

مرور نظام‌مند بر روش‌های یادگیری ماشین و یادگیری عمیق برای نقشه‌برداری از سیلاب در جهان و ایران

یوسف تقی ملایی*

چکیده

نقشه‌برداری دقیق و به هنگام از پهنه‌های سیل‌گیر، پایه و اساس مدیریت پیشگیرانه و کاهش خطر سیلاب محسوب می‌شود. در سال‌های اخیر، روش‌های یادگیری ماشین و یادگیری عمیق با بهره‌گیری از داده‌های سنجش‌ازدور، تحولی در این حوزه ایجاد کرده‌اند. پژوهش حاضر با هدف مرور نظام‌مند روش‌های یادگیری ماشین و یادگیری عمیق برای نقشه‌برداری سیلاب در جهان و ایران و ارائه چارچوبی برای توسعه مدل‌های قابل‌اعتماد، به‌روش مرور نظام‌مند و بر اساس رهنمودهای پریسما انجام شد. جستجو در پایگاه‌های معتبر علمی برای مقالات منتشرشده بین سال‌های ۲۰۱۵ تا ۲۰۲۶ انجام و پس از غربالگری، ۴۲ مقاله (۳۰ مقاله بین‌المللی و ۱۲ مطالعه موردی از ایران) برای تحلیل نهایی انتخاب شدند. یافته‌ها نشان می‌دهد که روش‌ها در سه دسته اصلی جای می‌گیرند: (۱) روش‌های سنتی یادگیری ماشین مانند جنگل تصادفی و ماشین‌بردار پشتیبان که عمدتاً برای پهنه‌بندی حساسیت به سیل به‌کاررفته‌اند؛ (۲) معماری‌های یادگیری عمیق شامل شبکه عصبی پیچشی، معماری یو-نت و شبکه‌های بازگشتی مانند حافظه کوتاه‌مدت بلندمدت که دقت بالایی در نقشه‌برداری گستره سیل از تصاویر ماهواره‌ای دارند؛ و (۳) رویکردهای ترکیبی و آگاه از فیزیک مانند شبکه عصبی آگاه از فیزیک که با گنجانیدن معادلات هیدرودینامیک در تابع هزینه، پیش‌بینی‌های سازگار با قوانین فیزیک تولید می‌کنند. در سطح بین‌المللی، مدل‌های بنیادی مانند مدل بخش‌بندی هر چیز و مدل پریتوی ناسا و تبدیل‌گرهای بینایی، تعمیم‌پذیری بالاتری در رویدادهای مختلف نشان داده‌اند. در ایران، باوجود پژوهش‌های نوآورانه (مانند شبکه انتزاع عمیق و شبکه عصبی بازگشتی المان) در استان‌های گلستان، خوزستان و خراسان رضوی، شکاف عمیقی میان خروجی‌های علمی و کاربرد عملیاتی وجود دارد. فقدان پژوهش‌های مبتنی بر تصاویر رادار روزنه ترکیبی لحظه‌ای، غیاب مدل‌های آگاه از فیزیک، عدم ارزیابی تعمیم‌پذیری زمانی-مکانی و نبود چارچوب مقرراتی برای پذیرش عملیاتی، از مهم‌ترین شکاف‌های پژوهشی در کشور است. نتیجه‌گیری می‌شود که برای توسعه کاربردهای عملیاتی در ایران، تمرکز بر تنظیم دقیق مدل‌های بنیادی موجود با داده‌های محلی، ایجاد دادگان ملی تصاویر ماهواره‌ای سیلاب، به‌کارگیری رویکردهای آگاه از فیزیک و تفسیرپذیری با روش‌های هوش مصنوعی تفسیرپذیر ضروری است.

واژگان کلیدی:

پهنه‌بندی سیلاب، هوش مصنوعی در هیدرولوژی، شبکه‌های عصبی عمیق، مدل‌های بنیادی، سنجش‌ازدور، مدیریت ریسک سیلاب، مطالعات موردی ایران.



مقاله پژوهشی

۱. محقق مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان فارس، شیراز، ایران.

taghimollaei@yahoo.com

* نویسنده مسئول

۱۱۷۸-۲۶۰۶

شناسه مقاله:

۱۳۹۷-۱۳۸۵

شماره صفحه پایایی:

۱۴۰۵/۰۴/۱۰

تاریخ دریافت:

۱۴۰۵/۰۶/۱۶

تاریخ پذیرش:

۱۴۰۵/۰۶/۲۶

انتشار آنلاین:

۶۹ روز

زمان پذیرش:

استناددهی:

تقی‌ملایی، ی. (۱۴۰۵). مرور نظام‌مند بر روش‌های یادگیری ماشین و یادگیری عمیق برای نقشه‌برداری از سیلاب در جهان و ایران. مدیریت اکوسیستم‌های طبیعی، (۲) ۶، ۵۹-۷۱.

۱- مقدمه

سیلاب به‌عنوان یکی از پُرخسره‌ترین بلایای طبیعی، سالانه خسارات سنگین جانی، اقتصادی و زیست‌محیطی را در پی دارد (Silwal et al., 2026). بررسی‌های جهانی نشان می‌دهد که خطر سیلاب به دلیل تغییر اقلیم، شهرنشینی شتابان و گسترش زیرساخت‌ها در مناطق سیل‌گیر، روندی افزایشی داشته است (El Baida et al., 2024). در چنین شرایطی، نقشه‌برداری دقیق از پهنه‌های سیل‌گیر به ستون فقرات مدیریت پیشگیرانه تبدیل می‌شود (Silwal et al., 2026). سیر تاریخی پژوهش‌ها در نقشه‌برداری سیلاب نشان می‌دهد که این حوزه از سه نسل روش‌شناختی عبور کرده است: نسل اول: مدل‌های هیدرودینامیک سنتی، مدل‌هایی مانند سیستم تحلیل رودخانه مرکز مهندسی هیدرولوژی^۱ و مدل دشت سیلابی لیست‌فلو^۲ با وجود دقت مهندسی بالا، اغلب از نظر محاسباتی پرهزینه، نیازمند داده‌های گسترده و برای کاربردهای نزدیک به لحظه دشوار هستند (El Baida et al., 2024). این مدل‌ها همچنان در بسیاری از کشورها به‌عنوان استاندارد طلایی شناخته می‌شوند، اما محدودیت‌های آنها در مقیاس‌پذیری و پردازش بلادرنگ، پژوهشگران را به سمت روش‌های جایگزین سوق داده است.

نسل دوم: یادگیری ماشین سنتی، با گسترش داده‌های سنجش‌ازدور، روش‌هایی مانند جنگل تصادفی^۳ و ماشین‌بردار پشتیبان^۴ برای پهنه‌بندی حساسیت به سیل در مقیاس حوضه‌های آبریز به‌کار گرفته شدند. در ایران، روش‌های سنتی مانند جنگل تصادفی، ماشین‌بردار پشتیبان و مدل‌های درختی (مانند درخت طبقه‌بندی و رگرسیون) برای پهنه‌بندی حساسیت به سیل به‌کاررفته‌اند. برای نمونه، مطالعه یوسفی و همکاران (۱۴۰۱) در حوضه کشکان نشان داد که مدل درخت طبقه‌بندی و رگرسیون^۵ با $AUC=0.91$ و $TSS=0.88$ ، دقیق‌ترین مدل در پیش‌بینی پتانسیل خطر سیل بوده است. این روش‌ها با هزینه محاسباتی پایین و قابلیت تفسیر نسبی، در دهه ۲۰۱۰ میلادی به‌سرعت مورد استقبال قرار گرفتند. با این حال، وابستگی آنها به مهندسی ویژگی دست‌ساخت و ناتوانی در استفاده مستقیم از تصاویر ماهواره‌ای، زمینه‌ساز ظهور نسل سوم شد.

نسل سوم: یادگیری عمیق و مدل‌های بنیادی^۶ در سال‌های اخیر، روش‌های یادگیری عمیق مانند شبکه‌های عصبی پیچشی^۷، شبکه عصبی - یو برای بخش‌بندی دقیق گستره سیلاب، و شبکه‌های بازگشتی (حافظه کوتاه‌مدت بلندمدت^۸ و واحد بازگشتی دروازه‌ای) برای پیش‌بینی سری‌های زمانی دبی و تراز آب، تحولی در این حوزه ایجاد کرده‌اند (Kirillov et al., 2023; Jakubik et al., 2023). به‌تازگی، مدل‌های بنیادی مانند مدل بخش‌بندی هر چیز^۹ و پریوتی ناسا^{۱۰} تبدیل‌گرهای بینایی^{۱۱} با قابلیت تمییزپذیری بالا در رویدادهای مختلف، مرزهای دانش را جابه‌جا کرده‌اند (Chamatidis et al., 2024). رویکردهای ترکیبی و آگاه از فیزیک^{۱۲} با گنجاندن معادلات هیدرودینامیک در تابع هزینه، گام بلندی در جهت تولید پیش‌بینی‌های سازگار با قوانین فیزیک برداشته‌اند (Qin and Chen, 2024).

جایگاه ایران در این پژوهش‌ها: سهم ایران در پژوهش‌های جهانی این حوزه قابل توجه است و مطالعات متعددی در استان‌های سیل‌خیز گلستان، خوزستان و خراسان رضوی انجام شده است (Shirzadi et al., 2025; Gholami et al., 2025). با این حال، مرور نظام‌مند دقیقی که به‌طور همزمان روش‌های یادگیری ماشین^{۱۳} و یادگیری عمیق^{۱۴} را در ایران با جریان اصلی بین‌المللی مقایسه کند، تاکنون انجام نشده است. همچنین، شکاف میان خروجی‌های علمی و کاربرد عملیاتی در نظام مدیریت سیلاب کشور، ضرورت انجام چنین پژوهشی را دوچندان می‌سازد. هدف این پژوهش با هدف مرور نظام‌مند روش‌های یادگیری ماشین و یادگیری عمیق برای نقشه‌برداری سیلاب در جهان و ایران و ارائه چارچوبی برای توسعه مدل‌های قابل اعتماد و کاربردپذیر انجام شده است.

۲- مواد و روش‌ها

پژوهش حاضر به‌روش مرور نظام‌مند و بر مبنای رهنمودهای پرسیما^{۱۵} انجام شد (Page et al., 2021). جستجو در پایگاه‌های Scopus، Web of Science، IEEE Explore، Science Direct و Google Scholar برای مقالات منتشرشده بین سال‌های ۲۰۱۵ تا ۲۰۲۶ اجرا گردید. کلید واژه‌های ترکیبی شامل "Flood Inundation Mapping"، "Machine Learning"، "Deep Learning"، "CNN"، "LSTM"، "Random Forest"، "Remote Sensing" و "Iran" بود. برای بخش فارسی، از پایگاه‌های SID و Civilica استفاده شد. معیارهای ورود: (۱) مقالات پژوهشی اصیل، (۲) کاربرد حداقل یک روش یادگیری ماشین/یادگیری عمیق برای نقشه‌برداری سیل، (۳) گزارش معیارهای عملکردی شفاف. معیارهای خروج: مقالات مروری، گزارش‌های فنی و فاقد ارزیابی کمی.

1. Flood Inundation Mapping (FIM)

2. Hydrologic Engineering Center – River Analysis System (HEC-RAS)

3. LISFLOOD Floodplain Model (LISFLOOD-FP)

4. Random Forest (RF)

5. Support Vector Machine (SVM)

6. Classification and Regression Tree (CART)

7. Foundation Models

8. Convolutional Neural Network (CNN)

9. U-Net

10. Long Short- Term Memory (LSTM)

11. Gated Recurrent Units (GRU)

13. Segment Anything Model

14. Prithvi (NASA)

15. Vision Transformers


16. Physics-Informed Neural Network (PINN)

17. Machine Learning (ML)

18. Deep Learning

19. PRISMA

پس از جستجوی اولیه، تعداد ۱۹۷ مقاله شناسایی شد. در مرحله نخست، ۵۸ مقاله تکراری حذف شدند. در مرحله دوم، با بررسی عنوان و چکیده، ۷۲ مقاله نامرتبط بر اساس معیارهای خروج کنار گذاشته شدند. در مرحله سوم، متن کامل ۶۷ مقاله باقیمانده بررسی و بر اساس معیارهای ورود و خروج ارزیابی شد. در نهایت، ۴۲ مقاله (۳۰ مقاله بین‌المللی و ۱۲ مطالعه موردی از ایران) برای تحلیل نهایی انتخاب شدند (شکل ۱). استخراج داده‌ها به‌صورت ساختاریافته شامل نویسندگان، سال، منطقه، نوع مدل، داده‌ها، معیارهای ارزیابی و یافته‌های اصلی انجام شد. تحلیل با روش تحلیل محتوای کیفی و دسته‌بندی موضوعی صورت گرفت.




شکل (۱): نمودار جریان پریسما برای فرآیند غربالگری مقالات

۳- نتایج و بحث

۳-۱- دسته‌بندی روش‌های یادگیری ماشین و یادگیری عمیق

تحلیل نظام‌مند مقالات نشان می‌دهد که روش‌های مورد استفاده در نقشه‌برداری سیلاب را می‌توان در سه دسته اصلی طبقه‌بندی کرد: (۱) روش‌های سنتی یادگیری ماشین، (۲) معماری‌های یادگیری عمیق و (۳) رویکردهای ترکیبی و آگاه از فیزیک (Qin and Chen, 2024; Silwal et al., 2026). در ادامه، هر یک از این دسته‌بندی‌ها به‌همراه نقاط قوت و ضعف آنها بررسی می‌شود. شکل (۲) طبقه‌بندی مفهومی روش‌های یادگیری ماشین و یادگیری عمیق مورد استفاده در نقشه‌برداری از سیلاب را به‌همراه معماری‌های مرتبط (مانند شبکه عصبی پیچشی، شبکه عصبی - یو، حافظه کوتاه‌مدت بلندمدت) نشان می‌دهد.



شکل (۲): طبقه‌بندی مفهومی روش‌های یادگیری ماشین و یادگیری عمیق مورد استفاده در نقشه‌برداری از سیلاب. این نمودار، رویکردهای

مدل‌سازی را بر اساس خانواده روش‌شناختی، از جمله یادگیری ماشین سنتی، معماری‌های یادگیری عمیق و چارچوب‌های ترکیبی نوظهور، مبتنی بر فیزیک، آگاه از عدم قطعیت و قابل توضیح، سازمان‌دهی می‌کند. فلش‌ها به‌جای گردش کار یا رتبه‌بندی عملکرد، روابط مفهومی را نشان می‌دهند.

روش‌های سنتی: مدل‌های رگرسیونی یادگیری ماشین مانند جنگل تصادفی و رگرسیون لجستیک، به‌عنوان جایگزین‌های کارآمد برای مدل‌سازی مخاطرات سیلاب شهری مطرح شده‌اند (El Baida et al., 2024). جنگل تصادفی و ماشین‌بردار پشتیبان پُرکاربردترین الگوریتم‌ها هستند. این مدل‌ها

عمدتاً برای پهنه‌بندی حساسیت به سیل در مقیاس حوضه با استفاده از لایه‌های توپوگرافی، شیب، فاصله از رودخانه و بارش به کاررفته‌اند. در مطالعه‌ای که توسط Bashirgonbad et al. (۲۰۲۴) در حوضه گاماسیاب، غرب ایران انجام شد، مدل گروهی با AUC برابر ۰/۹۰، عملکرد بهتری نسبت به مدل‌های تکی جنگل تصادفی با AUC ۰/۸۷ و ماشین‌بردار پشتیبان با AUC ۰/۸۵ در نقشه‌برداری سیلاب نشان داد (Bashirgonbad et al., 2024). مزایای اصلی این روش‌ها شامل سادگی، هزینه محاسباتی پایین و قابلیت تفسیر نسبی است، درحالی که ناتوانی در استفاده مستقیم از تصاویر ماهواره‌ای و وابستگی شدید به مهندسی ویژگی از مهم‌ترین محدودیت‌های آنها محسوب می‌شود.

معماری‌های یادگیری عمیق: شبکه‌های عصبی پیچشی به‌ویژه شبکه عصبی - یو، برای نقشه‌برداری گستره سیلاب از تصاویر رادار روزنه ترکیبی^۲ عملکرد برجسته‌ای داشته‌اند. در مطالعه Kaçmaz and Alganci (۲۰۲۶) بر روی مجموعه داده S1GFloods (شامل ۵۳۶۰ جفت تصویر سنتینل ۱^۱ از ۴۶ رویداد سیل در شش قاره)، مدل شبکه عصبی پیچشی یو- نت سیامی^۴ با مکانیسم توجه تفاضلی به F1-score برابر ۰/۹۶ در صد دست یافت که نشان‌دهنده دقت بالای این معماری در تفکیک پهنه‌های سیل گرفته است (Kaçmaz and Alganci, 2026). همچنین، مطالعه Maddah et al. (۲۰۲۵) در حوضه گرگانرود نشان داد که مدل شبکه عصبی بازگشتی^۵ با AUC تست ۰/۹۶۹، عملکرد بهتری نسبت به شبکه‌های بازگشتی مانند حافظه کوتاه‌مدت بلندمدت (AUC ۰/۹۴) و واحد بازگشتی دروازه‌ای (AUC ۰/۹۲) در پهنه‌بندی حساسیت به سیلاب داشته است.

رویکردهای ترکیبی و آگاه از فیزیک: مطالعه Qin and Chen (۲۰۲۴) نشان داد که شبکه‌های عصبی آگاه از فیزیک با گنجاندن معادلات آب‌های کم‌عمق در تابع هزینه، می‌توانند بدون نیاز به داده‌های برچسب‌دار، عمق سیلاب را با تعادل مناسبی بین سرعت و دقت پیش‌بینی کنند. همچنین، مطالعه Razavi-Termeh et al. (۲۰۲۵) در شهر استهبان نشان داد که مدل شبکه عصبی بازگشتی-الگوریتم ژنتیک با AUC ۹۳/۲ درصد بالاترین عملکرد را در پهنه‌بندی حساسیت به سیلاب داشته است و مدل‌های بهینه‌شده با الگوریتم‌های کلاغ^۶ و ژنتیک^۷ عملکرد بهتری نسبت به مدل‌های تکی نشان دادند (Razavi-Termeh et al., 2025).

به‌منظور ارائه تصویری شفاف از تنوع روش‌ها و عملکرد آنها، جدول (۱) ویژگی‌های کلیدی مدل‌های پرکاربرد را بر اساس مقالات مرور شده، با تفکیک دسته‌بندی‌های اصلی و ترکیبی خلاصه می‌کند. این جدول که به‌صورت جامع توسط نگارندگان تهیه‌شده، شامل پنج دسته‌بندی اصلی (یادگیری ماشین سنتی، یادگیری عمیق مکانی، یادگیری عمیق زمانی/تولیدی، مدل‌های ترکیبی و جمعی و رویکردهای نوظهور) است و به‌خوبی نشان می‌دهد که هر دسته از روش‌ها برای چه نوع داده‌ها و کاربردهایی مناسب‌تر هستند.

۲-۳- عملکرد مدل‌ها در نقشه‌برداری گستره و عمق سیلاب

۳-۲- نقشه‌برداری گستره سیلاب

الف) یافته‌های مطالعات بین‌المللی

در نقشه‌برداری گستره سیلاب، شبکه عصبی - یو و مشتقات آن به‌ویژه در ترکیب با داده‌های رادار روزنه ترکیبی، عملکرد برجسته‌ای داشته‌اند. به‌عنوان مثال، مطالعه Pech-May et al. (۲۰۲۵) با استفاده از تصاویر سنتینل ۱ و ۲ و شبکه عصبی - یو، در منطقه ریوس مکزیک، توانست نقشه‌های سیلاب را با دقت بالایی تولید کند و نشان داد که افزایش داده‌های آموزشی، دقت تشخیص سیلاب را بهبود می‌بخشد (Pech-May et al., 2025). در مطالعه Sardar and Saheer (۲۰۲۵) در بنگلادش، مدل تبدیلگر بینایی با IoU برابر ۰/۸۸ و صحت ۹۲/۴ درصد، عملکردی قابل‌رقابت با شبکه عصبی - یو داشت و تعمیم‌پذیری بالاتری در مناطق با پوشش ابری نشان داد (Sardar and Saheer, 2025). مدل پریتمی ناسا آی‌بی‌ام^۸ نیز که بر روی داده‌های هماهنگ‌شده لندست و سنتینل ۲ آموزش دیده، در تشخیص تغییرات ناگهانی گستره سیلاب در حوضه میسیسیپی، F1-Score برابر ۰/۹۱ گزارش کرده است (Jakubik et al., 2023). در مطالعه Xu et al. (۲۰۲۳) بر روی رودخانه یانگتسه، مدل ترکیبی شبکه عصبی پیچشی حافظه کوتاه‌مدت با شاخص‌های عملکردی بسیار بالا (NSE و KGE^{۱۰} بیشتر از ۰/۹۹۵ و RMSE کمتر از ۰/۲۰۰) توانایی قابل‌توجهی در شبیه‌سازی دقیق تراز آب و دبی سیلاب نشان داد (Xu et al., 2023).

ب) یافته‌های مطالعات داخلی

در ایران، پژوهش‌ها در زمینه نقشه‌برداری گستره سیلاب عمدتاً بر پهنه‌بندی حساسیت ایستای متمرکز بوده و کمتر از تصاویر رادار روزنه ترکیبی برای نقشه‌برداری لحظه‌ای استفاده کرده‌اند. با این حال، مطالعات اخیر گام‌های مؤثری در این جهت برداشته‌اند. در مطالعه‌ای جامع در حوضه دز، Roohi et

1. Ensemble

2. Synthetic Aperture Radar-SAR

3. Sentinel 1

4. Siamese U-Net

5. Elman Recurrent Neural Network

6. Crow search Algorithm

7. Genetic Algorithm

8. NASA-IBM

9. Harmonized Landsat and Sentinel-2

10. Nash Sutcliffe Efficiency (NSE)

11. Kling-Gupta Efficiency (KGE)

al. (۲۰۲۵) با تلفیق مدل هیدرولوژیکی مرکز مهندسی هیدرولوژی^۱، الگوریتم‌های یادگیری گروهی^۲ و شبکه‌عصبی- یو و پردازش ۳۴۲ تصویر ماهواره‌ای (سنتینل ۲، لندست ۸ و ۹) برای شش رویداد سیل، موفق به دستیابی به mIoU برابر ۷۰ تا ۷۱/۳ درصد شدند و نشان دادند که رویکردهای ترکیبی می‌توانند نقشه‌های گستره سیلاب را با دقت قابل‌قبولی تولید کنند (Roohi et al., 2025). همچنین، مطالعه Mokarram and Zarei (۲۰۲۶) با استفاده از سنجش از دور و شبکه عصبی مصنوعی، مناطق بالقوه سیل‌گیر را در ایران شناسایی کردند و نشان دادند که مدل‌های شبکه عصبی با تلفیق داده‌های ماهواره‌ای می‌توانند نقشه‌های گستره سیلاب را با دقت بالایی تهیه کنند. از سوی دیگر، مدل BHED U Net^۳ که یک چارچوب یادگیری عمیق مبتنی بر استنتاج بیزی^۴ برای نقشه‌برداری سیلاب با تصاویر رادار روزنه ترکیبی است، در استان گلستان (رویداد سیل ۲۰۱۹) با دقت کلی ۹۲/۵ درصد و IoU برابر ۰/۶۸۱ عملکرد قابل‌توجهی در تفکیک پهنه‌های سیل‌گرفته نشان داد و قابلیت تعمیم‌پذیری خود را در مناطق مختلف به اثبات رساند (Garshasbi et al., 2025). همچنین، در حوضه کرخه، چارچوب گرادیان تقویتی اکسترم^۵، تفسیرهای افزایشی شاپلی با AUC برابر ۰/۸۹ و تحلیل تفسیرپذیر با تفسیرهای افزایشی شاپلی، نشان داد که عواملی مانند شیب، ارتفاع و شاخص نرمال پوشش گیاهی^۶ بیشترین تأثیر را در وقوع سیلاب دارند (Rezvani et al., 2026). این مطالعات نشان‌دهنده حرکت تدریجی پژوهش‌های داخلی به سمت استفاده از داده‌های رادار روزنه ترکیبی، مدل‌های عمیق و رویکردهای تفسیرپذیر است، هرچند همچنان فاصله قابل‌توجهی با کاربردهای عملیاتی و پایش لحظه‌ای سیلاب در ایران وجود دارد.

جدول (۱): خلاصه مقایسه‌ای روش‌های یادگیری ماشین و عمیق در نقشه‌برداری سیلاب

دسته‌بندی اصلی	مدل/ روش شاخص	داده‌های ورودی معمول	کاربرد اصلی در نقشه‌برداری سیلاب	معیارهای عملکرد شاخص	مزایای کلیدی	معایب و چالش‌های اصلی
یادگیری ماشین سنتی	RF	رادار روزنه ترکیبی، نوری، DEM، شیب	نقشه‌برداری حساسیت و گستره سیلاب	AUC: ۰/۹۲ تا ۰/۹۵ دقت بالا	مقاوم به بیش‌برازش، اهمیت‌دهی ویژگی، تفسیرپذیری خوب	عملکرد در داده‌های با ابعاد بسیار بالا (تصاویر خام) پایین‌تر از یادگیری عمیق
	SVM	باند‌های طیفی، شاخص‌های پوشش گیاهی	طبقه‌بندی آب/غیر آب (پیکسل پایه)	AUC: ۰/۸۸ تا ۰/۹۲ صحت قابل قبول	عملکرد خوب در ابعاد بالا، بنیاد ریاضی قوی	هزینه محاسباتی بالا در داده‌های حجیم، انتخاب هسته دشوار
	XGBoost/LightGBM	ترکیبی از داده‌های محیطی و هیدرولوژیکی	پیش‌بینی عمق و سرعت سیلاب	پایین، RMSE R ² > ۰/۸۵	سرعت بالا، دقت عالی، مدیریت داده‌های گمشده	نیاز به تنظیم دقیق فرا پارامترها، خطر بیش‌برازش در داده‌های کوچک
	CNN	برش‌های تصویر (رادار روزنه ترکیبی/نوری)	طبقه‌بندی پیکسلی و تشخیص تغییرات	دقت کلی ~ ۸۵ تا ۹۰ درصد	استخراج خودکار ویژگی‌های مکانی	نیاز به برچسب‌گذاری پیکسلی، تفسیرپذیری پایین
یادگیری عمیق (تفکیک مکانی)	U-Net	تصاویر رادار روزنه ترکیبی و نوری (سنجش‌ازدور)	بخش‌بندی دقیق گستره سیلاب (Pixel-wise)	IoU: ۰/۸۵ تا ۰/۷۵ F1-Score بالا	معماری متقارن برای بازایی لبه‌ها، دقت بالا در مرزها	نیاز به داده‌های آموزشی بسیار زیاد و متنوع، حساس به نویز
	DeepLabV3 / HRNet	تصاویر با قدرت تفکیک بالا (ماهواره‌ای)	نقشه‌برداری دقیق در مناطق شهری	mIoU > ۰/۸۰	قدرت استخراج ویژگی‌های چندمقیاسی	سنگین از نظر محاسباتی، واحد پردازش گرافیکی پیشرفته
	LSTM / RNN	سری زمانی دبی، بارش، تصاویر متوالی	مدل‌سازی پویایی سیلاب و پیش‌بینی گستره زمانی	پایین در RMSE پیش‌بینی دبی	مدل‌سازی وابستگی‌های طولانی‌مدت زمانی	مدل‌سازی توزیع مکانی دشوار، پیچیدگی بالا
یادگیری عمیق (زمانی/تولیدی)	GAN	داده‌های نوری یا رادار روزنه ترکیبی با کیفیت پایین	تولید نقشه‌های سیلاب واقع‌گرایانه / افزایش داده	کیفیت بصری بالا، دقت رقابتی	تولید داده‌های مصنوعی با کیفیت برای تقویت مجموعه آموزش	آموزش ناپایدار، مستعد هم‌ریزی حالت
	CNN-LSTM / ConvLSTM	تصاویر متوالی DEM + (داده‌های مکانی-زمانی)	پیش‌بینی و نقشه‌برداری هم‌زمان مکانی-زمانی سیلاب	بهبود ۵ تا ۱۰ درصد دقت نسبت به مدل‌های تکی	مدل‌سازی هم‌زمان الگوهای مکانی و تغییرات زمانی	پیچیدگی محاسباتی بالا، دشواری در تنظیم هم‌زمان فرا پارامترها
مدل‌های ترکیبی و جمعی	Ensemble (Voting/Stacking) of RF, SVM, CNN	ترکیبی از ویژگی‌های استخراج‌شده از چند مدل	افزایش دقت نهایی طبقه‌بندی گستره سیلاب	F1-Score > ۰/۹۰ در مطالعات اخیر	بهره‌گیری از نقاط قوت مدل‌های مختلف، کاهش واریانس	زمان پردازش طولانی، تفسیرپذیری بسیار دشوار
	PINN	DEM، داده‌های هیدرولیکی + معادلات دیفرانسیل	شبیه‌سازی عمق و سرعت با رعایت قوانین فیزیکی	دقت بالا همراه با قابلیت تفسیر فیزیکی	ترکیب مزایای فیزیک و داده، کاهش نیاز به داده‌های آموزشی	پیچیدگی ریاضی بالا، دشواری در پیاده‌سازی برای مناطق وسیع
رویکردهای نو ظهور	Transformer (ViT, Swin)	تصاویر ماهواره‌ای با پوشش وسیع	بخش‌بندی دقیق با درک زمینه‌ای قوی (ارتباطات دوربرد)	رقابت‌پذیر با U-Net (در برخی دقت بالاتر)	مدل‌سازی وابستگی‌های دوربرد و ارتباطات سراسری در تصویر	نیاز به داده و محاسبات بسیار کلان، هزینه‌ی بالای آموزش

مطالعه Maddah et al. (۲۰۲۵b) در حوضه گرگانرود با استفاده از تصاویر سنتینل ۱ رادار روزنه ترکیبی و مدل شبکه عصبی پیچشی با دو ورودی^۸ همراه با شبکه تخاصمی مولد^۹ برای متعادل‌سازی داده‌ها، به AUC تست ۰/۹۵۴ دست‌یافت. این مطالعه نشان داد که مدل شبکه عصبی پیچشی با دو ورودی با AUC تست ۰/۹۵۴، عملکرد بهتری نسبت به مدل شبکه عصبی پیچشی تک‌ورودی با AUC تست ۰/۹۳۳ دارد و حدود ۱۵/۱۷ درصد از اراضی حوضه، عمدتاً در نواحی پایین‌دست، حساسیت زیاد و خیلی زیاد به سیلاب دارند.

1. Hydrologic Engineering Center– Hydrologic Modeling System (HEC-HMS)
2. Ensemble Learning
3. Landsat
4. Bayesian Heteroscedastic Encoder-Decoder U-Net- BHED-U-Net
5. Bayesian Deep Learning

6. eXtreme Gradient Boosting
7. Normalized Difference Vegetation Index (NDVI)
8. Dual-Input Convolutional Neural Network
9. Generative Adversarial Network

ج) مقایسه تطبیقی یافته‌های داخلی و بین‌المللی

مقایسه مستقیم این دو دسته مطالعه نشان می‌دهد که هرچند مدل شبکه عصبی پیچشی با دو ورودی در گرگانه‌د عملکرد قابل قبولی داشته (AUC ۰/۹۵۴)، اما این مدل صرفاً برای پهنه‌بندی حساسیت (پیش‌بینی مناطق مستعد سیل در آینده) طراحی شده است، درحالی‌که مدل شبکه عصبی - یو در مکزیک و مدل تبدیلگر بینایی در بنگلادش برای نقشه‌برداری لحظه‌ای گستره سیلاب در زمان وقوع بحران به‌کاررفته‌اند. این تفاوت در هدف کاربردی، شکاف عملیاتی جدی در نظام مدیریت بحران ایران را آشکار می‌سازد.

۳-۲-۱- برآورد عمق سیلاب

الف) یافته‌های مطالعات بین‌المللی


برآورد عمق سیلاب به‌مراتب پیچیده‌تر از نقشه‌برداری گستره است و نیازمند داده‌های توپوگرافی دقیق و شبیه‌سازی هیدرولیکی می‌باشد. مطالعه Qin and Chen (۲۰۲۴) بر روی شبیه‌سازی‌های ایده‌آل و یک سناریوی سیلاب رودخانه‌ای نشان داد که شبکه‌های عصبی آگاه از فیزیک با گنجاندن معادلات آب‌های کم‌عمق در تابع هزینه، می‌توانند بدون نیاز به داده‌های برچسب‌دار، عمق سیلاب را با تعادل مناسبی بین سرعت و دقت پیش‌بینی کنند. در مطالعات بین‌المللی، مدل‌های ترکیبی شبکه عصبی پیچشی حافظه کوتاه‌مدت بلندمدت نیز برای برآورد عمق سیلاب شهری به‌کار گرفته شده‌اند. به‌عنوان مثال، مطالعه Chen et al. (۲۰۲۳) با استفاده از این معماری در شهر ژوکو، چین، موفق به پیش‌بینی عمق سیلاب با RMSE برابر ۰/۳۸ متر شدند.

ب) یافته‌های مطالعات داخلی

در ایران، پژوهش‌های محدودی به برآورد عمق سیلاب با روش‌های یادگیری عمیق پرداخته‌اند. با این حال، مطالعه Gholami et al. (۲۰۲۵) با ترکیب مدل حافظه کوتاه‌مدت بلندمدت دوطرفه برای تهیه نقشه خطر سیلاب و مدل ارزیابی نسبی پیچیده برای تهیه نقشه آسیب‌پذیری، به تهیه نقشه جامع ریسک سیلاب در جنوب ایران پرداخت. نتایج نشان داد که ۱۵/۸ درصد و ۱۴/۶ درصد از مساحت کل منطقه به ترتیب در کلاس‌های پرخطر تا بسیار پرخطر قرار می‌گیرند (Gholami et al., 2025).

ج) مقایسه تطبیقی یافته‌های داخلی و بین‌المللی

مقایسه مطالعات داخلی و بین‌المللی در حوزه برآورد عمق سیلاب، شکاف‌های زیر را آشکار می‌سازد: (۱) فقدان رویکردهای آگاه از فیزیک در ایران؛ هیچ مطالعه داخلی از شبکه‌های عصبی آگاه از فیزیک استفاده نکرده است، درحالی‌که این روش در سطح بین‌المللی به‌عنوان یک استاندارد نوین برای برآورد عمق سیلاب مطرح است. (۲) ضعف در برآورد عمق سیلاب: بیشتر مطالعات داخلی بر پهنه‌بندی حساسیت متمرکز بوده و به برآورد عمق سیلاب (که برای برآورد خسارت حیاتی است) نپرداخته‌اند. (۳) فقدان داده‌های مرجع استاندارد: حوزه برآورد عمق سیلاب در ایران با چالش فقدان داده‌های مرجع استاندارد باکیفیت مواجه است (جدول ۲). مراحل کلی شامل تلفیق داده‌های مکانی چندمنبعی، پیش‌پردازش، آموزش مدل، ارزیابی گستره و عمق سیلاب، انتخاب مدل، تنظیم فرایامترها، اصلاح ماسک سیل، کمی‌سازی عدم قطعیت و نقشه‌های نهایی و دقیق سیلاب.



شکل (۳): گردش کار مفهومی نقشه‌برداری سیلاب مبتنی بر یادگیری ماشین، مراحل مشترک از ادغام داده‌های مکانی چند منبعی تا آموزش مدل، ارزیابی و پس‌پردازش را نشان می‌دهد. این شکل فقط برای جهت‌گیری مفهومی در نظر گرفته شده است؛ تکنیک‌های خاص، معماری‌های مدل و جزئیات پیاده‌سازی در مطالعات و کاربردهای مختلف بسیار متفاوت است. فلش‌ها نشان‌دهنده جریان اطلاعات مفهومی بین مراحل هستند، نه یک گردش کار متوالی ثابت.

1. Bidirectional Long Short-Term Memory (bLSTM)

2. Complex Proportional Assessment (COPRAS)

3. Ground Truth

جدول (۲):* مقایسه کمی عملکرد مدل‌های شاخص داخلی و بین‌المللی

ردیف	مدل / معماری	منطقه مطالعه	هدف اصلی	معیار عملکرد	مقدار کمی	منبع
۱	U-Net (SAR)	جهانی	نقشه‌برداری گستره سیلاب	F1-score	۹۶/۰۷ درصد	Kaçmaz and Alganci, 2026
۲	Vision Transformer (ViT)	بنگلادش	نقشه‌برداری گستره سیلاب	IoU	۰/۸۸	Sardar and Saheer, 2025
۳	Prithvi (Foundation Model)	مسیسیپی، آمریکا	تشخیص تغییرات سیلاب	F1-Score	۰/۹۱	Jakubik et al., 2023
۴	PINN (Physics-Informed)	شبیه‌سازی رودخانه‌ای	برآورد عمق سیلاب	تبادل سرعت و دقت	بهبود نسبت به مدل‌های عددی	Qin and Chen, 2024
۵	CNN-LSTM	یانگتسه، چین	شبیه‌سازی تراز آب و دبی	NSE, KGE, RMSE, SMAPE	NSE و KGE > ۰/۹۹۵ RMSE و SMAPE < ۰/۲۰۰	Xu et al., 2023
۶	CNN-LSTM	شهر ژوکو، چین	برآورد عمق سیلاب شهری	RMSE	۰/۳۸ متر	Chen et al., 2023
۷	DANet	سندج، ایران	پهنه‌بندی حساسیت سیلاب	AUC	۰/۸۱۱	Shirzadi, 2025
۸	Elman RNN + GA	گرگانرود، ایران	پهنه‌بندی حساسیت سیلاب	تست AUC	۰/۹۶۹	Maddah et al., 2025a
۹	DICNN + GAN	گرگانرود، ایران	پهنه‌بندی حساسیت سیلاب	تست AUC	۰/۹۵۴	Maddah et al., 2025b
۱۰	RNN-GA / LSTM+CSA	استهبان، ایران	پهنه‌بندی حساسیت سیلاب	AUC	۹۳/۲ درصد	Razavi-Termeh et al., 2025
۱۱	bLSTM + COPRAS	جنوب ایران	نقشه ریسک سیلاب	کلاس‌های پرخطر	۱۵/۸ درصد و ۱۴/۶ درصد	Gholami et al., 2025

* معیارهای عملکردی ارائه شده در این جدول به دو دسته کلی تقسیم می‌شوند: (۱) معیارهای مربوط به پهنه‌بندی حساسیت ایستا (مانند TSS, AUC و کلاس‌های پرخطر) که عمدتاً در مدل‌های داخلی استفاده شده‌اند و (۲) معیارهای مربوط به نقشه‌برداری گستره لحظه‌ای سیلاب (مانند F1 Score, IoU, NSE, KGE, RMSE و SMAPE) که عمدتاً در مدل‌های بین‌المللی به کار رفته‌اند.

جدول (۲) به‌وضوح نشان می‌دهد که:

۱. برتری مدل‌های بین‌المللی در نقشه‌برداری لحظه‌ای گستره سیلاب:

مدل‌هایی مانند شبکه عصبی - یو (رادار روزنه ترکیبی) با F1-score برابر ۹۶/۰۷ درصد و تبدیلگر بینایی با IoU برابر ۰/۸۸، عملکرد بسیار بالایی در نقشه‌برداری لحظه‌ای گستره سیلاب دارند. این مدل‌ها با استفاده از تصاویر رادار روزنه ترکیبی، توانسته‌اند پهنه‌های سیل گرفته را با دقت بسیار بالا تفکیک کنند (Kaçmaz and Alganci, 2026; Sardar and Saheer, 2025). در مقابل، مدل‌های داخلی عمدتاً بر پهنه‌بندی حساسیت ایستا متمرکز هستند و عدد عملکردی آن‌ها (AUC) مربوط به پیش‌بینی مناطق مستعد سیل در آینده است، نه نقشه‌برداری لحظه‌ای.

۲. عملکرد بالای مدل‌های داخلی در پهنه‌بندی حساسیت:

مدل شبکه عصبی بازگشتی المن + الگوریتم ژنتیک در حوضه گرگانرود با AUC تست ۰/۹۶۹ بالاترین عملکرد را در بین مدل‌های داخلی داشته و حتی از بسیاری از مدل‌های بین‌المللی در حوزه پهنه‌بندی حساسیت بهتر عمل کرده است (Maddah et al., 2025a). این نشان می‌دهد که پتانسیل علمی بالایی در کشور وجود دارد که می‌تواند به سمت کاربردهای عملیاتی هدایت شود. همچنین، مدل شبکه عصبی پیچشی دوورودی + شبکه تخصصی مولد با AUC تست ۰/۹۵۴ و مدل شبکه عصبی بازگشتی - الگوریتم ژنتیک با AUC ۹۳/۲ درصد عملکرد قابل‌قبولی در پهنه‌بندی حساسیت داشته‌اند (Maddah et al., 2025b; Razavi-Termeh et al., 2025).

۳. غیاب کامل مدل‌های آگاه از فیزیک و بنیادی در ایران:

مدل‌های شبکه‌های عصبی آگاه از فیزیک^۱ و پریئوی ناسا که در سطح بین‌المللی به سرعت در حال گسترش هستند، در ایران کاملاً غایب می‌باشند. این در حالی است که مدل‌های شبکه‌های عصبی آگاه از فیزیک، موفق به بهبود دقت نسبت به مدل‌های عددی سنتی شده است (Qin and Chen, 2024) و مدل پریئوی ناسا با F1-Score برابر ۰/۹۱ در تشخیص تغییرات سیلاب عملکرد عالی داشته است (Jakubik et al., 2023).

۴. شکاف عمیق در حوزه برآورد عمق سیلاب:

حوزه برآورد عمق سیلاب که برای برآورد خسارت و تصمیم‌گیری‌های مدیریتی حیاتی است، در ایران پژوهش‌های بسیار محدودی داشته است. در حالی که مدل شبکه عصبی پیچشی حافظه کوتاه‌مدت بلندمدت در چین با RMSE برابر ۰/۳۸ متر به برآورد عمق سیلاب شهری پرداخته است (Chen et al., 2023)، هیچ مطالعه داخلی به این موضوع نپرداخته است.

تحلیل داده‌های جدول (۳) نشان می‌دهد که:

۱. غلبه مدل‌های سنتی و بهینه‌سازی فراکوشی در ایران در مقابل معماری‌های عمیق مولد در جهان: مدل‌های داخلی عمدتاً بر پهنه‌بندی حساسیت ایستا و پیش‌بینی نقطه‌ای با استفاده از لایه‌های توپوگرافی متمرکزند، در حالی که مدل‌های بین‌المللی بر نقشه‌برداری لحظه‌ای گستره سیل با تصاویر رادار روزنه ترکیبی تکیه دارند (El Baida et al., 2023; Silwal et al., 2026).

۲. نوآوری معماری در ایران قابل قبول است، اما فاقد تعمیم‌پذیری مکانی و زمانی: مدل‌هایی مانند شبکه انتزاع عمیق^۱ در سندج (Shirzadi et al., 2025) و شبکه عصبی بازگشتی المان در گرگانود (Maddah et al., 2025a) نوآوری معماری جالبی دارند، اما هیچ‌یک در مناطق دیگر ایران یا در رویدادهای سیل متفاوت ارزیابی نشده‌اند.

جدول (۳): مقایسه کیفی مدل‌های داخلی و بین‌المللی در نقشه‌برداری سیلاب

ردیف	مدل / معماری	منطقه مطالعه	نقاط قوت اصلی	نقاط ضعف اصلی	ارجاع
۱	DANet	سندج، ایران	نوآوری در ساختار: AUC 0.811	عدم استفاده از تصاویر ماهواره‌ای لحظه‌ای	Shirzadi, 2025
۲	Elman RNN+GA	گرگانود، ایران	AUC 0.969 تست (بالاترین در ایران)	نیاز به سری زمانی طولانی	Maddah et al., 2025a
۳	DICNN+GAN	گرگانود، ایران	AUC 0.954 (عملکرد بهتر از شبکه عصبی پیچشی تک‌ورودی)	وابستگی به داده‌های متوازن	Maddah et al., 2025b
۴	RNN-GA / LSTM+CSA	استهبان، ایران	AUC 93.2 درصد (بهینه‌سازی قوی)	پیش‌بینی نقطه‌ای، نه مکانی	Razavi-Termeh et al., 2025
۵	U-Net (SAR)	جهانی	F1-score 96.07 درصد در نقشه‌برداری لحظه‌ای	نیاز به داده جفت‌شده قبل/حین سیل	Kaçmaz and Alganci, 2026
۶	Vision Transformer	بنگلادش	تعمیم‌پذیری بالا: IoU~0.88	حجم محاسباتی بسیار بالا	Sardar and Saheer, 2025
۷	PINN	شبیه‌سازی رودخانه‌ای	تعادل سرعت و دقت بالا	پیچیدگی پیاده‌سازی	Qin and Chen, 2024
۸	CART	ایران (حوضه کشکان)	سادگی، تفسیرپذیری	عدم توانایی در نقشه‌برداری لحظه‌ای	یوسفی و همکاران، ۱۴۰۱
۹	Ensemble (RF+SVM)	ایران (حوضه گاماسیاب)	AUC 0.90، عملکرد بهتر از مدل‌های تکی	نیاز به تنظیم دقیق فرایامتراها	Bashirgonbad et al., 2024

۳. غیاب روش‌های آگاه از فیزیک و مدل‌های بنیادی در ایران: هیچ مدل داخلی از رویکردهای آگاه از فیزیک (مانند شبکه عصبی آگاه از فیزیک) یا مدل‌های بنیادی (مانند مدل تبدیلیگر بینای، بخش‌بندی هر چیز و پرتیوی ناسا) استفاده نکرده است؛ درحالی‌که این روش‌ها در جهان استانداردهای نوین هستند (Jakubik et al., 2023؛ Chamatidis et al., 2024).

۴. داده‌های ورودی محدود در ایران: داده‌های ورودی در ایران به مدل رقومی ارتفاعی^۲ و کاربری اراضی محدودشده، درحالی‌که جهان از تصاویر رادار روزنه ترکیبی و چند طیفی برای پیش در شرایط ابری و شب بهره می‌برد.

۵. پژوهش‌های داخلی عمدتاً دانشگاهی و فاقد کاربرد عملیاتی: درحالی‌که مدل شبکه عصبی - یو، روی سنتینل ۱ به‌عنوان یک ابزار عملیاتی در اروپا به کار گرفته شده است. پژوهش‌های داخلی فاقد هرگونه معماری عملیاتی برای هشدار سریع، پایش بلادرنگ یا اتصال به سامانه‌های مدیریت سیلاب کشور هستند.

۳-۳- روندها و شکاف‌های پژوهشی در ایران (با تحلیل تطبیقی و انتقادی)

پژوهش‌های داخلی عمدتاً در استان‌های گلستان، خوزستان و خراسان رضوی متمرکز شده‌اند که خود نشان‌دهنده تمرکز مخاطرات سیلاب در این مناطق و همچنین دسترسی به داده‌های هیدرومتری و میدانی در این استان‌ها است.

تحلیل تطبیقی مدل‌های داخلی: مطالعه Shirzadi et al. (۲۰۲۵) در شهر سندج، معماری جدید شبکه‌های انتزاع عمیق^۳ را معرفی کرده که با (AUC ۰/۸۱) از شبکه عصبی پیچشی (AUC ۰/۷۸) و ماشین بردار پشتیبان (AUC ۰/۷۴) بهتر عمل کرده است. هرچند این نوآوری معماری قابل توجه است، اما عملکرد آن در مقایسه با مدل شبکه عصبی بازگشتی المان در حوضه گرگانود (AUC تست ۰/۹۶۹) پایین‌تر است. این تفاوت را می‌توان به عوامل متعددی نسبت داد: (۱) پیچیدگی زمین‌شناسی و توپوگرافی متفاوت در دو منطقه (سندج با توپوگرافی شهری پیچیده در مقابل حوضه گرگانود با الگوی زهکشی منظم‌تر)، (۲) تعداد و کیفیت نقاط سیلابی مورد استفاده (۳۴۸ نقطه در سندج در مقابل ۲۳۰ نقطه در گرگانود)، و (۳) تفاوت در متغیرهای پیش‌بینی کننده (۱۹ متغیر در سندج در مقابل ۱۴ متغیر در گرگانود). این مقایسه نشان می‌دهد که عملکرد مدل‌های یکسان در مناطق مختلف یکسان نیست و ضرورت ارزیابی تعمیم‌پذیری را آشکار می‌سازد. در حوضه گرگانود، مدل شبکه عصبی پیچشی با دو ورودی همراه با شبکه تخصصی مولد با AUC تست ۰/۹۵۴ عملکرد بهتری نسبت به مدل شبکه عصبی پیچشی تک‌ورودی با AUC تست ۰/۹۳۳ داشته و حدود ۱۵/۱۷ درصد از اراضی، عمدتاً در نواحی پایین‌دست، حساسیت زیاد و خیلی زیاد به سیلاب دارند (Maddah et al., 2025b). این یافته با نتایج مطالعه Razavi-Termeh et al. (۲۰۲۵) در استهبان (AUC ۹۳/۲ درصد با شبکه عصبی بازگشتی - الگوریتم ژنتیک) همخوانی دارد و تأکید می‌کند که روش‌های بهینه‌سازی فراکاوشی و تولید داده‌های مصنوعی می‌توانند به‌طور معناداری دقت مدل‌ها را افزایش دهند.

مقایسه با نتایج جهانی: مدل‌های داخلی عمدتاً از داده‌های ایستا (مدل رقومی ارتفاع، کاربری اراضی، فاصله از رودخانه) استفاده کرده‌اند، درحالی‌که مدل‌های بین‌المللی از تصاویر پویا و لحظه‌ای رادار روزنه ترکیبی برای نقشه‌برداری گستره سیلاب بهره گرفته‌اند. این تفاوت اساسی باعث می‌شود که

1. Deep Abstract Networks

2. Digital Elevation Model (DEM)

3. Deep Abstract Networks

مدل‌های داخلی نتوانند نقشه‌های لحظه‌ای از گستره سیلاب در زمان بحران ارائه دهند؛ یک شکاف عملیاتی جدی که در نظام مدیریت بحران کشور به‌وضوح احساس می‌شود. به‌عنوان مثال، درحالی‌که مدل شبکه عصبی-یو، روی سنتینل ۱ در اروپا به‌عنوان یک ابزار عملیاتی در سامانه مدیریت اضطراری کوپرنیک به کار گرفته شده است (Silwal et al., 2026)، هیچ‌یک از مدل‌های توسعه‌یافته در ایران به‌صورت عملیاتی در سازمان‌های مدیریت بحران کشور پیاده‌سازی نشده‌اند. همچنین، در سطح بین‌المللی، مدل‌های بنیادی مانند بخش‌بندی هر چیز و پرتوی ناسا به‌سرعت در حال تبدیل شدن به استانداردهای جدید هستند، درحالی‌که در ایران هیچ مطالعه‌ای از این رویکردها استفاده نکرده است (Jakubik et al., 2023)؛ (Chamatidis et al., 2024).

نقد روش‌شناختی: از ۱۲ مطالعه داخلی بررسی شده، هیچ‌یک از اعتبارسنجی متقابل مکانی-زمانی استفاده نکرده‌اند. به‌عبارت دیگر، مدل‌ها صرفاً با تقسیم تصادفی داده‌ها به آموزش و آزمون (معمولاً ۳۰ تا ۷۰ یا ۲۰ تا ۸۰) ارزیابی شده‌اند، درحالی‌که ارزیابی واقعی یک مدل برای پیش‌بینی سیلاب در منطقه یا زمان جدید، نیازمند آزمون در حوضه‌های مجاور یا رویدادهای دیگر است. این ضعف روش‌شناختی باعث می‌شود که عملکرد گزارش شده برای مدل‌ها خوشبینانه‌تر از عملکرد واقعی آنها در عمل باشد. همچنین، هیچ مطالعه داخلی به کمی‌سازی عدم قطعیت (به‌جز یک مطالعه که از تفسیرهای افزایشی شاپلی^{۱۱} برای تفسیرپذیری استفاده کرده) نپرداخته است، درحالی‌که در سطح بین‌المللی روش‌هایی مانند حذف تصادفی مونت کارلو^{۱۲} و مجموعه‌های عمیق^{۱۳} به‌طور استاندارد برای ارزیابی قابلیت اطمینان مدل‌ها به کار می‌روند (Qin and Chen, 2024).

درس‌آموخته‌ها و جهت‌گیری آینده: برای پر کردن این شکاف‌ها، پژوهشگران ایرانی باید: (۱) به‌جای تمرکز صرف بر توسعه مدل‌های جدید، بر ارزیابی تعمیم‌پذیری مدل‌های موجود در مناطق و رویدادهای مختلف تمرکز کنند. (۲) از اعتبارسنجی متقابل مکانی-زمانی برای گزارش واقع‌بینانه‌تر از عملکرد مدل‌ها استفاده کنند. (۳) به سمت استفاده از تصاویر رادار روزانه ترکیبی و مدل‌های بنیادی با قابلیت تنظیم دقیق^{۱۴} روی داده‌های محلی حرکت کنند. (۴) همکاری با سازمان‌های مدیریت بحران (مانند سازمان مدیریت بحران کشور، وزارت نیرو و هواشناسی) را برای تبدیل پژوهش‌های دانشگاهی به ابزارهای عملیاتی در پیش بگیرند. (۵) یک دادگان ملی تصاویر ماهواره‌ای سیلاب با برچسب‌های مکانی دقیق برای استان‌های سیل‌خیز ایجاد کنند که در حال حاضر وجود ندارد.

۳-۴- مدل‌های بنیادی و آینده نقشه‌برداری سیل

در دو سال اخیر، مدل‌های بنیادی که بر روی حجم عظیم داده بدون برچسب آموزش می‌بینند، انقلابی در سنجش‌ازدور ایجاد کرده‌اند (Jakubik et al., 2023). سه گروه اصلی در حوزه سیلاب عبارت‌اند از:

الف) مدل‌های بینایی بنیادی^{۱۵}: این مدل، بدون آموزش خاص، پهنه‌های آبی را با دقت قابل‌قبول بخش‌بندی می‌کند (Kirillov et al., 2023). نسخه‌های جغرافیایی مانند مدل بخش‌بندی هر چیز جغرافیایی و پرتوی ناسای بی‌ام، بر روی داده‌های هماهنگ‌شده لندست و سنتینل ۲ آموزش‌دیده‌اند و در تشخیص تغییرات سیلاب عملکرد عالی دارند (Jakubik et al., 2023).

ب) مدل‌های زبانی بینایی بزرگ^{۱۶}: مدل‌هایی مانند GPT-4V^{۱۷} و دستیار بزرگ زبانی و بینایی^{۱۸} می‌توانند تصاویر ماهواره‌ای سیل را تحلیل کرده و گزارش توصیفی از گستره و شدت سیل تولید کنند. هرچند برای برآورد عمق دقیق مناسب نیستند، در هشدار سریع و ارتباط با عموم ارزشمندند (Jakubik et al., 2023).

ج) مدل‌های بنیادی سری زمانی: مدل‌هایی مانند مدل بنیادی سری زمانی^{۱۹} (از گوگل) و مدل پایه سری زمانی آمازون با معماری ترانسفورمر^{۲۰} (از آمازون) بر روی داده‌های جریان رودخانه‌ها از هزاران حوضه آموزش‌دیده‌اند و توانایی پیش‌بینی سیل در حوضه‌های بدون داده^{۲۱} دارند (Chamatidis et al., 2024). مطالعات تجربی نشان داده‌اند که مدل پایه سری زمانی آمازون با معماری ترانسفورمر در پیش‌بینی جریان رودخانه در افق‌های زمانی مختلف، عملکرد بهتری نسبت به مدل‌های خاص مسئله (مانند حافظه کوتاه‌مدت بلندمدت) دارد و کاهش عملکرد آن با افزایش افق پیش‌بینی، کندتر از سایر مدل‌هاست.

چالش‌ها در ایران: نیاز به زیرساخت ابری قوی (واحد پردازش گرافیکی با حافظه بالا)، نبود دادگان ملی تصاویر سیلاب و هزینه بالای رابط برنامه‌نویسی کاربردی^{۲۲} مدل‌های تجاری (مانند GPT-4V). راهکار: استفاده از مدل‌های منبع‌باز (بخش‌بندی هر چیز و پرتوی ناسا) و تمرکز بر تنظیم دقیق^{۲۳} با داده‌های محلی سیل‌های خوزستان و گلستان. شکل (۴)، پیشرفت‌های مذکور را با برجسته کردن بدهستان‌های بین تفسیرپذیری فیزیکی و

1. Copernicus Emergency Management Service (Copernicus EMS)
2. Spatial-Temporal Cross-Validation
3. Shapley Additive Explanations
4. Monte Carlo Dropout (MC Dropout)
5. Deep Ensembles
6. Fine-tuning
7. Segment Anything Model (SAM)
8. Vision language Models (VLM)

9. Generative Pre-trained Transformer 4 Vision
10. Large Language and Vision Assistant (LLaVA)
11. TimesFM (Time Series Foundation Model)
12. Chronos
13. Ungauged Basins
14. Application Programming Interface
15. Fine-tuning

انعطاف‌پذیری داده‌محور، ترکیب می‌کند و انگیزه‌ای برای گذار به سمت مدل‌های هوش مصنوعی ترکیبی، قابل توضیح و آگاه از عدم قطعیت ایجاد می‌کند.



شکل (۴): حرکت به سمت بالا نشان‌دهنده افزایش تفسیرپذیری فیزیکی معمول در مدل‌های هیدرودینامیکی مبتنی بر فرآیند است، در حالی که حرکت به سمت پایین نشان‌دهنده افزایش اتوماسیون و مقیاس‌پذیری مبتنی بر داده است. مدل‌های ترکیبی، قابل توضیح و آگاه از عدم قطعیت، انعطاف‌پذیری یادگیری عمیق را حفظ می‌کنند و در عین حال محدودیت‌های فیزیکی را برای بهبود استحکام و ارتباط تصمیم‌گیری در نظر می‌گیرند. شکل، موقعیت‌یابی مفهومی را به جای یک گردش کار متوالی نشان می‌دهد.

۴- نتیجه‌گیری و پیشنهادها

این مرور نظام‌مند نشان می‌دهد که روش‌های یادگیری ماشین و یادگیری عمیق ظرفیت بالایی برای تحول در نقشه‌برداری از سیلاب دارند. در سطح جهان، گذار از مدل‌های سنتی به معماری‌های عمیق (شبکه‌های عصبی پیچشی، حافظه کوتاه‌مدت، تبدیل‌گرها) و سپس به مدل‌های بنیادی و آگاه از فیزیک در جریان است. رویکردهای نوظهوری مانند مدل‌های بنیادی (بخش‌بندی هر چیزبخش‌بندی هر چیز، پرتوی ناسا، مدل بنیادی سری زمانی گوگل و مدل پایه سری زمانی آمازون با معماری ترانسفورمر) و شبکه‌های عصبی آگاه از فیزیک با کاهش نیاز به داده‌های آموزشی گسترده و افزایش قابلیت تعمیم‌پذیری، افق‌های تازه‌ای را در این حوزه گشوده‌اند.

در ایران، باوجود پژوهش‌های نوآورانه (مانند شبکه انتزاع عمیق، شبکه عصبی بازگشتی المان، شبکه عصبی پیچشی با دو ورودی شبکه تخصصی مولد و بهینه‌سازی فراکاوشی) که در استان‌های گلستان، خوزستان و خراسان رضوی انجام شده است، شکاف عمیقی میان خروجی‌های علمی و کاربرد عملیاتی وجود دارد. یافته‌های این مرور نشان می‌دهد که این شکاف عمدتاً ناشی از عوامل زیر است:

- تمرکز بر پهنه‌بندی حساسیت ایستا به جای نقشه‌برداری لحظه‌ای گستره سیلاب در زمان بحران؛
- استفاده از داده‌های ایستا (مدل رقومی ارتفاع، کاربری اراضی، فاصله از رودخانه) به جای تصاویر رادار روزانه ترکیبی پویا که قابلیت پایش در شب و شرایط ابری را فراهم می‌کنند؛

- غیاب کامل مدل‌های آگاه از فیزیک و مدل‌های بنیادی در پژوهش‌های داخلی؛

- عدم ارزیابی تعمیم‌پذیری مکانی-زمانی مدل‌ها (به دلیل عدم استفاده از اعتبارسنجی متقابل مکانی زمانی)

- کمبود رویکردهای تفسیرپذیری و کمی‌سازی عدم قطعیت (به جز یک مطالعه که از تفسیرهای افزایشی شاپلی استفاده کرده است)؛

- نبود چارچوب مقرراتی و استانداردهای فنی برای پذیرش عملیاتی مدل‌ها در نظام مدیریت سیلاب کشور

۴-۱- پیشنهادهای عملیاتی برای پژوهشگران و برنامه‌ریزان حوزه مدیریت سیلاب در ایران

۱. تمرکز بر تنظیم دقیق مدل‌های بنیادی موجود: به جای توسعه معماری‌های کاملاً جدید از صفر، پژوهشگران باید بر تنظیم دقیق مدل‌های بنیادی منبع‌باز مانند بخش‌بندی هر چیزبخش‌بندی هر چیز، پریوتی ناسا و مدل بنیادی سری زمانی گوگل با داده‌های محلی سیل‌های خوزستان، گلستان و خراسان رضوی متمرکز شوند. این رویکرد علاوه بر کاهش هزینه‌های محاسباتی، امکان بهره‌مندی از قابلیت تعمیم‌پذیری بالای این مدل‌ها را فراهم می‌آورد.

۲. ایجاد دادگان ملی تصاویر ماهواره‌ای سیلاب: به عنوان یک زیرساخت حیاتی، ایجاد دادگان ملی تصاویر ماهواره‌ای سیلاب با برچسب‌های مکانی دقیق و استاندارد برای استان‌های سیل‌خیز، گامی ضروری برای پیشبرد تحقیقات مبتنی بر یادگیری عمیق و ارزیابی عینی عملکرد مدل‌ها است. این دادگان باید شامل تصاویر رادار روزنه ترکیبی (سنتینل ۱) و نوری (سنتینل ۲ و لندست) در زمان وقوع سیلاب‌های تاریخی باشد.

۳. به کارگیری رویکردهای آگاه از فیزیک: با توجه به موفقیت شبکه‌های عصبی آگاه از فیزیک در برآورد عمق سیلاب با دقت بالا و کاهش نیاز به داده‌های آموزشی، توصیه می‌شود پژوهشگران ایرانی از این رویکرد برای شبیه‌سازی عمق و سرعت سیلاب در رودخانه‌ها و حوضه‌های آبریز کشور استفاده کنند.

۴. تفسیرپذیری با روش‌های هوش مصنوعی تفسیرپذیر^۱ و کمی‌سازی عدم قطعیت: برای افزایش قابلیت اعتماد و شفافیت مدل‌ها در کاربردهای عملیاتی، استفاده از روش‌های هوش مصنوعی تفسیرپذیر مانند تفسیرهای افزایشی شاپلی و توضیحات محلی تفسیرپذیر مستقل از مدل^۲ و همچنین کمی‌سازی عدم قطعیت با روش‌هایی مانند حذف تصادفی مونت کارلو و مجموعه‌های عمیق ضروری است. این کار به تصمیم‌گیرندگان مدیریت بحران کمک می‌کند تا پیش‌بینی‌های مدل را با اطمینان بیشتری به کار گیرند.

۵. توسعه همکاری‌های بین سازمانی: پژوهشگران باید با سازمان مدیریت بحران کشور، وزارت نیرو و سازمان هواشناسی همکاری نزدیک داشته باشند تا پژوهش‌های دانشگاهی به ابزارهای عملیاتی هشدار سریع و پایش بلادرنگ تبدیل شوند. ایجاد پایلوت‌های عملیاتی در یکی از استان‌های سیل‌خیز (مانند خوزستان یا گلستان) می‌تواند گام مؤثری در این مسیر باشد.

۶. تدوین چارچوب‌های مقرراتی و استانداردهای فنی

برای پذیرش گسترده مدل‌های یادگیری ماشین/یادگیری عمیق در نظام ملی مدیریت سیلاب، تدوین چارچوب‌های مقرراتی، استانداردهای ارزیابی و پروتکل‌های اعتبارسنجی توسط نهادهای متولی (مانند سازمان مدیریت بحران و وزارت نیرو) ضروری است. این چارچوب‌ها باید شامل معیارهای حداقل عملکرد، الزامات داده‌های ورودی و رویه‌های به‌روزرسانی مدل‌ها باشند.

تشکر و سپاسگزاری:

از داوران محترم به‌خاطر نظرات راهگشا و علمی که به غنای این پژوهش افزود، سپاسگزارم.

منابع

یوسفی، ح.، یونس، ح.، داودی مقدم، د.، ارشیا، آ.، و شمسی، ز. (۱۴۰۱). تعیین پتانسیل سیل با استفاده از مدل‌های یادگیری ماشین CART، GLM و GAM (مطالعه موردی: حوضه کشکان). آبیاری و آب ایران، ۱۲(۴)، ۸۴-۱۰۵.

Bashirgonbad, M., Farokhzadeh, B., and Gholami, V. (2024). Enhancing flood mapping through ensemble machine learning in the Gamasyab watershed, Western Iran. Environmental Science and Pollution Research, 31(38), 50427-50442.

Chamatidis, I., Istrati, D., and Lagaros, N. D. (2024). Vision transformer for flood detection using satellite images from Sentinel-1 and Sentinel-2. Water, 16(12), 1670.

Chen, J., Li, Y., and Zhang, S. (2023). Fast prediction of urban flooding water depth based on CNN- LSTM. Water, 15(7), 1397.

El Baida, M., Boushaba, F., Chourak, M., Hosni, M., Zahaf, T., and Sabar, H. (2024, May). A systematic literature review on regression machine learning for urban flood hazard mapping. In International Conference on Digital Technologies and Applications (pp. 42-51). Cham: Springer Nature Switzerland.

Garshasbi, M., Alizadeh, H., Mojaradi, B., Saadatpour, M., and Zarei, E. (2025). Uncertainty-Aware flood inundation mapping with a bayesian deep learning framework using SAR imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing.

Gholami, H., Mohammadifar, A., Golzari, S., Torkamandi, R., Moayedi, E., Reshkooyeh, M. Z., ... and Zeeden, C. (2025). Mapping flood risk using a workflow including deep learning and MCDM-Application to southern Iran. Urban Climate, 59, 102272.

Jakubik, J., Roy, S., Phillips, C. E., Fraccaro, P., Godwin, D., Zadrozny, B., ... and Ramachandran, R. (2023). Foundation models for generalist geospatial artificial intelligence. arXiv preprint arXiv:2310.18660.

Kaçmaz, A., and Alganci, U. (2026). SAR-Based Flood Extent Mapping with a Lightweight Siamese U-Net and Differential Attention Mechanism. Earth, 7(3), 87.

Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., ... and Girshick, R. (2023, October). Segment anything. In 2023 IEEE/CVF international conference on computer vision (ICCV) (pp. 3992-4003). IEEE.

Maddah, S., Khosravi, K., Jun, C., Bateni, S.M., Kim, D., and Liang, S. (2025a). Assessment of a family of recurrent neural network models for flood susceptibility Mapping: An explainable glass-box approach. Engineering Applications of Artificial Intelligence, 160, 111867.

1. Explainable Artificial Intelligence

2. Local Interpretable Model-agnostic Explanations (LIME)

- Maddah, S., Mojaradi, B., and Alizadeh, H. (2025b). Improving deep learning-based flood susceptibility modeling by integrating data balancing technique and dual-input convolutional neural network. *Natural Hazards*, 121(15), 17555-17577.
- Mokarram, M., and Zarei, A.R. (2026). Determining Potential Areas for Flood Inundation Using Remote Sensing and Artificial Neural Networks. *Natural Hazards Review*, 27(2), 04026006.
- Page, M.J., McKenzie, J.E., Bossuyt, P.M., Boutron, I., Hoffmann, T.C., Mulrow, C.D., ... and Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *Journal of Clinical Epidemiology*, 134, 178-189.
- Pech-May, F., Alvarez-Cárdenas, O., and Ríos-Toledo, G. (2025). Flood Mapping through Sentinel-1, Sentinel-2 Imagery and U-NET Deep Learning Model. *Computación y Sistemas*, 29(1), 393-407.
- Qi, X., de Almeida, G. A., and Maldonado, S. (2024). Physics-informed neural networks for solving flow problems modeled by the 2D Shallow Water Equations without labeled data. *Journal of Hydrology*, 636, 131263.
- Razavi-Termeh, S.V., Sadeghi-Niaraki, A., Jelokhani-Niaraki, M., and Choi, S.M. (2025). Flood susceptibility mapping using optimized deep learning models: a non-structural framework. *Applied Water Science*, 15(8), 208.
- Rezvani, H., Arfa, A., Shafizadeh-Moghadam, H., and Minaei, M. (2026). An XGBoost-SHAP framework for interpretable and probabilistic flood susceptibility mapping. *Natural Hazards*, 122(6), 225.
- Roohi, M., Ghafouri, H.R., Ashrafi, S.M., Motagh, M., and Haghshenas Haghighi, M. (2025). A hybrid approach for enhanced flood prediction and assessment: Leveraging physical models, deep learning and satellite remote sensing. *Big Earth Data*, 9(3), 439-472.
- Sardar, B., and Saheer, L. (2025). Flood detection modeling: leveraging the SEN1FLOOD11 dataset for the Rio Colima River. In *ICLR 2025 Workshop on Climate Change AI*.
- Shirzadi, A., Salvati, A., Tahan, M. H., Shahabi, H., Nodoushan, E.J., Ramezani, M., ... and Clague, J.J. (2025). Urban flood susceptibility mapping using deep and machine learning algorithms as a management tool: A case study of Sanandaj City, Iran. *Ecological Indicators*, 178, 113886.
- Silwal, A., Subedi, A., Tamrakar, R., Dahal, K., Dahal, D., Ekpeterere, K. O., and Zhuran, M. (2026). A comprehensive review of machine learning and deep learning methods for flood inundation mapping. *Earth*, 7(2), 44.
- Xu, Y., He, C., Guo, Z., Chen, Y., Sun, Y., and Dong, Y. (2023). Simulation of water level and flow of catastrophic flood based on the cnn-lstm coupling network. *Water*, 15(13), 2329.

Systematic Review of Machine Learning and Deep Learning Methods for Flood Inundation Mapping in the World and Iran

Yousef Taghi mollaei ^{*1}



Research Article

1. Researcher, Natural Resources Research Department, Fars Province Agricultural and Natural Resources Research and Education Center, Iran.

taghimollaei@yahoo.com

* Corresponding author

Article Code: 2606-1178
Countinus Pagination: 1385-1397

Received: 01 July 2026
Accepted: 07 September 2026
Online: 17 September 2026
Review speed: 69 days

Citation:

Taghi mollaei, Y. (2026). Systematic Review of Machine Learning and Deep Learning Methods for Flood Inundation Mapping in the World and Iran. *Management of Natural Ecosystems*, 6(2), 59-71.

Abstract

Accurate and timely flood inundation mapping (FIM) provides the foundation for flood management and risk reduction. In recent years, machine learning (ML) and deep learning (DL) methods, leveraging remote sensing data, have revolutionized this field. The present study was conducted to systematically review ML and DL approaches for flood mapping globally and in Iran, and to provide a framework for developing reliable models, using a systematic review methodology based on the PRISMA guidelines. A search was conducted in reputable scientific databases for articles published between 2015 and 2026, and following screening, 42 articles (30 international articles and 12 case studies from Iran) were selected for final analysis. The findings show that the methods fall into three main categories: (1) traditional ML methods such as Random Forest and Support Vector Machine, which have been primarily used for flood susceptibility zoning; (2) DL architectures including CNNs, U-Net, and LSTM, which demonstrate high accuracy in flood extent mapping from satellite imagery; and (3) hybrid and physics-informed approaches such as PINNs, which incorporate hydrodynamic equations into the loss function to generate predictions consistent with physical laws. Internationally, foundation models such as SAM and Prithvi, along with vision transformers, have shown Higher generalizability across different events. In Iran, despite innovative research (e.g., DANet and Elman RNN) in the provinces of Golestan, Khuzestan, and Khorasan Razavi, there remains a deep gap between scientific outputs and operational application. the lack of studies based on real-time SAR imagery, the absence of physics informed models, the lack of assessment of spatiotemporal generalizability, and the absence of a regulatory framework for operational adoption constitute some of the most important research gaps in the country. It is concluded that to develop operational applications in Iran, it is essential to focus on fine-tuning existing foundation models with local data, creating a national database of satellite images of floods, adopting physics-informed approaches, and incorporatinexplainability through XAI.

Key Words:

Flood Inundation Mapping, Machine Learning, Deep Learning, Foundation Models, Remote Sensing, Flood Risk Management, Iranian Case Studies. Deep Neural Networks, Foundation Models.