

مقاله علمی-پژوهشی

پیش‌بینی تلفات تبخیر و باد بردگی در سامانه‌های آبیاری بارانی با استفاده از شبکه‌های عصبی

مصنوعی

سید ایمان ساعدی^{۱*}، تروی پیترز^۲

تاریخ دریافت: ۱۴۰۰/۱۱/۱۲ تاریخ پذیرش: ۱۴۰۰/۱۲/۲۳

چکیده

تلفات تبخیر و باد بردگی (WDEL) در سامانه‌های آبیاری بارانی عاملی است که دریافت آب در نقاط مختلف مزرعه را دستخوش تغییر می‌کند و باعث کاهش یکنواختی پاشش می‌گردد. لذا پیش‌بینی این تلفات می‌تواند نقش مهمی در بهبود عملکرد آن‌ها ایفا نماید. در این پژوهش از شبکه‌های عصبی مصنوعی برای برآورد ساعتی راندمان دبی آب‌پاش (SDE) استفاده شده است که این پارامتر، خود وابسته به تلفات باد بردگی و تبخیر است. پارامترهای مؤثر در برآورد WDEL که به‌عنوان ورودی شبکه عصبی مدنظر قرار گرفت با محاسبه ضرایب همبستگی رتبه‌بندی اسپرمن انتخاب شدند. بر این اساس، سرعت باد، دما، رطوبت نسبی و تبخیر-تعرق مرجع به‌عنوان ورودی و SDE به‌عنوان خروجی مدل مدنظر قرار گرفت. ارزیابی عملکرد مدل شبکه عصبی ایجادشده با استفاده از ۱۰۲۴ داده به‌دست‌آمده توسط ساختار نواری برآورد WDEL صورت گرفت. مدل شبکه عصبی پیشنهادی که یک مدل ۱-۱۶-۱۹-۴ با تابع آموزش مبتنی بر تنظیم بیزین است پس از بررسی ۳۷۸۰ مدل متفاوت انتخاب گردید. نتایج نشان داد که مدل توسعه داده‌شده می‌تواند با دقت بالایی مقادیر ساعتی SDE را برآورد کند ($MAPE= 1/19$ ، $RMSE= 0/16$ ، $R= 0/84$) و به‌عنوان یک روش قابل اتکاء در ارزیابی عملکرد سامانه‌های آبیاری بارانی استفاده شود.

واژه‌های کلیدی: آبیاری بارانی، تلفات باد بردگی و تبخیر، شبکه عصبی، یکنواختی

مقدمه

که در استفاده از این سامانه‌ها وجود دارد این است که آبی که از آب‌پاش خارج می‌شود تا به زمین برسد ممکن است تحت تأثیر تلفات باد بردگی قرار گرفته و حتی پس از آبیاری به سبب تبخیر آب از ساقه‌ها و برگ‌ها از دسترس خارج شود (Tolk et al., 1995; Cavero et al., 2009) و به این ترتیب راندمان دبی آب‌پاش^۳ (SDE) را کاهش دهد. پژوهش‌ها نشان داده‌اند که بسته به ویژگی‌های طراحی سامانه (از قبیل اندازه، نوع فاصله، فشار کاری و ارتفاع نازل‌ها)، پارامترهای آب و هوایی (مثل سرعت و جهت باد، دما، کمبود فشار بخار، تابش خورشیدی و غیره) و نیز شرایط زمین (کاشته شده یا خالی از محصول)، مقدار تلفات باد بردگی و تبخیر^۴ (WDEL) در هنگام به‌کارگیری سامانه‌های آبیاری بارانی بین ۰ تا ۴۸/۸٪ تغییر می‌کند (Ortiz et al., 2009; Urrego-Pereira et al., 2013). با این حال، این تلفات باعث کاهش راندمان آبیاری می‌شوند؛ پارامتری که به‌صورت حاصل تقسیم مقدار آب ذخیره‌شده در ناحیه ریشه بر مقدار آبی که نازل‌های آب‌پاش را ترک می‌کند تعریف می‌شود (Burt

سامانه‌های آبیاری بارانی از قبیل سامانه خطی و سنتریوت برای آبیاری زمین‌های کشاورزی وسیع بسیار کارآمد هستند. در این سامانه‌ها آبیاری توسط آب‌پاش‌ها صورت می‌گیرد و مجموعه آب‌پاش‌ها که روی یک محور سوار شده‌اند با یک الگوی خطی یا دایره‌ای در زمین حرکت کرده و آب را به تمام نقاط زمین می‌رسانند. این روش آبیاری دارای مزایای منحصر به فردی است که از جمله آن می‌توان به آبیاری منظم و مداوم، امکان آبیاری مزارع بزرگ، هزینه پایین نیروی انسانی و نیز قابلیت سازگاری با اهداف مدیریتی متفاوت اشاره نمود (Peters and Evett, 2007; Lamm et al., 2015; Baimonte and Baimonte 2019). با این حال یکی از مشکلاتی

۱- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران

۲- استاد دپارتمان مهندسی بیوسیستم، دانشگاه ایالتی واشنگتن، امریکا

*- نویسنده مسئول: (Email: isaedi@shahroodut.ac.ir)

DOR: 20.1001.1.20087942.1401.16.3.6.7

3- Sprinkler Discharge Efficiency

4- Wind Drift and Evaporation Loss

داده‌شده می‌افزاید (Sadeghi et al., 2015). از سویی دیگر، مدل‌های فیزیکی توسعه داده‌شده همانند مدل‌های ارائه‌شده توسط اوپکو و همکاران، لی یو و همکاران، موکبا و همکاران، یا تامپسون و همکاران پیچیده هستند و نیازمند پارامترهای زیادی مثل توزیع اندازه قطرات، فشار در هر کدام از خروجی‌ها، دمای آب، زاویه پاشش آبفشان و غیره می‌باشند (Thompson et al., 1993 a,b; Mokeba et al., 1997; Liu et al., 2016; Opoku et al., 2018).

روش‌های هوش مصنوعی و بخصوص شبکه‌های عصبی مصنوعی در بسیاری از کاربردها در مهندسی آب و آبیاری با موفقیت مورد استفاده قرار گرفته‌اند، کاربردهایی از قبیل برآورد تلفات رسوب و میزان نفوذ در آبیاری به روش فارو (King et al., 2015; Mattar et al., 2015)؛ شبیه‌سازی توزیع آب و نیترات در آبیاری قطره‌ای (Li et al., 2015)؛ برنامه‌ریزی پایدار آبیاری (al., 2004; Lazarovitch et al., 2009)؛ و غیره. همچنین، مطالعات اخیر نشان داده‌اند که دقت مدل‌های شبکه عصبی برای پیش‌بینی WDEL در سیستم‌های ایزوله و/یا سامانه‌های آب‌پاشی (Al-Ghobari et al., 2018; Maroufpoor et al., 2018; Marey et al., 2018; Sarwar et al., 2019a) در مقایسه با روش‌های رگرسیون خطی بالاتر است. با این حال، مطالعات کمی پیرامون کاربرد مدل‌های شبکه عصبی برای پیش‌بینی WDEL در سامانه‌های آبیاری بارانی از قبیل سنتریوت مشاهده شده‌است.

یک مدل شبکه عصبی مصنوعی (ANN) یک روش مدل‌سازی است که از شبکه‌های بیولوژیکی و سیستم عصبی مرکزی جانداران الهام می‌گیرد تا نتیجه چندین ورودی را در خروجی تولید کند. شبکه‌های عصبی مصنوعی حاوی مجموعه‌ای از ارتباطات داخلی دارای وزن می‌باشند. یک معماری کلی از شبکه عصبی مصنوعی شبکه‌های چندلایه پرسپترون^۲ (MLP) می‌باشند که مشتمل بر چندین لایه از نرون‌های ساده محاسبه‌گر می‌باشند که به صورت ابزارهای جمع‌کننده غیرخطی عمل می‌کنند. این‌ها از طریق رابط‌های دارای وزن در بین لایه‌ها به هم متصل هستند، به طوری که محاسبات عددی از سمت چپ به راست و بدون دریافت بازخورد از لایه قبلی صورت می‌پذیرد. مقادیر ورودی و وزن‌های ارتباط‌دهنده برای محاسبه خروجی برای هر نرون لایه پنهان استفاده می‌شوند. این نرون مجموع حاصل ضرب وزن‌ها در بردارهای ورودی به علاوه یک وزن بایاس می‌باشد. خروجی هر نرون از یک تابع فعال‌سازی با ورودی نرون لایه پنهان محاسبه می‌شود که خود، در مرحله بعد بردار ورودی برای لایه خروجی خواهد بود. خروجی شبکه عصبی سپس به همین طریق محاسبه می‌شود. این مجموع در مرحله بعدی از یک تابع فعال‌سازی عبور می‌کند. پس از اینکه داده‌های محاسبه‌شده در

et al., 1997). کاهش راندمان آبیاری که به سبب شرایط متغیر آب و هوایی اتفاق می‌افتد عملاً باعث خواهد شد که مقادیر متفاوتی از آب به زمین برسد و این به معنای یکنواختی ضعیف آبیاری در مقیاس وسیع است (Sadeghi et al., 2015). به منظور رفع این مشکل، کشاورزان بعضاً مبادرت به بیش‌آبیاری می‌کنند تا مطمئن شوند که تمام مزرعه به طور کافی آب دریافت کرده‌اند. این مسئله در مقیاس وسیع معایب متعددی در پی دارد از جمله هدر رفت انرژی پمپاژ، افزایش رواناب، فرسایش خاک و شسته شدن مواد مغذی خاک (Santos et al., 2003; Luz and Heermann, 2005; Bauder et al., 2008). این مشکلات طبیعتاً منجر به کاهش درآمد مزرعه و افزایش هزینه‌های تولید محصولات کشاورزی می‌گردد؛ بنابراین، به کارگیری استراتژی‌های مناسب در برآورد و نیز مدیریت WDEL در سامانه‌های آبیاری بارانی نه تنها باعث صرفه‌جویی در منابع آب و نیز انرژی خواهد شد بلکه افزایش درآمد اقتصادی و نیز بهبود شرایط محیط و مزرعه را نیز در پی خواهد داشت. یک راه‌حل اولیه برای این منظور آن است که سرعت پیشروی سامانه را در اوایل صبح، زمانی که WDEL کمتر است تا حدی افزایش داد و سپس در هنگام ظهر و بعدازظهر، هنگامی که این تلفات نسبتاً بالاتر است، مقداری کاهش داد (Sadeghi et al., 2017). بدون شک داشتن اطلاعات پیرامون WDEL در بازه‌های زمانی کوتاه، در مدیریت این عامل بسیار مؤثرتر خواهد بود. البته این کار چندان آسان نخواهد بود چرا که اندازه‌گیری‌ها یا برآوردهای آنی این تلفات دارای عدم قطعیت‌های فراوان است. این مسئله ذهن بسیاری از پژوهشگران را به خود معطوف ساخته که منجر به توسعه چندین مدل فیزیکی و تجربی برای برآورد WDEL تحت عملکرد سامانه‌های آبیاری بارانی در سی سال اخیر گردیده است (Steiner et al. 1983; Yazar 1984; Kohl et al., 1987; Trimmer 1987; Abo-Ghobar 1992; Thompson et al. 1997; Faci et al., 2001; Playan et al. 2004, 2005; Ortiz et al., 2009; Molle et al., 2012; Rajan et al., 2015; Sarwar et al., 2019a,b). در مدل‌های تجربی عموماً از قوطی‌های جمع‌آوری آب^۱ استفاده می‌شود. این قوطی‌ها در زیر سامانه بر روی زمین قرار داد می‌شوند به طوری که هر یک بتوانند آب پاشیده شده توسط یک یا دو آبفشان را دریافت کنند (King et al., 2012). از آنجایی که استفاده از قوطی‌های جمع‌آوری آب یک روش پرهزینه و زمان‌بر است، راهبردهای تجربی لزوماً معطوف به تعداد محدودی از نقاط داده‌برداری می‌شدند. مشکل دیگری که این روش داده‌برداری دارد، این است که فرایند داده‌برداری به صورت ناپیوسته انجام می‌شود که این مسئله نمی‌تواند اثر تغییرات شرایط آب و هوایی بر تلفات باد بردگی و تبخیر را در طول فصل رشد به طور کامل بیان کند. این امر بر عدم قطعیت مدل‌های رگرسیونی توسعه

حین یک فرایند آموزش پردازش می‌شوند، هر وزن برآورد می‌شود. فرضیه این تحقیق آن است که مدل‌های شبکه عصبی توانایی برآورد WDEL در سامانه‌های آبیاری بارانی را افزایش می‌دهند و می‌توانند به‌عنوان ابزاری بسیار مفید برای بهبود عملکرد آن‌ها به شمار آیند. به‌منظور دستیابی به این هدف در مطالعه حاضر به‌جای استفاده از روش سنتی قوطی‌های جمع‌آوری آب برای توسعه و اعتبارسنجی مدل، از یک تکنیک جدید داده‌برداری تحت عنوان آزمون "نواری" استفاده می‌شود (Sadeghi et al., 2015) که قادر به تولید مجموعه بزرگی از داده‌هاست. این تکنیک در بخش‌های بعدی توضیح داده خواهد شد. هدف اصلی این پژوهش به‌کارگیری مدل شبکه عصبی برای برآورد WDEL در سامانه آبیاری بارانی است تا این راهبرد به‌عنوان ابزاری مفید در بهبود عملکرد این سامانه‌ها در مزارع بزرگ مدنظر قرار گیرد.

مواد و روش‌ها

ساختار آزمایش

آزمایشات در مرکز تحقیقات و توسعه کشاورزی آبی وابسته به دانشگاه ایالتی واشنگتن آمریکا واقع در نزدیکی شهر پروسر در ایالت واشنگتن آمریکا (46° 15' 6.40" N, 119° 44' 21.64" W) انجام پذیرفت. ساختار آزمایش مشتمل بود بر دو سیستم آبیاری خطی (هریک به طول ۶۰ متر) که تحت هر کدام سه نوار بلند جمع‌آوری رواناب سطحی ساخته شده بود (شکل ۱). آب‌پاش‌ها از نوع اسپینر شش شیاره با صفحه پاشش زردرنگ (model S3000, Nelson Irrigation Corp., Walla Walla, WA) بودند که به فاصله ۳ متری از هم و در ارتفاع ۱/۵۵ متری از سطح زمین نصب‌شده و مجهز به رگولاتورهای فشار ۱۰۳ kPa (۱۵ PSI) و نازل‌های ۴/۳۷ میلی-متری (۲۲، Nelson Irrigation Corp) بودند. دبی نازل‌ها در آزمایشات اولیه به میزان $13/04 \text{ L min}^{-1}$ با توجه به معیارهای حجم تخلیه‌شده و زمان جریان به دست آمد.

داده‌های واقعی WDEL با استفاده از ساختار آزمون نواری حاصل گردید (Sadeghi et al., 2015). این نوارهای بلند به ابعاد $0/1 \times 1 \text{ m}$ (A و B و C در شکل‌های ۱ و ۲) از تخته ساخته شدند و در فواصل نوک به نوک ۳ متری قرار گرفتند. تخته‌ها با چوب‌هایی در زمین محکم شدند تا مرزها مشخص شوند. ناحیه داخلی مربوط به هر نوار با پوششی غیر قابل نفوذ پوشش داده شد تا به جمع‌آوری آب از ناحیه تعریف‌شده کمک کند. هر نوار دارای شیب تقریبی ۳٪ بود که اجازه ایجاد رواناب (آب جمع‌آوری‌شده) و هدایت آن به داخل یک دستگاه دبی سنج^۲ (Hydrological Services Pty

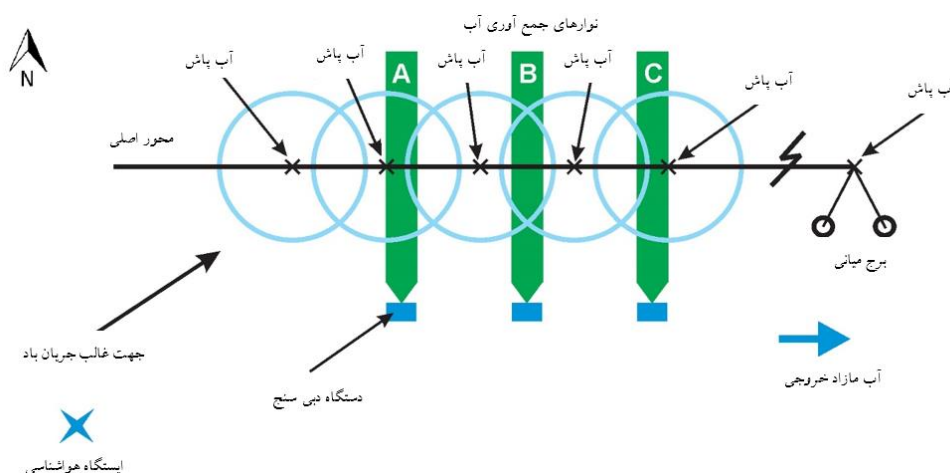
ایستگاه هواشناسی

ایستگاه هواشناسی مورد استفاده در این پژوهش بخشی از شبکه هواشناسی دانشگاه ایالتی واشنگتن^۳ بود. این ایستگاه در ۱۰۰ متری جنوب غربی مزرعه مورد آزمایش واقع شده بود (شکل ۱) و پارامترهای هواشناسی زیر را در بازه‌های زمانی ۵ ثانیه‌ای ذخیره می‌کرد: الف) دما و رطوبت نسبی هوا (RH و T) در ارتفاع یک و نیم متری از سطح زمین با استفاده از یک پروب دما - رطوبت نسبی (T and RH, PC72V; Michell Instruments Ltd., UK) سرعت و جهت باد در ارتفاع ۲ متری از سطح زمین با استفاده از یک بادسنج فتجانی (014A-L; Campbell Scientific Inc. Logan UT) و یک حسگر جهت باد (024A-L; Campbell Scientific Inc.) و ج) تابش خورشیدی در ارتفاع ۲ متری با استفاده از پیرانومتر (SP-110; Apogee Inc. Logan UT). مقادیر میانگین ساعتی این متغیرهای آب و هوایی با استفاده از دیتالاگر (CR1000; Campbell Scientific Inc. Logan UT) تهیه شدند.


1- Strip test

2- Tipping bucket

3- AgWeatherNet, www.weather.wsu.edu



شکل ۱- نمایش ساختار داده‌برداری در مزرعه (برگرفته از Sadeghi et al., 2015)



شکل ۲- طرح‌واره یک نوار داده‌برداری (برگرفته از Sadeghi et al., 2015)

جمع‌آوری داده‌های تجربی

پس از روشن کردن سامانه آبیاری تقریباً ۵ دقیقه طول می‌کشد تا فشار آب‌پاش‌ها افزایش یابد و سپس ۲-۳ دقیقه طول می‌کشد تا آب جمع‌آوری شده به نقطه خروجی برسد. با این حال، تصمیم گرفته شد که داده‌های ۳۰ دقیقه اول از هر آزمون کنار گذاشته شود تا از شرایط پایدار سامانه اطمینان حاصل شود. مقادیر SDE برای هر بازه زمانی با تقسیم دبی میانگین سه نوار بر دبی میانگین نازل آب‌پاش (L) و استفاده از ضریب اصلاحی نسبت عرض نوار (β) به فاصله جلویی آب‌پاش (λ) با استفاده از رابطه (۱) به دست می‌آید (Sadeghi et al., 2015).

$$SDE = \frac{\left(\sum_{j=2}^n q_{A,j} + \sum_{j=2}^m q_{B,j} + \sum_{j=2}^p q_{C,j} \right) \times \lambda}{q_{av}(n+m+p-3)\beta} \quad (1)$$

به طوری که m و n و p تعداد کل دفعات داده‌برداری در بازه زمانی (که در اینجا ۵ دقیقه لحاظ شده است) به ترتیب برای نوارهای A، B و C؛ z اندیسی که نشان‌دهنده تعداد داده‌برداری در بازه زمانی (یعنی ۱-۱) برای نوار A، ۱-۱ $z \le m$ برای نوار B و ۱-۱ $z \le p$ برای نوار C؛ به ترتیب دبی نوارهای A، B و C بین (j-1) (امین و زامین دفعه داده‌برداری هستند که با استفاده از رابطه (۲) محاسبه می‌شوند. به عنوان مثال،

و j ، یعنی (q_j) به صورت رابطه (۲) محاسبه می‌شود:

$$q_j = \frac{0.5 \times \alpha}{t_j - t_{j-1}} \quad (2)$$

به طوری که 0.5 ظرفیت حجمی سطل ($L/5$)؛ α ضریب کالیبراسیون که برای هر کدام از سه دبی سنج تعیین می‌شود (برای جزئیات بیشتر رجوع شود به Sadeghi et al., 2017)؛ t_j و t_{j-1} بیانگر زمانی بر حسب دقیقه است که در آن دفعه شماره j و $j-1$ به ترتیب اتفاق می‌افتند.

آزمایشات به صورت مجزا در طول فصل رشد سال ۲۰۱۴ انجام گرفت. بازه‌های زمانی جمع‌آوری داده به گونه‌ای انتخاب شدند که نماینده گستره وسیعی از شرایط آب و هوایی و نیز شرایط روز و شب باشند. بیش از ۱۱۶۰۰ داده راندمان دبی آب‌پاش در فواصل زمانی ۵ دقیقه‌ای و در شرایط آب و هوایی متفاوت ثبت گردید. این داده‌ها سپس میانگین‌گیری شدند تا در نهایت ۱۰۲۴ داده ساعتی راندمان دبی آب‌پاش به دست آید. این داده‌ها برای توسعه مدل شبکه عصبی مناسب هستند به سبب الف) انحراف معیار نسبتاً پایین (۲/۷۵٪) میانگین ۱۱/۷٪ برای WDEL ساعتی و مقادیر کمینه و بیشینه ۴/۵٪ و ۲۱٪ برای کل داده‌ها و ب) شرایط کاملاً متغیر آب و هوایی در طول آزمون‌های داده‌برداری. مقادیر میانگین روزانه رطوبت نسبی، سرعت باد و دما به ترتیب ۳۵-۷۵٪، ۱.۱-۴/۵ m/s و ۱۰-۲۹ °C بود، درحالی که مقادیر حداکثر (میانگین‌های ۵ دقیقه‌ای) به ترتیب در بازه ۹۸-۱۱٪، ۱۷/۱ m/s و ۰-۴۰ °C به دست آمدند. شایان‌ذکر است که در این داده‌برداری شرایط آب و هوایی حدی یعنی بسیار خشک یا مرطوب، گرم یا سرد و بادخیز یا آرام نیز استحصال گردید که این مسئله منجر به تولید داده‌های متنوع و مناسب برای ایجاد یک مدل شبکه عصبی مناسب گردید.

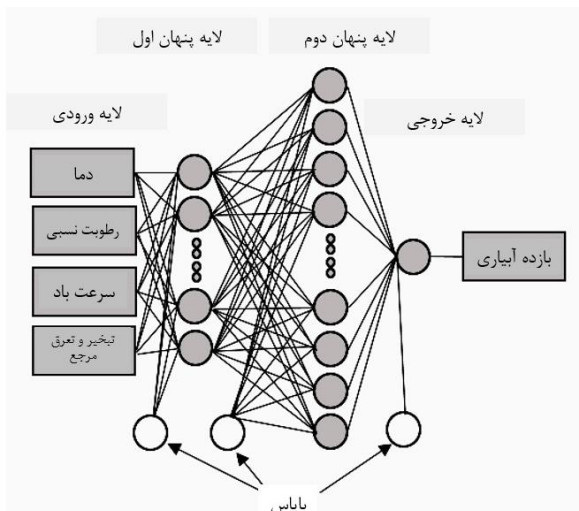
توسعه مدل شبکه عصبی

شبکه‌های عصبی مصنوعی برای پردازش پدیده‌های فیزیکی پیچیده، نامشخص و نیز پدیده‌هایی که نمایش ریاضی آن‌ها دشوار است ابزارهایی مفیدی به شمار می‌آیند (Tu, 1996). این شرایط در مورد پژوهش حاضر به منظور بررسی WDEL صدق می‌کند. شبکه‌های عصبی مصنوعی نیاز به مجموعه‌ای از داده‌ها دارند. لذا در کاربردهایی که داده‌های ورودی محدود هستند، همانند آزمون قوطی جمع‌آوری آب و/یا در معرض تغییرات زیادی هستند، مثل بسیاری از شرایط کشاورزی، موفقیت مدل‌های شبکه عصبی محدود می‌شود (Dumitru and Maria, 2013). داده‌های WDEL ذاتاً بسیار متغیر

هستند چرا که فاکتورهای خارجی زیادی مثل تغییرات ناگهانی در جهت و سرعت باد و نیز تلاطم هوا وجود دارند که بر این تلفات آبی اثر می‌گذارند. علاوه بر این، ناهمگنی بین عوامل غیر بیولوژیکی WDEL (مثل ارتفاع، فشار، نوع و فاصله آب‌پاش‌ها و غیره) در آبیاری بارانی می‌تواند تغییرات بیشتر و مهم‌تری را باعث شوند.

تعیین ورودی‌های مدل شبکه عصبی

پیش از انجام تحلیل شبکه عصبی، با استفاده از نرم‌افزار SAS نسخه ۹/۴، (SAS Institute Inc., Cary, NC, USA) تحلیل‌های آماری صورت گرفت تا مهم‌ترین پارامترهای هواشناسی مؤثر بر SDE (یعنی ورودی‌های مدل شبکه عصبی) تعیین شوند. چندین پارامتر آب و هوایی کلیدی از جمله مقادیر ساعتی دمای هوا (T)، رطوبت نسبی (RH)، سرعت و جهت باد (WS و WD)، تابش خورشیدی (SR)، کمبود فشار بخار (VPD) و تبخیر و تعرق خالص مرجع (ET_0)، به عنوان محرک‌های اصلی WDEL انتخاب شدند. ET_0 با استفاده از روش ارائه‌شده توسط آلن محاسبه شد (Allen et al. 1998). در مرحله بعد، با استفاده از ضرایب همبستگی رتبه‌بندی اسپرمن ساختار همبستگی این متغیرها ارزیابی شد (جدول ۱). به سبب همبستگی بالای این پارامترها، به منظور اجتناب از احتمال خطی بودن، متغیرها مورد بازبینی قرار گرفتند. انتخاب متغیرها با توجه به ضریب همبستگی غیر پارامتری اسپرمن و اثر معنی‌دار در مدل ($p < 0.05$) صورت گرفت. این روش نشان داد که پارامترهای هواشناسی ارزیابی شده دارای اثر معنی‌داری بر راندمان ساعتی دبی آب‌پاش می‌باشند ($p < 0.001$). با این حال، تنها WS ، T ، RH و ET_0 در نهایت به عنوان متغیرهای مستقل (یعنی ورودی شبکه عصبی مدنظر) انتخاب شدند (شکل ۳)، چرا که همبستگی بالایی بین این پارامترها مشاهده شد (جدول ۱). ET_0 از این جهت انتخاب شد که اثر ترکیبی SR ، T ، RH و VPD بر راندمان دبی ساعتی آب‌پاش را نشان دهد و در نتیجه عملکرد برآورد در ANN را بهبود بخشد. با این فرض که WDEL مهم‌ترین فاکتور مؤثر بر راندمان دبی آب‌پاش است، این متغیرهای اقلیمی مؤثر با آنچه توسط اشتاینر و همکاران، کلر و بلایسنر، پلایان و همکاران، اورتیز و همکاران، ماری و همکاران، سرور و همکاران و غیره گزارش شده است سازگاری دارند (Steiner et al. 1983, Keller and Bliesner 1990, Playan et al. 2005, Sarwar et al. 2009, Ortiz et al., 2018, Marey et al. 2019a,b).



شکل ۳- ساختار شبکه عصبی با دو لایه پنهان برای برآورد راندمان آبیاری؛ لایه‌های مختلف با رابط‌های وزنی به هم مرتبط می‌شوند

منظور گردید. از آنجایی که الگوریتم BR نیازی به داده‌های ارزیابی ندارد (ساعدی و همکاران، ۱۳۹۷)، ۸۰٪ داده‌ها در این حالت برای آموزش و ۲۰٪ برای تست لحاظ شد. شایان ذکر است که به دلیل آنکه آزمایشات ما در ۲۴ ساعت شبانه‌روز به‌طور پیوسته صورت نمی‌گرفت، تمام ساعات شبانه‌روز (از ۱ تا ۲۴) دارای تعداد یکسانی داده ساعتی SDE نبودند. در نتیجه، انتخاب تصادفی داده‌ها متناسب با تعداد کل داده‌های در دسترس برای یک ساعت خاص از شبانه‌روز تنظیم گردید. این کار از ایجاد بایاس‌های احتمالی که در مدل‌های شبکه عصبی به سبب انتخاب تصادفی داده‌ها اتفاق می‌افتد جلوگیری می‌کند.

فرایند آموزش را می‌توان با به‌کارگیری یک سری از عملیات پیش‌پردازش که بر روی داده‌های ورودی و خروجی انجام می‌شود بهبود بخشید. بیشتر توابع مورد استفاده برای توسعه شبکه‌های عصبی به صورت خودکار این عملیات پیش‌پردازش را انجام می‌دهند. با این حال، در مورد الگوریتم BR بهترین عملکرد در شرایط به دست می‌آید که داده‌ها در بازه [۱ و -۱] نرمال شوند (ساعدی و همکاران، ۱۳۹۷). نرمال‌سازی داده‌ها در الگوریتم BR معمولاً با استفاده از رابطه (۳) صورت می‌گیرد (روحانی و همکاران، ۱۳۹۴):

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min} \quad (3)$$

در رابطه (۳) y_{\max} و y_{\min} به ترتیب برابر با ۱ و -۱ می‌باشند. به منظور بازگرداندن داده‌های تولید شده توسط الگوریتم BR به مقیاس اصلی، با به‌کارگیری معکوس رابطه (۳) یک فرایند پس‌پردازش انجام می‌پذیرد.

زمانی که از تابع آموزش BR استفاده می‌شود این مسئله خیلی مهم است که به الگوریتم اجازه دهیم تا همگرایی مؤثر همه پارامترها

معماری مدل‌های شبکه عصبی

از الگوریتم پس انتشار^۱ یا BP برای تولید مدل‌های شبکه عصبی استفاده شد. این الگوریتم سپس مورد بازبینی قرار گرفت تا مدل نهایی انتخاب شود. BP یک الگوریتم با کاهش شیب^۲ است که در آن شیب یک تابع هزینه بر حسب تمام وزن‌های شبکه محاسبه می‌شود. از این شیب برای به‌روزرسانی وزن‌ها به منظور به حداقل رساندن تابع هزینه استفاده می‌شود. در طول این فرایند، وزن‌ها تنظیم می‌شوند تا زمانی که تفاوت بین خروجی پیش‌بینی شده و داده هدف واقعی حداقل شود. برای یک مجموعه از داده‌های موجود که شامل ورودی‌ها و خروجی‌هاست، وزن‌ها به صورت مکرر توسط یک الگوریتم یادگیری بروز می‌شوند تا رفتار هدف را بتوانند تقریب بزنند. این فرایند از طریق "پس انتشار" لایه به لایه سیگنال خطا صورت می‌گیرد تا وزن‌ها با توجه به سیگنال خطا بروز رسانی شوند (Omid et al., 2010). به این ترتیب از بیش‌برازش جلوگیری می‌شود. بر اساس الگوریتم BP، فرایند آموزش با به‌کارگیری تابع فعال‌سازی (F) صورت گرفت. بدین منظور، یک تابع تانژانت هیپربولیک ($f(x) = \tanh(x)$) برای لایه‌های میانی و یک تابع خطی ($f(x) = x$) برای لایه خروجی استفاده می‌شود. همچنین، سه تابع آموزش در این پژوهش لحاظ گردید شامل لونیبرگ مارکوارت^۳ (LM)، گرادیان مزدوج مقیاس شده^۴ (SCG) و تنظیم بی‌زین^۵ (BR). در مورد LM و SCG، داده‌ها به صورت تصادفی به سه زیرمجموعه تقسیم شد به طوری که ۶۰٪ داده‌ها برای آموزش، ۲۰٪ برای ارزیابی و ۲۰٪ باقیمانده برای تست

- 1- Backpropagation
- 2- Gradient descent
- 3- Levenberg-Marquardt
- 4- Scaled Conjugate Gradient
- 5- Bayesian Regularization

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|}{n} \times 100\% \quad (5)$$

به طوری که در این روابط n تعداد داده‌های ارزیابی شده (۱۰۲۴) در این پژوهش، A_t و F_t به ترتیب داده‌های واقعی و پیش‌بینی شده می‌باشند.

نتایج و بحث

نتایج تحلیل ضریب همبستگی اسپرمن برای راندمان ساعتی دبی آب‌پاش (SDE) و متغیرهای آن شامل رطوبت نسبی (RH)، تابش خورشیدی (SR)، دمای هوا (T)، حداکثر سرعت باد (MWS)، سرعت باد (WS)، جهت باد (WD)، تبخیر و تعرق مرجع (ET_o) و کمبود فشار بخار (VPD) در جدول ۱ آورده شده است. نتایج این جدول تأیید می‌کنند که بهترین ورودی‌ها برای برآورد راندمان دبی ساعتی آب‌پاش به‌منظور توسعه یک مدل شبکه عصبی شامل دما، رطوبت نسبی، سرعت باد و تبخیر و تعرق مرجع است.

نتایج به‌کارگیری داده‌های جداگانه روز، شب و شبانه‌روز در جدول ۲ آورده شده است که از بین آن‌ها بهترین شبکه برای هر سری داده معرفی گردید. در تمامی شبکه‌ها از تابع تانژانت هیپربولیک به‌عنوان تابع انتقال در لایه‌ها و از تابع خطی به‌عنوان تابع انتقال خروجی استفاده گردید. در بین توابع آموزش مورد استفاده ضعیف‌ترین عملکرد در هر حالت مربوط به SCG بود. به غیر از داده‌های شب، در همه حالات بهترین عملکرد مربوط به BR بود. در مورد داده‌های شب LM بهترین عملکرد را نشان داد که البته کم‌دقت‌ترین حالت بین حالات مختلف نیز بود.

همان‌گونه که پیش‌تر بیان گردید، نتایج جدول ۲ همچنین نشان می‌دهد که جدا کردن داده‌های ساعتی SDE باعث بهبود معنی‌دار دقت پیش‌بینی مدل نمی‌شود و بنابراین از ۳۷۸۰ مدل توسعه داده شده ۱۲۶۰ مدل به‌جای می‌ماند.

نتایج ارزیابی ۱۲۶۰ مدل توسعه‌یافته باقیمانده برای پیش‌بینی SDE در جدول ۳ نشان داده شده است. پس از بررسی تمام مدل‌ها بهترین حالات برای هر کدام از توابع آموزش و در هر حالت یک یا دو لایه پنهان مشخص گردید. با توجه به نتایج جدول ۳ بهترین مدل ANN برای پیش‌بینی SDE در سامانه آبیاری خطی مربوط به الگوریتم آموزش BR بود که شامل چهار پارامتر ساعتی هواشناسی (دما، رطوبت نسبی، سرعت باد و تبخیر و تعرق مرجع) به‌عنوان ورودی مدل، ۱۹ نرون در لایه پنهان اول، ۱۶ نرون در لایه پنهان دوم و یک خروجی بود که با نماد ۴-۱۹-۱۶-۱ معمولاً نمایش داده می‌شود (جدول ۳). لذا این مدل به‌عنوان مدل پیشنهادی این پژوهش برای برآورد مقادیر ساعتی SDE معرفی می‌گردد.

اجرا شود. آموزش ممکن است با پیغام "رسیدن به حداکثر مومنتوم" متوقف شود، بدین معنی که فرایند آموزش دیگر باعث افزایش یادگیری نمی‌شود. این امر معمول می‌باشد و دلیل خوبی برای همگرایی مناسب الگوریتم است. همچنین زمانی که مجموع مربعات خطاها (SSE) و مجموع مربعات وزن‌ها (SSW) برای چندین تکرار ثابت باقی بمانند می‌توان گفت الگوریتم همگرا شده و می‌توان آموزش را متوقف نمود.

به‌منظور توسعه مدل‌های ANN، توابع آموزش LM، BR و SCG در شبکه‌های عصبی یک و دو لایه با لحاظ کردن یک تا ۲۰ نرون در هر لایه مورد بررسی و آزمون قرار گرفت. به‌عبارت‌دیگر، به‌منظور یافتن بهترین شبکه، راهبرد زیر مدنظر قرار گرفت:

۱. ایجاد شبکه‌های عصبی با یک لایه مخفی (تعداد نرون‌های لایه مخفی از ۱ تا ۲۰) و استفاده از توابع آموزش مختلف LM، SCG و BR همراه با پیش‌پردازش لازم (در مجموع ۶۰ شبکه).
۲. ایجاد شبکه‌های عصبی با دو لایه مخفی (تعداد نرون‌های هر لایه مخفی از ۱ تا ۲۰) و استفاده از توابع آموزش مختلف LM، SCG و BR همراه با پیش‌پردازش لازم (در مجموع ۱۲۰۰ شبکه).
۳. انجام مراحل ۱ و ۲ به‌طور جداگانه برای هر سری از داده‌های روز، شب و روز و شب با هم.

تمام محاسبات با استفاده از تولباکس شبکه عصبی نرم‌افزار متلب (Matlab R2015a (Mathworks, Natick, MA) انجام پذیرفت. با توجه به مراحل فوق، در مجموع ۳۷۸۰ مدل شبکه عصبی توسعه داده شد. برای انتخاب بهترین مدل ابتدا حالات جداگانه روز، شب و روز و شب با هم بررسی شد تا مشخص شود که آیا چنین تفکیکی می‌تواند به افزایش دقت منجر شود یا خیر. این بررسی با مقایسه پارامتر ضریب همبستگی (r) صورت گرفت. نتایج در جدول ۲ ارائه گردیده است. بر طبق این جدول، تفکیک داده‌های شب و روز منجر به افزایش معنی‌دار دقت نگردید و بهترین دقت در شرایطی به دست آمد که داده‌های شبانه‌روز در کنار هم لحاظ شوند و تابع آموزش BR استفاده شود (جدول ۲). با لحاظ کردن داده‌های پیوسته شبانه‌روز، فرایند انتخاب بهترین مدل ANN با در نظر گرفتن ۱۲۶۰ مدل باقیمانده ادامه یافت. در این مرحله، بهترین مدل برای هر تابع آموزش با توجه به معیارهای میانگین مربع خطا (RMSE) بر طبق رابطه (۴)، میانگین درصد خطای مطلق (MAPE) بر طبق رابطه (۵) و ضریب همبستگی r تعیین گردید.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (A_t - F_t)^2}{n}} \times 100\% \quad (4)$$

جدول ۱- ضرایب همبستگی اسپرمن برای تعیین ورودی‌های شبکه عصبی

	SDE	RH	SR	T	MWS	WS	WD	ET _o	VPD
SDE	۱	۰/۴۴ <۰/۰۰۰۱	-۰/۴ <۰/۰۰۰۱	-۰/۴۵ <۰/۰۰۰۱	-۰/۲۹ <۰/۰۰۰۱	-۰/۲۳ <۰/۰۰۰۱	۰/۰۴ ۰/۱۷۹۸	-۰/۳۹ <۰/۰۰۰۱	-۰/۲۶ <۰/۰۰۰۱
RH	۰/۴۴ <۰/۰۰۰۱	۱	-۰/۶۲ <۰/۰۰۰۱	-۰/۷۱ <۰/۰۰۰۱	-۰/۵۵ <۰/۰۰۰۱	-۰/۴۳ <۰/۰۰۰۱	۰/۲۴ <۰/۰۰۰۱	-۰/۷۷ <۰/۰۰۰۱	-۰/۷۰ <۰/۰۰۰۱
SR	-۰/۳۴ <۰/۰۰۰۱	-۰/۶۲ <۰/۰۰۰۱	۱	۰/۵۲ <۰/۰۰۰۱	۰/۴۸ <۰/۰۰۰۱	۰/۳۴ <۰/۰۰۰۱	-۰/۲۹ <۰/۰۰۰۱	۰/۸۸ <۰/۰۰۰۱	۰/۴۲ <۰/۰۰۰۱
T	-۰/۴۵ <۰/۰۰۰۱	-۰/۷۱ <۰/۰۰۰۱	۰/۵۲ <۰/۰۰۰۱	۱	۰/۳۴ <۰/۰۰۰۱	۰/۲۵ <۰/۰۰۰۱	-۰/۱۴ <۰/۰۰۰۱	۰/۶۰ <۰/۰۰۰۱	۰/۴۶ <۰/۰۰۰۱
MWS	-۰/۲۸ <۰/۰۰۰۱	-۰/۵۵ <۰/۰۰۰۱	۰/۴۸ <۰/۰۰۰۱	۰/۳۳ <۰/۰۰۰۱	۱	۰/۹۵ <۰/۰۰۰۱	۰/۰۶ ۰/۰۵۴۲	۰/۶۹ <۰/۰۰۰۱	۰/۴۶ <۰/۰۰۰۱
WS	-۰/۲۳ <۰/۰۰۰۱	-۰/۴۳ <۰/۰۰۰۱	۰/۳۴ <۰/۰۰۰۱	۰/۲۵ <۰/۰۰۰۱	۰/۹۵ <۰/۰۰۰۱	۱	۰/۲۳ <۰/۰۰۰۱	۰/۵۶ <۰/۰۰۰۱	۰/۴۰ <۰/۰۰۰۱
WD	۰/۰۴ ۰/۱۷۹۸	۰/۲۴ <۰/۰۰۰۱	-۰/۲۹ <۰/۰۰۰۱	-۰/۱۴ <۰/۰۰۰۱	۰/۰۶ ۰/۰۵۴۲	۰/۲۳ <۰/۰۰۰۱	۱	-۰/۲۱ <۰/۰۰۰۱	-۰/۱۱ ۰/۰۰۰۴
ET _o	-۰/۳۹ <۰/۰۰۰۱	-۰/۷۷ <۰/۰۰۰۱	۰/۸۸ <۰/۰۰۰۱	۰/۶۰ <۰/۰۰۰۱	۰/۶۹ <۰/۰۰۰۱	۰/۵۶ <۰/۰۰۰۱	-۰/۲۱ <۰/۰۰۰۱	۱	۰/۶۸ <۰/۰۰۰۱
VPD	-۰/۲۶ <۰/۰۰۰۱	-۰/۷۰ <۰/۰۰۰۱	۰/۴۲ <۰/۰۰۰۱	۰/۴۶ <۰/۰۰۰۱	۰/۴۶ <۰/۰۰۰۱	۰/۴۰ <۰/۰۰۰۱	-۰/۱۱ ۰/۰۰۰۴	۰/۶۸ <۰/۰۰۰۱	۱

جدول ۲- بررسی عملکرد شبکه عصبی با در نظر گرفتن جداگانه داده‌های روز، شب و شبانه‌روز

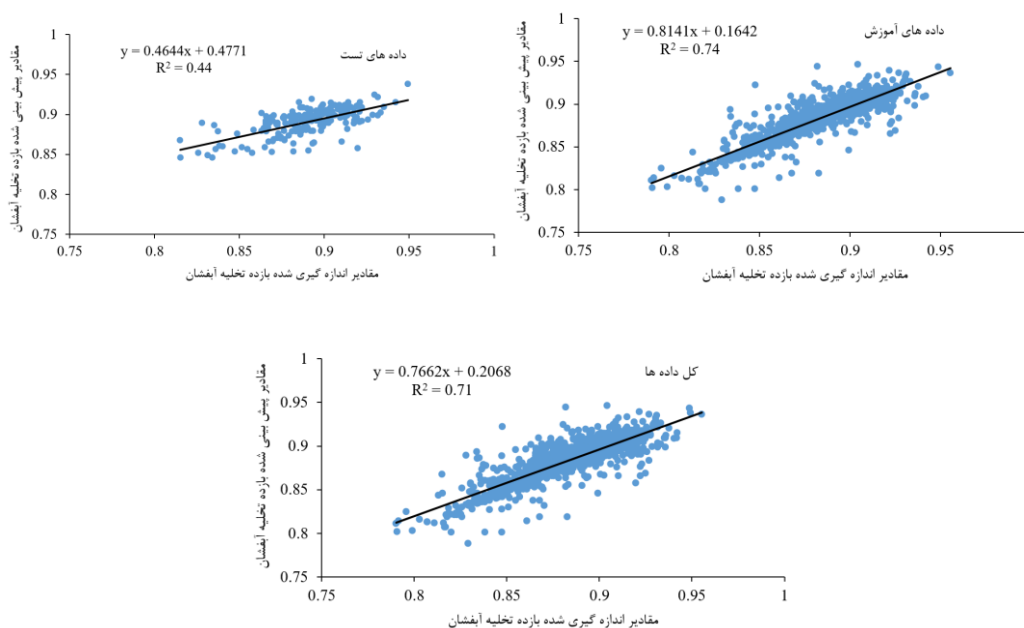
نوع داده‌های ساعتی	تعداد داده‌ها	معماری شبکه	تابع آموزش	عملکرد (r)
روز	۶۸۰	۱-۱۴-۱۶-۴	BR	۰/۸۳
شب	۳۴۴	۱-۱۰-۴	LM	۰/۵۷
شب + روز	۱۰۲۴	۱-۱۶-۱۹-۴	BR	۰/۸۳

جدول ۳- نتایج ارزیابی دقیق‌ترین الگوریتم‌های آموزش با یک یا دو لایه مخفی برای پیش‌بینی SDE

الگوریتم آموزش	تعداد لایه‌های پنهان	ساختار شبکه	r	RMSE	MAPE
LM	۱	۴-۱۶-۱	۰/۶۵۲	۰/۰۲۱	۱/۸۵۳
	۲	۴-۸-۱۰-۱	۰/۷۱۴	۰/۰۱۹	۱/۶۵۷
SCG	۱	۴-۹-۱	۰/۵۷۶	۰/۰۲۲	۲/۰۰۵
	۲	۴-۲۰-۱۵-۱	۰/۶۱۰	۰/۰۲۲	۱/۹۲۸
BR	۱	۴-۱۵-۱	۰/۶۳۸	۰/۰۱۶	۱/۲۱۰
	۲	۴-۱۹-۱۶-۱	۰/۸۴۰	۰/۰۱۵	۱/۱۹۱

جدول ۴- عملکرد مدل شبکه عصبی پیشنهادی بر روی داده‌های آموزش، تست و کل داده‌ها

نوع داده	تعداد داده	r	RMSE	MAPE
داده‌های آموزش	۸۱۸	۰/۸۶	۰/۰۱۴	۱/۱۱۳
داده‌های تست	۲۰۶	۰/۶۶	۰/۰۱۷	۱/۵۰۰
کل داده‌ها	۱۰۲۴	۰/۸۴	۰/۰۱۵	۱/۱۹۱



شکل ۴- عملکرد مدل شبکه عصبی پیشنهادی بر روی داده‌های آموزش، تست و کل داده‌ها برای پیش‌بینی SDE

جمع‌آوری آب بود. علاوه بر این، گستره اندازه‌گیری‌های WDEL آن‌ها ۱/۲٪ تا ۱۴/۷٪ با مقدار میانگین ۶/۶٪ بود (Playan et al. 2005). این دامنه کوچک‌تر از دامنه گزارش‌شده در مطالعه حاضر بوده است (۴/۵٪ تا ۲۱٪ با مقدار میانگین ۱۱/۷٪) که این مسئله احتمالاً به دلیل استفاده از قوطی‌های جمع‌آوری آب بود که ممکن است از آبیگری کامل در شرایط آب و هوایی بسیار متلاطم جلوگیری کند. همچنین، در حین آزمایش آن‌ها شرایط آب و هوایی دارای تغییرات پایین‌تری بود. به‌عنوان مثال، سرعت باد، دما و رطوبت نسبی به ترتیب بین ۰/۴-۰۶/۵۱ m/s، ۳۴/۳-۹/۹ °C و ۳۳/۸-۸۸/۷٪، تغییر می‌کرد. در مطالعه حاضر، این‌ها به ترتیب ۸-۵۰ °C، ۳/۲-۹۷/۴٪ و ۱۵/۴-۱۵/۴ اندازه‌گیری شدند. صادقی و همکاران با به‌کارگیری داده‌های مورد استفاده در مطالعه حاضر، با یک تحلیل رگرسیون خطی برای پیش‌بینی WDEL، مقدار r^2 را برابر با ۰/۳۶ به دست آوردند (Sadeghi et al., 2017) که بیانگر دقت بالاتر روش شبکه عصبی در مقایسه با تحلیل رگرسیون گام‌به‌گام می‌باشد. دقت بالاتر روش شبکه عصبی در مقایسه با تحلیل رگرسیون چندگانه برای پیش‌بینی مقادیر WDEL برای سامانه‌های آبیاری ایزوله و/یا ثابت توسط محققین گزارش شده است (Al-Ghobari et al. 2018). نتایج ما همین نتیجه‌گیری را برای سامانه‌های آبیاری متحرک تأیید می‌کند.

اخیراً، سرور و همکاران یک مدل شبکه عصبی برای پیش‌بینی WDEL تحت سامانه آبیاری خطی که در این مطالعه مورد بررسی قرار گرفت توسعه دادند. داده‌های WDEL در کار آن‌ها از طریق

همچنین، عملکرد مدل پیشنهادشده به‌طور مجزا بر روی داده‌های آموزش، تست و کل داده‌ها در جدول ۴ و شکل ۴ بیان شده است. یادآوری این نکته ضروری است که با توجه به اینکه مدل پیشنهادی از الگوریتم BR بهره می‌برد لذا در فرایند آموزش نیازی به داده‌های اعتبارسنجی نمی‌باشد و فقط داده‌های آموزش و تست مدنظر می‌باشند.

عملکرد مدل راندمان دبی آب‌پاش (و در نتیجه WDEL) برای سنتریوت‌ها بهتر از نتایج مدل‌های آماری یا رگرسیونی به‌دست آمده با استفاده از روش‌های مبتنی بر قوطی‌های جمع‌آوری آب بود. به‌عنوان مثال، اشتاینر و همکاران تعداد ۲۴ اندازه‌گیری برای تلفات آب‌پاش در یک کانوپی ذرت که توسط یک سامانه سنتریوت در آریزونا آبیاری می‌شد انجام داد. اگرچه آن‌ها یک همبستگی بین مقادیر WDEL با کمبود فشار بخار، دما و عبارتی که ترکیبی از کمبود فشار بخار و سرعت باد بود، پیدا کردند اما این‌ها تنها بخشی از تغییرات در داده‌های تست توسط قوطی‌های جمع‌آوری آب را می‌توانستند توضیح دهند (Steiner et al. 1983). اورتیز و همکاران تلفات باد بردگی و تبخیر تحت یک سنتریوت که مجهز به آب‌پاش‌هایی با نوع و ارتفاع متفاوت بود را برآورد کرده و مقادیر r^2 بین ۰/۲ تا ۰/۵۸ ($r < ۰/۷۶$) (Ortiz et al. 2009) را گزارش نمودند. در یک روش مشابه، پلایان و همکاران از روش رگرسیون خطی چندگانه گام‌به‌گام برای پیش‌بینی WDEL در یک ماشین آبیاری تجربی ثابت استفاده کرد و r^2 بین ۰/۱۱ و ۰/۷۴ ($r < ۰/۸۶$) را به دست آوردند. با این حال، مدل رگرسیون خطی آن‌ها تنها بر اساس ۵۲ آزمون قوطی

ابزارهای مبتنی بر رایانه برای کنترل آبیاری اجرا شوند. با توجه به دقت مناسب مدل شبکه عصبی برای پیش‌بینی SDE، می‌توان از آن برای ارزیابی عملکرد و نیز خودکار کردن فرایند آبیاری در سامانه‌های آبیاری بارانی استفاده نمود.

قدردانی

نویسندگان مراتب تقدیر و تشکر خود را از دکتر سید حسین صادقی به سبب همکاری‌های ارزشمند در انجام این پژوهش ابراز می‌دارند.

منابع

روحانی، ع.، ساعدی، س.ا.، گرایلو، ه. و آق‌خانی، م.ح. ۱۳۹۴. پیش‌بینی حجم، سطح جانبی و ضریب کرویت انار با استفاده از شبکه عصبی مصنوعی MLP. نشریه ماشین‌های کشاورزی. ۵ (۲): ۲۹۲-۳۰۱.

ساعدی، ا.، علیمردانی، ر. و موسی‌زاده، ح. ۱۳۹۷. پیش‌بینی میزان تابش خورشیدی با استفاده از دمای روزانه و شبکه‌های عصبی مصنوعی در اقلیم‌های مختلف آب و هوایی. نشریه ماشین‌های کشاورزی. ۸ (۱): ۱۹۷-۲۱۱.

Abo-Ghobar, H. M. 1992. Losses from low-pressure center-pivot irrigation systems in a desert climate as affected by nozzle height. *Agricultural Water Management*. 21(1): 23-32.

Al-Ghobari, H.M., El-Marazky, M.S., Dewidar, A.Z. and Mattar, M.A. 2018. Prediction of wind drift and evaporation losses from sprinkler irrigation using neural network and multiple regression techniques. *Agricultural Water Management*. 195: 211-221.

Bauder, T. A., Andales, A. A., and Waskom, R. M. 2008. Nitrogen and Irrigation Management, Colorado State University Extension.

Burt, C. M., Clemmens, A. J., Strelkoff, T. S., Solomon, K. H., Bliesner, R. D., Hardy, L. A., ... and Eisenhauer, D. E. 1997. Irrigation performance measures: efficiency and uniformity. *Journal of Irrigation and Drainage Engineering*. 123(6): 423-442.

Baiamonte, G. and Baiamonte, G. 2019. Using rotating sprinkler guns in centre-pivot irrigation systems. *Journal of Irrigation and Drainage*. 68(5): 893-908.

Cavero, J., Medina, E. T., Puig, M. and Martínez-Cob, A. 2009. Sprinkler irrigation changes maize canopy microclimate and crop water status, transpiration, and temperature. *Agronomy Journal*. 101(4): 854-864.

Dumitru, C. and Maria, V. 2013. Advantages and Disadvantages of Using Neural Networks for Predictions. *Ovidius University Annals, Series Economic Sciences*. 13(1).

Faci, J. M., Salvador, R., Playán, E and Sourell, H. 2001.

داده‌برداری توسط ۷۲ قوطی جمع‌آوری آب صورت گرفت (Sarwar et al. 2019a). مدل شبکه عصبی ما در پژوهش حاضر بر اساس داده‌های بسیار بیشتری (یعنی ۱۰۲۴ داده) ساخته شد که عملکرد بهتری را هم در بر داشت ($RMSE = ۱/۶\%$ در مقایسه با $۲\% = RMSE$ در Sarwar et al., 2019a). چنین دقت بالایی مجدداً قابلیت اعتماد روش "نواری" که در این پژوهش مورد استفاده قرار گرفت را به اثبات می‌رساند. شایان‌ذکر است که مدل شبکه عصبی SDE یک مدل تجربی است و بنابراین ممکن است در شرایطی که داده‌های آب و هوایی فراتر و متفاوت‌تر از محدوده داده‌های عددی مورد استفاده در این مطالعه اتفاق بیفتد ممکن است برآوردهای SDE دقیقی بر جای نگذارد. فاکتورهای غیر زیستی مثل نوع، قطر، ارتفاع، فشار و فاصله‌گذاری بین آب‌پاش‌ها و همچنین وجود کانوپی محصول اثر قابل ملاحظه‌ای بر SDE در ماشین‌های آبیاری متحرک خواهد داشت؛ بنابراین، اگرچه یک شبکه عصبی مصنوعی می‌تواند به عنوان یک ابزار بسیار خوب برای برآورد SDE به صورت تابعی از پارامترهای آب و هوایی در سنتریوت‌ها (یا سامانه‌های آبیاری خطی) به حساب آید، اما مدل ANN پیشنهادی در اینجا ممکن است برای سامانه‌های با طراحی متفاوت و/یا شرایط آب و هوایی متفاوت دقت لازم را در بر نداشته باشد. لذا بایستی تلاش‌های بیشتری صورت گیرد تا مدل‌های ANN کاربردی‌تری توسعه داد که بتوانند هم‌زمان هم عوامل زیستی و هم عوامل غیر زیستی مؤثر بر SDE در سامانه‌های آبیاری سنتریوت را لحاظ نمایند. یک چنین مدل‌های ANN اخیراً برای پیش‌بینی WDEL در سامانه‌های ایزوله و/یا سیستم‌های آبیاری ثابت توسعه داده شده‌اند (Al-Ghobari et al., 2018; Marey et al., 2018; Maroufpoor et al., 2018).

نتیجه‌گیری

این مطالعه نشان داد که شبکه‌های عصبی مصنوعی ابزاری قابل اطمینان برای پیش‌بینی راندمان دبی آب‌پاش و به دنبال آن WDEL تحت ماشین‌های آبیاری متحرک است. در مقایسه با مدل‌های پیشین مبتنی بر رگرسیون خطی، شبکه‌های عصبی نه تنها پیشگویی بهتری به همراه دارند بلکه قابلیت اطمینان بالاتری نیز دارند چرا که همانند روش‌های مبتنی بر قوطی‌های جمع‌آوری آب محدود به تعداد داده کمی نمی‌باشند. مدل شبکه عصبی پیشنهادی دارای چهار ورودی (دما، رطوبت نسبی، سرعت باد و تبخیر و تعرق مرجح)، ۱۹ نرون در اولین لایه پنهان، ۱۶ نرون در لایه پنهان دوم و یک خروجی می‌باشد که مقادیر SDE و به دنبال آن WDEL را به صورت ساعتی پیش‌بینی می‌کند. گرچه توصیف ریاضی مدل‌های شبکه عصبی ممکن است دشوار باشد اما می‌توانند به راحتی توسط میکروپروسورها در پنل کنترل سنتریوت و یا توسط کنترلرها یا

- Omid, M., Mahmoudi, A. and Omid MH. 2010. Development of pistachio sorting system using principal component analysis (PCA) assisted artificial neural network (ANN) of impact acoustics. *Expert Systems With Applications*. 37 (10): 7205–7212.
- Opoku, R. D., Shouqi, Y., Junping, L. and Livingstone, S. A. 2018. Droplet characterization and water distribution of fixed spray plate sprinkler used in linearly moved irrigation system. *Poljoprivredna tehnika*. 43(2): 17–29.
- Ortiz, J. N., Tarjuelo, J. M. and De Juan, J. A. 2009. Characterization of evaporation and drift losses with center pivots. *Agricultural Water Management*. 96(11): 1541–1546.
- Peters, R. T. and Evett, S. R. 2007. Spatial and temporal analysis of crop conditions using multiple canopy temperature maps created with center-pivot-mounted infrared thermometers. *Trans. ASABE*, 50(3): 919–927.
- Playán, E., Garrido, S., Faci, J. M. and Galán, A. 2004. Characterizing pivot sprinklers using an experimental irrigation machine. *Agricultural Water Management*. 70(3): 177–193.
- Playán, E., Salvador, R., Faci, J. M., Zapata, N., Martínez-Cob, A. and Sánchez, I. 2005. Day and night wind drift and evaporation losses in sprinkler solid-sets and moving laterals. *Agricultural Water Management*. 76(3): 139–159.
- Rajan, N., Maas, S., Kellison, R., Dollar, M., Cui, S., Sharma, S., and Attia, A. 2015. Emitter Uniformity and Application Efficiency for Centre-Pivot Irrigation Systems. *Journal of Irrigation and Drainage*. 64(3): 353–361.
- Raju, K. S., Kumar, D. N. and Duckstein, L. 2006. Artificial neural networks and multicriterion analysis for sustainable irrigation planning. *Computers and Operations Research*. 33(4): 1138–1153.
- Sadeghi, S. H., Peters, T. R., Amini, M. Z., Malone, S. L. and Loescher, H. W. 2015. Novel approach to evaluate the dynamic variation of wind drift and evaporation losses under moving irrigation systems. *Biosystems Engineering*. 135: 44–53.
- Sadeghi, S. H., Peters, T., Shafii, B., Amini, M. Z. and Stöckle, C. 2017. Continuous variation of wind drift and evaporation losses under a linear move irrigation system. *Agricultural Water Management*. 182: 39–54.
- Santos, F. L., Reis, J. L., Martins, O. C., Castanheira, N. L., and Serralheiro, R. P. 2003. Comparative assessment of infiltration, runoff and erosion of sprinkler irrigated soils. *Biosystems Engineering*. 86(3): 355–364.
- Sarwar, A., Peters, R. T. and Mohamed, A. Z. 2019a. Linear mixed modeling and artificial neural network techniques for predicting wind drift and evaporation losses under moving sprinkler irrigation systems. *Irrigation Science*. 1–12.
- Sarwar, A., Peters, R. T., Mehanna, H., Amini, M. Z. and Mohamed, A. Z. 2019b. Evaluating water application efficiency of low and mid elevation spray application under changing weather conditions. *Agricultural Water Management*. 221: 84–91.
- Steiner, J.L., E.T. Kanemasu and R.N. Clark. 1983. Spray losses and partitioning of water under a center pivot Comparison of fixed and rotating spray plate sprinklers. *Journal of Irrigation and Drainage Engineering*. 127(4): 224–233.
- Keller, J. and Bliesner, R. D. 1990. Sprinkle and trickle irrigation. Van Nostrand Reinhold.
- King, B. A., Dungan, R. S. and Bjorneberg, D. L. 2012. Evaluation of center pivot sprinkler wind drift and evaporation loss. In 2012 Dallas, Texas, July 29-August 1, 2012 (p. 1). American Society of Agricultural and Biological Engineers.
- King, B. A., Bjorneberg, D. L., Trout, T. J., Mateos, L., Araujo, D. F. and Costa, R. N. 2015. Estimation of furrow irrigation sediment loss using an artificial neural network. *Journal of Irrigation and Drainage Engineering*. 142(1), 04015031.
- Kohl, K. D., R. A. Kohl. and D. W. DeBoer. 1987. Measurement of low pressure sprinkler loss. *Transactions of the ASABE*. 30(4):1071–1074.
- Lamm, F. R., O'Brien, D. M., and Rogers, D. H. 2015. Economic comparison of subsurface drip and center pivot sprinkler irrigation using spreadsheet software. *Applied Engineering in Agriculture*. 31(6): 929.
- Lazarovitch, N., Poulton, M., Furman, A. and Warrick, A. W. 2009. Water distribution under trickle irrigation predicted using artificial neural networks. *The Journal of Engineering Mathematics*. 64(2): 207–218.
- Liu, J., Liu, X., Zhu, X. and Yuan, S. 2016. Droplet characterisation of a complete fluidic sprinkler with different nozzle dimensions. *Biosystems Engineering*. 148: 90–100.
- Luz, P. B., and Heermann, D. 2005. A statistical approach to estimating runoff in center pivot irrigation with crust conditions. *Agricultural Water Management*. 72(1): 33–46.
- Marey, S.A., El Marazky, M.S.A. and Aboukarima, A.M. 2018. Prediction of wind drift and evaporation losses of a sprinkler irrigation system using principal component analysis and artificial neural network technique. *Water Sa*. 44: 338–347.
- Maroufpoor, E., Sanikhani, H., Emamgholizadeh, S. and Kisi, O. 2018. Estimation of Wind Drift and Evaporation Losses from Sprinkler Irrigation systemS by Different Data-Driven Methods. *Journal of Irrigation and Drainage*. 67: 222–232.
- Mattar, M. A., Alazba, A. A. and El-Abedin, T. Z. 2015. Forecasting furrow irrigation infiltration using artificial neural networks. *Agricultural Water Management*. 148, 63–71.
- Mokeba, M. L., Salt, D. W., Lee, B. E. and Ford, M. G. 1997. Simulating the dynamics of spray droplets in the atmosphere using ballistic and random-walk models combined. *Journal of Wind Engineering and Industrial Aerodynamics*. 67: 923–933.
- Molle, B., Tomas, S., Hendawi, M. and Granier, J. 2012. Evaporation and wind drift losses during sprinkler irrigation influenced by droplet size distribution. *Journal of Irrigation and Drainage*. 61(2): 240–250.

- evaporation of intercepted water in improving irrigation efficiency. *Irrig. Sci.* 16:89–95.
- Trimmer, W.L. 1987. Sprinkler evaporation loss equation. *J. Irrig. Drain. Eng.*, ASCE 113 (4): 616–620.
- Tu, J. V. 1996. Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *The Journal of Clinical Epidemiology*. 49(11): 1225–1231.
- Urrego-Pereira, Y., Cavero, J., Medina, E. T. and Martínez-Cob, A. 2013. Role of transpiration reduction during center-pivot sprinkler irrigation in application efficiency. *Journal of Irrigation and Drainage Engineering*. 139(3): 221–232.
- Yazar, A. 1984. Evaporation and drift losses from sprinkler irrigation systems under various operating conditions. *Agricultural Water Management*. 8: 439–449.
- sprinkler system. *Transactions of the ASABE*. 26(4): 1128–1134.
- Thompson, A. L., Gilley, J. R. and Norman, J. M. 1993a. A sprinkler water droplet evaporation and plant canopy model: I. Model development. *Transactions of the ASABE*. 36(3): 735–741.
- Thompson, A. L., Gilley, J. R. and Norman, J. M. 1993b. A sprinkler water droplet evaporation and plant canopy model: II. Model application. *Transactions of the ASABE*. 36(3): 743–750.
- Thompson, A. L., Martin, D. L., Norman, J. M., Tolk, J. A., Howell, T. A., Gilley, J. R. and Schneider, A. D. 1997. Testing of a water loss distribution model for moving sprinkler systems. *Transactions of the ASAE*. 40(1): 81–88.
- Tolk, J.A., Howell, T.A., Steiner, J.L., Krieg, D.R. and A.D. Schneider. 1995. Role of transpiration suppression by

Prediction of Wind Drift and Evaporation Losses in Sprinkler Irrigation Systems Using Artificial Neural Networks

S.I. Saedi^{1*}, R.T. Peters²

Received: Feb.01, 2022

Accepted: Mar.14, 2022

Abstract

Wind drift and evaporation loss (WDEL) in sprinkler irrigation systems are a factor that affects the water delivery in a field and reduce the uniformity of spraying. So, predicting these losses can play an essential role in improving their performance of them. In this study, artificial neural networks (ANNs) have been used to estimate the hourly sprinkler discharge efficiency (SDE), which, in turn, is dependent on WDEL. The effective parameters in estimating WDEL, which were considered as model inputs, were selected by calculating Spearman rank correlation coefficients. Accordingly, wind speed, temperature, relative humidity, and reference evapotranspiration were considered as model inputs, whereas SDE was considered as model output. The performance evaluation of the developed neural network model was done using 1024 real data obtained by the Strip structure for estimating WDEL. The proposed model, which was a 4-19-16-1 model with a Bayesian regularization training function, was selected upon testing 3780 different neural networks. The results of this study showed that the developed model can accurately estimate the hourly values of sprinkler discharge efficiency ($R= 0.84$, $RMSE= 1.6\%$, $MAPE= 1.19$) and can be used as a reliable method for evaluating the performance of sprinkler irrigation systems.

Keywords: ANN, Irrigation Uniformity, Sprinkler, WDEL

1- Assistant Professor, Department of Water and Soil Sciences, Faculty of Agricultural Engineering, Shahrood University of Technology, Shahrood, Iran

2- Professor, Department of Biological Systems Engineering, Washington State University, Pullman, WA, USA

(*- Corresponding Author Email: isaedi@shahroodut.ac.ir)