

(OPEN ACCESS)

Evaluation of the Capability of Physics-Aware Neural Networks in Accelerating Flood Simulation Using STE Software

Reza Teimourey¹, Amir Ahmad Dehghani^{*2}, Mahdi Meftah Halaghi³

1. Ph.D. Student in Water Sciences and Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: r.teimourey@gau.ac.ir
2. Corresponding Author, Professor, Dept. of Water Sciences and Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: a.dehghani@gau.ac.ir
2. Associate Prof., Dept. of Water Sciences and Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: mefteh@gau.ac.ir

Article Info

Article type:
Research Full Paper

Article history:
Received: 06.09.2024
Revised: 07.14.2024
Accepted: 08.05.2024

Keywords:
Physics-Aware Neural Networks,
Rapid Flood Modeling,
Shallow Water Equations,
STE Software

ABSTRACT

Background and Objectives: Floods cause significant damage to urban and rural areas. Rapid analysis and visualization of floodplains during a flood event are essential for identifying threatened areas and assessing potential damages. One of the most critical aspects of rapid flood modeling is the ability to accurately and promptly predict areas at risk. These predictions can warn authorities and residents in vulnerable areas, allowing for timely measures to reduce casualties and financial losses. During a flood, having precise and fast models helps officials make better decisions regarding rescue operations, evacuation, and resource allocation. Extensive research has been conducted on flood modeling, and numerous hydraulic, hydrological, and empirical models have been developed and reviewed. Despite numerous studies, there is still no software or model capable of rapid flood modeling during a flood event. Therefore, this research aims to develop the 2D module of the STE software to achieve accurate and rapid flood modeling using artificial intelligence methods and 2D shallow water equations.

Materials and Methods: In this study, the 2D module of the STE software was developed to evaluate the capabilities of two different architectures of Perceptron artificial neural networks, named physics-aware neural networks, in rapid flood modeling in the Eudlo Creek, located in the Sunshine Coast region of Queensland, Australia. The physics-aware neural networks were trained using a genetic algorithm. To test the trained networks and evaluate their ability for rapid flood modeling, their results were compared with those obtained from the finite difference numerical solution. The flood hydrograph used for modeling was obtained from the Australian Bureau of Meteorology for the upstream hydrometric station of the studied river.

Results: The comparison of results obtained from physics-aware neural networks (PANNs) with those from the finite difference method showed that PANNs can reduce the time required for modeling by 50 to 70 percent while maintaining significant accuracy and stability. Increasing the beta

parameter in both neural networks enhanced the modeling speed but reduced accuracy. Complex PANNs preserved higher levels of accuracy and stability, especially with larger time steps and higher beta values, resulting in less computational error and outcomes closer to the numerical solution. Increasing the beta parameter significantly increased errors while slightly reducing the modeling completion time. Hence, the optimal beta value for the study area and complex PANNs was determined to be 8. Complex PANNs also demonstrated acceptable accuracy in depicting changes in flow depth and floodplain over time, making them suitable for rapid flood modeling, floodplain mapping, identifying threatened areas, crisis management, and reducing flood damage.

Conclusion: The AI methods examined in this study demonstrated the ability to increase modeling speed and reduce the time required for flood modeling and floodplain mapping while maintaining adequate accuracy. These methods can serve as effective tools for rapid flood modeling, enabling quicker identification of flood-prone areas, timely notifications, and evacuations of at-risk regions, thereby helping to save lives and reduce financial losses.

Cite this article: Teimourey, Reza, Dehghani, Amir Ahmad, Meftah Halaghi, Mahdi. 2026. Evaluation of the Capability of Physics-Aware Neural Networks in Accelerating Flood Simulation Using STE Software. *Journal of Water and Soil Conservation*, 32 (4), 105-127.



© The Author(s).

DOI: 10.22069/jwsc.2026.22522.3734

Publisher: Gorgan University of Agricultural Sciences and Natural Resources

ارزیابی توانایی شبکه‌های عصبی آگاه از فیزیک در تسریع شبیه‌سازی سیلاب با استفاده از نرم‌افزار STE

رضا تیموری^۱، امیراحمد دهقانی^{۲*}، مهدی مفتاح هلتی^۳

۱. دانشجوی دکتری علوم و مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه: r.teimourey@gau.ac.ir
۲. نویسنده مسئول، استاد گروه علوم و مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه: a.dehghani@gau.ac.ir
۳. دانشیار گروه علوم و مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه: meftah@gau.ac.ir

اطلاعات مقاله	چکیده
<p>نوع مقاله: مقاله کامل علمی- پژوهشی</p> <p>تاریخ دریافت: ۱۴۰۳/۰۳/۲۰ تاریخ ویرایش: ۱۴۰۳/۰۴/۲۴ تاریخ پذیرش: ۱۴۰۳/۰۵/۱۵</p> <p>واژه‌های کلیدی: دسته معادلات آب کم‌عمق، شبکه‌های عصبی آگاه از فیزیک، مدل‌سازی سریع سیلاب، نرم‌افزار STE</p>	<p>سابقه و هدف: وقوع سیل موجب خسارات قابل توجهی به مناطق شهری و روستایی می‌شود. تحلیل سریع و مشاهده پهنه سیلاب در زمان وقوع سیل برای شناسایی مناطق مورد تهدید و ارزیابی خسارات احتمالی، ضروری است. یکی از مهم‌ترین ضرورت‌های مدل‌سازی سریع سیلاب، امکان پیش‌بینی دقیق و به موقع نقاط مورد تهدید سیلاب است. این پیش‌بینی‌ها می‌توانند به مقامات مسئول و ساکنان مناطق در معرض خطر هشدار دهند تا اقدامات لازم برای کاهش خسارات جانی و مالی انجام شود. در زمان وقوع سیلاب، داشتن مدل‌های دقیق و سریع به مسئولان کمک می‌کند تا تصمیمات بهتری در زمینه امداد و نجات، تخلیه مناطق و تخصیص منابع اتخاذ کنند. برای مدل‌سازی سیل پژوهش‌های گسترده‌ای انجام شده و مدل‌های هیدرولیکی، هیدرولوژیکی و تجربی زیادی ارائه و مورد بررسی قرار گرفته است. برخلاف انجام پژوهش‌های متعدد هنوز نرم‌افزار و مدلی که بتواند در زمان وقوع سیل، پهنه‌بندی سریع سیلاب را انجام دهد وجود ندارد، بنابراین در این پژوهش اقدام به کدنویسی و توسعه بخش دوبعدی نرم‌افزار STE به منظور مدل‌سازی دقیق و سریع سیلاب با استفاده از روش‌های هوش مصنوعی و معادلات دوبعدی آب کم‌عمق شده است.</p> <p>مواد و روش‌ها: در این پژوهش با توسعه بخش دوبعدی نرم‌افزار STE اقدام به ارزیابی توانایی دو ساختار متفاوت از شبکه‌های عصبی مصنوعی پرسپترون با نام شبکه‌های عصبی آگاه از فیزیک، در مدل‌سازی سریع سیلاب در رودخانه ایودلو کریک، در منطقه سانشاین کوست، کوئینزلند، کشور استرالیا شده است. در این پژوهش، تعلیم شبکه‌های عصبی آگاه از فیزیک با استفاده از الگوریتم هوشمند ژنتیک انجام گرفته و به منظور آزمون شبکه‌های تعلیم یافته و ارزیابی توانایی آن‌ها در مدل‌سازی سریع سیلاب به مقایسه نتایج با روش حل عددی</p>

تفاضل‌های محدود پرداخته شده است. برای انجام مدل‌سازی‌ها از هیدروگراف سیل دریافت شده از سایت هواشناسی کشور استرالیا برای ایستگاه هیدرومتری بالادست رودخانه مورد مطالعه استفاده شده است.

یافته‌ها: مقایسه نتایج به دست آمده از شبکه‌های عصبی آگاه از فیزیک با نتایج روش تفاضل‌های محدود نشان داد، شبکه‌های عصبی آگاه از فیزیک قادر هستند ۵۰ تا ۷۰ درصد زمان لازم جهت اتمام مدل‌سازی را با حفظ میزان قابل‌توجهی از دقت و پایداری آن کاهش دهند. افزایش ضریب بتا در هر دو شبکه عصبی باعث افزایش سرعت مدل‌سازی در مقابل کاهش دقت آن شده است. شبکه‌های عصبی آگاه از فیزیک پیچیده قادر به حفظ میزان بیشتری از دقت و پایداری مدل‌سازی به خصوص در گام‌های زمانی بزرگ‌تر و ضریب بتا بیشتر هستند و ضمن کاهش زمان لازم جهت اتمام مدل‌سازی، خطای کم‌تری وارد محاسبات کرده و نتایج را نزدیک‌تر به حل عددی ارائه می‌دهند. افزایش ضریب بتا خطای قابل‌توجهی را در مقابل کاهش اندک زمان اتمام مدل‌سازی به همراه خواهد داشت که بر این اساس می‌توان نتیجه گرفت ضریب بهینه بتا برای منطقه مورد مطالعه و شبکه‌های عصبی آگاه از فیزیک پیچیده مقدار ۸ هست. شبکه‌های عصبی آگاه از فیزیک پیچیده در ارائه نحوه تغییرات عمق جریان و پهنه سیلابی در طول زمان نیز با دقت قابل‌قبولی عمل کرده و برای مدل‌سازی سریع سیلاب، مشخص‌سازی پهنه سیلاب و مناطق مورد تهدید، مدیریت بحران و کاهش خسارات سیل مناسب است.

نتیجه‌گیری: روش‌های هوش مصنوعی مورد بررسی در این پژوهش، ضمن افزایش سرعت مدل‌سازی و کاهش زمان لازم جهت اتمام مدل‌سازی و پهنه‌بندی سیل از دقت مناسبی برخوردار بوده و می‌تواند ابزار مناسبی برای مدل‌سازی سریع سیلاب باشد که استفاده از این شبکه‌ها به مشخص‌سازی سریع‌تر مناطق مورد تهدید سیل، اطلاع‌رسانی و تخلیه به موقع مناطق در معرض خطر و کاهش خسارات جانی و مالی کمک خواهد کرد.

استناد: تیموری، رضا، دهقانی، امیراحمد، مفتاح هلقی، مهدی (۱۴۰۴). ارزیابی توانایی شبکه‌های عصبی آگاه از فیزیک در تسریع شبیه‌سازی سیلاب با استفاده از نرم‌افزار STE. پژوهش‌های حفاظت آب و خاک، ۳۲ (۴)، ۱۲۷-۱۰۵.

DOI: 10.22069/jwsc.2026.22522.3734



© نویسندگان.

ناشر: دانشگاه علوم کشاورزی و منابع طبیعی گرگان

مقدمه

مدل‌سازی و پهنه‌بندی سریع سیل یکی از مهم‌ترین ابزارهای مدیریت ریسک و کاهش خسارات ناشی از بلایای طبیعی است. سیلاب‌ها می‌توانند تأثیرات مخربی بر زیرساخت‌ها، محیط‌زیست و جوامع انسانی داشته باشند. با توجه به تغییرات اقلیمی و افزایش فراوانی و شدت رویدادهای سیلابی، اهمیت مدل‌سازی دقیق و سریع این پدیده‌ها بیش‌ازپیش نمایان شده است. مدل‌سازی سریع سیلاب موجب شناسایی سریع مناطق آسیب‌پذیر و مورد تهدید شده و این اطلاعات برای برنامه‌ریزی‌های شهری، تصمیم‌گیری‌ها در زمان بحران، طراحی زیرساخت‌های مقاوم و اتخاذ تدابیر پیشگیرانه بسیار حیاتی است. از سوی دیگر، پهنه‌بندی سیل به شناسایی مناطقی کمک می‌کند که در معرض خطر بیش‌تری قرار دارند و نیازمند توجه ویژه‌ای هستند. فناوری‌های پیشرفته مانند تصاویر ماهواره‌ای، داده‌های حس‌گرهای هوشمند و روش‌های هوش مصنوعی امروزه امکان پیش‌بینی و ارزیابی سریع سیلاب‌ها را فراهم کرده‌اند. این فناوری‌ها به مدیریت بحران، تخلیه به‌موقع مناطق در معرض خطر و کاهش خسارات جانی و مالی کمک می‌کنند. بنابراین، توسعه و به‌کارگیری مدل‌های پیشرفته برای مدل‌سازی و پهنه‌بندی سریع سیلاب نه‌تنها یک نیاز فنی بلکه یک ضرورت اجتماعی و زیست‌محیطی است. با این رویکرد، می‌توان از توانایی‌های علمی و فناوری برای حفظ ایمنی و رفاه جوامع و حفاظت از محیط‌زیست بهره‌مند شد. در زمان وقوع سیل مشکلات و سؤالات متعددی مطرح خواهند شد که نیاز به رسیدگی سریع، به‌موقع و مؤثر خواهند داشت و اگر زمان از دست برود خسارات حداکثر شده و مشکلات بی‌نهایت خواهند شد. برای پاسخگویی و رسیدگی به‌موقع به مشکلات، سؤالات و چالش‌های زمان وقوع بحران سیل نیاز به آگاهی از

شرایط دقیق پیشرو اعم از شدت آب‌گرفتگی، ناحیه مورد تهدید، پهنه سیلاب، عمق و سرعت جریان آب، ساختمان‌ها، جاده‌ها، پل‌ها و مناطق مسکونی و مورد تهدید و هم‌چنین همه نقاط بحرانی برای عبور سیلاب است که با مدل‌سازی سریع سیلاب می‌شود به این مهم رسیده و از آنچه پیش رو است آگاهی داشت تا اقدامات لازم خیلی سریع‌تر و به‌موقع انجام شود. برای این منظور مطالعات گسترده‌ای انجام شده و مدل‌های هیدرولیکی، هیدرولوژیکی و تجربی زیادی ارائه و مورد بررسی قرار گرفته است. مدل‌ها و روش‌های موجود جهت مشخص‌سازی پهنه سیلاب اغلب هیدرولیکی بوده که بار محاسباتی سنگینی داشته و زمان زیادی را صرف محاسبات می‌کنند و یا هیدرولوژیکی یا تجربی بوده که از دقت و بعضاً سرعت مطلوبی برخوردار نبوده و نمی‌توانند پهنه سیل گرفتگی را با دقت و در زمان مناسب ارائه دهند.

نیل و همکاران (۲۰۱۱) اقدام به مقایسه حل عددی سه دسته معادلات دوبعدی: آب کم‌عمق (دینامیک کامل)، آب کم‌عمق (تقریب اینرسی محلی) و موج دیفیوژن در حالت صریح پرداخته‌اند. در این پژوهش برای مقایسه بهتر هر سه مدل اقدام به کدنویسی هر سه مدل در یک محیط برنامه‌نویسی شده است. نتایج این پژوهش نشان داد که مدل موج دیفیوژن زمان بسیار بیش‌تری را برای اتمام مدل‌سازی نیاز دارد درحالی‌که مدل تقریب اینرسی محلی سریع‌ترین مدل در این پژوهش بوده است. برای جریان‌هایی که در راستای زمان، تدریجی تغییر می‌کنند حل معادلات دینامیک کامل ضروری نبوده و معادلات ساده‌شده قادر به مدل‌سازی دقیق جریان فوق بحرانی نبوده‌اند (۱).

دی آلمیدا و بیتس (۲۰۱۳) به مقایسه نتایج دسته معادلات آب کم‌عمق با تقریب اینرسی محلی با حل تحلیلی معادلات آب کم‌عمق (دینامیک کامل) در

مدل‌های آزمایشگاهی موردبررسی پژوهش پرداخته‌اند. نتایج این پژوهش نشان داده است توافق خوبی بین نتایج به‌دست‌آمده از معادلات ساده‌شده با نتایج معادلات دینامیک کامل به‌خصوص در جریان‌های زیربحرانی و مقادیر عدد فرود کم‌تر از ۰/۵ وجود دارد (۲).

تاناکا و توشیوکا (۲۰۱۷) به بررسی پایداری حل عددی دسته معادلات آب کم‌عمق با تقریب اینرسی محلی پرداخته‌اند. در این پژوهش شرایط پایداری حل عددی معادلات آب کم‌عمق در حالت نیمه‌ضمنی موردبررسی قرار گرفته و حالت ضمنی حل عددی این معادلات ارائه و برتری‌های آن موردبحث و بررسی قرار گرفته است (۳).

جمالی و همکاران (۲۰۲۱) به‌منظور کاهش زمان لازم جهت مدل‌سازی سیلاب، اقدام به بررسی روش‌های مختلف یادگیری ماشین کرده‌اند. در این پژوهش حل عددی دسته معادلات آب کم‌عمق در حالت تقریب محلی اینرسی مورداستفاده قرار گرفته است و از روش‌های یادگیری ماشین برای جایگزینی بخشی از معادلات روش تفاضل محدود استفاده شده است. یکی از روش‌های مورداستفاده در این پژوهش شبکه‌های عصبی مصنوعی بوده است. در این پژوهش استفاده از شبکه‌های عصبی مصنوعی با ساختار معمولی نشان داد این شبکه‌ها با ساختار معمولی قادر به مدل‌سازی گسترش سیل و سرعت بخشیدن به مدل‌سازی نمی‌باشند. هم‌چنین نتایج این پژوهش نشان داده است استفاده از دیگر روش‌های یادگیری ماشین می‌تواند زمان لازم جهت مدل‌سازی سیلاب را کاهش دهد (۴).

کیان و همکاران (۲۰۱۹) با استفاده از روش‌های یادگیری عمیق شبکه‌های عصبی مصنوعی با تکیه بر فیزیک مسأله به تخمین سریع گسترش سیلاب در منطقه شهری توسط دسته معادلات آب کم‌عمق

پرداختند. هدف از انجام این پژوهش رسیدن به یک روش سریع دوبعدی براساس قوانین فیزیک برای شبیه‌سازی سیل در مناطق شهری بوده و نتایج نشان داده است که این شبکه‌ها قادرند دقت بالایی را در تخمین گسترش سیلاب ارائه دهند (۵).

ماهش و همکاران (۲۰۲۲) به‌منظور افزایش دقت شبکه‌های عصبی مصنوعی اقدام به تعلیم فیزیک به این شبکه‌ها به‌منظور پیش‌بینی سیل در مقیاس مکانی زمانی براساس معادلات سنت و نانت کرده‌اند. در این پژوهش تعلیم شبکه‌های عصبی فیزیک آموخته با استفاده از نتایج حل عددی دسته معادلات سنت و نانت انجام‌شده و نتایج نشان داده است دقت شبکه‌های عصبی مصنوعی فیزیک آموخته بیش‌تر از شبکه‌های عصبی مصنوعی معمولی بوده و برای تخمین عمق آب مناسب هستند (۶).

نظری و همکاران (۲۰۲۲) به بررسی کارایی شبکه‌های عصبی مصنوعی فیزیک آموخته در یک محیط شبیه‌سازی‌شده توسط دسته معادلات سنت و نانت برای مدل‌سازی جریان آب در رودخانه پرداختند. هدف از انجام پژوهش ایجاد مدلی مناسب با دقت بالا و مطمئن به‌منظور استفاده به‌صورت پیش‌بینی در زمان واقعی بوده است. این پژوهش نتایج امیدوارکننده‌ای را برای این نوع مدل‌سازی نشان داد و جایگزین‌هایی را برای حل چالش‌های اصلی موجود در روش‌های استفاده‌شده ارائه کرد (۷).

جونگ و همکاران (۲۰۲۳) به بررسی دقت شبکه‌های عصبی فیزیک آموخته برای حل دسته معادلات آب کم‌عمق یک‌بعدی پرداختند. نتایج این پژوهش نشان داد شبکه‌های عصبی فیزیک آموخته از دقت بسیار بالایی در مقایسه با حل تحلیلی برخوردار هستند و این شبکه‌ها بسیار قوی‌تر از شبکه‌های عصبی معمولی عمل می‌کنند (۸).

کم عمق را توصیف می‌کند. در حالت دوبعدی این معادلات به صورت روابط ۱ تا ۳ می‌باشند.

$$\frac{\partial h}{\partial t} + \frac{\partial q_x}{\partial x} + \frac{\partial q_y}{\partial y} = 0 \quad (1)$$

$$\frac{\partial q_x}{\partial t} + \frac{\partial(uq_x)}{\partial x} + \frac{\partial(vq_y)}{\partial y} + gh \frac{\partial(h+z)}{\partial x} + \quad (2)$$

$$\frac{gn^2 \|q\| q_x}{h^{7/3}} = 0$$

$$\frac{\partial q_y}{\partial t} + \frac{\partial(vq_y)}{\partial y} + \frac{\partial(uq_x)}{\partial x} + gh \frac{\partial(h+z)}{\partial y} + \quad (3)$$

$$\frac{gn^2 \|q\| q_y}{h^{7/3}} = 0$$

که در روابط ۱ تا ۳، t زمان برحسب ثانیه، h عمق آب برحسب متر، q_x دبی جریان در واحد عرض در جهت x ، q_y دبی جریان در واحد عرض در جهت y ، $\|q\|$ برآیند دو بردار q_x و q_y (تمامی مقادیر مربوط به دبی جریان بر حسب مترمربع بر ثانیه هستند) و u سرعت جریان در جهت x ، v سرعت جریان در جهت y بر حسب متر بر ثانیه، Z تراز کف بر حسب متر، g شتاب گرانش زمین برحسب متر بر مجذور ثانیه و n ضریب زبری مانینگ می‌باشد.

کلید ساده‌سازی این معادلات به صورت تقریب اینرسی محلی براساس فرض ناچیز بودن ترم شتاب انتقالی نسبت به ترم‌های دیگر در دو رابطه ۲ و ۳ می‌باشد. بنابراین از ترم مذکور در جریان‌های زیربحرانی می‌توان چشم‌پوشی کرده و معادلات ساده‌سازی شده با نام تقریب اینرسی محلی را به صورت روابط ۴ تا ۶ نوشت (۲).

$$\frac{\partial h}{\partial t} + \frac{\partial q_x}{\partial x} + \frac{\partial q_y}{\partial y} = 0 \quad (4)$$

$$\frac{\partial q_x}{\partial t} + gh \frac{\partial(h+z)}{\partial x} + \frac{gn^2 \|q\| q_x}{h^{7/3}} = 0 \quad (5)$$

$$\frac{\partial q_y}{\partial t} + gh \frac{\partial(h+z)}{\partial y} + \frac{gn^2 \|q\| q_y}{h^{7/3}} = 0 \quad (6)$$


بررسی سوابق پژوهش نشان می‌دهد برخلاف انجام پژوهش‌های متعدد در رودخانه‌های مختلف با استفاده از روش‌های تجربی، هیدرولیکی و هوشمند هنوز نرم‌افزار و مدلی که بتواند در زمان وقوع سیل با دقت بالا و سرعت مناسب، جهت پهنه‌بندی سریع سیلاب و هشدار خسارات و آسیب‌های احتمالی پیشرو، محاسبات و مدل‌سازی‌های لازم را با استفاده از داده‌های موجود و شرایط جوی پیش‌بینی شده انجام داده و به مراجع ذی‌ربط در مدیریت بحران و نجات جان و مال مردم کمک کند وجود نداشته و با توجه به افزایش شدت تغییرات آب‌هوایی در دهه‌های اخیر نیاز به چنین نرم‌افزار و فناوری، بیش‌ازپیش احساس می‌شود. بنابراین در این پژوهش اقدام به کدنویسی و توسعه بخش دوبعدی نرم‌افزار STE به منظور مدل‌سازی دقیق و سریع سیلاب با استفاده از روش‌های هوش مصنوعی و معادلات دوبعدی آب کم‌عمق شده است.

مواد و روش‌ها

به منظور مدل‌سازی جریان آب سطحی به صورت دوبعدی معادلاتی که مورد بررسی قرار می‌گیرند با در نظر گرفتن فرضیاتی مستخرج از معادلات ناوی استوکس هستند و با نام دسته معادلات آب کم‌عمق شناخته شده‌اند که مجموعه‌ای از معادلات دیفرانسیل هذلولوی با مشتقات جزئی (یا سهموی در صورت در نظر گرفتن تنش برشی لزج) است که جریان تحت فشار در یک سیال را توصیف می‌کند. این معادلات از معادلات ناوی-استوکس انتگرال‌گیری شده در عمق، در شرایطی که مقیاس افقی بسیار بزرگ‌تر از مقیاس عمودی باشد، استخراج شده‌اند. معادله اصلی مورد استفاده در این پژوهش مجموعه‌ای از معادلات دیفرانسیل استخراج شده از معادلات آب کم‌عمق دوبعدی است که بقای جرم و مومنتوم جریان آب

انجام شود. در این حالت سلول‌هایی مستطیل شکل با فواصل Δx و Δy از هم که مقدار عمق آب در وسط سطح سلول و مقدار دبی در واحد عرض در اضلاع سلول محاسبه خواهند شد.

حل عددی دسته معادلات آب کم‌عمق با تقریب اینرسی محلی به روش تفاضل محدود^۱: برای حل معادلات مورد بررسی در این پژوهش لازم است تا شبکه‌بندی زیر بازه‌ها و گره‌های حل مطابق شکل ۱



شکل ۱- طرح شبکه‌بندی استفاده شده در حل عددی و شبکه‌های عصبی آگاه از فیزیک مورد بررسی.

Figure 1. The staggered grid used in the numerical scheme and PANN models.

رابطه ۵ و یا ۶، جایگذاری و حل برای رابطه ۵ مقدار $q_{ij+1/2}^{t+\Delta t}$ مطابق روابط ۸ تا ۱۴ قابل محاسبه است.

$$q_{ij+1/2}^{t+\Delta t} = \frac{T1+T2}{T3} \quad (8)$$

$$T1 = \theta q_{ij+1/2}^t + (1 - \theta) \frac{q_{ij-1/2}^t + q_{ij-3/2}^t}{2} \quad (9)$$

$$T2 = \quad (10)$$

$$gh_f \Delta t S$$

$$(11)$$

$$T3 = 1 + g \Delta t n^2 \left\| q_{ij+1/2}^t \right\| / h_f^{7/3}$$

$$h_f = \max(h_{ij}^t + z_{ij}, h_{ij+1}^t + \quad (12)$$

$$z_{ij+1}) -$$

$$\max(z_{ij}, z_{ij+1})$$

$$S = \frac{(h_{ij}^t + z_{ij}) - (h_{ij+1}^t + z_{ij+1})}{\Delta x} \quad (13)$$

یکی از مهم‌ترین مراحل برای حل دسته معادلات آب کم‌عمق به روش تفاضل‌های محدود حل معادله پیوستگی دوبعدی (رابطه ۸) است که با استفاده از این معادله مقدار عمق آب در زمان بعدی مطابق رابطه ۷ به دست خواهد آمد.

$$h_{ij}^{t+\Delta t} = h_{ij}^t + \left(\frac{q_{i+1/2, j}^{t+\Delta t} - q_{i-1/2, j}^{t+\Delta t}}{\Delta y} + \frac{q_{i, j+1/2}^{t+\Delta t} - q_{i, j-1/2}^{t+\Delta t}}{\Delta x} \right) \Delta t \quad (V)$$

که در این رابطه، t اندیس زمان، i اندیس مکان در جهت y ، j اندیس مکان در جهت x ، h عمق آب، q دبی در واحد عرض و Δt گام زمانی می‌باشد.

معادلات مومنتوم آب کم‌عمق با تقریب اینرسی محلی به سه حالت صریح، نیمه ضمنی و ضمنی قابل حل است که در این پژوهش از حالت نیمه ضمنی آن به دلیل پایداری بیش‌تر در حل و استفاده از پارامتر برآیند برداری دبی جریان که به تعلیم بهتر شبکه‌های عصبی کمک خواهد کرد استفاده شده است. با در نظر

گرفتن مقدار $\frac{gn^2 \left\| q_{ij+1/2}^t \right\| \left\| q_{ij+1/2}^{t+\Delta t} \right\|}{h_f^{7/3}}$ برای ترم اصطکاکی

1- Finite Difference (FD)

(رابطه ۱۵)، مدل‌سازی با سلول‌های محاسباتی کوچک، گام زمانی محاسباتی کوچک‌تری نیاز دارد. بنابراین زمان لازم برای اتمام مدل‌سازی بسیار طولانی است. یکی از راه‌های تسریع مدل‌سازی سیلاب با استفاده از این دسته معادلات، افزایش گام زمانی می‌باشد. با توجه به رابطه ۷ در صورتی که مقدار حجم آب خروجی از سلول بیش‌تر از مقدار حجم آب موجود در سلول به علاوه حجم آب ورودی به سلول محاسبه شود، خطای محاسباتی وارد شده و اصطلاحاً حجم گم‌شده یا حجم اضافه وارد مدل‌سازی می‌شود که به‌وجود آمدن این خطا در حل عددی ناشی از بزرگ بودن مقدار گام زمانی بوده و در صورت افزایش میزان این خطا محاسبات ناپایدار خواهد شد. در این پژوهش به‌منظور افزایش گام زمانی بدون ایجاد ناپایداری در حل و خطای محاسباتی از شبکه‌های عصبی مصنوعی پرسپترون با نام شبکه‌های عصبی آگاه از فیزیک به جای حل عددی معادلات مونتوم آب کم‌عمق استفاده شده است. این شبکه‌ها با دریافت مقادیر T_1, T_2, T_3 و گام زمانی مطلوب مقدار $q_{ij+\frac{1}{2}}^{t+\Delta t}$ یا $q_{i+\frac{1}{2}j}^{t+\Delta t}$ را مطابق با گام زمانی خواسته شده محاسبه کرده و از ایجاد ناپایداری و خطای محاسباتی جلوگیری می‌کنند. با توجه به نتایج به‌دست آمده از پژوهش انجام گرفته توسط جمالی و همکاران (۲۰۲۱)، شبکه‌های عصبی مصنوعی چندلایه با ساختار معمولی موفق به تسریع مدل‌سازی سیل نمی‌شوند، بنابراین در این پژوهش دو نوع شبکه عصبی آگاه از فیزیک با ساختار و معماری متفاوت مورد بررسی قرار گرفته است (۴).

۱- شبکه عصبی آگاه از فیزیک ساده: این شبکه عصبی از یک لایه عصبی و یک لایه فیزیکی تشکیل شده است که وظیفه لایه عصبی کنترل مقدار دبی

$$\|q_{ij+\frac{1}{2}}^t\| = \sqrt{\left(q_{ij+\frac{1}{2}}^t\right)^2 + \frac{\left(q_{i+\frac{1}{2}j}^t + q_{i-\frac{1}{2}j}^t + q_{i+\frac{1}{2}j+1}^t + q_{i-\frac{1}{2}j+1}^t\right)}{4}} \quad (14)$$

که در این روابط، S شیب سطح آب، h_f عمق آب موثر در ضلع سلول، θ ضریب مشخص کننده وزن جریان‌های بالادستی و پایین دستی (در این پژوهش مطابق توصیه دی‌آلمیدا و بیتس از مقدار ۰/۹ استفاده شده است) (۲) و $\|q_{ij+\frac{1}{2}}^t\|$ برآیند برداری دبی جریان در سلول $i, j + \frac{1}{2}$ می‌باشد.

شرط پایداری حل عددی طبق استاندارد کورانت-فردریشز-له‌وی^۱ برای گام زمانی محاسبات برابر رابطه ۱۵ می‌باشد.


$$\Delta t_{FD} \leq \alpha \frac{\min(\Delta x, \Delta y)}{\sqrt{g \times h_{max}}} \quad (15)$$

که در این رابطه، Δt_{FD} گام زمانی روش تفاضل محدود، h_{max} عمق حداکثر جریان در دامنه حل و α یک ضریب تنظیم برای شرط پایداری است که در این پژوهش مطابق توصیه دی‌آلمیدا و بیتس از مقدار ۰/۷ استفاده شده است (۲).

تسریع مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی: در حل عددی معادله آب کم‌عمق با تقریب اینرسی محلی به روش تفاضل محدود، مقدار گام زمانی و تعداد سلول‌های موجود در دامنه حل از مؤثرترین موارد در تعیین زمان لازم جهت اتمام مدل‌سازی و مشخص سازی پهنه سیلابی می‌باشند. تعداد سلول‌های موجود در دامنه حل تابع دقت مکانی و اندازه دامنه مدل‌سازی است. به منظور مدل‌سازی سیل در دقیق‌ترین حالت ممکن لازم است تا اندازه سلول‌های شبکه برابر با سلول‌های فایل رستری نقشه توپوگرافی منطقه باشد. در این حالت با توجه به شرایط پایداری حل عددی دسته معادلات آب کم‌عمق

هیدرولیکی، هندسی و گام زمانی می‌باشد.

جریان محاسبه شده برای زمان بعدی توسط حل عددی معادلات مومنتوم (رابطه ۸) با توجه به شرایط




شکل ۲- ساختار شبکه عصبی آگاه از فیزیک ساده.

Figure 2. The architecture of Simple Physics-Aware Neural Networks.

خروجی از لایه فیزیکی را داشته و دیگری وظیفه اصلاح خروجی و جلوگیری از افزایش و یا کاهش بیش از حد دبی جریان در شرایط مختلف را دارد.

۲- شبکه عصبی آگاه از فیزیک پیچیده^۱: این شبکه عصبی از دو لایه عصبی و یک لایه فیزیکی تشکیل شده است که یک لایه عصبی وظیفه کنترل مقدار



شکل ۳- ساختار شبکه عصبی آگاه از فیزیک پیچیده.

Figure 3. The architecture of Complex Physics-Aware Neural Networks.

با توزیع یکنواخت انتخاب می‌شوند، دبی جریان خروجی از سلول با توجه به گام زمانی مطلوب به صورت ضربی از گام زمانی روش تفاضل محدود مطابق روابط ۱۶ و ۱۷ محاسبه و به همراه ورودی‌های شبکه آماده فرآیند تعلیم شوند.

تعلیم شبکه‌های عصبی مصنوعی آگاه از فیزیک: برای تعلیم این شبکه‌ها لازم است تا یک بار منطقه مورد مطالعه توسط روش تفاضل محدود برای بخشی و یا کل یک هیدروگراف ورودی مدل‌سازی شود سپس با استفاده از نتایج بدست آمده به تعداد داده‌های آموزش در نقاط مکانی و زمانی که به صورت تصادفی

$$\Delta t_{PANN} = \beta \times \Delta t_{FD} \quad (16)$$

1- Complex Physics-Aware Neural Network (CPANN)

شده و نتایج به دست آمده با نتایج بدست آمده از حل عددی مورد مقایسه و ارزیابی قرار گرفته است.

نرم‌افزار توسعه یافته STE² و افزونه STEGIS:

بخش یک بعدی نرم‌افزار برآورد گر بار رسوبی در رودخانه‌ها توسط تیموری و دهقانی (۲۰۲۰) توسعه داده شد (۹ و ۱۰). این نرم‌افزار روش‌های مختلف برآورد بار رسوب اعم از ۹۲ روش هیدرولیکی، روش‌های مختلف هیدرولوژیکی و روش‌های هوشمند جهت برآورد باربستر، معلق و بار کل مطالعه و کد نویسی شده است. در این نرم‌افزار روش‌های مختلف محاسبه سرعت سقوط ذرات، تنش برشی، آستانه حرکت ذرات و دیگر پارامترهای هیدرولیکی در دسترس و قابل استفاده هستند و هم‌چنین روش‌های مختلف و مؤثری جهت بهینه‌سازی، هوشمندسازی، کالیبراسیون و افزایش دقت در برآورد بار رسوبی توسعه داده شده است.

با توجه به این‌که اخیراً پردازش‌گرها و سامانه اطلاعات جغرافیایی پیشرفت خوبی داشته و می‌توانند امکانات منحصر به فردی را در محاسبه، مدل‌سازی و جانمایی پهنه‌های سیلابی، هیدرولیک جریان، تحلیل‌های هیدرولوژیکی و برآورد رسوب ارائه دهند، به همین منظور در این پژوهش اقدام به توسعه و کدنویسی بخش دوبعدی نرم‌افزار STE با نام افزونه STEGIS شده است که وظیفه تحلیل‌های جغرافیایی و انجام تمامی عملیات جی آی اسی و محاسبات دو بعدی را بر عهده گرفته و نتایج را ارائه و تحلیل کند. در توسعه این افزونه سعی شده است تا تمامی ابزارهای مورد نیاز کاربر به گونه‌ای کدنویسی و در افزونه قرار گیرد تا کاربر در زمان انجام مدل‌سازی‌ها و تحلیل‌های هیدرولیکی، هیدرولوژیکی و غیره نیازی به نرم‌افزارهای متفرقه مانند QGIS، Arcmap، HEC-RAS،

$$q_{i+\frac{1}{2}}^{t+\Delta t_{PANN}} = \frac{\sum_{t=1}^{\beta} q_{i+\frac{1}{2}}^{t+\Delta t_{FD}}}{\beta} \quad (17)$$

که در این روابط، Δt_{PANN} گام زمانی خواسته شده از شبکه‌های عصبی آگاه از فیزیک، Δt_{FD} گام زمانی روش تفاضل محدود، $q_{i+\frac{1}{2}}^{t+\Delta t_{PANN}}$ مقدار دبی جریان اصلاح شده برای زمان بعدی با توجه به گام زمانی مطلوب، β ضریب گام زمانی روش تفاضل محدود و $q_{i+\frac{1}{2}}^{t+\Delta t_{FD}}$ دبی جریان محاسبه شده توسط روش تفاضل محدود برای زمان بعدی مطابق با گام زمانی روش تفاضل محدود می‌باشد.

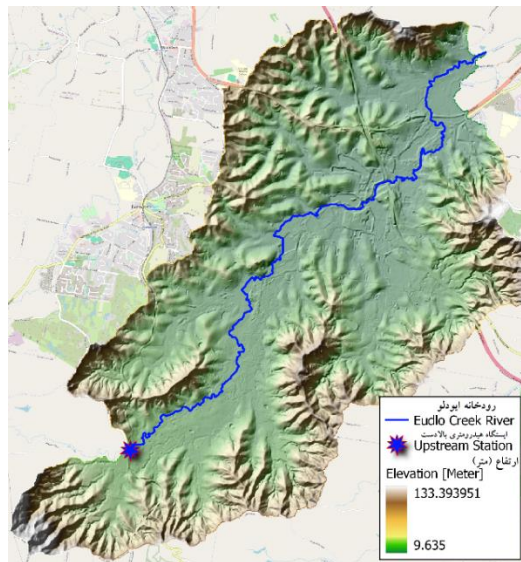
در این پژوهش تعلیم شبکه‌ها با استفاده از الگوریتم هوشمند ژنتیک کدنویسی شده در نرم‌افزار STE انجام شده است. سعی و خطا در تعلیم شبکه‌های عصبی آگاه از فیزیک نشان داده است، این شبکه‌ها به شدت حساس به بیش‌برازش بوده و با افزایش تعداد نورون‌ها و یا لایه‌های شبکه دچار بیش‌برازش شده و در زمان مدل‌سازی دچار ناپایداری در مدل‌سازی سیل خواهند شد. بنابراین مطابق شکل‌های ۲ و ۳ آرایش شبکه‌های عصبی مورد استفاده ۱-۲-۴ بوده است و به منظور جلوگیری از بیش‌برازش از روش رگولاریزاسیون^۱ L2 استفاده شده است.

در این پژوهش به منظور بررسی توانایی شبکه‌های عصبی آگاه از فیزیک در مدل‌سازی سریع سیلاب اقدام به تعلیم یک شبکه عصبی مجزا برای هر ضریب بتا (β) برابر ۴، ۶، ۸ و ۱۰ با استفاده از داده‌های به دست آمده از مدل‌سازی هیدروگراف ثابت با عمق جریان ۲/۵ متر به مدت ۱۰۰۰ دقیقه (سیلاب با دوره بازگشت ۱۰۰ ساله) شده است و سپس اقدام به آزمون شبکه‌ها و مدل‌سازی هیدروگراف سیل سال ۲۰۲۲ (شکل ۶)

کریک^۱ در منطقه سانشاین‌کوست^۲، کوئینزلند^۳ کشور استرالیا انتخاب شده است که از اهمیت بسیار بالایی برای مدل‌سازی سریع سیلاب و مشخص‌سازی مناطق مورد تهدید به دلیل وجود مناطق مسکونی، جمعیت بالا و متراکم در این منطقه برخوردار است. این رودخانه از کنار شهر روستایی پالم‌وودز^۴ می‌گذرد و پس از عبور از شهر سانشاین‌کوست به دریا می‌ریزد. به دلیل شرایط جغرافیایی و آب و هوایی منطقه، این رودخانه به‌طور منظم در معرض خطر سیل قرار دارد. مدل‌سازی سریع سیلاب در این رودخانه می‌تواند به پیش‌بینی دقیق‌تر و مدیریت بهتر سیلاب کمک کند. استفاده از تکنولوژی‌های مدرن در مدل‌سازی و شبیه‌سازی سیلاب می‌تواند به کاهش خسارات و حفظ جان و مال ساکنین محلی منجر شود. نقشه توپوگرافی برای منطقه مورد مطالعه با دقت مکانی ۱۰ متر دریافت شده و مطابق شکل ۴ می‌باشد.

HEC-HMS و غیره نداشته باشد. بنابراین سعی شده است تا تمامی ابزارهای مورد نیاز جهت کار با فایل‌های رستری، برداری و جغرافیایی و همچنین انجام محاسبات و تحلیل‌های هیدرولیکی، هیدرولوژیکی و توپوگرافی، تعلیم شبکه‌های عصبی مصنوعی آگاه از فیزیک و استفاده از این شبکه‌ها به منظور مدل‌سازی سریع‌تر سیلاب در این افزونه در دسترس کاربر بوده و به راحتی قابل استفاده باشد (اطلاعات بیشتر در سایت www.ste.hwstr.ir).

منطقه مورد مطالعه: با توجه به در دسترس بودن داده‌های ایستگاه‌های هیدرومتری کشور استرالیا از طریق سایت اداره هواشناسی این کشور با آدرس www.bom.gov.au/waterdata و دسترسی به نقشه‌های توپوگرافی با دقت بالای این کشور از طریق آدرس elevation.fsdf.org.au برای ارزیابی شبکه‌های عصبی آگاه از فیزیک در این پژوهش، رودخانه ایودلو

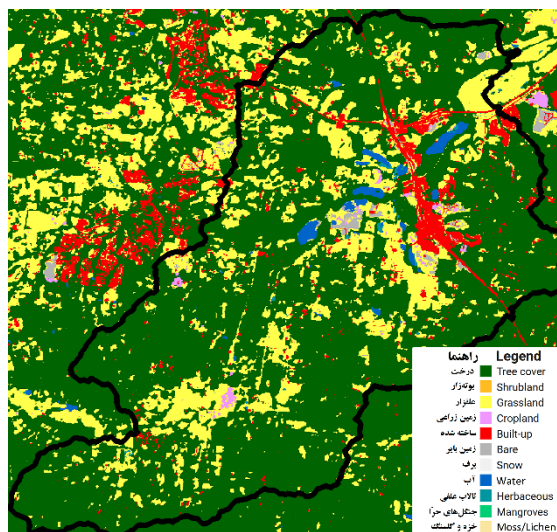


شکل ۴- نقشه توپوگرافی منطقه مورد مطالعه.

Figure 4. Digital elevation map of the study area.

STE از سامانه گوگل ارث انجین دریافت و از این نقشه برای تنظیم مقادیر ضریب زبری مانینگ در مدل‌سازی‌ها استفاده شده است.

نقشه پوشش زمین ESA WorldCover v200 با دقت مکانی ۱۰ متر مطابق شکل ۵ برای منطقه مورد مطالعه با استفاده از قابلیت اسکریپت نویسی نرم‌افزار




شکل ۵- نقشه پوشش زمین منطقه مورد مطالعه.

Figure 5. Land cover map of the study area.

- 1- Eudlo Creek
- 2- Sunshine Coast
- 3- Queensland
- 4- Palmwoods

دوره بازگشت‌های مختلف محاسبه و ارائه شده است. برای ایستگاه بالادست منطقه مورد مطالعه عمق جریان ۲/۵ متر به عنوان عمق جریان سیلابی با دوره بازگشت ۱۰۰ ساله با توزیع لوگ پیرسون^۱ محاسبه شده و از این مقدار برای تعلیم شبکه‌های عصبی آگاه از فیزیک استفاده شده است.

هیدروگراف سیل ثبت شده از تغییرات عمق جریان برای ایستگاه هیدرومتری بالادست رودخانه مورد مطالعه از ۲۰۲۲/۲/۲۵ ساعت ۳:۵۰ تا ۲۰۲۲/۲/۲۶ ساعت ۱۳:۳۰ مطابق شکل ۶ از طریق سایت اداره هواشناسی کشور استرالیا دریافت شده است. همچنین در این سامانه عمق سیلابی جریان با



شکل ۶- هیدروگراف سیل ثبت شده در سال ۲۰۲۲ از تغییرات عمق جریان برای ایستگاه هیدرومتری بالادست رودخانه ایودلو کریک.
Figure 6. The recorded 2022 flood hydrograph of flow depth variations for the upstream hydrometric station of Eudlo Creek.

مطابق جدول ۱ استفاده شده است.

برای انجام پژوهش از نوت‌بوک Y700 برند Lenovo با مشخصات سخت‌افزاری و نرم‌افزاری

جدول ۱- مشخصات سخت‌افزاری و نرم‌افزاری دستگاه استفاده شده برای انجام تمامی مدل‌سازی‌ها.

Table 1. Hardware and software specifications of the device used for the simulations.

پردازنده Processor	Intel(R) Core(TM) i7-6700HQ CPU 2.60GHz up to 3.5GHz 4 Cores, 8 Logical Processors
حافظه موقت RAM	16GB DDR4
نام سیستم عامل OS Name	Microsoft Windows 10 Pro
نگارش سیستم عامل OS Version	10.0.19045 Build 19045
STE	Version 6.78

در بالادست و عمق نرمال به‌عنوان شرط مرزی پایین‌دست در نرم‌افزار STE، اقدام به انجام مدل‌سازی با سلول‌های محاسباتی ۱۰ متری و برابر با نقشه توپوگرافی با قابلیت گام‌زمانی متغیر (آلفا α) برابر ۰/۷ و بتا (β) برابر ۱)، توسط حل عددی نیمه‌ضمنی دسته معادلات آب کم‌عمق با تقریب اینرسی محلی شده و سه نقشه عمق و سرعت جریان و پهنه سیلابی در حالت حداکثر برای ارزیابی دقت شبکه‌های عصبی آگاه از فیزیک در نظر گرفته شده است. مراحل اجرای پژوهش به‌صورت یک نمودار گردشی در شکل ۷ مشخص شده است.

در این پژوهش به‌منظور بررسی توانایی شبکه‌های عصبی آگاه از فیزیک در مدل‌سازی سریع سیلاب اقدام به تعلیم یک شبکه عصبی مجزا برای هر ضریب بتا (β) برابر ۴، ۶، ۸ و ۱۰ با استفاده از داده‌های به‌دست آمده از مدل‌سازی هیدروگراف ثابت با عمق جریان ۲/۵ متر به مدت ۱۰۰۰ دقیقه (سیلاب با دوره بازگشت ۱۰۰ ساله) شده است و سپس اقدام به آزمون شبکه‌ها و مدل‌سازی هیدروگراف سیل سال ۲۰۲۲ (شکل ۶) شده و نتایج به‌دست آمده با نتایج به‌دست آمده از حل عددی مورد مقایسه و ارزیابی قرار گرفته است. پس از تنظیم هندسه، ضرایب زبری مانینگ و مشخص‌سازی سطح مقطع ایستگاه هیدرومتری به‌عنوان شرط مرزی



شکل ۷- نمودار گردشی مراحل اجرای پژوهش.

Figure 7. Flowchart of the research implementation steps.

جزر میانگین مربعات خطا^۲: این معیار متوسط اختلاف میان مقدار پیش‌بینی شده توسط مدل و مقدار مشاهده شده را ارائه می‌دهد. از این معیار برای مقایسه نقشه‌های عمق و سرعت جریان استفاده شده است.

$$RMSE = \sqrt{1/n \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (18)$$

که در رابطه ۱۸، Y_i مقدار محاسبه شده توسط مدل، \hat{Y}_i مقدار مشاهده شده و n تعداد کل داده می‌باشد.

نتایج و بحث

ابتدا مدل‌سازی مربوط به استخراج داده‌های آموزش با استفاده از هیدروگراف ثابت با عمق جریان ۲/۵ متر به مدت ۱۰۰۰ دقیقه (سیلاب با دوره بازگشت ۱۰۰ ساله) برای شرط مرزی بالا دست تنظیم شده و مدل‌سازی با گام زمانی متوسط ۱/۱۹ ثانیه (بتا برابر ۱) و پس از گذشت ۶/۵۶ دقیقه به اتمام رسیده است در این مدل‌سازی تعداد ۲۱۴۵ داده به صورت تصادفی در بعد مکان و زمان از دامنه مدل‌سازی استخراج شده است. با استفاده از ۲۱۴۵ داده استخراج شده اقدام به تعلیم شبکه‌های آگاه از فیزیک ساده و پیچیده برای ضرایب بتا ۴، ۶، ۸ و ۱۰ شده و شرط پایان فرآیند تعلیم عدم بهبود شبکه پس از ۱۰۰۰ تکرار پیاپی در نظر گرفته شده است.

پارامترهای ارزیابی: باتوجه به این‌که برای منطقه مورد مطالعه در زمان وقوع سیل، تصاویر ماهواره‌ای مناسب جهت مشخص سازی دقیق پهنه آبگرفتگی بر روی زمین و مقایسه آن با نتایج وجود نداشت در این پژوهش اقدام به مقایسه نتایج به دست آمده از شبکه‌های عصبی ارائه شده با نتایج مدل‌سازی حل عددی به روش تفاضل محدود شده است که مقادیر عمق جریان، سرعت جریان و پهنه سیلابی در مقابل زمان لازم برای اتمام مدل‌سازی مورد توجه قرار گرفته است.

نمره^۱: این پارامتر میزان توانایی مدل در تخمین درست پهنه سیلابی را مشخص می‌کند به نحوی که به‌ازای تخمین درست سلول‌های پهنه سیل (مقدار مشاهده شده و محاسبه شده هر دو ۱ هستند) یک نمره مثبت و به‌ازای سلول‌هایی که به اشتباه پهنه سیل مشخص شده‌اند (مقدار محاسبه شده ۱ ولی مقدار مشاهده شده ۰ است) یک نمره منفی در نظر گرفته می‌شود. هرچه نمره بیش‌تر باشد نشان‌دهنده دقت بیش‌تر مدل است.

درصد نمره^۲: با تقسیم نمره به دست آمده بر تعداد کل سلول‌های پهنه سیل مشاهداتی (تمامی مقادیر مشاهده شده دارای مقدار ۱) ضرب در ۱۰۰، مقدار درصد نمره به دست خواهد آمد. هرچه این مقدار نزدیک‌تر به ۱۰۰ باشد دقت مدل بیش‌تر است.

جدول ۲- گام زمانی متوسط مدل‌سازی (برحسب ثانیه).

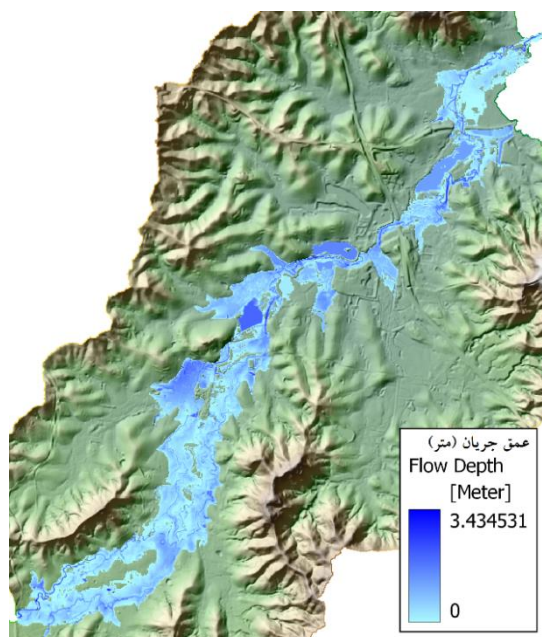
Table 2. The average time step used in the simulations (in seconds).

β	SPANN	CPANN	FD
4	5.2	5.19	×
6	7.9	7.8	×
8	10.52	10.43	×
10	×	13.06	×

1- Point

2- Point Percentage (Point%)

3- Root Mean Square Error (RMSE)



شکل ۸- نقشه پهنه سیلابی و عمق جریان هیدروگراف سیل سال ۲۰۲۲ مدل‌سازی شده توسط حل عددی (مساحت کل پهنه بدست آمده برابر ۵۴۷/۲۶ هکتار).

Figure 8. The flood extent map and flow depth of the 2022 flood hydrograph modeled by numerical solution (The total area of the resulting flood extent is 547.26 hectares).

برابر ۱) پس از گذشت ۲۴/۱۳ دقیقه به اتمام رسیده و نقشه عمق جریان و پهنه سیلابی به دست آمده مطابق شکل ۸ می‌باشد. با توجه به این‌که در منطقه و سیل مورد مطالعه پژوهش، حداکثر عدد فرود به دست آمده از نتایج مدل‌سازی با روش تفاضل محدود مقدار ۰/۷۷ بوده و جریان زیر بحرانی می‌باشد، بنابراین استفاده از معادلات آب کم‌عمق با تقریب اینرسی محلی دقتی برابر با دسته معادلات آب کم‌عمق (دینامیک کامل) خواهد داشت.

پس از تعلیم شبکه‌ها، هیدروگراف سیل سال ۲۰۲۲ برای شرط مرزی بالا دست تنظیم شده و مدل‌سازی برای هر یک از شبکه‌های عصبی تعلیم یافته انجام شده است. زمان لازم برای اتمام مدل‌سازی و ارائه نتایج توسط روش‌های عصبی بر حسب دقیقه مطابق جدول ۳ می‌باشد. در آخر برای مقایسه نتایج و صحت‌سنجی، با تنظیمات و شرایط مرزی یکسان با روش‌های عصبی اقدام به مدل‌سازی هیدروگراف سیل سال ۲۰۲۲ با استفاده از روش تفاضل محدود شده است. مدل‌سازی با گام زمانی متوسط ۱/۱۱ ثانیه (بتا

جدول ۳- زمان لازم جهت اتمام مدل‌سازی (بر حسب دقیقه).

Table 3. The time required to complete the simulations (in minutes).

β	SPANN	CPANN	FD
4	11.33	13.31	×
6	6.88	8.49	×
8	5.55	6	×
10	×	5.06	×

است تا پردازش بر روی تمامی سلول‌های محاسباتی انجام شود تا مدل‌سازی به پایان برسد را کاهش داده و بار محاسباتی مدل‌سازی را کم‌تر خواهد کرد. بنابراین مطابق جدول ۳ با افزایش ضریب بتا و گام زمانی شبکه عصبی، زمان لازم جهت اتمام مدل‌سازی کاهش پیدا خواهد کرد.

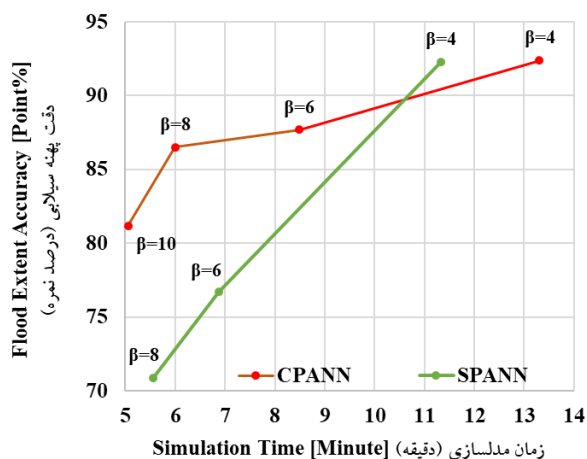
مطابق جدول‌های ۲ و ۳ روش حل عددی قادر به انجام مدل‌سازی با ضریب بتا بیش از ۱ نبوده و نمی‌تواند با گام زمانی بیش‌تر از مقدار به‌دست آمده از رابطه ۱۵ پایداری مدل‌سازی را حفظ کند. افزایش گام زمانی علاوه بر افزایش سرعت پیشروی مدل‌سازی در بعد زمان، تعداد دفعاتی که لازم

جدول ۴- خطای مدل‌سازی شبکه‌های عصبی در نقشه حداکثر (عمق و سرعت جریان بر حسب RMSE و پهنه سیلاب بر حسب درصد نمره).
Table 4. The PANN error in simulating maximum maps (depth and flow velocity in terms of RMSE, and flood extent in terms of Point%).

β	SPANN			CPANN		
	پهنه Extent	عمق Depth	سرعت Velocity	پهنه Extent	عمق Depth	سرعت Velocity
4	92.3	0.15	0.04	92.4	0.14	0.03
6	76.7	0.36	0.13	87.7	0.21	0.06
8	70.9	0.67	0.14	86.5	0.24	0.09
10	×	×	×	81.2	0.57	0.1

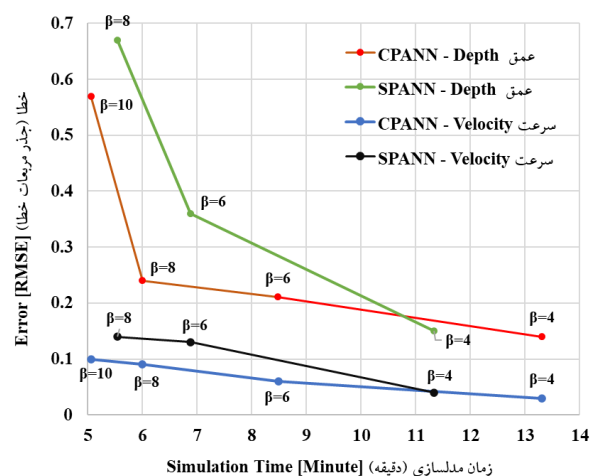
تا حدود ۱۵ درصد نسبت به شبکه‌های عصبی آگاه از فیزیک ساده افزایش داده است. این در حالی است که شبکه‌های عصبی آگاه از فیزیک پیچیده قادر به حفظ میزان بیش‌تری از دقت و پایداری مدل‌سازی به‌خصوص در گام‌های زمانی بزرگ‌تر و ضریب بتا بیش‌تر هستند و ضمن کاهش زمان لازم جهت اتمام مدل‌سازی، خطای کم‌تری وارد محاسبات کرده و نتایج را نزدیک‌تر به حل عددی ارائه می‌دهند. شبکه‌های عصبی آگاه از فیزیک ساده قادر به حفظ پایداری مدل‌سازی با استفاده از ضریب بتا برابر ۱۰ نبوده‌اند و مدل‌سازی با استفاده از شبکه عصبی تعلیم داده شده برای ضریب بتا ۱۰ ناپایدار شده و شکست خورده است. از طرفی شبکه عصبی آگاه از فیزیک پیچیده ضمن حفظ پایداری مدل‌سازی با استفاده از ضریب بتا ۱۰، دقت بیش‌تری را در ارائه نتایج نسبت به شبکه‌های عصبی ساده نشان داده است.

با توجه به جدول‌های ۳ و ۴ شبکه‌های عصبی آگاه از فیزیک قادر هستند ۵۰ تا ۷۰ درصد زمان لازم جهت اتمام مدل‌سازی را با حفظ میزان قابل توجهی از دقت و پایداری مدل‌سازی کاهش دهند. با توجه به شکل‌های ۹ و ۱۰ افزایش ضریب بتا در هر دو شبکه عصبی باعث افزایش سرعت مدل‌سازی در مقابل کاهش دقت مدل‌سازی شده است. بخش زیادی از کاهش دقت مدل‌سازی با توجه به افزایش ضریب بتا به دلیل غیرخطی بودن تغییرات دبی جریان در طول زمان و وابستگی شدید آن به تغییرات شرایط هیدرولیکی در سلول‌های مجاور می‌باشد. با مقایسه میزان خطا و زمان لازم جهت اتمام مدل‌سازی شبکه‌های عصبی آگاه از فیزیک ساده و پیچیده می‌توان نتیجه گرفت، استفاده از دو لایه عصبی در شبکه‌های عصبی آگاه از فیزیک پیچیده باعث بالا رفتن بار محاسباتی بر روی پردازنده در زمان مدل‌سازی شده و زمان لازم جهت اتمام مدل‌سازی را



شکل ۹- زمان لازم جهت اتمام مدلسازی در مقابل دقت پهنه سیلاب.

Figure 9. The time required to complete the simulations versus the flood extent accuracy.

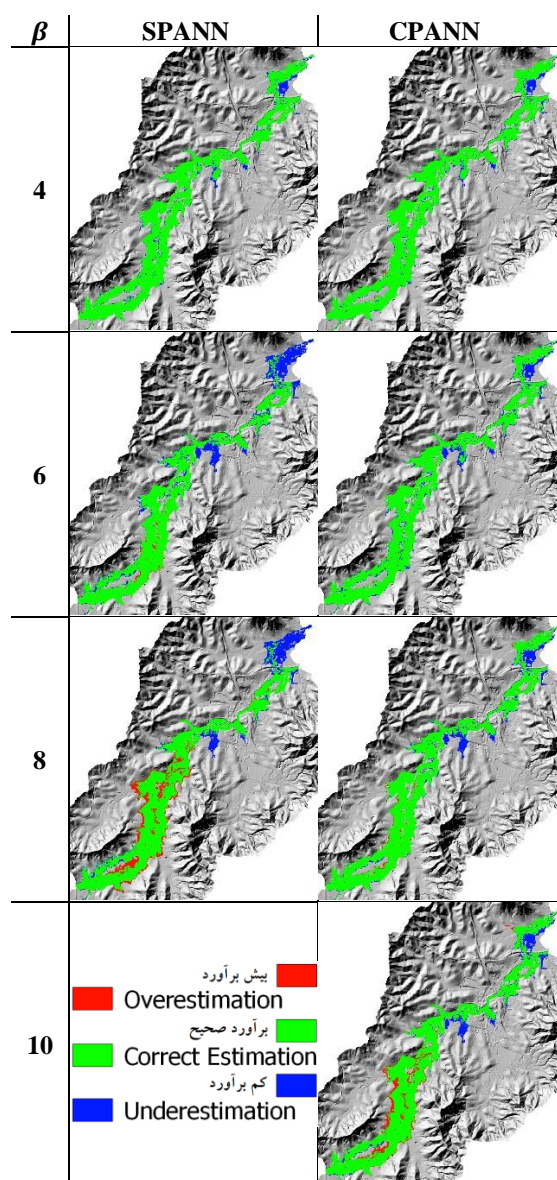


شکل ۱۰- زمان لازم جهت اتمام مدلسازی در مقابل میزان خطای عمق و سرعت جریان.

Figure 10. The time required to complete the simulations versus the error in flow depth and flow velocity.

است. از بررسی میزان درصد اختلاف مساحت پهنه محاسبه شده نیز می‌توان نتیجه گرفت، شبکه‌های عصبی آگاه از فیزیک پیچیده توانایی بیشتری در حفظ دقت مدلسازی در برابر افزایش گام زمانی و سرعت مدلسازی دارند.

با توجه به جدول ۵ و شکل ۱۱ با افزایش ضریب بتا و گام زمانی لایه فیزیکی میزان دبی خروجی خود را افزایش داده و لایه‌های عصبی به منظور حفظ پایداری سعی در کاهش مقدار دبی خروجی از شبکه خواهند داشت، بنابراین در هر دو شبکه میزان قابل توجهی از خطا به صورت کم برآورد محاسبه شده



شکل ۱۱- اختلاف پهنه محاسبه شده توسط شبکه‌های عصبی آگاه از فیزیک در مقایسه با حل عددی.

Figure 11. The difference in the flood extent calculated by physics-aware neural networks compared to the numerical solution.

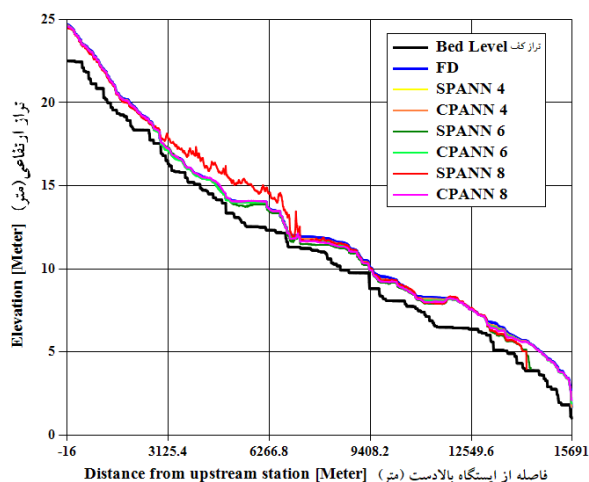
جدول ۵- درصد اختلاف مساحت پهنه محاسبه شده توسط شبکه‌های عصبی آگاه از فیزیک در مقایسه با حل عددی.

Table 5. The percentage difference in the flood extent area calculated by physics-aware neural networks compared to the numerical solution.

β	بیش برآورد Over Estimation		برآورد صحیح Correct Estimation		کم برآورد Under Estimation	
	SPANN	CPANN	SPANN	CPANN	SPANN	CPANN
4	0.02	0.13	92.29	92.31	7.69	7.56
6	2.22	0.25	76.31	87.62	21.47	12.12
8	20.34	2.97	66.69	85.37	12.97	11.65
10	×	13.62	×	76.91	×	9.46

نهایتاً کم‌تر برآورد کردن پهنه سیلابی به‌خصوص در پایین‌دست منطقه مورد مطالعه خواهد شد که این مسأله در شبکه‌های عصبی آگاه از فیزیک پیچیده به‌دلیل اصلاح مقدار خروجی شبکه توسط لایه عصبی دوم خیلی کم‌تر دیده شده و نتایج این شبکه عصبی، پهنه سیلابی را نزدیک‌تر به پهنه سیلابی به‌دست آمده از حل عددی برآورد کرده است.

با افزایش ضریب بتا، تک‌لایه عصبی شبکه‌های عصبی آگاه از فیزیک ساده سعی در کاهش مقدار خروجی خود (مقدار دبی جریان در واحد عرض) به‌منظور کاهش خطای شبکه و حفظ پایداری مدل‌سازی در برآورد دبی‌های بزرگ خواهد داشت که این امر باعث ایجاد خطا و کم‌تر برآورد کردن دبی‌های کوچک و غالب جریان نسبت به واقعیت و



شکل ۱۲- تراز سطح آب محاسبه شده توسط روش‌های مورد بررسی در طول مجرای اصلی رودخانه.

Figure 12. The water level predicted by the examined models along the main channel of the river.

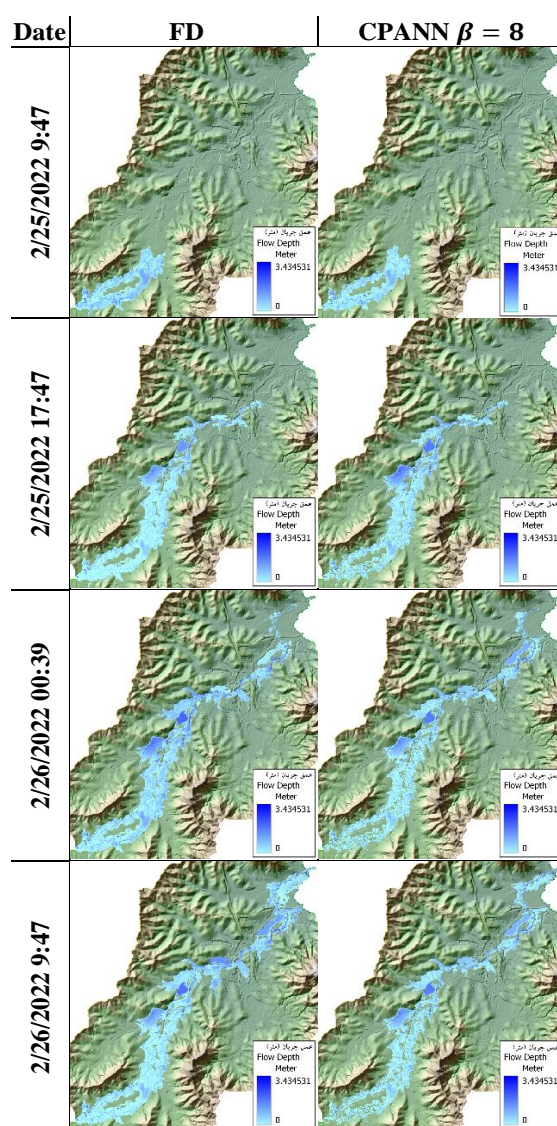
آمده در وسط رودخانه به‌دلیل شیب تند، بالا رفتن سرعت جریان و عدم توانایی شبکه عصبی در حفظ پایداری مدل‌سازی بوده است و خطای به‌وجود آمده در پایین‌دست جریان به‌دلیل سعی شبکه در کاهش مقدار خروجی خود (مقدار دبی جریان در واحد عرض) به‌منظور کاهش خطای شبکه و حفظ پایداری مدل‌سازی در برآورد دبی‌های بزرگ بوده که باعث ایجاد خطا و کم‌تر برآورد کردن دبی‌های کوچک و غالب جریان نسبت به واقعیت شده و نهایتاً جریان با سرعت کم‌تری پیشروی داشته و دیرتر از واقعیت به پایین‌دست رسیده است.

با توجه به نتایج به‌دست آمده شبکه عصبی آگاه از فیزیک پیچیده با ضریب بتا برابر ۸ ضمن ارائه سرعت

مطابق شکل ۱۲ شبکه‌های عصبی مصنوعی آگاه از فیزیک پیچیده در تمامی ضرایب بتا با دقت بسیار خوبی تراز سطح آب را در طول مجرای اصلی رودخانه مورد مطالعه مدل‌سازی کرده و مقادیر به‌دست آمده از این روش‌ها منطبق بر مقادیر به‌دست آمده از مدل‌سازی با استفاده از حل عددی می‌باشد. شبکه‌های عصبی مصنوعی آگاه از فیزیک ساده نیز با ضریب بتا ۴ تراز سطح آب در طول مجرای اصلی رودخانه را با دقت خوب و منطبق بر نتایج حل عددی مدل‌سازی کرده است ولی این شبکه‌ها در مدل‌سازی با ضریب بتا ۸ خطای زیادی را در مدل‌سازی تراز سطح آب در پایین‌دست رودخانه و وسط رودخانه که دارای شیب به نسبت تندتر می‌باشد، داشته است. خطای به‌وجود

زمان مطابق شکل ۱۳ ارائه شده است. از مقایسه مقادیر عمق جریان و پهنه سیلابی مدل‌سازی شده در طول زمان با نتایج حل عددی می‌توان نتیجه گرفت شبکه‌های عصبی آگاه از فیزیک پیچیده در ارائه نحوه تغییرات عمق جریان و پهنه سیلابی در طول زمان نیز با دقت قابل‌قبولی عمل کرده و برای مدل‌سازی سریع سیلاب، مشخص‌سازی پهنه سیلاب و مناطق مورد تهدید، مدیریت بحران و کاهش خسارات سیل مناسب می‌باشند.

بالا در مدل‌سازی و کاهش زمان لازم جهت اتمام مدل‌سازی از دقت مناسبی برخوردار است. با توجه به جدول‌های ۳ و ۴ افزایش ضریب بتا خطای قابل‌توجهی را در مقابل کاهش اندک زمان اتمام مدل‌سازی به همراه خواهد داشت که بر این اساس می‌توان نتیجه گرفت ضریب بهینه بتا برای منطقه مورد مطالعه و شبکه‌های عصبی آگاه از فیزیک پیچیده مقدار ۸ می‌باشد. بنابراین عمق جریان مدل‌سازی شده توسط این روش و حل عددی در ۴ مرحله در طول



شکل ۱۳- نقشه عمق جریان مدل‌سازی شده توسط حل عددی و شبکه عصبی آگاه از فیزیک پیچیده با بتا برابر ۸ در طول زمان.

Figure 13. The simulated flow depth map by numerical solution and the complex physics-aware neural network with a beta value of 8 over time.

نتیجه‌گیری کلی

با توجه به اهمیت مدل‌سازی سریع سیلاب و مشخص‌سازی پهنه‌های دقیق سیلابی به‌منظور اقدام به‌موقع و کاهش خسارات ناشی از سیل در این پژوهش با توسعه بخش دوبعدی نرم‌افزار توسعه‌یافته STE به ارزیابی توانایی شبکه‌های عصبی آگاه از فیزیک با دو ساختار ساده و پیچیده به‌منظور حل سریع‌تر دسته معادلات آب کم‌عمق پرداخته شده و میزان مقاومت هر یک از روش‌ها در حفظ دقت و پایداری مدل‌سازی نسبت به افزایش گام زمانی موردبررسی قرار گرفته است. در این پژوهش با استفاده از عمق جریان سیلاب با دوره بازگشت ۱۰۰ ساله اقدام به تعلیم شبکه‌های عصبی آگاه از فیزیک شده و با استفاده از مدل‌سازی هیدروگراف سیل ثبت‌شده در ایستگاه هیدرومتری بالادست رودخانه مورد مطالعه توسط حل عددی دسته معادلات آب کم‌عمق، شبکه‌های عصبی تعلیم‌یافته مورد ارزیابی، بحث و بررسی قرار گرفته‌اند. به‌صورت خلاصه نتایج این پژوهش نشان داد:

(۱) شبکه‌های عصبی آگاه از فیزیک قادر هستند ۵۰ تا ۷۰ درصد زمان لازم جهت اتمام مدل‌سازی را با حفظ میزان قابل‌توجهی از دقت و پایداری مدل‌سازی کاهش دهند.

(۲) افزایش ضریب بتا در هر دو شبکه عصبی باعث افزایش سرعت مدل‌سازی در مقابل کاهش دقت مدل‌سازی شده است.

(۳) استفاده از شبکه‌های عصبی آگاه از فیزیک پیچیده به‌دلیل استفاده از دولایه عصبی در ساختار خود باعث بالا رفتن بار محاسباتی بر روی پردازنده در زمان مدل‌سازی شده و زمان لازم جهت اتمام مدل‌سازی را تا حدود ۱۵ درصد نسبت به شبکه‌های عصبی آگاه از فیزیک ساده افزایش خواهد داد.

(۴) شبکه‌های عصبی آگاه از فیزیک پیچیده قادر به حفظ میزان بیش‌تری از دقت و پایداری مدل‌سازی

به‌خصوص در گام‌های زمانی بزرگ‌تر و ضریب بتا بیش‌تر هستند و ضمن کاهش زمان لازم جهت اتمام مدل‌سازی، خطای کم‌تری وارد محاسبات کرده و نتایج را نزدیک‌تر به حل عددی ارائه می‌دهند.

(۵) شبکه عصبی آگاه از فیزیک پیچیده با ضریب بتا برابر ۸ ضمن ارائه سرعت بالا در مدل‌سازی و کاهش زمان لازم جهت اتمام مدل‌سازی از دقت مناسبی برخوردار است.

(۶) افزایش ضریب بتا خطای قابل‌توجهی را در مقابل کاهش اندک زمان اتمام مدل‌سازی به همراه خواهد داشت که بر این اساس می‌توان نتیجه گرفت ضریب بهینه بتا برای منطقه مورد مطالعه و شبکه‌های عصبی آگاه از فیزیک پیچیده مقدار ۸ است.

(۷) شبکه‌های عصبی آگاه از فیزیک پیچیده در ارائه نحوه تغییرات عمق جریان و پهنه سیلابی در طول زمان نیز با دقت قابل‌قبولی عمل کرده و برای مدل‌سازی سریع سیلاب، مشخص‌سازی پهنه سیلاب و مناطق مورد تهدید، مدیریت بحران و کاهش خسارات سیل مناسب است.

تقدیر و تشکر

این پژوهش مستخرج از رساله دکتری تحت حمایت دانشگاه علوم کشاورزی و منابع طبیعی گرگان صورت گرفته است و نویسندگان مقاله مراتب سپاس و قدردانی خود را از این دانشگاه اعلام می‌دارند.

داده‌ها و اطلاعات

داده‌های مورد استفاده در این پژوهش از منابع آنلاین و رایگان که در دسترس عموم قرار گرفته است، استفاده شده که توضیحات تکمیلی ضمن درج لینک دسترسی به منبع در متن مقاله ارائه شده است.

تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مسأله مورد تأیید همه نویسندگان است.

مشارکت نویسندگان

نویسنده اول: طرح تحقیق و روش‌شناسی، برنامه‌نویسی و توسعه برنامه، آماده‌سازی داده‌ها، انجام محاسبات، مدل‌سازی و شبیه‌سازی، تهیه پیش‌نویس مقاله، تهیه نقشه‌ها و اطلاعات مکانی، اصلاح و نهایی‌سازی مقاله نویسنده دوم: طرح تحقیق و روش‌شناسی، اصلاح و نهایی‌سازی مقاله، مشارکت در آنالیزها، نظارت تحقیق نویسنده سوم: بازبینی مقاله، مشارکت در آنالیزها، نظارت تحقیق

اصول اخلاقی

اصول اخلاقی در انجام و انتشار این اثر عملی رعایت شده است و این موضوع مورد تأیید تمامی نویسندگان می‌باشد.

حمایت مالی

این پژوهش با حمایت مالی دانشگاه علوم کشاورزی و منابع طبیعی گرگان در قالب رساله دکتری نویسنده اول با عنوان "شبیه‌سازی سریع گسترش سیلاب و برآورد رسوب با استفاده از روش‌های هوشمند" صورت گرفته است.

منابع

1. Neal, J., Villanueva, I., Wright, N., Willis, T., Fewtrell, T., & Bates, P. (2012). How much physical complexity is needed to model flood inundation?. *Hydrological Processes*, 26(15), 2264-2282.
2. De Almeida, G. A., & Bates, P. (2013). Applicability of the local inertial approximation of the shallow water equations to flood modeling. *Water Resources Research*, 49(8), 4833-4844.
3. Tanaka, T., & Yoshioka, H. (2017). Numerical stability analysis of the local inertial equation with semi-and fully implicit friction term treatments: assessment of the maximum allowable time step. *Journal of Advanced Simulation in Science and Engineering*, 4(2), 162-175.
4. Jamali, B., Haghghat, E., Ignjatovic, A., Leitão, J. P., & Deletic, A. (2021). Machine learning for accelerating 2D flood models: Potential and challenges. *Hydrological Processes*, 35(4), e14064.
5. Qian, K., Mohamed, A., & Claudel, C. (2019). Physics informed data driven model for flood prediction: Application of deep learning in prediction of urban flood development. arXiv preprint arXiv: 1908. 10312.
6. Mahesh, R. B., Leandro, J., & Lin, Q. (2022). Physics informed neural network for spatial-temporal flood forecasting. In *Climate Change and Water Security: Select Proceedings of VCDRR 2021*. Springer Singapore.
7. Nazari, L. F., Camponogara, E., & Seman, L. O. (2022). Physics-informed neural networks for modeling water flows in a river channel. *IEEE Transactions on Artificial Intelligence*, 5(3), 1001-1015.
8. Jung, S., An, H., & Lee, G. (2023). Exploring the power of physics-informed neural networks for accurate and efficient solutions to 1D shallow water equations. *Journal of Korea Water Resources Association*, 56(12), 939-953.
9. Teimourey, R., & Dehghani, A. A. (2021). Assessment of bed load transport formula by using developed applied software (STE) (Case study: Chehel-chai, Khormaloo and Soosara rivers in Golestan province). *Amirkabir Journal of Civil Engineering*, 52(11), 2743-2760.
10. Teimourey, R., & Dehghani, A. A. (2020). Comparison of Different Methods for Estimating Bed Load using developed software of STE (case study: Babolroud River). *Journal of Water and Soil Conservation*, 27(1), 229-236.

