

## ارائه یک روش جدید مبتنی بر شبکه عصبی برای تشخیص فنولوژی گیاه گندم با استفاده از داده های

### سننیل ۲

#### خدیجه آقاجانی

استادیار، دانشکده فنی مهندسی دانشگاه مازندران، بابلسر

#### چکیده

در این مقاله قابلیت امکان تشخیص مراحل اصلی رشد گیاه گندم با استفاده از داده های سننیل ۲ در مناطق دزفول، شهید کریمی و عجیرب بررسی شده است. در این تحقیق از نحوه تغییر شاخص نرمال شده تفاوت پوشش گیاهی (NDVI) در زمان رخداد فاز های اصلی گیاه برای تشخیص مرحله رشد استفاده شده است. با توجه به برجسب های منتسب به هر فاز، در این پژوهش، پنج فاز شامل سبز شدن، پنجه زنی، آبستنی، توسعه دانه و رسیدگی در نظر گرفته شده است. در ابتدا با توجه به موجود نبودن این شاخص برای برخی زمینها در زمانهای ابری، درونبایی انجام شده است. سپس جهت از بین بردن تغییرات شدید نامطلوب که می تواند عملیات تشخیص را کمی دچار مشکل کند هموار سازی سیگنال انجام میشود. در ادامه با استفاده از یادگیری ماشین، زمان های وقوع فازهای اصلی رشد گیاه با توجه به نمودار هموار شده تخمین زده می شود. جهت ارزیابی روش از معیار ریشه میانگین مربعات خطا (RMSE) به ازای هر فاز استفاده شده است. با توجه به مشاهدات انجام شده مقدار این خطا برای فازهای اول، دوم، سوم، چهارم و پنجم به ترتیب ۳/۲۴، ۲/۸۲، ۳/۱، ۲/۶۵ و ۳/۱ روز است.

کلید واژه — تشخیص مرحله رشد، هوش مصنوعی، یادگیری ماشین، شبکه های عصبی.

#### ۱. مقدمه

یکی از مسایل مهم در کشاورزی تشخیص مرحله رشد گیاهان زراعی است که به کمک آن می توان تصمیمات بهتری را در جهت عملیاتی نظیر آبیاری، سم پاشی، کود دهی و سایر مسایل اتخاذ نمود [۱]. برای گندم، بعنوان مثال افزودن نیتروژن در زمان پنجه زنی یا شخم زنی موثر است حال آنکه اگر در زمان ظهور سنبله افزایش نیتروژن انجام شود منجر به هدر رفتن آن و همینطور آسیب های زیست محیطی می شود [۲]. جهت افزایش کیفیت، بهتر است افزودن نیتروژن در زمان گل دهی انجام شود [۳]. بعنوان مثال دیگر، بررسی شده است که بهتر است هر گونه عملیات قارچ کشی در زمان آغاز ظهور سنبله متوقف شود [۴]. یکی دیگر از مسائل مهم آبیاری است که بهتر است قبل از گلدهی انجام شود. در غیر اینصورت، عبارتی انجام آبیاری بعد از فاز گلدهی، پیامدهایی نظیر کاهش کارایی آبیاری و افزایش بیماری های قارچی [۳] محتمل است. با این حال، مشاهده

شده که در دمای بسیار بالا پس از گلدهی، استفاده از آبیاری در مقیاس کم از زمان گلدهی تا خمیر نرم می تواند برای به حداکثر رساندن عملکرد نهایی دانه، مطلوب باشد [۵] با توجه به مواردی از این دست می توان به اهمیت تشخیص فاز رشد گیاه پی برد. عبارتی ساده تر، شناسایی موفق و پایش مراحل رشد، به دلیل ارتباط مستقیم آنها با برخی از اعمال کشاورزی و تولید ملی محصولات، زیان های اقتصادی کشاورز و سیاست گذار را کاهش می دهد. علاوه بر این در تحقیقات متعددی می توان به نقش تشخیص مرحله رشد گیاهان در تحلیل چگونگی تغییرات آب و هوایی اشاره نمود [۶].

توسعه فناوری دوربین های دیجیتال و حس گرهای سنسجش از دور کمک بزرگی در تحلیل محصولات کشاورزی است [۷]. اگرچه در سال های اخیر از شاخص های زیادی نظیر شاخص گیاهی پیشرفته (EVI)، شاخص گیاهی (SAVI)، استفاده شده است اما پرکاربردترین شاخص گیاهی، شاخص گیاهی تفاوت نرمال شده (NDVI) است که مستقیماً با شاخص سطح برگ (LAI) مرتبط است [۸].

در مقاله [۹]، با اعمال روش ترکیب مقدار حداکثر (MVC) و فیلتر هموار سازی بر روی شاخص سبزیگی (VI) به تشخیص مرحله رشد گیاهان بهره پرداخته است. آقای ژنگ و همکاران در مقاله [۱۰] با استفاده از شاخص های NDVI و کلروفیل لبه قرمز به تشخیص مرحله رشد گیاه برنج پرداخته اند. در این مقاله در ابتدا نمودار نقطه ای با استفاده از روش لجستیک دوگانه به یک نمودار پیوسته هموار تبدیل شده است. سپس با استفاده از زمانهای وقوع نقطه حداکثر و حداقل و نقطه صفر در این نمودار فاز های اصلی رشد گیاه تشخیص داده شده است. در مقاله [۱۱]، عملیات مشابهی برای تشخیص فاز رشد گیاه برنج انجام شده است. در این مقاله گزارش داده شده است که در این کاربرد، شاخص کلروفیل لبه قرمز نسبت به NDVI مناسب تر است. همینطور روش تابع گوسی متقارن نسبت به تابع لجستیک دوگانه و تابع گوسی آسیمتریک با میزان اورفیتینگ پایین تری همراه است.

در مقاله [۱۲]، پس از هموار سازی نمودار EVI به کمک تبدیل موجک، از نقاط حداکثر و حداقل و نقاط عطف نمودار در جهت تشخیص مراحل رشد گیاهان استفاده شده است. عملیات تقریباً مشابهی در مقاله [۱۳] برای تشخیص مرحله رشد گیاهان متعددی ارائه شده است. در مقاله [۱۴] بعد از هموار سازی، نمودار زمانی بر



است. در این مطالعه از شبکه عصبی برای این منظور استفاده شده است. از اطلاعات ۹۰٪ زمین ها برای آموزش و از باقیمانده داده ها برای تست استفاده شده است. برای ارزیابی از معیار ریشه میانگین مربعات خطا به ازای هر فاز استفاده شده است. خطای مدل پیشنهادی به ازای فازهای اول، دوم، سوم، چهارم و پنجم به ترتیب تقریباً ۳/۲۴، ۲/۸۲، ۳/۱ و ۲/۶۵ و ۳/۱ روز است.

مقاله پیش رو دارای بخش های زیر است: بخش ۲ به آماده سازی داده ها و ارزیابی روش پیشنهادی اختصاص دارد. در بخش ۳ به پیاده سازی و مشاهدات پرداخته شده است. نتیجه گیری در بخش ۴ ارائه شده است.

## ۲. آماده سازی داده ها و ارزیابی روش پیشنهادی

در این بخش، آماده سازی داده ها و مدل پیشنهادی را ارزیابی می نمایم.

### آماده سازی داده ها:

در این بخش در ابتدا به آماده سازی داده ها و سپس به مدل پیشنهادی می پردازیم. در این تحقیق زمین هایی از بخش های دزفول، شهید کریمی و عجیب که به کاشت گندم زمستانی می پردازند مورد بررسی قرار گرفته شده است. در اینجا، از داده های ماهواره سنیتل ۲ که بطور معمول هر ۵ الی ۶ روز در میان تهیه می شود استفاده شده است. نمونه ای از اطلاعات NDVI یک زمین در شکل (۱) نمایش داده شده است. محور افقی در این نمودار نشان دهنده شماره روز از شروع فصل کشت است و محور عمودی میزان میانگین شاخص NDVI در آن زمین است. بطور معمول انتظار میرود که فاصله زمانی بین جمع آوری داده ها ۵ الی ۶ روز باشد اما به دلیل ابری بودن هوا گاهی فاصله زمانی بیشتر از این مقدار میشود. جهت غلبه بر مشکل داده های مجهول از روش های مختلفی میتوان استفاده نمود [۱۶]. در اینجا از روش اسپلاین برای درونیابی استفاده شده است. در پژوهش های متعددی، هموار سازی نمودار پس از درونیابی، جهت کاهش اثر تخریبی مشاهدات غیر قابل قبول و حاوی خطا توصیه شده است [۱۷، ۱۸]. به این صورت که با در نظر گرفتن پنجره ای به طول ۹ روز، به مرکز پنجره مقداری برابر با میانگین پنجره اختصاص داده میشود. در شکل (۱) همراه با نمودار NDVI، نمودار هموار شده نیز نمایش داده شده است.

روی یک تابع لاجستیک دوگانه تعمیم یافته برازش شده است. سپس با استفاده از روش های متفاوت نظیر روش مبتنی آستانه گذاری، روش مبتنی بر مشتق و روش مبتنی بر انحنای منحنی، تاریخ مراحل اصلی رشد گیاه تخمین زده شده است.

از مقالات دیگر در زمینه تشخیص فاز رشد گیاه گندم با استفاده از داده های راداری، میتوان به [۷] و [۱۵] اشاره نمود. در مقاله [۷]، از ضرایب VH و VV در زوایای ۳۲-۳۴ و ۴۳-۴۵ درجه به دست آمده از تصاویر سنیتل ۱ متعلق به بخش هایی از منطقه بکا در لبنان جهت تشخیص فاز رشد گندم به صورت چهار فاز اصلی جوانه زنی، خوشه شدن و خمیر نرم، و برداشت استفاده شده است. در این مقاله پس از هموار سازی، نمودارهای سری زمانی VH و VV و نسبت VV/VH، تابع مجموع گوسی با سه مولفه بر روی هر کدام از نمودارها فیت شده است. با کمینه کردن مقدار مربع خطا، مقادیر پارامترهای مدل تخمین زده شده است. در گام بعدی رفتار نمودارها در زمانهای رخداد فازهای اصلی بررسی شده و قوانینی جهت تصمیم گیری در مورد زمان رخداد هر فاز استخراج شده است. برای مثال مشاهده شده است که اولین پیک در نمودار VV/VH نشان دهنده فاز جوانه زنی و اولین دره در نمودار VV بعد از جوانه زنی زمان ظهور سنبله رو نشان می دهد. اولین ماکزیمم بعد از ظهور سنبله در نمودار VH فاز خمیری نرم را نشان می دهد.

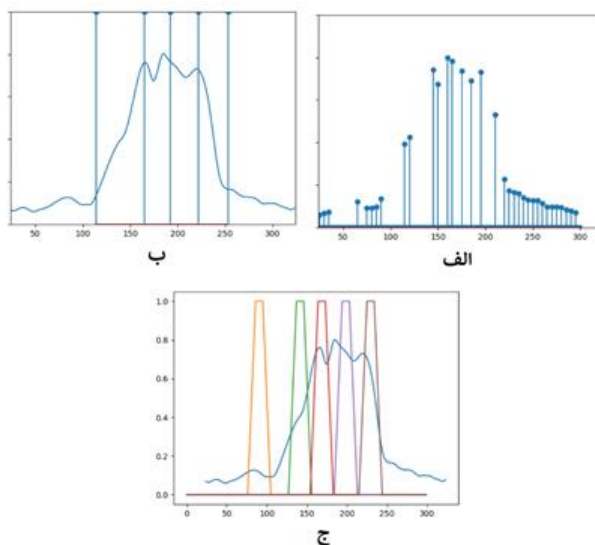
در مقاله [۱۵]، نیز به دلیل در دسترس نبودن داده های NDVI از داده های راداری جهت تشخیص استفاده شده است. در این مقاله، از اختلاف لگاریتم دو پارامتر VH و VV و نمودار شیب آن، زمان وقوع فازهای اصلی گیاه تخمین زده شده است. مطالعه بر روی بخش هایی از زمین های واقع در استان های شمالی چین شامل هبی، شاندونگ و هنان انجام شده است. در این مناطق گندم در اوایل اکتبر کشت و در ماه ژوئن برداشت می شود. پس از هموار سازی، از تطابق زمان فازها و رفتار نمودار در آن نقاط، قوانینی جهت تشخیص فازها مشخص می شود. بعنوان مثال اولین پیک در نمودار اختلاف لگاریتم های VV و VH نشان دهنده فاز جوانه زنی است و یا دومین پیک در نمودار شیب نمودار اختلاف لگاریتم ها نشان دهنده فاز ظهور سنبله است. در این مقاله هدف استفاده از داده های زمانی NDVI جهت تشخیص فاز رشد گیاه گندم است. به دلیل مشکلاتی از قبیل ابری بودن هوا، در برخی زمانها داده های NDVI در دسترس نیست. لذا از درونیابی اسپلاین برای محاسبه داده های مجهول بر اساس داده های در دسترس استفاده شده است. در اینجا به ازای هر زمین میانه شاخص NDVI محاسبه و نهایتاً به کمک درونیابی مقادیر مجهول مشخص می شود. در گام بعدی برای کم کردن تغییرات شدید، هموار سازی انجام شده است. گام بعدی استفاده از یک روش یادگیری ماشین جهت تشخیص فاز اصلی با توجه به تغییرات در نمودارهای NDVI

ایجاد بردار ویژگی ابتدا یک نمونه برداری با فاصله ۵ روز از سیگنال انجام میشود. سپس مقدار خام این نمونه ها و اختلاف دو به دوی بعضی از آنها بعنوان بردار ویژگی محاسبه می شود. در اینجا، با توجه به تعداد فاز های اصلی ۵ خروجی ( یک خروجی به ازای هر فاز) در نظر گرفته شده است. عبارتی دیگر ورودی شبکه یک بردار ۲۵ بعدی و خروجی آن یک بردار ۵ تایی است. اگر نقطه ای که بردار ویژگی برای آن به دست آمده زمان رخداد یکی از فاز ها باشد به خروجی متناسب به آن فاز مقدار یک و به ازای عناصر متناسب به فاز های دیگر مقدار ۰ اختصاص داده می شود. اگر نقطه جز هیچکدام از فاز ها نباشد خروجی برداری با مقادیر ۰ می شود.

یکی از مشکلات این روش این است که در نظر گرفتن خروجی به صورت میله ای ( شکل ۱.ب) همگرایی کافی در مدل، جهت یادگیری را ایجاد نمی کند. لذا برای بهبود دقت، از توابع عضویت دوزنقه ای به ازای هر فاز استفاده نمودیم. به این صورت که در هر نقطه ای متناسب به هر فاز، دوزنقه ای با مرکزیت نقطه مذکور و پهنای ۲۰ روز در نظر گرفته می شود. حال با ایجاد این تغییر، با روش قبلی بردار خروجی ایجاد می شود. در شکل (۱-ج) نمایشی از زمان فازها با در نظر گرفتن تابع عضویت دوزنقه ای آمده است.

بردار های ویژگی به دست آمده همراه با بردار خروجی آن، به عنوان یک نمونه داده جهت آموزش شبکه استفاده می شود. با توجه به پنجره لغزان و حرکت آن بر روی سیگنال زمانی، جهت ایجاد بردار های ورودی و خروجی، به ازای هر نمودار متناسب با طول سیگنال، تعدادی نمونه ایجاد می شود. برای مثال اگر طول سیگنال ۲۰۰ نقطه باشد با حذف نقاط مرزی در دو طرف سیگنال، ۱۷۰ نمونه (ورودی/خروجی) ایجاد می شود. با این روش، با در نظر گرفتن تمام زمین های در نظر گرفته شده جهت آموزش، تعداد مناسبی ورودی/خروجی برای آموزش شبکه ایجاد می شود. شبکه عصبی استفاده شده در این مساله شبکه ای با ۲۵ ورودی و ۵ خروجی و ۲ لایه میانی با تعداد گره های ۲۰ و ۱۰ گره است.

پس از آموزش شبکه جهت آزمایش، به ازای هر نقطه از نمودار تست، پنجره ای با مرکزیت آن نقطه در نظر گرفته می شود و سپس بردار ویژگی استخراج شده به عنوان ورودی به شبکه اعمال می شود. به ازای هر نقطه یک بردار ۵ تایی بعنوان خروجی تولید می شود که برای رسیدن به خروجی مطلوب ( زمان وقوع هر فاز) عملیات پس پردازش بر روی نتایج خام انجام می شود. نمونه هایی از خروجی های خام به دست آمده توسط شبکه به ازای یک فایل تست در شکل (۲-ب) نمایش داده شده است. همانطور که در این شکل قابل مشاهده است خروجی شبکه به ازای هر نقطه (نقطه مرکزی پنجره ای که بردار ویژگی از آن استخراج شده است) بردار ۵ تایی شامل مقادیری متعلق به بازه (۰ و ۱) ایجاد شده است. هر عدد میزان احتمال تعلق نقطه مذکور به هر فاز را



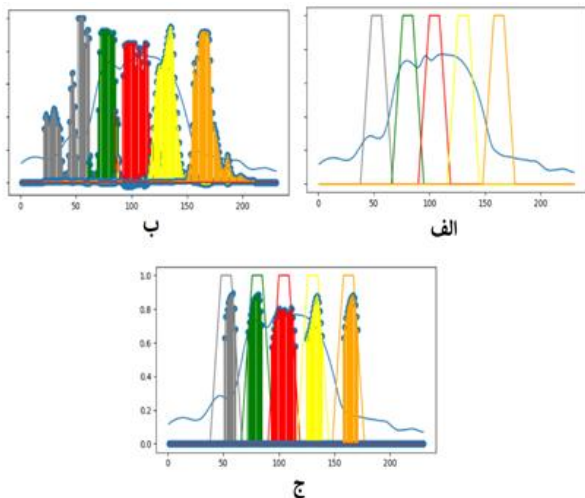
شکل ۱. نمودار میانه NDVI متعلق به یک پلی گان. (ب) نتیجه انجام درونیایی همراه با نمایش زمان وقوع پنج فاز. (ج) در نظر گرفتن توابع عضویت دوزنقه ای به ازای هر فاز.

به ازای هر زمین ۵ تاریخ به عنوان زمان فاز های اصلی گزارش داده شده است. در این تحقیق با توجه به داده های جمع آوری شده برای گندم ۵ فاز اصلی به نام های سبز شدن، پنجه زنی، آبستنی، توسعه دانه و رسیدگی در نظر گرفته شده است. در شکل (۱-ب) در نمودار NDVI این زمانها به کمک ۵ میله نمایش داده شده است. هدف از انجام این تحقیق تشخیص زمان وقوع این فاز ها با توجه به نمودار زمانی است. بدین منظور می توان از یک ابزار مبتنی بر یادگیری ماشین استفاده نمود تا تناظر بین نمودار زمانی و فاز های مشخص شده را یاد بگیرد. در این تحقیق از شبکه های عصبی جهت یادگیری استفاده شده است.

#### مدل پیشنهادی:

با توجه به ساختار شبکه های عصبی، در این بخش باید ورودی و خروجی شبکه را مشخص نماییم. با توجه به نمودار شکل (۱.ب) به نظر می رسد می توان از میزان تغییرات مقادیر نمودار زمانی (افزایشی و یا کاهشگی بودن نمودار) و مقدار خام نمودار در آن حوالی، تا حد خوبی رخداد و یا عدم رخداد هر فاز را تشخیص داد. بعنوان مثال با توجه به شکل (۱.ب) اگر نمودار افزایشی باشد و مقادیر نمودار حول و حوش مقدار ۰,۲ باشد فاز اول در حال وقوع است. برای اینکه این مساله تو سط ابزاری مانند شبکه عصبی قابل آموزش شود باید این اطلاعات را بصورت بردار مناسبی به شبکه وارد نمود.

برای این منظور به ازای هر نقطه از نمودار، پنجره ای حول هر نقطه با طول ۳۰ روز در نظر گرفته شده است به طوری که نقطه مذکور نقطه مرکزی پنجره باشد. از این پنجره بردار ویژگی ای با طول ۲۵ استخراج می شود. این بردار به عنوان ورودی شبکه در نظر گرفته می شود. برای



شکل ۲. نمونه‌ای از خروجی مدل پیشنهادی (الف) نمودار زمانی NDVI همراه با زمان فاز های اصلی بصورت توابع دوزنقه ای. (ب) خروجی اولیه شبکه (ج) هم پوشانی ای از خروجی نهایی پس از هموارسازی و آستانه گذاری همراه با زمانهای گزارش داده شده به صورت توابع دوزنقه ای. در این نمونه خطاهای به دست آمده به ازای فاز های اول، دوم، سوم، چهارم و پنجم به ترتیب ۳، ۱/۵، ۰/۵، ۱/۵ و ۲ روز است.

پس از آموزش مدل، نوبت به تست مدل است. به این منظور مدل آموزش داده شده بر داده های تست به روشی که در بخش قبل توضیح داده شد اعمال می شود. مقدار ریشه میانگین مجذور مربعات خطا به ازای هر فاز به عنوان معیار ارزیابی محاسبه می شود. برای ارزیابی دقیق تر مدل، انتخاب داده های تست و آموزش که بصورت تصادفی است ۵ بار انجام و نهایتاً میانگین خطاهای به دست آمده بعنوان نتایج نهایی در جدول (۱) گزارش داده شده است.

جدول ۱. میانگین RMSE مدل پیشنهادی به ازای فازهای مختلف.

فاز اول	فاز دوم	فاز سوم	فاز چهارم	فاز پنجم	میزان خطای RMSE به روز
۳/۲۴	۲/۸۲	۳/۱	۲/۶۵	۳/۱	

در مجموع الگوریتم پیشنهادی به طور میانگین در تشخیص هر فاز تقریباً دارای خطای ۳ روزه است. به نظر می رسد الگوریتم پیشنهادی، علیرغم مشکلات موجود (وجود خطا در داده ها و فقدان وجود شاخص NDVI در برخی بازه ها) دارای دقت مناسبی در تخمین زمان وقوع فاز های مختلف گیاه گندم است.

نشان می دهد. هر خروجی با یک رنگ نشان داده شده است. برای مثال فاز اول با رنگ خاکستری و فاز آخر با رنگ نارنجی نشان داده شده است.

برای تشخیص زمان تقریبی هر فاز با استفاده از نمودارهای به دست آمده عملیات پس پردازش زیر بر روی هر خروجی انجام می شود. ابتدا پس از هموار سازی مقادیر به دست آمده، به ازای هر فاز، میزان ماکزیمم پیدا می شود. سپس نقاط با مقدار احتمال بیشتر از ۰.۸ مقدار ماکزیمم بعنوان مناطق احتمالی رخداد فاز مذکور در نظر گرفته می شود. عبارتی دیگر مقادیر کمتر از ۰.۸ برابر مقدار ماکزیمم دیگر در ادامه کار در نظر گرفته نمی شود و به آنها مقدار صفر اختصاص داده می شود (شکل ۲ ج). برای به دست آوردن نقطه ای تحت عنوان زمان وقوع فاز، میانگین وزنی نقاط با مقدار غیر صفر محاسبه و به فاز مذکور نسبت داده می شود.

برای ارزیابی کمی روش پیشنهادی، باید با معیار مناسبی مقادیر زمانی به دست آمده شده بعنوان خروجی و مقادیر گزارش داده شده مقایسه شود. به این منظور از پارامتر ریشه میانگین مجذور مربعات خطا استفاده شده است. برای محاسبه این پارامتر از رابطه زیر به ازای هر فاز استفاده شده است:

$$RMSE = \sqrt{\frac{\sum_i (x_i - \hat{x}_i)^2}{N}} \quad [1]$$

که در این رابطه  $x_i$  و  $\hat{x}_i$  و  $N$  به ترتیب زمان گزارش داده شده، زمان تخمین زده شده توسط الگوریتم و تعداد داده است.

### ۳. نتایج و بحث

در این بخش به ارزیابی مدل پیشنهادی می پردازیم. در ابتدا میانگین مقادیر NDVI متناسب به هر زمان بصورت یک نمودار بر حسب شماره روز از شروع کشت در نظر گرفته می شود. با انجام درون یابی و به دنبال آن هموار سازی، نمودارها بهبود می یابند. سپس با پنجره لغزان که در بخش قبل به آن اشاره شده به ازای هر نقطه بردار ویژگی ورودی و خروجی متناظر با آن محاسبه می شود.

از ۹۰٪ زمین ها به عنوان داده های آموزش و از ۱۰٪ باقیمانده بعنوان تست استفاده شده است. مدل یادگیرنده در این مطالعه یک شبکه عصبی با دو لایه میانی است. مقدار تکرار برای آموزش مدل ۲۰۰۰ در نظر گرفته شده است. با توجه در نظر گرفتن پنجره ای به طول ۳۰ روز با مرکزیت نقطه مرکزی می توان گفت که برای تشخیص مرحله رشد گیاه در هر زمان حداقل به داده های ۱۵ روز قبل و ۱۵ روز بعد نیاز است.



#### ۴. نتیجه گیری

در این مقاله روشی برای تشخیص مرحله رشد گیاه گندم با استفاده از شاخص NDVI ارائه شده است. در این مقاله در ابتدا عملیات درونبایی و هموار سازی بر روی میانگین مقادیر NDVI در هر پلیگان انجام می شود. سپس به ازای هر نقطه پنجره ای حول آن نقطه در نظر گرفته می شود و به ازای آن پنجره، بردار ویژگی استخراج می شود. خروجی مدل یک بردار ۵ تایی است. برای بالا بردن دقت مدل به جای در نظر گرفتن تاریخ ها به صورت میله ای توابع دوزنقه ای با مرکزیت تاریخ هر فاز در نظر گرفته می شود. جهت ارزیابی از معیار RMSE به ازای هر فاز استفاده شده است. علیرغم محدودیت های شاخص NDVI در این کاربرد، در این مطالعه نتایج قابل قبول و مطلوبی به دست آمده است.

#### مراجع

- phenology monitoring and mapping. Remote Sensing, 11(19), 2228 .
- [۸] Veloso, A.; Mermoz, S.; Bouvet, A.; Le Toan, T.; Planells, M.; Dejoux, J.F.; Ceschia, E. 2017. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. Remote Sens. Environ. 199, 415–426 .
- [۹] Tian, J., Zhu, X., Chen, J., Wang, C., Shen, M., Yang, W., Tan, X., Xu, S. and Li, Z., 2021. Improving the accuracy of spring phenology detection by optimally smoothing satellite vegetation index time series based on local cloud frequency. ISPRS Journal of Photogrammetry and Remote Sensing, 180, pp.29-44.
- [۱۰] Zheng, H., Cheng, T., Yao, X., Deng, X., Tian, Y., Cao, W. and Zhu, Y., 2016. Detection of rice phenology through time series analysis of ground-based spectral index data. Field Crops Research, 198, pp.131-139 .
- [۱۱] Ma, Y., Jiang, Q., Wu, X., Zhu, R., Gong, Y., Peng, Y., Duan, B. and Fang, S., 2021. Monitoring Hybrid Rice Phenology at Initial Heading Stage Based on Low-Altitude Remote Sensing Data. Remote Sensing, 13(1), p.86 .
- [۱۲] Sakamoto, T., Yokozawa, M., Toritani, H., Shibayama, M., Ishitsuka, N. and Ohno, H., 2005. A crop phenology detection method using time-series MODIS data. Remote sensing of environment, 96(3-4), pp.366-374 .
- [۱۳] Diao, C., 2020. Remote sensing phenological monitoring framework to characterize corn and soybean physiological growing stages. Remote Sensing of Environment, 248, p.11960 .
- [۱۴] Xin, Q., Li, J., Li, Z., Li, Y. and Zhou, X., 2020. Evaluations and comparisons of rule-based and machine-learning-based methods to retrieve satellite-based vegetation phenology using MODIS and USA National Phenology Network data. International Journal of Applied Earth Observation and Geoinformation, 93, p.102189 .
- [۱۵] Song, Y., & Wang, J. (2019). Mapping winter wheat planting area and monitoring its phenology using Sentinel-1 backscatter time series. Remote Sensing, 11(4), 449 .
- [۱۶] Belda, S., Pipia, L., Morcillo-Pallarés, P., Rivera-Caicedo, J.P., Amin, E., De Grave, C. and Bano, A.; Yasmeen, S. Role of phytohormones under induced drought stress in wheat. Pakistan J. Bot. 2010,
- [۲] Abebe, Z., & Feyisa, H. 2017. Effects of nitrogen rates and time of application on yield of maize: rainfall variability influenced time of N application. International Journal of agronomy, 2017. doi: <https://doi.org/10.1155/2017/1545280>
- [۳] Wegulo, S. N., Baenziger, P. S., Nopsa, J. H., Bockus, W. W., & Hallen-Adams, H. 2015. Management of Fusarium head blight of wheat and barley. Crop Protection, 73, 100-107 .
- [۴] Blandino, M., Haidukowski, M., Pascale, M., Plizzari, L., Scudellari, D., & Reyneri, A. (2012). Integrated strategies for the control of Fusarium head blight and deoxynivalenol contamination in winter wheat. Field Crops Research, 133, 139-149
- [۵] Han, J., Shi, L., Yang, Q., Huang, K., Zha, Y. and Yu, J., 2021. Real-time detection of rice phenology through convolutional neural network using handheld camera images. Precision Agriculture, 22(1), pp.154-178 .
- [۶] Yang, Y., Tao, B., Liang, L., Huang, Y., Matocha, C., Lee, C.D., Sama, M., Masri, B.E. and Ren, W., 2021. Detecting Recent Crop Phenology Dynamics in Corn and Soybean Cropping Systems of Kentucky. Remote Sensing, 13(9), p.1615 .
- [۷] Nasrallah, A., Baghdadi, N., El Hajj, M., Darwish, T., Belhouchette, H., Faour, G., ... & Mhawej, M. 2019. Sentinel-1 data for winter wheat



Verrelst, J., 2020. DATimeS: A machine learning time series GUI toolbox for gap-filling and vegetation phenology trends detection. *Environmental Modelling & Software*, 127, p.104666.

[۱۷] Wei, W., Wu, W., Li, Z., Yang, P. and Zhou, Q., 2016. Selecting the optimal NDVI time-series reconstruction technique for crop phenology detection. *Intelligent Automation & Soft Computing*, 22(2), pp.237-247 .

[۱۸] Pan, Z., Huang, J., Zhou, Q., Wang, L., Cheng, Y., Zhang, H., Blackburn, G.A., Yan, J. and Liu, J., 2015. Mapping crop phenology using NDVI time-series derived from HJ-1 A/B data. *International Journal of Applied Earth Observation and Geoinformation*, 34, pp.188-197