

## کاربرد شبکه‌های عصبی کانولوشن آشکارساز چندجعبه تک شات (SSD) در تشخیص و استخراج خودکار میله چاه‌های قنات از تصاویر ماهواره‌ای گوگل ارث

مصطفی کابلی‌زاده<sup>۱\*</sup>، محمد عباسی<sup>۲</sup>

۱- استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم زمین، دانشگاه شهید چمران اهواز  
۲- دانشجوی دکتری گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم زمین، دانشگاه شهید چمران اهواز

تاریخ دریافت مقاله: ۱۴۰۲/۰۴/۲۱ تاریخ پذیرش مقاله: ۱۴۰۲/۰۹/۰۱

### چکیده

شناسایی قنات‌ها و تهیه نقشه آن‌ها یکی از وظایف حیاتی در علم مدیریت منابع آب‌های زیرزمینی است. با این حال، تهیه نقشه قنات دشوار است، زیرا روش‌های مرسوم مانند نقشه‌برداری میدانی پر هزینه و زمانبر هستند و در برخی مواقع بدلیل ساختار دریاچه چاه‌های قنات، برداشت زمینی با چالش‌های متعددی مواجه است. شناسایی عوارض از داده‌های تصویری با استفاده از تکنیک‌های پردازش تصاویر کامپیوتری و شبکه‌های عصبی یکی از امیدوارکننده‌ترین تکنیک‌ها برای شناسایی چاه‌های قنات است. با توجه به اینکه تصاویر ماهواره‌ای سامانه گوگل ارث، تنها تصاویر ماهواره‌ای با قدرت تفکیک بالای مکانی، بدون هزینه و در دسترس هستند، در این تحقیق از تصاویر ماهواره‌ای گوگل ارث استفاده شده است. در این پژوهش بیش از ۶۰۰ نمونه آموزشی از دهانه میله چاه‌های قنات تهیه شده است و از شبکه عصبی کانولوشن بر مبنای آشکارساز چندجعبه تک شات با پایه شبکه *ResNet*، برای کشف و استخراج خودکار مکان هندسی میله چاه‌های قنات با توجه به سرعت بالاتر انجام پردازش، استفاده شده است. مدل پیشنهادی توسط نمونه‌های آموزشی بر مبنای ۸۵ درصد داده آموزشی و ۱۵ درصد داده اعتبارسنجی، با ۵۰ دوره تکرار و دقت ۸۹ درصد آموزش داده شده است. مدل آموزش دیده بر روی تصویر منطقه مورد مطالعه برای کشف میله چاه‌های قنات اجرا شده است. نتایج نشان می‌دهد که این مدل می‌تواند با معیار دقت برابر ۰/۹۱ و معیار بازیابی برابر ۰/۸۲ و معیار *F1Score* برابر ۰/۸۶ در کشف موقعیت مکانی دهانه میله چاه‌های قنات که دارای شکل مناسب هستند، عمل نماید. برای مناطقی که شکل دهانه میله چاه‌ها تخریب شده است، دقت تشخیص و استخراج موقعیت میله چاه‌ها برابر ۰/۶۵ است. نتایج این پژوهش نشان می‌دهد که امکان تشخیص و استخراج اتوماتیک میله چاه‌های قنات با دقت مناسب از تصاویر ماهواره‌ای دانلود شده از سامانه گوگل ارث امکان‌پذیر است.

کلید واژه‌ها: شبکه عصبی کانولوشن، آشکارساز چندجعبه تک شات، قنات، *ResNet*، گوگل ارث.

\* نویسنده مکاتبه کننده: اهواز، دانشگاه شهید چمران، دانشکده علوم زمین، گروه سنجش از دور و GIS.

تلفن: ۰۹۱۶۳۴۷۰۱۷۷

## ۱- مقدمه

قنات اصلی‌ترین نماد رابطه انسان و آب است. قنات‌ها علاوه بر آبادانی و توسعه کشاورزی پایدار می‌توانند در رونق گردشگری قنات و در نتیجه اشتغال‌زایی نقش مهمی داشته باشند. قنات‌ها هزاران سال است که نشان‌دهنده یک پیشرفت تکنولوژیکی و راه‌حل عمده برای تامین آب در مناطق خشک و نیمه خشک بوده‌اند و تاریخچه آن‌ها با پیدایش چندین تمدن در طول تاریخ اجین شده است [۱ و ۲]. حفظ قنات به عنوان یک منبع پایدار آب در مناطق خشک بسیار ضروری است. برای مدیریت قنات نیاز اصلی، تهیه داده‌های مکانی قنات است. در این راستا اولین گام تهیه نقشه میله چاه‌های قنات برای برنامه‌ریزی بهینه است. تهیه نقشه‌های قنات به روش‌های مستقیم زمینی مانند برداشت با دوربین‌های نقشه‌برداری یا سیستم‌های تعیین موقعیت ماهواره‌ای معمولاً زمانبر و نیاز به هزینه بالایی دارد. همچنین با توجه به ساختار دهانه میله چاه‌های قنات برداشت زمینی با چالش‌های خاصی مواجه است. لذا استفاده از تصاویر هوایی یا ماهواره‌ای با قدرت تفکیک مکانی بالا می‌تواند یک راه‌حل بهینه برای تهیه نقشه قنات باشد. امضای سیستم‌های قنات زیرزمینی بر روی تصاویر هوایی یا ماهواره‌ای، دهانه‌های دایره‌ای شکل میله‌های عمودی چاه‌های آن‌ها است که می‌تواند در تشخیص خودکار الگو بسیار موثر باشد. نیاز اولیه این روش‌ها دسترسی به تصاویر با قدرت تفکیک بالای مکانی مانند تصاویر پهپاد (پرنده هدایت‌پذیر از دور)، هوایی و ماهواره‌ای با امکان تشخیص میله‌های چاه‌های قنات می‌باشد. تهیه تصاویر پهپاد و بطور کلی عملیات پرواز و پردازش‌های آن‌ها هزینه‌بر می‌باشد، هرچند دارای دقت بالاتری می‌باشند. در این پژوهش از تصاویر ماهواره‌ای برای کشف موقعیت مکانی قنات استفاده شده است. با توجه به اینکه تنها تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا که در کشور بدون هزینه در دسترس هستند، تصاویر ماهواره‌ای گوگل ارث می‌باشند. در این تحقیق از تصاویر ماهواره-

ای گوگل ارث برای استخراج موقعیت مکانی میله چاه‌های قنات استفاده شده است. هدف این پژوهش استخراج خودکار میله چاه‌های قنات از تصاویر ماهواره‌ای گوگل ارث می‌باشد. در این راستا نیاز به استفاده از روش‌های نوین کشف اشیا از تصاویر مبتنی بر بینایی کامپیوتر است. تشخیص ویژگی‌های بصری متمایز یکی از مهم‌ترین مشکلات در تمام مراحل بینایی کامپیوتر از جمله در زمینه سنجش از دور است. از آنجایی که روش‌های مرسوم مانند ماشین‌های بردار پشتیبان [۳] نیاز به استخراج ویژگی‌های زمان‌بر و طراحی دستی دارند، تلاش‌های قابل توجهی برای توسعه روش‌هایی برای استخراج خودکار ویژگی‌ها انجام شده است. اخیراً یادگیری عمیق به یک راه‌حل جدید برای تشخیص اهداف و طبقه‌بندی تصاویر تبدیل شده است، زیرا این روش جدید نیازی به استخراج دستی ویژگی‌ها ندارد [۴]. یادگیری عمیق نوعی تکنیک یادگیری ماشینی است که از الگوریتم‌هایی الهام گرفته از ساختار و عملکرد مغز انسان استفاده می‌کند که شبکه‌های عصبی مصنوعی نامیده می‌شوند [۵ و ۶]. یادگیری عمیق در دهه گذشته به دلیل توانایی زیاد در یادگیری، به شدت مورد توجه قرار گرفته است. یادگیری عمیق به مدل‌هایی که بر اساس لایه‌های پردازشی متعدد ساخته شده‌اند، اجازه می‌دهد تا نمایش نمونه‌های داده را با چندین سطح انتزاع بیاموزند. یادگیری عمیق مدل‌هایی را که بر اساس لایه‌های چندگانه تشکیل شده‌اند، قادر می‌سازد تا بازنمایی نمونه‌های داده را با چندین محدوده سطوح انتزاعی بیاموزند [۷]. یادگیری عمیق بر اساس عملکرد پیشرفته خود، در حوزه‌های مختلفی مانند بینایی کامپیوتر [۸]، تشخیص گفتار [۹] و بازیابی اطلاعات [۱۰] استفاده شده است. یادگیری عمیق شامل یادگیری هم‌زمان ویژگی‌ها و طبقه‌بندی‌کننده‌ها می‌شود و از داده‌های آموزشی برای دسته‌بندی محتوای تصویر بدون مشخصات قبلی ویژگی‌های تصویر استفاده می‌کند. در میان تمام

مجموعه داده های کوچک استفاده کرد. محققان در این پژوهش نشان دادند که یادگیری عمیق، حتی با مجموعه داده های کوچک هم، می تواند با موفقیت برای تشخیص خودکار میله چاه های قنات اعمال شود. از آنجایی که زیرساخت های قنات در بسیاری از کشورها و زمینه ها یافت می شوند و چاه های آن ها دارای امضاهای مشابهی هستند، به تدریج می توان مجموعه داده های آموزشی را از مکان های گسترده ای در جهان جمع آوری و شبکه عصبی کانولوشن را برای این کار بهینه کرد [۱۶]. همچنین محققان با استفاده از تصاویر گوگل ارث و مدل شما فقط یک بار به تصویر نگاه می کنید (YOLOv5)، بصورت خودکار نقشه قنات در حوضه تورپان در منطقه خودمختار اویغور سین کیانگ را با دقت کلی ۸۶ درصد تهیه نمودند [۱۷]. در برخی موارد ممکن است بصورت دستی عملیات تشخیص و استخراج موقعیت مکانی میله چاه های قنات از تصاویر ماهواره ای انجام شود که به توجه به محدوده قنات و زمانبر بودن فرآیند دستی از نظر هزینه نیز مقرون به صرفه نمی باشد. همچنین تشخیص و استخراج توسط عامل های انسانی می تواند یکسان نباشد. لذا با حذف روند رقوم سازی دستی با تشخیص و استخراج اتوماتیک، می توان زمان ارزشمند و محدود محققین قنات را بر روی اعتبارسنجی و تجزیه و تحلیل نتایج متمرکز کرد. علاوه بر این، خودکارسازی تشخیص میله چاه های قنات، فرصت های تحقیقاتی جدیدی را باز می کند. هدف اصلی این پژوهش کشف محل چاه های قنات از تصاویر ماهواره ای با قدرت تفکیک بالای مکانی گوگل ارث بر مبنای شبکه های عصبی کانولوشن آشکارساز چندجعبه تک شات (SSD) می باشد. نوآوری این پژوهش استفاده از مدل آشکارساز چندجعبه تک شات [۱۸] برای یک مدلسازی مجموعه یادگیری عمیق به منظور کاهش پیچیدگی اجرا و افزایش قابلیت انتقال طرح برای الگوهای مکانی با استفاده از تصاویر سامانه گوگل ارث در دسترس در ایران است.

<sup>۱</sup>You Only Look Once

<sup>۲</sup>Single Shot Multibox Detector

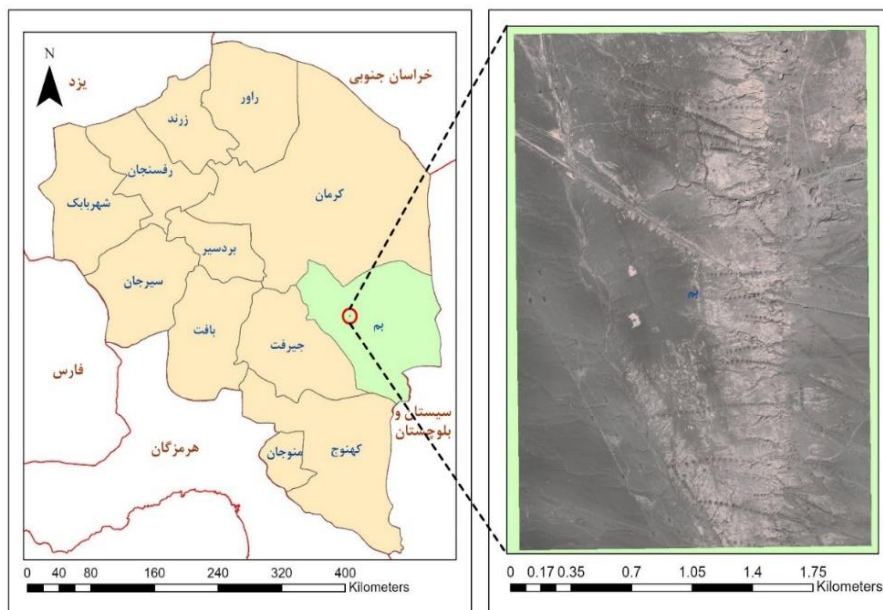
شبکه های مبتنی بر یادگیری عمیق، شبکه عصبی کانولوشن را برای یادگیری ویژگی های بصری در زمینه بنیایی کامپیوتر، از جمله سنجش از دور، محبوب ترین است. تحقیقات اخیر نشان داده است که شبکه عصبی کانولوشن برای کاربردهای مختلف موثر است [۱۱]. شبکه های عصبی کانولوشن اکنون در حوزه مکانی - طیفی استفاده می شوند [۱۲]. شبکه عصبی کانولوشن یک فناوری امیدوارکننده در زمینه سنجش از دور است [۱۳ و ۱۴]. همچنین اخیراً، یادگیری عمیق به دلیل عملکرد برتر از نظر دقت و تطبیق مدل ها، به عنوان یک ابزار قدرتمند برای جامعه سنجش از دور ظاهر شده است [۱۵]. یادگیری عمیق به لطف پیشرفت های اخیر مانند افزایش قدرت پردازنده ها، بهبود در پردازنده های گرافیکی و افزایش حجم داده ها (به عنوان مثال، فیلم ها و تصاویر) جهش های بزرگی به ویژه، در بخش بنیایی کامپیوتر داشته است. علم سنجش از دور شاهد افزایش عظیمی در تولید و بهبود قدرت تفکیک تصاویر رقومی اخذ شده از سنجنده های نصب شده بر روی سکوها های هوایی یا ماهواره های است که تقریباً هر زاویه از سطح زمین را پوشش می دهند. این رشد در داده ها، جامعه علوم زمین و سنجش از دور را به استفاده از الگوریتم های یادگیری عمیق برای حل وظایف مختلف سنجش از دور سوق داده است. در این راستا در این تحقیق از روش های یادگیری عمیق جهت استخراج خودکار میله چاه های قنات از تصاویر گوگل ارث استفاده شده است. پژوهش های کمی در خصوص کشف قنات از تصاویر ماهواره ای انجام شده است که به مهمترین آن ها مانند استفاده از تصاویر ماهواره ای کرونا<sup>۱</sup> برای تشخیص خودکار میله چاه های قنات با استفاده از شبکه های عصبی کانولوشن عمیق در منطقه کردستان عراق اشاره کرد. مطالعه تطبیقی فناوری قنات در مقیاس منطقه ای در حال حاضر غیرممکن است، زیرا هیچ کس زمان لازم برای ایجاد نقشه های دقیق از میله چاه های قنات را به صورت دستی ندارد. می توان از یادگیری انتقال و تقویت داده ها برای غلبه بر مشکل

<sup>۱</sup>CORONA

## ۲- مواد و روش‌ها

منطقه مورد مطالعه در این پژوهش قنات شهرستان بزم در استان کرمان است. این شهرستان از نظر جغرافیایی در ۵۸ درجه و ۲۱ دقیقه طول شرقی و ۲۹ درجه و ۶ دقیقه عرض شمالی و ارتفاع از سطح دریا ۱۰۵۰ متر می‌باشد و دارای آب و هوای خشک است. بزم یکی از شهرهای تاریخی ایران است. قنات یکی از مهمترین

تامین‌کننده‌های آب کشاورزی در شهرستان بزم می‌باشد و دارای قنات متعدد می‌باشد. دبی قنات بزم، مهمترین شاخص این قنات است. دشت بزم در حدود ۷۰۲ کیلومتری جنوب شرقی مرکز استان کرمان و در حاشیه کویر لوت واقع شده که جزء مناطق خشک کشور محسوب می‌شود. شکل (۱) موقعیت منطقه مورد مطالعه در این پژوهش را نشان می‌دهد.



شکل ۱: منطقه مورد مطالعه

محدوده شهرستان بزم شکل (۱) می‌باشد. این تصاویر توسط نرم‌افزارهای دانلود تصاویر از نرم‌افزار گوگل ارث بصورت ژئورفرنس شده در سیستم تصویر  $UTM$  ژون ۴۰ استخراج شده است. شکل (۲) وضوح مکانی تصویر تعدادی از میله چاه‌های قنات در منطقه مورد مطالعه را نشان می‌دهد.

در این مطالعه، از تصاویر ماهواره‌ای گوگل ارث به عنوان منبع تصاویر ماهواره‌ای استفاده شده است. تصاویر ماهواره‌ای گوگل ارث منابع داده مختلفی دارند، که می‌توان به تصاویر ماهواره لندست با قدرت تفکیک مکانی متوسط تا تصاویر ماهواره‌ای کوئیک برد با قدرت تفکیک مکانی بالا اشاره نمود. در این پژوهش، از تصاویر ماهواره‌ای با قدرت تفکیک مکانی ۰٫۶۵ متر دانلود شده از سامانه گوگل ارث استفاده شده است. تصاویر مورد استفاده مربوط به سال ۱۳۹۹ (۲۰۲۱) در

<sup>۱</sup>Universal Transverse Mercator

<sup>۲</sup>QuickBird



شکل ۲: قدرت تفکیک مکانی میله چاه‌های قنات در تصاویر گوگل ارث منطقه مورد مطالعه

مصنوعی را می‌توان به صورت رابطه‌های (۱) و (۲) توصیف کرد [۴].

$$u = \sum_i w_i x_i \quad \text{رابطه (۱)}$$

$$z = f(u + b) = f\left(\sum_i w_i x_i + b\right) \quad \text{رابطه (۲)}$$

در رابطه (۱) و (۲)، پارامترهای  $u$ ،  $z$ ،  $w$  و  $b$  به ترتیب کل ورودی، خروجی، متغیرهای ورودی، وزن‌ها و بایاس را نشان می‌دهند. تابع  $f$  یک تابع فعال‌سازی را نشان می‌دهد که می‌تواند یک تابع خطی یا غیرخطی، سیگموئید، هذلولی یا یکسو شده باشد.

در این پژوهش از یک تابع خطی اصلاح شده به عنوان تابع فعال‌سازی استفاده شده است و این تابع به عنوان واحد خطی اصلاح شده ( $ReLU$ ) نامیده می‌شود. تابع  $ReLU$  را می‌توان به صورت رابطه (۳) تعریف کرد [۱۹]:

$$f(u) = \max(0, u) = \begin{cases} u & (u > 0) \\ 0 & (u \leq 0) \end{cases} \quad \text{رابطه (۳)}$$

تابع فعال‌سازی  $ReLU$  باعث می‌شود خروجی برخی از نورون‌ها صفر شود که باعث پراکندگی شبکه و کاهش وابستگی متقابل پارامترها می‌شود و به طور موثر از مشکل بیش‌برازش نیز جلوگیری می‌کند [۲۰].

## ۲-۱- شبکه‌های عصبی کانولوشن ( $CNN$ )<sup>۱</sup>

در این پژوهش، از شبکه‌های عصبی کانولوشن استفاده شده است که نوع خاصی از شبکه‌های عصبی پیشخور هستند که از چندین لایه کانولوشنال و لایه‌های ادغام تشکیل شده‌اند (شکل (۳)).

شبکه عصبی پیشخور یک شبکه عصبی مصنوعی است که در آن اتصالات بین گره‌ها یک چرخه را تشکیل نمی‌دهند. این شبکه‌ها که شبیه‌سازی فعالیت‌های عصبی در مغز را انجام می‌دهند، عموماً به‌عنوان سیستم‌هایی از واحدهای پردازشی به هم پیوسته (نورون‌های مصنوعی) ارائه می‌شوند که می‌توانند مقادیر را از ورودی‌ها محاسبه کنند، و در نتیجه یک خروجی ایجاد می‌کنند که ممکن است در واحدهای بعدی استفاده شود. نورون‌های مصنوعی اساساً واحدهای پردازشی هستند که برخی از عملیات را بر روی چندین متغیر ورودی محاسبه می‌کنند و معمولاً یک خروجی دارند که از طریق تابع فعال‌سازی محاسبه می‌شود. به طور معمول، یک نورون مصنوعی دارای وزن  $w_i$  است که نشان‌دهنده درجه ارتباط بین نورون‌های مصنوعی است که دارای متغیرهای ورودی  $x_i$  و یک بردار آستانه  $b$  است.

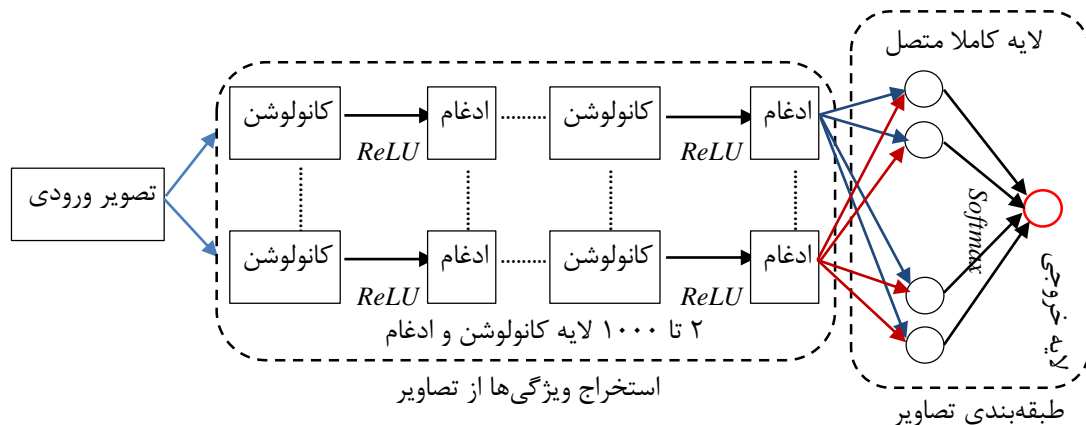
از نظر ریاضی، کل ورودی و خروجی نورون‌های

<sup>۱</sup>Convolutional Neural Network

<sup>۲</sup>Convolutional

<sup>۳</sup>Pooling

<sup>۴</sup>Rectified Linear Unit



شکل ۳: نمایش شماتیک شبکه‌های کانولوشن [۴]

بسیار مهم است. بنابراین، لایه ادغام وظیفه نمونه برداری از خروجی لایه کانولوشن و حفظ موقعیت مکانی تصویر و همچنین انتخاب مفیدترین ویژگی‌ها برای لایه‌های بعدی را دارد. پس از چندین لایه کانولوشن و ادغام، لایه‌های کاملاً به هم متصل هستند که تمام نورون‌های لایه قبلی را گرفته و به تک تک نورون‌های لایه خود متصل می‌کنند.

در نهایت، به دنبال تمام لایه‌های کانولوشن، ادغام و کاملاً متصل، ممکن است از یک لایه طبقه‌بندی کننده برای محاسبه احتمال تعلق کلاس هر تصویر استفاده شود. در این پژوهش از تابع *Softmax* استفاده شده است که این تابع احتمالات هر کلاس هدف را بر روی تمام کلاس‌های هدف ممکن محاسبه می‌کند و به صورت رابطه (۴) نوشته می‌شود:

رابطه (۴)

$$y_k = \text{soft max}_k (u_1, u_2, \dots, u_k) = \frac{e^{u_k}}{\sum_{j=1}^k e^{u_j}}$$

در رابطه (۴)،  $k$  تعداد واحدهای خروجی و  $u$  نشان دهنده متغیرهای ورودی است.

برای ارزیابی عملکرد شبکه، باید یک تابع زیان نیز

Fully Connected

Loss Function

یک شبکه عصبی کانولوشن از یک لایه کانولوشن و یک لایه ادغام تشکیل شده است. لایه کانولوشن در استخراج ویژگی‌ها از تصاویر نقش دارد. در این فرآیند، یک فیلتر با اندازه ثابت بر روی تصاویر اعمال می‌شود و الگوهای درجات خاکستری باندها را از تصاویر استخراج می‌کند. بعد از هر لایه کانولوشن، لایه‌های ادغام وجود دارد که برای کاهش واریانس ویژگی‌ها ایجاد می‌شود که با محاسبه عملیات یک ویژگی خاص بر روی یک قسمت از تصویر انجام می‌شود.

لایه ادغام دو عملکرد دارد. اولین عملکرد کاهش حساسیت موقعیت ویژگی‌ای است که از لایه کانولوشن استخراج می‌شود. به طوری که مقدار خروجی لایه ادغام حتی زمانی که موقعیت مقدار ویژگی استخراج شده توسط لایه کانولوشن در تصویر جابجا شود، تغییر نمی‌کند. عملکرد دوم بزرگ کردن میدان پذیرنده برای لایه‌های متوالی کانولوشن است. دو عملیات ممکن حداکثر و دیگری عملیات میانگین، که در آن مقادیر حداکثر و میانگین به ترتیب بر روی منطقه ویژگی اعمال می‌شوند. این فرآیند تضمین می‌کند که می‌توان نتایج یکسانی را حتی زمانی که ویژگی‌های تصویر دارای تفسیرها یا چرخش‌های کوچکی هستند، به دست آورد، و این برای طبقه‌بندی و تشخیص اشیا

تا به طور طبیعی اشیاء با اندازه های مختلف را کنترل نماید. این روش نسبت به روش هایی دیگر ساده تر است، زیرا مراحل نمونه برداری مجدد پیکسل را حذف می کند و تمام محاسبات را در یک شبکه واحد انجام می دهد. در نهایت آموزش آشکارساز چندجعبه تک شات را آسان می کند و ادغام آن در سیستم هایی که به یک جزء تشخیص نیاز دارند را آسان می کند [۲۱].

شکل (۴) معماری کلی شبکه عصبی کانولوشن با آشکارساز چندجعبه تک شات را نشان می دهد. در این پژوهش شبکه طبقه بندی تصویر از پیش آموزش دیده، شبکه *ResNet* می باشد.

### ۲-۳- مدل *ResNet*

معماری *ResNet* اولین بار در سال ۲۰۱۵ توسط هی و همکاران ارائه شد. در آن زمان، این معماری برنده چندین مسابقه شد و رکورد جدیدی را برای طبقه بندی مجموعه داده های تصاویر ثبت کرد. ایده اصلی مدل *ResNet* این است که بلوک های ساختمان آن برای «یادگیری توابع باقیمانده با ارجاع به ورودی های لایه، به جای یادگیری توابع غیر مرجع» طراحی شده اند [۲۲]. در این مدل یک ورودی دلخواه  $x$  به لایه ای از شبکه عصبی و خروجی بهینه  $y$  در نظر گرفته شده است. در مورد یک تابع بدون مرجع، شبکه مستقیماً تابع  $f$  را که  $y$  را تولید می کند، تقریب می زند:  $y = f(x)$ . منظور از تابع باقیمانده در این زمینه، این است که شبکه جدید اکنون  $y = x + f(x)$  را تقریب می زند. بنابراین شبکه به جای اینکه یاد بگیرد که چگونه ورودی باید تبدیل شود تا خروجی مورد نظر را ایجاد کند، تفاوت بین ورودی و خروجی بهینه را یاد می گیرد. شکل (۵) نشان می دهد که چگونه این مفهوم بر روی لایه های یک شبکه کانولوشن اعمال می شود.

تعریف شود. تابع زیان، اثربخشی شبکه را در مدل سازی مجموعه داده آموزشی ارزیابی می کند. هدف از آموزش به حداقل رساندن خطای تابع زیان است.

آنروپی متقاطع تابع *Softmax* به صورت رابطه (۵) تعریف می شود:

$$E = - \sum_{n=1}^N \sum_{k=1}^K t_{n.k} \log y_k \quad \text{رابطه (۵)}$$

در رابطه (۵)،  $t$  نشان دهنده بردار داده های آموزشی است،  $K$  نشان دهنده کلاس محتمل و  $N$  نشان دهنده تعداد کل نمونه ها است.

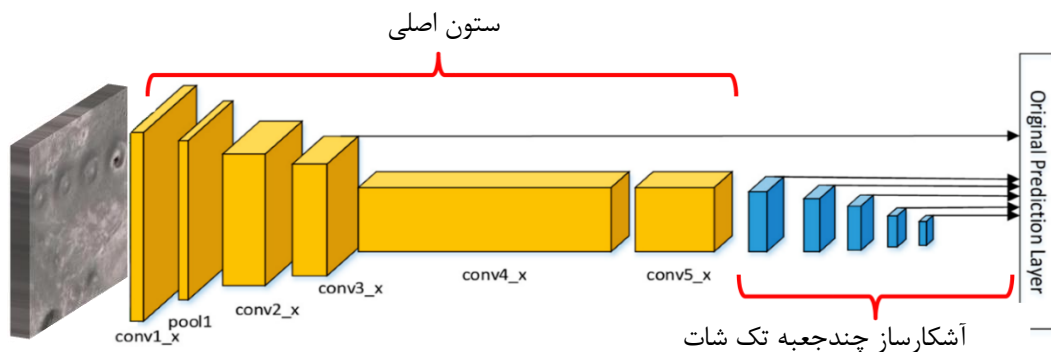
### ۲-۲- آشکارساز چندجعبه تک شات

آشکارساز چندجعبه تک شات (*SSD*) دارای دو جزء است: یک مدل ستون اصلی و سر<sup>۲</sup> مدل ستون اصلی معمولاً یک شبکه طبقه بندی تصویر از پیش آموزش دیده است که به عنوان استخراج کننده ویژگی عمل می کند. آشکارساز چندجعبه تک شات به جای استفاده از پنجره متحرک، تصویر را با استفاده از یک شبکه تقسیم می کند و هر سلول شبکه ای مسئول تشخیص اشیاء در آن ناحیه از تصویر است. تشخیص اشیاء به معنای پیش بینی کلاس و مکان یک شیء در آن منطقه است. اگر شیئی وجود نداشته باشد، آن را به عنوان کلاس پس زمینه در نظر گرفته و مکان نادیده گرفته می شود. شبکه عصبی عمیق آشکارساز چندجعبه تک شات، فضای خروجی جعبه های مرزی را به مجموعه ای از جعبه های پیش فرض بر روی نسبت ها و مقیاس های مختلف در هر مکان نقشه ویژگی تفکیک می کند. در زمان پیش بینی، شبکه امتیازهایی را برای حضور هر دسته شیئی در هر جعبه پیش فرض ایجاد می کند و تنظیماتی را برای مطابقت بهتر با شکل شیء ایجاد می کند. علاوه بر این، این شبکه پیش بینی ها را از نقشه های چندگانه با وضوح های مختلف ترکیب می کند


<sup>۱</sup>Single Shot MultiBox Detector

<sup>۲</sup>Backbone

<sup>۳</sup>Head



شکل ۴: معماری کلی شبکه عصبی کانولوشن با آشکارساز چندجعبه تک شات



شکل ۵: بلوک ساختمان مدل ResNet [۲۲]

عملکرد آن را بدتر کند، زیرا بلوک‌های جدید تغییر هویت را یاد می‌گیرند و در نتیجه عملکرد مدل پایه را حفظ می‌کنند. اما بلوک‌های جدید اضافه شده تعداد درجات آزادی و عمق شبکه را افزایش می‌دهند، بنابراین ظرفیت یادگیری ویژگی‌های پیچیده را افزایش می‌دهند. در نتیجه اگر نمایش بهتری از داده‌ها وجود داشته باشد، شبکه جدید باید بتواند آن را یاد بگیرد.

#### ۲-۴- برآورد دقت یادگیری

مدل در هر دوره یادگیری با استفاده از توابع دقت و زیان اعتبارسنجی می‌شود. تابع دقت نشان‌دهنده دقت مدل در طبقه‌بندی تصاویر اعتبارسنجی است، در حالی

بلوک شبکه ResNet یک ورودی دریافت می‌کند که در آن یک کانولوشن اعمال می‌شود، به دنبال آن نرمال‌سازی دسته‌ای و فعال‌سازی ReLU انجام می‌شود. این کار برای بار دوم تکرار می‌شود و ورودی به نقشه ویژگی حاصل اضافه می‌شود. با این معماری یادگیری تبدیل هویت آسان‌تر است، زیرا بهینه‌ساز فقط باید وزن‌ها را در لایه‌های کانولوشن به صفر برساند. مشاهدات مدل‌های قبلی این بود که افزودن لایه‌های بیشتر به شبکه موجود لزوماً عملکرد را افزایش نمی‌دهد. نقش کلیدی مدل ResNet ایجاد یک لایه یا بلوک است که بتواند به راحتی تغییر هویت را یاد بگیرد. چیدمان این بلوک‌ها در بالای شبکه موجود در حالت ایده‌آل نباید

تصاویر ماهواره‌ای دانلود شده از سامانه گوگل ارث بر مبنای مدل‌های یادگیری عمیق می‌باشد. شکل (۶) ساختار مدل پیشنهادی بر مبنای شبکه عصبی کانولوشن را نشان می‌دهد.

در این تحقیق، ابتدا داده‌های آموزشی با استفاده از روش تصویر قطعه قطعه شده آماده شده است [۲۴]. در این روش، ابتدا تصاویر ماهواره‌ای گوگل ارث برای منطقه مورد مطالعه در شهرستان بم، با ابعاد ۲۵۶ در ۲۵۶ پیکسل برای دو کلاس قنات بر اساس شکل، رنگ، بافت و ساختار دهانه میله چاه قنات در نرم‌افزار *ArcGIS Pro* بریده شده است و در مرحله بعد، این تصاویر به مربع‌های با ۵۰٪ همپوشانی هم به صورت عمودی و هم به صورت افقی بریده شده است. در نهایت تصاویر قطعه قطعه شده به عنوان تصاویر آموزشی استفاده شده است. در منطقه مورد مطالعه شکل برخی از میله چاه‌های قنات تخریب شده است و امکان تشخیص و استخراج توسط عامل انسانی نیز با مشکل مواجه است، لذا در این مطالعه برای آموزش از میله چاه‌های قناتی استفاده شده است که دارای شکل مناسب هستند. قنات با شکل مناسب در منطقه مورد مطالعه نمونه‌های آموزشی در دو کلاس (دریچه باز و دریچه بسته) طبقه‌بندی شده‌اند. تعداد میله چاه‌های قنات در منطقه مورد مطالعه به وسعت تقریبی ۳۰ کیلومتر مربع برابر ۲۴۹۶ میله چاه بوده است که ۵۵۷ میله چاه آن دارای شکل تخریب شده و ۱۹۳۹ میله چاه دارای شکل مناسب در دو کلاس (دریچه باز و دریچه بسته) بوده است. برای هر کلاس حداقل ۳۰۰ نمونه آموزشی و در مجموع بیش از ۶۰۰ نمونه آموزشی دریچه میله قنات انتخاب شده است.

شکل (۷) تعدادی از نمونه‌های آموزشی استخراج شده از تصویر اصلی همراه با دو نمونه آموزشی انتخاب شده برای دو کلاس را نشان می‌دهد. به منظور نشان دادن عملکرد مدل مورد استفاده، هیچ پیش‌پردازشی بر روی تصاویر انجام نشده است.

که تابع زیان نشان‌دهنده عدم دقت پیش‌بینی توسط مدل است. اگر یادگیری مدل موفقیت‌آمیز باشد، مقدار تابع زیان، کم و مقدار تابع دقت، زیاد است. با این حال، اگر مقدار تابع زیان در طول یادگیری زیاد شود، نشان‌دهنده بیش‌برازش است. معیار دقت و معیار بازیابی یا حساسیت رایج‌ترین شاخص‌های ارزیابی برای تشخیص اهداف در یادگیری عمیق هستند. هر چه مقدار این معیارها بالاتر باشد، توانایی پیش‌بینی قوی‌تر است. فرمول‌های محاسبه دقت تشخیص و نرخ بازیابی به ترتیب در رابطه‌های (۶) و (۷) نشان داده شده است:

$$P = \frac{TP}{TP + FP} \quad \text{رابطه (۶)}$$

$$R = \frac{TP}{TP + FN} \quad \text{رابطه (۷)}$$

در رابطه‌های (۶) و (۷)، مثبت واقعی ( $TP$ )، منفی کاذب ( $FN$ ) و مثبت کاذب ( $FP$ ) بر اساس ماتریس ابهام محاسبه می‌شوند که تعداد تشخیص‌های مختلف را نشان می‌دهند.  $TP$  تعداد اهدافی را نشان می‌دهد که به درستی شناسایی شده‌اند و  $FP$  تعداد اهدافی را نشان می‌دهد که هدف نبوده‌اند، اما به اشتباه به عنوان هدف شناسایی شده‌اند.  $FN$  تعداد اهدافی را نشان می‌دهد که هدف هستند، اما شناسایی نشده‌اند [۲۳].

معیار  $F1\text{-Score}$  یک معادل بین این دو پارامتر ارزیابی مدل است و به عنوان میانگین هارمونیک آن‌ها تعریف می‌شود (رابطه (۸)):

$$F1_{Score} = 2 \times \frac{P \times R}{P + R} \quad \text{رابطه (۸)}$$

### ۳- یافته‌ها

هدف این پژوهش کشف دهانه میله چاه‌های قنات از

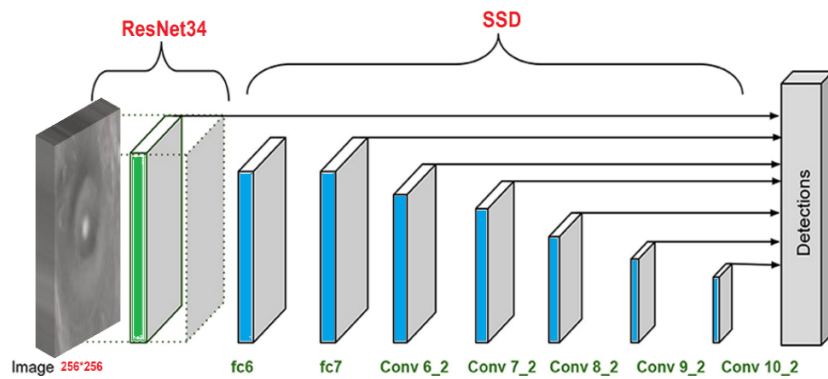
<sup>۱</sup>Precision

<sup>۲</sup>Recall


<sup>۳</sup>True Positive

<sup>۴</sup>False Negative

<sup>۵</sup>False Positive



شکل ۶: ساختار مدل پژوهش بر مبنای آشکارساز چندجعبه تک شات برای کشف قنات



شکل ۷: نمونه‌های تصاویر آموزشی میله چاه‌های قنات در منطقه مورد مطالعه در دو کلاس پیشنهادی

برچسب‌گذاری بر عملکرد مدل تأثیر می‌گذارد. بدون داده‌های برچسب‌گذاری شده واقعی، قضاوت در مورد اینکه اشتباهات در داده‌های آموزشی ممکن است در عملکرد ضعیف مدل نقش داشته باشد، دشوار است. در این تحقیق سعی شده است تعداد نمونه آموزشی بهینه برای دستیابی به دقت بهتر در مدل پیشنهادی انتخاب شود.

در این پژوهش از شبکه عصبی کانولوشن بر مبنای آشکارساز چندجعبه تک شات با شبکه *ResNet* برای کشف و استخراج خودکار مکان هندسی میله چاه‌های


قنات‌ها را می‌توان تا حد زیادی به صورت بصری تشخیص و مکان هندسی آن‌ها را استخراج نمود، زیرا دهانه میله چاه‌ها در ترازهای بلند و خطی دیده می‌شوند. در منطقه مورد مطالعه دهانه میله چاه‌ها در تصاویر گوگل ارث قابل تشخیص است. ایجاد مجموعه داده‌های آموزشی بزرگ و با کیفیت بالا یکی از بزرگترین چالش‌ها در مسیر استفاده از یادگیری عمیق است. به منظور افزایش نرخ فراخوان، اشیاء با سطح اطمینان پایین‌تر باید برچسب‌گذاری شوند. عدم قطعیت، سوگیری و خطا در طول فرآیند

آشکارساز چندجعبه تک شات تنها یک یا چند لایه کانولوشن است که به *ResNet34* اضافه شده است و خروجی ها به عنوان جعبه های مرزی و کلاس های اشیاء در موقعیت مکانی فعال سازی لایه های نهایی تفسیر می شوند. مدل مورد نظر با برنامه نویسی به زبان پایتون و استفاده از کتابخانه های یادگیری عمیق و نرم افزار *ArcGIS Pro* پیاده سازی شده است.

پارامترهای مدل اجرا شده در این مطالعه شامل تعداد دوره های آموزشی برابر ۵۰ ( $epoch=50$ ) و نرخ یادگیری به صورت کاهشی استفاده شده است. آموزش مدل پیشنهادی بر روی داده های آموزشی با یک کامپیوتر شخصی لپ تاپ با پردازشگر مرکزی نسل هشت *Core i7* و *RAM* برابر ۱۲ گیگابایت، حدود ۵ ساعت و ۳۶ دقیقه طول کشیده است. میانگین دقت داده های اعتبارسنجی لایه نهایی مدل برابر ۸۹ درصد بوده است. به دنبال افزایش تعداد دوره های آموزشی، مقادیر دقت افزایش و مقادیر تابع زیان کاهش یافته است. این نتایج نشان می دهد که همه مدل ها بیش از حد به مجموعه داده ها برازش نشده اند و با موفقیت ویژگی های تصاویر قطعه شده را یاد گرفته اند (شکل ۸).

قنوات استفاده شده است. برخلاف رویکردهای مرسوم برای آموزش طبقه بندی کننده ها با استخراج ویژگی های طراحی شده دستی، مدل پیشنهادی سلسله مراتب ویژگی ها را از پیکسل ها به طبقه بندی کننده ها می آموزد و لایه ها را به طور مشترک آموزش می دهد. در این پژوهش از لایه نهایی مدل آشکارساز چندجعبه تک شات برای شناسایی قنات از تصاویر گوگل ارث استفاده شده است. به طور تصادفی همه تصاویر با هم مخلوط شده تا از هم پوشانی داده های آموزشی و داده های اعتبارسنجی جلوگیری شود، سپس ۸۵ درصد تصاویر به دست آمده به عنوان داده آموزشی و ۱۵ درصد باقی مانده به عنوان داده اعتبارسنجی استفاده گردیده است.

برای آموزش از شبکه *ResNet* با ۳۴ لایه (*ResNet 34*) استفاده شده است که یک مدل یادگیری عمیق کلاسیک است، به این علت که در این مطالعه از تصاویر با اندازه کوچک به عنوان داده های آموزشی و اعتبارسنجی استفاده می کند. این شبکه با دو لایه کانولوشن، دو لایه ادغام و یک لایه کاملاً متصل ساخته شده است. *ResNet34*، منجر به تولید ۲۵۶ نقشه ویژگی با ابعاد  $7*7$  برای یک تصویر ورودی می شود.




شکل ۸: تابع زیان بر اساس دوره های یادگیری (دسته های تصاویر پردازش شده)

درصد می‌باشد. بنابراین بهترین گزینه‌های هدف برای اعتبارسنجی الگوریتم تشخیص حفظ شدند. با توجه به شکل و تراکم دهانه میله چاه‌های قنات عملکرد مدل پیشنهادی مورد بررسی قرار گرفت که در ادامه به آن‌ها اشاره شده است:

#### ۱) مناطق با تراکم کم و شکل مناسب دهانه میله چاه‌های قنات

مدل پیشنهادی در مناطقی که شکل دهانه میله چاه‌ها تغییر نکرده و فاصله بین آن‌ها زیاد است، دارای دقت بالایی بوده است و تمام میله چاه‌های قنات را تشخیص می‌دهد. شکل (۹) یک نمونه از نتیجه عملکرد مدل بر روی مناطق با تراکم کم و شکل مناسب میله چاه‌ها را نشان می‌دهد.

پس از آموزش مدل، مدل آموزش دیده پیشنهادی بر روی تصویر ماهواره‌ای گوگل ارث دانلود شده به مساحت ۳۰ کیلومتر مربع برای کشف میله چاه‌های قنات اجرا شده است. برای هر میله چاه قنات کشف شده توسط مدل، جعبه مستطیلی برای نمایش مکان قنات بدست آمد. هر جعبه مرزی دارای امتیاز اطمینان از ۰ تا ۱ است که درجه اطمینان برای حضور یک میله چاه قنات را نشان می‌دهد. پس از آن، برای حذف کادرهای مرزی اضافی که با همدیگر همپوشانی بالایی داشتند، با نگه‌داشتن یکی با بالاترین امتیاز اطمینان استفاده شد. در نهایت، تمام جعبه‌های مرزی با امتیاز اطمینان کمتر از  $0.2$  (۲۰ درصد) حذف شدند، دامنه اطمینان قنات کشف شده بین  $0.3/0.2$  تا  $0.87/0.99$




شکل ۹: نتیجه مدل اعمال شده در مناطق با شکل مناسب و تراکم کم میله چاه‌ها

تشخیص می‌دهد، در این مورد میزان همپوشانی بین جعبه‌های شناسایی مجاز است. شکل (۱۰) یک نمونه از نتیجه عملکرد مدل بر روی مناطق با تراکم بالا و شکل مناسب میله چاه‌ها را نشان می‌دهد.

#### ۲) مناطق با تراکم بالا و شکل مناسب دهانه میله چاه‌های قنات

مدل پیشنهادی در مناطقی که شکل دهانه میله چاه‌ها تغییر نکرده و فاصله بین آن‌ها کم است، دارای دقت بالایی بوده و بیش از ۹۰ درصد میله چاه‌های قنات را




شکل ۱۰: نتیجه مدل اعمال شده در مناطق با شکل مناسب و تراکم بالای میله چاه‌ها

بین آن‌ها زیاد و در نتیجه تراکم کم است، دارای دقت پایینی می‌باشد. شکل (۱۱) یک نمونه از نتیجه عمکرد مدل بر روی مناطق با تراکم کم و شکل تخریب شده میله چاه‌ها را نشان می‌دهد.

### ۳) مناطق با تراکم کم و شکل تخریب شده دهانه میله چاه‌های قنات

مدل پیشنهادی در مناطقی که شکل دهانه میله چاه‌ها در گذر زمان تخریب شده و بطور کلی شکل دهانه میله چاه‌ها به سختی قابل شناسایی است و همچنین فاصله




شکل ۱۱: نتیجه مدل اعمال شده در مناطق با شکل تخریب شده و تراکم کم میله چاه‌ها

بوده است. شکل (۱۲) یک نمونه از نتیجه عمکرد مدل بر روی مناطق با تراکم زیاد و شکل تخریب شده میله چاه‌ها را نشان می‌دهد. در این حالت حتی تشخیص و استخراج دهانه میله چاه‌ها برای عامل انسانی نیز چالشی بوده و دارای خطای انسانی است.

### ۴) مناطق با تراکم زیاد و شکل تخریب شده دهانه میله چاه‌های قنات

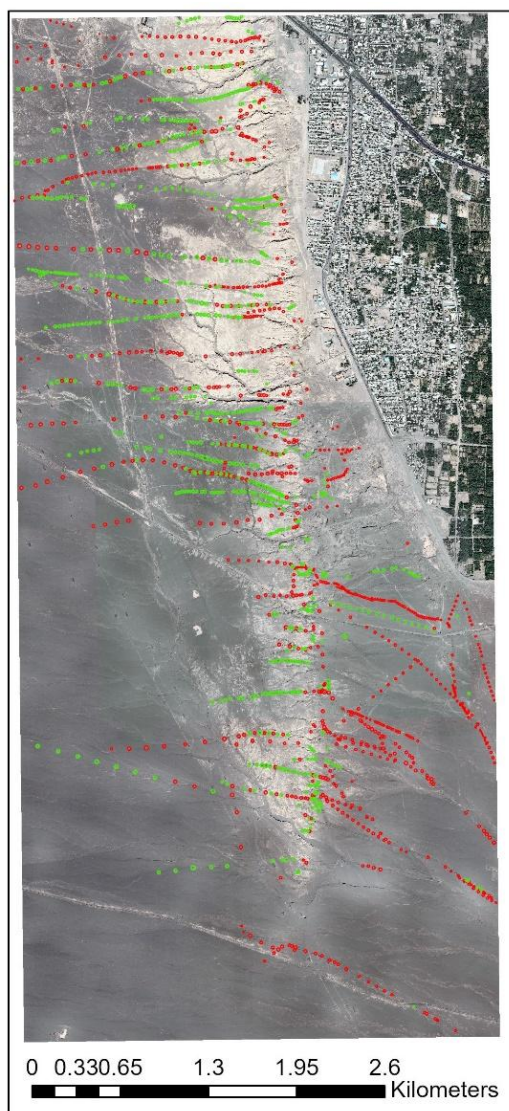
مدل پیشنهادی در مناطقی که شکل دهانه میله چاه‌ها تخریب شده و فاصله بین آن‌ها کم و در نتیجه تراکم زیاد است، دارای دقت خیلی پایینی می‌باشد. در این مورد میزان همپوشانی بین جعبه‌های شناسایی مجاز




شکل ۱۲: نتیجه مدل اعمال شده در مناطق با شکل تخریب شده و تراکم بالای میله چاه‌ها

مورد مطالعه به وسعت ۳۰ کیلومتر مربع در تشخیص قنوت با شکل مناسب را نشان می‌دهد. شکل (۱۴) بخشی از محدوده تصویر ماهواره‌ای گوگل ارث با وضوح بالا، حاوی میله چاه‌های قنات کشف شده توسط مدل را برای مناطق دارای میله چاه با شکل مناسب نشان می‌دهد.

در این پژوهش هدف تشخیص و استخراج موقعیت مکانی دهانه میله چاه‌هایی بوده است که دارای شکل مناسب بوده‌اند، بدیهی است در صورت اعمال دقت برای چاه‌های قنات تخریب شده، دقت تشخیص و استخراج کاهش خواهد یافت. شکل (۱۳) نتیجه نهایی اعمال مدل بر روی منطقه



شکل ۱۳: نتیجه نهایی مدل اعمال شده برای کشف میله چاه‌های قنوت در منطقه مورد مطالعه



شکل ۱۴: نمونه میله چاه‌های قنات کشف شده توسط مدل در منطقه مورد مطالعه

خواهد بود (جدول (۲)).  
جدول (۲) نتیجه ارزیابی دقت مدل استفاده شده را برای کلیه قنات‌های تخریب شده و با شکل مناسب نشان می‌دهد.

جدول (۱) نتیجه ارزیابی دقت مدل استفاده شده را برای قنات‌ها با شکل مناسب نشان می‌دهد. بدیهی است در مناطقی که شکل میله چاه‌های قنات تخریب شده و حتی توسط عامل انسانی استخراج و تشخیص آن مشکل است، دقت مدل پیشنهادی خیلی کمتر

جدول ۱: معیارهای ارزیابی دقت مدل برای میله چاه‌های قنات با شکل مناسب

معیار $F1$ Score	معیار بازیابی ( $Recall$ )	معیار دقت ( $Precision$ )
۰٫۸۶	۰٫۸۲	۰٫۹۱

جدول ۲: معیارهای ارزیابی دقت مدل برای تمام میله چاه‌های قنات

معیار $F1$ Score	معیار بازیابی ( $Recall$ )	معیار دقت ( $Precision$ )
۰٫۶۲	۰٫۶۰	۰٫۶۵

در فضای سه بعدی یا دوبعدی بر روی تصاویر ارتوفتو، تشخیص و استخراج نماید که همین مرحله تبدیل (تشخیص و استخراج عوارض) زمانبر است و در نتیجه هزینه تهیه نقشه زیاد خواهد شد. در این راستا استفاده از تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا برای تشخیص و استخراج نقشه قنات پیشنهاد می‌شود. با توجه به هزینه نسبتاً بالای اخذ تصاویر ماهواره‌ای می‌توان از تصاویر ماهواره‌ای در دسترس در سامانه گوگل ارث استفاده نمود. در صورت استخراج بصری عوارض از تصاویر ماهواره‌ای نیاز به اپراتور تبدیل و تفسیر تصاویر وجود دارد و ممکن است اپراتورهای مختلف تشخیص و حتی نحوه استخراج متفاوتی داشته باشند. در این راستا

#### ۴- نتیجه‌گیری

قنات به عنوان یک سازه تامین آب پایدار در مناطق کم آب یا خشک شناخته شده است. مدیریت این سازه‌های آبی با توجه به شرایط آب و هوایی ضروری است. اولین گام در این راستا تهیه نقشه قنات موجود است. روش‌های زمینی تهیه نقشه قنات با توجه به شرایط آب و هوایی و نیاز به صرف هزینه و زمان بالا، هر چند دارای دقت بالایی می‌باشند، مقرون به صرفه نیستند. لذا راه کار بعدی استفاده از تصاویر هوایی و تصاویر ماهواره‌ای با قدرت تفکیک بالا است. علاوه بر هزینه تهیه تصاویر هوایی و همچنین نیاز به پردازش و عملیات مثلث‌بندی باید اپراتور تبدیل عوارض مورد نظر را بصورت بصری

پیش فرض استفاده می‌کند و می‌تواند برای آشکارسازی شیئی استفاده شود [۲۶].

در این پژوهش ابتدا نمونه‌های آموزشی دهانه میله چاه-های قنات از تصاویر ماهواره‌ای دانلود شده از سامانه گوگل ارث استخراج شده است. بیش از ۶۰۰ نمونه آموزشی در تصاویر با ابعاد ۲۵۶ در ۲۵۶ پیکسل برای آموزش مدل تهیه شده است. سعی گردیده مدل طوری انتخاب گردد که بتوان آن‌را با نمونه آموزشی کمتر و در زمان کمتر آموزش داد. مدل پیشنهادی در این پژوهش یک مدل شبکه عصبی کانولوشن بر مبنای آشکارساز چندجعبه تک شات بر پایه شبکه *ResNet34* می‌باشد. مدل با برنامه‌نویسی پایتون و کتابخانه‌های آماده یادگیری عمیق پیاده‌سازی شده است. پس از آموزش مدل، مدل آموزش دیده بر روی یک تصویر ماهواره‌ای گوگل ارث ژئورفرنس شده در محدوده منطقه مورد مطالعه اجرا شده است و موقعیت مکانی میله چاه‌های قنات در سیستم تصویر *UTM* استخراج شده است. نتایج ارزیابی مدل بروی میله چاه‌های قنات با شکل مناسب بر اساس معیار دقت برابر ۰/۹۱ و معیار بازیابی برابر ۰/۸۲ و معیار *F1Score* برابر ۰/۸۶ می‌باشد. بطور کلی نتایج نشان می‌دهد که مدل یادگیری عمیق پیشنهادی می‌تواند در تشخیص و استخراج میله چاه-های قنات از تصاویر ماهواره‌ای موجود در سامانه گوگل ارث استفاده شود.

مدل در مناطقی که شکل دهانه میله چاه بهتر حفظ شده و تخریب نشده باشد، بهترین عملکرد را داشته است. بیشترین میزان مثبت کاذب به مثبت واقعی در مناطقی بود که میله چاه قنات در گذر زمان تخریب شده است یا قطعیت شناسایی پایین است. همچنین در مناطقی که فاصله بین میله چاه‌ها کمتر از ۱۰ متر بوده است، بدلیل قدرت تفکیک مکانی تصویر و نزدیکی نسبی میله چاه‌های قنات، مدل نتایج ضعیف‌تری داشته است. نتایج نشان می‌دهد که امکان تشخیص و استخراج اتوماتیک میله چاه‌های قنات با دقت مناسب از تصاویر ماهواره‌ای دانلود شده از سامانه گوگل ارث

در این پژوهش برای تشخیص و استخراج خودکار دهانه چاه‌های قنات از تصاویر ماهواره‌ای با قدرت تفکیک بالای در دسترس گوگل ارث استفاده شده است. برای تشخیص اهداف از تصاویر بهترین روش در عصر حاضر روش‌های یادگیری عمیق می‌باشد. مزیت استفاده از یادگیری عمیق این است که می‌تواند ویژگی‌ها را به تنهایی یاد بگیرد که در مقایسه با الگوریتم‌های کلاسیک یادگیری ماشین باعث صرفه جویی در زمان می‌شود. یکی دیگر از ویژگی‌های یادگیری عمیق دقت بالاتر آن است، به این معنی است که آموزش بیشتر یا ورودی داده بیشتر اغلب منجر به دقت بالاتر نسبت به مدل‌های قبلی می‌شود. اما، مدل‌های یادگیری عمیق به زمان بیشتری برای آموزش نیاز دارند، ولی زمان کوتاه‌تری برای استنباط در مقایسه با الگوریتم‌های یادگیری ماشین معمولی نیاز دارند. برای دقت بهتر، یادگیری عمیق به مقادیر زیادی مجموعه داده به عنوان ورودی در طول آموزش نیاز دارد. یادگیری عمیق و شبکه‌های عصبی کانولوشنال اخیراً به راه‌حل جدیدی برای تشخیص اهداف و طبقه‌بندی تصاویر تبدیل شده‌اند. در عمل، دو نوع الگوریتم اصلی تشخیص اشیا وجود دارد. نوع اول الگوریتم‌هایی مانند *R-CNN* و *Fast(er) R-CNN* هستند که از یک رویکرد دو مرحله‌ای استفاده می‌کنند. یعنی ابتدا برای شناسایی مناطقی که انتظار می‌رود اشیاء در آنجا کشف شوند و سپس اشیاء را فقط در آن مناطق با استفاده از شبکه کانولوشنی شناسایی می‌کنند. نوع دوم، الگوریتم‌هایی مانند *YOLO* (شما فقط یک بار نگاه می‌کنید) [۲۵] و آشکارساز چندجعبه تک شات از یک رویکرد کاملاً کانولوشنال استفاده می‌کنند که در آن شبکه می‌تواند تمام اشیاء درون یک تصویر را در یک نگاه پیدا کند. الگوریتم‌های اول معمولاً دقت بهتری دارند، اما اجرای آن‌ها کندتر است، در حالی که الگوریتم‌های تک‌مرحله‌ای کارآمدتر هستند و دقت قابل قبولی هم دارند و به همین دلیل در این پژوهش از این الگوریتم استفاده شده است. آشکارساز چندجعبه تک شات از نسبت ابعاد

خواهد داشت. همچنین می‌توان با ادغام تصاویر چندطیفی کارکرد مدل را بهبود بخشید. در صورت افزایش تعداد نمونه‌های آموزشی با شرایط متفاوت می‌توان به نتایج بهتری دست یافت. برای تحقیقات آتی پیشنهاد می‌گردد که از سایر مدل‌های یادگیری عمیق و همچنین تصاویر پهپاد فتوگرامتری استفاده گردد.

امکان‌پذیر است که با نتایج پژوهش لی و همکاران مطابقت دارد. لی و همکاران در حوضه تورپان در منطقه خودمختار اویغور سین کیانگ با استفاده از مدل یادگیری عمیق YOLOv5 نقشه فنوات را با دقت کلی ۸۶ درصد از تصاویر ماهواره‌ای گوگل ارث تهیه نمودند [۱۷]. در صورت استفاده از تصاویر هوایی و همچنین افزایش تعداد نمونه‌های آموزشی دقت مدل افزایش

## مراجع

- pp. 8599\_8603, 2013.
- [1] M. Khaneiki, "Territorial Water Cooperation in the Central Plateau of Iran", Springer Nature, Switzerland, 2019.
- [2] A. Yazdi and M. Khaneiki, "Qanat Knowledge: construction and maintenance", Springer, Dordrecht, 2017.
- [3] H. Drucker, C. J. Burges, L. Kauffman, A. Smola and V. Vapnik, "Support vector regression machines. Neural information processing systems", Eds Mozer MC, Jordan JI & Petsche T. pp. 155–161, 1997.
- [4] S. Watanabe, K. Sumi and T. Ise, "Identifying the vegetation type in Google Earth images using a convolutional neural network: a case study for Japanese bamboo forests", BMC Ecol 20, 65, 2020.
- [5] Y. Bengio, "Learning deep architectures for AI", Foundat Trends Mach Learn, 2:1–127, 2009.
- [6] I. Goodfellow, Y. Bengio and A. Courville, "Deep Learning", MIT press, 2016.
- [7] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning", Nature, vol. 521, pp. 436\_444, 2015.
- [8] A. Voulodimos, N. Doulamis, A. Doulamis and E. Protopapadakis, "Deep learning for computer vision: A brief review, Comput. Intell", Neurosci., vol. 2018, pp. 1\_13, 2018.
- [9] L. Deng, G. Hinton and B. Kingsbury, "New types of deep neural network learning for speech recognition and related applications: An overview", in Proc. IEEE Int. Conf. Acoust., Speech Signal Process.,
- [10] H. Palangi, L. Deng, Y. Shen, J. Gao, X. He, J. Chen, X. Song and R. Ward, "Deep sentence embedding using long short-term memory networks: Analysis and application to information retrieval", IEEE/ACM Trans, Audio, Speech, Language Process., vol. 24, no. 4, pp. 694\_707, Apr, 2016.
- [11] A. Karpathy, G. Toderici, S. Shetty, T. Leung, R. Sukthankar and L. Fei-Fei, "Largescale video classification with convolutional neural networks", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (Columbus). 1725–1732, 2014.
- [12] S. Alberto, M. Savardi, A. Baronio and S. Benini, "Deep learning meets hyperspectral image analysis: A multidisciplinary review", Journal of Imaging 5, no. 5: 52, 2019.
- [13] K. Nogueira, O.A.B. Penatti and J.A. Dos Santos, "Towards better exploiting convolutional neural networks for remote sensing scene classification", Pattern Recogn. 61:539–56, 2017.
- [14] X.X. Zhu, D. Tuia, L. Mou, G.S. Xia, L. Zhang and F. Xu, "Deep Learning in remote sensing: a comprehensive review and list of resources", IEEE Geosci Remote Sens Mag. 5:8–36, 2017.
- [15] L. Ma, Y. Liu, X. Zhang, Y. Ye, G. Yin and B. A. Johnson, "Deep learning in remote sensing applications: A meta-analysis and review", ISPRS J. Photogram. Remote Sens. 152, 166–177, 2019.

- [16] S. Mehrnoush, A. Mehrtash, E. Khazraee and A. Jason, "Deep learning in archaeological remote sensing: Automated qanat detection in the kurdistan region of Iraq", *Remote Sensing* 12, no. 3: 500, 2020.
- [17] Q. Li, H. Guo, L. Luo and X. Wang, "Automatic Mapping of Karez in Turpan Basin Based on Google Earth Images and the YOLOv5 Model", *Remote Sens*, 14, 3318, 2022.
- [18] D. Erhan, C. Szegedy, S. Reed, C.Y. Fu and A.C. Berg, "SSD: Single shot multibox detector", In *Proceedings of the Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Springer: Cham, Switzerland, Volume 9905, pp. 21–37, 2016.
- [19] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition", in *CVPR*, 2016.
- [20] B. Xu, N. Wang, T. Chen and M. Li, "Empirical evaluation of rectified activations in convolutional network", *arXiv Prepr. arXiv:00853/1505*, 2015.
- [21] W. Liu, D. Anguelov, D. Erhan and et al., "SSD: single shot multibox detector", In: *European conference on computer vision*. Cham: Springer, p. 21–37, 2016.
- [22] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition", In: *arXiv e-prints*, 03385/1512, 2015.
- [23] T.Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Doll'ar and C.L. Zitnick, "Microsoft coco: Common objects in context", In *European Conference on Computer Vision*; Springer: Berlin/Heidelberg, Germany, pp. 740–755, 2014.
- [24] T. Ise, M. Minagawa and M. Onishi, "Classifying 3 moss species by deep learning, using the "chopped picture" method", *Open J Ecol*. 8:166–73, 2018.
- [25] J. Redmon, S. Divvala, R. Girshick and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection", *arXiv:02640/1506*, 2015.
- [26] J. Jeong, H. Park and N. Kwak, "Enhancement of SSD by concatenating feature maps for object detection", In: *BMVC'17*, 2017.



## ***Application of convolutional neural networks single-shot multibox detector (SSD) in automatic detection and extraction of Qanat from Google Earth satellite images***

*Mostafa Kabolizadeh<sup>1</sup>, Mohammad Abbasi<sup>2\*</sup>*

1- Assistant Professor, Department of Remote Sensing and Geographical Information System, Faculty of Earth Sciences, Shahid Chamran University of Ahvaz.

2- Phd. Student of Remote Sensing and Geographical Information System, Faculty of Planning and Environmental Sciences, University of Shahid Chamran Ahvaz.

### **Abstract**

Identifying qanat and mapping them is one of the vital tasks in the science of groundwater resources management. However, it is difficult to map qanats because conventional methods such as field mapping are very costly and time consuming, and in some cases, due to the structure of qanat, land extraction faces many challenges. Identifying objects from image data using computer image processing techniques and neural networks is one of the most promising techniques for identifying qanats. Due to the fact that the satellite images of Google Earth system are the only satellite images with high spatial resolution, free of charge and available, the Google Earth satellite images have been used in this research. In this research, more than 600 educational samples have been prepared from the openings of qanats. In this research, due to its higher processing speed, the convolutional neural network single-shot multi-box detector based on ResNet network has been used to automatically detect and extract the geometric location of qanats. The proposed model has been taught by training samples based on 85% of the training data and 15% of the validation data, with 50 repetition courses and an accuracy of more than 90%. The trained model is implemented on the image of the study area in order to discover the shafts of qanats. The results show that this model can work with the accuracy criterion equal to 0.91, the recovery criterion equal to 0.82, and the F1Score criterion equal to 0.86 in discovering the location of the rod of the aqueduct wells with a suitable shape. For the areas where the shape of the rod of the wells is destroyed, the accuracy of detecting and extracting the position of the wells is equal to 0.65. This research shows that it is possible to automatically identify and extract aqueduct well rods with appropriate accuracy from satellite images downloaded from the Google Earth system.

**Key words:** Convolution Neural Network, Single Shot Multi-box Detector, Qanat, ResNet, Google Earth.

**Correspondence Address :** Department of Remote Sensing and Geographical Information System, Faculty of Earth Sciences, Shahid Chamran University of Ahvaz, Iran.

**Tel:** +98 916 3470177.

**Email:** m.kabolizade@scu.ac.ir