



## Assessment of Factors Effective on Forecasting of Debris Floods Using Bayesian Network Model

M. Sheikh Kazemi<sup>1</sup>, M.E. Banihabib<sup>2\*</sup>, J. Soltani<sup>3</sup>,  
A. Roozbahani<sup>4</sup>, and M. Tanhapour<sup>5</sup>

### Abstract

Predicting debris floods is important in reducing their damages. The aim of this study is the prediction of sediment concentration of debris floods and ordinary floods in Ammameh, Navrood and Casilian basins which are located in Tehran, Gilan and Mazandaran provinces, respectively, using bayesian network (BN) and artificial neural network (ANN) models. Accordingly, average basin elevation (EL), average basin slope (S), watershed area (A), current day rainfall (R), antecedent rainfall for the last 3 days (AR) and previous day discharge were selected as input variables. Then, 32 scenarios were tested to determine the most effective factors on the sediment concentration of flood. For the scenario derived from all selected factors, indices  $R^2$  and MAPE in the test stage were obtained as 0.97 and 8.55%, respectively. Assessment of the effect of different factors showed that the the accuracy of the BN model's prediction are most affected by EL, R, PQ, A and 1-day AR. Indices  $R^2$  and MAPE for this scenario were obtained 0.916 and 11.01%, respectively. It was selected as the best scenario due to the least number of predictors and the highest accuracy. The most effective factors identified in this study can be used to predict debris flood in similar basins.

**Keywords:** Debris Flood, Sediment Concentration, Bayesian Network Model, Artificial Neural Network.

Received: September 4, 2019

Accepted: January 13, 2020

## ارزیابی اثر متغیرهای تأثیرگذار بر پیش‌بینی سیلاب واریزه‌ای با استفاده از مدل شبکه بیزین

مهسا شیخ کاظمی<sup>۱</sup>، محمدابراهیم بنی حبیب<sup>۲\*</sup>، جابر سلطانی<sup>۳</sup>،  
عباس روزبهرانی<sup>۴</sup>، میترا تنهاپور<sup>۵</sup>

### چکیده

پیش‌بینی سیلاب واریزه‌ای جهت کاهش خسارات ناشی از آن از اهمیت ویژه‌ای برخوردار است. هدف این تحقیق پیش‌بینی غلظت رسوبات سیلاب (واریزه‌ای و معمولی) توسط مدل‌های شبکه بیزین و شبکه عصبی در حوضه‌های امامه، ناورود و کسلیان است که به ترتیب در استان‌های تهران، گیلان و مازندران واقع شده‌اند. بدین منظور، متوسط ارتفاع، شیب حوضه، مساحت حوضه، بارش فعلی، بارش پیشین (به مدت ۳ روز قبل) و دبی ۱ روز قبل به عنوان متغیرهای ورودی انتخاب شدند. سپس برای تعیین مؤثرترین عوامل بر غلظت رسوبات سیلاب، ۳۲ سناریو ارزیابی شد. برای سناریو حاصل از کلیه عوامل منتخب، شاخص‌های  $R^2$  و MAPE در مرحله آزمون، به ترتیب ۰/۹۷ و ۸/۵۵٪ برآورد گردید. ارزیابی اثر متغیرهای مختلف نشان داد مؤثرترین عوامل بر دقت پیش‌بینی شبکه بیزین به ترتیب ارتفاع حوضه، بارش فعلی، دبی روز قبل، مساحت حوضه و بارش پیشین یک روز قبل می‌باشند. شاخص‌های  $R^2$  و MAPE برای این سناریو ۰/۹۱ و ۱۱/۰۱٪ است که به دلیل داشتن کمترین تعداد عوامل ورودی و بالاترین دقت به عنوان بهترین سناریو انتخاب گردید. مقایسه عملکرد مدل بیزین با مدل شبکه عصبی نشان داد مدل شبکه بیزین دقت پیش‌بینی بالاتری دارد. مؤثرترین عوامل شناسایی شده می‌تواند برای پیش‌بینی سیلاب واریزه‌ای در حوضه‌های مشابه استفاده گردد.

**کلمات کلیدی:** سیلاب واریزه‌ای، غلظت رسوب، مدل شبکه بیزین، مدل شبکه عصبی.

تاریخ دریافت مقاله: ۹۸/۶/۱۳

تاریخ پذیرش مقاله: ۹۸/۱۰/۲۳

1- M.Sc. Student, Hydraulic Structures, College of Abouraihan, University of Tehran, Tehran, Iran.

2- Professor, Department of Irrigation and Drainage Engineering, College of Abouraihan, University of Tehran, Tehran, Iran. Email: [banihabib@ut.ac.ir](mailto:banihabib@ut.ac.ir)

3- Assistant Professor, Department of Irrigation and Drainage Engineering, College of Abouraihan, University of Tehran, Tehran, Iran. Email: [jsoltani@ut.ac.ir](mailto:jsoltani@ut.ac.ir)

4- Associate Professor, Department of Irrigation and Drainage Engineering, College of Abouraihan, University of Tehran, Tehran, Iran. Email: [roozbahany@ut.ac.ir](mailto:roozbahany@ut.ac.ir)

5- Ph.D. Student, Water Resources Engineering, College of Abouraihan, University of Tehran, Tehran, Iran.

\*- Corresponding Author

۱- دانشجوی کارشناسی ارشد سازه‌های آبی، دانشکده پردیس ابوریحان، دانشگاه تهران.

۲- استاد گروه مهندسی آبیاری و زهکشی، دانشکده پردیس ابوریحان، دانشگاه تهران.

۳- استادیار گروه مهندسی آبیاری و زهکشی، دانشکده پردیس ابوریحان، دانشگاه تهران.

۴- دانشیار گروه مهندسی آبیاری و زهکشی، دانشکده پردیس ابوریحان، دانشگاه تهران.

۵- دانشجوی دکتری مهندسی منابع آب، دانشکده پردیس ابوریحان، دانشگاه تهران.

\*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان زمستان ۱۳۹۹ امکانپذیر است.

## ۱- مقدمه

(Lin et al., 2012) در این زمینه صورت گرفته است. مدل‌های مذکور در پیش‌بینی سیلاب واریزه‌ای به کار رفتند اما تحقیقات محدودی توسط مدل بیزین در این زمینه انجام شده است.

برخی از محققان برای پیش‌بینی سیلاب از مدل شبکه بیزین استفاده کردند. (Peng and Zhang, 2012; Tanhapour et al., 2017). Peng and Zhang (2012) از مدل شبکه بیزین برای تحلیل خطر سیلاب در اثر فاجعه شکست سد، استفاده کردند. آن‌ها نشان دادند، شدت سیلاب، عمق آب، تخلیه و زمان هشدار مهم‌ترین عوامل مؤثر بر مرگ و میر است. (Tanhapour et al., 2017). اثر بارش پیشین بر رخداد سیلاب واریزه‌ای با استفاده از مدل شبکه بیزین در ناحیه البرز ایران ارزیابی نمودند. آن‌ها وقایع بارندگی را یک بار به صورت مجزا و بار دیگر به صورت تجمعی به عنوان ورودی مدل در نظر گرفتند و به شکل سناریوهای مختلف ارزیابی کردند. نتایج این تحقیق نشان داد، دقت مدل در حالت بارش پیشین مجزا، ۱۳ درصد نسبت به حالت بارش پیشین تجمعی بیشتر است و بالاترین دقت مدل به ازای سناریو بارش پیشین ۳ روز قبل به صورت مجزا، معادل ۹۱ درصد برآورد شد. اما آن‌ها از مدل بیزین برای پیش‌بینی وقوع یا عدم وقوع سیلاب واریزه‌ای استفاده کردند و غلظت رسوبات سیلاب واریزه‌ای را پیش‌بینی نکردند لذا در این پژوهش علاوه بر پیش‌بینی غلظت رسوبات، جهت ارزیابی عملکرد مدل از تعداد بیشتری باران سنج استفاده شده است و توانایی پیش‌بینی مدل در اثر افزایش تعداد ایستگاه‌های باران سنج مورد بررسی واقع شده است.

با توجه به اینکه عوامل مختلفی در وقوع سیلاب واریزه‌ای تأثیرگذار هستند و جمع‌آوری کلیه عوامل هزینه‌بر است، به منظور ارائه مدلی عملی‌تر و تعیین مؤثرترین عوامل در بهبود توانایی مدل برای پیش‌بینی غلظت رسوبات سیلاب واریزه‌ای و معمولی، انجام این تحقیق ضرورت پیدا می‌کند. پیش‌بینی غلظت رسوبات سیلاب واریزه‌ای در تعیین ضریب زبری جریان و دبی پیک این سیلاب‌ها حائز اهمیت است (Banihabib and Forghani, 2017; Banihabib and Masumi, 2008). در این تحقیق جهت پیش‌بینی غلظت رسوبات سیلاب واریزه‌ای، در ۳ حوضه واقع در استان‌های گیلان، مازندران و تهران از مدل‌های شبکه بیزین و شبکه عصبی استفاده شده است و سناریوهای مختلفی جهت شناسایی مؤثرترین عوامل بر دقت پیش‌بینی مدل ارزیابی شده است تا با صرف حداقل زمان و هزینه ممکن بتوان نتایج قابل اعتمادی ارائه داد. لازم به ذکر است در این تحقیق از شبکه‌ای از باران‌سنج‌ها برای هر حوضه به منظور ارزیابی اثر آن‌ها بر دقت پیش‌بینی مدل استفاده شده است.

سیلاب واریزه‌ای نوعی از سیلاب با غلظت رسوب بالا است که بر زبری هیدرولیکی جریان تأثیر می‌گذارد. این جریان با سرعت زیاد حرکت نموده و دارای قدرت تخریب بالایی می‌باشد و با محدوده چگالی جرمی بین  $1/3$  تا  $2/3$  تن در مترمکعب، سرعت ۳ تا ۱۵ متر بر ثانیه مشخص می‌شود (Banihabib and Forghani, 2017; Zhuang et al., 2015; Banihabib, 2002). سیلاب واریزه‌ای عمدتاً در نواحی نیمه‌خشک، کوهستانی شیب‌دار و آتشفشانی به وقوع می‌پیوندد (Banihabib, 2002). بطور کلی با توجه به ویژگی‌های ذکر شده در فوق می‌توان سیلاب‌های واریزه‌ای را شناسایی نمود.

سیلاب‌های واریزه‌ای از جمله حوادث طبیعی هستند که تهدیدی جدی برای جان، مال و توسعه اقتصادی بشر می‌باشند (Banihabib and Forghani, 2017). سیلاب‌های واریزه‌ای اغلب به طور ناگهانی به ویژه در مناطق شیب‌دار کوهستانی رخ می‌دهند و بر اقتصاد محلی، زندگی و زیرساخت‌ها (مانند سدها و جاده‌ها) در شهرها و روستاها اثرگذار است (Banihabib and Bahram, 2009; Esfahani and Banihabib, 2016). با توجه به خسارات عظیم این پدیده و رخداد مکرر آن پیش‌بینی سیلاب واریزه‌ای به منظور کاهش خسارات ناشی از آن ضروری است (Jakob and Weatherly, 2003; Tanhapour et al., 2017).

در سال‌های اخیر، تحقیقات گسترده‌ای توسط محققان مختلف (Zhang et al., 2013; Peng, 2016) در زمینه تخمین رواناب و رسوب (Asadi et al., 2019) و ارزیابی خطرات وقوع سیلاب واریزه‌ای، با استفاده از روش‌های متعدد هوش مصنوعی انجام شده است. هوش مصنوعی از جمله روش‌های محاسباتی جدیدی هستند که برای بسیاری از مسائل هیدرولیک، هیدرولوژی و منابع آب به کار گرفته شده‌اند (Hirano et al., 1995; Sharghi et al., 2019). از مدل شبکه عصبی برای پیش‌بینی رخداد سیلاب واریزه‌ای و تحلیل آن استفاده کردند. نتایج تحقیقات آن‌ها نشان می‌داد، مدل شبکه عصبی، علاوه بر پیش‌بینی سیلاب واریزه‌ای، می‌تواند برای برآورد رواناب این سیلاب‌ها به خوبی عمل کند. (Kern et al., 2017). برای پیش‌بینی وقایع سیلاب واریزه‌ای در رشته کوه غربی ایالات متحده از روش‌های تکنیکی یادگیری ماشین از جمله رگرسیون لجستیک، آنالیز واریانس، درخت تصمیم‌گیری، شبکه عصبی، K نزدیکترین همسایگی و ماشین بردار پشتیبان استفاده کردند. نتایج تحقیق این محققان، برتری روش‌های هوش مصنوعی نسبت به روش‌های آماری را ثابت می‌کرد. تحقیقات مشابه توسط سایر محققین (Nikolopoulos et al., 2018);

## ۲- روش تحقیق

### ۱-۲- منطقه مورد مطالعه

معمولی، داده‌های روزانه دبی جریان (متر مکعب در ثانیه) و دبی رسوب (تن در روز) برای مجموعه حوضه‌های یاد شده در محدوده سال‌های ۱۳۹۵-۱۳۷۶، از سازمان مدیریت منابع آب ایران اخذ گردید. برای مجموعه ایستگاه‌های یاد شده، غلظت رسوبات، مطابق رابطه ۱ محاسبه شد. بدین ترتیب، در صورتی که غلظت بدون بعد رسوب سیلاب (حجم رسوب به حجم جریان) بیشتر از ۰/۰۲ شود، سیلاب واریزه‌ای رخ داده است (Hirano et al., 1997; Banihabib, 1999). در این رابطه،  $C$  بیانگر غلظت حجمی رسوبات سیلاب واریزه‌ای،  $q_s$  دبی رسوب و  $q_w$  دبی جریان آب است.

$$C = \frac{q_s}{q_w} \quad (1)$$

در این مطالعه، از اطلاعات مربوط به سه حوزه آبریز شامل کسلیان در استان مازندران، ناورود اسالم در استان گیلان و امامه در شمال استان تهران استفاده شده است. شکل ۱، (الف، ب و پ) موقعیت ایستگاه‌های هیدرومتری که در آن‌ها سیلاب (واریزه‌ای و معمولی) رخ داده را نشان می‌دهد. مناطق مورد مطالعه در این تحقیق بخشی از ناحیه خزری هستند که بیشتر مستعد بارندگی سنگین و به تبع آن وقوع سیلاب به ویژه سیلاب واریزه‌ای می‌باشند.

### ۲-۲- داده‌های ورودی و وقایع سیلاب واریزه‌ای

وقوع سیلاب توسط عوامل پیچیده‌ای مانند آب و هوا، زمین‌شناسی، توپوگرافی و هیدرولوژی تحت تأثیر قرار می‌گیرد (Liang et al., 2012). به طور کلی، دو عامل اساسی شامل عوامل فیزیوگرافی (مساحت حوضه، طول رودخانه، شکل حوضه و شیب تند) و عوامل هیدرولوژیکی (رطوبت کافی، بارندگی‌های شدید) در شکل‌گیری سیلاب واریزه‌ای مؤثر می‌باشند (Chang et al., 2010). در این تحقیق، برای پیش‌بینی غلظت رسوبات سیلاب واریزه‌ای و

### ۳-۲- معرفی شبکه‌های بیزین

شبکه بیزین برای اولین بار توسط جودا پرل در سال ۱۹۸۸ طراحی شد (Pearl, 1988). از مزایای مهم این مدل می‌توان به مواردی از قبیل تحلیل ریسک و عدم قطعیت با دقت بیشتر نسبت به سایر مدل‌ها، امکان توسعه شبکه در حالت وجود داده‌های ناقص، امکان و سهولت

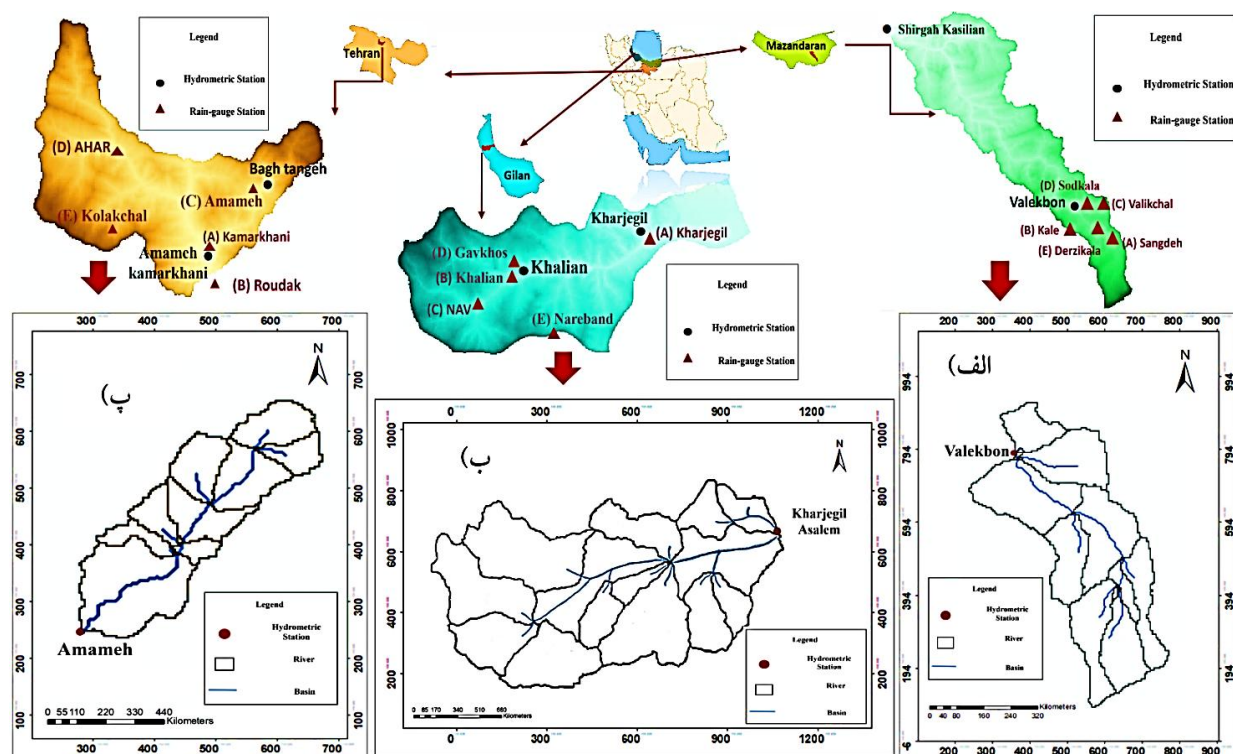


Fig. 1- Location of hydrometric stations of basins a) Casilian b) Navrood c) Amameh

شکل ۱- موقعیت ایستگاه‌های هیدرومتری حوضه‌های الف (کسلیان، ب (ناورود پ) امامه

تحقیق حاضر، از الگوریتم یادگیری EM برای آموزش پارامترها استفاده شده است.

آموزش ساختار به معنای تعیین متغیرهای وابسته و مستقل و یافتن ارتباطهای ممکن بین متغیرها به صورت کیفی است و هدف اصلی آن، پیدا کردن بهترین ساختار برای شبکه بیزین است (Liang et al., 2012). برای یادگیری ساختار می توان از الگوریتم یادگیری بر مبنای محدودیت استفاده کرد که بر اساس استقلال شرطی و وابستگی بین متغیرها، توسط آزمونهای آماری به دست می آید (مانند الگوریتمهای PC و NPC<sup>3</sup>). در صورتیکه متخصص از ساختار شبکه و ارتباط میان گرهها مطمئن باشد، نیازی به استفاده از الگوریتمهای یادگیری ساختار نیست و ارتباطات توسط متخصص تعیین می گردد (Anbari et al., 2017). بنابراین در این تحقیق از هیچ یک از الگوریتمهای یادگیری ساختار استفاده نشده است.

#### ۲-۵- ساختار شبکه بیزین

در این تحقیق، از نرم افزار Hugin 8.4 (Hugin expert A/S., 2014) برای یادگیری ساختار شبکه بیزین استفاده شده است (Madsen et al., 2003). گرههای شبکه بیزین در جدول ۱ معرفی شدند. همچنین ساختار گرافیکی سناریو مبنا متشکل از کلیه عوامل پیش بینی کننده در شکل ۲ نشان داده شده است. هر گره در ساختار شبکه می تواند یکی از سه حالت، شامل گره والد، گره ولد وضعیت و یا گره ولد خروجی را به خود اختصاص دهد (Mohajerani et al., 2010). گرههایی که هیچ پیکانی به آنها وارد نشده، گرههای والد هستند (مانند متغیرهای متوسط ارتفاع و مساحت حوضه در شکل ۲). گرههایی که از آنها هیچ پیکانی خارج نمی شود، گرههای ولد خروجی نام دارند (مانند متغیر غلظت رسوبات در شکل ۲). همچنین گرهی که پیکان به آن وارد و از آن خارج می شود گره ولد وضعیت نام دارد (همانند متغیرهای شیب، دبی جریان روز قبل و بارش فعلی و پیشین).

#### ۲-۶- مدل شبکه عصبی مصنوعی<sup>۴</sup> (ANN)

شبکه عصبی مصنوعی اولین بار در سال ۱۹۴۳ معرفی شد و یک سیستم پردازش اطلاعات است که ویژگیهای عملکرد آن شبیه به شبکه عصبی مغز انسان است. با توجه به نوع الگوریتم یادگیری، مدل های ANN عمدتاً به شبکههای پیشخور<sup>۵</sup> و شبکههای پسخور<sup>۶</sup> تقسیم بندی می شوند. شبکه پرسپترون چند لایه<sup>۷</sup>، یکی از انواع شبکههای پیشخور است که از سه لایه ورودی، خروجی و میانی (لایه پنهان) تشکیل شده اند.

به روزرسانی پارامترها و احتمالات شرطی بین پارامترهای مختلف، اشاره کرد. این شبکهها را می توان به سه دسته شبکههای بیزین گسسته، پیوسته و هیبرید تقسیم بندی نمود (Lerner, 2002). در صورتی که متغیر پیش بینی شونده کیفی باشد شبکه بیزین گسسته و در حالتی که متغیر پیش بینی شونده از نوع عددی و کمی باشد، شبکه بیزین پیوسته است. همچنین شبکه بیزین هیبرید ترکیبی از دو حالت مذکور است (Lerner, 2002).

شبکه بیزین از دو جزء اصلی کمی و کیفی تشکیل می شود (Khakzad et al., 2011). جزء کیفی شبکه از ترکیب گره و کمان تشکیل شده که گرهها بیانگر متغیرهای مسأله و کمانها نشانگر اثرات و ارتباطات متقابل بین متغیرها است (Bromley et al., 2005; Aguilera et al., 2011). همچنین مدل شبکه بیزین کمیت ارتباط میان متغیرها را به صورت عددی و از طریق توزیع احتمال مشترک، با استفاده از جداول احتمالات شرطی که به جداول CPT<sup>۸</sup> معروفند، به نمایش می گذارد. این شبکه یکی از روشهای نوین گرافیکی احتمالاتی است که اساس آن بر مبنای تئوری بیز استوار است. این قاعده اولین بار توسط توماس بیز در قرن ۱۸ میلادی به وجود آمد که به صورت زیر است (Aguilera et al., 2011; Ebrahimi et al., 2015):

اگر E و F دو رویداد مفروض باشند، به گونه ای که  $P(E) \neq 0$  و  $P(F) \neq 0$  آنگاه داریم:

$$P(E/F) = \frac{P(E)P(F/E)}{P(F)} \quad (2)$$

همچنین برای n رویداد شامل  $E_1, E_2, \dots, E_n$  که  $P(E) \neq 0$  باشد، برای  $1 \leq i \leq n$  داریم:

$$P(E_i/F) = \frac{P(F/E_i)P(E_i)}{P(F/E_1)P(E_1) + P(F/E_2)P(E_2) + \dots + P(F/E_n)P(E_n)} \quad (3)$$

#### ۲-۴- روش های آموزش مدل شبکه بیزین

روش های یادگیری شبکه بیزین به دو دسته شامل یادگیری پارامتری و یادگیری ساختاری تقسیم می شود. آموزش پارامترها به معنی تعیین احتمالات شرطی بین هر دو گره از شبکه، با داشتن ساختار آموزش دیده آن و همچنین داده های مشاهداتی است (Hesar et al., 2012). در شبکه های بیزین الگوریتم EM<sup>۲</sup> وظیفه یادگیری پارامترها را بر عهده دارد. این الگوریتم، بر اساس داده های مشاهداتی، توزیع احتمالات شرطی برای هر گره را برآورد می کند و با انجام یک فرآیند تکراری، در هر بار تکرار، لگاریتم احتمال داده ها را با توجه به توزیع احتمال توأم موجود، محاسبه می کند (Tanhapour et al., 2017).

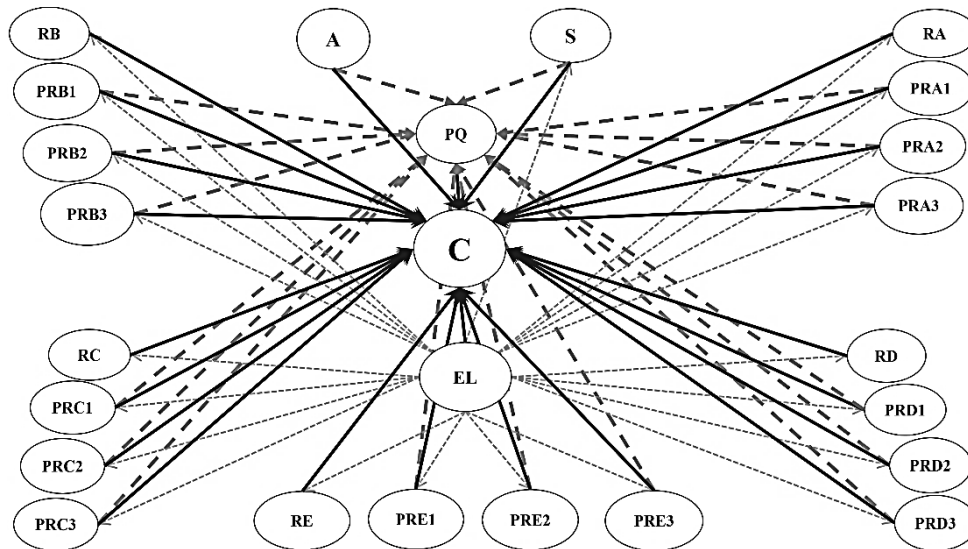


Fig. 2- Graphical structure of basic scenario  
شکل ۲- ساختار گرافیکی سناریو مبنا

Table 1- The set of used variables in the Bayesian Network model  
جدول ۱- مجموعه متغیرهای مورد استفاده در مدل شبکه بیزین

BN Variable	Symbol	BN Variable	Symbol
Basin area	A	2-day Antecedent rainfall for station E	PRE1
Average basin slope	S	2-day Antecedent rainfall for station A	PRA2
Average basin elevation	EL	2-day Antecedent rainfall for station B	PRB2
Discharge-one day ago	PQ	2-day Antecedent rainfall for station C	PRC2
Current day rainfall for station A	RA	2-day Antecedent rainfall for station D	PRD2
Current day rainfall for station B	RB	2-day Antecedent rainfall for station E	PRE2
Current day rainfall for station C	RC	3-day Antecedent rainfall for station A	PRA3
Current day rainfall for station D	RD	3-day Antecedent rainfall ago for station B	PRB3
Current day rainfall for station E	RE	3-day Antecedent rainfall for station C	PRC3
1-day Antecedent rainfall for station A	PRA1	3-day Antecedent rainfall for station D	PRD3
1-day Antecedent for station B	PRB1	3-day Antecedent rainfall for station E	PRE3
1-day Antecedent rainfall for station C	PRC1	Sediment concentration	C
1-day Antecedent rainfall for station D	PRD1		

این راستا داده‌ها به دو بخش آموزش و آزمون تقسیم شده و در هر دو مدل ۸۰ درصد داده‌ها به مرحله آموزش و ۲۰ درصد به مرحله آزمون اختصاص داده شده است. مجموعاً برای آموزش و آزمون مدل شبکه بیزین، از ۳۶ داده استفاده شده که ۲۸ داده در مرحله آموزش (۹ واقعه سیلاب واریزه‌ای و ۱۹ واقعه سیلاب معمولی) و ۸ داده در مرحله آزمون (۴ واقعه سیلاب واریزه‌ای و ۴ واقعه سیلاب معمولی) به کار رفته است. برای صحت‌سنجی مدل از معیارهای ارزیابی شامل ضریب تبیین ( $R^2$ )، ریشه میانگین مربعات خطا (RMSE) و متوسط درصد خطای مطلق (MAPE) استفاده شده است که در ادامه روابط آن‌ها ارائه شده است:

$$R^2 = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum (X - \bar{X})^2 \sum (Y - \bar{Y})^2}} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (5)$$

الگوریتم پس انتشار خطا مشهورترین الگوریتم برای آموزش شبکه MLP است. این الگوریتم شامل دو مرحله است. در مرحله اول عملیات یادگیری و پردازش داده‌ها به سمت جلو از لایه ورودی به سمت لایه خروجی صورت می‌گیرد. پس از محاسبه خطا، مرحله دوم به سمت عقب شروع می‌شود. به عبارتی خطا در لایه خروجی به سمت عقب (به سمت لایه ورودی) انتشار می‌یابد (Emamgholizadeh et al., 2014). در مطالعه حاضر از شبکه MLP با الگوریتم یادگیری پس انتشار خطا و تابع محرک سیگموئید در لایه پنهان استفاده شده است که با استفاده از نرم افزار MATLAB شبیه‌سازی شده است.

### ۷-۲- صحت‌سنجی مدل

صحت‌سنجی مدل، از مهم‌ترین مراحل توسعه مدل است که نشانگر میزان اطمینان‌پذیری مدل می‌باشد (Ebrahimi et al., 2015). در

در واقع هدف از مراحل ۳ تا ۵ ارزیابی اثر تأخیر زمانی عامل بارندگی به صورت توأم بر دقت پیش‌بینی مدل است تا مشخص گردد که آیا تأخیرهای زمانی بارندگی می‌تواند دقت پیش‌بینی مدل را بهبود دهد و در صورت بهبود عملکرد مدل، دقت پیش‌بینی مدل بیشتر تحت تأثیر کدام یک از تأخیرهای زمانی بارندگی می‌باشد. در نهایت تا این مرحله می‌توان مهم‌ترین متغیرهای مؤثر بر دقت پیش‌بینی مدل را شناسایی کرد.

مرحله ششم: شناسایی مهم‌ترین عوامل و ارزیابی عملکرد سناریو حاصل از موثرترین عوامل بر دقت پیش‌بینی مدل (سناریو ۳۲).

### ۳- نتایج و بحث

در تحقیق حاضر، پس از انتخاب مجموعه عوامل مؤثر بر رخداد سیلاب واریزه‌ای، ترکیبی از سناریوهای مختلف برای پیش‌بینی وقوع سیلاب واریزه‌ای مورد آزمون قرار گرفته است تا در نهایت بهترین سناریو با عملکرد بهتر و تعداد پارامتر کمتر تعیین شود. هم‌چنین عملکرد مدل برای بررسی اثر هر یک از پارامترها تحلیل شده است.

### ۳-۱- بررسی ساختار و ترکیب مختلف سناریوهای پیش‌بینی سیلاب واریزه‌ای

در میان سناریوهای مختلف، سناریویی که بهترین مقادیر مربوط به شاخص‌های ارزیابی ( $R^2$ ، RMSE و MAPE) را به خود اختصاص دهد، به‌عنوان بهترین سناریو معرفی می‌گردد. معمولاً هر چه تعداد پارامترهای پیش‌بینی‌کننده در یک سناریو بیشتر باشد، دقت پیش‌بینی مدل بالاتر می‌رود، اما از آنجا که ممکن است همیشه دسترسی به کلیه عوامل پیش‌بینی‌کننده به سهولت میسر نباشد، ترکیبی از سناریوهای مختلف مورد آزمون قرار گرفته است تا در نهایت بهترین سناریو با عملکرد بهتر و تعداد پارامتر کمتر تعیین شود. هم‌چنین جدول‌های ۲ و ۳ عوامل حذف شده در هر سناریو و شاخص‌های دقت پیش‌بینی مدل بیزین را نشان می‌دهند. با توجه به جدول ۲، در سناریو اول اثر کلیه عوامل ورودی در ساختار گرافیکی در نظر گرفته شده است.

مطابق جدول برای سناریو اول مقدار شاخص‌های ارزیابی  $R^2$ ، RMSE و MAPE به ترتیب معادل ۰/۹۷، ۰/۰۰۱ و ۰/۵۵٪ برآورد شدند. از آنجا که در سناریو اول اثر کلیه عوامل پیش‌بینی‌کننده در ساختار شبکه بیزین در نظر گرفته شده است، به همین علت خطای برآورد غلظت رسوبات سیلاب بسیار ناچیز بوده و دقت پیش‌بینی مدل بالا است.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_i - Y_i}{Y_i} \right| \times 100 \quad (6)$$

$$Diff - MAPE = MAPE_{base} - MAPE_i \quad (7)$$

$X_i$  مقادیر محاسباتی و  $Y_i$  مقادیر مشاهداتی است. در رابطه ۷،  $MAPE_{base}$  مربوط به سناریو مبنا و  $MAPE_i$  مربوط به سناریو  $i$  است.

### ۲-۸- مراحل ارزیابی سناریوهای پیش‌بینی سیلاب

با توجه به هدف این پژوهش که پیش‌بینی غلظت رسوبات سیلاب (واریزه‌ای و معمولی) می‌باشد، ترکیب مختلفی از عوامل، در ساختار شبکه بیزین در نظر گرفته شده است. از آنجا که ممکن است همیشه دسترسی به کلیه متغیرهای پیش‌بینی‌کننده به سهولت امکان‌پذیر نباشد، هدف از تشکیل سناریوهای متعدد، یافتن سناریویی است که با وجود تعداد پارامترهای کمتر، دقت پیش‌بینی قابل قبولی داشته و نتایج قابل اعتمادی ارائه دهد. در این راستا سناریوهای تعریف گردیده است که در جدول‌های ۲ و ۳ ارائه شده است. روش مورد استفاده برای شناسایی موثرترین عوامل بر دقت پیش‌بینی مدل به شرح زیر است: در مرحله اول عملکرد مدل BN به ازای سناریو مبنا (دارای کلیه متغیرهای پیش‌بینی‌کننده) ارزیابی شده است (سناریو ۱). معمولاً هر چه تعداد متغیرهای پیش‌بینی‌کننده مدل بیشتر باشد، دقت پیش‌بینی آن نیز بالاتر می‌رود. از این‌رو، آنالیز حساسیت به منظور شناسایی مهم‌ترین عوامل بر دقت پیش‌بینی صورت می‌گیرد.

در مرحله دوم هر بار یکی از پارامترها از ساختار سناریو مبنا به‌صورت مجزا حذف می‌گردد (۲ تا ۲۵). در این صورت میزان تأثیر هر یک از پارامترها در عملکرد مدل مشخص می‌شود. در این مقاله در صورتی که با حذف هر یک از عوامل ورودی، میزان افزایش متوسط درصد خطای مطلق (MAPE) نسبت به سناریو مبنا حدوداً بیشتر از ۳۰٪ شود، قابل توجه فرض شده است و آن عامل به‌عنوان یکی از موثرترین عوامل پیش‌بینی‌کننده در میان کلیه عوامل ورودی شناخته می‌شود زیرا حذف آن عامل از ساختار شبکه بیزین به میزان زیادی روی دقت پیش‌بینی مدل تأثیر گذاشته است.

مرحله سوم: حذف توأم پارامترهای بارندگی (فعلی و پیشین تا ۳ روز قبل) به ازای کلیه ایستگاه‌های باران‌سنجی به‌طور هم‌زمان (سناریو ۲۶ تا ۲۹).

مرحله چهارم: حذف کلیه پارامترهای بارش پیشین (یک الی سه روز قبل) به‌طور هم‌زمان (سناریو ۳۰).

مرحله پنجم: حذف کلیه پارامترهای بارندگی (فعلی و پیشین) به‌صورت توأم (سناریو ۳۱).

**Table 2- Bayesian network results for different scenarios in the test and train stages (Part 1)**  
 جدول ۲- نتایج شبکه بیزین برای سناریوهای مختلف در مراحل آموزش و آزمون (قسمت اول)

NO	Variable/Variables deleted	Train				Test			
		R <sup>2</sup>	RMSE	MAPE	Diff-MAPE	R <sup>2</sup>	RMSE	MAPE	Diff-MAPE
1	-	0.984	0.001	7.23	-	0.973	0.001	8.55	-
2	A	0.81	0.005	21.5	14.27	0.801	0.005	22.24	13.7
3	S	0.89	0.003	10.34	3.11	0.886	0.003	11.64	3.09
4	PQ	0.85	0.003	30.8	23.57	0.839	0.004	32.44	23.89
5	EL	0.75	0.005	40.5	33.27	0.743	0.005	41.44	32.89
6	RA	0.8	0.005	24.12	16.89	0.800	0.005	24.36	15.81
7	RB	0.83	0.004	23.73	16.5	0.813	0.005	24.85	16.3
8	RC	0.84	0.005	21.54	14.31	0.826	0.005	23.96	15.41
9	RD	0.85	0.004	24.8	17.57	0.838	0.005	26.89	18.34
10	RE	0.81	0.005	23.16	15.93	0.800	0.005	24.33	15.78
11	PRA1	0.90	0.003	10.6	3.37	0.894	0.003	11.40	2.85
12	PRB1	0.92	0.003	9.33	2.1	0.918	0.003	10.29	1.74
13	PRC1	0.90	0.003	10.5	3.2	0.897	0.003	11.38	2.83
14	PRD1	0.90	0.003	10.2	2.97	0.902	0.003	11.25	2.7
15	PRE1	0.9	0.003	10.52	3.29	0.894	0.003	11.38	2.83
16	PRA2	0.92	0.003	10.35	3.12	0.911	0.003	11.25	2.7

**Table 3- Bayesian network results for different scenarios in the test and train stages (Part 2)**  
 جدول ۳- نتایج مدل شبکه بیزین برای سناریوهای مختلف در مراحل آموزش و آزمون (قسمت دوم)

NO	Variable/Variables deleted	Train				Test			
		R <sup>2</sup>	RMSE	MAPE	Diff-MAPE	R <sup>2</sup>	RMSE	MAPE	Diff-MAPE
17	PRB2	0.92	0.003	11.92	4.69	0.919	0.003	12.07	3.52
18	PRC2	0.93	0.003	10.3	3.07	0.920	0.003	11.9	3.35
19	PRD2	0.925	0.003	9.78	2.55	0.923	0.003	10.44	1.89
20	PRE2	0.91	0.003	10.1	2.87	0.919	0.003	10.14	1.59
21	PRA3	0.926	0.003	10.35	3.12	0.923	0.003	10.84	2.29
22	PRB3	0.95	0.002	9.41	2.18	0.947	0.002	10.06	1.51
23	PRC3	0.94	0.002	10.07	2.84	0.930	0.002	10.88	2.33
24	PRD3	0.95	0.002	9.43	2.2	0.945	0.002	10.11	1.56
25	PRE3	0.94	0.003	10.41	3.18	0.923	0.003	11.05	2.5
26	RA, RB, RC, RD, RE	0.79	0.006	36.2	28.97	0.772	0.007	37.77	29.22
27	PRA1, PRB1, PRC1, PRD1, PRE1	0.88	0.002	12.45	5.22	0.865	0.003	13.77	5.22
28	PRA2, PRB2, PRC2, PRD2, PRE2	0.90	0.003	11.23	4	0.898	0.003	11.87	3.32
29	PRA3, PRB3, PRC3, PRD3, PRE3	0.93	0.003	10.18	2.95	0.927	0.003	10.69	2.14
30	PRA1, PRB1, PRC1, PRD1, PRE1, PRA2, PRB2, PRC2, PRD2, PRE2, PRA3, PRB3, PRC3, PRD3, PRE3	0.88	0.004	35.47	28.24	0.872	0.004	36.29	27.74
31	RA, RB, RC, RD, RE, PRA1, PRB1, PRC1, PRD1, PRE1, PRA2, PRB2, PRC2, PRD2, PRE2, PRA3, PRB3, PRC3, PRD3, PRE3	0.72	0.005	45.12	37.89	0.711	0.006	46.90	38.35
32	PRA2, PRB2, PRC2, PRD2, PRE2, PRA3, PRB3, PRC3, PRD3, PRE3	0.92	0.003	10.85	3.62	0.916	0.003	11.01	2.46

زمان بارندگی‌های شدید، نقش مهمی در فرسایش و میزان جابجایی واریزه‌ها ایفا می‌کند (Peng, 2016).

لازم به ذکر است که هر یک از حوضه‌های آبریز امامه، ناورود و کسلیان دارای ۵ ایستگاه باران‌سنجی می‌باشند که برای هر یک از ایستگاه‌های باران‌سنجی، وقایع بارش فعلی و بارش پیشین تا ۳ روز قبل در نظر گرفته شده است. در سناریوهای ششم تا دهم از اثر عامل بارش فعلی هر یک از ایستگاه‌ها به صورت مجزا بر پیش‌بینی رخداد سیلاب چشم‌پوشی شده است. به عنوان مثال در سناریو ششم اثر بارش فعلی ایستگاه‌های باران‌سنج A برای هر سه حوضه حذف گردیده است. ارزیابی عملکرد مدل شبکه بیزین براساس سه آماره  $R^2$ ، RMSE و MAPE نشان می‌دهد که دقت مدل‌سازی کاهش چشمگیری داشته است. به طوری که ضریب همبستگی، میانگین مربعات مجذور خطا و متوسط درصد خطای مطلق به ترتیب معادل ۰/۸، ۰/۰۵ و ۲۴/۳۶ درصد به دست آمد و شاخص خطا MAPE نسبت به سناریو اول ۱۵/۸۱ درصد افزایش یافته است. از آنجا که بارندگی نقش اساسی در تولید رواناب دارد، به همین علت وجود عامل بارش فعلی در ساختار شبکه بیزین، تأثیر مهمی در پیش‌بینی صحیح آن دارد. نتایج مربوط به سناریوهای هفتم تا دهم نیز مشابه با نتایج سناریو ششم می‌باشد. با مقایسه این سناریوها نسبت به سناریوهای ۲ تا ۵ می‌توان به اهمیت عامل بارش در عملکرد مدل پی برد. ولی در این سناریوها تنها حذف اثر یک باران‌سنج بررسی گردیده است لذا در صورت حذف تمام پارامترهای بارش فعلی، افت عملکرد مدل شبکه بیزین قابل توجه خواهد بود.

در سناریو یازدهم الی پانزدهم، عامل بارش پیشین یک روز قبل هر یک از ایستگاه‌های باران‌سنجی به صورت مجزا از ساختار شبکه حذف شده است. به عنوان مثال در سناریو یازدهم، اثر بارش پیشین یک روز قبل ایستگاه‌های A که معرف سه حوضه می‌باشند، مورد بررسی قرار گرفته است و شاخص‌های آماری متوسط درصد خطای مطلق، خطای جذر میانگین مربعات و ضریب تبیین به ۱۱/۴ درصد، ۰/۰۳ و ۰/۸۹۴ به ترتیب محاسبه شده است. اختلاف شاخص MAPE نسبت به سناریو اول معادل ۲/۸۵ درصد برآورد شده است. نتایج سناریوهای دوازدهم تا پانزدهم مشابه نتایج سناریو یازدهم می‌باشد. به طور کلی وقایع بارندگی پیشین از طریق افزایش رطوبت خاک منجر به افزایش فشار منفذی و کاهش مقاومت اصطکاکی در سطح گسیختگی می‌شوند و بدین ترتیب احتمال وقوع سیلاب را افزایش می‌دهند. ارزیابی سناریوهای ۱۱ تا ۱۵ نشان می‌دهد نتایج مدل شبکه بیزین با واقعیت مطابقت دارد و ملاحظه می‌گردد با نادیده گرفتن اثری که بارش یک

در سناریو دوم با حذف اثر عامل مساحت از ساختار شبکه، میزان شاخص‌های ضریب تبیین، خطای جذر میانگین مربعات و متوسط درصد خطای مطلق به ترتیب ۰/۸۰۱، ۰/۰۵ و ۲۲/۲۴ درصد برآورد شده است. با مقایسه این سناریو نسبت به سناریو اول مشخص می‌گردد، شاخص خطای MAPE به میزان ۱۳/۶۹ درصد نسبت به سناریو اول افزایش یافته است که قابل ملاحظه می‌باشد و گویای اهمیت این عامل در پیش‌بینی وقوع سیلاب است. بنابراین، مساحت حوضه، به عنوان عامل مهمی برای بهبود دقت پیش‌بینی مدل شبکه بیزین عمل می‌کند. در حقیقت، با افزایش مساحت حوضه، حجم جریان بیشتر می‌گردد و در نتیجه منجر به افزایش قدرت جریان جهت فرسایش مواد در پایین‌دست می‌شود (Chang et al., 2010).

در سناریو سوم، عامل متوسط شیب حوضه از ساختار شبکه حذف شده است. در این سناریو میزان RMSE، ۰/۰۳، شاخص  $R^2$ ، ۰/۸۸۶ و مقدار MAPE، ۱۱/۴۶ درصد می‌باشد. در این حالت، شاخص خطا MAPE نسبت به سناریو اول ۳/۰۹ درصد افزایش یافته است که مقدار قابل توجهی نیست. به طور کلی، شیب حوضه یکی از عوامل مهم برای وقوع سیلاب است. اکثر سیلاب‌ها در شیبی بین ۱۵ تا ۳۰ درجه اتفاق می‌افتد (Tanhapour et al., 2017).

در سناریو چهارم اثر عامل دبی جریان آب در روز قبل از وقوع سیلاب واریزه‌های نادیده گرفته شده است و شاخص‌های آماری متوسط درصد خطای مطلق، خطای جذر میانگین مربعات و ضریب تبیین به ترتیب برابر با ۳۲/۴۴ درصد، ۰/۰۴ و ۰/۸۳۹ محاسبه شده‌اند. در این حالت، عملکرد مدل نسبت به سناریو اول کاهش یافته است زیرا اختلاف شاخص MAPE نسبت به سناریو اول معادل ۲۳/۸۹ درصد برآورد شده است. با مقایسه این سناریو نسبت به سناریوهای قبل مشخص می‌شود، ابتدا عامل دبی جریان روز قبل سپس مساحت در پیش‌بینی موارد رخداد سیلاب مؤثر است. لذا با توجه به تأثیر قابل توجه عوامل مختلف روی دبی جریان در ساختار شبکه بیزین، می‌توان این عامل را به عنوان عامل مهم و تأثیرگذاری روی افزایش عملکرد مدل برای پیش‌بینی رخداد سیلاب شناخت.

در سناریو پنجم با حذف اثر عامل ارتفاع، مقدار شاخص RMSE، ۰/۰۵ برآورد گردیده است همچنین میزان شاخص MAPE، ۴۱/۴۴ درصد و  $R^2$ ، ۰/۷۴۳ برآورد گردیده است و شاخص خطای MAPE به میزان ۳۲/۸۹ درصد نسبت به سناریو اول افزایش یافته است و عملکرد مدل نسبت به سناریو اول را به طور چشمگیری کاهش داده است. بنابراین این عامل به عنوان عامل مهم در بهبود توانایی پیش‌بینی مدل شناخته می‌شود. عامل ارتفاع با تأثیر بر میزان بارندگی، به ویژه در



به‌سزایی بر افت عملکرد مدل شبکه بیزین نسبت به سناریوهای ۶ تا ۱۵ داشته است. در واقع بارندگی با تأثیر بر اشباع و فرسایش خاک به حرکت توده‌ای ذرات خاک همراه با جریان کمک کرده و منجر به وقوع سیلاب واریزه‌ای می‌گردد. از طرفی اثر بارش پیشین بر وقوع سیلاب واریزه‌ای عمدتاً به دلیل تأثیراتی است که بر افزایش رطوبت خاک دارد. در اثر افزایش رطوبت خاک، مقدار نفوذ جریان کمتر و در نتیجه حجم رواناب ناشی از سیلاب واریزه‌ای افزایش می‌یابد. به‌طور کلی عامل بارش فعلی و بارندگی پیشین ۱ روز قبل به‌عنوان عواملی مهم برای شروع سیلاب واریزه‌ای و معمولی عمل می‌کنند.

در سناریوهای بیست و هشتم و بیست و نهم، به ترتیب متغیرهای بارش پیشین دو روز قبل و سه روز قبل کل ایستگاه‌های باران‌سنجی بصورت همزمان از مدل حذف گردید که نتایج آن بیانگر این امر می‌باشد که این متغیرها بر پیش‌بینی سیلاب تا حدودی تأثیرگذار است. ولی به نسبت عوامل دیگر تأثیر کمتری بر عملکرد مدل داشته است. درحقیقت حذف اثر بارندگی پیشین با تأخیر زمانی کمتر (مانند بارش پیشین ۱ روز قبل) نسبت به بارندگی پیشین با تأخیر زمانی بیشتر (۲ یا ۳ روز قبل) بر افت عملکرد مدل بیشتر است؛ زیرا هر چه مدت زمان بیشتری از وقوع بارش پیشین بگذرد، اثر آن در کاهش نفوذ و افزایش رواناب و در نتیجه راه‌اندازی سیلاب واریزه‌ای کاهش می‌یابد (Zhuang et al., 2015).

در سناریو سی‌ام، حذف کل عامل‌های بارندگی پیشین از ساختار شبکه منجر به کاهش قطعیت مدل در پیش‌بینی سیلاب شده و دقت مدل برای پیش‌بینی صحیح رخداد نیز به ویژه وقوع سیلاب واریزه‌ای که از اهمیت بالایی برخوردار است، کاهش یافته است.

در سناریو سی و یکم، با حذف کل عامل‌های بارندگی (فعلی و پیشین) از ساختار شبکه منجر به کاهش دقت مدل و پیش‌بینی سیلاب گردیده است و به دلیل اثرگذاری بیشتر متغیر بارش فعلی، عملکرد مدل شبکه بیزین را بیشتر تحت تأثیر قرار داده است. بارندگی یکی از عوامل اصلی شروع سیلاب است و وقوع سیلاب متأثر از هر دو عامل بارش فعلی و بارش پیشین است (Liang et al., 2012) به همین علت، زمانی که اثر عوامل مربوط به بارش (بارش فعلی و بارش پیشین) به صورت توأم نادیده گرفته می‌شود، تأثیر قابل ملاحظه‌ای در پیش‌بینی مدل شبکه بیزین نسبت به سناریو مینا دارد و دقت پیش‌بینی به‌شدت کاهش می‌یابد. لازم به ذکر است، چون بارندگی عاملی بسیار مهم در پیش‌بینی سیلاب است لذا سناریوهای ۳۰ و ۳۱ به دلیل ارزیابی اثر عوامل بارندگی بر روی دقت پیش‌بینی رخداد سیلاب به مجموعه سناریوهای مورد بررسی اضافه شدند. از مقایسه نتایج حاصل از

روز قبل بر رطوبت خاک دارد، عملکرد مدل برای شناسایی موارد رخداد سیلاب تا حدودی کاهش یافته است.

در سناریوهای ۱۶ تا ۲۰ اثر بارش پیشین دو روز قبل مربوط به هر یک از ایستگاه‌های باران‌سنجی و در سناریوهای ۲۱ تا ۲۵ اثر بارش پیشین سه روز قبل مربوط به هر یک از ایستگاه‌ها نادیده گرفته شده است. با توجه به شاخص‌های ارزیابی ارائه شده در جدول‌های فوق مشاهده می‌شود در اثر حذف وقایع بارش پیشین با تأخیر زمانی بیشتر (۲ روز قبل و ۳ روز قبل) افت عملکرد مدل ناچیز است. به‌عنوان مثال در سناریو ۱۶ با حذف اثر بارش پیشین دو روز قبل ایستگاه‌های A مقدار شاخص  $R^2$  و MAPE به ترتیب معادل ۰/۹۱ و ۱۱/۲۵٪ بدست آمده است. شاخص خطا MAPE نسبت به سناریو اول ۲/۷ درصد افزایش یافته است. به‌طور کلی با ارزیابی سناریوهای یادشده می‌توان نتیجه گرفت هر چه مدت زمان بیشتری از وقوع یک واقعه بارندگی قبل از وقوع سیلاب سپری شود، به دلیل کاهش اثر رطوبت ناشی از آن در خاک، تأثیر آن در رخداد سیلاب کاهش می‌یابد.

از میان سناریوهای اول تا بیست و پنجم، بهترین مقادیر شاخص‌های ارزیابی برای سناریو اول به دست آمده و از آنجاکه بالاترین دقت پیش‌بینی و بیشترین تعداد متغیر پیش‌بینی‌کننده متعلق به این سناریو می‌باشد، این سناریو به‌عنوان سناریو مینا در نظر گرفته شده و سایر سناریوها، نسبت به این سناریو مقایسه شده است. جهت شناسایی پارامترهای موثر بر پیش‌بینی وقوع و عدم وقوع سیلاب (واریزه‌ای و معمولی)، با حذف تک تک پارامترها (در سناریوهای ۲ تا ۲۵) به بررسی و تحلیل شاخص‌ها پرداخته شد. در ادامه به منظور مشاهده اثر تعداد باران‌سنجی‌ها بر پارامترهای بارش (فعلی و پیشین ۱ الی ۳ روز) و همچنین دقت عملکرد مدل شبکه بیزین، سناریوهای ۲۶ تا ۳۱ ارزیابی شده است.

در سناریو بیست و ششم کلیه متغیرهای بارش فعلی و در سناریو بیست و هفتم کلیه متغیرهای بارش پیشین ۱ روز قبل مربوط به هر پنج ایستگاه باران‌سنجی به صورت همزمان از ساختار شبکه حذف شده است. همان‌گونه که دیده می‌شود حذف اثر این عوامل منجر به کاهش عملکرد مدل شبکه بیزین و افزایش شاخص خطا شده است. به‌عنوان مثال در سناریو ۲۶، معیارهای ضریب همبستگی، میانگین مربعات مجذور خطا و متوسط درصد خطای مطلق به ترتیب برابر ۰/۷۷۲، ۰/۰۰۷ و ۳۷/۷۷ درصد می‌باشند و شاخص خطای MAPE به میزان ۲۹/۲۲ درصد نسبت به سناریو اول افزایش یافته است که این اختلاف قابل ملاحظه می‌باشد. لذا حذف اثرات مرتبط با بارش فعلی و بارش پیشین ۱ روز قبل در هر ۵ ایستگاه باران‌سنجی بصورت توأم، تأثیر

مدل بالاست و نسبت به سناریو مبنا تأثیر ناچیزی در افزایش خطای پیش‌بینی مدل داشته است. در این پژوهش نتایج حاصل از مدل شبکه بیزین و بررسی سناریوها با توجه به اعمال شبکه‌ای از باران سنج‌ها، موجب بهبود عملکرد مدل شبکه بیزین گردیده است به عبارتی با افزایش تعداد ایستگاه‌های باران‌سنجی می‌توان دقت مدل را تا حدودی بهبود بخشید.

جهت کسب اطمینان بیشتر برای معرفی مدل بیزین به عنوان مدل مناسب و قابل اطمینان برای پیش‌بینی غلظت رسوبات در این تحقیق، عملکرد مدل شبکه بیزین با مدل شبکه عصبی برای سناریوهای ۱ (سناریو حاصل از کلیه عوامل ورودی) و ۳۲ (سناریو مربوط به مؤثرترین عوامل) مقایسه شده است که نتایج آن در جدول ۴ ارائه شده است. شاخص خطای MAPE در مرحله آزمون برای مدل بیزین نسبت به مدل ANN برای سناریو ۱ به میزان قابل ملاحظه‌ای کمتر است (حدوداً ۱۹٪). بنابراین می‌توان نتیجه گرفت مدل شبکه بیزین دقت پیش‌بینی بالاتری نسبت به مدل ANN دارد.

#### ۴- نتیجه‌گیری

خسارات ناشی از سیلاب واریزه‌ای یکی از مسائل مهمی است که اکثر مناطق کشور با آن مواجه هستند. لذا نیاز به وجود آمدن سیستم‌های پیش‌بینی سیلاب واریزه‌ای امری ضروری است. تحقیق حاضر بر ارائه یک مدل مناسب برای پیش‌بینی غلظت رسوبات سیلاب‌های واریزه‌ای و معمولی در حوضه‌های مستعد سیلاب واریزه‌ای نظیر حوضه‌های ناورد، کسلیان و امامه با استفاده از مدل شبکه بیزین متمرکز است.

سناریوهای ۱ تا ۳۱ استنباط می‌شود، عواملی شامل ارتفاع حوضه، بارش فعلی، دبی روز قبل، مساحت حوضه و بارش پیشین یک روز قبل نسبت به دیگر عوامل، تأثیر به‌سزایی در عملکرد مدل شبکه بیزین دارند و به‌عنوان مؤثرترین عوامل بر دقت پیش‌بینی مدل شبکه بیزین شناخته شده‌اند؛ زیرا حذف اثر هر یک از این عوامل به طور مجزا از ساختار سناریو مبنا، دقت پیش‌بینی مدل شبکه بیزین را به میزان قابل توجهی کاهش داده است. بطور کلی این کاهش عملکرد، گویای نقش برجسته و مهم عوامل فوق‌الذکر در ساختار شبکه بیزین در بین کل متغیرهای مورد بررسی است.

از این رو سناریو ۳۲ با اعمال اثر مهم‌ترین عوامل در پیش‌بینی رخداد سیلاب (ارتفاع حوضه، بارش فعلی، دبی روز قبل، مساحت حوضه و بارش پیشین یک روز قبل) در نظر گرفته شده است که نتایج حاصل از معیارهای ضریب همبستگی، میانگین مربعات مجذور خطا و متوسط درصد خطای مطلق به ترتیب ۰/۹۱۶، ۰/۰۰۳ و ۱۱/۰۱ درصد برآورد گردید. در این سناریو ۱۱ مورد از عوامل پیش‌بینی‌کننده نسبت به سناریو مبنا کاهش پیدا کرده درحالی‌که شاخص خطای MAPE به میزان ۱/۵٪ نسبت به سناریو مبنا افزایش یافته است. بنابراین در صورتی که دسترسی به کلیه عوامل ورودی امکان‌پذیر نباشد، این سناریو پس از سناریو مبنا به‌عنوان بهترین سناریو معرفی می‌گردد. شکل ۳ و شکل ۴ به ترتیب ساختار گرافیکی و نمودار داده‌های مشاهداتی غلظت رسوب در برابر مقادیر محاسباتی را نشان می‌دهند. بر اساس شکل ۴ مشاهده می‌شود در مرحله آموزش ۹۲٪ و در مرحله آزمون ۹۱٪ پراکندگی نقاط مشاهداتی توسط نقاط محاسباتی پوشش داده شده است که نشان می‌دهد با وجود کاهش ۱۱ متغیر ورودی نسبت به سناریو مبنا و اعمال اثر تنها مؤثرترین عوامل، دقت پیش‌بینی




Fig. 3- Graphical structure of the best scenario`  
 شکل ۳- ساختار گرافیکی بهترین سناریو




Fig. 4- Observational sediment concentration versus predicted values in a) Train stage b) Test stage  
 شکل ۴- غلظت رسوب مشاهداتی در برابر محاسباتی (الف) مرحله آموزش (ب) مرحله آزمون

Table 4- Comparison of BN model's performance with ANN model for scenarios 1 and 32  
 جدول ۴- مقایسه عملکرد مدل شبکه بیزین با مدل ANN برای سناریوهای ۱ و ۳۲

NO	Model	Train				Test			
		R <sup>2</sup>	RMSE	MAPE	Diff-MAPE	R <sup>2</sup>	RMSE	MAPE	Diff-MAPE
1	ANN	0.768	0.007	25.22	-	0.723	0.008	27.39	-
1	BN	0.984	0.001	7.23	-	0.973	0.001	8.55	-
32	ANN	0.71	0.009	35.48	10.26	0.680	0.009	38.69	11.3
32	BN	0.92	0.003	10.85	3.62	0.916	0.003	11.01	2.46

یک روز قبل به‌عنوان بهترین سناریو شناخته شد. شاخص‌های ارزیابی برای این سناریو شامل معیارهای ضریب همبستگی، میانگین مربعات مجذور خطا و متوسط درصد خطای مطلق به ترتیب معادل ۰/۹۱۶۸، ۰/۰۰۳۳ و ۱۱/۰۱ درصد برآورد شد.

• مقایسه عملکرد مدل شبکه بیزین نسبت به مدل شبکه عصبی نشان داد مدل شبکه بیزین دقت پیش‌بینی بالاتر و عملکرد بهتری دارد.

به طور کلی، در تحقیق حاضر علاوه بر معرفی یک روش سریع و راحت، از رویکردی واقع‌گرا و قابل اعتماد، برای کاهش خطر سیلاب اعم از معمولی و واریزه‌ای استفاده شده است. همچنین روش ارائه شده در این تحقیق را می‌توان برای پیش‌بینی سیلاب واریزه‌ای در سایر مناطق کوهستانی مشابه به کار برد.

#### پی‌نوشت‌ها

- 1- Conditional Probability Table (CPT)
- 2- Estimation Maximization (EM)
- 3- Necessary Path Condition (NPC)
- 4- Artificial Neural Network (ANN)
- 5- Feed-Forward Network
- 6- Recurrent Networks
- 7- MultiLayer Perceptron (MLP)

پیش‌بینی غلظت رسوبات سیلاب واریزه‌ای به دلیل تأثیر آن بر زبری هیدرولیکی جریان و افزایش دبی پیک سیلاب واریزه‌ای حائز اهمیت است. بدین ترتیب، اثر مجموعه عوامل مساحت حوضه، ارتفاع و متوسط شیب حوضه، دبی جریان آب یک روز قبل، بارش فعلی و بارش پیشین (تا ۳ روز قبل از وقوع سیلاب) مجموعه‌ای از ایستگاه‌های باران‌سنجی هر حوضه برای شبیه‌سازی وقوع سیلاب در نظر گرفته شد. بطور خلاصه مهم‌ترین نتایج حاصل از تحقیق حاضر بشرح زیر است:

- سناریو حاصل از کلیه عوامل پیش‌بینی‌کننده با اختصاص شاخص‌های ارزیابی  $R^2$ ، RMSE و MAPE در مرحله آزمون به ترتیب ۰/۹۷، ۰/۰۰۱ و ۸/۵۵ درصد به‌دلیل دارا بودن بیشترین تعداد عوامل پیش‌بینی‌کننده و بالاترین دقت به‌عنوان سناریو مینا معرفی گردید.
- در اثر حذف هر بار یکی از عوامل پیش‌بینی‌کننده، عواملی نظیر ارتفاع حوضه، بارش فعلی، دبی روز قبل، مساحت حوضه و بارش پیشین یک روز قبل به‌عنوان مؤثرترین عوامل بر دقت پیش‌بینی مدل شناخته شدند.
- در صورتی که دسترسی به کلیه عوامل پیش‌بینی‌کننده امکان‌پذیر نباشد، سناریو با مجموعه عوامل پیش‌بینی‌کننده شامل ارتفاع حوضه، بارش فعلی، دبی روز قبل، مساحت حوضه و بارش پیشین

- Hassan-Esfahani L, Banihabib M E (2016) The impact of slit and detention dams on debris flow control using GSTARS 3.0. *Environmental Earth Sciences* 75(4):1-11
- Hesar A S, Tabatabaee H, Jalali M (2012) Monthly rainfall forecasting using Bayesian belief networks. *International Research Journal of Applied and Basic Sciences* 3(11):2226-2231
- Hirano M, Moriyama T, Kawahara K (1995) Prediction of the occurrence of debris flow and a runoff analysis by the use of neural networks. *Journal of Natural Disaster Science* 17(2):53-63
- Hirano M, Harada T, Banihabib ME, Kawahara K (1997) Estimation of hazard area due to debris flow. In: *Debris-Flow Hazards Mitigation: Mechanics, Prediction, and Assessment* proceedings of First International Conference, 7 Aug, San Francisco, 697-706
- Jakob M, Weatherly H (2003) A hydroclimatic threshold for landslide initiation on the North Shore Mountains of Vancouver, British Columbia. *Geomorphology* 54(3-4):137-56
- Kern AN, Addison P, Oommen T, Salazar SE, Coffman RA (2017) Machine learning based predictive modeling of debris flow probability following wildfire in the intermountain Western United States. *Mathematical Geosciences* 49(6):717-35
- Khakzad N, Khan F, Amyotte P (2011) Safety analysis in process facilities: Comparison of fault tree and Bayesian network approaches. *Reliability Engineering & System Safety* 96(8):925-32
- Liang W J, Zhuang D F, Jiang D, Pan J J, Ren H Y (2012) Assessment of debris flow hazards using a Bayesian Network. *Geomorphology* 171:94-100
- Lin J W, Chen C W, Peng C Y, (2012) Potential hazard analysis and risk assessment of debris flow by fuzzy modeling. *Natural Hazards* 64(1):273-282
- Madsen AL, Lang M, Kjørulff UB, Jensen F (2003) The Hugin tool for learning Bayesian networks. In: *European Conference on Symbolic and Quantitative Approaches to Reasoning and Uncertainty*, 2 Jul, 594-605
- Mohajerani H, Mosaedi A, Kholghi M, Meftah Helaghi M, Saadoldin A (2010) Introducing bayesian decision making networks and their application in water resources management. In: *First National Conference on Coastal Water Resources Management*, December 17-17, Sari, Iran (In Persian)
- Nikolopoulos EI, Destro E, Bhuiyan MA, Borga M, Anagnostou EN (2018) Evaluation of predictive models for post-fire debris flow occurrence in the
- Aguilera PA, Fernández A, Fernández R, Rumí R, Salmerón A (2011) Bayesian networks in environmental modelling. *Environmental Modelling & Software* 26(12):1376-1388
- Anbari MJ, Tabesh M, Roozbahani A (2017) Risk assessment model to prioritize sewer pipes inspection in wastewater collection networks. *Journal of Environmental Management* 190:91-101
- Asadi H, Shahedi R, Sidle C, and Kalami Heris S M (2019) Prediction of suspended sediment by intelligence models using hydrologic and hydrogeomorphic data. *Iran-Water Resources Research* 15(3):105-119 (In Persian)
- Banihabib M (1999) Hydraulic roughness of flow with high concentrations of sediment. In: *2nd Conference Hydraulic*, 16-18 November, Tehran, Iran, 174-181 (In Persian)
- Banihabib ME, Bahram E (2009) Experimental analyses of sedimentation in the slit dam Reservoir. In: *World Environmental and Water Resources Congress*, May 17-21, Kansas, Missouri, United States, 1-12
- Banihabib ME, Forghani A (2017) An assessment framework for the mitigation effects of check dams on debris flow. *Catena* 152:277-84
- Banihabib M E, Masumi A (2008) Effect of high-concentrated sediment transport on inundation of rivers: Case study Masuleh Flood. In: *Iranian Hydraulic Conference*, Tehran, Iran, 166-173 (In Persian)
- Banihabib ME (2002) Mud flow and debris. In: *Proceeding of Conference of Prevent and Reduce of Flood Risks*, Gorgan, Iran, 1-8 (In Persian)
- Bromley J, Jackson NA, Clymer OJ, Giacomello AM, Jensen FV (2005) The use of Hugin® to develop Bayesian networks as an aid to integrated water resource planning. *Environmental Modelling & Software* 20(2):231-42
- Chang T C, Wang Z Y, Chien Y H (2010) Hazard assessment model for debris flow prediction. *Environmental Earth Sciences* 60(8):1619-1630
- Ebrahimy E, Rozbahany A, Kardan Moghadam H (2015) Analysis of uncertainty effective parameters on forecasting the groundwater level with Bayesian network approach. In: *Shahid Beheshti Conference*, 17-18 Oct, Tehran, Iran, 1-10 (In Persian)
- Emamgholizadeh S, Kashi H, Marofpoor I, Zalaghi E (2014) Prediction of water quality parameters of Karoon River (Iran) by artificial intelligence-based models. *International Journal of Environmental Science and Technology* 11(3):645-656

- previous precipitation in the forecasting of debris floods occurrence in Alborz Region of Iran. *Iran-Water Resources Research* 13(4):118-131 (In Persian)
- Xu W, Yu W, Jing S, Zhang G, Huang J (2013) Debris flow susceptibility assessment by GIS and information value model in a large-scale region, Sichuan Province (China). *Natural Hazards* 65(3):1379-92
- Zhang H, Liu X, Cai E, Huang G, Ding C (2013) Integration of dynamic rainfall data with environmental factors to forecast debris flow using an improved GMDH model. *Computers and Geosciences* 56:23-31
- Zhuang J, Cui P, Wang G, Chen X, Iqbal J, Guo X (2015) Rainfall thresholds for the occurrence of debris flows in the Jiangjia Gully, Yunnan Province, China. *Engineering Geology* 195:335-346
- western United States. *Natural Hazards and Earth System Sciences* 18(9):2331-2343
- Pearl J (1988) Probabilistic reasoning in intelligent systems: networks of plausible inference. California, Morgan Kaufmann, 57
- Peng M, Zhang LM (2012) Analysis of human risks due to dam-break floods-part 1: A new model based on Bayesian networks. *Natural Hazards* 64(1):903-33
- Peng S H (2016) Hazard ratings of debris flow evacuation sites in hillside communities of Ershui town ship, Changhua County Taiwan. *Water* 8(2):54
- Sharghi E, Nourani V, and Behfar N (2019) Evaluation and application of ensemble AIbased models for estimating piezometric heads in earth fill dams. *Iran-Water Resources Research* 14(4):164-173 (In Persian)
- Tanhapour M, Banihabib ME, Roozbahani A (2017) Bayesian networks model to study the effect of