

## تحلیل عدم قطعیت خروجی شبکه عصبی در شبیه‌سازی هدایت هیدرولیکی اشباع خاک

محسن پوررضا ییلندی<sup>1\*</sup>، عباس خاشعی سیوکی<sup>2</sup>

تاریخ دریافت: 1394/4/6 تاریخ پذیرش: 1394/8/20

### چکیده

هدایت هیدرولیکی اشباع خاک از مهم‌ترین ویژگی‌های فیزیکی خاک است که در مدیریت آبیاری مزارع، انتقال آلودگی و همچنین جریان آب در محیط‌های غیراشباع نقش مهمی را دارا است. لیکن در بیش‌تر موارد به علت محدودیت‌های عملی و یا هزینه‌ای، اندازه‌گیری آن با دشواری همراه است. از این رو استفاده از مدل‌های شبیه‌سازی داده محور مانند شبکه عصبی مصنوعی با صرف هزینه کم و کارایی بالا می‌تواند جایگزین مناسبی برای این منظور باشد. از آنجا که انتخاب دوره‌های مختلف آموزش و آزمون به همراه توابع انتقال و آموزش متفاوت در این نوع مدل‌ها به عنوان مهم‌ترین منبع خطا می‌باشد، لذا عدم اطمینان و قطعیت لازم در مقادیر خروجی شبیه‌سازی شده مدل نیز از آن قابل نتیجه‌گیری می‌باشد. از این رو در این تحقیق بررسی منابع عدم قطعیت مذکور در شبیه‌سازی هدایت هیدرولیکی اشباع خاک مورد بررسی قرار گرفته است. در انجام این تحقیق، تعداد 151 نمونه از خاک‌های زراعی (اراضی اطراف شهرستان بجنورد) انتخاب و متغیرهای مؤثر چگالی ظاهری و واقعی خاک با کمک رگرسیون مرحله‌ای از بین دوازده متغیر مختلف اندازه‌گیری شده جهت برآورد هدایت هیدرولیکی اشباع به کار گرفته شد. نتایج تحلیل عدم قطعیت به‌دست آمده از 1000 سری داده مختلف نمونه‌گیری شده (با کمک نمونه گیر مونت کارلو) جهت استفاده در دوره‌های آموزش و آزمون شبکه عصبی پرسپترون با دو لایه بررسی و ارزیابی گردید. علاوه بر این، عملکرد ترکیب توابع انتقال و آموزش مختلف شبکه عصبی در تمام 1000 سری داده نیز به‌عنوان دومین منبع خطا ارزیابی شد. نسبت درصد قرارگیری مشاهدات در بازه اطمینان به پهنای بازه (معیار NUE) برای توابع انتقال لگاریتم سیگموئید (NUE=0.57) و خطی (NUE=0.59) نسبت به تابع تانژانت سیگموئید (NUE=0.25)، بالاتر و بهتر مشاهده گردید. همچنین از بین توابع مختلف آموزش تنها تابع کاهش گرادیان دارای زمان اجرای بالاتر و مقدار معیار NUE پایین‌تر به نسبت بقیه بوده و بنابراین بیش‌ترین عدم قطعیت را در نتایج مقادیر هدایت هیدرولیکی خروجی شبیه‌سازی شده داشت.

**واژه‌های کلیدی:** توابع انتقال و آموزش، هدایت هیدرولیکی اشباع خاک، عدم قطعیت شبکه عصبی مصنوعی

### مقدمه

مصنوعی معطوف شده است (Tayfur et al, 2014). این مدل‌ها که قابلیت ارتباط مستقیم بین داده‌های ورودی و خارجی بدون نیاز به درک کامل از فرآیند را فراهم می‌آورند مدل‌های داده محور<sup>3</sup> نیز نامیده می‌شوند.

تحقیقات بسیاری در زمینه تخمین هدایت هیدرولیکی اشباع خاک با کمک شبکه‌های عصبی مصنوعی در مناطق مختلف ارائه شده است. یائو و همکاران به تخمین مقدار هدایت هیدرولیکی اشباع خاک با کمک شبکه عصبی مصنوعی<sup>4</sup> در زمین‌های کشاورزی ساحلی و شور جیانگ‌سوی شمالی در کشور چین پرداختند و شوری خاک را یکی از تأثیرگذارترین فاکتورها در مقدار این پارامتر برشمردند که بایستی همواره به‌عنوان یکی از داده‌های ورودی خاک مورد استفاده قرار گیرد (Yao et al, 2015). تیفور و همکاران تخمین هدایت هیدرولیکی اشباع خاک را با کمک چندین روش هوش مصنوعی مانند شبکه عصبی، سیستم فازی و نرو فازی نیز به‌صورت

هدایت هیدرولیکی اشباع خاک از مهم‌ترین ویژگی‌های فیزیکی و هیدرولیکی خاک است که در مدل‌سازی حرکت آب و املاح شیمیایی در خاک، در مدیریت آب آبیاری در مزرعه، تحقیقات جریان آب در سفره‌های زیرزمینی، جریان آب در سدهای خاکی و همچنین در آبخوبی به‌منظور نمک‌زدایی و دفع مواد آلوده‌کننده خاک مورد استفاده قرار می‌گیرد (Motaghian and Mohammadi, 2011). طیف گسترده‌ای از مدل‌های عددی توسعه داده شده‌اند تا به تخمین این پارامتر بپردازند تا از طریق آن بتوانند حرکت آب زیرزمینی را مدل‌سازی کنند (Tsai and Li, 2008). در بیش‌تر موارد به علت محدودیت‌های عملی، صرف وقت بالا و یا هزینه زیاد، اندازه‌گیری آن با دشواری همراه بوده و از این رو توجه ویژه به مدل‌های هوش

1- استادیار گروه مهندسی آب، دانشگاه بیرجند

2- استادیار گروه مهندسی آب، دانشگاه بیرجند

\* - نویسنده مسئول: (Email: mohsen.pourreza@birjand.ac.ir)

3- Data-driven models

4- Artificial Neural Network (ANN)

علوم خاک و مباحث مرتبط با هدایت هیدرولیکی و پارامترهای مؤثر بر آن انجام نشده است. بنابراین مهم‌ترین هدف این تحقیق، بررسی و تخمین عدم قطعیت خروجی مدل‌های شبکه عصبی مصنوعی در تخمین هدایت هیدرولیکی اشباع خاک می‌باشد که در این راستا همان طور که در مقدمه ذکر گردید از روش مارس و همکاران به عنوان جدیدترین و کاراترین روش حاضر بهره گرفته شده است (Marce et al, 2004). به هر حال باید دقت داشت که برای اعمال نتایج این مدل‌ها به منظور کاربردهای مدیریتی در مهندسی و علوم آب، داشتن اطلاعاتی در مورد عدم قطعیت این مدل‌ها می‌تواند راه‌گشا باشد و به تصمیم‌گیران و مدیران این بخش کمک شایانی نماید.

## مواد و روش‌ها

### موقعیت جغرافیایی منطقه مورد مطالعه

منطقه مورد مطالعه، دشت دامنه‌ای قره‌میدان واقع در 70 کیلومتری شمال غرب بجنورد می‌باشد که دارای وسعت بیش از 300 هکتار می‌باشد. در آغاز پژوهش، با استفاده از نرم‌افزار ArcGIS و دستگاه GPS، کل منطقه به شبکه‌هایی با طول مساوی 150 متر تقسیم‌بندی گردید. در آذر سال 1388 از بخش‌های مذکور نیز از عمق 0-25 سانتی‌متری نمونه‌برداری خاک انجام شد و تعداد 151 نمونه خاک با شرایط متنوع انتخاب گردید (جلالی و همکاران، 1392).

### شبکه عصبی مصنوعی

برای اجرای مدل شبکه عصبی مصنوعی در این تحقیق از بخش جعبه ابزار شبکه عصبی مصنوعی در نرم افزار متلب استفاده شد. هم-چنین به منظور به‌دست آوردن پایداری مدل، مجموعه داده‌ها برای بار اول در محدوده 0 تا 1 نرمال شدند (رابطه 1) و سپس به مقادیر اولیه برگشت داده شدند.

$$X_{norm} = \left[ \frac{X - X_{min}}{X_{max} - X_{min}} \right] \times 0.8 + 0.1 \quad (1)$$

که در آن  $X$  مقدار اولیه،  $X_{min}$  و  $X_{max}$  به ترتیب مقادیر حداقل و حداکثر،  $X_{norm}$  مقدار نرمال شده و 0/8 و 0/1 عوامل سنجش هستند. برای عوامل سنجش مقادیر مختلفی ممکن است تعیین شود. با این حال هیچ قانون پیشنهادی و روش استاندارد وجود ندارد که بتواند در شرایط خاص مورد استفاده قرار بگیرد. در این مطالعه عوامل سنجش به ترتیب 0/8 و 0/1 انتخاب شدند.

اولین مرحله و در عین حال از مهم‌ترین مراحل در ساخت مدل-های ANNs، انتخاب ورودی‌های مؤثر از بین اطلاعات موجود می-باشد (Zealand et al, 1999). انتخاب ورودی‌های مناسب به دلایل زیر مهم می‌باشد:

الف- با افزایش تعداد متغیرهای ورودی، پیچیدگی محاسبات و

یک‌جا انجام دادند و نتیجه گرفتند خروجی ناشی از ترکیب نتایج همه مدل‌ها به نسبت خروجی هر یک از مدل‌های مذکور به صورت منفرد کاراتر می‌باشد (Tayfur et al, 2014).

یکی از موارد مهمی که بر خلاف مدل‌های آماری در مدل‌های شبکه عصبی به آن‌ها کم‌تر پرداخته شده است تحلیل عدم قطعیت در هنگام ارائه نتایج می‌باشد. از آنجا که مدل‌های مورد استفاده در تحقیقات مرتبط، از انواع مدل‌های مبتنی بر داده (داده محور) می-باشند لذا روش تحلیل عدم قطعیت این گونه مدل‌ها نیز متفاوت با مدل‌های مفهومی بوده و می‌تواند یکی از جنبه‌های مهم تحقیقی در استفاده و توسعه مدل‌های مذکور باشد (اکبرزاده و همکاران، 1389). در این نوع مدل‌ها بدیهی است که پیش‌بینی‌ها قطعی نیستند و تحلیل مذکور می‌تواند استفاده از نتایج مدل‌های پیش‌بینی را کارآمدتر سازد. بررسی مراجع نشان می‌دهد روش‌های محدودی برای تعیین عدم قطعیت در این نوع مدل‌ها پیشنهاد شده که از آن جمله می‌توان به روش‌های Bootstrap و تخمین زنده ساندویچ (ارائه شده توسط تیبشیرانی)، حداکثر درست‌نمایی و استنتاج بی‌زی (ارائه شده توسط دیبوسکی) و روش مونت کارلو پیشنهاد شده توسط مارس و همکاران اشاره نمود (Tibshirani, 1994; Dybowski, 1997 and Marce et al, 2004). با بررسی این منابع، روش مارس و همکاران به دلیل جدید بودن و عملکرد مناسب گزارش شده از آن، در این تحقیق مورد توجه قرار گرفت. این روش بر مبنای قرارگیری مدل‌ها در قالب یک پروسه نمونه‌گیری تصادفی مونت کارلو می‌باشد که اولین بار برای برآورد میزان خروج سالانه مواد معدنی مغذی محلول در جریان رودخانه از حوضه، با استفاده از مدل نروفازی به کار گرفته شده است. موارد محدودی از استفاده از این روش تاکنون گزارش شده است که از جمله آن‌ها پژوهش آکیلا و همکاران می‌باشد که در آن عدم قطعیت مقادیر خروجی مدل نروفازی را در پیش‌بینی جریان هفتگی رودخانه مورد بررسی قرار دادند (Aqila et al, 2007). نوری و همکاران نیز از این روش به منظور آنالیز عدم قطعیت مدل‌های ANFIS و ANN برای پیش‌بینی تولید زباله هفتگی استفاده نمودند (Noori et al, 2009). تحلیل دقت و عدم قطعیت مدل‌های هوشمند در پیش‌بینی ضریب انتشار طولی رودخانه‌ها نیز توسط اکبرزاده و همکاران با کمک همین روش انجام گردید اکبرزاده و همکاران (1389). فرخ نیا و مرید نیز عدم قطعیت خروجی مدل‌های ANN و ANFIS در پیش‌بینی جریان رودخانه صوفی چای را بر روش مذکور بررسی کردند فرخ نیا و مرید (1388). نتیجه تحقیق آن‌ها نشان داد که خروجی مدل نروفازی با دقت بالاتر دارای عدم قطعیت کم‌تری نیز می‌باشد. هم‌چنین در تحقیق طالبی زاده و همکاران عدم قطعیت پیش‌بینی بار رسوب با شبکه عصبی مورد بررسی قرار گرفت (Talebizadeh et al, 2010). لذا با توجه به سابقه تحقیق مشاهده می‌گردد تاکنون مطالعه‌ای در موضوع عدم قطعیت مدل‌های شبیه‌سازی داده محور مرتبط با

حافظه مورد نیاز مدل به سرعت افزایش می‌یابد.

**جدول 1- مقادیر آماره‌های ارزیابی جهت انتخاب پارامترهای مؤثر با روش رگرسیون مرحله ای**

سناریو	RMSE	R <sub>adj</sub>	R <sup>2</sup>
همه متغیرها	11/83	0/65	0/67
بدون دو متغیر کلیدی اخر (چگالی واقعی و ظاهری خاک)	16/17	0/34	0/38

**جدول 2- خلاصه‌ای از آماره‌های توصیفی پارامترهای خاکی به کار رفته جهت تخمین هدایت هیدرولیکی**

ویژگی	واحد	دامنه	کمینه	بیشینه	میانگین	انحراف معیار	ضریب تغییرات
جرم ویژه ظاهری	g.cm <sup>-3</sup>	0/49	1/26	1/75	1/53	0/086	5/62
جرم ویژه حقیقی	g.cm <sup>-3</sup>	0/59	2/19	2/78	2/56	0/088	3/43
شن	g.g <sup>-1</sup>	0/71	0/04	0/75	0/2107	0/08382	39/77
سیلت	g.g <sup>-1</sup>	0/49	0/13	0/62	0/4870	0/05408	11/10
رس	g.g <sup>-1</sup>	0/32	0/12	0/44	0/3023	0/04482	15
کربن آلی	%	1/70	0/21	1/91	0/88	0/22	24/9
مواد خنثی شونده	%	42	5/75	47/75	21/99	5/36	24/38
شوری	dS.m <sup>-1</sup>	3/54	0/27	3/81	1/74	0/48	28
رطوبت اشباع ( $\theta_s$ )	m.m <sup>-3</sup>	0/09	0/38	0/46	0/407	0/0126	3/1
هدایت هیدرولیکی اشباع خاک	cm.d <sup>-1</sup>	193/22	1/39	194/62	17/12	19/85	1/16

سازی از شبکه پرسپترون چند لایه استفاده شده است، چرا که این شبکه‌ها در شناخت الگو و تابع حاکم بر مسایل غیر خطی بسیار متبحرند. هم‌چنین الگوریتم پس‌انتشار خطا<sup>1</sup> که از مطرح‌ترین الگوریتم‌های آموزش این شبکه است، در این تحقیق مورد استفاده قرار گرفته است. شبکه عصبی پرسپترون، یک شبکه پیش رو چند لایه، شامل یک ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. گره‌های ورودی، اطلاعات را از بیرون دریافت می‌کنند و نتایج از طریق نرون‌های لایه خروجی شبکه حاصل می‌گردد. شبکه عصبی پیش رو از مجموعه اطلاعات ورودی، یک پاسخ در مسیر رو به جلو تولید می‌کند. به عبارت دیگر هیچ پس‌خوری ندارد. هم‌چنین اتصالات این شبکه کامل است یعنی هر نرون به تمام نرون‌های لایه بعدی اتصال دارد (Menhaj, 1998).

جهت ارزیابی سیستم‌های شبکه عصبی مصنوعی<sup>2</sup> همه داده‌ها به 3 قسمت، 50 درصد برای آموزش<sup>3</sup>، 25 درصد برای تست و سایر داده‌ها برای اعتبارسنجی<sup>4</sup> تقسیم شدند. بنابراین از مجموع 151 سری داده اندازه‌گیری شده موجود، 81 سری برای آموزش، 35 سری برای

ب- با ورود متغیرهای زیاد، آموزش مدل مشکل و ناکارآمد می‌شود.

ج- ورود متغیرهای پرت سبب افزایش تعداد حداقل‌های موضعی در سطح خطا گردیده که این امر می‌تواند باعث عدم همگرایی و در نتیجه دقت پایین مدل گردد (Bowden et al, 2005).

برای انتخاب متغیرهای مؤثر تاکنون روش‌های زیادی ارائه گردیده است که می‌توان خلاصه‌ای از این روش‌ها را در تحقیق بودن و همکاران (2005) یافت نمود (Bowden et al, 2005). در این تحقیق انتخاب ورودی‌های مؤثر در شبکه بر اساس روش رگرسیون مرحله‌ای صورت گرفت که خلاصه نتایج آن به شرح جدول 1 می‌باشد. بدین ترتیب بر طبق جدول مذکور مشاهده می‌شود مؤثرترین ورودی‌ها از بین متغیرهای موجود در جدول 2، سناریو بدون دو متغیر جرم ویژه ظاهری و حقیقی می‌باشد که در آن مقادیر معیارهای ارزیابی، تفاوت معنی‌داری با سناریو تمامی متغیرها دارا می‌باشد. بنابراین دو متغیر مذکور به‌عنوان متغیرهای کلیدی جهت انجام ورودی شبیه‌سازی در شبکه عصبی مورد استفاده قرار گرفت. ذکر این نکته که نتایج بقیه ترکیب‌های دوتایی از متغیرهای 12 گانه به دلیل حجم بالای نتایج گزارش نشده و تنها به بهترین ترکیب با بیش‌ترین تفاوت در مقادیر معیارها اکتفا شده است.

در علوم مهندسی آب و آبخیزداری در بیش‌تر موارد برای مدل -

1- Back Propagation  
2- ANN  
3- Training  
4- Validation

تست و 35 سری نهایی نیز برای اعتبارسنجی اختصاص یافت.

### عدم قطعیت شبکه عصبی

از آنجا که مهم‌ترین منبع عدم قطعیت مدل‌های داده-محور انتخاب داده‌های مرحله آموزش می‌باشد (Talebizadeh et al, 2010) که خود منجر به تعیین وزن‌های مختلف می‌گردد لذا انتخاب ترکیب‌های مختلف داده‌های این مرحله می‌تواند سبب خروجی‌های متفاوت گردد و ضرورت بررسی این شبیه‌سازی‌های مختلف ناشی از وزن‌های به‌دست آمده از داده‌های مختلف را توجیه می‌کند.

همان‌طور که ذکر گردید مدل‌های شبکه عصبی در قالب یک نمونه‌گیری مونت کارلو به کار گرفته می‌شوند. اساس کار شبیه‌سازی مونت کارلو نیز بر پایه استفاده از اعداد تصادفی و حصول تابع توزیع احتمالات یک مدل می‌باشد. بدین صورت که متغیرها (ورودی به مدل) با استفاده از تابع توزیع احتمالات مربوط به طور تصادفی تولید شده و سپس خروجی معادل آن‌ها از مدل مورد نظر به‌دست می‌آید و این عمل بارها تکرار می‌شود. سپس عدم قطعیت خروجی از طریق محاسبه شاخص‌های آماری و یا تعیین تابع توزیع احتمالات برآورد می‌شود (Eckhardt et al, 2003).

از آنجا که منابع عدم قطعیت موجود در خروجی مدل‌های داده محور (در این تحقیق شبکه عصبی مصنوعی) تنها به وزن‌های مختلف ناشی از داده‌های آموزش مربوطه محدود نشده و ساختن مدل نیز خود می‌تواند باعث تولید خطا نماید لذا در این تحقیق سعی شد که تا حدودی به بررسی رفتار توابع انتقال و توابع آموزش مختلف مورد استفاده در نرم افزار متلب پرداخته شود. به‌طوری که سه تابع انتقال تانژانت سیگموئید<sup>1</sup>، لگاریتم سیگموئید<sup>2</sup> و خطی<sup>3</sup> برای هر دو لایه شبکه به‌صورت یکسان و پنج روش آموزش شبه‌نیوتن<sup>4</sup>، کاهش گرادیان<sup>5</sup>، لونیگ-مارکارد<sup>6</sup>، پس‌انتشار برگشتی<sup>7</sup> و شیب توام مقیاس مقیاس شده<sup>8</sup> برای این منظور در نظر گرفته شدند.

شرح روش کار به صورت گام به گام و طی مراحل زیر توضیح داده می‌شود:

1- تقسیم داده‌ها برای دوره‌های آموزش، آزمون و تست:

از مجموع کل داده‌های برداشت شده از سطح منطقه، حدود 50 درصد آن (81 سری نمونه) برای آموزش مدل استفاده گردید. در نتیجه باقی‌مانده داده‌ها نیز که شامل دو سری 35 تایی می‌باشد برای

دوره‌های آزمون و تست به کار گرفته شد.

2- مرحله 1 به تعداد بالا (در این تحقیق 1000 تکرار) و به-صورت تصادفی با استفاده از روش مونت کارلو تکرار گردید به‌طوری که داده‌های دوره آموزش و تست در تمام 1000 نمونه با یکدیگر متفاوت بوده و تنها 35 نمونه مربوط به دوره آزمون در طی تکرارها یکسان فرض گردید.

3- نتایج ناشی از وزن‌های آموزش شبکه در اختیار داده‌های دوره آزمون قرار گرفته و باند اطمینان پیش‌بینی خروجی مدل استخراج شد.

4- مراحل 1 تا 3 برای توابع انتقال و آموزش مختلف تکرار و محدوده‌های اطمینان نتایج خروجی شبیه‌سازی شده و نمودارهای آن-ها برای تمامی حالات نتیجه‌گیری شد.

### معیارهای ارزیابی

از آنجا که در تحقیقات مرتبط با تحلیل عدم قطعیت تنها معیارهای خطا مانند ریشه میانگین مربعات خطا<sup>9</sup> به کار نرفته و نیاز به معیارهایی به‌منظور ارزیابی محدوده‌های اطمینان تولید شده می‌باشد، لذا معیارهای زیر برای این منظور تعریف و به کار برده می‌شوند. هر چند یافتن شبیه‌سازی‌های مناسب که در این تحقیق 5 درصد کل اجرا می‌باشد با کمک معیار RMSE انتخاب شده و در نهایت بازه اطمینان 95 درصد برآورد می‌شود.

**معیار  $P_{CI}$** : درصد قرارگیری داده‌های اندازه‌گیری شده در محدوده اطمینان 95 درصد ( $CI^{10}$ ) (Li et al, 2009):

$$P_{CI95\%} = \frac{nK_{obs}^{CI}}{N} \times 10 \quad (2)$$

که  $nK_{obs}^{CI}$  تعداد مشاهدات (در این تحقیق هدایت هیدرولیکی اندازه‌گیری شده بر حسب متر بر روز) قرار گرفته در محدوده اطمینان و N تعداد کل اندازه‌گیری‌ها است.

**معیار  $ARIL_{CI}$** : پهنای نرمال شده محصور بین حد بالا و حد پایین هدایت هیدرولیکی شبیه‌سازی شده در سطح اطمینان CI (Jin et al, 2010) که به‌صورت زیر تعریف می‌گردد:

$$ARIL_{CI} = \frac{1}{n} \sum \frac{Limit_{upper,t} - Limit_{lower,t}}{K_{obs,t}} \quad (3)$$

در این رابطه،  $Limit_{upper,t}$  و  $Limit_{lower,t}$  حد بالا و پایین محدوده اطمینان 95 درصد برای t امین مقدار شبیه‌سازی هدایت هیدرولیکی است و n تعداد کل اندازه‌گیری‌ها، و  $K_{obs,t}$  بار هدایت هیدرولیکی مشاهده شده است. هر چه فاکتور p به 100 درصد و فاکتور  $ARIL$  به صفر نزدیک‌تر باشد شبیه‌سازی‌ها مناسب‌تر خواهند بود.

9- Root Mean Square Error

10- Confidence Interval

1- tansig  
2- logsig  
3- Purelin  
4- trainbfg  
5- traingd  
6- trainlm  
7- trainrp  
8- trainscg

مقایسه این سه سری نمودار نشان می‌دهد که دو تابع انتقال لگاریتم سیگموئید و خطی به نسبت تانژانت سیگموئید دارای قطعیت بیش‌تر می‌باشند. همچنین در مقایسه دقیق‌تر می‌توان بازه پهن‌تر (مقدار معیار ARIL بیش‌تر) نمودارهای تابع لگاریتم را به نسبت تابع خطی مشاهده نمود که از این حیث برتری با تابع خطی می‌باشد ولی به دلیل قرارگیری تعداد مشاهدات بیش‌تر (نقاط با خط آبی رنگ) در بازه اطمینان نمودارهای لگاریتم، هر دو تابع دارای شرایط برتری یکسانی ارزیابی می‌شوند و برای ارزیابی بهتر بایستی به مقایسه مقادیر معیارهای مذکور (موجود در جدول 2) رجوع شود.

هم‌چنین با توجه به نمودارهای قرار گرفته در اشکال 1 تا 3، می‌توان به طور کلی نتیجه گرفت مقادیر هدایت هیدرولیکی بیشینه و محدوده‌های اطمینان متناظر آن‌ها در تابع انتقال لگاریتم بهتر از تابع انتقال خطی بوده و قطعیت بیش‌تری دارد. برعکس، نقاط با مقادیر کم‌تر هدایت هیدرولیکی با تابع انتقال خطی بهتر برآورد شده و بنابراین قطعیت بیش‌تری دارند.

همان‌طور که از جدول 2 نیز نتیجه می‌شود مقادیر فاکتور NUE به‌عنوان عاملی که تأثیر دو معیار دیگر را در خود نهفته دارد، به طور نسبی در 5 ردیف اول که مربوط به تابع انتقال لگاریتم می‌باشد از همه بزرگ‌تر بوده، پس از آن در ردیف‌های 6 تا 10 (تابع انتقال خطی) با مقادیر کم‌تر در رتبه دوم و در نهایت ردیف‌های 11 تا 15 (تابع انتقال تانژانت) در رتبه سوم قرار می‌گیرد.

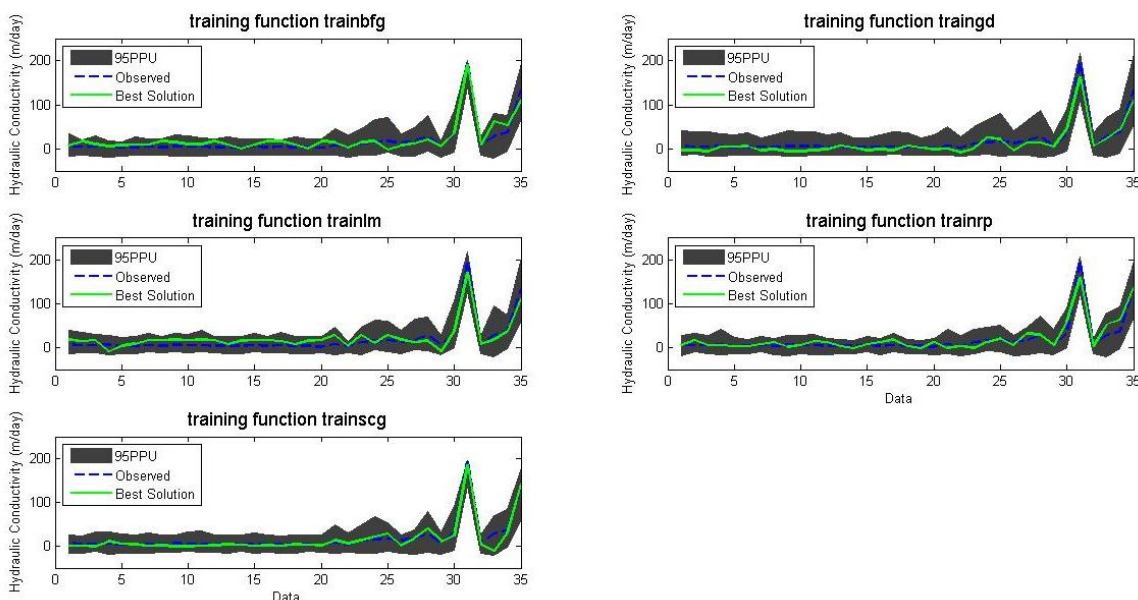
**معیار  $NUE_{CI}$** : با توجه به رفتار متفاوت این دو شاخص و لزوم جم‌بندی نتایج، از شاخصی جدیدی به‌عنوان شاخص کل عدم قطعیت استفاده گردید (رهنما و همکاران، 1393). این شاخص تجمیع دو شاخص قبلی می‌باشد و هرچه که مقدار بیش‌تری را نمایش دهد، روند مطلوب‌تری را نشان می‌دهد. با توجه به تأثیر بالاتر فاکتور ARIL در این تحقیق مطابق رابطه زیر از توان دو مقدار فاکتور p استفاده شده است:

$$NUE_{CI} = \frac{p_{CI}^2}{ARIL_{CI}} \quad (4)$$

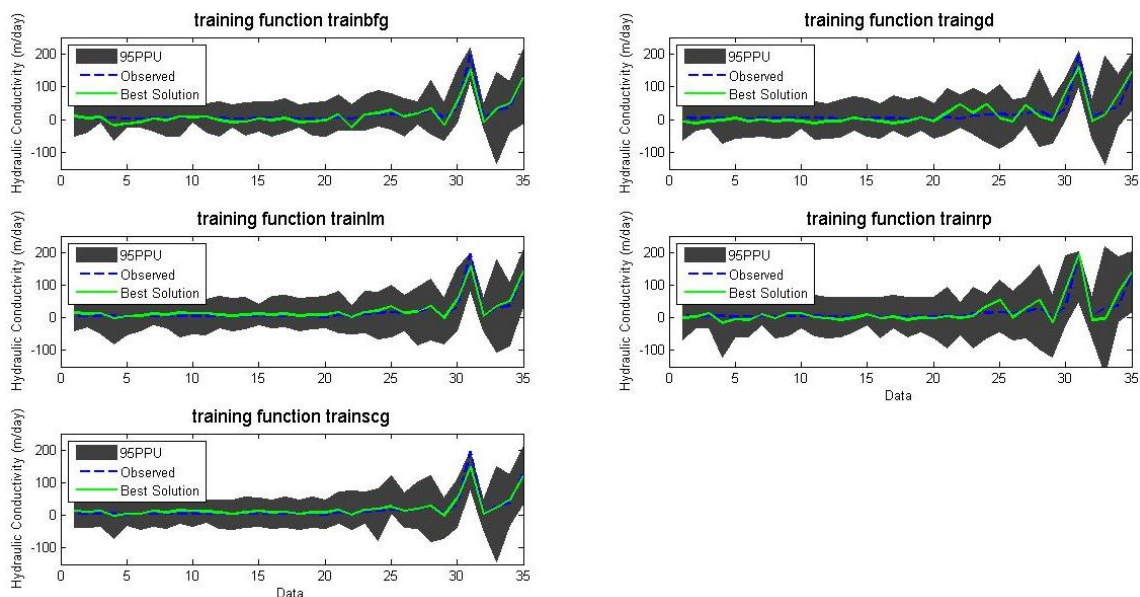
## نتایج و بحث

نتایج ناشی از اجرای 1000 بار اجرای مدل شبکه عصبی با 81 سری داده مختلف دوره آموزش شبکه عصبی که توسط نمونه‌گیری مونت کارلو به‌دست آمده است، برای هر یک از پانزده سناریو (ترکیب سه تابع انتقال با 5 تابع آموزش) حاصل گردید که در ادامه به‌طور مفصل بحث و نتیجه‌گیری شده‌اند.

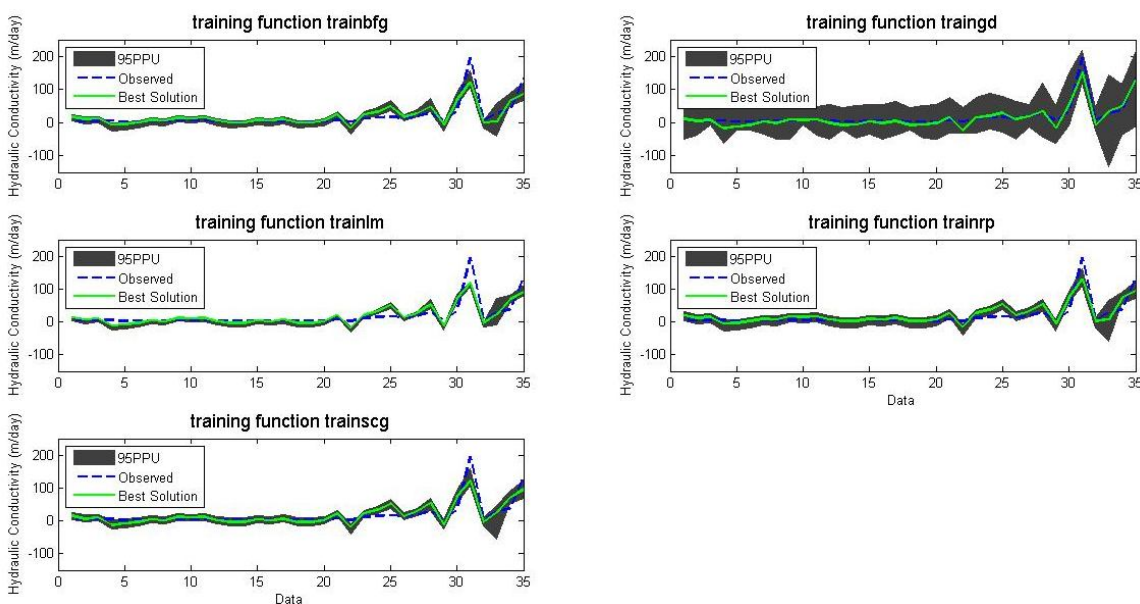
اشکال 1 تا 3 نمایش محدوده اطمینان 95 درصد خروجی مدل به‌ازاء پانزده سناریو موجود را نمایش می‌دهد. به طوری که شکل 1 نمایش تابع انتقال لگاریتم سیگموئید، شکل 2 نمایش تابع انتقال تانژانت سیگموئید و شکل 3 نیز نمایش تابع انتقال خطی می‌باشند که هر یک با 5 تابع آموزش مختلف موجود در نرم افزار متلب اجرا شده‌اند.



شکل 1- بازه 95% اطمینان خروجی با ترکیب استفاده از تابع انتقال logsig با توابع آموزش مختلف



شکل 2- بازه 95% اطمینان خروجی با ترکیب استفاده از تابع انتقال tansig با توابع آموزش مختلف



شکل 3- بازه 95% اطمینان خروجی با ترکیب استفاده از تابع انتقال purelin با توابع آموزش مختلف

از 3000 اجرای مربوط به سه تابع انتقال می‌باشد. با مقایسه نمودارهای مربوط به سه تابع انتقال (شکل 4) به صورت کلی می‌توان همان نتیجه برتری نسبی دو تابع خطی و لگاریتمی به نسبت تابع تانژانت را مشاهده نمود. این نتیجه با کمک جدول نتایج قرار گرفته در زیر (جدول 2) نیز قابل استنباط می‌باشد. مقادیر تقریباً نزدیک 0/57 و 0/59 به ترتیب برای دو تابع انتقال لگاریتم و خطی نشان از برتری نامحسوس تابع انتقال خطی دارد. در مورد مقایسه توابع آموزش مختلف نیز به جز تابع گرادیان کاهش که دارای

پس از اخذ نتایج 15 سناریو مذکور، نتایج آن‌ها به صورت ترکیبی نیز مورد تجزیه و تحلیل قرار گرفت. به طوری که نتایج اجراهای همه توابع آموزش (5 تابع آموزش) با هم یکجا جمع و سپس با 5000 اجرای موجود محدوده 95 درصد اطمینان به تفکیک هر یک از توابع انتقال مانند قبل استخراج و در شکل 4 قرار گرفت. همین روند جمع نتایج و برآورد بازه اطمینان این بار برای توابع انتقال مختلف و به تفکیک توابع آموزش استخراج و در شکل 5 به نمایش گذاشته شده است. در این حالت هر یک از نمودارهای قرار گرفته در شکل 5 ناشی



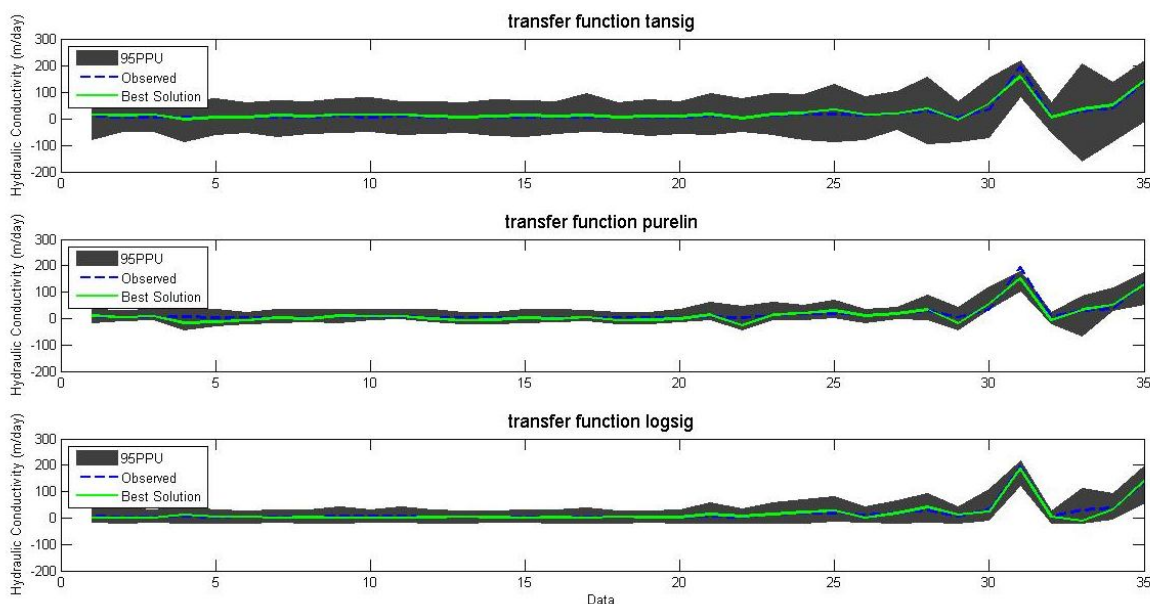
### نتیجه‌گیری

در این تحقیق ارزیابی عدم قطعیت مربوط به ساختار مدل‌سازی شبکه عصبی، مورد تحلیل و بررسی قرار گرفت. نتیجه‌گیری از اجراهای متفاوت با سناریوهایی که از ترکیب توابع انتقال و آموزش مختلف موجود در نرم افزار متلب با نمونه‌گیری‌های مختلف دوره آموزش به‌دست آمده از مونت کارلو در این بخش ارائه می‌گردد.

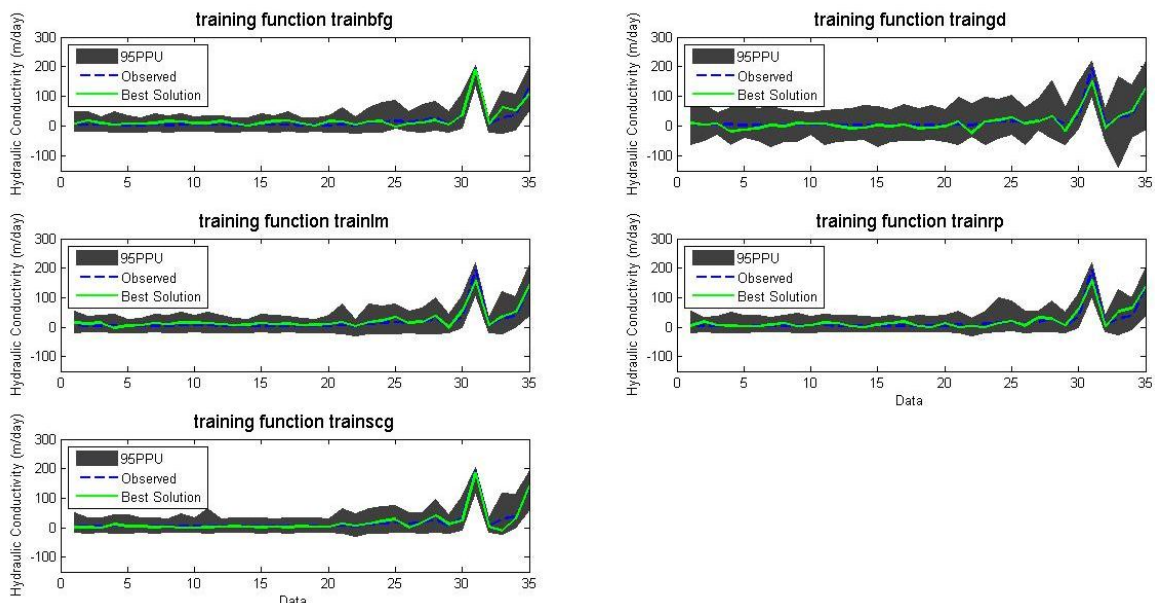
محدوده اطمینان پهن (شاخص ARIL بالا) می‌باشد باقی توابع در یک رتبه قرار گرفته و تفاوت محسوسی با یکدیگر ندارند. این نکته نیز با مقایسه مقادیر NUE از جدول 3 قابل نتیجه‌گیری می‌باشد.

جدول 3 - مقادیر معیارهای عدم قطعیت ARIL و P95% و NUE در ارزیابی سناریوهای مختلف

سناریو	تابع انتقال	تابع آموزش	ARIL	P95%	NUE
1	logsig	Trainbfg	1.39	1	0.72
2	logsig	Traingd	1.64	1	0.61
3	logsig	Trainlm	1.45	1	0.69
4	logsig	trainrp	1.37	1	0.73
5	logsig	trainscg	1.41	1	0.71
6	purelin	trainbfg	0.71	0.63	0.56
7	purelin	traingd	1.18	0.83	0.58
8	purelin	trainlm	0.40	0.31	0.24
9	purelin	trainrp	0.88	0.71	0.58
10	purelin	trainscg	0.75	0.66	0.58
11	tansig	trainbfg	2.80	1	0.36
12	tansig	traingd	3.33	1	0.30
13	tansig	trainlm	3.21	1	0.31
14	tansig	trainrp	3.84	1	0.26
15	tansig	trainscg	2.93	1	0.34



شکل 4- بازه 95% اطمینان خروجی در توابع آموزش مختلف به تفکیک هر یک از توابع انتقال



شکل 5- بازه 95% اطمینان خروجی در توابع انتقال مختلف به تفکیک هر یک از توابع آموزش

جدول 4 - مقادیر معیارهای عدم قطعیت ARIL و P95% و NUE در ارزیابی ترکیب سناریوها با توابع انتقال و آموزش مختلف

تعداد شبیه سازی	تابع انتقال	تابع آموزش	ARIL	P95%	NUE
5000	logsig	overall	1.74	1	0.57
5000	purelin	overall	1.59	0.97	0.59
5000	tansig	overall	4.05	1	0.25
3000	overall	trainbfg	1.85	1	0.54
3000	overall	traingd	3.40	1	0.29
3000	overall	trainlm	1.93	1	0.52
3000	overall	trainrp	1.92	1	0.52
3000	overall	trainscg	1.84	1	0.54

(حدود 24 ساعت) در مقایسه با بقیه (بین 2 تا 5/2 ساعت) مدنظر قرار گیرد.

- با مقایسه محدوده‌های اطمینان به دست آمده برای مقادیر هدایت هیدرولیکی به طور خلاصه می‌توان تابع انتقال لگاریتم را برای مقادیر بیشینه و تابع انتقال خطی را برای مقادیر کمینه هدایت هیدرولیکی مناسب‌تر گزارش داد و قطعیت بیشتری نیز از نتایج آن انتظار داشت. ضمن آنکه تابع انتقال خطی اکثر مقادیر هدایت هیدرولیکی بیشینه را کمتر از مقدار واقعی تخمین زده است.
- به طور خلاصه، با تکیه بر نتایج معیارهای ارزیابی، قابلیت تخمین مناسب هدایت هیدرولیکی شبکه عصبی با تابع انتقال لگاریتم با اعمال توابع آموزش مختلف و حساسیت کمتر این تابع نسبت به تغییرات در داده‌های آموزشی در قیاس با سایر سناریوهای مورد استفاده مشاهده گردید.

نتایج اخذ شده از تحقیق حاضر پس از اجرا و تحلیل 15 سناریوی مختلف برای ارزیابی عدم قطعیت ناشی از ساختار مدل‌سازی شبکه عصبی به طور خلاصه به شرح زیر می‌باشد:

- در بررسی عملکرد توابع انتقال مختلف با مقایسه بازه‌های اطمینان موجود و معیارهای ارائه شده می‌توان به ترتیب دقت توابع لگاریتم سیگموئید، خطی و تانژانت سیگموئید را در برآورد تخمین هدایت هیدرولیکی برشمرد. این نکته در باب قطعیت بیشتر توابع انتقال لگاریتم و خطی به نسبت تابع تانژانت سیگموئید در مقادیر NUE ارائه شده جدول 2 نیز قابل درک می‌باشد.
- ارزیابی عدم قطعیت ترکیب سناریوها با توابع آموزش مختلف نیز نشان داد که به جز تابع آموزش کاهش گرادیان بقیه توابع عملکرد نسبتاً مشابهی داشته‌اند. البته این نتیجه زمانی کامل‌تر می‌شود که زمان اجرای این تابع آموزش



- hydrological model. *Journal of Hydrology*. 383:147-155.
- Li, L., Xia, J., Xu, C.-Y., Chu, J., Wang, R. 2009 Analyse the sources of equifinality in hydrological model using GLUE methodology. In: *Hydroinformatics in Hydrology, Hydrogeology and Water Resources, Proceedings of Symposium JS.4 at the Joint IAHS & IAH Convention, Hyderabad, India*. IAHS Publ. 331: 130-138.
- Marcé, R., Comerma, M., García, J.C., Armengol, J. 2004 A neuro-fuzzy modeling tool to estimate fluvial nutrient loads in watersheds under time-varying human impact. *Limnology and Oceanography: Methods*. 2.11: 342-355.
- Menhaj, M. B. 1998 *Fundamentals of neural networks. Computational intelligence*. 1: 222-229.
- Motaghian, H.R., Mohammadi, J. 2011 Spatial estimation of saturated hydraulic conductivity from terrain attributes using regression, kriging, and artificial neural networks. *Pedosphere*. 21.2: 170-177.
- Noori, R., Abdoli, M.A., Farokhnia, A and Abbasi, M. 2009 Results uncertainty of solid waste generation forecasting by hybrid of wavelet transform-ANFIS and wavelet transform-neural network. *Expert Systems with Applications*. 36.6: 9991-9999.
- Talebzadeh, M., Morid, S., Ayyoubzadeh, S.A., Ghasemzadeh, M. 2010 Uncertainty analysis in sediment load modeling using ANN and SWAT model. *Water Resources Management*. 24.9: 1747-1761.
- Tayfur, G., Nadiri, A.A., Moghaddam, A.A. 2014 Supervised intelligent committee machine method for hydraulic conductivity estimation. *Water Resources Management*. 28.4: 1173-1184.
- Tibshirani, R. 1994 A Comparison of Some Error Estimates for Neural Network Models. Technical Working Paper No. 94-10, Department of Statistics, University of Toronto.
- Tsai, F.T.C., Li, X. 2008. Multiple parameterization for hydraulic conductivity identification. *Groundwater* 46(6):851-864.
- Yao, R.J., Yang, J.S., Wu, D.H., Li, F.R., Gao, P., Wang, X.P. 2015 Evaluation of pedotransfer functions for estimating saturated hydraulic conductivity in coastal salt-affected mud farmland. *Journal of Soils and Sediments*, 1-15.
- Zealand, C.M., Burn, D.H and Simonovic, S.P. 1999 Short term streamflow forecasting using artificial neural network. *Journal of Hydrology*. 214: 32-48.
- تقدیر و تشکر**
- این تحقیق در قالب طرح پژوهشی به شماره ابلاغیه 94/د/607 مورخ 94/1/25 و با استفاده از اعتبارات پژوهشی دانشگاه بیرجند انجام شده است که بدینوسیله تشکر و قدردانی می‌شود.
- منابع**
- اکبرزاده، ع، نوری، ر، فرخ‌نیا، ا، خاکپور، ا و صباحی، م. س. 1389. تحلیل دقت و عدم قطعیت مدل‌های هوشمند در پیش‌بینی ضریب انتشار طولی رودخانه‌ها. فصلنامه علمی-پژوهشی آب و فاضلاب، جلد 21، شماره 3، صفحه 99-107.
- جلالی، پ، خاشعی سیوکی، ع و همایی، م. 1392. مقایسه روش‌های زمین آماری با روش غیر پارامتریک K- نزدیک‌ترین همسایه برای برآورد هدایت هیدرولیکی اشباع خاک. 20,5: 162-147.
- رهنما، ب، ناصری، م و زهرایی، ب. 1393. تشخیص ساختار بهینه و تحلیل عدم قطعیت مدل بیان آبی ماهانه، مجله پژوهش آب ایران 8: شماره 14، 77-86.
- فرخ‌نیا، ا و مریدی، س. 1388. تحلیل عدم قطعیت مدل‌های شبکه عصبی و نروفازی در پیش‌بینی جریان رودخانه، تحقیقات منابع آب ایران 5,3: شماره 14-27.
- Aqil, M., Kitab, I., Yanob, A., Nishiyamac, S. 2007 Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool. *Journal of Environ Managment* 85.1: 215-223.
- Bowden, G.J., Dandy, G.C., Maier, H.R. 2005 Input determination for neural network models in water resources applications. Part 1—background and methodology. *Journal of Hydrology*. 301.1: 75-92.
- Dybowski, R. 1997 Assigning confidence intervals to neural network predictions. Technical report, Division of Infection (St Thomas' Hospital), King's College London.
- Eckhardt, K., Breuer, L and Frede, H.G. 2003 Parameter uncertainty and the significance of simulated land use change effects. *Journal of Hydrology*. 273.1: 164-176.
- Jin, X., XU, C.Y., Zhang, Q., Sing, V.P. 2010 Parameter and modeling uncertainty simulated by GLUE and a formal Bayesian method for a conceptual

## Uncertainty Analysis of Artificial Neural Networks in Simulation of Saturated Hydraulic Conductivity Using Monte-Carlo Simulation

M. Pourreza Bilondi<sup>\*1</sup> and A. Khashei-Siuki<sup>2</sup>  
Received: Jun.27, 2015 Accepted: Nov.11, 2015

### Abstract

Hydraulic conductivity as a key soil property is essential for irrigation management purposes and plays an important role in understanding site-specific unsaturated water flow and transport processes. Since it cannot often be measured because of practical and/or cost-related reasons, data driven models such as artificial neural network may be applied for prediction of soil hydraulic properties. This paper aimed to assess uncertainty analysis in neural network prediction originated from different weights due to different training data sets. Here, we present a unique dataset that consists of 151 samples collected from arable land around Bojnourd City, containing of sand, silt and clay contents, saturated water content, Electrical Conductivity (EC), pH, real density, Organic matter (OM), Total Neutralizing Value (TNV) and bulk density ( $\rho_b$ ). Bulk and real densities determined based on stepwise regression analysis as most important inputs to neural network model. Then a two layer perceptron neural network with 1000 different samples trained with some available transfer and training functions in Matlab. Results assessed with NUE as an integrated index defined as ratio of percentage of the observation coverage by 95 percent prediction uncertainty (95PPU) divided by average relative interval length of 95PPU. Uncertainty analysis results revealed that log-sigmoid and linear transfer functions with NUE values 0.57 and 0.59 performed better tan-sigmoid transfer function with NUE=0.25. Also all training functions (except of gradient descent training function) could predict saturated hydraulic conductivity with high reliability.

**Keywords:** Uncertainty Analysis in artificial neural network, transfer and training functions, saturated hydraulic conductivity.

---

1- Assistant Professor of Water Engineering Department., University of Birjand  
2- Assistant Professor of Water Engineering Department., University of Birjand  
(\*-Corresponding Author Email: Mohsen.pourreza@birjand.ac.ir)