

تحلیل دقت و عدم قطعیت مدل‌های هوشمند در پیش‌بینی ضریب انتشار طولی رودخانه‌ها

عباس اکبرزاده^۱ روح‌اله نوری^۲ اشکان فرخ‌نیا^۳
امیر خاکپور^۴ محمد سلمان صباحی^۵

(دریافت ۸۸/۲/۱۶ پذیرش ۸۹/۳/۱۱)

چکیده

پیش‌بینی دقیق ضریب انتشار طولی در رودخانه‌های طبیعی تا حد بسیار زیادی در تعیین توزیع غلظت آلاینده‌ها در چنین محیط‌هایی مؤثر است. عدم قطعیت موجود در نتایج به‌دست آمده از مدل‌های پیش‌بینی می‌تواند در تصمیم‌گیری‌های مناسب برای برخورد با مواد آلاینده در رودخانه‌ها تأثیر منفی داشته باشد. به‌همین دلیل، تحلیل و تعیین عدم قطعیت مدل‌های مورد استفاده برای پیش‌بینی این پارامتر بسیار مفید است. در این تحقیق با توجه به اهمیت این امر، با استفاده از مدل‌های شبکه عصبی (ANN) و نروفازی تطبیقی (ANFIS)، ابتدا مدل مناسب برای پیش‌بینی ضریب انتشار طولی در رودخانه‌های طبیعی ارائه گردید و در ادامه تحلیل عدم قطعیت دو مدل مذکور بر مبنای روش مونت-کارلو انجام شد. برای این منظور از اطلاعات هیدرولیکی و هندسه جریان استفاده گردید. نتایج این تحقیق بیانگر این مطلب بود که اگرچه مدل ANN در پیش‌بینی ضریب انتشار طولی دارای عملکرد خوبی است، اما نتایج این مدل با عدم قطعیت زیادی همراه است. با مقایسه نتایج به‌دست آمده از تحلیل عدم قطعیت دو مدل ANN و ANFIS مشخص گردید که مدل ANFIS نسبت به مدل ANN از عدم قطعیت کمتری برخوردار است و از این لحاظ بر مدل ANN برتری دارد.

واژه‌های کلیدی: مونت-کارلو، ضریب انتشار طولی، شبکه عصبی، سیستم استنتاج فازی-عصبی تطبیقی، شاخص عرض باند

Accuracy and Uncertainty Analysis of Intelligent Techniques for Predicting the Longitudinal Dispersion Coefficient in Rivers

Abbas Akbarzadeh¹ Roohollah Noori² Ashkan Farokhnia³
Amir Khakpour⁴ Mohammad Salman Sabahi⁵

(Received May. 6, 2009 Accepted Jun. 1, 2010)

Abstract

Accurate prediction of longitudinal dispersion coefficient (LDC) can be useful for the determination of pollutants concentration distribution in natural rivers. However, the uncertainty associated with the results obtained from forecasting models has a negative effect on pollutant management in water resources. In this research, appropriate models are first developed using ANN and ANFIS techniques to predict the LDC in natural streams. Then, an uncertainty analysis is performed for ANN and ANFIS models based on Monte-Carlo simulation. The input parameters of the models are related to hydraulic variables and stream geometry. Results indicate that ANN is a suitable model for predicting the LDC, but it is also associated with a high level of uncertainty. However, results of uncertainty analysis show that ANFIS model has less uncertainty; i.e. it is the best model for forecasting satisfactorily the LDC in natural streams.

Keywords: Monte-Carlo, Longitudinal Dispersion Coefficient, Neural Network, Adaptive Neuro-Fuzzy Inference System, Bound Wide Factor.

1. Assist. Prof., Water Research Institute, Ministry of Energy, Tehran
2. Member of Water Research Institute, Ministry of Energy, Ph.D. Student of Environmental Eng., Dept. of Environmental Eng., Tehran University (Corresponding Author) (+98 21) 77000305 roohollahnoori@gmail.com
3. Member of Water Research Institute, Ministry of Energy, Ph.D. Student of Hydraulic Structures Eng., Tarbiat Modarres University, Tehran.
4. Management Director of CELCO., Ph.D. Student of Environmental Eng., Dept. of Environmental, Tehran University
5. Ph.D. Student of Environmental Eng., Dept. of Environmental, Tehran University

- ۱- استادیار، معاونت مؤسسه تحقیقات آب، وزارت نیرو، تهران
- ۲- کارشناس مؤسسه تحقیقات آب، وزارت نیرو، دانشجوی دکتری مهندسی محیط زیست، دانشکده محیط زیست، دانشگاه تهران (نویسنده مسئول) ۷۷۰۰۰۳۰۵ (۰۲۱) roohollahnoori@gmail.com
- ۳- کارشناس مؤسسه تحقیقات آب، وزارت نیرو، دانشجوی دکتری مهندسی سازه‌های آبی، دانشگاه تربیت مدرس، تهران
- ۴- مدیرعامل شرکت عمران زیست آزما (CELCO)، دانشجوی دکتری مهندسی محیط زیست، دانشکده محیط زیست، دانشگاه تهران
- ۵- دانشجوی دکتری مهندسی محیط‌زیست، دانشکده محیط‌زیست، دانشگاه تهران

که مدل پیشنهادی وی از دقت بالاتری (حدود ۱۴ درصد) برخوردار است [۲ و ۴]. ریاحی و همکاران در تحقیقی دیگر با استفاده از مدل ANFIS اقدام به مدل‌سازی LDC نمودند و نتایج خود را با نتایج سایر محققان مقایسه نمودند که نتایج حاکی از عملکرد بهتر مدل پیشنهادی توسط آنها بود [۱۰].

تحلیل عدم قطعیت مدل‌های هوشمند، با توجه به این مطلب که پیش‌بینی‌ها قطعی نیستند، می‌تواند یکی از جنبه‌های مهم تحقیقی در استفاده و توسعه مدل‌های مذکور باشد. به هر حال باید دقت داشت که برای اعمال نتایج این مدل‌ها به منظور کاربردهای مدیریتی در منابع آب، داشتن اطلاعاتی در مورد عدم قطعیت این مدل‌ها می‌تواند راهگشا باشد و در تصمیم‌گیری مدیران ذی‌ربط کمک شایانی نماید. با سیری در تحقیقات انجام گرفته توسط مدل‌های ANN و ANFIS کمبود چنین تحقیقاتی در زمینه مطالعات کیفی منابع آب به‌وضوح دیده می‌شود. همچنین بررسی مراجع نشان می‌دهد که در مطالعات بسیار محدودی، تحلیل عدم قطعیت این مدل‌ها مورد تحقیق قرار گرفته است. با بررسی منابع موجود در این خصوص با توجه روشهای متعدد، روش پیشنهاد شده توسط مارسی و همکاران^{۱۷} به دلیل جدید بودن و عملکرد مناسب آن، در این تحقیق مورد توجه قرار گرفت [۱۱، ۱۲ و ۱۳]. این روش بر مبنای قرارگیری مدل‌ها در قالب یک پروسه نمونه‌گیری تصادفی مونت-کارلو^{۱۸} است. عقیل و همکاران با استفاده از این روش، عدم قطعیت مقادیر خروجی مدل ANFIS را در پیش‌بینی جریان هفتگی رودخانه مورد بررسی قرار دادند و استفاده از روش مونت کارلو را برای مدل ANFIS مناسب گزارش نمودند [۱۴]. نوری و همکاران نیز از این روش به منظور آنالیز عدم قطعیت مدل‌های ANN و ANFIS برای پیش‌بینی تولید زیاله هفتگی استفاده نمودند [۱۵]. در این تحقیق با توجه به مطالب ذکر شده موارد زیر مورد بررسی قرار گرفت:

الف- توسعه مدل‌های ANN و ANFIS برای پیش‌بینی LDC

ب- آنالیز عدم قطعیت نتایج مدل‌های ANN و ANFIS

ج- مقایسه عملکرد دو مدل ANN و ANFIS در پیش‌بینی LDC

۲- مواد و روشها

۲-۱- اطلاعات مسئله

معمولاً ابزار ریاضی مدل‌سازی پدیده‌های طبیعی و به تبع آن پدیده‌های زیست‌محیطی، مدل‌های قطعی^{۱۹} یا مدل‌های آماری است. مدل‌های قطعی بر مبنای روابط علی و معلولی و در مهندسی

برای کنترل کیفی منابع آب، لازم است تزریق آلاینده‌ها به رودخانه‌های طبیعی و کانال‌ها با روشهای منطقی و دقیق انجام پذیرد. این عمل نیازمند آگاهی دقیق از توانایی انتقال آلاینده مذکور در رودخانه و اختلاط و قدرت خودپالایی رودخانه است. به این منظور پیش‌بینی ضریب انتشار طولی (LDC)^۱ که یکی از مهم‌ترین پارامترهای هیدرولیکی است، می‌تواند برای نیل به این هدف بسیار مؤثر باشد.

تلاشهای زیادی طی چند دهه اخیر برای تخمین LDC در رودخانه‌های طبیعی توسط محققان مختلف انجام گرفته است که مدل‌های داده محور در این زمینه سهم مهمی را به خود اختصاص داده‌اند. تیفور^۲ و سینگ^۳ در تحقیقی اقدام به مدل‌سازی LDC در رودخانه‌های طبیعی با استفاده از شبکه عصبی مصنوعی (ANN)^۴ نمودند. آنها با مقایسه نتایج به دست آمده از کار خود با تحقیقات انجام گرفته توسط کاشفی پور و فالکنر^۵، فیشر^۶، سئو^۷ و چونگ^۸ و دنگ و همکاران^۹، برتری مدل ارائه شده توسط خود را نتیجه گرفتند [۱-۵]. توپراک^{۱۰} و سیگیزاوغلو^{۱۱} با استفاده از سه نوع مدل ANN شامل شبکه پیش‌خور پس‌انتشار^{۱۲}، تابع پایه شعاعی^{۱۳} و شبکه عصبی رگرسیونی تعمیم یافته^{۱۴} به محاسبه LDC پرداختند [۶].

نوری و همکاران طی تحقیقی، به مرور انتقادی کارهای انجام گرفته در زمینه پیش‌بینی LDC پرداختند و در نهایت نیز مدل مناسبی با استفاده از سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)^{۱۵} و ماشین بردار پشتیبان (SVM)^{۱۶} پیشنهاد نمودند [۷]. ریاحی و همکاران با استفاده از مدل ANFIS، چارچوب مناسبی برای تخمین LDC ارائه نمودند [۸]. در تحقیقی دیگر نیز کاشفی پور با استفاده از ANN و به‌کارگیری پارامترهای بدون بعد شده هیدرولیکی و هندسی جریان، اقدام به پیش‌بینی ضریب انتشار طولی در مجاری روباز نمود [۹]. وی در نهایت با مقایسه نتایج خود با نتایج سئو و چونگ و کاشفی پور و فالکنر به این نتیجه رسید

¹ Longitudinal Dispersion Coefficient (LDC)

² Tayfur

³ Singh

⁴ Artificial Neural Network (ANN)

⁵ Falconer

⁶ Fischer

⁷ Seo

⁸ Cheong

⁹ Deng et al.

¹⁰ Toprak

¹¹ Cigizoglu

¹² Feedforward Backpropagation

¹³ Radial Base Function (RBF)

¹⁴ Generalized Regression Neural Network

¹⁵ Adaptive Neuro-Fuzzy Inference System (ANFIS)

¹⁶ Support Vector Machine (SVM)

¹⁷ Marce et al.

¹⁸ Monte-Carlo

¹⁹ Deterministic Models

در جدول ۲ مشخصات آماری هر یک از متغیرهای ورودی و خروجی به دو مدل ANN و ANFIS نشان داده شده است.

۲-۲- شبکه عصبی مصنوعی

با توجه به مراجع کافی برای مدل ANN، در این تحقیق به توضیحاتی اندک در مورد نوع شبکه مورد استفاده و تقسیم‌بندی متغیرهای مسئله برای ورود به مدل‌های مذکور اشاره شد [۲۱-۲۳]. در استفاده از ANN مشکلی که همواره وجود دارد مشکل فوق برازشی^۱ شبکه است که در این حالت آموزش شبکه به خوبی انجام می‌شود ولی شبکه از جامعیت مناسب برخوردار نیست یعنی نتایج به دست آمده برای مرحله تست شبکه با خطای زیادی همراه است. برای رفع این مشکل از روش الگوریتم توقف آموزش (STA)^۲ استفاده شد. در این روش، متغیرهای مورد استفاده به سه دسته آموزش و صحت‌سنجی (مجموعاً اطلاعات کالیبراسیون مدل را تشکیل می‌دهند) و دسته تست، تقسیم می‌شوند [۲۴]. تابع انتقال نیز در لایه پنهان و خروجی شبکه به ترتیب تابع سیگموئیدی و خطی انتخاب شدند. همچنین برای بهینه کردن پارامترهای شبکه نیز از الگوریتم لونیبرگ-مارکوویت^۳ (LM) استفاده گردید.

۲-۳- سیستم استنتاج فازی-عصبی تطبیقی

ANFIS یکی از مدل‌های توسعه یافته فازی بر مبنای به‌کارگیری تکنیک‌های آموزش مختلف در ANN است که عملکرد موفقی را در مدل‌سازی توابع غیرخطی از خود نشان داده است [۲۵-۲۶]. این مدل از یک شبکه پیش‌خور برای بهینه کردن پارامترهای سیستم استنتاج فازی (FIS)^۴ استفاده می‌کند. الگوریتم آموزش برای مدل ANFIS شامل یک الگوریتم ترکیبی متشکل از روشهای کاهش گرادیان و حداقل مربعات است [۲۶-۲۷]. معمول‌ترین نوع FIS که قابلیت قرارگیری در یک شبکه تطبیقی را داراست، سیستم فازی سوگنو می‌باشد که خروجی آن یک رابطه خطی است و پارامترهای آن را می‌توان با ترکیب روشهای حداقل مربعات خطا و انتشار خطا به عقب بر اساس کاهش گرادیان برآورد نمود [۲۶]. در مورد ANFIS و الگوریتم ترکیبی مورد استفاده آن، مطالعات گسترده‌ای صورت گرفته است [۲۵-۲۷]. در شکل‌های ۱ و ۲ به ترتیب نمونه‌ای از سیستم استنتاج فازی سوگنو مرتبه اول که دارای دو ورودی y و x و خروجی z است و همچنین معماری ANFIS معادل آن نشان داده شده است.

محیط‌زیست غالباً برگرفته از قانون بقای جرم است. از جمله مدل‌های قطعی می‌توان به مدل‌های توسعه داده شده در زمینه کیفیت آب مانند Qual2K و C-Equal-W2 اشاره نمود. از طرفی مدل‌های آماری، داده محور بوده و بر مبنای تجربیات مشاهده شده استوارند. مدل‌های ANN و ANFIS نیز جزء مدل‌های پیشرفته آماری و اساساً داده محور هستند. اطلاعات ورودی به این مدل‌ها نیز بسته به هدف تحقیق، مختلف است و غالباً از دو طریق مشخص می‌شوند: با استفاده از تجربیات مهندسی و یا با استفاده از ابزار ریاضی. به‌عنوان مثال بررسی تحقیقات مختلف نشان می‌دهد که اطلاعات مورد نیاز برای تخمین دبی یک رودخانه توسط این دو ابزار تا حدود زیادی به تجربیات مهندسی محقق مربوط می‌شود. به‌همین دلیل در مقالات متعدد، اطلاعات مختلفی برای این منظور مورد استفاده قرار گرفته است [۱۳-۱۴].

ورودی به مدل‌های ANN و ANFIS در مورد برخی پدیده‌ها با استفاده از استدلال‌های ریاضی مشخص، تعیین می‌شوند. به‌عنوان مثال در این مورد می‌توان به موضوع مقاله حاضر که ضریب انتشار طولی رودخانه‌هاست، اشاره نمود. با استفاده از آنالیز تشابه ابعادی صورت گرفته در این مورد، مشخص شده که این ضریب، تابعی از پارامترهای عرض، عمق، سرعت، سرعت برشی، عدد رینولدز و فاکتور شکل بستر است. با توجه به ناچیز بودن اهمیت عدد رینولدز در رودخانه‌ها و همچنین مشکل بودن محاسبه فاکتور شکل بستر، در بیشتر مطالعات انجام شده در این زمینه از ۴ پارامتر استفاده شده در تحقیق مذکور، به‌عنوان ورودی به مدل استفاده شده است [۴]. با توجه به مشکل بودن حل معادله یک بعدی انتقال-پخش مربوط به LDC و نیاز به اطلاعات زیاد، از سال ۱۹۶۰ به بعد مطالعات گسترده‌ای در زمینه ارائه مدلی مناسب برای تخمین این پارامتر در رودخانه‌ها شروع شد و تاکنون نیز ادامه دارد. در طی سالیان گذشته اطلاعات ثبت شده زیادی از عرض رودخانه (W)، عمق رودخانه (H)، سرعت جریان (U) و سرعت برشی جریان (U^*) در رودخانه‌های مختلف آمریکا توسط محققان مختلفی از سرتاسر دنیا مورد استفاده قرار گرفته است. هر محقق با استفاده از این اطلاعات سعی در ارائه مدلی مناسب به این منظور داشته است که برخی از این اطلاعات در مقاله مذکور مورد استناد قرار گرفته‌اند (جدول ۱) [۱۶-۲۰]. لازم به ذکر است که برای مدل‌سازی ضریب انتشار طولی، بازه یا سال نمونه‌برداری جزء پارامترهای مورد نیاز محسوب نمی‌شوند و تمامی اطلاعات ثبت شده از رودخانه‌ها طی سالیان گذشته در مقالات مختلف، فاقد این اطلاعات بوده‌اند و تنها به ارائه اطلاعات ورودی ذکر شده و خروجی (ضریب انتشار طولی) در کنار نام رودخانه بسنده کرده‌اند. در این تحقیق نیز از اطلاعات موجود عرض، عمق، سرعت و سرعت برشی جریان استفاده شد.

¹ Overfitting

² Stop Training Algorithm (STA)

³ Levenberg-Marquardt (LM)


⁴ Fuzzy Inference System (FIS)

جدول ۱- اطلاعات خام ورودی مورد استفاده در تحقیق مذکور


No.	Reference	Channel	W (m)	H (m)	U (m/s)	U* (m/s)	LDC (m ² /s)	No.	Reference	Channel	W (m)	H (m)	U (m/s)	U* (m/s)	LDC (m ² /s)
1	Nordin and Sabol [20]	Wind/Bighorn River	85.34	2.38	1.74	0.153	464.6	51	Fischer [16]	Copper Creek	80	2.74	0.14	0.0097	34.9
2	Godfrey and Frederick [17]	Copper Creek	18.29	0.38	0.15	0.116	20.71	52	McQuivey and Keefer [19]	Comite River	12.5	0.26	0.31	0.043	6.97
3	Godfrey and Frederick [17]	Clinch River	57.91	2.45	0.75	0.104	40.49	53	McQuivey and Keefer [19]	John Day River	24.99	0.56	1.01	0.14	13.94
4	Nordin and Sabol [20]	Comite River	15.7	0.23	0.36	0.039	69	54	Godfrey and Frederick [17]	Clinch River	48.46	1.16	0.21	0.069	14.76
5	Nordin and Sabol [20]	Conococheague Creek	42.21	0.69	0.23	0.064	40.8	55	Godfrey and Frederick [17]	Clinch River	53.24	2.41	0.66	0.107	36.93
6	McQuivey and Keefer [19]	Radkin River	71.63	3.84	0.76	0.128	260.13	56	Fischer [16]	Clinch River	36	0.58	0.3	0.049	8.08
7	Nordin and Sabol [20]	Sabine River	14.17	0.5	0.13	0.037	12.8	57	Fischer [16]	Copper Creek	15.9	0.49	0.21	0.079	19.52
8	Fischer [16]	Clinch River	53.3	2.09	0.79	0.107	46.45	58	McQuivey and Keefer [19]	Elkhorn River	32.6	0.3	0.43	0.046	9.29
9	Nordin and Sabol [20]	Sabine River	12.19	0.51	0.23	0.03	14.7	59	Fischer [16]	Power River	33.8	0.85	0.16	0.055	9.5
10	Nordin and Sabol [20]	Tickfau River	14.94	0.59	0.27	0.08	10.3	60	Nordin and Sabol [20]	Tangioahoa River	31.39	0.81	0.48	0.072	45.1
11	Nordin and Sabol [20]	Sabine River	160.32	2.32	1.06	0.054	308.9	61	McQuivey and Keefer [19]	Bayou Anacoco	36.58	0.91	0.4	0.067	39.48
12	McQuivey and Keefer [19]	Sabine River	127.4	4.75	0.64	0.081	668.9	62	McQuivey and Keefer [19]	Missouri River	183	2.33	0.89	0.066	465
13	Nordin and Sabol [20]	Sabine River	21.34	0.93	0.36	0.035	24.2	63	McQuivey and Keefer [19]	Elkhorn River	50.9	0.42	0.46	0.046	20.9
14	Godfrey and Frederick [17]	Powell River	36.78	0.87	0.13	0.054	15.5	64	McQuivey and Keefer [19]	Bayou Anacoco	80	2.74	0.034	0.0024	22.3
15	Godfrey and Frederick [17]	Powell River	20	0.42	0.29	0.045	13.9	65	McQuivey and Keefer [19]	Wind/Bighorn River	67.1	0.98	0.88	0.11	41.81
16	McQuivey and Keefer [19]	Antietam Creek	19.8	0.52	0.43	0.069	9.29	66	Fischer [16]	Copper Creek	18.3	0.84	0.52	0.1	21.4
17	Nordin and Sabol [20]	Chattahoochee River	75.59	1.95	0.74	0.138	88.9	67	McQuivey and Keefer [19]	John Day River	34.14	2.47	0.82	0.169	65.03
18	McQuivey and Keefer [19]	Missouri River	182.9	2.23	0.93	0.065	464.52	68	McQuivey and Keefer [19]	Wind/Bighorn River	68.58	2.16	1.55	0.168	162.58
19	Nordin and Sabol [20]	Monocacy River	97.54	1.15	0.32	0.058	119.8	69	McQuivey and Keefer [19]	Chattahoochee River	65.5	1.13	0.39	0.075	32.52
20	McQuivey and Keefer [19]	Wind/Bighorn River	59.44	1.1	0.88	0.119	41.81	70	McQuivey and Keefer [19]	Missouri River	197	3.11	1.53	0.078	892
21	McQuivey and Keefer [19]	Sabine River	35.1	0.98	0.21	0.041	39.48	71	McQuivey and Keefer [19]	Bayou Anacoco	19.8	0.41	0.29	0.044	13.94
22	Nordin and Sabol [20]	Chattahoochee River	16.66	0.49	0.2	0.08	16.84	72	Nordin and Sabol [20]	Diffcult Run	14.48	0.31	0.25	0.062	1.9
23	Nordin and Sabol [20]	Bayou Bartholomew	17.53	0.45	0.32	0.024	5.8	73	Nordin and Sabol [20]	Red River	155.14	1.74	0.47	0.036	177.7
24	McQuivey and Keefer [19]	Monocacy River	36.6	0.45	0.32	0.051	13.94	74	Nordin and Sabol [20]	Monocacy River	48.7	0.55	0.26	0.052	37.8
25	McQuivey and Keefer [19]	Amite River	42.4	0.8	0.42	0.069	30.2	75	Nordin and Sabol [20]	Little Pincy Creek	15.85	0.22	0.39	0.053	7.1
26	Seo and Cheong (1998)	Monocacy River	92.96	0.71	0.16	0.046	41.4	76	McQuivey and Keefer [19]	Nooksack River	86	2.94	1.2	0.514	153.29
27	Fischer [16]	Copper Creek	18.6	0.39	0.14	0.116	9.85	77	Godfrey and Frederick [17]	Copper Creek	16.76	0.47	0.24	0.08	24.62
28	McQuivey and Keefer [19]	Muddy Creek	19.5	1.2	0.45	0.093	32.5	78	Nordin and Sabol [20]	Antletam Creek	21.03	0.48	0.62	0.069	25.9
29	Fischer [16]	Copper Creek	16.2	0.49	0.25	0.079	9.5	79	McQuivey and Keefer [19]	Susquehanna River	203	1.35	0.39	0.065	92.9
30	McQuivey and Keefer [19]	Missouri River	201	3.56	1.28	0.082	836.13	80	McQuivey and Keefer [19]	Antietam Creek	15.8	0.39	0.32	0.06	9.29
31	Nordin and Sabol [20]	Chattahoochee River	91.9	2.44	0.52	0.094	166.9	81	Nordin and Sabol [20]	Mississippi River	533.4	4.94	1.05	0.069	457.7
32	McQuivey and Keefer [19]	Amite River	37	0.81	0.29	0.07	23.2	82	Nordin and Sabol [20]	Mississippi River	711.2	19.94	0.56	0.041	237.2
33	Seo and Cheong (1998)	Mississippi River	537.38	8.9	1.51	0.097	341.1	83	Nordin and Sabol [20]	Amite River	21.34	0.52	0.54	0.027	501.4
34	Godfrey and Frederick [17]	Clinch River	28.65	0.61	0.35	0.069	10.7	84	Nordin and Sabol [20]	Tangioahoa River	29.87	0.4	0.34	0.02	44
35	Yotsukura et al. (1970)	Missouri River	180.59	3.28	1.62	0.078	1486.45	85	Nordin and Sabol [20]	Red River	253.59	1.62	0.61	0.032	143.8
36	McQuivey and Keefer [19]	Nooksack River	64.01	0.76	0.67	0.268	34.84	86	Nordin and Sabol [20]	Bear Creek	13.72	0.85	1.29	0.553	2.9
37	McQuivey and Keefer [19]	Comite River	15.8	0.41	0.37	0.055	13.94	87	Nordin and Sabol [20]	Red River	161.54	3.96	0.29	0.06	130.5
38	Nordin and Sabol [20]	Antletam Creek	12.8	0.3	0.42	0.057	17.5	88	Nordin and Sabol [20]	Red River	152.4	3.66	0.45	0.057	227.6
39	Nordin and Sabol [20]	Monocacy River	51.21	0.65	0.62	0.044	29.6	89	McQuivey and Keefer [19]	Muddy Creek	13.4	0.81	0.37	0.077	13.9
40	Fischer [16]	Clinch River	59.4	2.13	0.86	0.104	53.88	90	Nordin and Sabol [20]	Wind/Bighorn River	44.2	1.37	0.99	0.142	184.6
41	Seo and Cheong (1998)	Monocacy River	40.54	0.41	0.23	0.04	66.5	91	McQuivey and Keefer [19]	Monocacy River	47.5	0.87	0.44	0.07	37.16
42	McQuivey and Keefer [19]	Antietam Creek	24.4	0.71	0.52	0.081	25.55	92	Nordin and Sabol [20]	Antletam Creek	11.89	0.66	0.43	0.085	20.9
43	Nordin and Sabol [20]	Sabine River	116.43	1.65	0.58	0.054	131.3	93	Nordin and Sabol [20]	Bayou Bartholomew	33.38	1.4	0.2	0.031	54.7
44	McQuivey and Keefer [19]	White River	16	0.43	0.37	0.056	13.9	94	McQuivey and Keefer [19]	Bayou Anacoco	25.91	0.94	0.34	0.067	32.52
45	McQuivey and Keefer [19]	Monocacy River	35.1	0.32	0.21	0.043	4.65	95	Nordin and Sabol [20]	Conococheague Creek	49.68	0.41	0.15	0.081	29.3
46	Fischer [16]	Clinch River	46.9	0.86	0.28	0.067	13.93	96	McQuivey and Keefer [19]	Radkin River	70.1	2.35	0.43	0.101	111.48
47	McQuivey and Keefer [19]	White River	67	0.55	0.35	0.044	30.2	97	Nordin and Sabol [20]	Antletam Creek	24.08	0.98	0.59	0.098	101.5
48	Nordin and Sabol [20]	Salt Creek	32	0.5	0.24	0.038	52.2	98	Godfrey and Frederick [17]	Copper River	19.61	0.84	0.49	0.101	20.82
49	McQuivey and Keefer [19]	Sabine River	103.6	2.04	0.56	0.054	315.87	99	Godfrey and Frederick [17]	Conchella Canal	24.69	1.58	0.66	0.041	5.92
50	Nordin and Sabol [20]	Conococheague Creek	42.98	1.13	0.63	0.081	53.3	100	Fischer [16]	Coachell Canal	24.4	1.56	0.67	0.043	9.57

جدول ۲- برخی از مهم ترین مشخصات آماری پارامترهای مورد استفاده در این تحقیق

مشخصه آماری	ضریب انتشار طولی (مترمربع بر ثانیه)	عرض رودخانه (متر)	عمق رودخانه (متر)	سرعت جریان (متر بر ثانیه)	سرعت برشی جریان (متر بر ثانیه)
میانگین	۱۱۵/۳	۷۳/۲	۱/۵۴	۰/۵۳	۰/۰۸۱
بیشینه	۱۴۸۶/۵	۷۱۱/۲	۱۹/۹۴	۱/۷۴	۰/۵۵۳
کمینه	۱/۹	۱۱/۹	۰/۲۲	۰/۰۳	۰/۰۰۲
میانه	۳۳/۷	۳۶/۹	۰/۸۶	۰/۴۳	۰/۰۶۷
انحراف معیار	۲۱۸/۷	۱۰۶/۹	۲/۲۷	۰/۳۶	۰/۰۷۵



شکل ۱- سیستم استنتاج فازی سوگنو



شکل ۲- معماری مدل ANFIS معادل سیستم استنتاجی فازی مورد بحث


۲-۴- برآورد عدم قطعیت در پیش‌بینی‌ها

مهم‌ترین هدف این تحقیق بررسی و تخمین عدم قطعیت در خروجی مدل‌های ANN و ANFIS بود. اساس کار روش شبیه‌سازی مونت-کارلو بر پایه استفاده از اعداد تصادفی و حصول تابع توزیع احتمالاتی خروجی یک مدل است. به این صورت که متغیرها (ورودی به مدل) با استفاده از تابع توزیع احتمالاتی مربوط، به‌طور تصادفی تولید شده و سپس خروجی معادل آنها از مدل مورد نظر به دست می‌آید و این عمل بارها تکرار می‌شود. در مرحله بعد نیز عدم قطعیت خروجی (تابع) از طریق محاسبه شاخصهای آماری و یا تعیین تابع توزیع احتمالاتی برآورد می‌شود [۲۸]. تفاوت روش مورد بحث در این تحقیق با تعریف بالا، استفاده از نمونه‌های تصادفی گرفته شده به جای اعداد تصادفی ساخته شده، بود. این روش به روش نمونه‌گیری دودویی Bootstrap

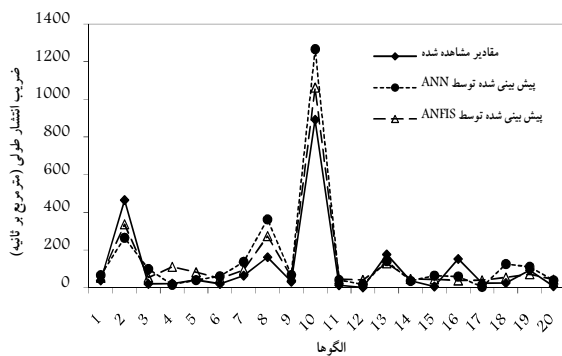
بسیار شباهت داشته و تنها فرق آن در عدم تکرار یک الگو در یک نمونه است [۲۹]. در این روش ابتدا از اطلاعاتی که برای کالیبراسیون مدل در نظر گرفته شده‌اند به دفعات زیاد (در این تحقیق ۱۰۰ بار) بدون تکرار نمونه‌گیری می‌شود به نحوی که تعداد داده‌های کالیبراسیون در هر نمونه یکسان باشد و برای هر نمونه عملیات کالیبراسیون مدل انجام می‌گردد [۱۴]. در نتیجه پارامترهای مدل به دفعات زیاد و هر بار بر اساس نمونه‌ای از وقایع اتفاق افتاده در گذشته، به دست می‌آیند. با استفاده از این تکنیک محاسباتی حجیم، به جای پیش‌بینی یک عدد مطلق مطابق با آنچه در تحقیقات مشابه انجام گرفته، محدوده‌ای از خروجی که نتیجه عدم قطعیت مدل ساخته شده است، حاصل خواهد شد. برای بررسی عدم قطعیت، حدود اطمینان ۹۵ درصد (95PPU)^۱ برای پیش‌بینی‌ها مد

^۱ 95 Percent Prediction Uncertainty (95PPU)

شکل ۵ آمده است. همچنین شاخصهای عدم قطعیت این مدل در جدول ۳ ارائه شده‌اند. به منظور ارائه متوسط پیش‌بینی LDC، از ۱۰۰ پیش‌بینی انجام شده توسط مدل ANN میانگین گرفته شد که نتایج این تحلیل در جدول ۳ ارائه شده است.



شکل ۳- مقادیر تجربی در مقابل پیش‌بینی شده LDC در مرحله کالیبراسیون دو مدل ANN و ANFIS



شکل ۴- مقادیر تجربی در مقابل پیش‌بینی شده LDC در مرحله تست دو مدل ANN و ANFIS

۳-۲- توسعه مدل ANFIS

در لایه اول ANFIS، مقادیر هر متغیر ورودی باید به چند کلاس برای ساختن قوانین مربوط دسته‌بندی شود. قوانین فازی از ترکیب دو یا چند تابع عضویت در لایه دوم ساخته می‌شوند. برای کلاس‌بندی داده‌های ورودی و ساخت قوانین، روشهای متعددی پیشنهاد گردیده است که رایج‌ترین آنها عبارت‌اند از: افزای شبکه‌ای^۱ و خوشه‌بندی فازی کاهشی^۲. در این تحقیق از روش خوشه‌بندی فازی کاهشی برای ساخت توابع عضویت و قوانین استفاده شد [۳۱ و ۳۲]. این روش بر مبنای اندازه‌گیری تراکم نقاط موجود در فضای متغیرهای مورد استفاده است که آنها را براساس شعاع جستجوی داده شده محاسبه می‌کند. برای تعیین مقدار مناسب I_a از

نظر قرار گرفت که طریقه به‌دست آوردن آن تعیین حدود $2/5$ درصد (X_L) و $97/5$ درصد (X_U) توزیع نرمال تجربی به‌دست آمده از ۱۰۰ پیش‌بینی انجام شده، بود. حدود اطمینان مناسب حدودی است که بالای ۸۰ درصد از پیش‌بینی‌های انجام گرفته توسط هر یک از دو مدل ANN و ANFIS، در آن حدود قرار گرفته و دارای عرض متوسط قابل قبولی باشند [۱۵]. برای سنجش عرض متوسط باند اطمینان، شاخص فاکتور عرض باند مطابق رابطه (۱) پیشنهاد شد [۳۰].

$$d - \text{factor} = \frac{\bar{d}_x}{\sigma_x} \quad (1)$$

که در این رابطه

σ_x انحراف استاندارد مقادیر LDC اندازه‌گیری شده و \bar{d}_x عرض متوسط باند اطمینان است که مطابق رابطه ۲ تعریف می‌شود:

$$\bar{d}_x = \frac{1}{n} \sum_{i=1}^k (X_U - X_L) \quad (2)$$

در حالت کلی مقدار فاکتور عرض باند کوچک‌تر از ۱ مناسب به حساب می‌آید [۳۰].

لازم به ذکر است که برای مدل‌سازی LDC در این تحقیق با استفاده از ANN و ANFIS و همچنین تعیین عدم قطعیت این دو مدل از نرم‌افزار MATLAB استفاده شد.

۳- بحث و نتایج


۳-۱- توسعه مدل ANN

در این تحقیق از تابع سیگموئید از نوع تانژانتی در لایه پنهان شبکه استفاده شد. مقادیر خروجی این تابع بین ۱ و ۱- قرار می‌گیرند. بنابراین متغیرها قبل از ورود به ANN بین مقادیر ۱ و ۱- استاندارد شدند. در مرحله بعد با روش سعی و خطا و تغییر در تعداد نرون‌های لایه پنهان شبکه، بهترین ساختار شبکه که شامل ۴ نرون در لایه پنهان شبکه بود، برای پیش‌بینی LDC به‌دست آمد. نتایج مرحله آموزش و تست مدل بهینه مذکور به ترتیب در شکل‌های ۳ و ۴ ارائه شده است. شکل ۴ که بیانگر نتایج مرحله تست ANN است، نشان می‌دهد که مقادیر پیش‌بینی شده توسط مدل، تطابق خوبی با مقادیر مشاهده‌ای دارد که این مسئله بیانگر دقت مطلوب مدل ANN در پیش‌بینی LDC در رودخانه‌های طبیعی است. بعد از آموزش مدل بهینه ANN، از آن برای تحلیل عدم قطعیت استفاده گردید و پس از به‌دست آوردن ۱۰۰ مقدار برای پیش‌بینی، حدود اطمینان ۹۵ درصد توسط مدل ANN از طریق تعیین مقادیر $2/5$ درصد و $97/5$ درصد توزیع نرمال به‌دست آمده، مشخص گردید. حدود اطمینان ۹۵ درصد در مراحل کالیبراسیون و تست ANN در


¹ Grid Partition

² Subtractive Fuzzy Clustering

مشخص می‌شود که مدل ANFIS نسبت به مدل ANN عملکرد بهتری دارد و از عدم قطعیت کمتری در پیش‌بینی LDC در رودخانه‌های طبیعی برخوردار است.



شکل ۵- عرض باند اطمینان ۹۵ درصد برای پیش‌بینی LDC در مراحل کالیبراسیون و تست مدل ANN



شکل ۶- عرض باند اطمینان ۹۵ درصد برای پیش‌بینی LDC در مراحل کالیبراسیون و تست مدل ANFIS

۴- نتیجه‌گیری

اندازه‌گیری ضریب انتشار طولی در رودخانه‌های طبیعی نیازمند صرف وقت و هزینه‌های زیادی است. به همین دلیل استفاده از مدلی که توانایی مدل‌سازی دقیق این پدیده دینامیک و پیچیده را داشته باشد به‌عنوان جایگزینی مناسب سالهاست که مد نظر محققان مختلف بوده است. در این راستا هدف اصلی مقاله حاضر ارائه مدلی برای این منظور با استفاده از مدل‌های هوشمند ANN و ANFIS بود. نکته دیگر مشکل وجود عدم قطعیت در ارائه نتایج است که گام بعدی این مقاله نیز پیشنهاد چارچوبی مناسب در تحلیل عدم قطعیت مدل‌های ANN و ANFIS بر مبنای روش مونت-کارلو جهت LDC در رودخانه‌های طبیعی بود.

روش سعی و خطا استفاده شد. به این منظور اعداد ۰/۱ تا ۰/۹ با گام افزایشی ۰/۰۵ مورد استفاده قرار گرفتند و در پایان مقدار مناسب T_e تعیین گردید. این مقدار برابر ۰/۳۶ به دست آمد که نتیجه آن تابع عضویت برای هر ورودی بود. بعد از تعیین ساختار اولیه FIS، کالیبراسیون و تست مدل انجام و مدل بهینه ANFIS ساخته شد. شکل‌های ۳ و ۴ بیانگر نتایج به دست آمده در مرحله آموزش و تست مدل بهینه ANFIS است. مطابق شکل ۴ مشاهده می‌شود که مدل ANFIS نیز همانند ANN در مدل‌سازی LDC دارای عملکرد موفقیت‌آمیزی است هر چند که مدل ANN در برخی موارد و خصوصاً در مقادیر بزرگ LDC از عملکرد بهتری برخوردار است. برای تحلیل عدم قطعیت این مدل همانند مرحله قبل عمل شد. حدود اطمینان ۹۵ درصد در مراحل کالیبراسیون و تست ANFIS در شکل ۶ ارائه شده‌اند. به منظور ارائه متوسط پیش‌بینی LDC، از ۱۰۰ پیش‌بینی انجام شده توسط مدل ANFIS میانگین گرفته شد که نتایج این تحلیل در جدول ۳ ارائه شده است.

جدول ۳- نتایج کالیبراسیون و تست مدل‌های ANN و ANFIS

ANFIS		ANN		آماره
تست	کالیبراسیون	تست	کالیبراسیون	
۰/۹۲	۰/۸۷	۱/۵۴	۱/۶۹	d-factor
۹۵/۰۰	۷۶/۲۵	۱۰۰	۹۷/۵۰	Bracketed by 95PPU (%)
۰/۸۷	۰/۸۱	۰/۹۰	۰/۸۴	R ²

۳-۳- مقایسه عملکرد دو مدل ANN و ANFIS

همانطور که در شکل‌های ۵ و ۶ مشاهده می‌شود در اکثر پیش‌بینی‌ها، ANN دارای عدم قطعیت بیشتری در مقادیر خروجی بود. همچنین عرض باند اطمینان ۹۵ درصد ANN نسبت به مدل ANFIS پهنای بیشتری داشت به طوری که مقدار d-factor مدل ANN در هر دو مرحله کالیبراسیون و تست از مقدار d-factor مدل ANFIS بیشتر بود. در حالت کلی مقدار d-factor مدل ANN برای هر دو مرحله کالیبراسیون و تست از مقدار توصیه شده ۱، بزرگ‌تر بود در حالی که این مقدار در مدل ANFIS برای هر دو مرحله مذکور از مقادیر مطلوبی برخوردار بود. لذا با توجه به این فاکتور، برتری مدل ANFIS در هر دو مرحله کالیبراسیون و تست نسبت به مدل ANN مشاهده شد. از طرفی تعداد داده‌های مشاهداتی قرار گرفته شده در باند ۹۵ درصد در هر دو مرحله کالیبراسیون و تست برای مدل ANN از مدل ANFIS بیشتر بود که این امر به دلیل پهنای بیشتر باند در مدل ANN بود. به هر حال تعداد داده‌های مشاهداتی قرار گرفته شده در باند ۹۵ درصد مدل ANFIS نیز مقدار مطلوبی داشت. با توجه به مطالب ذکر شده و همچنین شکل‌های ۵ و ۶

به دست آمده برای مدل ANN از دقت کافی برخوردار نبود و عدم قطعیت زیادی به همراه داشت. به طور کلی می توان بیان نمود که نتایج به دست آمده از این تحقیق نشان دهنده قابلیت مناسب مدل های هوشمند در برآورد LDC در رودخانه های طبیعی بر مبنای ویژگی های فیزیکی آنها است. همچنین تحلیل عدم قطعیت نتایج مدل ها نشان داد که برآوردهای مدل ANFIS علاوه بر دقت مناسب، از عدم قطعیت قابل قبولی نیز برخوردار است که نشان دهنده پایداری و اطمینان پذیری این مدل در برآورد LDC در رودخانه هاست. بنابراین می توان در آینده برای موارد مطالعاتی و کاربردی که در اختیار داشتن LDC رودخانه مورد نیاز باشد، از مدل ANFIS توسعه داده شده در تحقیق حاضر استفاده نمود.

به منظور نیل به اهداف ذکر شده ابتدا مدل های مناسب ANN و ANFIS با استفاده از اطلاعات موجود در مراجع علمی، توسعه داده شد. نتایج بیانگر دقت قابل قبول هر دو مدل بود به طوری که شاخص R^2 در مرحله تست ANN و ANFIS به ترتیب معادل ۰/۹۰ و ۰/۸۷ به دست آمد. در این مرحله مشاهده شد که هر چند نتایج دو مدل ANN و ANFIS قابل قبول بودند اما در حالت کلی مدل ANN به خصوص در برآورد مقادیر بزرگ LDC از عملکرد نسبتاً بهتری برخوردار بود.

در مرحله بعد آنالیز عدم قطعیت مدل های مذکور انجام گرفت که نتایج آن بیانگر عدم قطعیت کمتر مدل ANFIS در هر دو مرحله کالیبراسیون و تست نسبت به مدل ANN بود. در این مرحله نتایج

۵- مراجع

- 1- Tayfur, G., and Singh, V.P. (2005). "Predicting longitudinal dispersion coefficient in natural streams by artificial neural network." *J. of Hydraulic Engineering*, 131 (11), 991-1000.
- 2- Kashefipour, M.S., and Falconer, R. A. (2002). "Longitudinal dispersion coefficients in natural channels." *Water Res.*, 36 (6), 1596-1608.
- 3- Fischer, B.H. (1975). "Discussion of 'Simple method for predicting dispersion in streams,' by R. S. McQuivey and T. N. Keefer." *J. of Environmental Engineering Div.*, 101 (3), 453-455.
- 4- Seo I. W., and Cheong, T.S. (1998). "Predicting longitudinal dispersion coefficient in natural Streams." *J. of Hydraulics Engineering*, 124 (1), 25-32.
- 5- Deng, Z.Q., Singh, V.P., and Bengtsson, L. (2001). "Longitudinal dispersion coefficient in straight rivers." *J. of Hydraulic Engineering*, 127 (1), 919-927.
- 6- Toprak, Z. F., and Cigizoglu, H.K. (2008). "Predicting longitudinal dispersion coefficient in natural streams by artificial intelligence methods." *Hydrol. Process*, 22 (20), 4106-4129.
- 7- Noori, R., Karbassi, A., Farokhnia, A., and Dehghani, M. (2009). "Predicting the longitudinal dispersion coefficient using support vector machine and adaptive neuro-fuzzy inference system techniques." *Environmental Engineering Science*, 26 (10), 1503-1510.
- 8- Riahi-Madvar, H., Ayyoubzadeh, S.A., Khadangi, E., and Ebadzadeh, M.M. (2009). "An expert system for predicting longitudinal dispersion coefficient in natural streams by using ANFIS." *Expert Systems with Applications*, 36 (4), 8589-8596.
- 9- Kashefipour, M. (2007). "Prediction of longitudinal dispersion coefficient in natural rivers using artificial neural networks." *Iranian J. of Hydraulic*, 3, 15-25. (In Persian)
- 10- Riahi madvar, H., and Ayyaoubzadeh, S. A. (2008). "Estimating longitudinal dispersion coefficient of pollutants using adaptive neuro-fuzzy inference system." *J. of Water and Wastewater*, 67, 34-46. (In Persian)
- 11- Tibshirani, R. (1994). *A comparison of some error estimates for neural network models*, No. 94-10, Technical Working Report, Department of Statistics, University of Toronto.
- 12- Dybowski, R. (1997). *Assigning confidence intervals to neural network predictions*, Technical report, Division of Infection (St Thomas' Hospital), King's College, London.
- 13- Marce, R., Comerma, M., García, J.C., and 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, 342-355.

- 14- Aqil, M., Kita, I., Yano, A., and Nishiyama, S. (2007). "Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool." *J. of Environmental Management*, 85 (1), 215-223.
- 15- 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.
- 16- Fischer, H.B. (1968). "Dispersion predictions in natural streams." *J. of Hydraulic Division*, 94(5), 927-943.
- 17- Godfrey, R.G., and Frederick, B.J. (1970). "Stream dispersion at selected sites." *U.S. Geological Survey*, Prof. Paper 433-K, Washington D.C.
- 18- Yotsukura, N., Fischer, H.B., and Sayre, W.W. (1970). "Measurement of mixing characteristics of the Missouri River between Sioux City, Iowa and Plattsmouth, Nebraska." *US Geological Survey Water-Supply*, Paper 1899-G, Washington, D.C.
- 19- McQuivey, R.S., and Keefer, T.N. (1974). "Simple method for prediction dispersion in streams." *J. of Environment Engineering*, 100 (4), 997-1011.
- 20- Nordin, C.F., and Sabol, G.V. (1974). "Empirical data on longitudinal dispersion in rivers." *U.S. Geological Survey Water Resources Investigation*, Washington D.C., 20-74.
- 21- Haykin, S. (1999). *Neural networks: A comprehensive foundation*, 2nd Ed., Prentice Hall, New Jersey.
- 22- Noori, R., Abdoli, M.A., Jalili-Ghazizade, M., and Samifard, R. (2009). "Comparison of ANN and PCA based multivariate linear regression applied to predict the weekly municipal solid waste generation in Tehran." *Iranian J. of Public Health*, 38 (1), 74-84.
- 23- Jalili-Ghazizade, M., and Noori, R. (2008). "Prediction of municipal solid waste generation by use of artificial neural network: A case study of Mashhad." *International J. of Environmental Research*, 2 (1), 22-33.
- 24- Noori, R., Farokhnia, A., Morid, S., and Riahi Madvar, H. (2009). "Effect of input variables preprocessing in artificial neural network on monthly flow prediction by PCA and wavelet transformation." *J. of Water and Wastewater*, 69, 13-22. (In Persian)
- 25- Jang, J.S.R., and Gulley, N. (1995). *The fuzzy logic toolbox for use with MATLAB*, Mathworks Inc., Massachusetts.
- 26- Jang, J.S.R., Sun, C.T, and Mizutani, E. (1997). *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*, Prentice-Hall, New Jersey.
- 27- Jang, J.S.R. (1991). "Rule extraction using generalized neural networks." *Proc. of the 4th IFSA World Congress*, 82-86.
- 28- Eckhardt, K., Breuer, L., and Frede, H.G. (2003). "Parameter uncertainty and the significance of simulated land use change effects." *J. of Hydrology*, 273 (1-4), 164-176.
- 29- Efron, B., and Tibshirani, R.J. (1993). *An introduction to the bootstrap*, Chapman and Hall, New York.
- 30- Abbaspour, K.C., Yang, J., Maximov, I., Siber, R., Bogner, K., Mieleitner, J., Zobrist, J., and Srinivasan, R. (2007). "Modelling hydrology and water quality in the pre-alpine/alpine thur watershed using SWAT." *J. of Hydrology*, 333 (2-4), 413-430.
- 31- Jang, J. S. R., and Sun, C. T. (1995). "Neuro-fuzzy modeling and control." *Proc. of the IEEE*, 83, 378-406.
- 32- Chiu, S.L. (1994). "Fuzzy model identification based on cluster estimation." *J. of Intelligent and Fuzzy Systems*, 2 (3), 267-278.