

# بررسی توانایی شبکه‌های عصبی کانولوشن سه‌بعدی و شبکه‌های عصبی بازگشتی بر طبقه‌بندی دقیق‌تر محصولات کشاورزی با استفاده از تصاویر سری زمانی نوری

مریم تیموری\*<sup>۱</sup>، مهدی مختارزاده<sup>۲</sup>

<sup>۱</sup> دانشجوی دکتری سنجش‌ازدور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی

mteimouri@mail.kntu.ac.ir

<sup>۲</sup> دانشیار دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی

m\_mokhtarzade@kntu.ac.ir

(تاریخ دریافت: فروردین‌ماه ۱۴۰۰، تاریخ تصویب: دی‌ماه ۱۴۰۱)

## چکیده

یکی از چالش‌های جدی در حوزه سنجش‌ازدور، استخراج ویژگی‌های مناسب از داده‌های ماهواره‌ای می‌باشد. با ظهور نسل جدیدی از شبکه‌های عصبی عمیق، قابلیت استخراج ویژگی‌ها و همچنین طبقه‌بندی دقیق محصولات به طور اتوماتیک امکانپذیر شده‌است. از سویی، استخراج ویژگی‌های مناسب می‌تواند تا حدی اثرات شباهت طیفی را در شناسایی محصولات مختلف کاهش دهند و باعث بهبود دقت طبقه‌بندی محصولات شوند. همچنین، استفاده از داده‌های چند زمانه در طول دوره رشد، اطلاعات مفیدی درباره محصولات در اختیار محققین قرار می‌دهد. در این راستا، باهدف دستیابی به ویژگی‌های مناسب از تصاویر سری زمانی، سه روش شبکه‌های عصبی کانولوشن سه‌بعدی، شبکه عصبی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای در این تحقیق مورد بررسی و ارزیابی قرار گرفتند. در معماری بررسی‌شده برای شبکه عصبی کانولوشن سه‌بعدی، تلاش بر آن شد که بهترین بردارهای ویژگی زمانی-مکانی از تصاویر استخراج شوند و سپس نتایج بدست‌آمده از این شبکه با دو روش شبکه‌های بازگشتی مورد مقایسه قرار گیرند. درنهایت، پارامترهای ارزیابی بدست‌آمده از ماتریس خطا در این تحقیق نشان می‌دهد که شبکه عصبی کانولوشن سه‌بعدی، با حصول دقت کلی ۹۰.۷۰٪ و ضریب کاپا ۸۹.۳۷٪ به ترتیب در حدود ۳.۵۰٪ و ۴.۰۰٪ نسبت به شبکه عصبی حافظه طولانی کوتاه‌مدت توانایی بیشتری در شناسایی محصولات داشته‌است. همچنین، دقت کلی نتایج طبقه‌بندی توسط شبکه واحد بازگشتی دروازه‌ای نزدیک به دقت کلی شبکه عصبی کانولوشن سه‌بعدی بوده‌است و تنها دقت کلی این روش ۱.۴۸٪ از شبکه واحد بازگشتی دروازه‌ای بهتر عمل کرده‌است. بنابراین، نتایج حاصل مؤید کارایی شبکه عصبی کانولوشن سه‌بعدی برای شناسایی و طبقه‌بندی محصولات می‌باشد.

**واژگان کلیدی:** طبقه‌بندی محصولات، تصاویر سری زمانی، شبکه عصبی کانولوشن سه‌بعدی، شبکه عصبی حافظه طولانی کوتاه‌مدت، شبکه واحد بازگشتی دروازه‌ای

## ۱- مقدمه

افزایش روزافزون جمعیت و افزایش تقاضای جهانی برای مواد غذایی، بخش مدیریت کشاورزی را مجبور به داشتن اطلاعات دقیق و به هنگام برای مدیریت بهتر مزارع کشاورزی می‌نماید. عدم دستیابی به اطلاعات دقیق در زمینه نوع محصولات و سطح زیر کشت آن‌ها در هر سال، هزینه‌های سنگینی را بر کشور تحمیل می‌کند. همچنین جمع‌آوری این اطلاعات به روش‌های سنتی (جمع‌آوری داده‌های میدانی توسط کارشناسان) بسیار هزینه‌بر و زمانبر است. از سویی، تکنولوژی سنجش‌ازدور نقش مهمی را در تولید نقشه‌های توزیع مکانی محصولات در مقیاس‌های منطقه‌ای و جهانی دارد [۱]. به همین دلیل، با ظهور سنسورهای ماهواره‌ای با قدرت تفکیک‌های مکانی متوسط و بالا، محققین تلاش‌های گسترده‌ای در زمینه اتوماتیک‌سازی جمع‌آوری این نقشه‌ها با استفاده از تصاویر ماهواره‌ای کرده‌اند. از سویی، باندهای تصاویر نوری یک منبع غنی از اطلاعات برای طبقه‌بندی محصولات فراهم می‌کنند که این اطلاعات حاوی میزان انرژی بازگشتی از محصولات است که نقش بسزایی در تشخیص و تفکیک آن‌ها دارند [۲، ۳]. شناسایی و طبقه‌بندی محصولات با بکارگیری تنها اطلاعات طیفی موجود در یک تصویر نوری، به نتیجه مطلوبی دست نخواهد یافت که دلیل این امر را می‌توان تغییرات زیاد طیف بازتابی از یک محصول در طول دوره رشد آن دانست [۴]. برای حل این مشکل، بیشتر محققین از تصاویر سری زمانی محصولات استفاده می‌کنند [۵، ۶] که این تصاویر حاوی اطلاعات ارزشمندی از تغییرات طیفی یک محصول در طول دوره رشد است. از طرفی، تصاویر سری زمانی سنتینل-۲ به دلیل برداشت‌های مکرر در بازه‌های زمانی مختلف، الگوی رشد زمانی محصولات را نشان می‌دهند [۷]. بنابراین، این تحقیق، بر طبقه‌بندی محصولات با استفاده از تصاویر سری زمانی نوری سنتینل-۲ متمرکز شده‌است.

از سوی دیگر، ویژگی‌های بکار گرفته‌شده در تحقیقات مختلف برای شناسایی و تفکیک محصولات را می‌توان به سه دسته کلی تقسیم‌بندی کرد: (۱) زمانی-مکانی [۵، ۸، ۹] (۲) طیفی [۷، ۱۰، ۳] (۳) زمانی-مکانی-طیفی [۱۱-۱۶]. در سال‌های اخیر، شبکه‌های عصبی عمیق، موفقیت‌های چشمگیری در حوزه سنجش‌ازدور داشته است [۲۲-۱۷]. این شبکه‌ها، قادر به استخراج ویژگی‌های سلسله‌مراتبی از

تصاویر به طور خودکار هستند. از میان روش‌های مختلفی که در این دسته از شبکه‌ها وجود دارند، شبکه عصبی کانولوشن سه‌بعدی<sup>۱</sup> [۲۳-۲۵] و شبکه‌های عصبی بازگشتی [۲۶-۲۸] توانایی استخراج ویژگی‌های زمانی را از تصاویر سری زمانی دارند.

Kussul و همکارانش در سال ۲۰۱۷، به شناسایی انواع محصولات با استفاده از شبکه‌های عصبی کانولوشن یک و دوبعدی پرداختند [۶]. در این راستا، در سال ۲۰۱۸، Ji و همکارانش با استفاده از شبکه‌های عصبی کانولوشن سه بعدی انواع محصولات کشاورزی را از تصاویر سری زمانی Gaofen-1 و Gaofen-2 طبقه‌بندی کردند [۲۹]. Shakya و همکارانش در سال ۲۰۲۰، یک روش تلفیق بر مبنای پیکسل با استفاده از شبکه‌های کانولوشن دو بعدی برای طبقه‌بندی محصولات از تصاویر سنتینل ۱ و ۲ را ارائه کردند [۲۰]. همچنین در سال ۲۰۲۱، Adrian و همکارانش با استفاده از روش آنالیز مولفه اولیه، تصاویر سنتینل ۱ و ۲ را بایکدیگر تلفیق کردند [۲۵]. سپس، آن‌ها از یک طبقه‌بندی کننده بر مبنای شبکه عصبی کانولوشن برای شناسایی و تفکیک محصولات استفاده کردند.

در سال ۲۰۱۲، Ji و همکارانش، یک چارچوب خاصی از شبکه‌های عصبی کانولوشن سه‌بعدی را پیشنهاد دادند [۲۹] که قادر به استخراج ویژگی‌های زمانی-مکانی بود. از سوی دیگر، شبکه عصبی حافظه طولانی کوتاه‌مدت<sup>۲</sup> [۳۰] و شبکه عصبی واحد بازگشتی دروازه‌ای<sup>۳</sup> [۳۱]، قادر به مدل‌سازی وابستگی زمانی داده‌ها و درنهایت استخراج ویژگی‌های زمانی از تصاویر می‌باشند و از آنجا که طیف بازتابی از محصول در طول دوره رشد آن تغییراتی دارد. بنابراین، ویژگی‌های استخراج‌شده از تصاویر نقش بسزایی در شناسایی محصولات دارند. در این راستا با هدف بررسی و مقایسه پتانسیل ویژگی‌های استخراج‌شده از هر شبکه عصبی کانولوشن سه‌بعدی، شبکه حافظه طولانی کوتاه‌مدت و شبکه واحد بازگشتی دروازه‌ای به شناسایی و تفکیک محصولات پرداخته می‌شود.

در ادامه ساختار این مقاله به شرح زیر است: بخش دوم، مواد و روش‌های شبکه‌های عصبی عمیق کانولوشن

<sup>۱</sup> 3D-Convolutional Neural Networks (3D-CNNs)

<sup>۲</sup> Long Short-Term Memory (LSTM)

<sup>۳</sup> Gated Recurrent Unit (GRU)

کوتاهمدت، متشکل از سلول حالت  $h_t$  و حافظه  $C_t$  است. همچنین، هر واحد این شبکه‌ها متشکل از سه دروازه ورودی، فراموشی و خروجی (شکل (۱)) می‌باشد. در این شبکه‌ها، میزان اطلاعاتی که باید در طول فرآیند آموزش، فراموش و یا حفظ گردد توسط دروازه‌ها کنترل می‌شوند و این عمل باعث جلوگیری محوشدگی گرادیان می‌شود. معادله‌های ۳ تا ۸ نحو عملکرد شبکه عصبی حافظه طولانی کوتاهمدت را بیان می‌کنند.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

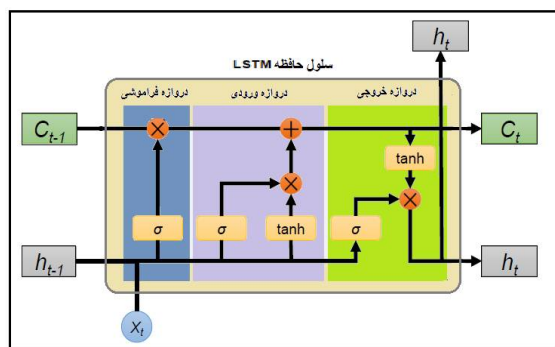
$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (7)$$

$$h_t = o_t \odot \tanh(C_t) \quad (8)$$

$h_t$  و  $C_t$  بیانگر بردارهای لایه میانی،  $x_t$  بردار ورودی،  $b_f, b_i, b_c, b_o$  بردارهای بایاس شبکه،  $W_o, W_f, W_c, W_i$  ماتریس‌های پارامتر و تابع‌های فعالیت شبکه با  $\sigma$  و  $\tanh$  نشان داده شده است.



شکل ۱: معماری سلول شبکه عصبی حافظه طولانی کوتاهمدت [۲۸]

در سال ۲۰۱۴، Cho و همکارانش شبکه واحد بازگشتی دروازه‌ای را پیشنهاد دادند [۳۱]. در واقع شبکه عصبی واحد بازگشتی دروازه‌ای یک نوع شبکه عصبی حافظه طولانی کوتاهمدت بهبود یافته است. اساسی‌ترین تغییرات صورت گرفته در این شبکه‌ها نسبت به شبکه

سه‌بعدی و بازگشتی توضیح داده شده است. بخش سوم، داده‌های ورودی و پیش‌پردازش معرفی می‌شود. در بخش چهارم، روش تحقیق شرح داده خواهد شد. سپس، در بخش‌های پنجم و ششم به ترتیب به پیاده‌سازی و ارزیابی نتایج پرداخته می‌شود. در نهایت، خلاصه و نتیجه‌گیری تحقیق بیان شده است.

## ۲- مواد و روش‌ها

### ۲-۱- شبکه‌های عصبی بازگشتی

شبکه‌های عصبی بازگشتی از اتصالات بین نرون‌های متوالی تشکیل شده‌اند. آن‌ها توانایی یادگیری وابستگی‌های زمانی بین داده‌ها را دارند. همانطور که در معادله (۱) و (۲) مشاهده می‌شود، عملکرد این شبکه‌ها به نحوی است که خروجی در بازه زمانی قبلی ( $t-1$ ) به همراه داده ورودی در زمان  $t$ ، به‌عنوان ورودی آن نرون در نظر گرفته می‌شود.

$$h_t = \sigma_h(i_t) = \sigma_h(U_h x_t + V_h h_{t-1} + b_h) \quad (1)$$

$$y_t = \sigma_y(o_t) = \sigma_y(W_y h_t + b_y) \quad (2)$$

$x_t$  و  $y_t$  به ترتیب نشان‌دهنده بردار ورودی ( $m \times 1$ ) و بردار خروجی ( $n \times 1$ ) شبکه می‌باشد. همچنین، دیگر پارامترهای شبکه،  $h_t$  بردار لایه میانی ( $n \times 1$ )،  $b_h$  بردار بایاس ( $n \times 1$ ) و  $U$  و  $W$  ماتریس پارامترها ( $n \times m$ )،  $\sigma_h$  و  $\sigma_y$  تابع فعالیت و  $V$  ماتریس پارامتر ( $n \times n$ ) است.

یکی از ضعف‌های اصلی این شبکه‌ها محوشدگی گرادیان است. هنگامی که دنباله ورودی طولانی می‌باشد، این شبکه‌ها دیگر قادر به حفظ ترم‌های طولانی دنباله نیستند. برای حل این مشکل، دو نوع شبکه عصبی بازگشتی حافظه طولانی کوتاهمدت و واحد بازگشتی دروازه‌ای مطرح شدند.

در سال ۱۹۹۷، شبکه عصبی حافظه طولانی کوتاهمدت، توسط Hochreiter و Schmidhuber پیشنهاد داده شد [۳۰]. این شبکه‌ها، قابلیت ذخیره‌سازی اطلاعات در بازه‌های زمانی بلندمدت، رفتار پیش‌فرض و عادی را دارند. ورودی شبکه عصبی حافظه طولانی کوتاهمدت، دنباله‌ای از متغیرها ( $x_1, x_2, \dots, x_t$ ) می‌باشد که  $x_t$  بردار ویژگی در زمان  $t$  است. هر واحد شبکه عصبی حافظه طولانی

## ۲-۲- شبکه های عصبی کانولوشن

شبکه های عصبی کانولوشن از سه لایه ورودی، میانی و خروجی تشکیل شده است. لایه میانی این شبکه ها خود نیز متشکل از سه لایه اصلی، کانولوشن، پولینگ و تماماً متصل است. هسته اصلی تشکیل دهنده این شبکه ها، لایه کانولوشن است. هر لایه کانولوشن برای تولید نقشه های ویژگی، از چندین فیلتر مختلف تشکیل شده است که از ضرب پیچشی تصویر ورودی در هر فیلتر ایجاد می شود. این ویژگی ها بسیار قابل اطمینان تر و مؤثرتر از ویژگی های قانون مینا هستند [۳۲].

در این تحقیق، به منظور استخراج همزمان ویژگی های زمانی و مکانی، شبکه های عصبی کانولوشن سه بعدی بکار برده شد. این شبکه ها متشکل از اپراتورهای کانولوشن سه بعدی هستند. این اپراتورها، قابلیت استخراج و حفظ ویژگی های پویا را از طریق دنباله های متوالی به عهده دارند [۲۳]. معادله (۱۳)، نحوه عملکرد یک اپراتور کانولوشن سه بعدی [۲۳] را نشان می دهد.

$$y_{cde} = \sigma \left( \sum_n \sum_{k=0}^N \sum_{i=0}^M \sum_{j=0}^M w_{kij,n} x_{c+i,d+j,e+k,n} + b \right) \quad (13)$$

$w_{ij,n}$  بیانگر یک کرنل سه بعدی،  $k$  شاخص زمانی،  $N$  طول زمان،  $n$  نشان دهنده  $n$  امین نقشه ویژگی لایه قبلی،  $y_{cde}$  و  $x_{cde}$  به ترتیب بیانگر نرون ورودی و خروجی در موقعیت  $(c, d, e)$  می باشند.

سپس بعد از هر اپراتور کانولوشن، یک لایه پولینگ قرار می گیرد که نقش آن ها، کاهش ابعاد نقشه های ویژگی است که به دلیل در نظر گرفتن پیکسل های همسایگی در محاسبات خود، نسبت به تغییر مکان ثبات دارند. یکی از معروفترین آن ها، عملگر ماکزیمم می باشد که عملکرد قابل قبول تری نسبت به دیگر عملگرها در تحقیقات سنجش از دور دارند.

در نهایت، آخرین لایه های یک شبکه عصبی کانولوشن، لایه های تماماً متصل است که این لایه ها، همانند لایه های شبکه های عصبی معمولی می باشند و اغلب از دو تا سه لایه میانی تشکیل شده اند. همچنین فرایند آموزش این شبکه ها، متشکل از دو مرحله پیش سو و پس انتشار است.

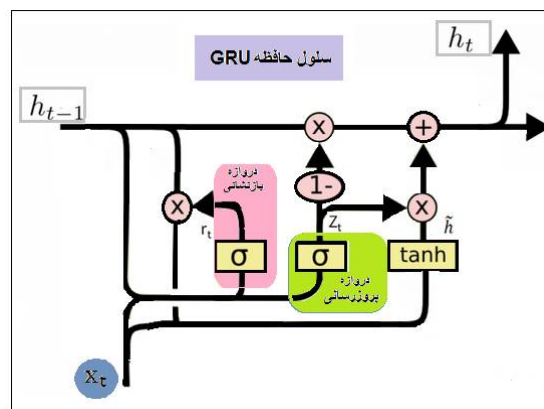
عصبی حافظه طولانی کوتاه مدت، افزودن دو دروازه بروزرسانی و بازنشانی (شکل (۲)) است. دروازه بروزرسانی تعیین می کند چه میزان از اطلاعات مربوط به گام های زمانی مراحل قبل بدون آنکه در حین گذر زمان (طی گام های زمانی مختلف) دستخوش تغییر شوند به آینده منتقل شوند. همچنین، دروازه بازنشانی همانند سوچی عمل می کند که توسط آن تعیین می شود چه میزان اطلاعات گذشته باید فراموش شوند. پس به طور کلی می توان بیان کرد که شبکه های واحد بازگشتی دروازه ای، علاوه بر رفع مشکل شبکه های عصبی بازگشتی سنتی (محوشدگی گرادیان)، باعث کاهش اطلاعات اضافی موجود در شبکه عصبی حافظه طولانی کوتاه مدت می شوند. معادلات ۹ تا ۱۲، نحو محاسبات شبکه واحد بازگشتی دروازه ای را بیان می کنند.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (9)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (10)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t] + b_h) \quad (11)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (12)$$



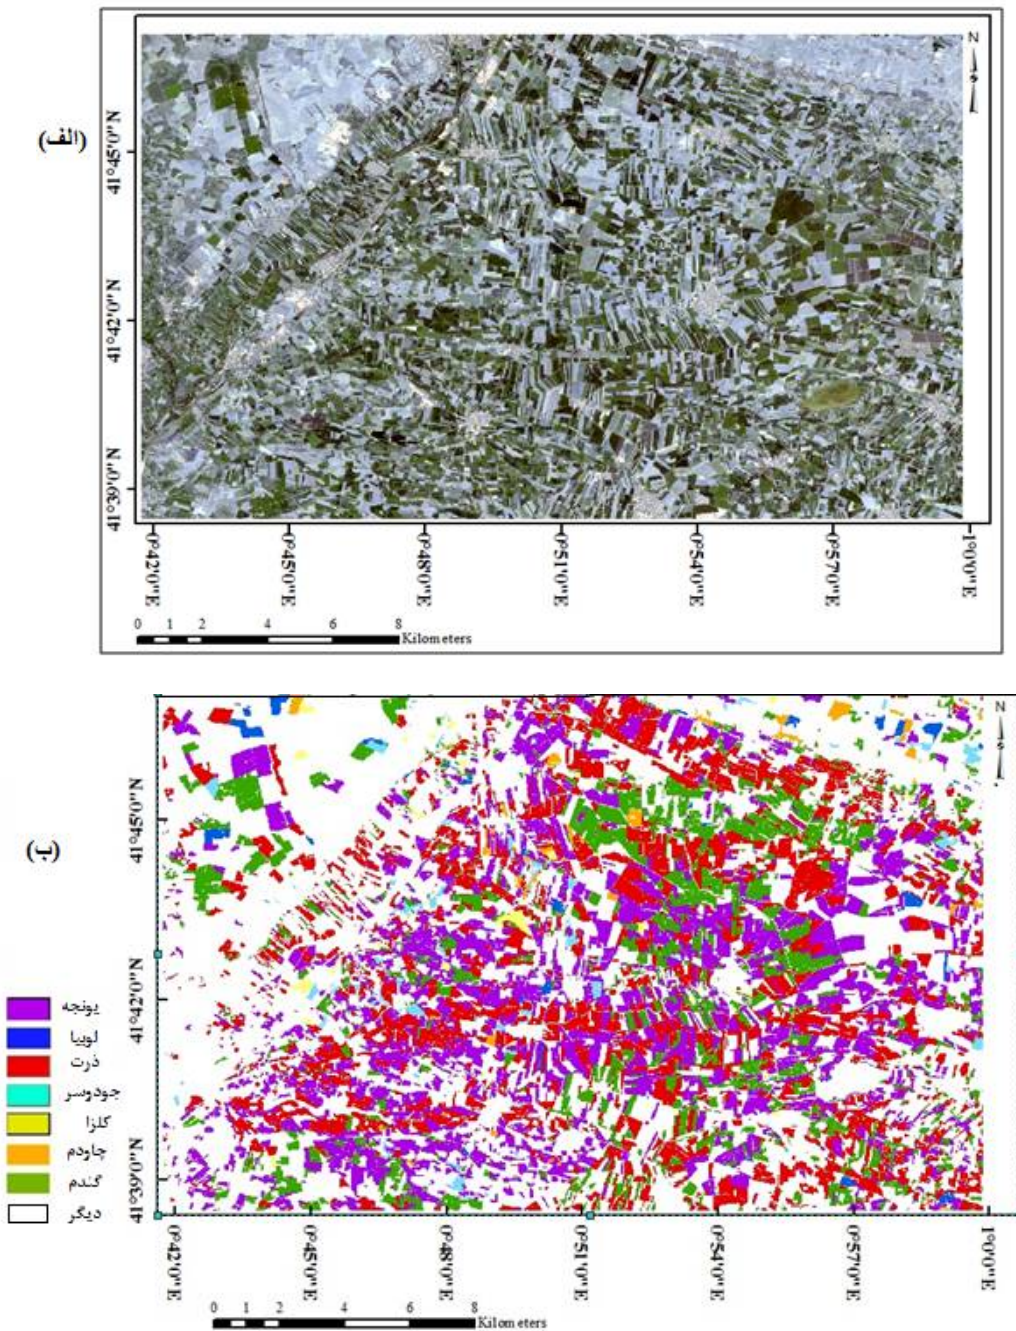
شکل ۲: معماری سلول شبکه واحد بازگشتی دروازه ای [۲۹]

$h_t$  بیانگر بردارهای لایه میانی،  $x_t$  بردار ورودی،  $b_z, b_r, b_h$  بردارهای بایاس شبکه،  $W_z, W_r, W_h$  ماتریس های پارامتر و تابع های فعالیت شبکه با  $\sigma$  و  $\tanh$  نشان داده شده است.

زمین با دقت بالا و تصاویر ماهواره‌ای مرتبط به آن بازه زمانی می‌باشد. در این تحقیق به منظور شناسایی و طبقه‌بندی محصولات، از تصاویر نوری سنتینل ۲ استفاده شده است. ماهواره سنتینل ۲ در ۲۳ ژوئن ۲۰۱۵، مأموریت خود را آغاز کرد. تصاویر این ماهواره شامل ۱۳ باند طیفی در محدوده مرئی، مادون قرمز، مادون قرمز نزدیک و مادون قرمز طول موج کوتاه است.

### ۳- مشخصات داده‌های مورد استفاده و پیش پردازش

منطقه مورد مطالعه در بخش شمال شرقی اسپانیا واقع شده است که شامل محصولات مختلفی از قبیل یونجه، ذرت، گندم، جو دوسر، چاودم، لوبیا و کلزا است (شکل ۳). برتری انتخاب این داده، در دسترس بودن داده واقعی



شکل ۳: الف) منطقه مطالعاتی ب) نقشه واقعیت زمین

با توجه به تحقیقات صورت گرفته، استفاده از چهار باند طیفی تصاویر سنتینل-۲ برای اهداف طبقه‌بندی کفایت می‌کند و استفاده از باندهای بیشتر از این تصاویر باعث بهبود دقت طبقه‌بندی نخواهد شد [۳۳]. بنابراین، در این مطالعه از چهار باند طیفی، قرمز، سبز، آبی و مادون قرمز با قدرت تفکیک ۱۰ متر استفاده شده است. پیش‌پردازش‌های لازم بر این تصاویر شامل تصحیحات هندسی و اتمسفریک است.

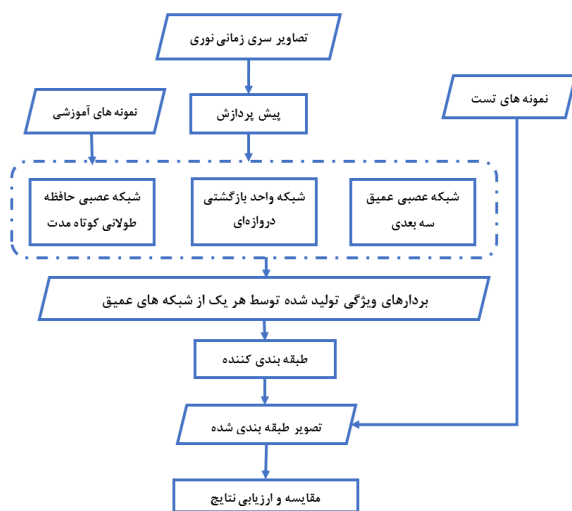
در این تحقیق، با توجه به تقویم زراعی محصولات، شش تصویر در ماه‌های فوریه، آوریل، مه، ژوئن، ژوئیه و اوت در نظر گرفته شده است که از تصویر ماه مارس به دلیل وجود ابر صرف نظر شد. همچنین، جهت پیاده‌سازی الگوریتم‌ها، منطقه‌ای با ابعاد ۱۵۹۳×۲۵۱۶ پیکسل انتخاب شد که نقشه واقعیت زمین مرتبط به آن منطقه در سطح وسیع توسط سازمان کشاورزی شهر کاتالونیا جمع‌آوری شده است. در نهایت، برای آموزش شبکه و ارزیابی نتایج به ترتیب ۱۲۰۰ و ۴۰۰۰ نمونه آموزشی و تست در نظر گرفته شد.

#### ۴- روش تحقیق

در این تحقیق، ابتدا شبکه عصبی کانولوشن سه‌بعدی برای طبقه‌بندی محصولات پیاده‌سازی شد. در این راستا، به منظور استخراج ویژگی‌های زمانی-مکانی، ساختار داده‌های ورودی به این شبکه‌ها، مطابق با روش پیشنهاد شده توسط Ji و همکارانش [۲۰] تنظیم گردید. سپس، به تجزیه و تحلیل نقاط ضعف و قوت، تأثیر ویژگی‌های استخراج شده از این شبکه‌ها نسبت به روش‌های شبکه‌های عصبی بازگشتی (عصبی حافظه طولانی-کوتاه مدت، واحد بازگشتی دروازه‌ای) در شناسایی محصولات پرداخته شد. شکل ۴، روند کلی تحقیق را نشان می‌دهد.

از سوی دیگر، برای داشتن یک شبکه عمیق با کارایی بالا، تنظیم پارامترهای شبکه، نقش مهمی در آموزش آن دارد. در این راستا، با بررسی‌های متعددی که از طریق آزمون سعی و خطا صورت گرفته است، بهترین پارامترهای بهینه برای سه شبکه انتخاب شدند. همچنین، هشت نرون در لایه خروجی هر شبکه تنظیم شد که وظیفه تصمیم‌گیری درباره ماهیت قطعه‌های ورودی را به عهده دارند. جهت ارزیابی نتایج طبقه‌بندی، ماتریس خطا [۳۴] مورد استفاده قرار گرفت که این ماتریس حاصل شده از مقایسه پیکسل معلوم (واقعیت زمین) با پیکسل متناظر در نتایج طبقه‌بندی می‌باشد. با

استفاده از درایه‌های تشکیل شده از این ماتریس، سه معیار دقت کلی، ضریب کاپا و دقت شناسایی محصول (دقت کلاسی) برای تحلیل و ارزیابی نتایج حاصل از طبقه‌بندی محصولات در نظر گرفته شده است.



شکل ۴: روند کلی تحقیق

#### ۵- پیاده‌سازی

با هدف پیاده‌سازی شبکه‌های عصبی کانولوشن و بازگشتی، شش تصویر سنتینل ۲ در ماه‌های فوریه، آوریل، مه، ژوئن، ژوئیه و اوت انتخاب شدند. در ادامه، ساختار و معماری پیشنهاد شده برای شبکه عصبی سه‌بعدی در بخش ۵-۱ توضیح داده می‌شود. سپس در بخش ۵-۲، ساختار و معماری شبکه عصبی بازگشتی ارائه شده است. در نهایت در بخش ۵-۳، نحو تنظیم پارامترهای هر شبکه توضیح داده خواهد شد.

##### ۵-۱- شبکه‌های عصبی کانولوشن سه‌بعدی

در الگوریتم‌های مبتنی بر ویژگی، هرچه بردارهای ویژگی استخراج شده از تصویر، مفیدتر باشند نتایج طبقه‌بندی تحت تأثیر آن بهبود چشمگیرتری خواهند داشت. از سویی، تصاویر چند زمانه نوری حاوی اطلاعات مکان، طیف و زمان می‌باشند. به منظور بهره‌برداری از تمام این اطلاعات، وجود یک معماری که قادر به استخراج تمامی این ویژگی‌ها به طور همزمان باشد احساس می‌شود. اما از آنجاکه شبکه‌های عصبی کانولوشن دوبعدی به دلیل ریاضیات خود (در نظر گرفتن کرنل‌های دوبعدی)

### ۵-۳- تنظیم پارامترهای هر شبکه عمیق

از آنجاکه در پیاده‌سازی شبکه‌های عصبی کانولوشن سه‌بعدی، برخی پارامترها نقش اساسی را در نتایج طبقه‌بندی ایفا می‌کنند. بنابراین، با استفاده از روش تجربی سعی شد بهترین پارامترها برای هر شبکه عمیق انتخاب شوند. در این مطالعه، اندازه قطعه ورودی با ابعاد مختلف از قبیل  $7 \times 7$ ،  $9 \times 9$ ،  $11 \times 11$ ،  $13 \times 13$ ،  $15 \times 15$ ، ...،  $23 \times 23$  بررسی شدند. بهترین ابعاد قطعه ورودی برابر  $7 \times 7$  بوده است. همچنین، بهترین پارامترهای شبکه برای نرخ یادگیری، تعداد دوره زمانی و اندازه ریزنمونه‌ها به ترتیب  $0.001$ ،  $1000$  و  $500$  می‌باشند. برای پیاده‌سازی شبکه‌های عصبی بازگشتی نیز با استفاده از آزمون تجربی سعی و خطا، پارامترهای مختلفی از قبیل تعداد دوره زمانی، تعداد واحدهای لایه میانی، تعداد سلول‌ها بررسی شده‌است. در نهایت بهترین مقدار عددی هر پارامتر برای داشتن یک شبکه بهینه برای طبقه‌بندی محصولات استفاده شد که مهم‌ترین این پارامترها عبارتند از تعداد دوره زمانی برای هر دو شبکه بازگشتی برابر  $1000$  است. از طرفی، اندازه ریزنمونه‌ها برای شبکه‌های عصبی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای به ترتیب  $20$  و  $50$  انتخاب شده‌است.

در این تحقیق، فرایند آموزش شبکه‌ها برای تمامی آزمایش‌ها در محیط برنامه‌نویسی Python و با استفاده از کتابخانه Keras با TensorFlow backend در محیط ubuntu پیاده‌سازی شده‌است. سیستم مورد استفاده مجهز به کارت پردازنده گرافیکی GTX 1080 TI و با  $32$  گیگابایت RAM بوده‌است.

### ۶- ارزیابی نتایج

در ادامه این مقاله، نتایج بدست‌آمده از طبقه‌بندی محصولات توسط شبکه‌های عصبی عمیق ارائه و نتایج مورد تجزیه و تحلیل قرار می‌گیرند. به‌منظور ارزیابی نقشه‌های طبقه‌بندی‌شده، از ماتریس خطا<sup>۲</sup> استفاده گردید که درایه‌های این ماتریس، از چهار مفهوم اصلی، مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب تشکیل شده‌است. مثبت و منفی واقعی بیانگر تعداد پیکسل‌هایی است به‌درستی در کلاس‌های مرتبط، طبقه‌بندی شده‌اند که

اطلاعات زمان را از دست می‌دهند [۲۳]، به همین منظور، جهت در اختیار داشتن تمامی ویژگی‌های زمانی-مکانی، یک شبکه عصبی کانولوشن سه‌بعدی طراحی شد.

در این شبکه، به‌منظور استخراج بهترین ویژگی‌های زمانی-مکانی، از ساختار پیشنهادشده برای قطعه‌های ورودی توسط  $I_1$  و همکارانش استفاده گردید. در این ساختار، اگر  $M$  تصویر سری زمانی در  $N$  باند طیفی وجود داشته باشد، ابتدا تمامی باندها از یکدیگر تفکیک‌شده، سپس تمامی تصاویر زمانی در یک باند خاص، مانند سبز پشت‌سره‌م قرار خواهند گرفت. سپس یک شبکه با  $N$  شاخه ورودی تشکیل می‌شود که ورودی هر شاخه، طبق ساختار توضیح داده شده در هر باند می‌باشد که در هر شاخه یک اپراتور کانولوشن با  $32 \times 32$  فیلتر طراحی شده‌است. سپس تابع فعال‌ساز Relu بر خروجی هر شاخه اعمال می‌شود و در نهایت بردارهای ویژگی تولید شده در هر  $N$  شاخه، نظیر به نظیر با یکدیگر جمع می‌شوند. در مرحله بعد، سه اپراتور کانولوشن سه‌بعدی با تعداد کرنل‌های مختلف به ترتیب  $32$ ،  $32$  و  $64$  طراحی شدند. در این شبکه، ابعاد بهینه کرنل‌ها  $3 \times 3 \times 3$  در نظر گرفته شده‌اند. تابع فعالیت غیرخطی Relu، بر خروجی هر یک از این اپراتورها اعمال می‌شود. سپس یک عملگر ماکزیمم پولینگ سه‌بعدی با ابعاد  $1 \times 2 \times 2$  بکار برده شد. سپس ویژگی‌های تولیدشده از آخرین اپراتور کانولوشن، به دولایه تماماً متصل متوالی به ترتیب با تعداد نرون‌های  $128$  و  $64$  نرون داده شده‌است. در نهایت، هشت نرون در لایه خروجی برای برچسب‌دهی کلاس به هر پیکسل تنظیم شد. بیان این نکته حائز اهمیت است که جهت جلوگیری از مشکل بیش برآزش<sup>۱</sup> شبکه، بعد از هر لایه تماماً متصل از یک لایه dropout برابر با  $0.4$  استفاده شده‌است.

### ۵-۲- شبکه‌های عصبی بازگشتی

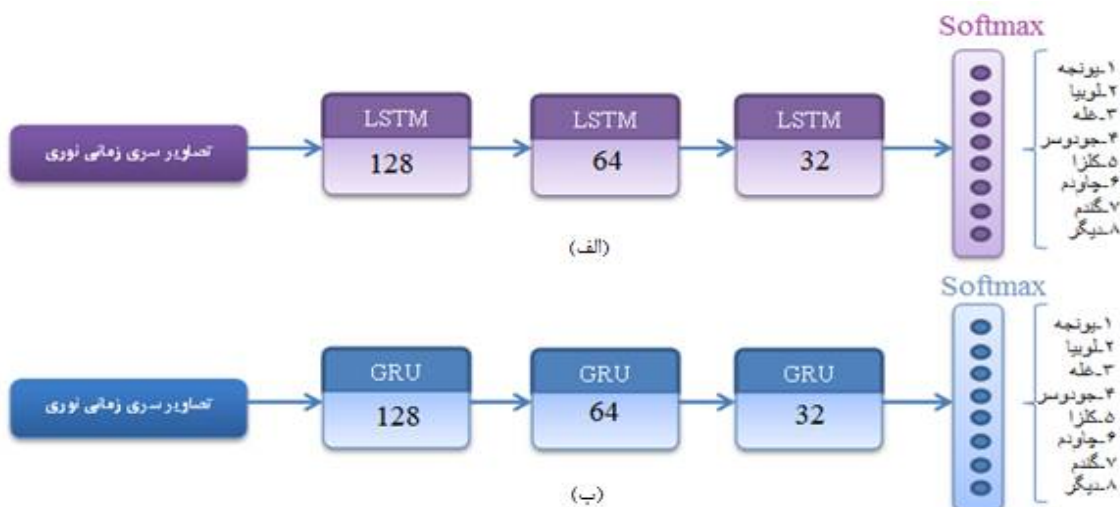
شکل‌های (۵-الف) و (۵-ب)، معماری طراحی‌شده برای طبقه‌بندی محصولات توسط هر دو شبکه بازگشتی را نشان می‌دهند که در سه سلول میانی این شبکه‌ها،  $128$ ،  $64$ ،  $32$  واحد به ترتیب طراحی شده‌است. سپس در لایه آخر، از تابع softmax به عنوان یک طبقه‌بندی‌کننده استفاده شد و همچنین باندهای طیفی تصاویر سری زمانی نوری به‌عنوان بردار ورودی به این شبکه‌ها تغذیه شده‌است.

<sup>۲</sup> Confusion Matrix

<sup>۱</sup> Overfitting

که به‌اشتباه در کلاس دیگر طبقه شده‌اند که مقادیر غیر قطر اصلی را تشکیل می‌دهند.

شامل مقادیر واقع در قطر اصلی این ماتریس هستند. همچنین، مثبت و منفی کاذب بیان‌کننده پیکسل‌هایی است



شکل ۵: الف) معماری شبکه عصبی حافظه طولانی کوتاه‌مدت و ب) معماری شبکه واحد بازگشتی دروازه‌ای

بازگشتی تنها ویژگی‌هایی زمانی را استخراج می‌نمایند. در مقایسه بین دو روش شبکه عصبی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای مشاهده می‌شود عملکرد شبکه واحد بازگشتی دروازه‌ای به‌مراتب بهتر از شبکه عصبی حافظه طولانی کوتاه‌مدت بوده‌است که می‌توان دلیل آن را ساختار بهینه آن دانست که در بخش ۱-۲ توضیح داده شده‌است. با این وجود، عملکرد شبکه واحد بازگشتی دروازه‌ای بسیار نزدیک به شبکه عصبی کانولوشن سه‌بعدی است.

از مقایسه دقت کلاسی محصولات مختلف می‌توان پی برد که عملکرد شبکه عصبی کانولوشن سه‌بعدی در تمامی کلاس‌ها بهتر بوده‌است. این شبکه در شناسایی ذرت، گندم و چاودم در حدود ۶۰٪، ۹۰٪ و ۲۹۰٪ بهتر از شبکه عصبی حافظه طولانی کوتاه‌مدت عمل کرده‌است. همچنین، عملکرد شبکه عصبی کانولوشن در کلاس‌های گندم، چاودم و ذرت عملکرد چشمگیری نسبت به شبکه عصبی واحد بازگشتی دروازه‌ای داشته‌است. از طرفی، هر سه شبکه عمیق در شناسایی یونجه عملکرد مناسبی نداشته‌اند. در حالیکه شبکه عصبی کانولوشن سه‌بعدی در شناسایی چاودم و کلزا به ترتیب به دقت کلاسی ۹۹٫۵۰٪ و ۹۷٫۴۰٪ رسیده‌است که عملکرد بسیار چشمگیری داشته‌است.

از سوی دیگر، دقت کلی نسبت مجموع پیکسل‌های صحیح طبقه‌بندی شده را به پیکسل‌های معلوم نشان می‌دهد. یکی از ضعف‌های این پارامتر، بکارگیری تنها اطلاعات واقع در قطر این ماتریس می‌باشد و از اطلاعات مفید غیر قطری چشم‌پوشی می‌نماید. از سوی دیگر، به‌منظور ارزیابی صحت نتایج طبقه‌بندی، از پارامتر کاپا استفاده شده‌است. این معیار دقت طبقه‌بندی را نسبت به یک طبقه‌بندی کاملاً تصادفی محاسبه می‌نماید. مزیت این معیار نسبت به دقت کلی این می‌باشد که از مقادیر غیرقطری ماتریس خطا در محاسبه این پارامتر استفاده می‌شود، بنابراین، از نقش شانس در طبقه‌بندی صرف‌نظر می‌کند. از سوی دیگر، دقت کلاسی بیانگر نسبت تعداد پیکسل‌های درست طبقه‌بندی شده به کل پیکسل‌ها در آن کلاس می‌باشد.

جدول ۱، ۲ و ۳ به ترتیب نتایج بدست‌آمده از طبقه‌بندی محصولات کشاورزی توسط شبکه عصبی کانولوشن سه‌بعدی، شبکه عصبی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای را نشان می‌دهند. باتوجه به دقت کلی حاصل شده از این روش‌ها، می‌توان بیان نمود که روش شبکه عصبی کانولوشن سه‌بعدی دقت کلی بالاتری نسبت به دو روش دیگر داشته‌است. دلیل این امر را می‌توان بکارگیری ویژگی‌های مکانی و زمانی در این شبکه دانست. این در حالی است که دو شبکه عصبی



جدول ۱: پارامترهای ارزیابی نتایج شبکه عصبی کانولوشن سه‌بعدی

دقت تولیدکننده (%)	دیگر	گندم	چاودم	کلزا	جو دوسر	ذرت	لوبیا	یونجه	
۸۹.۳۰	۳۸	۷	۲	۱۰	۱۳	۲۱	۵	۸۰.۱	یونجه
۹۴.۸۹	۱۹	۴	۰	۶	۵	۴	۹۱.۰	۱۱	لوبیا
۸۱.۶۳	۴۸	۲۵	۲	۳	۱۷	۹۰.۲	۱۷	۹۱	ذرت
۹۷.۸۰	۶	۶	۱	۰	۹۳.۵	۰	۵	۳	جودوسر
۹۶.۹۲	۱۰	۵	۰	۹۷.۴	۰	۰	۱	۱۵	کلزا
۹۲.۶۴	۲۷	۲	۹۹.۵	۰	۱۴	۲	۱۲	۲۲	چاودم
۸۸.۷۹	۴۸	۹۳.۵	۰	۵	۴	۱۶	۲۵	۲۰	گندم
۸۴.۵۴	۸۰.۴	۱۶	۰	۲	۱۲	۵۵	۲۵	۳۷	دیگر
دقت مصرف‌کننده (دقت کلاسی) (%)	۸۰.۴۰	۹۳.۵۰	۹۹.۵۰	۹۷.۴۰	۹۳.۵۰	۹۰.۲۰	۹۱.۰۰	۸۰.۱۰	
دقت کلی (%) :			۹۰.۷۰						
ضریب کاپا (%) :			۸۹.۳۷						

نیز تأییدکننده این نتیجه‌گیری (شباهت طیفی یونجه و ذرت) می‌باشند. از مقایسه دیگر مقادیر واقع در جداول فوق مشخص می‌شود که گندم و ذرت تا حدی دارای شباهت طیفی می‌باشند. به‌منظور تفسیر چشمی عملکرد سه شبکه عمیق در طبقه‌بندی محصولات، یک‌بخشی از منطقه مطالعاتی (شکل ۶-ت) انتخاب شد.


از سوی دیگر، ماتریس خطای شبکه عصبی کانولوشن سه‌بعدی نشان می‌دهد که تعداد پیکسل‌های کلاس یونجه که به‌اشتباه در کلاس ذرت طبقه‌بندی شده‌اند نسبت به دیگر کلاس‌ها بیشتر می‌باشند که می‌توان دلیل این امر را شباهت طیفی این دو محصول دانست. همچنین، مقادیر متناظر واقع در ماتریس خطا در دو شبکه عصبی بازگشتی

جدول ۲: پارامترهای ارزیابی نتایج شبکه عصبی حافظه طولانی کوتاه‌مدت


دقت تولیدکننده (%)	دیگر	گندم	چاودم	کلزا	جودوسر	ذرت	لوبیا	یونجه	
۸۰.۸۲	۴۲	۱۳	۱	۵	۱۰	۱۴	۹	۳۹.۶	یونجه
۹۳.۲۹	۱۴	۲	۶	۰	۳	۵	۴۴.۵	۲	لوبیا
۸۳.۰۴	۱۳	۲۴	۳	۰	۱۱	۴۲.۱	۷	۲۸	ذرت
۸۹.۵۷	۲۳	۹	۱	۰	۴۵.۵	۰	۱۷	۳	جودوسر
۹۲.۴۳	۴	۱۲	۰	۴۷.۶	۰	۱	۱۱	۱۱	کلزا
۸۶.۵۶	۸	۱۳	۴۸.۳	۲	۱۱	۱۲	۵	۲۴	چاودم
۸۹.۹۸	۶	۴۲.۲	۲	۱۱	۳	۲۱	۳	۱	گندم
۸۱.۹۳	۳۹.۰	۵	۴	۶	۷	۲۶	۳	۳۵	دیگر
دقت مصرف‌کننده (دقت کلاسی) (%)	۷۸.۰۰	۸۴.۴۰	۹۶.۶۰	۹۵.۲۰	۹۱.۰۰	۸۴.۲۰	۸۹.۰۰	۷۹.۲۰	
دقت کلی (%) :			۸۷.۲۰						
ضریب کاپا (%) :			۸۵.۳۷						

جدول ۳: پارامترهای ارزیابی نتایج شبکه واحد بازگشتی دروازه‌ای


	یونجه	لوبیا	ذرت	جودوسر	کلزا	چاودم	گندم	دیگر	دقت تولیدکننده (%)
یونجه	۴۰۰	۶	۱۴	۲	۵	۰	۲۴	۳۶	۸۲.۱۴
لوبیا	۲	۴۵۰	۴	۶	۲	۰	۶	۶	۹۴.۵۴
ذرت	۲۵	۹	۴۴۳	۱۰	۰	۱	۱۹	۲۱	۸۳.۹۰
جودوسر	۲	۱۳	۰	۴۶۵	۰	۲	۷	۱۷	۹۱.۹۰
کلزا	۲۴	۶	۰	۰	۴۸۶	۰	۱	۴	۹۳.۲۸
چاودم	۱۹	۱۲	۶	۵	۲	۴۸۸	۱	۹	۹۰.۰۴
گندم	۱۳	۳	۲۰	۲	۰	۹	۴۴۲	۱۲	۸۸.۲۲
دیگر	۱۵	۱	۱۳	۱۰	۵	۰	۰	۳۹۵	۸۹.۹۸
دقت مصرف‌کننده (دقت کلاسی) (%)	۸۰.۰۰	۹۰.۰۰	۸۸.۶۰	۹۳.۰۰	۹۷.۳۰	۹۷.۶۰	۸۸.۴۰	۷۹.۰۰	
دقت کلی (%):									۸۹.۲۳
ضریب کاپا (%):									۸۷.۶۹



شکل ۶: خروجی حاصل شده از طبقه‌بندی بخشی از منطقه مطالعاتی توسط الف) شبکه عصبی کانولوشن سه‌بعدی ب) شبکه عصبی واحد بازگشتی دروازه‌ای ج) شبکه عصبی حافظه طولانی کوتاه‌مدت د) نقشه واقعیت زمین



(ب)



(الف)

شکل ۷: نمودار ارزیابی پارامترهای سه روش شبکه عصبی عمیق (الف) منطقه مطالعاتی اول و (ب) منطقه مطالعاتی دوم

از کلاس‌ها انتخاب شده‌اند. تمامی الگوریتم‌های شبکه عصبی عمیق بر این منطقه به طور مجدد پیاده‌سازی شدند. در تمامی شبکه‌های عمیق، تعداد پارامترهای بهینه بررسی و انتخاب شدند. نتایج حاصل شده مجدداً برتری شبکه‌های عصبی کانولوشن سه بعدی را نشان می‌دهند.

جدول ۵: پارامترهای ارزیابی نتایج شبکه عصبی واحد بازگشتی دروازه‌ای

محصول	جو	ذرت	گندم	دقت تولیدکننده (%)
جو	۴۴۶۵	۲۱۶	۴۵۲	۹۹.۸۶
ذرت	۱۲۵	۴۳۶۹	۵۲۱	۱۲.۸۷
گندم	۴۱۰	۴۱۵	۴۰۲۷	۰۰.۸۳
دقت مصرف‌کننده (%)	۳۰.۸۹	۳۸.۸۷	۵۴.۸۰	
دقت کلی (%):				۷۴.۸۵
ضریب کاپا (%):				۶۱.۷۸

جدول ۶: پارامترهای ارزیابی نتایج شبکه عصبی حافظه طولانی کوتاه مدت

محصول	جو	ذرت	گندم	دقت تولیدکننده (%)
جو	۴۲۱۳	۲۵۷	۶۶۸	۰۰.۸۲
ذرت	۱۷۳	۴۳۱۹	۶۱۶	۵۵.۸۴
گندم	۶۱۴	۴۲۴	۳۷۱۶	۱۷.۷۸
دقت مصرف‌کننده (%)	۲۶.۸۴	۳۸.۸۶	۳۲.۷۴	
دقت کلی (%):				۶۵.۸۱
ضریب کاپا (%):				۴۸.۷۲

از مقایسه بین نقشه‌های طبقه‌بندی شده توسط شبکه‌های عصبی عمیق با نقشه واقعیت زمین، شبکه عصبی کانولوشن سه بعدی عملکرد بهتری داشته‌است. سپس، بر روی نقشه‌های تولید شده، دایره‌های زرد رنگ نشان داده شده‌است که از مشاهده و مقایسه این نواحی می‌توان نتیجه گرفت که نویز در تصویر طبقه‌بندی شده توسط شبکه عصبی کانولوشن سه بعدی کمتر می‌باشد و نتایج آن همگن‌تر از دو شبکه عصبی بازگشتی است.


جدول ۴: پارامترهای ارزیابی نتایج شبکه کانولوشن سه بعدی

محصول	جو	ذرت	گندم	دقت تولیدکننده (%)
جو	۴۵۸۹	۲۲۳	۳۸۷	۱۰.۸۸
ذرت	۴۳	۴۳۰۳	۳۷۸	۰۹.۹۱
گندم	۳۶۸	۴۶۴	۴۲۳۵	۵۸.۸۳
دقت مصرف‌کننده (%)	۷۸.۹۱	۰۶.۸۶	۷۰.۸۴	
دقت کلی (%):				۵۱.۸۷
ضریب کاپا (%):				۲۷.۸۱


به منظور ارزیابی بیشتر عملکرد سه روش شبکه عصبی عمیق، منطقه‌ای دیگر از نواحی کشاورزی اسپانیا با ابعاد ۲۱۶۲×۳۸۸۰ پیکسل (شکل ۸) انتخاب شد. این منطقه شامل سه نوع محصول عمده، گندم، ذرت و جو می‌باشد. با توجه به تقویم زراعی محصولات تصاویر سنتینل ۲-، چهار ماه، فوریه، آوریل، مه و ژوئن در نظر گرفته شدند. همچنین به منظور آموزش و ارزیابی دقت، ۵۰۰۰ قطعه آموزشی و 5000 قطعه تست به طور تصادفی از بخش‌های مختلف تصویر برای هر یک




(الف)




(ب)




(ت)



(پ)



(ج)



(ث)

شکل ۸: (الف) منطقه مطالعاتی دوم، (ب) نقشه واقعیت زمین، (پ) نقشه واقعیت زمین بخشی از منطقه دوم، (ت) شبکه عصبی کانولوشن سه‌بعدی، (ث) شبکه عصبی واحد بازگشتی دروازه‌ای و (ج) شبکه عصبی حافظه طولانی کوتاه‌مدت

جداول ۴، ۵، ۶ و نمودار (۷-ب) نتایج بدست‌آمده از سه روش شبکه عصبی عمیق را نشان می‌دهد که عصبی کانولوشن سه‌بعدی در تشخیص دو محصول گندم و جو نسبت به دو شبکه عصبی بازگشتی عملکرد قویتری داشته‌است. در شناسایی ذرت، عملکرد ذرت با استفاده از شبکه عصبی واحد بازگشتی دروازه‌ای بهتر بوده‌است. بطور کل، شبکه عصبی کانولوشن سه‌بعدی با دقت کلی و ضریب کاپا به ترتیب ۸۷.۵۱ و ۸۱.۲۷ نشان می‌دهد توانایی بیشتری نسبت به دو شبکه عصبی بازگشتی در شناسایی محصولات داشته‌است.

به‌منظور تفسیر چشمی نتایج طبقه‌بندی سه روش شبکه عصبی، یک زیرمجموعه از این منطقه انتخاب شد. همانطور که در شکل (۸) نشان می‌دهد نتایج حاصل شده از شبکه عصبی کانولوشن سه‌بعدی بسیار همگن‌تر بوده است و برخلاف آن نتایج حاصل از شبکه عصبی حافظه طولانی کوتاه‌مدت نوین بیشتر و حتی در شناسایی ذرت در برخی مزارع ضعیف عمل کرده‌است.

## ۷- نتیجه‌گیری

داده‌های چند زمانه نوری از دوره رشد محصول اطلاعات ارزشمندی برای تفکیک و طبقه‌بندی محصولات کشاورزی در اختیار محققین قرار می‌دهد. با این وجود، ارائه روشی خودکار که قادر به استخراج ویژگی‌های بهینه زمانی-مکانی و طیفی از این داده‌ها باشند، هنوز یک چالش جدی برای محققین به شمار می‌آید. در این مقاله، به بررسی روش‌های

## مراجع

مختلف شبکه‌های عصبی عمیق مانند شبکه‌های عصبی کانولوشن سه‌بعدی، شبکه‌های عصبی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای برای طبقه‌بندی محصولات از تصاویر سری زمانی نوری پرداخته شده‌است. این روش‌ها، قادر به شناسایی تغییرات زمانی در طول دوره رشد محصول می‌باشند. بنابراین، ما در این تحقیق، از پتانسیل این روش‌ها در استخراج ویژگی‌های زمانی بهره بردیم. در این راستا، به‌منظور دستیابی به یک طبقه‌بندی با عملکرد قوی، معماری‌های مختلفی از آن‌ها در نظر گرفته شده‌است. در ادامه، به بررسی قابلیت آن‌ها در استخراج ویژگی‌های بهینه پرداخته شده‌است. سپس، با بررسی‌های صورت گرفته در این تحقیق مشخص شد که شبکه عصبی کانولوشن سه‌بعدی عملکرد موفقیت‌آمیزی نسبت به شبکه‌های عصبی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای در طبقه‌بندی محصولات داشته‌است. همان‌طور که در تحقیق نشان داده شده است، دقت کلی شناسایی محصولات در شبکه‌های عصبی کانولوشن سه‌بعدی به ترتیب ۳۵.۰٪ و ۴۸.۱٪ نسبت به شبکه عصبی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای عملکرد بهتری داشته‌است. درحالی‌که در مقایسه دو روش شبکه عصبی بازگشتی، شبکه واحد بازگشتی دروازه‌ای قابلیت بیشتری نسبت به شبکه عصبی حافظه طولانی کوتاه‌مدت در تفکیک محصولات داشته‌است. در تحقیقات آینده، به بررسی توانایی شبکه‌های عصبی کانولوشن سه‌بعدی در طبقه‌بندی محصولات توسط تصاویر رادار پرداخته خواهد شد.

- [۱] X.-P. Song, P. V. Potapov, A. Krylov, L. King, C. M. Di Bella, A. Hudson, A. Khan, B. Adusei, S. V. Stehman, and M. C. Hansen, "National-scale soybean mapping and area estimation in the United States using medium resolution satellite imagery and field survey," *Remote Sensing of Environment*, vol. 190, pp. 383-395, 2017.
- [۲] D. Haboudane, N. Tremblay, J. R. Miller, and P. Vigneault, "Remote estimation of crop chlorophyll content using spectral indices derived from hyperspectral data," *IEEE Transactions on Geoscience and remote Sensing*, vol. 46, pp. 423-437, 2008.
- [۳] E. Cloutis, D. Connery, D. Major, and F. Dover, "Airborne multi-spectral monitoring of agricultural crop status: effect of time of year, crop type and crop condition parameter," *Remote Sensing*, vol. 17, pp. 2579-2601, 1996.
- [۴] A. Verhegghen, S. Bontemps, and P. Defourny, "A global NDVI and EVI reference data set for land-surface phenology using 13 years of daily SPOT-VEGETATION observations," *International Journal of remote sensing*, vol. 35, pp. 2440-2471, 2014.
- [۵] S. Niazmardi, S. Homayouni, A. Safari, H. McNairn, J. Shang, and K. Beckett, "Histogram-based spatio-temporal feature classification of vegetation indices time-series for crop mapping," *International Journal of Applied Earth Observation and Geoinformation*, vol. 72, pp. 34-41, 2018.

- [۶] N. Kussul, L. Mykola, A. Shelestov, and S. Skakun, "Crop inventory at regional scale in Ukraine: developing in season and end of season crop maps with multi-temporal optical and SAR satellite imagery," *European Journal of Remote Sensing*, vol. 51, pp. 627-636, 2018.
- [۷] F. Vuolo, M. Neuwirth, M. Immitzer, C. Atzberger, and W.-T. Ng, "How much does multi-temporal Sentinel-2 data improve crop type classification?," *International Journal of Applied Earth Observation and Geoinformation*, vol. 72, pp. 122-130, 2018.
- [۸] G. V. Laurin, C. Belli, R. Bianconi, P. Laranci, and D. Papale, "Early mapping of industrial tomato in Central and Southern Italy with Sentinel 2, aerial and RapidEye additional data," *The Journal of Agricultural Science*, vol. 156, pp. 396-407, 2018.
- [۹] G. Waldhoff, U. Lusse, and G. Bareth, "Multi-Data Approach for remote sensing-based regional crop rotation mapping: A case study for the Rur catchment, Germany," *International Journal of Applied Earth Observation and Geoinformation*, vol. 61, pp. 55-69, 2017.
- [۱۰] D. I. Moody, S. P. Brumby, R. Chartrand, R. Keisler, N. Longbotham, C. Mertes, S. W. Skillman, and M. S. Warren, "Crop classification using temporal stacks of multispectral satellite imagery," in *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XXIII*, 2017, p. 101980G.
- [۱۱] H. Qiong, W.-b. WU, S. Qian, L. Miao, C. Di, Q.-y. YU, and H.-j. TANG, "How do temporal and spectral features matter in crop classification in Heilongjiang Province, China?," *Journal of integrative agriculture*, vol. 16, pp. 324-336, 2017.
- [۱۲] B. Mulianga, A. Bégué, P. Clouvel, and P. Todoroff, "Mapping cropping practices of a sugarcane-based cropping system in Kenya using remote sensing," *Remote Sensing*, vol. 7, pp. 14428-14444, 2015.
- [۱۳] M. Teimouri, M. Mokhtarzade, N. Baghdadi, and C. Heipke, "Fusion of Time-Series Optical and SAR Images Using 3D Convolutional Neural Networks for Crop Classification," *Geocarto International*, no. just-accepted, pp. 1-16, 2022.
- [۱۴] T. Xia *et al.*, "Exploring the potential of Chinese GF-6 images for crop mapping in regions with complex agricultural landscapes," *International Journal of Applied Earth Observation and Geoinformation*, vol. 107, p. 102702, 2022.
- [۱۵] T. Sakamoto, "Early Classification Method for US Corn and Soybean by Incorporating MODIS-Estimated Phenological Data and Historical Classification Maps in Random-Forest Regression Algorithm," *Photogrammetric Engineering & Remote Sensing*, vol. 87, no. 10, pp. 747-758, 2021.
- [۱۶] C. Zhang *et al.*, "Rapid in-season mapping of corn and soybeans using machine-learned trusted pixels from Cropland Data Layer," *International Journal of Applied Earth Observation and Geoinformation*, vol. 102, p. 102374, 2021.
- [۱۷] M. E. Paoletti, J. M. Haut, J. Plaza, and A. Plaza, "A new deep convolutional neural network for fast hyperspectral image classification," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 145, pp. 120-147, 2018.
- [۱۸] Z. Deng, H. Sun, S. Zhou, J. Zhao, L. Lei, and H. Zou, "Multi-scale object detection in remote sensing imagery with convolutional neural networks," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 145, pp. 3-22, 2018.
- [۱۹] M. Voelsen, M. Teimouri, F. Rottensteiner, and C. Heipke, "INVESTIGATING 2D AND 3D CONVOLUTIONS FOR MULTITEMPORAL LAND COVER CLASSIFICATION USING REMOTE SENSING IMAGES," *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 3, pp. 271-279, 2022.
- [۲۰] A. Shakya, M. Biswas, and M. Pal, "CNN-based fusion and classification of SAR and Optical data," *International Journal of Remote Sensing*, vol. 41, no. 22, pp. 8839-8861, 2020.
- [۲۱] L. Zhong, L. Hu, and H. Zhou, "Deep learning based multi-temporal crop classification," *Remote sensing of environment*, vol. 221, pp. 430-443, 2019.
- [۲۲] H. Zhao, S. Duan, J. Liu, L. Sun, and L. Reymondin, "Evaluation of Five Deep Learning Models for Crop Type Mapping Using Sentinel-2 Time Series Images with Missing Information," *Remote Sensing*, vol. 13, no. 14, p. 2790, 2021.
- [۲۳] S. Ji, C. Zhang, A. Xu, Y. Shi, and Y. Duan, "3D Convolutional Neural Networks for Crop Classification with Multi-Temporal Remote Sensing Images," *Remote Sensing*, vol. 10, p. 75, 2018.
- [۲۴] R. Fernandez-Beltran, T. Baidar, J. Kang and F. Pla, "Rice-yield prediction with multi-temporal sentinel-2 data and 3D CNN: A case study in Nepal "Remote Sensing, vol. 13, p. 1391, 2021.

- [۲۵] J. Adrian, V. Sagan and M. Maimaitijiang "Sentinel SAR-optical fusion for crop type mapping using deep learning and Google Earth Engine "ISPRS Journal of Photogrammetry and Remote Sensing, vol. 175, p. 215-235, 2021.
- [۲۶] D. Ienco, R. Gaetano, C. Dupaquier, and P. Maurel, "Land cover classification via multitemporal spatial data by deep recurrent neural networks," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, pp. 1685-1689, 2017.
- [۲۷] D. H. T. Minh, D. Ienco, R. Gaetano, N. Lalande, E. Ndikumana, F. Osman, and P. Maurel, "Deep recurrent neural networks for winter vegetation quality mapping via multitemporal sar sentinel-1," *IEEE Geoscience and Remote Sensing Letters*, vol. 15, pp. 464-468, 2018.
- [۲۸] E. Ndikumana, D. Ho Tong Minh, N. Baghdadi, D. Courault, and L. Hossard, "Deep Recurrent Neural Network for Agricultural Classification using multitemporal SAR Sentinel-1 for Camargue, France," *Remote Sensing*, vol. 10, p. 1217, 2018.
- [۲۹] S. Ji, W. Xu, M. Yang, and K. Yu, "3D convolutional neural networks for human action recognition," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 35, pp. 221-231, 2012.
- [۳۰] S. Hochreiter and J. Schmidhuber, "LSTM can solve hard long time lag problems," *Advances in neural information processing systems*, pp. 473-479, 1997.
- [۳۱] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning phrase representations using RNN encoder-decoder for statistical machine translation," *arXiv preprint arXiv:1406.1078*, 2014.
- [۳۲] Q. Gao, S. Lim, and X. Jia, "Hyperspectral Image Classification Using Convolutional Neural Networks and Multiple Feature Learning," *Remote Sensing*, vol. 10, p. 299, 2018.
- [۳۳] S. Morell-Monzó, J. Estornell, and M.-T. Sebastiá-Frasquet, "Comparison of Sentinel-2 and high-resolution imagery for mapping land abandonment in fragmented areas," *Remote Sensing*, vol. 12, no. 12, p. 2062, 2020.
- [۳۴] Y.Rezaei, SB. Fatemi, "Principles of Remote Sensing," publications of Azade, 1358.