



ORIGINAL RESEARCH PAPER

Detection of Rice Seedlings in UAV Image Using DenseNet Network

K. Borooshan¹, S. Behzadi^{*2}¹ Department of GIS and Remote Sensing, Faculty of Natural Resources and Environment, Islamic Azad University-Science and Research Branch, Tehran, Iran² Department of Surveying Engineering, Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran

ABSTRACT

Received: 17 June 2023
Reviewed: 20 July 2023
Revised: 07 August 2023
Accepted: 03 September 2023

KEYWORDS:

Deep Learning
DenseNet Network
Detection
Rice Seedlings
Remote SENSING
UAV

* Corresponding author

✉ behzadi@sru.ac.ir

☎ (+9821) 22970021

Background and Objectives: Rice, recognized as a strategic product for food security, holds a significant position not only in national economies but also globally. The importance of rice in meeting the dietary needs of populations and its role in achieving food security have led to a serious and substantial emphasis on this staple crop. In this regard, accurate and up-to-date data collection on the status of rice fields, especially information related to the quantity and quality of products, is crucial. Remote sensing technologies have been proposed as an efficient and effective solution in this context, enabling cost-effective data collection over extensive areas. Among these technologies, drones, due to their superior spatial resolution and higher precision in various monitoring tasks compared to satellites, offer relative advantages. This research employs an advanced approach called deep learning to estimate the cultivation area of rice seedlings or seedbeds using RGB images captured by drones in the Wufeng region of Taichung Province, Taiwan. The method leverages the capabilities of deep neural networks as an effective tool for analyzing complex data, achieving high accuracy in distinguishing various types of rice seedling or seedbed cultivation areas.

Methods: In this study, an advanced deep learning technique called DenseNet is employed for modeling and predicting the rice seedling or seedbed cultivation area in RGB images taken by drones. This method, utilizing complex algorithms and a set of processing layers, can extract high-level abstract concepts from the data. One unique feature of DenseNet is its use of a layer-to-layer algorithm instead of traditional layer concatenation approaches, resulting in reduced weights and parameters, as well as increased network efficiency. The ability of deep learning to process data in real-time immediately after image acquisition demonstrates the dynamic potential of DenseNet in quickly and accurately processing information. This capability allows real-time analysis and prediction of the rice seedling or seedbed cultivation area, providing the necessary information for optimal farm management.

Findings: The results obtained from this research demonstrate a confirmation of an accuracy exceeding 99.8% on validation data. This exceptionally high percentage indicates the remarkable capability of the DenseNet deep learning method in accurately estimating the cultivation area of rice seedlings or seedbeds. This high accuracy not only showcases the excellent performance of the model in identifying and predicting the rice cultivation area but also instills confidence in users. The presented model has successfully achieved precise detection and assessment of the rice seedling or seedbed cultivation area. This practical application provides valuable tools for farmers and farm managers to gain more accurate and timely awareness of their farm's status, facilitating better decision-making in cultivation and productivity.

Conclusion: This study convincingly shows the viability of employing drones in conjunction with sophisticated deep learning techniques for accurately estimating the cultivation area of rice seedlings or seedbeds. This approach proves feasible, especially in geographical areas similar to Wufeng in Taichung Province, Taiwan. The integration of drones and deep learning represents a notable technological leap in monitoring capabilities, offering substantial assistance to pertinent authorities involved in agricultural management and ensuring food security.



NUMBER OF REFERENCES

31



NUMBER OF FIGURES

7



NUMBER OF TABLES

0

مقاله پژوهشی

آشکارسازی نشاء برنج در تصویر پهپاد با استفاده از شبکه DenseNet

کیارش بروشان^۱، سعید بهزادی^{۲*}^۱ گروه سنجش از دور و سیستم اطلاعات مکانی، دانشکده منابع طبیعی و محیط زیست، دانشگاه آزاد- واحد علوم و تحقیقات، تهران، ایران^۲ گروه مهندسی نقشه برداری، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران

چکیده

پیشینه و اهداف: برنج به عنوان یک محصول استراتژیک در زمینه امنیت غذایی نه تنها در اقتصاد کلان جوامع بلکه در جایگاه جهانی نیز جایگاه ویژه‌ای دارد. اهمیت این محصول در تأمین نیازهای غذایی جمعیت و نقش آن در تحقق امنیت غذایی، اهمیت جدی و چشم‌گیری به آن اختصاص داده است. در این راستا، جمع‌آوری دقیق و به‌روز اطلاعات از وضعیت مزارع برنج، به ویژه اطلاعات مرتبط با کمیت و کیفیت محصولات، امری بسیار حیاتی و اساسی است. استفاده از تکنولوژی‌های سنجش از دور در این زمینه به‌عنوان یک راهکار کارآمد و موثر مطرح شده است. این تکنولوژی‌ها امکان جمع‌آوری اطلاعات پایشی از مزارع را با کمترین هزینه و در مناطق گسترده‌تر فراهم می‌آورند. از جمله این تکنولوژی‌ها، پهپادها به‌خاطر توانایی بهتر در تفکیک مکانی و دقت بالاتر در انجام پایش‌های مختلف نسبت به ماهواره‌ها، از مزایای نسبی برخوردارند. تحقیق حاضر از یک رویکرد پیشرفته به نام یادگیری عمیق استفاده می‌نماید تا به منظور تخمین سطح زیر کشت برنج نشاء یا نهال از تصاویر RGB گرفته شده از پهپادها در منطقه ووفنگ استان تایچانگ کشور تایوان، اقدام نماید. این روش از توانمندی‌های شبکه‌های عصبی عمیق به‌عنوان یک ابزار موثر برای تحلیل داده‌های پیچیده بهره‌مند شده و به دقت بالایی در تفکیک انواع مختلف سطح زیر کشت نشاء یا نهال برنج دست یافته است.

روش‌ها: در این تحقیق، از یکی از روش‌های پیشرفته یادگیری عمیق به نام DenseNet برای مدل‌سازی و پیش‌بینی سطح زیر کشت برنج نشاء یا نهال در تصاویر RGB گرفته شده از پهپادها استفاده شده است. این روش به وسیله الگوریتم‌های پیچیده و مجموعه‌ای از لایه‌های پردازشی، قابلیت استخراج مفاهیم انتزاعی سطح بالا را از داده‌ها دارد. یکی از ویژگی‌های منحصر به فرد DenseNet این است که از الگوریتم لایه به لایه (Layer-to-Layer) به جای رویکردهای سنتی که از ادغام لایه‌ها (layer concatenation) استفاده می‌کنند، بهره‌می‌برد. در این الگوریتم، هر لایه مستقل از سایر لایه‌ها کار می‌کند و به لایه‌های قبلی متصل می‌شود، که باعث کاهش تعداد وزن‌ها و پارامترها و همچنین افزایش کارایی شبکه می‌شود. استفاده از قابلیت یادگیری عمیق برای پردازش به‌هنگام داده‌ها به صورت فوری پس از اخذ تصاویر نشان‌دهنده قابلیت پویای DenseNet در پردازش اطلاعات به‌سرعت و با دقت بالا است. این امکان به ما اجازه را می‌دهد که در زمان واقعی به تحلیل و پیش‌بینی سطح زیر کشت برنج نشاء یا نهال پرداخته و اطلاعات مورد نیاز برای اداره بهینه مزارع را بدست آوریم.

یافته‌ها: نتایج به‌دست‌آمده از این تحقیق، تأییدگر دقت بسیار بالای ۹۹.۸ درصد بر روی داده‌های اعتبارسنجی نشان می‌دهد. این درصد بسیار بالا نشان‌دهنده توانایی فوق‌العاده روش یادگیری عمیق DenseNet در تخمین دقیق سطح زیرکشت برنج نشاء یا نهال می‌باشد. این دقت بالا نه تنها نشان‌دهنده عملکرد بسیار خوب مدل در شناسایی و پیش‌بینی میزان کاشت برنج، بلکه اطمینان بخش بوده و به کاربران اعتماد می‌بخشد. مدل ارائه‌شده توانسته است با دقت بسیار بالا به تشخیص و ارزیابی سطح زیر کشت برنج نشاء یا نهال بپردازد. این امر در عمل به کشاورزان و مدیران مزارع ابزاری ارزشمند ارائه می‌دهد تا به‌صورت دقیق‌تر و سریع‌تر از وضعیت مزرعه خود آگاه شوند و تصمیم‌گیری‌های بهتری در مدیریت کشت و بهره‌وری انجام دهند.

نتیجه‌گیری: در مجموع، این تحقیق نشان می‌دهد که استفاده از پهپادها به همراه روش‌های یادگیری عمیق، به منظور تخمین سطح زیرکشت برنج نشاء یا نهال با دقت بالا، در مناطقی چون ووفنگ استان تایچانگ تایوان، امکان‌پذیر است. این ارتقاء در تکنولوژی پایش می‌تواند به مدیران ذی‌ربط در امور کشاورزی و امنیت غذایی کمک زیادی کند.

تاریخ دریافت: ۲۷ خرداد ۱۴۰۲
تاریخ داوری: ۲۹ تیر ۱۴۰۲
تاریخ اصلاح: ۱۶ مرداد ۱۴۰۲
تاریخ پذیرش: ۱۲ شهریور ۱۴۰۲

واژگان کلیدی:

آشکارسازی
پهپاد
سنجش از دور
شبکه DenseNet
نشاء برنج
یادگیری عمیق

* نویسنده مسئول

behzadi@sru.ac.ir

۰۲۱-۲۲۹۷۰۰۲۱

مقدمه

(function) با باندهای قرمز و مادون قرمز نزدیک استفاده کردند که نتایج حاکی از میانگین خطای نسبی برای برنج بر محصول برابر با ۱۱.۵ و انحراف معیار ۹.۲ و ضریب تخمین ۰.۲ بود [۹]. ریاحی و همکاران با استفاده از سنجنده OLI ماهواره لندست-۸ و روش طبقه‌بندی حداکثر احتمال و NDVI اقدام به شناسایی و تفکیک اراضی زیر کشت برنج در ناحیه لنجانان استان اصفهان نمودند. نتایج حاکی از ضریب کاپا و صحت کلی ۰.۸ و ۹۰٪ در روش حداکثر احتمال و ۰.۹ و ۹۳٪ برای روش NDVI بود [۱۰، ۱۱]. دشتی و همکاران با استفاده از تصویر مرداد و شهریور ۱۳۹۵ سنتینل ۲ و روش‌های حداکثر احتمال، حداقل فاصله از میانگین و فاصله ماه‌الانوبی اقدام به تفکیک اراضی برنج و سویا در چهار حوضه آبخیز استان گلستان نمودند. نتایج حاکی از افزایش ۲۵٪ سطح زیر کشت نسبت به سال ماقبل و کاهش ۱۳.۸٪ محصول سویا است. همچنین ضرایب کاپا و صحت کلی برای روش منتخب حداکثر احتمال برابر با ۹۲٪ و ۹۵٪ ارزیابی نمودند [۱۲]. صدوقی و همکاران با استفاده از تصاویر مودیس و لندست ۸ اقدام به برآورد عملکرد برنج با استفاده از مدل SVM در استان گیلان نمودند. ایشان از تعداد ۲۰ کرت و اطلاعاتی از جمله عملکرد واقعی اندازه‌گیری میدانی را انجام داده و سپس آن‌ها را درون‌یابی نمودند. نتایج حاکی از همبستگی بالای ۸۰٪ بین عملکرد عملکرد واقعی و عملکرد برآوردی و ضریب تبیین ۶۵٪ بود. ایشان این مدل را جهت شبیه‌سازی عملکرد برنج مناسب ارزیابی نمودند [۱۳]. یاقوتی و همکاران با هدف برقراری رابطه رگرسیونی بین عملکرد ارقام محلی و شاخص‌های NDVI، SAVI، DVI و RVI مستخرج از تصویر لندست ۷ در شهرستان تفت مطالعه‌ای انجام دادند. ایشان شاخص NDVI را مناسب‌ترین شاخص در برآورد عملکرد ارقام محلی و پرمحصول دانسته و مقادیر ضریب تبیین ۰.۷ و ۰.۶ بین عملکرد عملکرد واقعی و عملکرد عملکرد برآوردی را نشان از کارایی مدل EF دانستند [۱۴، ۱۵]. گلپور و همکاران به تشخیص ارقام شلتوک، برنج قهوه‌ای و برنج سفید پرداختند. ایشان با استفاده از ۱۰۸ ویژگی بافتی تصاویر برنج، ماتریس هم‌وقوعی تصویر خاکستری را به شبکه عصبی پس‌انتشار خطا با یک لایه جهت طبقه‌بندی آموزش دادند. نتایج حاکی از دقت‌های ۹۲، ۹۷ و ۹۸ درصد برای شلتوک، برنج قهوه‌ای و برنج سفید بود. نتایج برای موارد ذکر شده با شبکه عصبی دو لایه برابر با ۹۶، ۹۷ و ۹۸ درصد بود. در نهایت ایشان دقت ۹۸٪ را با ۴۵ ویژگی برای برنج قهوه‌ای و دقت ۹۳٪ را با ۱۱ ویژگی برای برنج سفید و دقت ۹۶٪ را با ۱۸ ویژگی مناسب ارزیابی نمودند [۱۶]. جعفری و همکاران به برآورد ضریب گیاهی KC (Crop Coefficient) و شاخص سطح برگ (Leaf Area Index) در مراحل مختلف از دو قطعه شالیزار با استفاده از سنجنده OLI ماهواره لندست-۸ پرداختند. ایشان مقدار متوسط ضریب گیاهی را در مراحل نشاء، پنجه‌زنی، خوشه‌دهی، و رسیدن را به ترتیب ۰.۹۲/۰، ۰.۲۴/۱، ۰.۱۹/۱، ۰.۱۲/۱ به‌دست آوردند. که نشان از رابطه خطی بین این ضریب و شاخص تفاوت نرمال شده گیاهی (NDVI) به مقدار $r > 0.92$ است و این شاخص را برای برآورد ضریب گیاهی برنج مناسب دانستند. همچنین شاخص

مدیران حوزه امنیت غذایی نیاز دارند تا سطح زیر کشت محصولات زراعی به‌صورت مستمر و تقریباً به‌هنگام (real-time) در دسترس باشد تا بتوانند جهت تصمیم‌سازی و تصمیم‌گیری‌های بعدی از آن استفاده کنند. در چند دهه گذشته افزایش تولید کشاورزی مورد توجه قرار گرفته است. افزایش تقاضا و عدم گسترش زمین‌های کشاورزی، نیاز کشاورزی دقیق را به‌وجود آورده تا تولید و بهره‌وری بهبود یابد [۱]. متدهای متداول موجود در پردازش تصاویر ماهواره و پهپاد چند طیفی جهت پایش برنج، مبتنی بر فنومتریک و SMF (Shape model fitting) نیازمند سری زمانی هستند [۲]. بدین معنا که ابتدا باید زمان کاشت، داشت و برداشت طی شود و تصاویر پهپاد یا ماهواره آن اخذ شده و سپس برای تشخیص دوره رشد مبتنی بر سری زمانی، شاخص‌هایی نظیر سبزی‌نگی و غیره اعمال و با آستانه‌گذاری، تفکیک شوند [۳]. که عملکرد این روش‌ها بستگی به مدت زمان و دوره تکرار داده دارد و در مرحله رسیدگی برنج نیز به خوبی عمل نمی‌کند [۴]. در روش‌های یادگیری عمیق هر زمان که تصویر پهپادی یا ماهواره‌ای مهیا باشد می‌توان پردازش تصویر را اعمال و نتیجه را دریافت کرد [۵]. منتها باید داده‌های تاریخچه یک‌بار از قبل به مدل روش‌های یادگیری عمیق آموزش داده شده باشد [۶، ۷]. همچنین باید اشاره نمود که با توجه به تنوع محصولات زراعی و باغی، و همچنین تأثیرات آفات و تنش‌هایی مانند کم‌آبی، کود و بیماری، علناً نمی‌توان برای تک تک محصولات مدل‌های فیزیکی و تجربی ارائه داد و راهی جز استفاده از روش‌های یادگیری عمیق شاید بهترین انتخاب باشد. تاکنون تحقیقات مختلفی در مورد محصول برنج اعم از فنولوژی یا دوره رشد، کیفیت برنج، تخمین سطح زیر کشت، تهیه نقشه علف هرز، مصارف بیمه‌ای و غیره انجام شده است. در این بخش به برخی از این تحقیقات که با به‌کارگیری تصاویر ماهواره‌ای و پهپادی انجام شده پرداخته می‌شود.

علیزاده و همکاران با استفاده از داده‌های سری زمانی NDVI (Normalize) و (Difference Index) و (Land Surface Water Index) LSWI محصول ۱۶ روزه سنجنده مودیس با قدرت تفکیک ۲۵۰ متری برای تفکیک سه مرحله فنولوژی کاشت، سردهی و برداشت پرداختند. آن‌ها رفتار این دو شاخص را در فنولوژی برنج معکوس دانسته و با استفاده از ۱۸۳ نقطه کنترلی، خطای RMSE را برای مرحله نشاء‌کاری برابر ۷/۸ و مرحله برداشت را برابر با ۶.۶ ارزیابی نمودند. در نهایت، این روش را در مقیاس منطقه‌ای برای پایش برنج مناسب ارزیابی نمودند [۸]. ورما و همکاران از ۴ تصویر سنسور LISS-III ماهواره IRS-1D به برآورد میزان تولید برنج پرداختند. از ۴ تصویر موجود، ۲ تصویر مربوط به فصل برنج‌کاری و ۲ تصویر دیگر مربوط به فصل غیر برنج‌کاری بود. ایشان از آنالیز مؤلفه اصلی جهت کاهش بعد نمونه‌های ورودی به شبکه عصبی (Multi-layer perceptron) استفاده کردند. نتایج حاکی از دقت کلی ۹۸٪ و ضریب کاپا ۰.۹۶ روی مجموعه سنجشی بود. همچنین، جهت تفکیک برنج کم محصول از پر محصول از شبکه عصبی (Radial basis)

مرحله رسیدگی مناسب ارزیابی کرده و مقدار R^2 را در حدود ۰.۴ ارائه نمودند [۲۰، ۲۱]. هانگ و همکاران به بررسی دو روش شیء منا و یادگیری عمیق برای تهیه نقشه علف هرز مزارع برنج پرداختند. ایشان از تصاویر پهپاد با ۴ روز مختلف در دو کرت متفاوت با ارتفاع پروازی ۱۰ متر استفاده نمودند. همچنین از الگوریتم K-mean جهت بهبود استخراج رنگ و بافت برای متد شیء منا استفاده نمودند. ایشان با انتخاب محتاطانه ابرمتغییرها و تصاویر اندازه 1000×1000 پیکسل، صحت نهایی را برای روش شیء منا در حدود ۶۶٪ برآورد و برای روش یادگیری عمیق با شبکه تمام متصل و اعمال پیش آموزش انتقالی (Pre-train transfer learning) و سایر تنظیمات برای معماری VggNet را در حدود ۸۲٪ ارائه دادند [۲۲]. یانگ و همکاران اقدام به ترکیب روش یادگیری عمیق با شاخص‌های سبزیگی جهت تشخیص مزارع برنج در مقیاس بزرگ جهت مصارف بیمه‌ای در کشور تایوان استان تایچانگ، منطقه ووفنگ نمودند. ایشان از محدوده ۲۳۰ هکتاری، ۲ تصویر با ارتفاع پروازی ۲۳۰ متری در سال ۲۰۱۷ و ۲۰۱۹ برداشت کردند. ایشان سه شاخص سبزیگی (Excess Red) EXR، (Excess Green) EXG و (Excess Green minus Excess Red) را محاسبه و به مدل اضافه نمودند. در ادامه تصاویر را به کاشی‌های 480×480 پیکسلی تقسیم و ۵ کلاس را برچسب‌گذاری کردند و دو معماری FCN-AlexNet و SegNet را روی آن اعمال نمودند. نتایج حاکی از امتیاز ۰.۸ برای معماری FCN-AlexNet و ۰.۷۹ برای معماری SegNet بود [۴]. دویا و همکاران به پایش متغیرهای زیست توده جمعی و غلظت نیتروژن برگ محصول برنج توسط پهپاد پرداختند. ایشان داده زمینی زیست توده را با وزن کردن مقدار معینی از محصولی که در اجاق با دمای ۶۵ درجه برای ۴ روز متوالی که رطوبت خود را از دست داده به دست آوردند. همچنین برای مقدار نیتروژن از دستگاه SPAD بهره بردند. نتایج حاکی از قابلیت تخمین شبکه عصبی با میانگین ۸۰٪ و ۷۸٪ برای زیست‌توده و نیتروژن برگ است [۲۳]. ژائو و همکاران به تشخیص وجود یا عدم وجود برنج به کمک معماری U-net با استفاده از پهپاد دارای سنجنده چند طیفی که در ارتفاع ۱۰۰ متری تصویر برداری کرده بود پرداختند. نتایج حاکی از همبستگی بین تصاویر رنگی و چند طیفی با مقدار ۰.۹۴ و ۰.۹۲ بود [۲۴].

همان‌طور که در پیشینه بررسی شد، جهت پایش برنج عموماً برای تصاویر ماهواره از روش‌های سری زمانی بهره گرفته شده است. مشکل اصلی این روش آن است که برای پردازش، نیاز به سپری شدن زمان کاشت، داشت و برداشت است و بصورت به‌هنگام امکان استفاده از این روش نیست. همچنین این روش برای مرحله رسیدگی برنج نمی‌تواند به‌خوبی تفکیک را انجام دهد. و در مورد روش‌های مبتنی بر شبکه‌های عصبی، یادگیری ماشین و یادگیری عمیق معماری‌های متنوعی روی تصاویر پهپاد و ماهواره انجام پذیرفته است. هدف اصلی این پژوهش، استخراج سطح زیر کشت محصول نشاء یا نهال برنج به‌صورت به‌هنگام در تصویر پهپاد RGB با یکی از روش‌های یادگیری عمیق به‌نام DenseNet می‌باشد.

RGVI (Rice Growth Vegetation Index) را با ضریب همبستگی $r > 0.93$ در تعیین شاخص سطح برگ مناسب دانسته و در بیش از ۹۰ درصد تغییرات در مقدار شاخص سطح برگ را در مراحل رشد پیش‌بینی می‌کند [۱۷]. یانگ و همکاران برای شناسایی مراحل رشد برنج توسط رویکرد روش‌های یادگیری عمیق با پهپاد از ۶۷۲ پلات داده فنولوژی برداشت نموده و آن‌ها را به مقیاس BBCH تبدیل نمودند. بدین معنا که مرحله دانه را با ۰۰ و مرحله رسیدگی کامل و برداشت را با ۹۹ برچسب‌گذاری نمودند. ایشان مراحل رشد را به ۸ دسته: ۱- توسعه برگ، ۲- پنجه‌زنی، ۳- کشیدگی ساقه، ۵- ظهور سردهی، ۶- گل‌دهی، ۷- ایجاد میوه، ۸- رسیدن کامل طبقه‌بندی و مقیاس BBCH آن‌ها را نیز به ترتیب ۱۸، ۲۵، ۳۲، ۳۸، ۵۵، ۶۱ و ۸۶ برچسب‌گذاری نمودند. شایان‌ذکر است ایشان از مرحله ۴ داده برداشت نکردند. داده‌های مذکور توسط پهپادی با ۵ سنسور آبی، سبز، قرمز، لبه قرمز و مادون قرمز با ارتفاع پروازی ۲۹۳ متر به میانگین هر ۷ روز برداشت نمودند. در نهایت ایشان علاوه بر رویکرد SMF از ۵ معماری VGG16, Inception, ResNet, Inception-ResNet و شبکه عصبی ابداعی خویش را روی داده‌های ذکر شده اعمال که صحت و خطای مطلق میانگین آن‌ها به ترتیب ۰.۴ - ۰.۲، ۰.۲ - ۰.۸۱، ۰.۲ - ۰.۸۳، ۰.۲ - ۰.۸۱ و ۰.۲ - ۰.۸۳ اعلام نمودند [۱۸، ۱۹]. تری و همکاران از پهپاد با سنسور چند طیفی و روش یادگیری عمیق جهت ارائه یک رویکرد جدید برای ارزیابی کیفیت برنج استفاده کردند. ایشان از ۲ کرت تقریباً ۲ هکتاری ۸۰۰ تصویر برداشت و پس از اعمال فرآیندهایی از قبیل تنظیم کنتراست، بریدن تصویر به ابعاد 256×256 پیکسل و فیلترگذاری جهت بائری کردن تصویر، آن‌ها را توسط معماری LeNet-5 آموزش دادند. ایشان بهترین تنظیمات را توسط سعی و خطا بدست آورده و نتیجه نهایی را با دقت ۷۲/۰ ارائه دادند. همچنین، بزرگ بودن اندازه تصاویر پردازشی را بر ایجاد نویز و افزایش زمان پردازش در نتیجه نهایی تأثیرگذار دانستند و پیشنهاد داده‌افزایی (Data Augmentation) را مهم دانستند [۱]. یانگ و همکاران از شبکه عصبی کانولوشنال جهت تخمین مزارع برنج در زمان برداشت با کمک تصاویر پهپاد استفاده نمودند. ایشان در منطقه گوانگجو استان چین از ۱۶۰ هکتار تصویر برداری و سپس به ۶ کلاس: ۱- برگ باز نشده، ۲- حداکثر تعداد پنجه، ۳- گل‌دهی، ۴- مرحله رسیدگی آبکی (نرم)، ۵- مرحله شیری کامل و ۶- مرحله رسیدگی کامل در مقیاس BBCH برچسب‌گذاری نمودند. داده‌ها را با اندازه 156×156 پیکسل به معماری AlexNet آموزش داده و همچنین شاخص‌های سبزیگی را محاسبه نمودند. نتایج، حاکی از بیشترین دقت برای شاخص‌های EVI (Enhanced Vegetation Index)، SAVI (Soil-adjusted Vegetation Index)، OSAVI (Modified soil-adjusted Vegetation Index)، (Optimized Soil Adjusted Vegetation Index) و کمترین دقت مربوط به شاخص‌های GRVI (Ratio Vegetation Index Green)، WDRVI (Green Normalized Difference Vegetation Index) و NDVI (Wide Dynamic Range Vegetation Index) بود. ایشان شبکه عصبی کانولوشنالی را برخلاف شاخص‌های سبزیگی برای ارزیابی

روش تحقیق

منطقه مورد مطالعه


مجموعه داده‌هایی که از تصاویر ارتوموزاییک تشکیل شده، در گیت هاب از ۱۰ فوریه ۲۰۲۱ قابل دسترس است (<https://github.com/aipal-nchu/RiceSeedlingDataset>) این مجموعه داده، شامل ۱۳ تصویر از مراحل رشد است که در سال‌های ۲۰۱۸، ۲۰۱۹ و ۲۰۲۰ با سیستم مختصات TWD97/TM2 در زون ۱۲۱ با شماره EPSG:3826 زمین مرجع شده اند [۲۵]. شکل ۱، مسیر پروازی تصویر پهپاد از شالیزار برنج در تصویر ماهواره‌ای که توسط مرکز تحقیقات برنج تایوان TARI (Taiwan Agricultural Research Institute) در منطقه ووفنگ در استان تایچانگ تهیه شده است را نشان می‌دهد.

داده‌ها و اطلاعات مورد استفاده

تصویر پهپاد (2018-08-23_ARI80_20m_Orthomosaic) مورد استفاده در این پژوهش در تاریخ ۲۳ آگوست ۲۰۱۸ در ساعت ۰۷:۳۰ تا ۰۸:۰۰ صبح توسط سنجنده RGB ساخت شرکت DJI با برند فانتوم ۴ پرو با فاصله کانونی ۸.۸ میلی‌متر تهیه شده است (شکل ۲) [۲۵]. این پهپاد با ارتفاع پروازی اسمی ۲۰ متری و قدرت تفکیک مکانی ۳.۵ میلی‌متری با سرعت ۱.۸ تا ۲.۲ متر بر ثانیه اقدام به ثبت تصویر نمود.

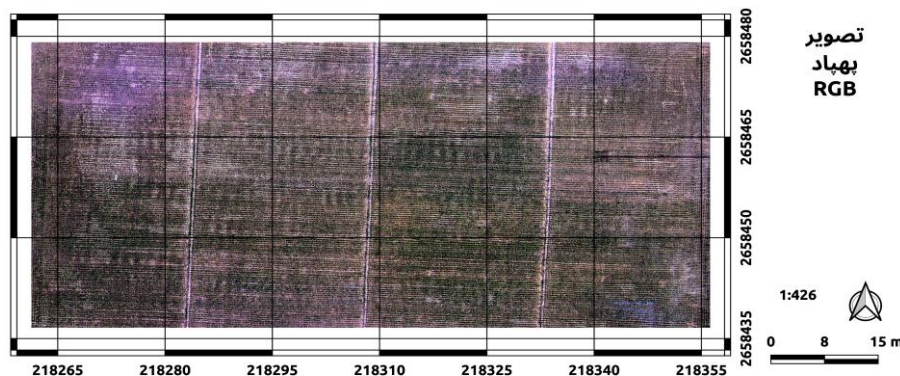
روش شناسی

در این پژوهش، جهت استخراج سطح زیر کشت برنج، ابتدا تصویر پهپادی RGB که به‌صورت رایگان در دسترس عموم است، از گیت هاب (<https://github.com/aipal-nchu/RiceSeedlingDataset>) دانلود و سپس در نرم‌افزار QGIS هر باند آن به‌صورت جداگانه نرمال و در نهایت به یکدیگر چسبانده شدند. سپس یک شبکه مشبک (Mesh grid) برای کل تصویر ساخته شد. ابعاد این شبکه مشبک باید به گونه‌ای باشد که تعداد مشخصی از پیکسل‌ها در آن جای بگیرد و این تعداد پیکسل بر اساس کیفیت تصویر، دقت خروجی مورد نیاز و غیره متفاوت و بر اساس تجربه است. در ادامه، مناطقی که دارای خالص‌ترین محدوده نشاء برنج (Rice Seedling) و خاک (Arable Land) می‌باشند، از تصویر برش می‌خورند و به‌عنوان نمونه‌های آموزشی به شبکه DenseNet ارائه می‌شوند. منتها قبل از این مرحله این نمونه‌ها به دو بخش آموزشی و آزمایشی به نسبت ۷۵ به ۲۵ تقسیم‌بندی می‌شوند. در مرحله بعد، پس از ساخت مدل باید به کل تصویر اعمال شود ولی چون سیستم پردازشی برای این کار ضعیف بود، ابتدا تصویر پهپاد به ۱۰۹ تصویر کوچک‌تر توسط شبکه مشبک تقسیم‌بندی شد و پس از اعمال مدل و طبقه‌بندی، در نهایت به یکدیگر چسبانده شدند. روند نما (Flowchart) پیشنهادی جهت استخراج سطح زیر کشت نشاء برنج در تصویر پهپادی RGB در شکل ۳ نشان داده شده است.



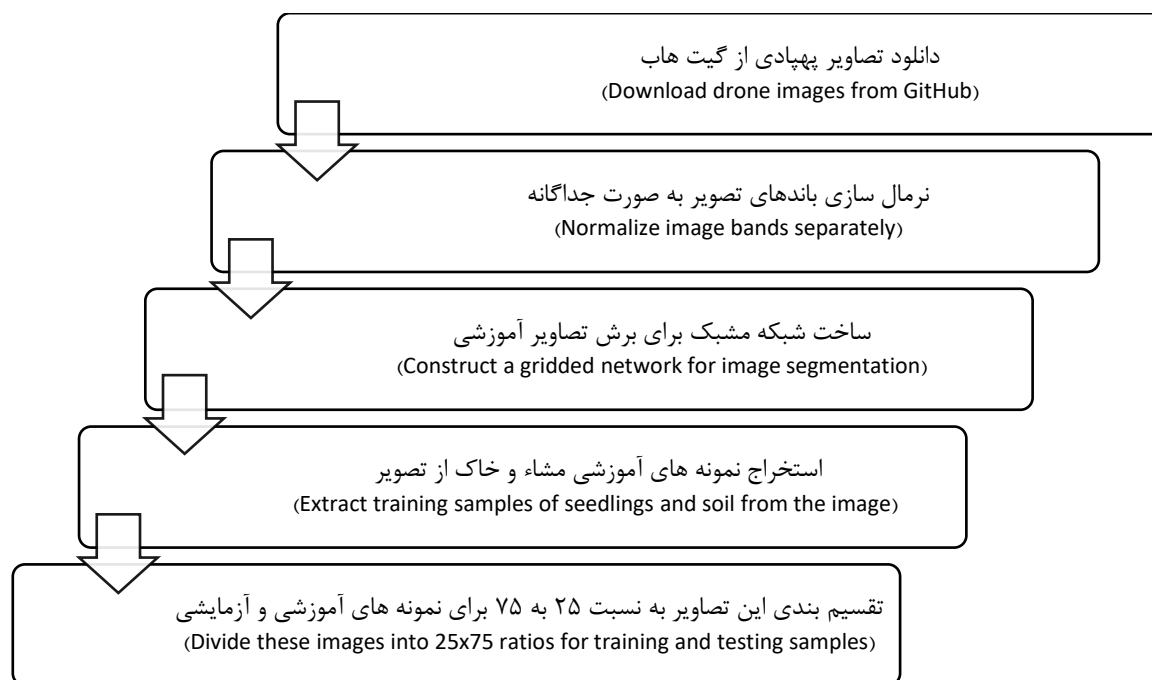
شکل ۱: کرت برنج منطقه مطالعاتی در کشور تایوان، استان تایچانگ [۲۵]

Fig. 1: Rice fields of the study area in Taiwan, Taichung Province



شکل ۲: تصویر پهپادی RGB از منطقه مورد مطالعه [۲۵]

Fig. 2: RGB image of the study area acquired by UAV



شکل ۳: روندنمای استخراج سطح زیر کشت برنج از تصویر پهپاد RGB
Fig. 3: Flowchart of extraction of the area under rice cultivation from the RGB UAV image

پیش پردازش

در بخش آماده سازی داده ها، موضوع تغییر مقیاس از موضوعات پراهمیت در حوزه یادگیری ماشین است و معمولاً به دو روش استانداردسازی (Standardization) و نرمال سازی (Normalization) صورت می گیرد [۲۶، ۲۷]. در استانداردسازی تبدیلی (Transformation)، داده ها بدون مقیاس با میانگین صفر و انحراف معیار برابر با یک نرمال می شوند. رعایت ساختار داده استاندارد جزء مهم ترین بخش های یک معماری می باشد [۲۸، ۲۹]. معماری DenseNet به گونه ای طراحی شده که ورودی آن به صورت تصاویری با ابعاد $n \times n$ پیکسل است. نویسنده، برای سهولت کار، از این پس این تصاویر را به نام پنجره داده نام گذاری می کند. مقدار n ، رابطه کاملاً مستقیمی با کیفیت قدرت تفکیک مکانی سنجنده دارد. هر چه سنجنده در ارتفاع پروازی کمتری تصویر برداشت کند، کیفیت تصویر بهتر است. مسلماً مقدار n هر چه بیشتر باشد، نتیجه خروجی مدل حاصل از معماری روش های یادگیری عمیق، بهتر و قابل اطمینان تر و احتمالاً هزینه پردازشی نیز بالاتر خواهد بود [۳۰].

جهت برش پنجره داده از تصویر پهپاد از یک شبکه مشبک که دارای تعداد مشخصی از پیکسل است، استفاده شد (شکل ۴). نکته خیلی مهم دیگر، خالص بودن پنجره داده است. بدین معنا که پیکسل های برداشت شده هر کلاس، باید دقیقاً مربوط به همان کلاس باشد. وجود پیکسل هایی از کلاس های دیگر به شدت روی نتیجه نهایی اثرگذار خواهند بود. انتخاب پنجره داده های خالص رابطه مستقیمی با ارتفاع پروازی سنجنده دارد. از طرفی دیگر، اگر تعداد n از مقدار معینی کمتر شود، اصلاً معماری DenseNet اجرا نخواهد شد. بنابراین، باید مقدار n در پنجره داده و تعداد پنجره داده، در مقدار بهینه خود باشد که بتوان


هم از پس هزینه پردازشی برآمد و هم مهم تر از همه بتوان تعداد بهینه ای از پنجره داده را مهیا نمود. نویسنده، با صرف زمان بسیار و با سعی و خطا به این تعداد بهینه از ابعاد پنجره داده، دست یافته است. در این پژوهش به غیر از داده تصویر رنگی پهپاد، هیچ گونه داده دیگری وجود ندارد. بنابراین، با توجه به شواهد بصری از تصویر رنگی، اقدام به نمونه برداری برای پنجره داده شد. بطور کل ۲، عارضه نهال یا نشاء برنج و خاک جهت استخراج پنجره داده در نظر گرفته شد. برای انتخاب پنجره داده، با توجه به ارتفاع بالای سنجنده، پنجره داده هایی انتخاب شدند که قسمت اعظم آن توسط نهال یا نشاء برنج پوشیده شده بود. همچنین به علت کیفیت پایین تصویر امکان برداشت پنجره داده برای عارضه سایه وجود نداشت.

معماری DenseNet

از شبکه های عصبی می توان به شبکه عصبی کانولوشن نام برد که در تشخیص و پردازش تصویر، فیلم، سیستم های توصیه کننده و پردازش زبان طبیعی کاربرد دارند. DenseNet (شکل ۵) یکی از شبکه های نورونی کانولوشن است که توسط گروه هایی از دانشگاه های Cornwell, Tsinghua و هوش مصنوعی فیس بوک در سال ۲۰۱۷ ارایه شد (<http://archiaai.ir/introduction-cnns-architectures>). با استفاده از ایده skip connection ورودی بلاک های موجود در این معماری از تمامی لایه های قبل به دست می آید و بین هر دو بلاک عملیات Pooling و غیره توسط بلوک Transition انجام می پذیرد [۲۲، ۳۱]. این عمل، باعث افزایش کارایی شده و اطلاعات می توانند در انتشار رو به عقب به صورت مستقیم در شبکه حرکت کنند (<https://alisterta.github.io/2017-07-16>).

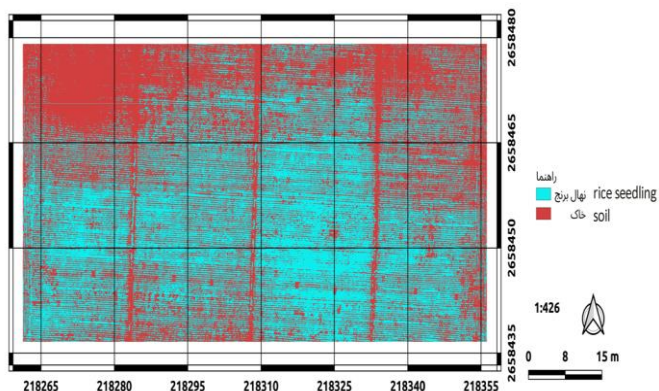


شکل ۴: نمونه‌هایی از پنجره داده برای نشاء برنج
Fig. 4: Examples of data windows for rice planting




شکل ۶: مقادیر صحت روی داده‌های اعتبارسنجی در دوره‌های تکرار
Fig. 6: Accuracy values on validation data in iteration periods

مدل ساخته شده توسط معماری DenseNet روی کل تصویر اعمال شد و نتیجه در شکل ۷ نمایش داده شده است. نتایج حاصله، با توجه به ارتفاع بالای سنجنده و خالص نبودن کلاس‌های پنجره داده، در مجموع مناسب ارزیابی می‌شود. البته برخی خطاها و طبقه‌بندی‌های اشتباه نیز وجود دارد که به علت کم بودن تعداد آن‌ها نسبت به کل تصویر و کیفیت تصویربرداری، قابل اغماض است. همچنین، برخی از اشتباهات در طبقه‌بندی، مربوط به سایه‌ها است. از آنجایی که این سایه‌ها کم و کوچک بوده و در پنجره داده جا نگرفته و امکان تهیه تعداد مناسبی از این داده وجود نداشت، از ساخت این مجموعه داده صرف‌نظر شد. این معماری در شناسایی سایه و برخی از نهال‌ها یا نشاء‌های برنج که کوچک بودند به خوبی عمل نکرده، که علت آن عدم آموزش این نوع از عارضه به مدل، ارتفاع بالای سنجنده و ساعت تصویربرداری (۰۷:۳۰ تا ۰۸:۰۰ صبح) است.



شکل ۷: نقشه نهایی طبقه‌بندی سطح زیر کشت نشاء برنج در تصویر RGB
Fig. 7: The final classification map of rice planting area in the RGB image

از ویژگی این معماری نسبت به معماری‌های دیگر آن است که به دلیل بهینه‌سازی موجود، ویژگی‌های هر لایه بسیار کمتر شده است. به عبارت دیگر عرض شبکه کمتر و عمق آن افزایش یافته است. این معماری، باعث آن می‌شود تا ویژگی‌های سطح پایین مثل بافت مورد توجه بیشتری نسبت به ویژگی‌های سطح بالا مانند لبه‌ها قرار گیرد. چون لایه‌ها به هم متصل‌اند، شبکه می‌تواند یاد بگیرد که از ویژگی‌های سطح پایین و یا ترکیبی از ویژگی‌های بالا و پایین را در نظر بگیرد.



شکل ۵: معماری مدل DenseNet [۲۲]
Fig. 5: Architecture of DenseNet model

نتایج و بحث

در این تحقیق، جهت استخراج سطح زیر کشت نهال برنج از تصویر پهپاد RGB و الگوریتم یادگیری عمیق به نام DenseNet استفاده گردید. برای این منظور، جهت به دست آوردن نمونه‌های آموزشی، پس از نرمال کردن تصویر، اقدام به بریدن نمونه‌های آموزشی نشاء برنج و خاک توسط شبکه مشبک شد. پس از تقسیم‌بندی این نمونه‌ها به نسبت ۷۵ به ۲۵ به معماری DenseNet آموزش داده و در نهایت مدل ساخته شده روی کل تصویر پهپاد پیاده‌سازی انجام گرفت. سیستم پردازشی در این تحقیق یک لپ‌تاپ با پیکربندی ۵ هسته سی‌پی‌یو، ۶ گیگ رم و کارت گرافیک Nvidia GeForce 840m با ۴ گیگ رم بود. پس از جمع‌آوری مجموعه پنجره داده، ساخت مدل زمان زیادی به خود اختصاص نداد و با هفت دوره تکرار (Epoch) به صحت ۸/۹۹ درصد روی داده‌های اعتبارسنجی رسید. ولی اعمال مدل بر روی کل تصویر حدود ۴۰ ساعت زمان برد. مقادیر صحت روی داده‌های اعتبارسنجی در هر دوره تکرار که بیشترین مقدار را داشت در شکل ۶ نمایش داده شده است.

نتیجه‌گیری

این مطالعه، به منظور استخراج سطح زیرکشت برنج نشاء یا نهال با استفاده از تصویر پهپاد RGB از فانتوم ۴ پرو در منطقه ووفنگ استان تایچانگ تایوان انجام شد. پس از انجام پیش‌پردازش‌های مورد نیاز بر روی تصاویر، از روش یادگیری عمیق DenseNet استفاده شد و سطح زیرکشت با دقت بالغ ۹۹.۸٪ بر روی داده‌های اعتبارسنجی شناسایی شد. یانگ و همکاران در همین منطقه با پهپاد و سنجنده مشابه در منطقه‌ای وسیع‌تر با پیکسل‌سایز ۳.۵ سانتی‌متری جهت استخراج برنج در شالیزار از دیگر عوارض مانند ساختمان، اتوبان و غیره استفاده نمودند [۴]. نتایج F1-score برای معماری FCN-AlexNet برابر ۰.۸ و برای SegNet برابر ۰.۷۹ و برای FCN-AlexNet با ترکیب RGB+ExGR برابر ۰.۷۸ به‌دست آوردند. ایشان این روش‌ها را ۱۰ تا ۱۵ برابر نسبت به روش بیشترین شباهت سریع‌تر و خطای اشتباه کمتر دانستند. جهت ایجاد یک بانک اطلاعاتی برای استفاده در روش‌های یادگیری عمیق، تصویری از پهپادها با ویژگی‌های خاص توصیه می‌شود. این تصاویر باید دارای چند ویژگی از جمله طیف‌های مختلف و رنگی باشند. همچنین، تصاویر باید از ارتفاع ۷ متری از سطح زمین گرفته شوند. این ارتفاع ممکن است برای استخراج و تحلیل دقیق تصاویر و مشاهده سطح زیرکشت مفید باشد. این تصاویر، می‌توانند به‌عنوان یک منبع داده مهم برای آموزش مدل‌های یادگیری عمیق مورد استفاده قرار گیرند. در واقع، تصاویر پهپاد با این ویژگی‌ها می‌توانند به تحلیل محصولات کشاورزی و باغی در طول یک سال زراعی و در زمین‌شناسی، منابع طبیعی، پسماند و غیره کمک زیادی کنند. همچنین، تنوع در تعداد و نوع عوارض در این تصاویر نشان از اهمیت بیشتر این پیشنهاد دارد. به عبارت دیگر، جمع‌آوری تصاویر تنوع بالا و تغییرات مکرر در شرایط مزرعه و زمین‌شناسی را برای تحلیل دقیق‌تر و ارتقاء کارایی روش‌های یادگیری عمیق ارائه می‌دهد. باید توجه داشت که در سال زراعی در حال برداشت، باید آفت و تنش هم در مزرعه وجود داشته باشد تا بتوان پایگاه داده‌ای جامع شامل آفت و تنش نیز برای همان سال زراعی ایجاد نمود. در غیر این صورت، فقط می‌توان به تفکیک فنولوژی محصول پرداخت و برای سال زراعی بعدی از سایت‌هایی تصویربرداری نمود که دارای آفت و تنش باشند. این اطلاعات اضافی، به ما کمک می‌کند تا داده‌هایی جامع‌تر و کاربردی‌تر برای آموزش و بهبود روش‌های یادگیری عمیق ارائه دهیم تا در شرایط واقعی مرتبط با زمین‌شناسی و کشاورزی عملکرد بهتری داشته باشند. برای این تحقیق، محدودیت‌هایی نیز وجود دارد. مهم‌ترین آن محدودیت‌های دسترسی به داده می‌باشد. البته ممکن است محدودیت‌هایی در دسترسی به تصاویر پهپاد چند طیفی و رنگی با ارتفاع ۷ متر از سطح زمین وجود داشته باشد. ولی این محدودیت‌ها می‌توانند به دلیل محدودیت‌های مالی یا قوانین محلی باشند. محدودیت‌های زمانی نمونه دیگری از محدودیت‌ها می‌باشد. تصاویر پهپاد و داده‌های مورد نیاز ممکن است برای یک بازه زمانی محدود در دسترس باشند و نتایج تحقیق ممکن است در زمان‌بندی محدود ارائه شود.

محدودیت‌های مالی نیز برای این انجام این تحقیق ممکن است وجود داشته باشد. محدودیت‌های مالی ممکن است از جمع‌آوری داده‌های بیشتر و تحلیل دقیق‌تر داده‌ها جلوگیری کنند.

مشارکت نویسندگان

در این مقاله نویسندگان به نسبت سهم برابر مشارکت داشته‌اند.

تشکر و قدردانی

نویسندگان از آقای دکتر یانگ و همکاران ایشان است، که با به اشتراک‌گذاری رایگان تصویر پهپاد زمینه را برای نگارش این مقاله مهیا نمودند، تشکر می‌نمایند. همچنین، نویسنده از سرکار خانم دکتر نادیا عباس‌زاده تهرانی و تمام اساتیدی که با سعه صدر تجربیات خویش را در اختیار قرار دادند کمال قدردانی را از آن فرهیختگان اعلام می‌دارد.

تعارض منافع

«هیچگونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مأخذ

- [1] Tri NC, Van Hoai T, Duong HN, Trong NT, Van Vinh V, Snaasel V, editors. A novel framework based on deep learning and unmanned aerial vehicles to assess the quality of rice fields. *Advances in Information and Communication Technology: Proceedings of the International Conference, ICTA 2016; 2017: Springer.*
- [2] Norouzi E, Behzadi S. Evaluating machine learning methods and satellite images to estimate combined climatic indices. *International Journal of Numerical Methods in Civil Engineering.* 2019;4(1):30-8. <https://doi.org/10.52547/nmce.4.1.30>
- [3] Mirzapour S, Alemi Safaval P, Karimi S, Behzadi S, Kheirkhah Zarkesh M, Zavar H, et al. Identification and Separation of Rice Fields Using Remote Sensing. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences.* 2023;10:509-14. <https://doi.org/10.5194/isprs-annals-X-4-W1-2022-509-2023>
- [4] Yang Q, Shi L, Han J, Yu J, Huang K. A near real-time deep learning approach for detecting rice phenology based on UAV images. *Agricultural and Forest Meteorology.* 2020;287:107938. <http://dx.doi.org/10.1016/j.agrformet.2020.107938>
- [5] Jalilzadeh A, Behzadi S. Machine learning method for predicting the depth of shallow lakes using multi-band remote sensing images. *Journal of Soft Computing in Civil Engineering.* 2019;3(2):54-64. <https://doi.org/10.22115/scce.2019.196533.1119>
- [6] Norouzi E, Behzadi S. The Feasibility of Machine-learning Methods to Extract the Surface Evaporation Quantity using

- [16] Golpour I, Amiri Parian J, Amiri Chayjan R, Khazaei J. Recognition of Paddy, Brown Rice and White Rice Cultivars Based on Textural Features of Images and Artificial Neural Network. *J Agric Mach.* 2015;5(1):73–81. <https://doi.org/10.22067/jam.v5i1.21550>
- [17] Jafari sayadi fatemeh, Gholami Sefidkouhi MA, ziyaeetabar ahmadi mirkahlegh. Leaf Area Index and Crop Coefficient Estimation from Operational Land Imager (OLI) Sensor Data. *J Water Res Agric.* 2018;32(3):395–404. <https://doi.org/10.22092/jwra.2018.117797>
- [18] Yang M-D, Tseng H-H, Hsu Y-C, Tsai HP. Semantic segmentation using deep learning with vegetation indices for rice lodging identification in multi-date UAV visible images. *Remote Sensing.* 2020;12(4):633. <https://doi.org/10.3390/rs12040633>
- [19] Mahjoobi M, Behzadi S. Solar desalination site selection on the Caspian Sea coast using AHP and fuzzy logic methods. *Modeling Earth Systems and Environment.* 2022:1-9. <https://doi.org/10.1007/s40808-022-01418-2>
- [20] Yang Q, Shi L, Han J, Zha Y, Zhu P. Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images. *Field Crops Res.* 2019;235:142-53. DOI: 10.1016/j.fcr.2019.02.022
- [21] Jalilzadeh A, Behzadi S, editors. Flood Mapping and Estimation of Flood Water-Level Using Fuzzy Method and Remote Sensing Imagery (Case Study: Golestan Province, Iran). *Forum Geografic*; 2020: University of Craiova, Department of Geography. <https://forumgeografic.ro/2021/2698/>
- [22] Huang H, Lan Y, Yang A, Zhang Y, Wen S, Deng J. Deep learning versus Object-based Image Analysis (OBIA) in weed mapping of UAV imagery. *IJRS.* 2020;41(9):3446-79. <https://ui.adsabs.harvard.edu/abs/2020IJRS...41.3446H/abstr act>
- [23] Devia CA, Rojas Bustos JP, Petro EE, Mondragon IF, Patino D, Rebolledo C, et al. Aerial monitoring of rice crop variables using an UAV robotic system. 2019;2:97-103. <https://doi.org/10.5220/0007909900970103>
- [24] Rao DS, Kavya N, Kumar SN, Venkat LY, Kumar NP. Detection and classification of rice leaf diseases using deep learning. *Int J Adv Sci Tech.* 2020;29(3):5868-74. <http://sersec.org/journals/index.php/IJAST/article/view/6626>
- [25] Yang M-D, Tseng H-H, Hsu Y-C, Yang C-Y, Lai M-H, Wu D-H. A UAV open dataset of rice paddies for deep learning practice. *Remote Sensing.* 2021;13(7):1358. <https://doi.org/10.3390/rs13071358>
- [26] Behzadi S. An intelligent location and state reorganization of traffic signal. *Geodesy and Cartography.* 2020;46(3):145-50. <https://doi.org/10.3846/gac.2020.10806>
- Satellite Imagery. *Journal of Electrical and Computer Engineering Innovations (JECEI).* 2021;9(2):229-38. <https://doi.org/10.22061/jecei.2021.7563.406>
- [7] Jafarian H, Behzadi S. Evaluation of PM2. 5 emissions in Tehran by means of remote sensing and regression models. *Pollution.* 2020;6(3):521-9. DOI: 10.22059/poll.2020.292065.706
- [8] Alizadeh H, Kheirkhah M, Abkar A, Dashti-Ahangar A. Monitoring rice paddy phenology using time series images of MODIS sensor of TERRA satellite. *Geomatic Conference, 2013, Tehran, Iran.* [In Persian].
- [9] Verma D, Singh AN, Kalubarme MH, Saroha GP, Sharma R, Brajendra. Varietal discrimination, acreage estimation and yield prediction of basmati aromatic rice in north-western India using satellite data. In: *Remote Sensing of Agriculture and Land Cover/Land Use Changes in South and Southeast Asian Countries.* 2022. p. 163–86. DOI:10.1007/978-3-030-92365-5_9
- [10] Riahi V, Zeaiean Firouzabadi P, Azizpour F, Darouei P. Identification and investigation of the area under cultivation in Lenjanat using Landsat 8 satellite images TT. *jgs.* 2019 Mar 1;19(52):147–69. [In Persian]. DOI: 10.29252/jgs.19.52.147
- [11] Chatsimab Z, Alesheikh AA, Voosoghi B, Behzadi S, Modiri M, editors. Development of a Land Subsidence Forecasting Model Using Small Baseline Subset—Differential Synthetic Aperture Radar Interferometry and Particle Swarm Optimization—Random Forest (Case Study: Tehran-Karaj-Shahriyar Aquifer, Iran). *Dokl Earth Sci*; 2020: Springer. https://ui.adsabs.harvard.edu/link_gateway/2020DokES.494..718C/doi:10.1134/S1028334X20090056
- [12] Kamkar B, Dashtimarvili M, Kazemi H. Detection of rice and soybean grown fields and their related cultivation area using Sentinel-2 satellite images in summer cropping patterns to analyze temporal changes in their cultivation area (Case study: four watershed basins of Golestan Province). *J Water Soil Conserv.* 2019;26(1):151–67. [In Persian]. DOI: 10.22069/JWSC.2019.15246.3044
- [13] Sadooghi L, Homae M, Noroozi A, Asadi Kapourchal S. Estimating rice yield using VSM model and satellite images in Guilan province. *Cereal Res.* 2017;6(3):397–410. In Persian. DOR: 20.1001.1.22520163.1395.6.3.10.2
- [14] Yaghouti H, Amiri E. Application of satellite imagery and remote sensing technology to estimate rice yield. *J Water Soil Resour Conserv.* 2018;7(3):55–69. [In Persian]. DOR: 20.1001.1.22517480.1397.7.3.4.2
- [15] Shiravand H, Khaledi S, Behzadi S, Sanjabi, H. Monitoring and Assessing the Changes in the Coverage and Decline of Oak Forests in Lorestan Province using Satellite Images and BFAST Model. *Journal of Applied researches in Geographical Sciences.* 2020;20(57):265-80. DOI: 10.29252/jgs.20.57.265



تخصصی ایشان یادگیری ماشین، مکان‌یابی و طراحی سایت با فریم‌ورک Django است.

Borooshan, K. Department of GIS and Remote Sensing, Faculty of Natural Resources and Environment, Islamic Azad University-Science and Research Branch, Tehran, Iran

✉ kiarash.borooshan@gmail.com



سعید بهزادی دارای مدرک دکتری تخصصی مهندسی عمران - نقشه برداری (گرایش سامانه اطلاعات مکانی) از دانشگاه صنعتی خواجه نصیر از تهران می‌باشد. از سال ۱۳۹۵ تاکنون به عنوان استادیار در گروه مهندسی عمران - نقشه

برداری دانشگاه تربیت دبیر شهید رجایی مشغول به فعالیت می‌باشند. ایشان تا کنون موفق به چاپ بیش از ۱۰۰ مقاله در مجلات و کنفرانس‌های معتبر بین‌المللی شده‌اند. زمینه‌های تخصصی ایشان عبارتند از: هوش مصنوعی، GIS پزشکی، کاربرد یادگیری ماشین و هوش مصنوعی در GIS.

Behzadi, S. Assistant Professor at the Department of Surveying Engineering, Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran

✉ behzadi@sru.ac.ir

[27] Behzadi S, Alesheikh AA. A Pseudo Genetic Algorithm for solving best path problem. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2008;3(1).
https://www.isprs.org/proceedings/xxxvii/congress/2_pdf/2_wg-ii-2/15.pdf

[28] Mousavi Z, Behzadi S. Geo-Portal Implementation with a Combined Approach of AHP and SWOT. International Journal of Natural Sciences Research. 2019;7(1):23-31.
<https://doi.org/10.18488/journal.63.2019.71.22.31>

[29] Mousavi Z, Behzadi S. Introducing an Appropriate Geoportals Structure for Managing Wildlife Location Data. International Journal of Natural Sciences Research. 2019;7(1):32-48.
<https://ideas.repec.org/a/pkp/ijonsr/v7y2019i1p32-48id2376.html>

[30] Behzadi S, Jalilzadeh A. Introducing a Novel Digital Elevation Model Using Artificial Neural Network Algorithm. Civil Engineering Dimension. 2020;22(2):47-51.
<https://doi.org/10.9744/ced.22.2.47-51>

[31] Hamoudzadeh A, Behzadi S. Predicting user's next location using machine learning algorithms. Spatial Information Research. 2021;29(3):379-87.
DOI: 10.1007/s41324-020-00358-2

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES

کیارش بروشان دارای مدرک کارشناسی ارشد سنجش از دور و سیستم اطلاعات مکانی (گرایش آب و خاک) از دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران می‌باشد. زمینه‌های

Citation (Vancouver): Borooshan K, Behzadi S. [Detection of Rice Seedlings in UAV Image Using DenseNet Network]. *J. RS. GEOINF. RES.* 2023; 1(2): 217-226

 <https://doi.org/10.22061/jrsg.2023.2020>



COPYRIGHTS

© 2023 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) (<https://creativecommons.org/licenses/by-nc/4.0/>)