

## تحلیل عدم قطعیت مدل شبیه‌سازی-بهینه‌سازی آبخوان با استفاده از الگوریتم مونت کارلو (زنجیره مارکوف)

خدیجه نوروزی خطیری<sup>۱</sup>، محمدحسین نیک‌سخن<sup>۲\*</sup>، امین سارنگ<sup>۳</sup>

۱. دانشجوی دکتری، دانشکده محیط زیست، پردیس دانشکده‌های فنی، دانشگاه تهران

۲. دانشیار، دانشکده محیط زیست، پردیس دانشکده‌های فنی، دانشگاه تهران

۳. استادیار، دانشکده محیط زیست، پردیس دانشکده‌های فنی، دانشگاه تهران

(تاریخ دریافت ۱۳۹۷/۶/۳۱؛ تاریخ تصویب ۱۳۹۷/۰۹/۱۰)

### چکیده

تحلیل عدم قطعیت، مرحله‌ای جدانشدنی در فرایند مدل‌سازی‌های هیدرولوژی است. ارزیابی کمی عدم قطعیت در خروجی‌های مدل شبیه‌سازی و تخمین پارامترهای آن، موجب افزایش اطمینان در نتایج مدل‌سازی و شناخت درستی از منابع عدم قطعیت می‌شود. با توجه به رشد روزافزون کاربرد مدل‌های آب زیرزمینی در مدیریت و پیش‌بینی رفتار آبخوان‌ها، پژوهش حاضر به منظور تحلیل عدم قطعیت در شبیه‌سازی کمی-کیفی آبخوان و تأثیر آن در نتایج بهینه‌سازی انجام شد. با استفاده از مدل هیدرولوژیکی SWAT، میزان تغذیه مشخص شده و وارد مدل جریان آب زیرزمینی MODFLOW و مدل انتقال آلاینده MT3DMS شد. در تحقیق حاضر از الگوریتم DREAMzs که یکی از الگوریتم‌های مبتنی بر مونت کارلو (زنجیره مارکوف) است، به منظور بررسی عدم قطعیت پارامترهای مدل MODFLOW استفاده شد. در ادامه، با لینک کردن مدل با MOPSO میزان بهینه‌هد و شوری در آبخوان مد نظر به دست آمد. نتایج به دست آمده نشان داد میزان دقت در ورودی‌های مدل سبب مطلوبیت در نتایج با توجه به هدف تعیین شده که کاهش میزان افت آب است، شد.

**کلیدواژگان:** آب زیرزمینی، شبیه‌سازی-بهینه‌سازی، عدم قطعیت، PSO.

## مقدمه

شبیه‌سازی جریان آب زیرزمینی همواره با عدم قطعیت ناشی از دانش ناقص درباره سیستم فیزیکی مطالعه‌شده، ساختار مدل، تغییرپذیری مکانی و زمانی احاطه شده است [۱]، زیرا داده‌هایی که بر اساس آنها مدل‌های ریاضی تهیه می‌شوند، معمولاً کافی نیستند و همچنین الگوریتمی که برای مدل‌سازی انتخاب می‌شود با آنچه در طبیعت اتفاق می‌افتد، دقیقاً یکسان نیست. به علاوه، در تبدیل الگوریتم به نرم‌افزار، فرض‌هایی در نظر گرفته می‌شود. همچنین، حتی در مدل‌های بسیار پیچیده با واسنجی خوب، اطلاعات ورودی مدل عدم قطعیت‌هایی دارند [۲].

تجزیه و تحلیل عدم قطعیت موجب می‌شود پارامترهایی که تأثیر بیشتری روی نتایج خروجی دارند، تشخیص داده شوند و دقت بیشتری در برآورد آنها به عمل آید که به این وسیله از خطای به دست آمده از مقادیر خروجی کاسته می‌شود [۳ و ۴]. در کل، تخمین پارامترها توسط روش‌ها و الگوریتم‌های مختلف بهینه‌سازی با خطا همراه است، چون داده‌های استفاده شده در واسنجی شامل خطاهای اندازه‌گیری می‌شود. بنابراین، عموماً انجام شبیه‌سازی مناسب و یافتن نقطه منحصربه‌فرد در فضای پارامتر غیرممکن است [۵]. روش‌های متعددی برای کمی کردن عدم قطعیت موجود در شبیه‌سازی آینده وجود دارد که از آن جمله می‌توان به روش‌های آماری و روش‌های مبتنی بر مونت کارلو اشاره کرد [۶]. تحلیل عدم قطعیت در مدل‌سازی علوم آب بسیار مورد توجه محققان بوده است. تا کنون مطالعات زیادی در این زمینه در مورد انواع مدل‌های ریاضی انجام شده است. از میان مطالعات گسترده تحلیل عدم قطعیت، مانند عدم قطعیت موجود در شبیه‌سازی هیدرولوژیکی [۷]، مدل‌سازی بارش-رواناب [۸]، برآورد دبی جریان رودخانه [۹] و مدل‌سازی رسوب [۱۰]، سهم مطالعاتی که به تحلیل عدم قطعیت در مدل‌های آب زیرزمینی پرداخته باشند، کمتر است. از جمله تحقیقاتی که بر عدم قطعیت شبیه‌سازی آب‌های زیرزمینی با دیدگاه آماری صورت گرفته است، می‌توان به مقاله Pohlh و همکارانش اشاره کرد [۱۱]. از بین روش‌های تحلیل عدم قطعیت مدل‌سازی آب‌های زیرزمینی می‌توان

به الگوریتم مونت کارلو (زنجیره مارکوف) <sup>۱</sup> (McMC) [۱۲] و [۱۳] الگوریتم‌های مشابه آن مانند <sup>۲</sup> bMcMC [۱۴] و <sup>۳</sup> N-McMC [۱۵ و ۱۶] روش عمومی عدم قطعیت تشابهات <sup>۴</sup> GLUE [۱۲ و ۱۷] و ساختار بیزی <sup>۵</sup> اشاره کرد. همان طور که قبلاً نیز گفته شد، مطالعات زیادی روی شبیه‌سازی-بهینه‌سازی صورت گرفته است (جدول ۱)، اما بسیاری از این مطالعات تحلیل عدم قطعیت ندارند، به خصوص این فقدان در مطالعات آب زیرزمینی بیشتر احساس می‌شود.

روش مونت کارلو (زنجیره مارکوف) بیزی (MCMC) یکی از این روش‌های نمونه‌برداری است. این الگوریتم براساس مدل هیدرولوژی و داده‌های مشاهده‌ای مد نظر، نمونه‌هایی تصادفی و همبسته (که از ویژگی‌های زنجیره مارکوف است) از توزیع پسین پارامترها تولید می‌کند [۴۱]. این روش در زمینه‌های مختلف از جمله استنباط آماری و هوش مصنوعی استفاده شده است [۴۲]. روش‌های MCMC شامل الگوریتم‌های شبیه‌سازی تصادفی است که به صورت پی‌درپی جواب‌ها را در فضای پارامتر بررسی می‌کند و با دنباله‌ای از تکرارهای ثابت به توزیع احتمالاتی پسین پارامترها (توزیع هدف) همگرا می‌شود. انواع مختلفی از نمونه‌بردارهای MCMC برای هر مسئله وجود دارد که به طور موفقیت‌آمیزی برای مدل‌های هیدرولوژیکی به کار گرفته شده و نشان داده که نسبت به روش‌های دیگر واسنجی مدل برتر است [۴۳]. برخی پژوهشگران از الگوریتم متروپولیس-هستینگس که ابتدایی‌ترین و عمومی‌ترین طبقه از نمونه‌بردارهای MCMC در چارچوب استنتاج بیزی است، برای شرح عدم قطعیت در مدل‌های مفهومی حوضه آبخیز استفاده کردند [۴۴ و ۴۵].

الگوریتم‌های مختلف بر مبنای MCMC نظیر الگوریتم متروپولیس-هستینگس (M-H) [۴۳]، به‌علت کاهش سرعت همگرایی و الگوریتم SCEM-UA <sup>۶</sup> [۷] به‌علت نیاز به تعداد اجرای زیاد و لزوم حذف مسیرهای پرت مورد انتقاد واقع شده‌اند [۴۶].

1. Markov Chain Monte Carlo
2. Blocking Monte Carlo Markov Chain
3. Null Space Monte Carlo Markov Chain
4. Generalized Likelihood Uncertainty Estimation
5. Bayesian Approach
6. Shuffled Complex Evolution Metropolis

جدول ۱. گزیده‌ای از مطالعات شبیه‌سازی-بهینه‌سازی به همراه تحلیل عدم قطعیت

نوع مدل تدوین‌شده	نوع مسئله حل شده		نام محقق و سال تحقیق
	بهینه‌سازی	عدم قطعیت	
✓	✓	✓	McKinney and Lin (1994) [۱۸]
✓	✓	✓	Huang and Mayer (1997) [۱۹]
✓	✓	✓	Storck et al. (1997) [۲۰]
✓	✓	✓	Das and Datta (2001) [۲۱]
✓	✓	✓	Hsiao and Chang (2002) [۲۲]
✓	✓	✓	Loaiciga (2004) [۲۳]
✓	✓	✓	Reed and Minsker (2004) [۲۴]
✓	✓	✓	Tran (2004) [۲۵]
✓	✓	✓	Zheng et al. (2005) [۲۶]
✓	✓	✓	Karamouz et al. (2007) [۲۷]
✓	✓	✓	Salazar et al. (2007) [۲۸]
✓	✓	✓	Bazargan-Lari et al. (2009) [۲۹]
✓	✓	✓	Mahjoub et al. (2011) [۳۰]
✓	✓	✓	Ketabchi and Ataie- [۳۱]
✓	✓	✓	Ashtiani (2011)
✓	✓	✓	Fallah-Mehdipour et al. [۳۲]
✓	✓	✓	(2013)
✓	✓	✓	Ayvaz and Elci (2013) [۳۳]
✓	✓	✓	Narula and Gosian (2013) [۳۴]
✓	✓	✓	Elci and Ayvaz (2014) [۳۵]
✓	✓	✓	Nakhaei et al. (2014) [۳۶]
✓	✓	✓	El Alfy (2014) [۳۷]
✓	✓	✓	Izady et al. (2015) [۳۸]
✓	✓	✓	Raei et al. (2017) [۳۹]
✓	✓	✓	Thomas et al. (2018) [۴۰]

متروپولیس تطبیقی تکامل تفاضلی<sup>۱</sup> (DREAM) را در چارچوب بیزی معرفی کردند [۴۷]. این الگوریتم از روش تکامل تفاضلی -زنجیره مارکوف DE-MC پیروی کرده [۴۹] و از تکامل تفاضلی به‌عنوان الگوریتم ژنتیک به‌منظور تکامل جمعیت همراه با نقش انتخاب متروپولیس استفاده می‌کند [۵۰].

الگوریتم DREAM برای ارزیابی عدم قطعیت مدل‌های

پژوهش‌های زیادی روی بهبود همگرایی و راندمان نمونه‌بردارهای MCMC به‌منظور نمونه‌برداری از توزیع‌های پارامتر با ابعاد زیاد انجام شده است [۴۷ و ۴۸]. Vrugt و همکارانش برای تخمین مؤثر تابع چگالی احتمال پسین پارامترهای مدل هیدرولوژیکی پیچیده و مسائل نمونه‌برداری با ابعاد زیاد و نیز افزایش راندمان نمونه‌برداری، یک نمونه‌بردار MCMC جدید به نام

1. DiffeRential Evolution Adaptive Metropolis

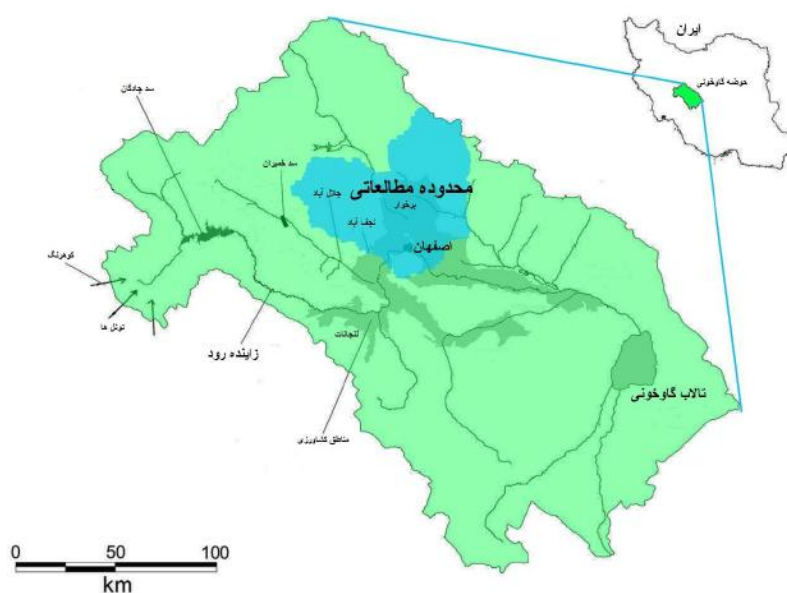
آبخوان همیشه مورد سؤال بوده است. هدف از تحقیق حاضر، ارزیابی کارایی مدل‌های شبیه‌ساز - بهینه‌ساز به منظور دست‌یافتن به چنین راه حلی است. بنابراین در مقاله حاضر، برای نخستین بار سعی شده است با در نظر گرفتن قیود حاکم بر سیستم آبخوان، امکان پذیر بودن حصول جواب‌های بهینه در یک مسئله بهینه‌سازی چندهدفه بزرگ از طریق تلفیق مدل‌های شبیه‌ساز-الگوریتم عدم قطعیت با مدل‌های بهینه‌سازی بررسی شود به گونه‌ای که نتایج به دست آمده از شبیه‌سازی با کمترین خطا توسط الگوریتم عدم قطعیت قابل بهره‌برداری توسط مدل‌های بهینه‌سازی باشد. به این منظور در ادامه، در بخش ساختار تحقیق، چگونگی تدوین مدل شبیه‌ساز آبخوان و ورودی آن از مدل SWAT، الگوریتم عدم قطعیت DREAM و مدل بهینه‌ساز چندهدفه شرح داده می‌شود.

#### مطالعه موردی

محدوده مطالعاتی اصفهان - برخوار از نظر وضعیت منابع آب جزء محدوده‌های ممنوعه و بحرانی کشور است. این منطقه با مساحت آبخوان حدود ۱۵۰۰ کیلومتر مربع یکی از محدوده‌های بزرگ تحت پوشش شرکت آب منطقه‌ای اصفهان است. شکل ۱ موقعیت این محدوده را در حوضه آبریز گاوخونی و استان اصفهان نشان می‌دهد.

هیدرولوژیکی در سال‌های اخیر توسط بعضی از محققان به کار رفته است. برای مثال، Montanari و Koutsoyiannis به منظور ارزیابی عدم قطعیت پارامترهای مدل بارش رواناب یکپارچه HyMod در حوضه آبخیز Secchia و مدل بارش رواناب توزیعی AFFDEF در حوضه رودخانه Leo در شمال ایتالیا از الگوریتم DREAM استفاده کردند و نشان دادند روش پیشنهادی مؤثر است و به ارزیابی عدم قطعیت پایداری منجر می‌شود [۵۱].

الگوریتم دیگری هم توسط روت و همکارانش توسعه یافت که بر پایه نسخه اولیه الگوریتم DREAM بوده است و الگوریتم DREAM-ZS نام دارد [۴۷]. این الگوریتم در مقایسه با الگوریتم DREAM از تعداد کمی زنجیر موازی (۳-۵ زنجیر) به منظور نمونه‌برداری پسین پارامتر استفاده می‌کند و در نتیجه در مسائل با پارامتر زیاد موجب افزایش راندمان نمونه‌برداری می‌شود. در دو حوضه آبخیز در ایالات متحده آمریکا با استفاده از این الگوریتم به بررسی عدم قطعیت پارامتر و پیش‌بینی مدل هیدرولوژیکی پرداخته شده است [۵۲]. همچنین، Koskela و همکارانش از این الگوریتم به منظور بررسی اثر عدم قطعیت ساختار مدل و بارش روی پارامترهای تخمینی مدل بارش رواناب IHACRES در حوضه آبخیز Rudback در فنلاند جنوبی استفاده کردند [۵۳]. در مسئله بهره‌برداری بهینه از منابع آب زیرزمینی، یافتن یک راه حل برای مدیریت مسائل کمی - کیفی



شکل ۱. موقعیت محدوده مطالعه شده اصفهان - برخوار [۵۴]

است. اهداف شامل مینیمم کردن تغییرات سطح آب زیرزمینی سالانه و مینیمم کردن تغییرات کیفی آب زیرزمینی و محدودیت‌ها شامل تأمین نیاز آبی، میزان پمپاژ و ماکزیمم ساعت پمپاژ روزانه می‌شوند. به ازای هر متغیر، مدل‌های شبیه‌سازی MODFLOW و MT3DMS به ترتیب فراخوانی شدند. سپس، قواعد کلی کاوشی و به‌روزرسانی متغیرها همراه با هدایت فرایند جست‌وجوی تکاملی و جمعیت پایه در مدل بهینه‌سازی فراکاوشی برای بهینه‌سازی متغیرهای بهره‌برداری و طراحی تا نیل به همگرایی ادامه یافت. برای لینک شبیه‌سازی به بهینه‌سازی از کدنویسی در MATLAB استفاده شد. شکل ۲ فلوچارت روش اجرایی تحقیق را نشان می‌دهد.

#### مدل عددی آب زیرزمینی

کد MODFLOW که توسط سازمان زمین‌شناسی آمریکا ارائه شده است، کاربردهای گسترده و مقبولیت زیادی نزد هیدرولوژیست‌ها دارد. نسخه اصلی مدل MODFLOW توسط McDonald و Harbough در USGS تهیه و ارائه شده است [۵۶]. این نرم‌افزار با زبان برنامه‌نویسی FORTRAN نوشته شده است و معادلات دیفرانسیل جریان آب زیرزمینی در محیط متخلخل بر پایه روش‌های تفاضل محدود حل می‌کند. پس از جمع‌آوری و آماده‌سازی اطلاعات موجود برای ساخت مدل، تخمین تغذیه آبخوان با مدل هیدرولوژیکی SWAT انجام شده است. سپس، مدل مفهومی کمی آبخوان در محیط GMS ساخته شده و پس از آن به مدل عددی کمی MODFLOW تبدیل می‌شود. در ادامه، مدل عددی کمی با استفاده از فرایند واسنجی دومرحله‌ای، واسنجی می‌شوند. آبخوان اصفهان-برخوار از نوع آزاد است که برای مدل‌سازی از شبکه‌بندی با سلول‌هایی به اندازه‌های مساوی (۵۰۰×۵۰۰) استفاده شد. هد اولیه با استفاده از هد چاه‌های مشاهداتی و الگوریتم کریجینگ در GIS میان‌یابی شدند. هدایت هیدرولیکی نیز با استفاده از داده‌های ۱۲ چاه اکتشافی و روش کریجینگ میان‌یابی شدند که البته بیشتر این مقادیر بعداً در فرایند کالیبراسیون اصلاح شدند. مقادیر هدایت هیدرولیکی بین ۰/۰۰۱ تا ۱۰۰ متر در روز، آنیزوتراپی افقی بین  $10^{-1}$  تا ۱۰۰، ضریب ذخیره بین ۰/۰۰۶ تا ۰/۶ و تغذیه نیز با توجه به خروجی مدل SWAT به دست آمد

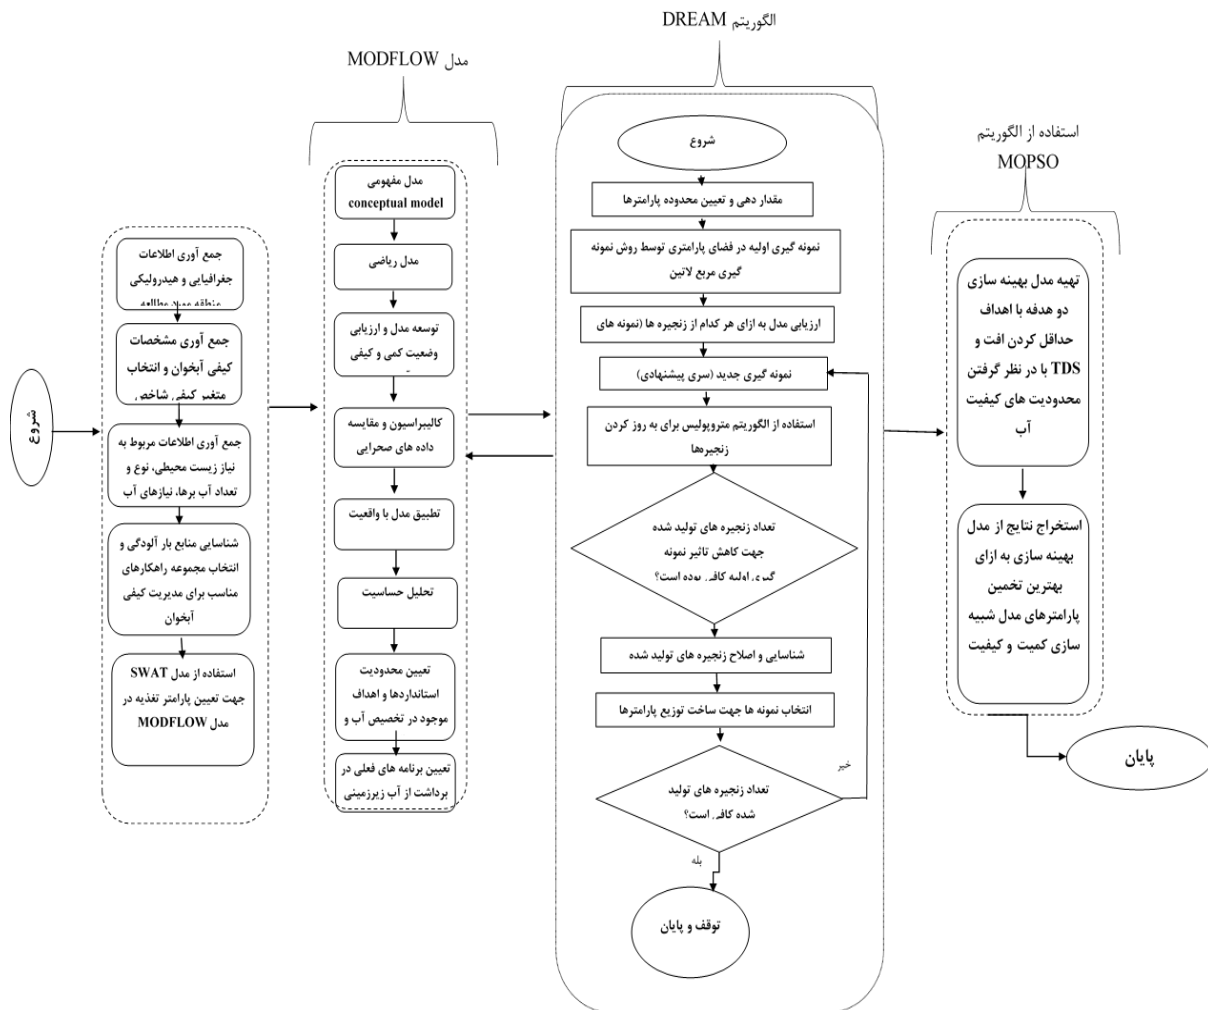
به دلیل توسعه زیاد جمعیت و صنعت و کشاورزی در منطقه، فشار زیادی به منابع آب وارد شده و با احتساب برداشت سالانه ۴۳۸ تا ۶۰۴ میلیون مترمکعب در سال از منابع آب زیرزمینی منطقه با افت مستمر کمیت آب از نظر پارامترهای نزول سطح ایستابی با متوسط ۹۷ سانتی‌متر در سال و کسر مخزن آبخوان به میزان ۸۴ میلیون مترمکعب ارسال مواجه است [۵۵].

#### مراحل انجام تحقیق

از آنجا که یکی از مؤلفه‌های بسیار مهم در مدل‌سازی سیستم‌های آب زیرزمینی پارامتر تغذیه از سطح است، ابتدا توزیع زمانی و مکانی آن با استفاده از یک مدل هیدرولوژیکی (SWAT) تعیین شد. سپس، یک مدل شبیه‌سازی کمی و کیفی آب زیرزمینی بر اساس آمار و اطلاعات موجود از منطقه و ورودی تغذیه از مدل SAWT توسعه داده شد. برای این منظور، از مدل GMS v10.1 با قابلیت‌های ویژه که از جمله آن می‌توان به امکان توسعه مدل مفهومی و تبدیل خودکار آن به مدل عددی و امکان سازگاری ارتباط با سیستم‌های اطلاعات جغرافیایی (GIS-Based) را برشمرد، استفاده شد. در GMS نیز به ترتیب از مدل‌های MODFLOW و MT3DMS به عنوان شبیه‌سازهای کمی و کیفی استفاده شد. واسنجی این مدل‌ها پیش از کاربرد در پیش‌بینی و ارزیابی پاسخ سیستم نسبت به آنچه دیده نشده است، اهمیت زیادی دارد. به این منظور، روش واسنجی دستی و خودکار با مدل PEST مد نظر قرار گرفته است. همان‌طور که قبلاً نیز گفته شد، از الگوریتم DREAM برای آنالیز عدم قطعیت استفاده شد. این روش که به‌خوبی قادر به بررسی فضای پارامتری با کمترین تعداد تکرار است، توسط لینک کدنویسی شده در محیط MATLAB به شبیه‌ساز متصل شد. در ادامه، مدل‌های شبیه‌ساز توسعه‌یافته با قابلیت احتساب فرایندها و ملزومات برنامه‌ریزی بهره‌برداری از آبخوان، به یک مدل بهینه‌ساز چندهدفه فراکاوشی به‌منظور بهینه‌سازی بهره‌برداری از آبخوان و سیستم منابع آب تحت بررسی متصل شد. به این منظور و با توجه به تعداد زیاد متغیرهای تصمیم، خطی نبودن معادلات حاکم در ساختار پیشنهادی و پیچیدگی حاکم بر مدل، از الگوریتم فراکاوشی بهینه‌سازی ازدحام ذرات چندهدفه (MOPSO)، بهره گرفته شد. متغیر تصمیم این مدل بهینه‌ساز، مقادیر دبی پمپاژ در چاه‌های بهره‌برداری

موردی محاسبه شد. مدل مفهومی کیفی آبخوان در محیط GMS ساخته شده و سپس به مدل‌های عددی کیفی MT3DMS تبدیل شد. در ادامه، مدل عددی کیفی با استفاده از فرایند واسنجی تک‌مرحله‌ای واسنجی شد. در نهایت، این مدل بهینه مبنای توسعه مدل کیفی آبخوان قرار گرفت. عملیات واسنجی و محدوده مدل‌سازی مدل کیفی به مدت ۹۶ ماه و برای دوره زمانی ۱۵ مهر ۱۳۸۱ (۷ اکتبر ۲۰۰۲) تا ۱۵ مهر ۱۳۸۹ (۷ اکتبر ۲۰۱۰) انجام شد. صحت‌سنجی نیز برای ۲۹ گام زمانی ماهانه از ۱۵ مهر ۱۳۸۹ (۷ اکتبر ۲۰۱۰) تا ۱۷ اسفند ۱۳۹۱ (۷ مارس ۲۰۱۳) انجام شد. ساخت و واسنجی مدل کیفی فقط در شرایط ناپایدار با گام زمانی ماهانه صورت گرفت.

که بیشتر آنها در فرایند کالیبراسیون اصلاح شدند و در نهایت مقادیر آن بین  $10^{-10}$  تا  $0.08$  متر در روز است. MT3DMS یک مدل عددی سه‌بعدی قدرتمند برای شبیه‌سازی انتقال ماده حل‌شده در شرایط و محیط‌های هیدروژئولوژیکی پیچیده است که می‌تواند فرایندهای انتقال را به صورت مستقل یا با یکدیگر شبیه‌سازی کند. MT3DMS قادر به شبیه‌سازی آلاینده‌های چندگانه مختلف و واکنش‌های آنهاست. این مدل توسط بسیاری از محققان با مدل MODFLOW مرتبط شده و پرداختن به مسئله مربوط به انتقال را بدون نیاز به ساخت مدلی جدید میسر ساخته است. پارامترهای انتقال TDS در آبخوان اصفهان-برخوار با استفاده از مقادیر چاه‌های اکتشافی در قسمت مطالعه



شکل ۲. فلوجارت روش اجرایی تحقیق

الگوریتم عدم قطعیت

جدیدترین روش MCMC که در تحقیق حاضر استفاده شده، توسط vrugt و همکارانش ارائه شده است [۴۷]. این روش نسخه ویرایش‌یافته الگوریتم بهینه‌سازی سراسری<sup>۱</sup> متروپولیس تکاملی پیچیده جابه‌جاشونده (SCEM-UA)<sup>۲</sup> را بهبود بخشیده است و قدرت خودتطبیقی<sup>۳</sup> و به‌روزشدن در چارچوب تکامل جمعیت اولیه را دارد [۷]. الگوریتم DREAM با استفاده از چندین زنجیر به‌طور هم‌زمان و بهره‌گیری از روش نمونه‌گیری مربع لاتین (LHS)<sup>۴</sup> به عنوان توزیع پسین به بررسی در فضای پارامتری ممکن<sup>۵</sup> می‌پردازد و به‌صورت خودکار توزیع پیشنهادی<sup>۶</sup> نمونه‌گیر را به سمت تابع نهایی ایستا<sup>۷</sup> تنظیم می‌کند.

۱. ایجاد یک جمعیت اولیه از بردار پارامترهای  $\theta_i (i=1, \dots, N)$  با استفاده از توزیع پیشین.

۲. ارزیابی مدل با استفاده از سری پارامتر انتخاب‌شده و محاسبه چگالی  $\pi(\theta^i)$  برای هر زنجیر  $i$ . در تحقیق حاضر ارزیابی مدل توسط روش کمترین مربعات خطا (SLS)<sup>۸</sup> انجام شد. به‌طور سنتی در مسئله واسنجی، تابع هدف مجموع مربعات خطا به‌کار می‌رود و هدف یافتن مقادیری از پارامتر است که این مقدار تابع هدف را کمینه کند (رابطه ۱) [۵۰].

$$F_{SLS} = \sum_{i=1}^n e_i(\theta)^2 \quad (1)$$

که  $e$  تفاوت داده‌های مشاهده‌ای و شبیه‌سازی شده مدل و  $\theta$  پارامترهای مدل است.

۳. محاسبه جهش  $(dx^i)$  در زنجیر  $i$  ام با استفاده از تکامل تفاضلی (رابطه ۲) [۵۷ و ۵۸].

$$dx^i = (1+e)\gamma(\delta.d') \sum_{j=1}^{\delta} (\theta^{r_2(j)} - \theta^{r_1(j)}) + \varepsilon \quad (2)$$

$\theta^{r_1(j)}$  و  $\theta^{r_2(j)}$  پارامترهای مربوط به دو سری زنجیر انتخابی ( $r_1$  و  $r_2$ ) از زنجیرهای پیشین است که انتخاب آنها تصادفی بوده،  $e$  و  $\varepsilon$  عبارات تصادفی،  $\gamma$  ضریبی است که به

مقادیر  $\delta$  و  $d'$  بستگی داشته که بهترین تخمین آن با رابطه  $\gamma = \frac{2.38}{\sqrt{2\delta d'}}$  بیان می‌شود [۴۹].  $\delta$  تعداد جفت زنجیر به‌کاررفته برای تولید سری پیشنهادی و  $d'$  تعداد پارامترهایی از زنجیر  $i$  ام بوده که در سری پیشنهادی مقدار آنها تغییر می‌یابد.

۴. تولید سری پارامترهای پیشنهادی  $(v^i)$  در هر زنجیر  $(i)$  با استفاده از رابطه ۳ استفاده می‌شود که  $\theta^i$  سری پارامتر زنجیره  $i$  در گام پیش (جمعیت اولیه) است.

$$v^i = \theta^i + dx^i \quad (3)$$

۵. تولید بردار  $U$  به اندازه  $d \times 1$  به صورت تصادفی و با توزیع یکنواخت استاندارد ( $d$  برابر تعداد پارامترها و  $U \in [0,1]$ ) و سپس جایگزینی هر جزء  $v_j^i (j = 1.2, \dots, d)$  با  $\theta_j^i$  با استفاده از طرح زیر (رابطه ۴) و با احتمال تلاقی: CR

$$\alpha(\theta^i, v^i) = \begin{cases} \min\left(\frac{\pi(v^i)}{\pi(\theta^i)}, 1\right) & \text{if } \pi(\theta^i) > 0 \\ 1 & \text{if } \pi(\theta^i) = 0 \end{cases} \quad (4)$$

۶. تولید عدد تصادفی  $u$  با توزیع یکنواخت استاندارد ( $u \in [0,1]$ ). اگر  $u > \alpha$  و یا  $\alpha = 1$  باشد سری پیشنهادی پذیرفته می‌شود یعنی  $v^i = \theta^i$  در غیر این‌صورت سری قبلی  $\theta^i$  وارد زنجیر می‌شود.

۷. محاسبه معیار همگرایی گلمن و رابین  $R$  برای هر پارامتر برای ساختن توزیع پسین پارامترها فقط از سری پارامترهایی استفاده می‌شود که به همگرایی رسیده باشند ( $R \leq 1.02$ ) [۵۹].

بهینه‌سازی

روش بهینه‌سازی استفاده‌شده در تحقیق حاضر PSO است که جزئیات این الگوریتم را می‌توان در تحقیق کندی و آبراهات ۱۹۹۵ مشاهده کرد [۶۰]. در تحقیق حاضر، متغیرهای تصمیم در مدل بهینه‌سازی، مقادیر دبی پمپاژ در چاه است. توابع هدف نیز از نوع حداقل‌سازی ناپایداری کمی و حداقل‌سازی ناپایداری کیفی انتخاب شده است (رابطه ۵).

1. Global Optimization Algorithm
2. Shuffle Complex Evolution Metroplis
3. Self-Adaptive
4. Latin Hypercube Sampling
5. Feasible Parameter Space
6. Proposal distribution
7. Stationary Target Distribution
8. Standard Least Squares

مقدار آب مصرفی سطحی در ماه  $t_p$  برحسب مترمکعب که برابر صفر است ( $m^3$ )؛  $SW_{t_p}^{max}$ ؛ بیشترین مقدار آب مصرفی سطحی در ماه  $t_p$  برحسب مترمکعب که برابر کل نیاز کشاورزی منطقه است ( $m^3$ )؛  $C^{min}$ ؛ کمترین غلظت شوری آب مصرفی که برابر صفر است؛  $C^{max}$ ؛ بیشترین غلظت شوری آب مصرفی که برابر دو هزار میلی گرم در لیتر است. میزان تقاضای آب مصرفی در منطقه مطالعه شده MCM ۶۰۰ است که از طریق آب سطحی و زیرزمینی تأمین می شود.

### ترکیب مدل SWAT و MODFLOW

در تحقیق حاضر از روش ترکیبی متوالی یا یک طرفه برای ترکیب دو مدل SWAT و MODFLOW استفاده شده است. در SWAT یک حوضه آبریز به چندین زیرحوضه تقسیم می شود که آنها نیز به زیرمجموعه هایی به نام واحدهای پاسخ هیدرولوژیکی (HRUs) تقسیم می شوند. برای توسعه شبیه ساز مدل SWAT در آبخوان اصفهان - برخوار از ورودی هایی که به چهار دسته تقسیم شده اند، استفاده شد. این ورودی ها شامل مدل ارتفاعی دیجیتالی (DEM)، داده های آب و هوا، داده های خاک و داده های کاربری اراضی است. HRU ها به صورت ترکیبی از کاربری اراضی، خاک و شیب زمین هستند.

در تحقیق حاضر ساخت و واسنجی دو مدل SWAT و MODFLOW به صورت مجزا از هم است. به بیان دیگر، نتایج مدل SWAT از قبیل تغذیه به عنوان داده های ورودی مدل MODFLOW استفاده می شود. پس از اجرای مدل SWAT، مقادیر تغذیه آب زیرزمینی همراه با تغییرات زمانی و مکانی آن به فرمت داده های ورودی مدل MODFLOW در GMS تبدیل شده است. خروجی مدل SWAT برای مقادیر تغذیه، شامل یک فایل متنی می شود که در آن سری زمانی مقادیر تغذیه برای هر HRU بر حسب mm/month آورده شده است. در این فایل، مقادیر تغذیه برای هر HRU با عنوان GW-RCH-i می آید که در آن i شامل شماره هر HRU است. از روی فایل متنی HRULandUseSoilsReport.txt، اطلاعات مربوط به هر زیرحوضه به تفکیک استخراج می شود. این اطلاعات شامل شماره HRU ها و مقدار مساحت هر HRU در هر زیرحوضه

$$\text{Min } F_v = \sum_{t=1}^{N_{tp}} \sum_{j=1}^{N_j} |H_{tj} - H_{vj}|$$

for  $t = 1, 2, \dots, N_{tp}$  and  $j = 1, 2, \dots, N_j$  (5)

$$\text{Min } F_v = \sum_{t=1}^{N_{tp}} \sum_{j=1}^{N_j} |C_{tj} - C_{vj}|$$

for  $t = 1, 2, \dots, N_{tp}$  and  $j = 1, 2, \dots, N_j$

$F_2$  و  $F_1$ ، توابع هدف؛  $N_{tp}$ ، تعداد کل ماه های برنامه ریزی که برابر ۱۲۵ است؛  $N_j$ ، تعداد کل سلول های مدل که برابر ۱۵۹۱۲ است؛  $H_{tj}$ ، سطح آب در گام زمانی  $t$ ام در سلول زام؛  $H_{vj}$ ، سطح آب در گام زمانی اول در سلول زام؛  $C_{tj}$ ، TDS آب در گام زمانی  $t$ ام در سلول زام؛  $C_{vj}$ ، TDS آب در گام زمانی اول در سلول زام هستند.

به طور کلی، قیود مسئله بهینه سازی در تحقیق حاضر از نوع کمی و کیفی است. قیود کیفی شامل محدود کردن میزان TDS در چاه است. قیود کمی نیز شامل محدودیت میزان آب سطحی در دسترس، محدودیت دبی پمپاژ در چاه های بهره برداری و محدودیت مربوط به تأمین نیاز آب می شود (روابط ۶-۱۱).

$$GW_{t_p} = t_d \sum_{k=1}^{NW} Q_{k,t_p} \quad \forall t_p = 1, \dots, N_{tp}$$
 (6)

$$C_{k,t_p} = f(\tilde{C}, \tilde{H}, \tilde{OC}_{Re,t_{p-1}}) \quad \forall t_p = 1, \dots, N_{tp}$$
 (7)

$$SW_{t_p} = D_{t_p} - GW_{t_p} \quad \forall t_p = 1, \dots, N_{tp}$$
 (8)

$$SW_{t_p}^{min} \leq SW_{t_p} \leq SW_{t_p}^{max} \quad \forall t_p = 1, \dots, N_{tp}$$
 (9)

$$Q^{min} \leq Q_{k,t_p} \leq Q^{max} \quad \forall t_p = 1, \dots, N_{tp}$$
 (10)

$$C^{min} \leq C_{k,t_p} \leq C^{max} \quad \forall t_p = 1, \dots, N_{tp}$$
 (11)

$GW_{t_p}$ ، مجموع آب پمپاژ شده از چاه های کشاورزی در ماه  $t_p$ ؛  $t_p$ ، شمارنده ماه؛  $t_d$ ، تعداد روزهای ماه  $t_p$ ؛  $Q_{k,t_p}$ ، دبی پمپاژ چاه  $k$  در ماه  $t_p$  ( $m^3/day$ )؛  $k$ ، شمارنده تعداد چاه های پمپاژ؛  $NW$ ، تعداد کل چاه های پمپاژ موجود در منطقه؛  $N_{tp}$ ، تعداد کل ماه های برنامه ریزی؛  $C_{k,t_p}$ ، غلظت شوری در چاه  $k$  در ماه  $t_p$  ( $mg/lit$ )؛  $SW_{t_p}$ ، میزان آب سطحی استفاده شده در ماه  $t_p$  ( $m^3$ )؛  $D_{t_p}$ ، آب مورد نیاز کشاورزی در ماه  $t_p$  برحسب مترمکعب؛  $SW_{t_p}^{min}$  حداقل



دریافت می‌کند و خروجی را می‌گیرد. این تکرار آن قدر صورت می‌گیرد که همگرا شود. سپس، خروجی دریافتی از مرحله قبل توسط الگوریتم MOPSO فراخوانی می‌شود و به این ترتیب، با توجه به توابع هدف مد نظر بهینه‌ترین هد و شوری در هر سلول شبکه آبخوان به دست می‌آید. شکل ۴ ورودی‌های HA، SC و HC را در تکرار پنجم نشان می‌دهد که DREAM آنها را پیش‌بینی کرده است. مشاهده می‌کنید که نمودار هد در سمت راست این نمودارها میزان فیتنس فانکشن هستند. پارامتر تغذیه منتج از خروجی SWAT شامل سری‌های مختلف است که نتایج حاصل از اتصال MODFLOW و DREAM برای این پارامتر در تکرار دوم در شکل ۵ ارائه شده است.

همگرایی هد و شوری در خروجی الگوریتم MOPSO در شکل ۶ ارائه شده است. همان طور که شکل نشان می‌دهد، در تکرارهای مختلف که در محور افقی نشان داده شده است، خروجی‌ها به همگرایی می‌رسند. در شکل‌های ۷ میزان بهینه پارامترهای هدایت هیدرولیکی و تغذیه که DREAM و MOPSO پیش‌بینی کرده است را در مقابل میزان مشاهداتی آن نشان می‌دهد. تمایل الگوریتم عدم قطعیت DREAM بر آن است که بهینه‌ترین میزانی که پیش‌بینی می‌کند نیز به میزان واقعی نزدیک باشد و ماهیت اصلی پارامتر از دست نرود. درخور توجه اینکه به دلیل تعداد زیاد سلول‌های شبکه آبخوان، تعداد ۱۰۰ سلول در این نمودار مقایسه شده است.

شکل ۸ نمودار توزیع تجمعی پارامترهای ورودی مد نظر و میزان واقعی آنها را نشان می‌دهد. برای نمونه نمودار تغذیه از پارامترهای ورودی در ۱۰۰ سلول نمایش داده شده است. همان طور که مشاهده می‌شود، میزان پارامترهای مشاهده‌ای به رنگ قرمز بوده و میزان مقادیر تخمین زده شده به رنگ آبی است.

تخمین پارامترها می‌تواند شاخصی برای ارزش مدل استنباط شود، در حالی که شکل توزیع پسین پارامترها می‌تواند درجه تخمین عدم قطعیت را نشان دهد. بنابراین، برای تعیین عدم قطعیت پارامترهای یک مدل از توزیع پسین آنها استفاده می‌شود. همچنین، پارامترهای دارای توزیع پسین مشابه توزیع پیشین نیز می‌تواند توجیه‌کننده حساسیت کم پارامتر یادشده باشد. هیستوگرام‌های پسین ناحیه‌ای کوچک از توزیع پیشین یکنواخت را اشغال می‌کنند، به این معنا که

و سایر اطلاعات از قبیل نوع پوشش زمین، شیب زمین، نوع خاک در هر HRU است. با توجه به اطلاعات داده شده، مقدار تغذیه در هر زیرحوضه با توجه به سطح HRU‌های موجود در آن و مقادیر تغذیه آنها با استفاده از فرمول‌های تغذیه به دست می‌آید [۶۱]. مراحل یادشده به کمک یک برنامه کامپیوتری نوشته شده در محیط MATLAB که از روی فایل‌های خروجی SWAT، مقدار تغذیه در MODFLOW را برای هر زیرحوضه در قالب یک فایل متن تولید می‌کند، انجام شده است. الگوی زمانی مقادیر تغذیه در محدوده مدل‌سازی به صورت ماهانه از ابتدای سال آبی ۲۰۰۲-۲۰۰۳ تا ۱۲۵ گام زمانی است.


### بحث و نتایج

برای خواندن دسته ورودی‌هایی که وارد الگوریتم DREAM می‌شوند، باید فرمت فایل‌های ورودی آماده شود و پس از ورود به الگوریتم DREAM و اصلاح خطاهای (عدم قطعیت) موجود دوباره فایلی به این منظور در محیط MATLAB نوشته شود تا مدل MODFLOW بتواند آنها را بخواند و خروجی را محاسبه کند. برای این منظور کدی نوشته شد که پارامترهای مد نظر را از ورودی‌های مدل جدا کند و فرمت لازم برای پذیرفته شدن توسط الگوریتم DREAM برنامه‌نویسی شد. این برنامه ورودی‌ها را از فایل با پسوند‌های ورودی مدل MODFLOW می‌خواند و به فرمت یک بردار درمی‌آورد. این بردار هر ورودی را دسته‌بندی کرده و در یک ماتریس به DREAM ارسال می‌کند. سپس، با اجرای فایل یادشده در MATLAB، برنامه به شکل اتوماتیک تبدیل‌ها و رسم‌ها را انجام می‌دهد، به DREAM ارسال می‌کند و پس از بازگشت از DREAM دوباره به فرمت فایل‌های اولیه درمی‌آورد و ذخیره می‌کند. شکل ۳، نمونه فرمت این فایل است که برنامه آن را به شکل یک ورودی قابل فهم برای DREAM در خواهد آورد.

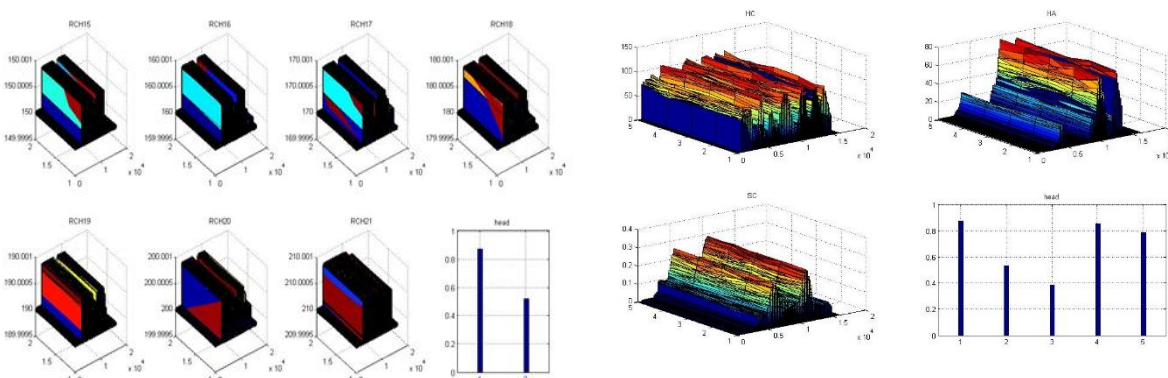
پس از تهیه ورودی‌های (هدایت هیدرولیکی HC، آنیزوتراپی افقی HA، ضریب ذخیره SC و تغذیه RCH) با فرمت مناسب الگوریتم DREAM، این ورودی‌ها توسط MODFLOW فراخوانی شده و وارد الگوریتم DREAM می‌شوند و خروجی آن، ورودی‌هایی است که مدل براساس کمترین اختلاف هد تخمین می‌زند. در ادامه، مدل MODFLOW ورودی‌های با اطمینان را از مرحله قبل

۱۱ (الف و ب) نشان داده شده است. نقشه‌های مد نظر گویای دخالت دادن الگوریتم عدم قطعیت (حذف خطاهای مشاهداتی در ورودی‌های مدل) در شبیه‌سازی-بهینه‌سازی است که سبب افزایش تراز سطح آب در به میزان حدود یک متر می‌شود. همچنین، میزان بهبود تراز آب زیرزمینی با توجه به تراز هد مشاهداتی در بعضی از نقاط منطقه مطالعه شده به حدود چهار متر می‌رسد. هدف دوم تحقیق حاضر نیز که کمینه‌کردن TDS است، سبب بهبود وضعیت این پارامتر به‌طور میانگین ۷۴۵ میلی‌گرم در لیتر شد. جدول ۲ آمار پارامترهای TDS مشاهداتی را در مقابل مقدار بهینه آن، نشان می‌دهد.

بیشتر پارامترها به‌خوبی تعیین شده‌اند. همچنین، این موضوع نشان‌دهنده قابلیت الگوریتم DREAM است که به‌طور تطبیقی مقیاس و جهت توزیع پیشنهادی را طی مدت تکامل زنجیرها به توزیع پسین به‌روز می‌کند و به همگرایی پارامترها به توزیع پسین منجر می‌شود. برای درک بهتر مفهوم تحلیل عدم قطعیت و مبانی مربوط به آن به مقاله‌های Nourali و همکارانش و Vrugt و همکارانش مراجعه شود [۶۲ و ۴۷]. شکل ۹ نمودار توزیع پیشین برای مقادیر مشاهداتی پارامترهای ورودی مدل است. شکل ۱۰ نمودار توزیع پسین برای مقادیر مشاهداتی پارامترهای ورودی مدل است. خروجی مدل در حالت اجرای شبیه‌سازی-بهینه‌سازی بدون الگوریتم DREAM و با الگوریتم DREAM در شکل




شکل ۳. ورودی هدایت هیدرولیکی




شکل ۵. ورودی تغذیه پیش‌بینی‌شده توسط DREAM


شکل ۴. ورودی‌های پیش‌بینی‌شده توسط DREAM به ازای پنج تکرار (HD,HA,SC)



شکل ۶. همگرایی خروجی‌های MOPSO



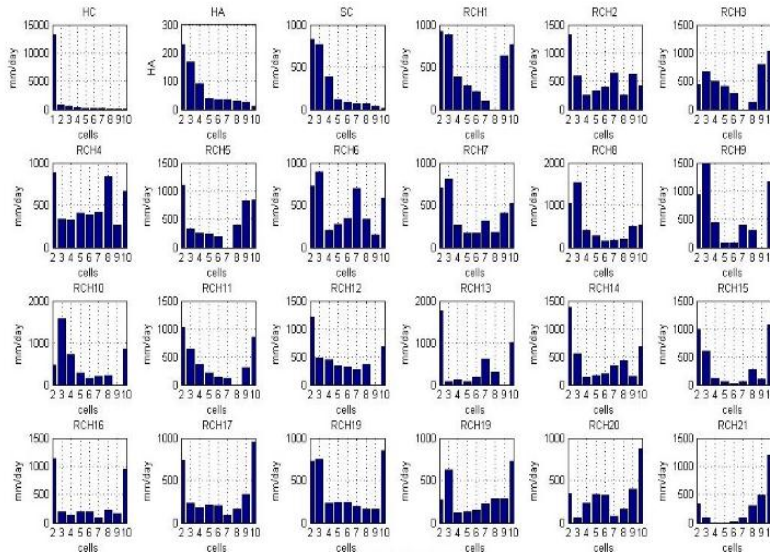
شکل ۷. نمودار پیش‌بینی میزان هدایت هیدرولیکی (الف)، تغذیه: (ب) توسط الگوریتم DREAM و مقایسه آن با مقدار مشاهداتی




شکل ۸. نمودار توزیع تجمعی پارامترهای ورودی

جدول ۲. آمار پارامتر TDS مشاهداتی در مقابل مقدار بهینه آن (میلی‌گرم بر لیتر)

پارامتر	میانگین		ماکزیمم		مینیمم	
	مشاهداتی	بهینه	مشاهداتی	بهینه	مشاهداتی	بهینه
TDS	۲۹۰۳/۸۹۴۳	۲۱۵۹/۲۷	۵۸۳۴/۲۲۷	۴۸۲۴	۸۵۵/۱۶۷۷	۲۹۹/۱۲



شکل ۹. نمودار توزیع بیشین پارامترهای ورودی

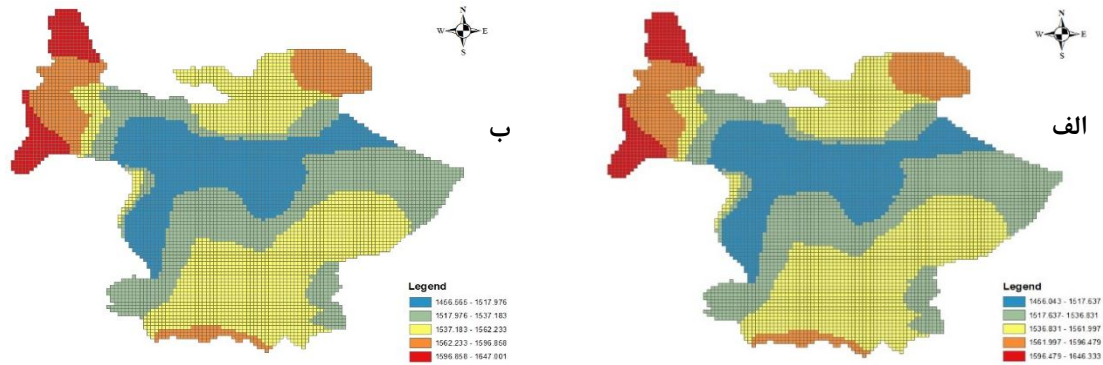


شکل ۱۰. نمودار توزیع پسین پارامترهای ورودی

آمد. با استخراج توابع پسین و مقایسه با پیشین آن، پارامتر هدایت هیدرولیکی، حساس شناخته شد. نتایج نشان داد پارامتر هدایت هیدرولیکی قابلیت تشخیص بیشتری دارد و نسبت به پارامتر تغذیه، تخمین مناسب‌تری داشته است که می‌توان گفت به دلیل ماهیت ماندگار نبودن تغذیه و همچنین تغییرات آن طی دوره مدل‌سازی، پارامتر تغذیه قابلیت تشخیص کمتری داشته است. میزان بهبود تراز آب زیرزمینی با توجه به تراز هد مشاهداتی در بعضی از نقاط منطقه مطالعه شده به حدود چهار متر می‌رسد. هدف دوم تحقیق حاضر نیز که کمینه‌کردن TDS است، سبب بهبود وضعیت این پارامتر به‌طور میانگین ۷۴۵ میلی‌گرم در لیتر شد.

### نتیجه‌گیری

مدیریت بهره‌برداری از منابع آب زیرزمینی با توجه به خصوصیات ویژه‌ای که دارد، تمهیدات خاصی را می‌طلبد. در تحقیق حاضر، با تدوین شبیه‌سازی-بهنه‌سازی، مقادیر بهینه هد و TDS از آبخوان با توجه به خصوصیات کمی و کیفی آن تعیین شد. رویکرد شبیه‌سازی-بهنه‌سازی که در تحقیق حاضر استفاده شد به دلیل داشتن قابلیت لحاظ کردن جزئیات کمی و کیفی آبخوان و در نظر گرفتن متغیرهای تصمیم‌به‌خوبی قادر به حل مسئله (میزان افت آب زیرزمینی و میزان شوری) است. با انجام تحلیل عدم قطعیت توسط الگوریتم DREAMzs، بهبود در خور توجهی در میزان عدم قطعیت مدل آب‌های زیرزمینی دشت مطالعه شده به وجود



شکل ۱۱. شبیه‌سازی-بهینه‌سازی بدون الگوریتم DREAM (الف) و با الگوریتم DREAM (ب)

### منابع

- [1].Mirzaei M, Huang Y.F, and El-Shafie A. Application of the generalized likelihood uncertainty estimation (GLUE) approach for assessing uncertainty in hydrological models. A review, Stochastic Environmental Research and Risk Assessment. 2015; 29(5): 1265-1273.
- [2].Rojas R, Kahunde S. Application of a multimodel approach to account for conceptual model and scenario uncertainties in groundwater modeling. Journal of Hydrology.2010; 394(3)416-435.
- [3].Montanari A, Grossi G. Estimating the uncertainty of hydrological forecasts. A statistical approach, Water Resources Research. 2008; 44: W00B08.
- [4].Blazkova S, Beven K. A limits of acceptability approach to model evaluation and uncertainty estimation in flood frequency estimation by continuous simulation: Skalka catchment, Czech Republic, Water Resources Research. 2009; 45: W00B16.
- [5].Blasone R.S, Parameter estimation and uncertainty assessment in hydrological modelling. 2007; Technical university of Denmark.
- [6].Johnson J. Framework to effectively quantify and communicate groundwater model uncertainty to management and client, U.S. department of the Interior Urea of Reclamation. Pacific Northwest Regional Office Boise. 2010; Idaho, U.S.A.
- [7].Vrugt JA, Gupta HV, Bouten W, Sorooshian S. A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic parameter estimation. Water Resources Research. 2003; 39(8):1201.
- [8].Kanso A, Chebbo G, Tassin B. Application of MCMC-GSA model calibration method to urban runoff quality modeling, Reliability Engineering & System Safety. 2004; 91(10-11):1398-1405.
- [9].Dotto C.B.S, Mannina G, Kleidorfen M, Vezzaro L, Henrichs M, cCarthy, et al. Comparison of different uncertainty techniques in urban stormwater quantity and quality modeling, Water Research. 2012; 46(8):2545-2558.
- [10]. Talebizadeh M, Morid S, Ayyoubzadeh SA, Ghasemzadeh M. ncertainty Analysis in Sediment Load Modeling Using ANN and SWAT Model. Water Resources Management. 2009; 24(9):1747-1761.
- [11]. Pohl G, Pohlmann K, Hassan A, Chapman J, Mihvec T. Assessing groundwater model uncertainty for the central Nevada test area. Spectrum 2002.
- [12]. Hassan AE, Bekhit HB, Chapman JB. Uncertainty assessment of a stochastic groundwater flow model using GLUE analysis. Journal of Hydrology. 2008; 362:89-109.
- [13]. Blasone R.S, Vrugt J.A, Madsen H, Rosberg D, Robinson B.A, Zvyoloski, G.A. Generalized likelihood uncertainty estimation (GLUE) using adaptive Markov Chain Monte Carlo sampling, Advances in Water Resources. 2008; 31:630-648.
- [14]. Fu J, Gomez-Hernandez JJ. Uncertainty Assessment and data worth in groundwater flow and mass transport modeling using a blocking markov chain montecarlo method. Journal of Hydrology. 2009; 364:328-341.
- [15]. Sepúlveda N. Doherty J. Uncertainty Analysis of a Groundwater Flow Model in East-Central Florida. Groundwater. 2015; 53(3):464-474.
- [16]. Keating EH, Doherty J, Vrugt JA, Kang Q. Optimization and uncertainty assessment of strongly non-linear groundwater models with high parameter dimensionality. Water Resources Research. 2010; W10517(46).
- [17]. Rojas R, Feyen L, Dassargues A. Conceptual model uncertainty in groundwater modeling: Combining generalized likelihood uncertainty

estimation and Bayesian model averaging. *Water Resources Research*. 2008; W12418 44(12):619-624.

[18]. McKinney DC, Lin MD. Genetic algorithm solution of groundwater management models. *Water Resources Research*. 1994; 30(6):1897.

[19]. Huang C, Mayer AS. Pump-and-treat optimization using well locations and pumping rates as decision variables. *Water Resources Research*. 1997; 33(5):1001-1012.

[20]. Storck P, Eheart JW, Valocchi AJ. A method for the optimal location of monitoring wells for detection of groundwater contamination in three-dimensional heterogeneous aquifers. *Water Resources Research*. 1997; 33(9):2081.

[21]. Das, Datta. Application of optimisation techniques in groundwater quantity and quality management. *Sadhana: Academy Proceedings in Enging*. 2001; 26 (4):293-316.

[22]. Hsiao CT, Chang LC. Dynamic optimal groundwater management with inclusion of fixed costs. *Journal of Water Resources Planning and Management*. 2002; 128(1):57-65.

[23]. Loaiciga HA. Analytical game theoretic approach to groundwater extraction. *Journal of Hydrology*. 2004; 297:22-33.

[24]. Reed PM, Minsker BS. Striking the balance: Long-term groundwater monitoring design for conflict objectives. *Journal of Water Resources Planning and Management*. 2004; 130(2):140-149.

[25]. Tran TM. Multi-Objective Management of Saltwater in Groundwater. Optimization under Uncertainty. 2004; TU Delft University of Technology.

[26]. Wu J, Zheng C, Chein C.C, Zheng L. A comparative study of Monte Carlo simple genetic algorithm and noisy genetic algorithm for cost-effective sampling network design under uncertainty. *Advance in Water Resources*. 2005;29(1) 899-911.

[27]. Karamouz M, Tabari M. M, Kerachian R. Application of artificial neural networks and generic algorithms in conjunctive use of surface and groundwater resources. *Water International*. 2007; 32(1): 163-176.

[28]. Salazar R, Szidarousky F, Coppola EJr, Rojana A. Application of game theory for groundwater conflict in Mexico. *Journal of Environmental Management*. 2007; 84: 560-571.

[29]. Bazargan-Lari MR, Kerachian R, Mansoori A. A conflict-resolution model for the conjunctive use of surface and groundwater resources that considers

water-quality issues: A case study. *Environmental Management*. 2009; 43:470-482.

[30]. Mahjoub MA, Ammar S, Edziri H, Bouraoui A, Zine Mighri, Z. Anti-inflammatory and antioxidant activities of some extracts and pure natural products isolated from *Rhus tripartita* (Ucria) leaves, stems and fruits. *Med. Chem. Res*. 2010; 19: 271-282.

[31]. Ketabchi H, Ataie-Ashtiani B. Development of Combined Ant Colony Optimization Algorithm and Numerical Simulation for Optimal Management of Coastal Aquifers. *Iran-Water Resources Research*. 2011; 7(1):1-12 (In Persian).

[32]. Fallah mahdipour A, Bozorg Hadad A, Alimohammadi S. Optimal Operation of the Conjunctive Aquifers - Dam system: The Genetic Programming Approach. *Water resource engineering*. 2014; 7(21):51-66 (In Persian).

[33]. Ayvaz MT, Elçi A. A groundwater management tool for solving the pumping cost minimization problem for the Tahtali watershed (Izmir-Turkey) using hybrid hs-solver optimization algorithm. *Journal of Hydrology*. 2013; 478:63-76.

[34]. Narula K, Gosain, A. K. Modeling hydrology, groundwater recharge and non-point nitrate loadings in the Himalayan Upper Yamuna basin. *Science of The Total Environment*. 2013; 468, S102-S116.

[35]. Elçi A, Ayvaz MT. Differential-evolution algorithm based optimization for the site selection of groundwater production wells with the consideration of the vulnerability concept. *Journal of Hydrology*. 2014; 511:736-749.

[36]. Nakhaei M, Mohammadi M, Rezaie M. Optimizing of aquifer withdrawal numerical model using genetic algorithm (case study: Uromiyeh coastal aquifer). *Iran-Water Resources Research*. 2014; 10(2):94-97 (In Persian).

[37]. El Alfy M. Numerical groundwater modelling as an effective tool for management of water resources in arid areas. *Hydrological Sciences Journal*. 2014; 59(6), 1259-1274.

[38]. Izady A, Davary K, Alizadeh A, Ziaei AN, Akhavan S, Alipoor, et al. Groundwater conceptualization and modeling using distributed SWAT-based recharge for the semi-arid agricultural Neishaboor plain, Iran. *Hydrogeology Journal*. 2015; 23(1): 47-68.

[39]. Raei E, Nikoo MR, Pourshahabi S. A multi-objective simulation-optimization model for in situ bioremediation of groundwater contamination: Application of bargaining theory *Journal of Hydrology*. 2017; 551: 407-422.

- [40]. Thomas A. Simulation optimization model for aquifer parameter estimation using coupled meshfree point collocation method and cat swarm optimization. *Engineering Analysis with Boundary Elements*. 2018; 91: 60-72.
- [41]. Bates BC, Campbell EP. A Markov Chain Monte Carlo scheme for parameter estimation and inference in conceptual rainfall - runoff modeling. *Water Resources Research*. 2001; 37: 937-947.
- [42]. Neal R. Probabilistic inference using Markov Chain Monte Carlo methods, Technical Report CRG-TR-93-1, Department of Computer Science. University of Toronto. Toronto. Canada. 1993; 144.
- [43]. Kuczera G, Parent E. Monte Carlo assessment of parameter uncertainty in conceptual catchment models: The Metropolis algorithm. *Journal of Hydrology*. 1998; 211: 69-85.
- [44]. Metropolis N, Rosenbluth A.W, Rosenbluth M.N, Teller A.H, Teller E. Equations of state calculations by fast computing machines. *Journal of Chemical Physics*. 1953; 21: 1087-1091.
- [45]. Hastings W.K. Monte Carlo sampling methods using Markov Chains and their applications. *Biometrika*. 1970; 57: 97-109.
- [46]. Laloy E, Vrugt J.A. High-dimensional posterior exploration of hydrologic models using multiple-try DREAM (ZS) and high-performance computing. *Water Resources Research*. 2012; 48: W01526.
- [47]. Vrugt, JA, Ter Braak CJF, Diks CGH, Robinson BA, Hyman JM, Higdon D. Accelerating Markov Chain Monte Carlo simulation using self-adaptative differential evolution with randomized subspace sampling. *International Journal of Nonlinear Sciences and Numerical Simulation*. 2009; 10: 273-290.
- [48]. Kuczera G, Kavetski D, Renard B, Thyer M. A limited-memory acceleration strategy for MCMC sampling in hierarchical Bayesian calibration of hydrological models. *Water Resources Research*. 2010; 46: W07602.
- [49]. Ter Braak CJF. A Markov chain Monte Carlo version of the genetic algorithm differential evolution: Easy Bayesian computing for real parameter spaces. *Statistics and Computing*. 2006; 16: 239-249.
- [50]. Vrugt JA, Ter Braak CJF, Clark MP, Hyman JM, Robinson BA. Treatment of input uncertainty in hydrologic modeling: Doing hydrology backward with Markov chain Monte Carlo simulation. *Water Resources Research*. 2008; 44: W00B09.
- [51]. Montanari A, Koutsoyiannis D. A blueprint for process-based modeling of uncertain hydrological systems. *Water Resources Research*. 2012; 48: W09555.
- [52]. Schoups G, Vrugt J.A. A formal likelihood function for parameter and predictive inference of hydrologic models with correlated, heteroscedastic and non-Gaussian errors. *Water Resources Research*. 2010; 46: W10531.
- [53]. Koskela JJ, Croke BWF, Koivusalo H, Jakeman AJ, Kokkonen T. Bayesian inference of uncertainties in precipitation-streamflow modeling in a snow affected catchment. *Water Resources Research*. 2012; 48: W11513.
- [54]. Kamali A, Niksokhan MH. Development of a Model for Calculation of Sustainability Index of Groundwater Resources. *Ecohydrology*. 2017; 4(4): 1071-1087. (In Persian)
- [55]. Studies of gavkhuni water balance, groundwater report, zayanderoud consulting company. 2015.
- [56]. McDonald M, Harbaugh GAW. A modular three-dimensional finite-difference ground-water flow model. 1988.
- [57]. Storn R, Price K. Differential evolution-A simple and efficient heuristic for global optimization over continuous spaces. *Journal of Global Optimization*. 1997; 11: 341-359.
- [58]. Price K.V, Storn R.M, Lampinen J.A. Differential evolution, A practical approach to global optimization, Springer. Berlin. 2005; 538 pp.
- [59]. Gelman A, Rubin D.B. Inference from iterative simulation using multiple sequences, *Statistical Science*. 1992; 7: 457-472.
- [60]. Eberhart RC, Kennedy J. A new optimizer using particle swarm theory. In: Proc. of the Sixth International Symposium on Micro Machine and Human Science; 1995; 4-6 October, Nagoya, Japan, 39-43.
- [61]. Alemayehu T, van Griensven A, Woldegiorgis B.T, Bauwens W. An improved SWAT vegetation growth module and its evaluation for four tropical ecosystems. *Hydrol. Earth Syst. Sci*. 2017; 21, 4449-4467.
- [62]. Nourali M, Ghahraman B, Pourreza-Bilondi M, Davary K. Effect of formal and informal likelihood functions on uncertainty assessment in a single event rainfall-runoff model. *Journal of Hydrology*. 2016; 540: 549-564.