, 13(2), 503.
<https://www.mdpi.com/2071-1050/13/2/503>