

مدلسازی بارش- رواناب با استفاده از مدل یادگیر عمیق (مطالعه موردی: حوضه آبریز گالیکش)

راضیه طاطار^۱، خلیل قربانی^{۲*}، مهدی مفتاح هلقی^۳، میثم سالاری جزی^۴

- (۱) دانش‌آموخته کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آب، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان
(۲) * ۳) دانشیار گروه مهندسی آب، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان
* نویسنده مسئول مکاتبات: ghorbani.khalil@yahoo.com
(۴) استادیار گروه مهندسی آب، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

تاریخ پذیرش: ۱۳۹۹/۰۸/۲۰

تاریخ دریافت: ۱۳۹۸/۱۱/۱۵

چکیده:

شبکه‌های عصبی مصنوعی یکی از روش‌های داده‌کاوی است که توسط پژوهشگران زیادی در حوزه‌های مطالعاتی مختلفی همچون مدلسازی آماری بارش-رواناب استفاده می‌شود. جهت بهبود عملکرد این شبکه‌ها، شبکه‌های عصبی یادگیر عمیق توسعه یافته‌اند تا دقت مدلسازی را افزایش دهند. پژوهش حاضر به منظور ارزیابی شبکه‌های یادگیر عمیق در بهبود عملکرد شبکه‌های عصبی مصنوعی در حوضه آبریز گالیکش انجام شد تا بر اساس داده‌های بارش و دما با گام‌های تاخیر زمانی ۱ تا ۵ ماهه، دبی در مقیاس زمانی ۱، ۳، ۶ و ۱۲ ماهه پیش‌بینی شود. نتایج مدل‌سازی بر اساس ۷۰ درصد داده‌ها (آموزش) و ۳۰ درصد داده‌ها (آزمون) نشان داد که در تمامی دوره‌های زمانی، شبکه عصبی یادگیر عمیق باعث بهبود عملکرد شبکه عصبی مصنوعی شده است و بطور متوسط $RMSE$ در داده‌های آموزش از $0/68 m^3/s$ به $0/65 m^3/s$ و در داده‌های آزمون از $0/84 m^3/s$ به $0/73 m^3/s$ کاهش یافته است و ضریب تعیین نیز بطور متوسط برای داده‌های آموزش از $0/57$ به $0/62$ و برای داده‌های آزمون از $0/51$ به $0/67$ افزایش یافته است. از دیگر نتایج این پژوهش نیز می‌توان به تاثیر دما بر افزایش دقت مدلسازی بارش-رواناب اشاره کرد.

کلید واژه‌ها: پیش‌بینی رواناب؛ شبکه عصبی مصنوعی؛ شبکه عصبی عمیق (یادگیری عمیق)؛ حوضه آبریز گالیکش؛ محاسبات نرم

مقدمه

به منظور اندازه‌گیری دبی جریان آب، فاقد ایستگاه هیدرومتری هستند. هیدرولوژیست‌ها برای برآورد سیلاب حاصل از رگبارها، ناگزیر به توسعه و تدوین مدل‌های بارش-رواناب صحیح و واسنجی‌شده متناسب با حوضه‌های آبریز مختلف می‌باشند (قهرمان و لطفی، ۱۳۸۸). مدلسازی بارش-رواناب به‌طور کلی به دو روش تقسیم می‌شود: ۱- روش‌های دانش‌محور (knowledge-driven) که رویکردهای مدلسازی آن مبتنی بر

یکی از پیچیده‌ترین فرآیندهای هیدرولوژیکی فرآیندهای بارش-رواناب است که از پارامترهای مختلف فیزیکی و هیدرولوژیکی تأثیر می‌پذیرد. لذا درک و پیش‌بینی فرآیندهای تولید رواناب و انتقال آن به نقطه خروجی حوضه آبریز یکی از اساسی‌ترین مباحث علم هیدرولوژی محسوب می‌شود (سلاجقه و همکاران، ۱۳۸۸). از آنجایی که بسیاری از حوضه‌های آبریز کشور

(Schmidhuber, 2015). این روش بیشتر برای کلاس‌بندی داده‌ها، پردازش تصاویر و ویدیو و تولید داده‌های جدید مورد استفاده قرار می‌گیرد. مدل‌های یادگیری عمیق در داده‌های حجیم عملکرد بهتری دارند. تحقیقات مختلفی در داخل و خارج از کشور در این زمینه انجام شده است. قربانی و همکاران (۱۳۹۵) به ارزیابی روش‌های هیدرولوژیک و داده‌کاوی در شبیه‌سازی و پیش‌بینی دبی جریان ماهانه در ایستگاه هیدرومتری ارازکوسه پرداختند. نتایج نشان داد که کاربرد مدل‌های داده‌کاوی $M5$ و KNN منجر به بهبود نتایج نسبت به کاربرد مدل هیدرولوژیک مفهومی $IHACRES$ شده است. دهقانی و همکاران (۱۳۹۵) با استفاده از شبکه عصبی مصنوعی و شبکه فازی-عصبی تطبیقی به مدل‌سازی بارش-رواناب حوضه آبخیز کسلیان پرداختند. نتایج نشان داد که شبکه عصبی-فازی تطبیقی با تابع عضویت زنگوله شکل نسبت به مدل شبکه عصبی مصنوعی در دوره آزمون توانایی بهتری برای مدل‌سازی بارش-رواناب در این حوضه دارد. پورنعمت رودسری و همکاران (۱۳۹۳) با استفاده از روش کنترل گروهی داده‌ها ($GMDH$) و شبکه‌های عصبی مصنوعی (ANN) به مدل‌سازی بارش-رواناب در حوضه آبخیز پلرود پرداختند. نتایج حاکی از توانایی بالای هر دو روش در پیش‌بینی و شناسایی روابط پیچیده بین متغیرها در پیش‌بینی رواناب روزانه ناشی از بارندگی می‌باشند. مقادیر نتایج معیارهای آماری بیانگر عملکرد بهتر رویکرد استقرائی $GHMD$ نسبت به شبکه‌های عصبی در مدل‌سازی بارش-رواناب در این حوضه می‌باشد. ستاری و همکاران (۱۳۹۳) به پیش‌بینی مقادیر بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی و مدل درخت $M5$ در ایستگاه اهر پرداختند. یافته‌ها نشان داد که هر دو روش نتایج نسبتاً دقیقی را برای پیش‌بینی ماهانه منطقه ارائه می‌کنند ولی مدل درختی $M5$ روابط خطی ساده‌ای در اختیار کاربر می‌گذارد و این روش کاربردی‌تر است. نجیب زاده و

خصوصیات و قوانین فیزیکی حاکم بر حوضه می‌باشد مانند شدت و مدت بارش، اندازه، شکل، شیب و خصوصیات ذخیره‌ای حوضه، توپوگرافی، نوع خاک و گیاه و خصوصیات اقلیمی حوضه. این مدل‌های فیزیکی شامل تعداد زیادی پارامترها و متغیرهای مشاهداتی می‌باشند که یک فرآیند هیدرولوژیک را توصیف می‌کنند. ۲- روش‌های داده‌محور (DD) ($data-driven$) که بجای استفاده از فرآیند فیزیکی از تجزیه و تحلیل همزمان ورودی و خروجی سری‌های زمانی استفاده می‌کنند و شامل معادلات ریاضی می‌باشند مانند مدل‌های مختلف آماری و روش‌های یادگیری ماشین از جمله شبکه‌های عصبی. با توجه به اینکه مدل‌سازی با روش‌های داده‌محور ممکن است توانایی کافی برای تفسیر فرآیندهای فیزیکی درون حوضه را نداشته باشد اما بطور صحیح و دقیقی می‌تواند رواناب خروجی حوضه را تخمین بزند (Solomatine and Ostfeld, 2008). در سال‌های اخیر محققان زیادی در سراسر جهان سعی کرده‌اند از روش‌های نوین داده‌کاوی از جمله شبکه‌های عصبی مصنوعی، سیستم استنتاج عصبی-فازی تطبیقی، برنامه‌ریزی بیان ژن (GEP)، ماشین بردار پشتیبان، مدل‌های درختی و نزدیک-ترین همسایگی برای مدل‌سازی دقیق مقدار رواناب سطحی استفاده کنند (ستاری و رضازاده‌جودی، ۱۳۹۷). از مزایای روش‌های هوشمند این است که می‌توان از آنها برای شبیه‌سازی مسائل غیرخطی و پیچیده استفاده کرد. امروزه روش‌های هوشمند در شبیه‌سازی بارش-رواناب بسیار مورد توجه قرار گرفته‌اند (کارآموز و عراقی‌نژاد، ۱۳۸۴). یکی از روش‌های نوین، شبکه‌های عصبی عمیق ($Deep learning neural network$) می‌باشد که زیر مجموعه‌ای از الگوریتم یادگیری ماشین می‌باشد. اصطلاح یادگیری عمیق اولین بار به ماشین یادگیری دکارت و شبکه‌های عصبی مصنوعی توسط آیزنبرگ و همکارانش معرفی شد. پس از آن موفق‌ترین یادگیرنده‌های عمیق در زمینه شبکه‌های عصبی مصنوعی بسیار محبوب شد

همکاران (۱۳۹۸) با بهره‌گیری از روش‌های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی در مدل‌سازی بارش رواناب در حوضه آبریز سد صفارود پرداختند. نتایج نشان داد که روش‌های SVR و MLP در مدل‌سازی بارش رواناب دارای عملکرد مناسبی در محدوده مورد مطالعه می‌باشد. خوشحال و همکاران (۱۳۹۲) به شبیه‌سازی بارش-رواناب با استفاده از شبکه عصبی مصنوعی در حوضه آبخیز فریدن پرداختند. نتایج حاصل، توانایی بالای شبکه عصبی مصنوعی در مدل نمودن بارش-رواناب را به هنگام استفاده از پارامترهای وئومورفولوژیکی در حوضه فریدن به خوبی نشان می‌دهد. غلامی و درواری (۱۳۹۲) به شبیه‌سازی بارش-رواناب با بکارگیری شبکه عصبی مصنوعی (ANN) و مدل HEC-HMS در حوضه آبخیز کسلیان پرداختند. مقایسه نتایج حاصل از بکارگیری شبکه عصبی مصنوعی در دو حالت با بکارگیری هدر رفت اولیه بهینه سازی شده وبدون آن، حاکی از کارایی بالای این روش و تاثیر بسیار مطلوب این عامل در افزایش دقت شبیه سازی روان آب و آبنمود سیلاب تا حدود دو برابر برای برخی وقایع می باشد. نیک‌پور و همکاران (۱۳۹۶) به بررسی کاربرد مدل‌های *WNN*، *ANN*، *LS-SVM* و *GEP* در شبیه‌سازی بارش-رواناب در رودخانه خیاوچای پرداختند. نتایج بیان‌کننده برتری مدل هیبرید موجک_عصبی با بیشترین ضریب همبستگی، کمترین ریشه میانگین مربعات خطا و ضریب نش ساتکلیف در مرحله صحت‌سنجی بود. نتایج آزمون آنوا نیز نتایج شاخص‌های آماری را تایید کرد و مدل هیبرید موجک_عصبی با داشتن کمترین مقدار آماره F و بیشترین سطح معناداری به عنوان بهترین مدل شناخته شد. Kumar Vyas و همکاران (۲۰۱۶) با استفاده از رگرسیون و شبکه عصبی مصنوعی به مدل سازی بارش-رواناب در رودخانه بناس هند پرداختند. نتایج نشان داد که روش شبکه عصبی مصنوعی نسبت به رگرسیون در پیش‌بینی مقادیر رواناب برتری دارد. Firat و Gungor

(۲۰۰۶) با استفاده از شبکه عصبی-فازی تطبیقی به پیش‌بینی جریان رودخانه مئاندر در ترکیه پرداختند. نتایج نشان داد که شبکه عصبی- فازی تطبیقی می‌تواند با موفقیت، صحت و قابلیت اطمینان بالا برای پیش‌بینی جریان رودخانه به کار رود. Patel و Joshi (۲۰۱۷) با استفاده از روش شبکه عصبی مصنوعی به مدل سازی ضرایب بارش رواناب در حوضه آبخیز داروی در هند پرداختند. نتایج نشان داد که مدل شبکه عصبی خطای بسیار پایینی داشته و برای شبیه‌سازی بارش-رواناب در این حوضه مناسب است و نتایج بدست آمده با ضریب ۹۹٪ درصد همبستگی داشته‌اند. Shoaib و همکاران (۲۰۱۹) با استفاده از مدل‌های شبکه عصبی موجک به مدلسازی بارش-رواناب در حوضه Baihe در چین و حوضه Brosna در ایرلند پرداختند. نتایج نشان داد که توابع موجک *db8* و *demy* (تقریب گسسته مایر) در سطح نهم، بهترین عملکرد را با رویکرد *RWA* ارائه دادند. Khan و Coulibaly (۲۰۰۶) از شبکه عصبی بیزی برای آموزش یک شبکه چندرسانه ای برای جریان روزانه رودخانه و شبیه‌سازی جریان مخزن در یک حوضه رودخانه منطقه کانادا استفاده نمودند. نتایج نشان داد که مدل *BNN* مدل مفهومی را بهتر از مدل پیشنهادی استاندارد *ANN* در شبیه‌سازی جریانهای متوسط، پیک و کم رودخانه و خروجی مخزن، به مراتب بهتر از مدل ارائه داد. یکی دیگر از مزیت های مهم روش *BNN* این است که مشکلات بیش از حد و زیرسازی به‌طور خودکار توسط الگوریتم یادگیری بیزی مورد استفاده قرار می‌گیرند، که برعکس مشکلات جدی با الگوریتم یادگیری *ANN* معمولی است. بجز مدل‌های هوشمند ذکر شده مدل نوین دیگری به‌نام شبکه عصبی عمیق وجود دارد که در حوضه مدل‌سازی بارش-رواناب استفاده نشده است. دو نمونه از مطالعات انجام شده با مدل شبکه عصبی عمیق به شرح زیر می‌باشد. فولادی و همکاران (۱۳۹۷) با استفاده از شبکه عصبی یادگیری عمیق به

۳۷۸/۱ متر و ارتفاع متوسط حوضه برابر با ۱۳۹۵/۲ متر از سطح دریا و شیب متوسط حوضه ۲۳/۳ درصد می‌باشد. رودخانه اوغان در این حوضه قرار دارد که رواناب این رودخانه به رودخانه گرگانرود متصل شده و در نهایت در سد گلستان ذخیره می‌شود.

طول شاخه اصلی رودخانه ۲۶/۲ کیلومتر و شیب خالص شاخه اصلی ۳/۵ درصد می‌باشد. زمان تمرکز برابر ۳/۹ ساعت و زمان تاخیر برابر ۲/۳ ساعت است.

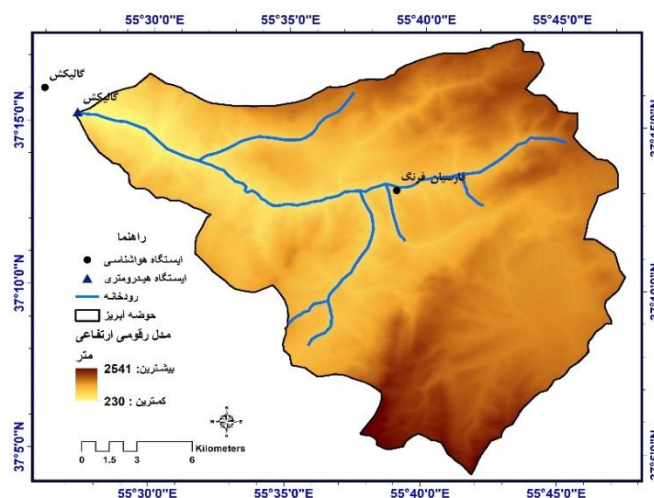
این حوضه دارای ایستگاه باران‌سنجی به نام فارسیان فرنگ و یک ایستگاه هیدرومتری و بارانسنجی دیگر به نام گالیکش می‌باشد. ایستگاه باران‌سنجی فارسیان فرنگ یک ایستگاه معمولی است که در ارتفاع ۹۰۰ متری قرار دارد. ایستگاه هیدرومتری گالیکش نیز در ارتفاع ۲۵۰ متری قرار دارد. این ایستگاه دارای اشل، لیمونوگراف، سطح سنج الکتریکی، تلفریک، دیتالاگر می‌باشد. داده‌های ایستگاه هیدرومتری گالیکش از سال ۱۳۴۵ به بعد موجود می‌باشد. ماه‌های اسفند و فروردین دارای بیشترین و ماه‌های خرداد و تیر دارای کمترین میزان بارش می‌باشند. میانگین رواناب سالانه ۲/۵ متر مکعب بر ثانیه و ماه‌های فروردین و اسفند دارای بیشترین و ماه‌های مهر و شهریور دارای کمترین میزان رواناب می‌باشند.

تشخیص درجه بدخیمی سرطان پروستات و تشخیص سرطان سینه پرداختند. نتایج نشان داد که این روش نسبت به روش‌های پیشین دارای دقت بیشتری می‌باشد. عبدی و صمدزادگان (۱۳۹۷) با استفاده از مدل‌های یادگیری عمیق به طبقه‌بندی اطلاعات سنجنده‌های مرئی-حرارتی هوایی پرداختند. نتایج نشان داد که دقت کلی طبقه‌بندی اطلاعات سنجنده‌ها با استفاده از روش‌های مبتنی بر یادگیری ژرف بهبود یافته است. بررسی مطالعات انجام شده نشان می‌دهد که یادگیری عمیق در مورد پیش‌بینی کلاس و طبقه‌بندی به ویژه در داده‌های حجیم باعث بهبود عملکرد شبکه عصبی مصنوعی می‌شود. با توجه به اینکه داده‌های بارش-رواناب از نوع پیوسته و از لحاظ مقداری از حجم بالایی برخوردار نمی‌باشد، این پژوهش انجام شد تا کارایی شبکه‌های عصبی عمیق در این مورد نیز بررسی شود.

مواد و روش‌ها

منطقه مطالعاتی و داده‌ها

منطقه مطالعاتی این تحقیق حوضه آبریز گالیکش می‌باشد. حوضه آبریز گالیکش، واقع در استان گلستان از زیرحوضه‌های حوضه گرگانرود می‌باشد که دارای مساحتی برابر با ۴۰۴/۸ کیلومتر مربع و محیطی برابر با ۸۸/۶ کیلومتر است. حداکثر ارتفاع حوضه ۲۴۶۱/۳ متر، حداقل ارتفاع



شکل ۱. موقعیت جغرافیایی منطقه مطالعه شده

جدول ۱. خصوصیات آماری مقادیر پارامترهای استفاده شده ایستگاه گالیکش در بازه زمانی ۱۳۷۵-۱۳۹۶

پارامتر	واحد	میانگین سالانه	کمترین	بیشترین	انحراف معیار	ضریب تغییرات
بارش (میانگین دو ایستگاه)	mm	۸۰۶ mm/year	۰	۳۱۶/۵	۴۵/۷	۰/۷
بارش (ایستگاه گالیکش)	mm	۸۶۴ mm/year	۰	۴۹۰/۵	۵۴/۶	۰/۷۸
بارش (ایستگاه فارسبان فرنگ)	mm	۷۴۷ mm/year	۰	۲۳۳/۲	۴۱/۸	۰/۶۹
رواناب (ایستگاه گالیکش)	m ³ /s	۰/۵	۰	۹/۴	۱/۶	۱/۳
دما (ایستگاه گالیکش)	C°	۲/۴	۱/۱۶	۳۰/۲	۸/۱	۰/۴۶

مدل های هوشمند

در تحقیق حاضر برای اجرای مدل های شبکه عصبی مصنوعی و شبکه عصبی عمیق از نرم افزار RapidMiner Studio استفاده شد. در ادامه به توضیح مختصر مدل های ذکر شده و ضرایب به کار رفته برای واسنجی مدل ها پرداخته می شود.

شبکه عصبی مصنوعی (ANN)

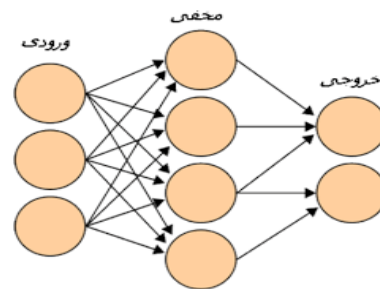
شبکه عصبی مصنوعی یک مکانیسم محاسباتی نوین است که با استفاده از پردازشگرهایی به نام نرون با شناخت روابط ذاتی بین داده ها رابطه ای میان لایه ورودی و لایه خروجی ارائه دهد (غفاری و وفاخواه، ۱۳۹۲). یک شبکه عصبی مصنوعی، از سه لایه ورودی، خروجی و پردازش تشکیل می شود. هر لایه شامل گروهی از سلول های عصبی (نورون) است که عموماً با کلیه نورون های لایه های دیگر در ارتباط هستند، مگر این که کاربر ارتباط بین نورون ها را محدود کند؛ ولی نورون های هر لایه با سایر نورون های همان لایه، ارتباطی ندارند. لایه اول (ورودی) نقش معرفی پارامترهای ورودی را به شبکه برعهده دارد، لایه دوم (لایه پنهان) لایه مابین لایه ورودی و لایه خروجی می باشد که نقش پردازش اطلاعات را بر عهده دارد و لایه خروجی محل قرار گرفتن پارامترهای خروجی شبکه می باشد (Tokar and Johnson., 1999). شبکه های عصبی از نظر ساختار و ارتباطات بین نرون ها به گروه های مختلفی تقسیم می شوند که یکی از رایج ترین

مدل های این شبکه، مدل پرسپترون چند لایه می باشد. در شبکه عصبی پرسپترون چند لایه الگوریتم مشخصی برای تعیین تعداد لایه های پنهان و تعداد نرون ها وجود ندارد و این امر اغلب به روش سعی و خطا انجام می گیرد (صف شکن و همکاران ۱۳۹۰). این روش یک روش یادگیری تحت نظارت است که می تواند به دو مرحله تقسیم شود: انتشار و به روز رسانی وزن. این دو مرحله تا زمانی که عملکرد شبکه به اندازه کافی خوب باشد تکرار می شود. در الگوریتم های انتشار اولیه، مقادیر خروجی با جواب صحیح برای محاسبه مقدار برخی از تابع خطای از پیش تعریف شده مقایسه می شود. با استفاده از تکنیک های مختلف، خطا سپس از طریق شبکه تغذیه می شود. با استفاده از این اطلاعات، الگوریتم وزن هر اتصال را تنظیم می کند تا مقدار تابع خطا را با مقدار کمی کاهش دهد. پس از تکرار این فرایند برای تعداد کافی از دوره های آموزشی، شبکه معمولاً به برخی از حالت هایی که خطا محاسبات کوچک است، همگرا می شود. در این مورد، می توان گفت که شبکه یک تابع هدف خاص را آموخته است. در شکل ۲ ساختار شبکه عصبی مصنوعی نشان داده شده است.

بهرتر از مدل های کم عمق هستند و از این رو لایه های اضافی در ویژگی های یادگیری کمک می کنند (Schmidhuber, 2015). شبکه عصبی عمیق با هربار تکرار یک کار، مهارت و تجربه خود را نسبت به دفعات قبلی بهبود می بخشد. تفاوت یادگیری عمیق و شبکه عصبی در آن است که یادگیری عمیق محدوده های گسترده تر از شبکه عصبی دارد و الگوریتم های یادگیری تقویتی (reinforcement learning) را نیز در برمی گیرد. در شکل ۴ ساختار شبکه عصبی عمیق نشان داده شده است.

روش انجام کار

۷۰ درصد داده ها به عنوان داده های آموزش و ۳۰ درصد آنها به عنوان داده های صحت سنجی در نظر گرفته شد. جهت پیش بینی جریان در ماه جاری از داده های جریان در ماه های قبل به عنوان ورودی در مدل های مورد بررسی استفاده گردید. ترکیبات ورودی ها در مدل های مختلف در جدول ۲ آمده است. که در این مدل ها، P بارش ماه، T میانگین دمای ماه، Q میانگین دبی ماه و اندیس t-L نیز مقادیر این پارامترها برای L ماه قبل می باشد.




شکل ۲. شمای ساده ای از شبکه عصبی مصنوعی

مدل یادگیری عمیق (شبکه عصبی عمیق) (Deep Learning)

یادگیری عمیق زیرمجموعه ای از الگوریتم های یادگیری ماشین بر اساس شبکه های عصبی مصنوعی می باشد که از چندین لایه استفاده می کند تا به طور پیوسته ویژگی های سطح بالاتر از ورودی خام را استخراج کند. یادگیری این الگوریتم می تواند تحت نظارت، نیمه نظارت و یا بدون نظارت باشد. در یادگیری عمیق هر سطح یاد می گیرد که داده های ورودی آن را به نمایندگی، کمی خلاصه تر و مرکب کند. مهم تر از همه، یک فرایند یادگیری عمیق می تواند یاد بگیرد که ویژگی های بهینه در چه سطحی به تنهایی قرار گیرد (Yoshua et al., 2015).

کلمه عمیق در یادگیری عمیق اشاره به تعداد لایه هایی است که از طریق آن داده ها به خروجی تبدیل می شوند. مدل های یادگیری عمیق قادر به استخراج ویژگی های



شکل ۳. شمای ساده ای از ساختار مدل یادگیری عمیق

جدول ۲. ساختار ریاضی مدل های استفاده شده

شماره مدل	ساختار ریاضی و متغیرها	خروجی مدل
۱	$f(P, T, Q, P_{t-1}, T_{t-1})$	Q_t
۲	$f(P, T, Q, P_{t-1}, T_{t-1}, P_{t-2}, T_{t-2})$	Q_t
۳	$f(P, T, Q, P_{t-1}, T_{t-1}, P_{t-2}, T_{t-2}, P_{t-3}, T_{t-3})$	Q_t
۴	$f(P, T, Q, P_{t-1}, T_{t-1}, P_{t-2}, T_{t-2}, P_{t-3}, T_{t-3}, P_{t-4}, T_{t-4})$	Q_t
۵	$f(P, T, Q, P_{t-1}, T_{t-1}, P_{t-2}, T_{t-2}, P_{t-3}, T_{t-3}, P_{t-4}, T_{t-4}, P_{t-5}, T_{t-5})$	Q_t
۶	$f(P, Q, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5})$	Q_t

معیارهای ارزیابی خطای مدل

در این تحقیق برای ارزیابی دقت و کارایی مدل‌ها از نمایه‌های ضریب تعیین (R^2)، ضریب نش- ساتکلیف (Nash-Sutcliffe) ریشه میانگین مربعات خطا (RMSE) طبق روابط زیر استفاده شد.

$$R^2 = \left(\frac{\sum_{i=1}^N (Q_i^O - \bar{Q}^O)(Q_i^P - \bar{Q}^P)}{\sqrt{\sum_{i=1}^N (Q_i^O - \bar{Q}^O)^2 \sum_{i=1}^N (Q_i^P - \bar{Q}^P)^2}} \right)^2 \quad (1)$$

$$NS = 1 - \frac{\sum_{i=1}^N (Q_i^O - Q_i^P)^2}{\sum_{i=1}^N (Q_i^O - \bar{Q}^O)^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q_i^O - Q_i^P)^2}{N}} \quad (3)$$

در روابط بالا، Q_i^O و Q_i^P به ترتیب مقادیر دبی مشاهداتی و محاسباتی توسط مدل در گام زمانی i ام، N تعداد گام‌های زمانی، \bar{Q}^O و \bar{Q}^P نیز به ترتیب میانگین مقادیر دبی مشاهداتی و محاسباتی است. علاوه بر معیارهای ارزیابی ذکر شده از نمودارهای پراکنش حول خط یک به یک برای مقایسه و تحلیل بیشتر استفاده شد.

نتایج و بحث

پارامترهای بهینه

در این پژوهش با روش‌های سعی و خطا، توابع و مقادیر بهینه در نرم‌افزار Rapid Miner، برای شبکه عصبی مصنوعی و مدل یادگیری عمیق به منظور حداقل کردن خطای مدل‌سازی بدست آمد. نوع شبکه عصبی آموزش بکار رفته، شبکه عصبی میانگین پیشخور (mean of

feedforward) می‌باشد که در آن از ۲ لایه پنهان استفاده شده‌است. نوع مدل یادگیر عمیق نیز در این پژوهش H2O با تعداد لایه‌های پنهان ۵۰ انتخاب شد که با روش سعی و خطا بهترین پارامتر فعال‌سازی آن Maxout بدست آمد. در جدول شماره ۳ مقدار بهینه پارامترهای استفاده شده‌ی دیگر در شبکه عصبی مصنوعی و مدل یادگیر جمعی ذکر شده‌است.

ارزیابی مدل‌ها

در این پژوهش، برای مدلسازی بارش-رواناب با مدل‌های شبکه عصبی مصنوعی و شبکه عصبی عمیق، مقیاس‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه رواناب در ۵ گام زمانی مورد بررسی قرارگرفت. نتایج آن به تفکیک در جدول‌های ۵ تا ۸ گزارش شده‌است. بر اساس نتایج گزارش شده در جدول‌ها، مدل شبکه عصبی مصنوعی و مدل یادگیری عمیق هر دو در مقیاس زمانی ۱ ماهه و در مدل شماره ۵ (جدول ۵) بهترین عملکرد را داشته‌اند. از سوی دیگر مشاهده می‌شود که هر دو مدل شبکه عصبی مصنوعی و مدل یادگیری عمیق در مقیاس زمانی ۱۲ ماهه (جدول ۸) عملکرد پایینی داشته‌اند. همچنین هر دو مدل شبکه عصبی مصنوعی و مدل یادگیری عمیق در کلیه مقیاس‌های زمانی، مدل‌های شماره ۱، ۲ و ۳ نتایج ضعیفی داشته‌اند و بیان‌کننده‌ی این است که در حوضه گالیکش فقط با استفاده از بارش و دمای ۱، ۲ و ۳ ماه قبل به تنهایی

جدول ۳. مقادیر پارامترهای استفاده شده در مدل شبکه عصبی مصنوعی و یادگیری عمیق

مدل یادگیری جمعی		شبکه عصبی مصنوعی	
بهترین مقدار	پارامتر	بهترین مقدار	پارامتر
H2O	نوع مدل یادگیری عمیق	mean of feed-forward	نوع شبکه آموزش
Maxout	تعداد لایه‌های پنهان	۲	تعداد لایه‌های پنهان
۵۰	تعداد تکرار	۲۰۰	تعداد حلقه آموزش
۱۴	آموزش نمونه در هر تکرار	۰/۰۱	نرخ یادگیری
-۲	اپسیلون	۰/۰۰۰۱	خطای اپسیلون
۰/۰۰۰۰۰۰۰۱			

مصنوعی به $0.75 m^3/s$ در داده‌های آموزش و m^3/s در داده‌های آزمون در مدل یادگیری عمیق، در مقیاس ۳ ماهه از $0.74 m^3/s$ در داده‌های آموزش و $0.93 m^3/s$ در داده‌های آزمون در شبکه عصبی مصنوعی به $0.67 m^3/s$ در داده‌های آموزش و $0.74 m^3/s$ در داده‌های آزمون در مدل یادگیری عمیق، در مقیاس ۶ ماهه از $0.72 m^3/s$ در داده‌های آموزش و $0.76 m^3/s$ در داده‌های آزمون در شبکه عصبی مصنوعی به $0.73 m^3/s$ در داده‌های آموزش و $0.67 m^3/s$ در داده‌های آزمون در مدل یادگیری عمیق، در مقیاس ۱۲ ماهه از $0.44 m^3/s$ در داده‌های آموزش و $0.74 m^3/s$ در داده‌های آزمون در شبکه عصبی مصنوعی به $0.47 m^3/s$ در داده‌های آموزش و $0.60 m^3/s$ در داده‌های آزمون در مدل یادگیری عمیق کاهش می‌یابد.

در تمامی گام‌های زمانی شبکه عصبی عمیق باعث افزایش ضریب نش-ساتکلیف نسبت به شبکه عصبی مصنوعی شده‌است. در شبکه عصبی عمیق همچنین بر اساس نتایج ذکر شده در مدل شماره ۶ در جداول ۵ تا ۸ ملاحظه می‌شود که استفاده نکردن از مقادیر دما در مقیاس‌های زمانی ذکر شده باعث کاهش ضریب تعیین می‌شود. تاثیر پارامتر دما بر مدل‌سازی بارش-رواناب توسط دهقانی و همکاران (۱۳۹۵) نیز تایید شده است.

ارزیابی مدل‌ها بر اساس نمودارهای پراکنش در شکل‌های ۴ تا ۷ حول خط یک به یک مدل‌های استفاده شده در این پژوهش نمایش داده شده است. همانطور که مشاهده می‌شود در شبکه عصبی عمیق پراکنش مناسب‌تری حول محور دیده

نمی‌توان برآورد صحیحی از رواناب حوضه داشت. در تحقیقات مشابه، مدل‌های تعریف شده بر اساس ترکیب گام‌های زمانی فعلی و پیشین بارش-رواناب با گام‌های زمانی بیشتر برای پیش‌بینی رواناب، بهترین نتیجه را به دنبال داشته است که از آن جمله می‌توان به تحقیقات قربانی و همکاران (۱۳۹۵) و نیکپور و همکاران (۱۳۹۶) اشاره کرد. مقایسه نتایج طبق جدول‌های ۵ تا ۸ نشان می‌دهد که مدل یادگیری عمیق نسبت به شبکه عصبی مصنوعی در همه‌ی مقیاس‌های زمانی و در تمامی مدل‌های ورودی دقت بالاتری در برآورد رواناب بر اساس بارش و دما داشته است. به‌طوری که متوسط ضریب تعیین در مقیاس ۱ ماهه از 0.75 در داده‌های آموزش و 0.70 در داده‌های آزمون در شبکه عصبی مصنوعی به 0.80 در داده‌های آموزش و 0.72 در داده‌های آزمون در مدل یادگیری عمیق، در مقیاس ۳ ماهه از 0.67 در داده‌های آموزش و 0.61 در داده‌های آزمون در شبکه عصبی مصنوعی به 0.72 در داده‌های آموزش و 0.67 در داده‌های آزمون در مدل یادگیری عمیق، در مقیاس ۶ ماهه از 0.48 در داده‌های آموزش و 0.50 در داده‌های آزمون در شبکه عصبی مصنوعی به 0.52 در داده‌های آموزش و 0.59 در داده‌های آزمون در مدل یادگیری عمیق، در مقیاس ۱۲ ماهه از 0.41 در داده‌های آموزش و 0.24 در داده‌های آزمون در شبکه عصبی مصنوعی به 0.42 در داده‌های آموزش و 0.70 در داده‌های آزمون در مدل یادگیری عمیق ارتقا می‌یابد. متوسط ریشه میانگین مربعات خطا در مقیاس ۱ ماهه از $0.81 m^3/s$ در داده‌های آموزش و $0.94 m^3/s$ در داده‌های آزمون در شبکه عصبی

می‌شود که نشان‌دهنده همبستگی بیشتر بین مقادیر مشاهداتی و پیش‌بینی شده توسط مدل ذکر شده است.

جدول ۵. مقایسه شبکه‌های عصبی مصنوعی و عمیق در برآورد رواناب با استفاده از بارش و دما در مقیاس ۱ ماهه

شماره مدل	شبکه عصبی مصنوعی						شبکه عصبی عمیق					
	آموزش			آزمون			آموزش			آزمون		
	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²
۱	۰٫۶۱	۰٫۶۱	۰٫۹۶	۰٫۶۲	۰٫۱۹	۰٫۶۷	۰٫۶۱	۰٫۶۱	۰٫۹۵	۰٫۶۳	۰٫۵۶	۰٫۹۹
۲	۰٫۶۹	۰٫۶۴	۰٫۹۴	۰٫۶۶	۰٫۲۲	۰٫۷۲	۰٫۶۵	۰٫۶۴	۰٫۹۲	۰٫۶۸	۰٫۶۴	۰٫۹۴
۳	۰٫۷۸	۰٫۷۴	۰٫۸۱	۰٫۷۲	۰٫۳۸	۰٫۸۶	۰٫۸۳	۰٫۷۵	۰٫۶۴	۰٫۷۵	۰٫۳۸	۰٫۸۸
۴	۰٫۸۲	۰٫۸	۰٫۷۱	۰٫۷۴	۰٫۱۲	۰٫۸۶	۰٫۸۲	۰٫۷۶	۰٫۶۳	۰٫۷۶	۰٫۵۳	۰٫۸۸
۵	۰٫۸۴	۰٫۸۴	۰٫۶۵	۰٫۷۴	۰٫۱۳	۰٫۸۹	۰٫۸۵	۰٫۷۸	۰٫۶۲	۰٫۷۸	۰٫۶۳	۰٫۸۷
۶	۰٫۵۹	۰٫۵۷	۰٫۸۹	۰٫۵۵	۰٫۶	۰٫۷۳	۰٫۶۸	۰٫۸۴	۰٫۶۱	۰٫۶۱	۰٫۶۲	۰٫۸۶

جدول ۶. مقایسه شبکه‌های عصبی مصنوعی و عمیق در برآورد رواناب با استفاده از بارش و دما در مقیاس ۳ ماهه


شماره مدل	شبکه عصبی مصنوعی						شبکه عصبی عمیق					
	آموزش			آزمون			آموزش			آزمون		
	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²
۱	۰٫۶۱	۰٫۳۱	۰٫۷۶	۰٫۵۷	۰٫۴۲	۰٫۶۴	۰٫۶	۰٫۷۴	۰٫۵۸	۰٫۶۷	۰٫۵۳	۱٫۰۲
۲	۰٫۶۶	۰٫۶۵	۰٫۷۱	۰٫۵۸	۰٫۵۷	۰٫۶۸	۰٫۶۷	۰٫۶۹	۰٫۶۷	۰٫۶۷	۰٫۶۸	۰٫۷۱
۳	۰٫۶۷	۰٫۵۹	۰٫۷۷	۰٫۶	۰٫۵۴	۰٫۷۲	۰٫۶	۰٫۶۶	۰٫۶۷	۰٫۶۱	۰٫۶۱	۰٫۷
۴	۰٫۶۸	۰٫۶۱	۰٫۷۵	۰٫۶۱	۰٫۵۷	۰٫۷۴	۰٫۷۲	۰٫۶۴	۰٫۷	۰٫۶۹	۰٫۶۸	۰٫۶۸
۵	۰٫۷۱	۰٫۶۱	۰٫۷۳	۰٫۷	۰٫۶	۰٫۸	۰٫۵۲	۰٫۶۲	۰٫۷۴	۰٫۶۳	۰٫۶۳	۰٫۶۳
۶	۰٫۵۲	۰٫۵	۰٫۹۱	۰٫۴۹	۰٫۴۵	۰٫۶۲	۰٫۵۱	۰٫۸۸	۰٫۵۶	۰٫۴۶	۰٫۴۶	۰٫۹۱

جدول ۷. مقایسه شبکه‌های عصبی مصنوعی و عمیق در برآورد رواناب با استفاده از بارش و دما در مقیاس ۶ ماهه


شماره مدل	شبکه عصبی مصنوعی						شبکه عصبی عمیق					
	آموزش			آزمون			آموزش			آزمون		
	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²
۱	۰٫۴	۰٫۴	۰٫۷۶	۰٫۴۹	۰٫۱۸	۰٫۴۹	۰٫۴	۰٫۷۵	۰٫۵۳	۰٫۳۳	۰٫۷۱	۰٫۷۱
۲	۰٫۴۵	۰٫۳۶	۰٫۷۴	۰٫۴۹	۰٫۰۶	۰٫۷۹	۰٫۳۹	۰٫۷۵	۰٫۵۹	۰٫۲۱	۰٫۶۸	۰٫۶۸
۳	۰٫۴۹	۰٫۳۸	۰٫۷۲	۰٫۵	۰٫۱۲	۰٫۷۶	۰٫۳۹	۰٫۷۴	۰٫۶	۰٫۱۸	۰٫۶۷	۰٫۶۷
۴	۰٫۵	۰٫۳۹	۰٫۷۲	۰٫۵۱	۰٫۱۲	۰٫۷۴	۰٫۴۹	۰٫۷۲	۰٫۶	۰٫۳۸	۰٫۶۷	۰٫۶۷
۵	۰٫۵۷	۰٫۴۹	۰٫۶۷	۰٫۵۳	۰٫۳	۰٫۷۱	۰٫۵۵	۰٫۶۹	۰٫۶۱	۰٫۵۱	۰٫۶۴	۰٫۶۴
۶	۰٫۴۸	۰٫۴۴	۰٫۹۸	۰٫۴۱	۰٫۲۳	۰٫۸۵	۰٫۵۴	۰٫۸	۰٫۵۲	۰٫۲۵	۰٫۹۴	۰٫۹۴

جدول ۸. مقایسه شبکه‌های عصبی مصنوعی و عمیق در برآورد رواناب با استفاده از بارش و دما در مقیاس ۱۲ ماهه

شماره مدل	شبکه عصبی مصنوعی						شبکه عصبی عمیق					
	آموزش			آزمون			آموزش			آزمون		
	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²	RMSE m^3/s	NSH	R ²
۱	۰٫۲۱	۰٫۰۵	۰٫۵۵	۰٫۱۹	۰٫۰۸	۰٫۲۴	۰٫۱	۰٫۵۴	۰٫۶	۰٫۱۸	۰٫۷	۰٫۷
۲	۰٫۳۳	۰٫۲	۰٫۴۶	۰٫۲۱	۰٫۱۱	۰٫۷۳	۰٫۳۳	۰٫۵۱	۰٫۶۷	۰٫۲۸	۰٫۶۶	۰٫۶۶
۳	۰٫۳۴	۰٫۱۱	۰٫۴۶	۰٫۲۵	۰٫۱۴	۰٫۷۲	۰٫۲۵	۰٫۵	۰٫۷	۰٫۱۹	۰٫۶۴	۰٫۶۴
۴	۰٫۵۵	۰٫۵۲	۰٫۳۹	۰٫۲۶	۰٫۴۸	۰٫۷۲	۰٫۵۳	۰٫۴۱	۰٫۷۳	۰٫۵۱	۰٫۵۴	۰٫۵۴
۵	۰٫۶۱	۰٫۳۶	۰٫۳۷	۰٫۲۸	۰٫۱۶	۰٫۷	۰٫۵۸	۰٫۳۹	۰٫۸۱	۰٫۳	۰٫۴۸	۰٫۴۸
۶	۰٫۱۶	۰٫۱	۱٫۱۵	۰٫۴	۰٫۱۸	۰٫۹۹	۰٫۱۲	۱٫۱	۰٫۵	۰٫۳۶	۰٫۹۴	۰٫۹۴



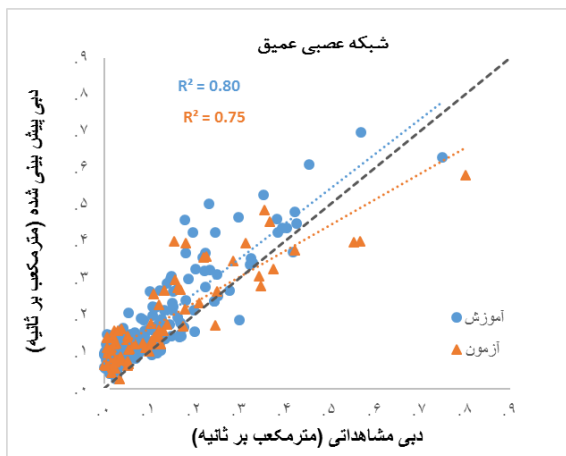
(ب)



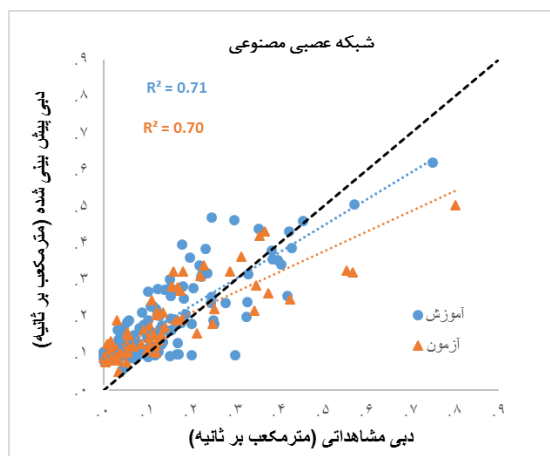
(الف)

شکل ۴. نمودار پراکنش مقادیر برآورد شده دبی در مقابل مقادیر دبی مشاهداتی در مقیاس ۱ ماهه

(الف) شبکه عصبی مصنوعی (ب) شبکه عصبی عمیق (مدل یادگیری عمیق)



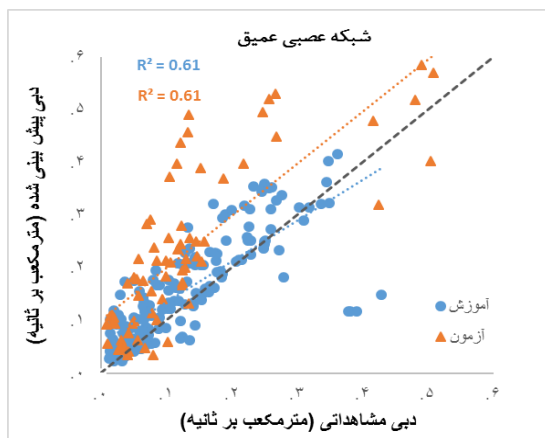
(ب)



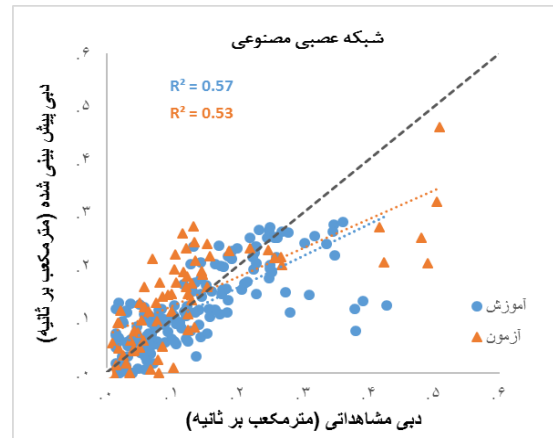
(الف)

شکل ۵. نمودار پراکنش مقادیر برآورد شده دبی در مقابل مقادیر دبی مشاهداتی در مقیاس ۳ ماهه

(الف) شبکه عصبی مصنوعی (ب) شبکه عصبی عمیق (مدل یادگیری عمیق)

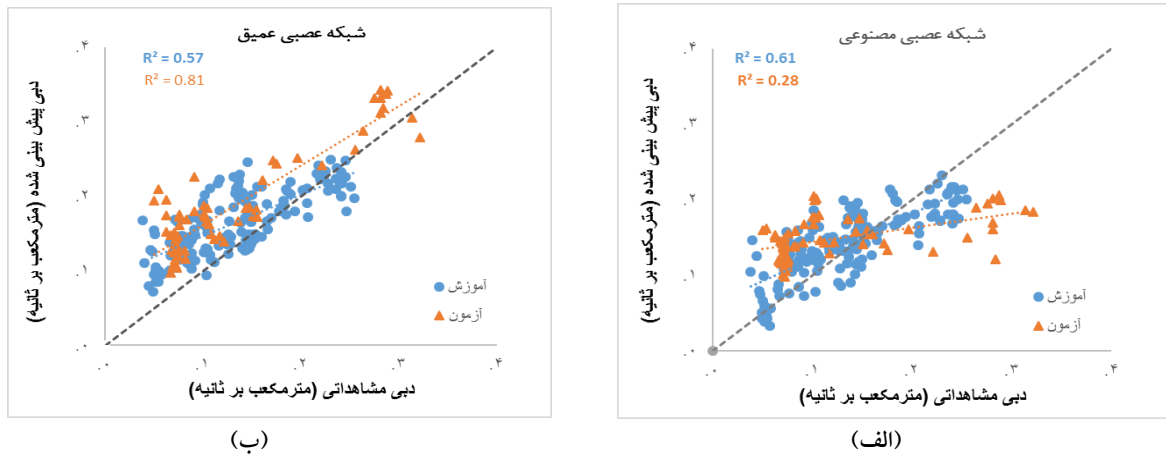


(ب)



(الف)

شکل ۶. نمودار پراکنش مقادیر برآورد شده دبی در مقابل مقادیر دبی مشاهداتی در مقیاس ۶ ماهه
(الف) شبکه عصبی مصنوعی (ب) شبکه عصبی عمیق (مدل یادگیری عمیق)



شکل ۷. نمودار پراکنش مقادیر برآورد شده دبی در مقابل مقادیر دبی مشاهداتی در مقیاس ۱۲ ماهه
(الف) شبکه عصبی مصنوعی (ب) شبکه عصبی عمیق (مدل یادگیری عمیق)

عملکرد خوبی ندارد، مدل یادگیری عمیق عملکرد خیلی بالایی دارد.

۳) تاثیر دما بر مدل‌سازی بارش-رواناب حائز اهمیت می‌باشد به طوری که دخالت ندادن این پارامتر به ویژه در مقیاس ۱۲ ماهه باعث می‌شود ضریب تعیین در داده‌های آموزش و آزمون به ترتیب از ۰/۴۲ و ۰/۷ به ۰/۲۴ و ۰/۵ کاهش می‌یابد و ریشه میانگین مربعات خطا در داده‌های آموزش و آزمون به ترتیب از $0.47 m^3/s$ و $0.7 m^3/s$ به $1.1 m^3/s$ و $0.94 m^3/s$ افزایش یابد.

۴) بر اساس فرضی که در ابتدای پژوهش در نظر گرفته شد مبنی بر اینکه مدل یادگیری عمیق می‌تواند باعث بهبود عملکرد شبکه عصبی مصنوعی شود. این فرض در مورد داده‌های پیوسته بارش-رواناب نیز تایید شد و می‌توان از این روش برای مدل‌سازی بارش-رواناب استفاده کرد.

در نهایت می‌توان نتیجه گرفت که شبکه یادگیر عمیق باعث بهبود دقت نتایج مدلسازی بارش-رواناب در حوضه آبریز گالیکش در تمام گام‌های زمانی شده است.

نتیجه‌گیری

در این پژوهش از مدل یادگیری عمیق برای بهبود عملکرد شبکه‌های عصبی مصنوعی در برآورد رواناب در حوضه آبریز گالیکش واقع در استان گلستان انجام شد و مهمترین نتایجی که در ارزیابی دو روش شبکه عصبی مصنوعی و مدل یادگیری عمیق برای برآورد رواناب رودخانه گالیکش بر اساس بارش و دما بدست آمد عبارتند از:

۱) در تمامی مقیاس‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه، مدل یادگیری عمیق نسبت به شبکه عصبی مصنوعی از دقت بالاتری برخوردار است.

۲) در مقیاس زمانی ۱ ماهه اختلاف بین شبکه عصبی مصنوعی و مدل یادگیری عمیق بیشترین مقدار می‌باشد به طوری که اختلاف این دو روش بر اساس متوسط ضریب تعیین، در داده‌های آموزش ۸ درصد و در داده‌های آزمون ۵ درصد و بر اساس متوسط ریشه میانگین مربعات خطا، در داده‌های آموزش $0.06 m^3/s$ و در داده‌های آزمون $0.03 m^3/s$ می‌باشد. همچنین در مقیاس زمانی ۱۲ ماهه که شبکه عصبی مصنوعی در داده‌های آموزش اصلا

منابع مورد استفاده

- خوشحال، ج.، حسینی، س.م. و فاطمی‌نیا، ف. ۱۳۹۲. شبیه‌سازی بارش- رواناب با استفاده از شبکه عصبی مصنوعی (مورد): حوضه آبخیز فریدن). مجله جغرافیا و برنامه‌ریزی محیطی. ۳ (۵۱): ۲۵-۴۰.
- دهقانی، ر.، قربانی، م.، تشنه لب، م.، ریخته‌گر غیائی، الف. و اسدی، الف. ۱۳۹۴. مقایسه و ارزیابی مدل‌های شبکه عصبی بیزین، برنامه‌ریزی بیان ژن، ماشین بردار پشتیبان و رگرسیون خطی در تخمین بده جریان. فصلنامه علمی پژوهشی مهندسی آبیاری و آب، ۵ (۲۰): ۵۸-۶۶.
- دهقانی، ن.، وفاخواه، م. و بهره‌مند، ع. ۱۳۹۵. مدل‌سازی بارش-رواناب با استفاده از شبکه عصبی مصنوعی و شبکه فازی-عصبی تطبیقی در حوضه آبخیز کسلیان. پژوهشنامه مدیریت حوزه آبخیز، ۷ (۱۳): ۱۲۸-۱۳۷.
- ستاری، م. ت.، رضازاده جودی، ع. و نهرین، ف. ۱۳۹۳. پیش‌بینی مقادیر بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی و مدل درختی M5 (مطالعه موردی: ایستگاه اهر). پژوهش‌های جغرافیای طبیعی. ۴۶ (۲): ۲۴۷-۲۶۰.
- سلاجقه، ع.، فتح‌آبادی، ع. و مهدوی، م. ۱۳۸۸. بررسی کارایی روش‌های عصبی-فازی و مدل‌های آماری در شبیه‌سازی فرایند بارش-رواناب. نشریه مرتع و آبخیزداری، ۶۲ (۱): ۶۵-۸۰.
- صف‌شکن، ف.، پیرمردیان، ن. و افشین شریفیان، ر. ۱۳۹۰. شبیه‌سازی آب نمود بارش-رواناب با توجه با الگوی زمان بارش و استفاده از شبکه عصبی مصنوعی در حوزه آبریز معرف کسلیان. مجله علوم و مهندسی آبخیزداری ایران، ۵ (۱۵): ۱-۱۰.
- عبدی، ق. و صمدزادگان، ف. ۱۳۹۷. طبقه‌بندی اطلاعات سنجنده‌های مرئی-حرارتی هوایی مبتنی بر مدل‌های یادگیری ژرف. نشریه علمی-پژوهشی علوم و فنون نقشه‌برداری، ۵ (۱۵): ۱-۱۰.
- غفاری، غ. و وفاخواه، م. ۱۳۹۲. شبیه‌سازی فرایند بارش-رواناب با استفاده از شبکه عصبی مصنوعی و سیستم فازی-عصبی تطبیقی. پژوهشنامه مدیریت حوزه آبخیز، ۴ (۸): ۱۲۰-۱۳۶.
- غلامی، و. و درواری، ز. ۱۳۹۲. شبیه‌سازی فرایند بارش- رواناب با بکارگیری شبکه عصبی مصنوعی (ANN) و مدل HEC-HMS (مطالعه موردی حوضه آبخیز کسلیان). نشریه علوم و مهندسی آبخیزداری ایران. ۷ (۲۱): ۶۷-۶۹.
- فولادی، ص.، فرسی، ح.، محمدزاده، س. ۱۳۹۷. استفاده از شبکه‌های عصبی یادگیری عمیق در تشخیص درجه بدخیمی سرطان پروستات و تشخیص سرطان سینه. مجله دانشکده پزشکی دانشگاه علوم پزشکی مشهد، ۶۱ (۵): ۱۱۷۸-۱۱۸۷.
- قربانی، خ.، سهرابیان، الف. و سالاری‌جزی، م. ۱۳۹۵. ارزیابی روش‌های هیدرولوژیکی و داده‌کاوی در شبیه‌سازی و پیش‌بینی دبی جریان ماهانه. نشریه پژوهش‌های حفاظت آب و خاک، ۲۳ (۱): ۲۰۳-۲۰۱۷.
- قهرمان، ب. و لطفی، م. ۱۳۸۸. کارایی مدل‌های هیدروگراف واحد در تعیین مشخصات هیدروگراف سیلاب. دانشگاه فردوسی مشهد.
- کارآموز، م. و عراقی‌نژاد، ش. ۱۳۸۴. هیدرولوژی پیشرفته. انتشارات دانشگاه امیرکبیر.
- نجیب‌زاده، ن.، قادری، ک. و احمدی، م.م. ۱۳۹۸. بهره‌گیری از روش‌های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی در مدل‌سازی بارش رواناب (مطالعه موردی: حوضه آبریز سد صفاورد). نشریه آبیاری و زهکشی ایران. ۶ (۱۳): ۱۷۰۹-۱۷۲۰.
- نیکپور، م. ر.، ثانی‌خانی، ه.، محمودی بابلان، س. و محمدی، ع. ۱۳۹۶. کاربرد مدل‌های *WNN*، *ANN*، *LS-SVM* و *GEP* در شبیه‌سازی بارش-رواناب رودخانه خیاوچای. مجله اکوهیدرولوژی، ۴ (۲): ۶۲۷-۶۳۹.

- Firat, M and Gungor, M.2006. River Flow Estimation Using Adaptive Neuro-Fuzzy Inference System. *Mathematics and Computers in Simulation*, 75: 87-96.
- Khan, M.S and Coulibaly, P. 2006. Bayesian neural network for rainfall-runoff modeling. *Journal of Water Resources Research*, 42.7
- Kumar Vyas, S., Prakash Mathur, Y., Sharma, G and Ghandvani, V.2016. Rainfall-Runoff Modelling: Conventional regression and Artificial Neural Networks approach. *Recent Advances and Innovations in Engineering (ICRAIE)*. DOI: 10.1109/ICRAIE.2016.7939532.
- Patel, A.B and Joshi, G.S. 2017. Modeling of Rainfall-Runoff Correlations Using Artificial Neural Network-A Case Study of Dharoi Watershed of a Sabarmati River Basin, India. *Civil Engineering Journal*, 3.2: 78-87
- Schmidhuber, J. 2015. Deep Learning in Neural Network: An Overview. *Neural Networks*. 61: 85-117. doi:10.1016/j.neunet.2014.09.003. PMID 25462637.
- Schmidhuber, J. 2015. Deep Learning. *Scholarpedia*. 10.11: 328-343
- Shoaib, M., Shamseldin, A., Khan, Sh., Sultan, M., Ahmed, F., Sultan, T., Dahri, Z.H and Ali, I. 2019. Input Selection of Wavelet-Coupled Neural Network Models for Rainfall-Runoff Modeling. *Journal of Water Resources Management*, 33.3: 955-973
- Solomatine, D.P and Ostfeld, A. 2008. Data-driven modeling: some past experience and new approaches. *Journal of Hydroinformatics*, 10.1: 3-22.
- Tokar, A.S and Johnson, P.A. 1999. Rainfall- Runoff Modeling Using Artificial Neural Networks. *Journal of Hydrology Engineering*, 3: 232-239.
- Yoshua, B., Yann, L and Geoffrey, H. 2015. Deep Learning. *Nature*. 521: 436-444. Doi: 10.1038/nature14539. PMID 26017442.



ISSN 2251-7480

Rainfall-Runoff modeling using Deep Learning model (Case Study: Galikesh Watershed)

Razieh Tatar¹, Khalil Ghorbani^{2*}, Mehdi Meftah halghi³ and Meysam Salarijazi⁴

1) M.Sc. Graduated of Water Resources Engineering, Department of Water Engineering, Faculty of Water and Soil Engineering, Gorgan University of Agricultural Sciences and Natural Resources

2*, 3) Associate Prof., Department of Water Engineering, Faculty of Water and Soil Engineering, Gorgan University of Agricultural Sciences and Natural Resources

*Corresponding author email: ghorbani.khalil@yahoo.com

4) Assistant Prof., Department of Water Engineering, Faculty of Water and Soil Engineering, Gorgan University of Agricultural Sciences and Natural Resources

Received: 04-02-2020

Accepted: 10-11-2020

Abstract

Artificial neural networks (ANN) are one of the data mining methods applied by many researchers in different fields of studies such as rainfall runoff modeling. To improve the performance of these networks, deep learning neural networks were developed to increase modeling accuracy. This study evaluated deep learning networks to improve the performance of artificial neural networks in Galikesh watershed and to predict flow discharge for 1, 3, 6 and 12-month time scale based on 1- to 5-month time scale lags made in rainfall and temperature data. Based on 70% and 30% of the data used for training and test respectively the results demonstrated that in all time steps, the deep learning neural network improved the performance of artificial neural network and on average RMSE decreased in both training and test from 0.68 to 0.65 and 0.84 to 0.73 respectively. Moreover, R-square was increased on average from 0.57 to 0.62 and 0.51 to 0.67 respectively in training and test. We can also denote the effect of temperature on the increase of accuracy of rainfall-runoff modeling.

Keywords: Runoff Prediction, Artificial Neural Network, Deep Neural Network (Deep Learning), Galilees Watershed, Soft Computing.