



کالیبراسیون خودکار مدل شبیه‌سازی آب‌های زیرزمینی (MODFLOW) با الگوریتم غیرقطعی SUFI-II

فریبرز معصومی^{۱*}، سعید نجارقابل^۲، اکبر صفرزاده^۱

۱- دانشگاه محقق اردبیلی، اردبیل، ایران
۲- دانشکده عمران، دانشگاه تبریز، تبریز، ایران.

تاریخچه داوری:

دریافت: ۱۳۹۸/۰۶/۱۴
بازنگری: ۱۳۹۸/۰۸/۱۴
پذیرش: ۱۳۹۸/۰۹/۱۹
ارائه آنلاین: ۱۳۹۸/۰۹/۲۴

کلمات کلیدی:

کالیبراسیون خودکار
MODFLOW
تحلیل عدم قطعیت
الگوریتم SUFI-II
آبخوان دشت اردبیل.

خلاصه: شبیه‌سازی ریاضی سیستم منابع آب زیرزمینی یکی از ابزارهای ضروری در مدیریت این منابع ارزشمند به حساب می‌آید و کالیبراسیون این مدل‌های شبیه‌ساز یکی از مراحل وقت‌گیر و پیچیده در این فرآیند است. کالیبراسیون خودکار که در سال‌های اخیر توسط محققان با الگوریتم‌های مختلفی توسعه داده شده‌است، یکی از روش‌های مؤثر در غلبه بر این مشکلات محاسباتی است. از طرف دیگر، کمبود داده‌های صحرائی از لحاظ زمانی و مکانی و پیچیدگی‌های هیدرولوژیکی و هیدروژئولوژیکی، عدم قطعیت‌های زیادی را به نتایج کالیبراسیون وارد می‌کند. الگوریتم SUFI-II یک روش کالیبراسیون خودکار مبتنی بر عدم قطعیت است که توانایی کالیبراسیون و تحلیل عدم قطعیت مدل‌های شبیه‌سازی عددی را دارد. در این مقاله، برای اولین بار، از این الگوریتم برای کالیبراسیون و تحلیل عدم قطعیت پارامترهای هیدرودینامیکی (هدایت هیدرولیکی و آبدهی ویژه) مدل MODFLOW استفاده شده‌است. نتایج اجرای مدل برای آب‌های زیرزمینی دشت اردبیل (شمال غربی ایران)، نشان دهنده قرار گرفتن به‌طور متوسط ۶۲ درصد مقادیر مشاهداتی سطح ایستایی در محدوده بازه اطمینان ۹۵ درصد است. در نهایت، با رویکرد پیشنهادی، مناسب‌ترین مقدار برای بازه پارامترهای هدایت هیدرولیکی و آبدهی ویژه تعیین شده‌است. همچنین کالیبراسیون مدل شبیه‌سازی آب زیرزمینی با استفاده از PEST نیز صورت گرفته است. مطابق نتایج، مقدار مجذور میانگین مربعات خطا (RMSE) در این حالت (RMSE = ۳/۳۷) بیشتر از مقدار به دست آمده از روش SUFI-II (RMSE = ۱/۸۶) است که نشان‌دهنده عملکرد بهتر الگوریتم SUFI-II نسبت به مدل PEST است.

۱- مقدمه

آب‌های زیرزمینی یکی از منابع حیاتی در تأمین آب مورد نیاز برای مصارف مختلف کشاورزی، صنعتی و شرب است [۱]. تغییرات اخیر در چرخه هیدرولوژیک به دلیل تغییرات آب و هوایی جهانی، رشد جمعیت و گسترش مناطق کشاورزی، باعث استفاده بیش از حد از منابع آب زیرزمینی در بیشتر نقاط دنیا شده‌است. مدیریت این منابع به دلیل مشکلاتی که در اثر استفاده بیش از حد، از جمله کاهش تراز آب زیرزمینی، کاهش کیفیت آب و افزایش هزینه‌های برداشت ایجاد می‌شود، ضروری است [۲].

یکی از ابزارهای مهم برای مدیریت منابع آب زیرزمینی، مدل‌های عددی جهت شبیه‌سازی این منابع است. در سال‌های اخیر، محققان

* نویسنده عهده‌دار مکاتبات: f_masoumi@uma.ac.ir

زیادی از مدل‌های عددی برای مدیریت منابع آب زیرزمینی استفاده کرده‌اند [۳-۶]. یکی از اصلی‌ترین چالش‌هایی که محققان در استفاده از مدل‌های شبیه‌سازی عددی دارند، کالیبراسیون این مدل‌ها است. به طور کلی، کالیبراسیون این مدل‌ها می‌تواند بر اساس سعی و خطا یا به صورت خودکار انجام شود. در دهه‌های اخیر، روش‌های مختلفی مبتنی بر مدل‌سازی معکوس برای برآورد پارامترهای هیدرولوژیکی به صورت خودکار توسعه داده شده‌است [۷-۱۰]. روش‌های کالیبراسیون خودکار در مقایسه با کالیبراسیون به روش سعی و خطا بسیار سریع‌تر است و به دلیل امکان جستجوی گسترده‌تر فضای پارامترها، نتایج بهتری را ارائه می‌دهند [۱۱]. همچنین، نرم‌افزارهای مختلفی برای کالیبراسیون خودکار مدل‌های آب‌های زیرزمینی مانند: PEST [۱۲]،



از جمله مطالعاتی که با استفاده از روش مونت کارلو صورت گرفته است می‌توان به تحقیق یون^۶ و همکاران [۲۵]، اشاره کرد. در این تحقیق، از روش توسعه‌یافته مونت کارلو فضای تهی^۷ (NSMC) به منظور ارزیابی عدم قطعیت پارامترهای مربوط به مدل MODFLOW استفاده و این روش را به عنوان راهکاری کارآمد در تحلیل عدم قطعیت جریان‌های زیرسطحی پیچیده و غیرخطی معرفی کرده‌اند. همچنین وو^۸ و همکاران [۲۶]، با استفاده از الگوریتم متروپولیس-مونت کارلو زنجیره مارکوف (AM-MCMC) و مدل عددی آب زیرزمینی برای یک آبخوان فرضی، تحلیل ریسک و عدم قطعیت انجام داده‌اند. نتایج، کارآمد بودن این روش را بدون نیاز به اصلاح ساختار مدل نشان داده است. پژوهش‌های انجام‌گرفته در سالیان اخیر نیز نشان‌دهنده کارایی مؤثر این روش در بررسی عدم قطعیت مدل‌های آب زیرزمینی است. از طرفی، یکی از مشکلات موجود در روش مونت کارلو، حجم زیاد محاسبات و نیاز به کد نویسی در مدل‌های پیچیده آب زیرزمینی است که منجر به صرف زمان بسیار زیادی در تحلیل عدم قطعیت سطح آب زیرزمینی در مدل‌سازی می‌گردد [۲۷].

یکی از محبوب‌ترین روش‌های مبتنی بر مونت کارلو که به طور گسترده جهت واسنجی و تحلیل عدم قطعیت پارامترهای مدل هیدرولوژیکی که دارای ساختاری شبیه بیزی و بر اساس اصل برابری نتایج است [۲۵ و ۲۸] مورد استفاده قرار می‌گیرد، روش عمومی عدم قطعیت تشابهات (GLUE) است که توسط بی ون^۹ و باینلی^{۱۰} [۲۹] ارائه شده است. این روش با آن که برای واسنجی و تخمین عدم قطعیت مدل‌های پیچیده توسعه‌یافته، اخیراً به یکی از پرکاربردترین روش‌های هم‌زمان انجام واسنجی و تحلیل عدم قطعیت در مدل‌های منابع آب و محیط‌زیست تبدیل شده است. محققان مختلفی از این روش در مدل‌های آب زیرزمینی استفاده کرده‌اند. جنسن^{۱۱} [۳۰]، با استفاده از روش GLUE برای یک آبخوان فرضی به ارزیابی تأثیر ناهمگنی در عدم قطعیت پرداخته است. همچنین تأثیر داده‌های سطح ایستایی مشاهداتی و دبی رودخانه را نیز در مقدار عدم قطعیت بررسی نموده و کارایی مؤثر این روش را نشان داده است.

UCODE [۱۳] و HydroPSO [۱۴]، ایجاد شده است. اگرچه این نرم‌افزارها روند کالیبراسیون را سرعت می‌بخشند، اما ممکن است به دلیل این که هدف اصلی آن‌ها تطابق مقادیر مشاهداتی و محاسباتی بدون در نظر گرفتن واقعیت‌های فیزیکی است، مقادیر غیرمنطقی برای پارامترها به دست آورند [۱۵].

مدل‌های آب زیرزمینی برای شبیه‌سازی و پیش‌بینی استفاده می‌شوند و نتایج این مدل‌ها به پارامترهای ورودی مدل بستگی دارد. از طرف دیگر، کمبود داده‌های میدانی و پیچیدگی‌های هیدروژئولوژیکی باعث ایجاد عدم قطعیت‌هایی در مدل می‌شود [۱۶]. روش‌های کالیبراسیون خودکار بر مبنای تحلیل عدم قطعیت از جمله روش‌هایی هستند که در سال‌های اخیر بیشتر مورد توجه محققین بوده است. در این روش‌ها تخمین‌های بازه‌ای از مقدار پارامترها فراهم می‌شود، برخلاف دیگر روش‌های بهینه‌سازی که تخمین‌های نقطه‌ای و قطعی از مقدار پارامترها به وجود می‌آورند. خطاهای موجود در اندازه‌گیری مشاهدات (مثل دما و میزان بارش)، در متغیرهای خروجی (مانند دبی و میزان رسوبات) و در فرضیات مدل مورد استفاده [۱۷] و همچنین وجود جواب‌های متفاوت با مقادیر یکسان از تابع هدف از جمله دلایلی است که هیدرولوژیست‌ها روی به استفاده از روش‌های مبتنی بر عدم قطعیت آورده‌اند. در مدل‌های آب زیرزمینی نیز تغییرات زمانی و مکانی پارامترهای ورودی و همچنین پیچیدگی‌های هیدروژئولوژیکی باعث ایجاد عدم قطعیت در مدل می‌شود. تحلیل عدم قطعیت، بر اساس پارامترهای متغیر ورودی، امکان توصیف تمام خروجی‌های امکان‌پذیر به همراه احتمال وقوع آن‌ها را فراهم می‌کند. در روش کالیبراسیون خودکار مبتنی بر عدم قطعیت، ابتدا یک بازه‌ای از مقادیر برای هر پارامتر در نظر گرفته می‌شود و در طی روند محاسبات بازه‌های پارامترها دقیق می‌شوند. در حال حاضر، از جمله روش‌های پرکاربرد که برای بررسی عدم قطعیت پارامترها استفاده می‌شود، می‌توان به روش عمومی عدم قطعیت تشابهات (GLUE^۱) [۱۸] و [۱۹]، زنجیره مارکوف مونت کارلو (McMC^۲) [۲۰] و [۲۱] و الگوریتم‌های مشابه آن مانند bMcMC^۳ [۲۲]، N-McMC^۴ [۲۳] و ساختار بیزن^۵ [۲۴] اشاره کرد.

6 Yoon
7 Null Space Monte carlo
8 Wu
9 Beven
10 Binley
11 Jensen

1 Generalized Likelihood Uncertainty Estimation
2 Markov Chain Monte Carlo
3 Blocking Monte carlo Markov Chain
4 Null Space Monte carlo Markov Chain
5 Bayesian Approach

و تحلیل عدم قطعیت در منابع آب زیرزمینی استفاده نشده است. از جمله مطالعاتی که با استفاده از این الگوریتم برای سیستم‌های منابع آب سطحی، صورت گرفته می‌توان به مقاله‌ی موسوی و همکاران [۳۶] اشاره کرد. در این مطالعه از الگوریتم SUFI-II به صورت متصل شده به مدل HEC-HMS برای کالیبراسیون خودکار و بررسی عدم قطعیت‌های حوضه رودخانه‌ی تامر واقع در شمال ایران استفاده شده است. نتایج استفاده از این مدل، نشان‌دهنده‌ی عملکرد خوب الگوریتم SUFI-II در کالیبراسیون خودکار بر مبنای عدم قطعیت است. کائو^۵ و همکاران [۳۷] نیز از الگوریتم SUFI-II برای تحلیل حساسیت و عدم قطعیت یک مدل در مقیاس روزانه برای حوضه یک رودخانه استفاده کرده‌اند. نتایج، نشان‌دهنده عملکرد خوب مدل SWAT کالیبره شده در پیش‌بینی جریان روزانه است. همچنین در مطالعه‌ی یانگ^۶ و همکاران [۳۸]، روش‌های مختلف GLUE، ParaSol، SUFI-II و MCMC را برای یک حوضه آبریز در چین مقایسه کرده‌اند. در این مطالعه نشان داده شده است که با در نظر گرفتن بازه‌های مختلف برای فضای پارامترها، روش‌های مختلف ممکن است هر یک به جواب‌های مختلفی همگرا شوند. همچنین از الگوریتم SUFI-II برای کالیبراسیون مدل‌های توسعه محصول نیز استفاده شده است. کمالی و همکاران [۳۹]، الگوریتم SUFI-II را با یک نرم‌افزار مدل‌سازی محصول (EPIC) به منظور کالیبراسیون بازه محصول ذرت برای یک مطالعه موردی توسعه داده‌اند که در نهایت منجر به تولید یک نرم‌افزار کاربرپسند (EPIC⁺) برای کالیبراسیون مدل‌های توسعه محصول شده است.

در این تحقیق، به منظور کالیبراسیون خودکار مدل آب زیرزمینی از یک ساختار مرکب مبتنی بر عدم قطعیت استفاده شده است. به این ترتیب که از کد MODFLOW برای مدل‌سازی آب زیرزمینی و از الگوریتم SUFI-II به منظور کالیبراسیون خودکار و تحلیل عدم قطعیت پارامترهای هدایت هیدرولیکی و آبدهی ویژه آبخوان استفاده شده است. برای پیش‌پردازش و پس‌پردازش مدل MODFLOW از نرم‌افزار کاربرپسند GMS استفاده شده است. توسعه مدل متصل شده‌ی SUFI-II-MODFLOW در محیط نرم‌افزار MATLAB صورت گرفته است. همچنین در ادامه، کالیبراسیون مدل آب زیرزمینی با استفاده از PEST نیز انجام شده و نتایج با الگوریتم SUFI-II مقایسه

روجاس^۱ و همکاران [۱۹]، با استفاده از دو روش GLUE و BMA^۲ به تحلیل عدم قطعیت‌های یک آبخوان فرضی که ناشی از ساختار مدل، داده‌های ورودی و پارامترهای مدل است پرداخته‌اند. نتایج نشان داده است که یک مدل با واسنجی عالی، نشان‌دهنده صحت مدل مفهومی نیست و عدم قطعیت موجود در نتایج اجتناب‌ناپذیر است. در ادامه روجاس و همکاران [۳۱]، روش پیشنهادی خود را به تحلیل عدم قطعیت موجود در سناریوهای پیش‌بینی یک مدل واقعی و در نظر گرفتن سه مدل مفهومی با سطوح پیچیدگی متفاوت در اطلاعات زمین‌شناسی تعمیم دادند و نشان دادند که در نظر گرفتن عدم قطعیت ناشی از سناریوهای مختلف تأثیر بسزایی در کاهش میزان عدم قطعیت کل دارد. همچنین محققان دیگری از این روش در مدل‌های آب زیرزمینی استفاده کرده‌اند [۱۶ و ۳۲]. در یک مطالعه، اینام^۳ و همکاران [۳۳]، از روش GLUE برای کالیبراسیون خودکار و تحلیل حساسیت یک مدل توزیع شده در مقیاس حوضه به منظور پیش‌بینی تغییرات تراز آب زیرزمینی استفاده نموده‌اند که تقریباً ۷۰ درصد مقادیر مشاهداتی تراز آب زیرزمینی در داخل بازه عدم قطعیت قرار گرفته است. در عین حال، این روش نیاز به تعداد شبیه‌سازی‌های بسیار زیاد دارد و این مسئله یک نقطه ضعف برای این روش به حساب می‌آید [۳۴]. همچنین از الگوریتم‌های تکاملی نیز در کالیبراسیون خودکار و تحلیل عدم قطعیت نیز استفاده شده است. بارنارت^۴ و همکاران [۳۵] یک الگوریتم تکاملی چندهدفه برای کالیبراسیون و کنترل حساسیت توسعه داده‌اند (MOESHA). در این الگوریتم توسعه یافته، عدم قطعیت پارامترهای ورودی و تحلیل حساسیت با یک الگوریتم ژنتیک ترکیب شده است که به صورت تکراری از فضای پارامترها نمونه‌برداری می‌شود. هزینه‌ی سنگین محاسباتی یکی از مشکلات عمده این الگوریتم است که برای کاهش بار محاسباتی در استفاده از این الگوریتم از روش موازی‌سازی استفاده شده است.

روش SUFI-II، از جمله روش‌هایی است که واسنجی و تحلیل عدم قطعیت مدل را هم‌زمان انجام می‌دهد. روش SUFI-II به طور گسترده‌ای در کالیبراسیون خودکار و تعیین عدم قطعیت مدل‌های هیدرولوژیکی استفاده شده است؛ اما تاکنون از این روش برای واسنجی

-
- 1 Rojas
 - 2 Bayesian Model Averaging
 - 3 Inam
 - 4 Barnhart

5 Cao
6 Yang

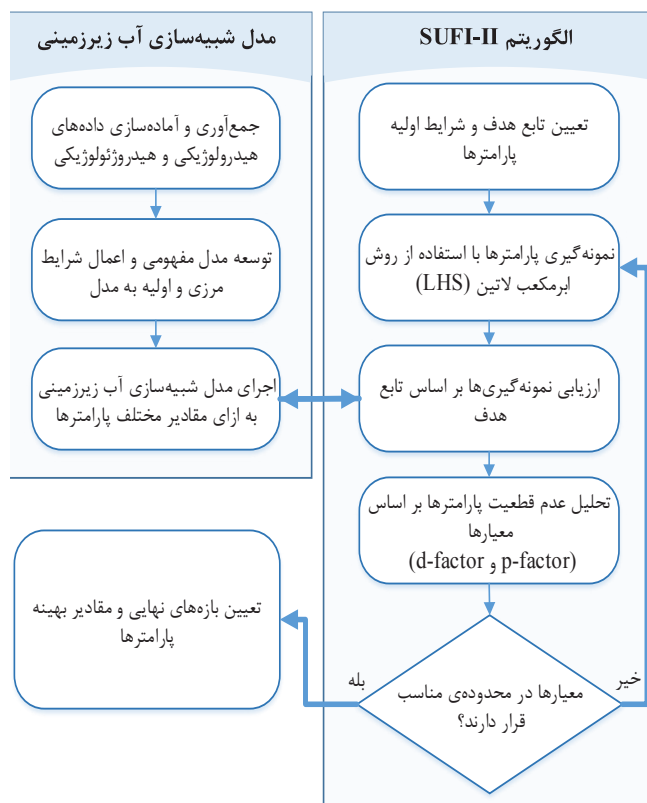
خودکار و تحلیل عدم قطعیت مدل به کار گرفته شده است. در واقع، در این ساختار الگوریتم SUFI-II با تغییر مقادیر پارامترها (که به عنوان ورودی مدل شبیه سازی آب زیرزمینی استفاده می شود)، مدل شبیه سازی آب زیرزمینی تهیه شده را به طور مکرر فراخوانی، نمونه گیری ها را با توجه به تابع هدف ارزیابی، معیارهای عدم قطعیت را محاسبه و در نهایت، مقادیر بهینه و بازه بهینه نهایی را برای هر یک از پارامترها مشخص می کند. مراحل مختلف الگوریتم SUFI-II و مدل شبیه سازی آب زیرزمینی به ترتیب در بخش های ۲-۲ و ۳-۲ به تفصیل بیان شده است.

۱-۱- منطقه مورد مطالعه

حوضه آبریز دشت اردبیل در محدوده طول شرقی $48^{\circ}40'$ - $48^{\circ}00'$ و عرض شمالی $38^{\circ}30'$ - $38^{\circ}00'$ قرار گرفته است. دشت اردبیل با مساحت حدود 1074 کیلومترمربع، با داشتن منابع آب زیرزمینی غنی و خاک مرغوب، در نیم قرن اخیر، همواره مورد توجه بوده و محل مناسبی جهت تأمین آب شرب و کشاورزی بوده است. از نظر توپوگرافی بخش پیرامونی منطقه، کوهستانی بوده و بخش مرکزی آن دشت آبرفتی است. شکل ۲، موقعیت منطقه مورد مطالعه را نشان می دهد. بیشترین ارتفاع مربوط به قله سلان با ارتفاع 4810 متر از سطح دریا و کمترین ارتفاع مربوط به ناحیه خروجی در شمال غربی دشت با ارتفاع 1170 متر از سطح دریا است. این دشت دارای سه رودخانه اصلی قره سو، بالیخلی چای و قوری چای است. نوران چای، هیرچای و شهریورچای نیز از دیگر رودهای این دشت می باشند.

۱-۲- الگوریتم مدل SUFI-II

این الگوریتم توسط عباسپور و همکاران [۴۰] در سال ۲۰۰۴ معرفی گردید. این الگوریتم نسخه ی دوم از الگوریتم SUFI است که عباسپور و همکاران [۴۱] در سال ۱۹۹۷ معرفی کرده بودند. این الگوریتم مبتنی بر تحلیل عدم قطعیت است و بدین صورت عمل می کند که ابتدا تابع هدفی تعریف می گردد، سپس بازه هایی برای کمینه و بیشینه هر پارامتر با توجه به مفهوم فیزیکی هر پارامتر در نظر گرفته می شود. توزیع اولیه پارامترها یکنواخت فرض می شود. تحلیل حساسیت مطلق برای تمام پارامترها قبل از آغاز روند تکراری الگوریتم ضروری است تا از این طریق بتوان تعداد پارامترهای کالیبراسیون را کاهش داده و مهم ترین آن ها را فقط در روند کار



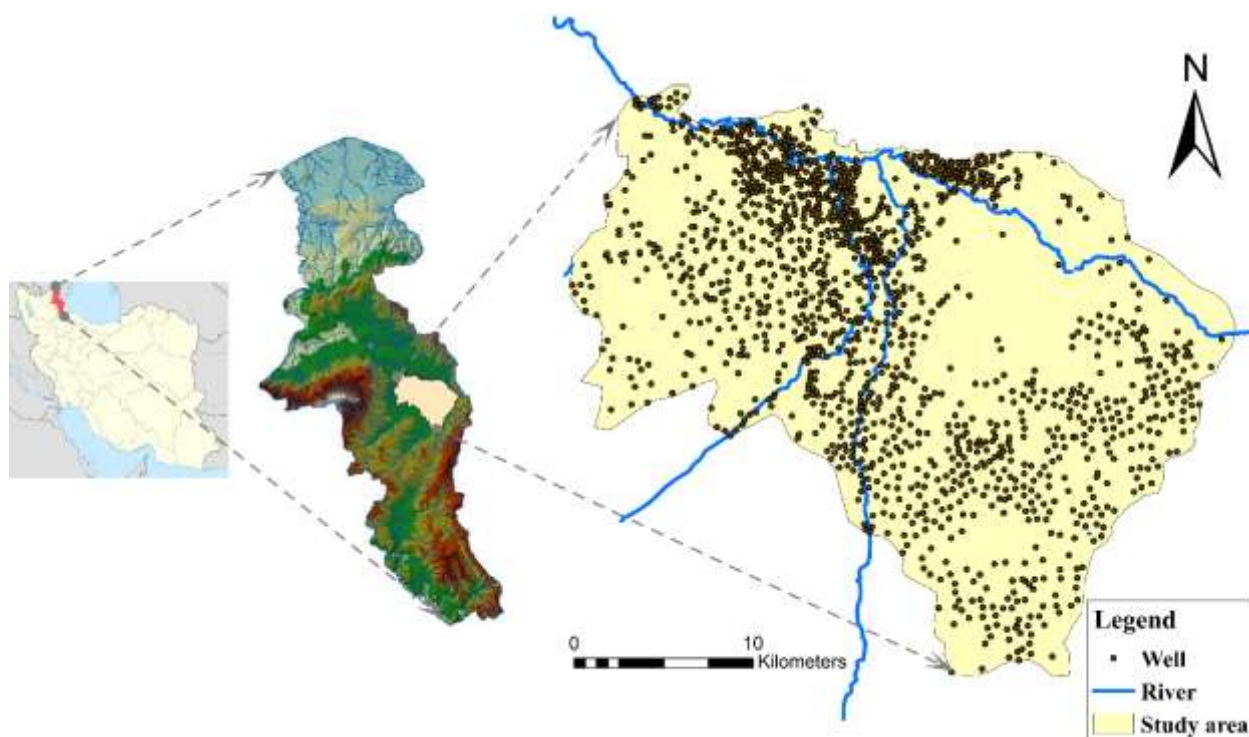
شکل ۱. مدل ارتباط داده شده MODFLOW-SUFI-II

Fig. 1. MODFLOW-SUFI2 linked model

شده است. اگرچه الگوریتم های بهینه سازی زیادی برای کالیبراسیون مدل های آب زیرزمینی توسعه داده شده است؛ اما تاکنون از الگوریتم SUFI-II برای کالیبراسیون مدل آب زیرزمینی استفاده نشده است. از مزیت های این الگوریتم نسبت به دیگر الگوریتم های بهینه سازی مرسوم، بازه ای در نظر گرفتن پارامترها در انتهای فرآیند کالیبراسیون و نیاز به تعداد شبیه سازی کمتر است. لازم به ذکر است به منظور ارزیابی ساختار ارائه شده در این تحقیق، آبخوان دشت اردبیل به عنوان مطالعه موردی انتخاب شده است.

۲- مواد و روش ها

ساختار کلی رویکرد استفاده شده در این مقاله که در شکل ۱ نشان داده شده است. مطابق این شکل، برای کالیبراسیون خودکار مدل شبیه سازی آب زیرزمینی، یک مدل شبیه سازی-واسنجی متصل شده به کار گرفته شده است. به همین منظور، بعد از آماده سازی داده های اولیه و تهیه مدل مفهومی، از کد MODFLOW به عنوان شبیه سازی آب های زیرزمینی دشت اردبیل و تعیین مقادیر تابع هدف تعیین شده برای واسنجی، به ازای مقادیر مختلف پارامترها استفاده شده است. همچنین الگوریتم SUFI-II نیز به منظور واسنجی



شکل ۲. آبخوان دشت اردبیل و محل چاه‌های بهره‌برداری

Fig. 2. Ardabil plain aquifer and location of wells

شاخص d -factor کوچک‌تر باشد، نتیجه‌ی واسنجی مطلوب‌تر است. مشاهده شده‌است که در طی روند واسنجی با استفاده از این الگوریتم هر دو شاخص در ابتدا بزرگ می‌باشند و با پیشرفت الگوریتم هر دو شاخص کوچک‌تر می‌شوند.

مراحل الگوریتم SUFI-II را می‌توان به صورت زیر بیان کرد [۴۲]:

مرحله اول: اولین مرحله در این الگوریتم تعریف تابع هدف است. توابعی مختلفی مانند: $RMSE$ ، Chi -square، R^2 ، Nash-Sutcliffe، و غیره استفاده کرد. در این تحقیق از رابطه‌ی ۱، به عنوان تابع هدف الگوریتم استفاده شده‌است.

$$RMSE = \left[\frac{\sum_{i=1}^n (C_i - O_i)^2}{n} \right]^{\frac{1}{2}} \quad (1)$$

در این رابطه C_i ، مقادیر محاسباتی؛ O_i ، مقادیر مشاهداتی و n نیز تعداد داده‌ها است.

مرحله دوم: تعریف مقادیر مطلق حداکثر و حداقل هر پارامتر است که از لحاظ فیزیکی معنادار باشد.

$$b_j : b_{j,abs_min} \leq b_j \leq b_{j,abs_max} \quad j = 1, \dots, m \quad (2)$$

در نظر گرفت. بازه‌های عدم قطعیت اولیه هر پارامتر برای نوبت اول از روش نمونه‌گیری، Latin Hypercube (LH) تعیین می‌شوند. نمونه‌گیری با روش مذکور از درون بازه‌های تعیین شده در گام قبل، انجام می‌پذیرد و با انجام تعدادی عملیات ماتریسی، بازه‌های عدم قطعیت هر پارامتر به دست می‌آید. این الگوریتم لازم است چند بار تکرار گردد تا بازه‌های عدم قطعیت پارامترها با پیشرفت الگوریتم، دقیق گردند. ناحیه عدم قطعیت با ۹۵PPU شناخته می‌شود که دربرگیرنده‌ی ۹۵ درصد از نتایج شبیه‌سازی است و با کوچک‌تر شدن بازه‌ی تغییرات پارامترها، این ناحیه نیز کوچک‌تر می‌شود. با دقیق شدن بازه‌های هر پارامتر، نتایج شبیه‌سازی به نحوی خواهد بود که اعداد مشاهداتی که خارج از ناحیه‌ی ۹۵PPU قرار دارند، افزایش می‌یابد. تعداد نقاط موجود در ناحیه‌ی ۹۵PPU که نشان‌دهنده‌ی شمول نتایج مدل بر مشاهدات و یا کیفیت نتایج مدل است، توسط شاخصی به نام p -factor و دقت بازه‌های تغییرات پارامترها توسط شاخص d -factor کمی می‌شود شاخص p -factor به صورت نسبت تعداد مشاهدات قرار گرفته در ناحیه‌ی ۹۵PPU به کل مشاهدات و همچنین d -factor به صورت میانگین پهنای ناحیه‌ی ۹۵PPU به انحراف معیار مشاهدات بیان می‌شود. با توجه به تعاریف شاخص‌ها، می‌توان نتیجه گرفت که هر چقدر شاخص p -factor بزرگ‌تر و

تعداد تمام ترکیبات ممکن از دو شبیه‌سازی (C_2^n) که به صورت $C_2^n = n! / [2! \times (n-2)!]$ محاسبه می‌گردد. ستون‌های ماتریس حساسیت برابر تعداد پارامترها (m) است. سپس بر اساس ماتریس همبستگی^۱ با پیروی از روش گوس-نیوتن به صورت $H = J^T J$ محاسبه می‌شود. بر اساس قضیه Carmer-Rao [۴۳] تخمینی از حد پایین ماتریس کوواریانس پارامترها، C ، به صورت $C = s_g^2 (J^T J)^{-1}$ محاسبه می‌گردد که s_g^2 واریانس مقادیر تابع هدف به ازای n مرتبه شبیه‌سازی مدل است. سپس انحراف معیار و بازه اطمینان ۹۵ درصد برای هر پارامتر از طریق اعضای قطری ماتریس کوواریانس C ، به صورت روابط ۵ تا ۷ تخمین زده می‌شود:

$$s_j = \sqrt{C_{jj}} \quad (۵)$$

$$b_{j,Lower} = b_j^* - abs(t_{\nu,0.025})s_j \quad (۶)$$

$$b_{j,Upper} = b_j^* + abs(t_{\nu,0.025})s_j \quad (۷)$$

در روابط ۶ و ۷، b_j^* مقدار پارامتر j ام است که به ازای آن بهترین مقدار تابع هدف به دست می‌آید و $t_{\nu,0.025}$ مقدار صدک متغیر تصادفی student t به ازای سطح معنی‌دار ۰/۰۲۵ با درجه آزادی ν بوده که در اینجا ν برابر $(n - m)$ است. می‌توان نشان داد که بازه اطمینان هر پارامتر در انتهای هر مرحله نسبت به مرحله قبل کوچک‌تر است. همچنین ماتریس همبستگی^۲ (r) پارامترها توسط اعضای قطری و غیر قطری ماتریس کوواریانس ارزیابی بر اساس رابطه‌ی ۸ می‌شود:

$$r_{i,j} = \frac{C_{ij}}{\sqrt{C_{jj}} \sqrt{C_{ii}}} \quad (۸)$$

حساسیت پارامترها با میانگین‌گیری از ستون‌های ماتریس ژاکوبین^۱، مطابق رابطه‌ی ۹، به دست می‌آید:

$$S_j = \bar{b}_j \frac{1}{C_2^n} \sum_{i=1}^{C_2^n} \left| \frac{\Delta g_i}{\Delta b_j} \right| \quad j=1, \dots, m \quad (۹)$$

بنابراین به این صورت بازه عدم قطعیت هر پارامتر طی روند الگوریتم دقیق می‌گردد.

مرحله هشتم: محاسبه انحراف معیار مشاهدات و بازه ۹۵PPU

که در این رابطه b_j نشان‌دهنده‌ی پارامتر j ام و m نیز تعداد پارامترهایی که باید بهینه‌سازی شود است.

مرحله سوم: این گام شامل آنالیز حساسیت مطلق برای تمام پارامترها است. این مرحله اختیاری است، اما برای تمام پارامترها در مراحل اولیه و اسنچی توصیه می‌شود. واضح است که هیچ بهینه‌سازی خودکاری نمی‌تواند جایگزین دانسته‌ها و دانش فیزیکی اثرات پارامترها روی سیستم شود. آنالیز حساسیت با ثابت نگه‌داشتن تمام پارامترها در مقدار واقعی و با تغییر تنها یک پارامتر در هر مرحله اجرا می‌شود، در حالی که هر پارامتر درون محدوده مشخص شده در مرحله اول تغییر می‌کند. به طوری که تأثیر تغییرات هر پارامتر در گام یک مشخص شود. ترسیم نتایج این شبیه‌سازی‌ها به همراه داده‌های مشاهده‌ای در یک گراف، اطلاعاتی در مورد انتخاب صحیح محدوده پارامترها به کاربر خواهد داد.

مرحله چهارم: اولین محدوده عدم قطعیت پارامترها برای نخستین دوره نمونه‌برداری (LH) Latin Hypercube تعیین می‌شود:

$$b_j : b_{j,\min} \leq b_j \leq b_{j,\max} \quad j = 1, \dots, m \quad (۳)$$

محدوده‌ها در این رابطه نسبت به محدوده‌های مطلق کوچک‌تر هستند و با توجه به تحلیل حساسیت صورت گرفته در مرحله در نظر گرفته می‌شود.

مرحله پنجم: نمونه‌گیری از بازه هر یک از پارامترها بر اساس روش نمونه‌گیری LH به تعداد n سری از ترکیب پارامترها که در اینجا n نشان دهنده‌ی تعداد شبیه‌سازی‌های مطلوب است.

مرحله ششم: به عنوان اولین مرحله از ارزیابی شبیه‌سازی‌ها، تابع هدفی که در مرحله اول تعیین شده، در این مرحله محاسبه می‌گردد. مرحله هفتم: در راستای ارزیابی هر دور نمونه‌گیری ابتدا ماتریس حساسیت (ماتریس ژاکوبین)، J ، با استفاده از رابطه زیر محاسبه می‌شود:

$$J = \Delta g_i / \Delta b_j^i \quad i=1, \dots, C_2^n, j=1, \dots, m \quad (۴)$$

که در این رابطه، Δg_i اختلاف تابع هدف هر ترکیب دوتایی از شبیه‌سازی مدل و Δb_j^i اختلاف مقادیر پارامتر j ام برای ترکیب i ام است. همچنین سطرهای ماتریس حساسیت برابر

1 Hessian matrix
2 Correlation matrix

بزرگ‌تر است [۴۲]

۱-۳- مدل شبیه‌ساز آب زیرزمینی

در این تحقیق، به منظور شبیه‌سازی جریان آب زیرزمینی از کد MODFLOW استفاده شده‌است. این کد توسط سازمان زمین‌شناسی آمریکا، تهیه شده‌است. نسخه اصلی این برنامه اولین بار توسط مک‌دونالد^۲ و هارباک^۳ [۴۴] تهیه گردیده است. این کد، جریان را به صورت سه‌بعدی و به روش تفاضل محدود مدل می‌نماید. همچنین نرم‌افزار GMS^۴ به عنوان رابط گرافیکی به منظور پیش‌پردازش و پس‌پردازش مدل آب زیرزمینی استفاده شده‌است. در واقع نرم‌افزار GMS به کمک مدول‌های مختلف، ورودی‌های مدل را به فرمت مناسب تهیه می‌کند، سپس هسته اصلی مدل مورد نظر (در اینجا، MODFLOW) را فراخوانی، برنامه را اجرا و مجدداً خروجی مدل را ساماندهی و به فرمت مناسب و دلخواه کاربر درمی‌آورد. تعریف شرایط موجود برای مدل‌سازی در نرم‌افزار، MODFLOW از طریق بسته‌های مربوطه صورت می‌گیرد. همچنین، از بسته نرم‌افزاری خودکار پارامتر، PEST، در نرم‌افزار GMS استفاده شده‌است. تابع هدف در این روش به صورت رابطه‌ی ۱۴ است. PEST با به حداقل رساندن مجموع مقادیر مجذور باقی‌مانده‌های وزن‌دار، فرآیند کالیبراسیون رو انجام می‌دهد.

$$\Phi(\text{Error}) = \sum (w_i r_i)^2, \quad r_i = (h_{\text{calculated}} - h_{\text{observed}}) \quad (14)$$

PEST بر مبنای کمینه کردن تابع Φ عمل می‌کند. در رابطه (۱۴)، $h_{\text{calculated}}$ ، h_{observed} و r_i به ترتیب، مقدار تراز آب محاسباتی، تراز آب زیرزمینی مشاهداتی و اختلاف این دو مقدار است. همچنین، وزن اختصاص یافته به هر یک از مشاهدات است.

رابط گرافیکی GMS هنگامی که کد MODFLOW را اجرا می‌کند، فایل‌هایی با فرمت HDF۵^۵ ذخیره می‌کند. این فرمت، داده‌ها را به صورت باینری ذخیره می‌کند و معمولاً برای مدیریت و طبقه‌بندی داده‌های انبوه استفاده می‌شود. توسعه این فرمت توسط مرکز ملی

برای هر پارامتر با توزیع ۹۷/۵ درصد (X_U) و ۲/۵ درصد (X_L) (هر یک از نقاط شبیه‌سازی به ازای نمونه‌گیری‌های LH. میانگین فاصله (d) حدود بالا و پایین محدوده‌ی ۹۵PPU به صورت زیر تعیین می‌شود.

$$\bar{d}_x = \frac{1}{k} \sum_{z=1}^k (X_{U,Z} - X_{L,Z}) \quad (10)$$

در این رابطه k تعداد نقاط داده‌های مشاهداتی است. همچنین d-factor به صورت میانگین پهنای ناحیه‌ی ۹۵PPU به انحراف معیار (σ_x) بوده و به صورت زیر بیان می‌شود.

$$d - \text{factor} = \frac{\bar{d}_x}{\sigma_x} \quad (11)$$

مرحله نهم: به خاطر این که عدم قطعیت پارامترها در ابتدا بزرگ است، مقدار \bar{d} در شبیه‌سازی اول بزرگ می‌شود. بنابراین لازم است دامنه پارامترها تعدیل شوند. دامنه جدید برای هر پارامتر به صورت زیر محاسبه می‌گردد:

$$b'_{j,\min} = b_{j,\text{Lower}} - \text{Max} \left(\frac{b_{j,\text{Lower}} - b_{j,\min}}{2}, \frac{b_{j,\max} - b_{j,\text{Upper}}}{2} \right) \quad (12)$$

$$b'_{j,\max} = b_{j,\text{Upper}} + \text{Max} \left(\frac{b_{j,\text{Lower}} - b_{j,\min}}{2}, \frac{b_{j,\max} - b_{j,\text{Upper}}}{2} \right) \quad (13)$$

که b' نشان دهنده محدوده جدید پارامترها است. از بهترین شبیه‌سازی پارامترها برای محاسبه $b_{j,\text{Lower}}$ و $b_{j,\text{Upper}}$ استفاده می‌شود. منظور از بهترین شبیه‌سازی پارامترها، شبیه‌سازی است که به ازای آن بهترین مقدار تابع هدف به دست آمده است. معیارهای فوق، در حالی که محدوده پارامترها برای تکرار بعدی را کاهش می‌دهند، حدود پارامترها طوری تعیین می‌شود که بهترین شبیه‌سازی در مرکزیت قرار گیرد. در روابط ۱۲ و ۱۳ عدم قطعیت در پارامترهای حساس سریع‌تر از پارامترهای غیر حساس کاهش می‌یابد. زیرا فاصله اطمینان برای پارامترهای غیر حساس

- 1 United States Geological Survey (USGS)
- 2 McDonald
- 3 Harbaugh
- 4 Groundwater Modeling System
- 5 Hierarchical Data Format

جدول ۱. مقادیر صحرائی پارامترهای هیدرودینامیکی آبخوان اردبیل

Table 1. Hydrodynamic parameters of Ardabil aquifer based on field data

هدایت هیدرولیکی (m/day)		نام پارامتر
محدوده اولیه	مقدار اولیه	
۲۵-۲	۱۱	HK1
۲۵-۲	۱۶	HK2
۲۵-۲	۷	HK3
۲۵-۲	۸/۵	HK4
آبدهی ویژه		نام پارامتر
محدوده اولیه	مقدار اولیه	
۰/۰۱ - ۰/۲۲	۰/۰۶	Sy1
۰/۰۱ - ۰/۲۲	۰/۱۹	Sy2
۰/۰۱ - ۰/۲۲	۰/۱۶	Sy3
۰/۰۱ - ۰/۲۲	۰/۰۹	Sy4
۰/۰۱ - ۰/۲۲	۰/۱۷	Sy5


برنامه‌های ابر رایانشی^۱ انجام گرفته است. در این تحقیق، از نرم‌افزار MATLAB برای دسترسی به HDF فایل‌ها و متصل کردن الگوریتم SUFI-II با کد MODFLOW استفاده شده است.

معادله حاکم بر جریان آب زیرزمینی در محیط متخلخل که توسط MODFLOW به کار می‌رود به صورت رابطه‌ی ۱۵ است:

$$\frac{\partial}{\partial x} \left(K_{xx} \frac{\partial h}{\partial x} \right) + \frac{\partial}{\partial y} \left(K_{yy} \frac{\partial h}{\partial y} \right) + \frac{\partial}{\partial z} \left(K_z \frac{\partial h}{\partial z} \right) - W = S_s \frac{\partial h}{\partial t} \quad (15)$$


که K_{xx} ، K_{yy} و K_{zz} مقادیر هدایت هیدرولیکی در جهت‌های x ، y و z می‌باشند. h بار هیدرولیکی، W مقدار تغذیه (در این حالت W منفی است) یا تخلیه (در این حالت W مثبت است)، $S_s = S_y/b$ ضریب ذخیره ویژه است که در آن S_y ضریب آبدهی ویژه b ضخامت آبخوان است. همچنین t نشان دهنده زمان است. به طور کلی S_y ، K_{xx} ، K_{yy} و K_{zz} تابعی از مکان هستند و W می‌تواند تابعی از مکان و زمان باشد [۴۵]. با توجه به رابطه (۱۵) پارامترهای هدایت هیدرولیکی و آبدهی ویژه نقش مهمی در جریان آب زیرزمینی دارند؛ بنابراین در نظر گرفتن مقادیر دقیق‌تر و کالیبراسیون مدل بر این اساس می‌تواند دقت مدل را افزایش دهد.

با توجه به اینکه مدل ریاضی MODFLOW دارای پارامترهای متعددی است [۳۰]، در نظر گرفتن همه این پارامترها برای تحلیل عدم قطعیت ناممکن است. در این مطالعه، از بین پارامترهای تأثیرگذار، آبدهی ویژه و هدایت هیدرولیکی که در تحقیق حسان^۲ و همکاران [۱۸]، مؤثر تشخیص داده شده‌اند، انتخاب شده‌اند و سایر پارامترهای مدل مقادیر پیش‌فرضشان استفاده شده‌است. در این



شکل ۳. توزیع مکانی هدایت هیدرولیکی در آبخوان اردبیل (m/day)

Fig. 3. Spatial distribution of hydraulic conductivity in Ardabil aquifer (m/day)



شکل ۴. توزیع مکانی آبدهی ویژه در آبخوان اردبیل

Fig. 4. Spatial distribution of specific yield in Ardabil aquifer

$$\text{NRMSE1}(\%) = \frac{RMSE}{X_{obs,max} - X_{obs,min}} \times 100 \quad (16)$$

$$\text{NRMSE2}(\%) = \frac{RMSE}{\bar{X}_{obs}} \times 100 \quad (17)$$

$$\text{NRMSE3}(\%) = \sqrt{\frac{1}{n} \sum \left(\frac{X_{cal} - X_{obs}}{X_{obs}} \right)^2} \times 100 \quad (18)$$

$$\text{NRMSE4}(\%) = \sqrt{\frac{1}{n} \sum \left(\frac{X_{cal} - X_{obs}}{X_{cal}} \right)^2} \times 100 \quad (19)$$

۳- نتایج و بحث


مدل آب‌های زیرزمینی دشت اردبیل برای یک دوره یک‌ساله (از اکتبر ۲۰۰۷ تا سپتامبر ۲۰۰۸) و ۱۲ دوره تنش مطابق با ۱۲ ماه سال در شرایط ناماندگار، بر اساس مدل مفهومی تهیه شده است (شکل ۶). همان‌طور که در این شکل نشان داده شده است، سطح آب زیرزمینی سپتامبر ۲۰۰۷ که از درون‌یابی ۱۲ چاه مشاهده‌ای توزیع شده در محدوده مطالعاتی با استفاده از روش وزنی فاصله معکوس (IDW) به دست آمده، به عنوان سطح اولیه آب زیرزمینی در نظر

تحقیق، تقسیم‌بندی نواحی برای پارامترهای هدایت هیدرولیکی و آبدهی ویژه بر اساس داده‌های مشاهداتی صحرائی صورت گرفته که به ترتیب در شکل ۳ و شکل ۴ آمده است. در جدول ۱ نیز مقادیر اولیه به همراه محدوده اولیه فرض شده برای هر یک از پارامترها نشان داده شده است. مقادیر اولیه بر اساس درون‌یابی انجام شده برای کل دشت و به منظور یک پیش‌فرض برای شروع الگوریتم تعیین شده است. همچنین محدوده فرض شده برای هر یک از این پارامترها بر مبنای کمترین و بیشترین مقدار داده‌های اندازه‌گیری صحرائی مشخص شده است.

به دلیل گستردگی آبخوان دشت اردبیل، پارامترهای آبدهی ویژه و نیز هدایت هیدرولیکی این آبخوان را می‌توان به زون‌های مختلف تقسیم‌بندی کرد. تقسیم‌بندی این نواحی بر اساس مدل مفهومی، توسعه داده شده برای آبخوان و همچنین داده‌های صحرائی اندازه‌گیری شده و در نهایت با مقداری تغییر در درون‌یابی انجام شده برای کل دشت به صورت شکل ۳ و شکل ۴ به دست آمده است.


در روابط ۱۶ تا ۱۹، $X_{obs,max}$ و $X_{obs,min}$ به ترتیب ماکزیمم و مینیمم مقادیر مشاهداتی، \bar{X}_{obs} میانگین مقادیر مشاهداتی، X_{cal} ، n و X_{obs} به ترتیب مقادیر محاسباتی، مشاهداتی تراز آب زیرزمینی و تعداد مشاهدات است.

داده شده برای کالیبراسیون مدل استفاده شده است. همان‌طور که در بخش‌های قبل اشاره شد، شاخص d -factor به عنوان میانگین پهنای ناحیه $95PPU$ به انحراف معیار داده‌های مشاهده تعریف شده است. همچنین، شاخص p -factor به عنوان کیفیت نتایج یا تعداد داده‌های قرار گرفته در $95PPU$ تعریف شده است. با کاهش ضریب d -factor و افزایش ضریب p -factor، عدم قطعیت مدل کاهش می‌یابد و نتایج با داده‌های مشاهده یکسان می‌شود؛ بنابراین، باید بین این شاخص‌ها تعادل برقرار شود. در اولین مرحله از الگوریتم، این شاخص‌ها حداکثر هستند. سپس در پی پیشرفت الگوریتم $SUFI-II$ ، این مقادیر کوچک‌تر می‌شوند. پایان این فرآیند بر اساس معادله‌ی ۱۴ است که حداقل ضریب d -factor و حداکثر ضریب p -factor را پیدا می‌کند. با توجه به اهمیت یکسان هر یک از ضرایب، وزن ضرایب یکسان در نظر گرفته شده است ($W_1 = W_2$). در این مقاله، الگوریتم $SUFI-II$ به ازای ۱۰۰۰ نمونه شبیه‌سازی اجرا و در مجموع، ۹ پارامتر برای کالیبراسیون مدل در نظر گرفته شده است. مطابق



شکل ۵. نقشه شیب هیدرولیک آبخوان دشت اردبیل (بر حسب درصد) [۴۶]


Fig. 5. Hydraulic gradient map of Ardabil plain aquifer (in percent)



شکل ۶. مدل مفهومی آبخوان دشت اردبیل

Fig. 6. The conceptual model of Ardabil aquifer

گرفته شده است. با توجه به خطوط هم-پتانسیل به دست آمده از چاه‌های مشاهداتی برای این ماه، مرزهای ورودی، خروجی و بدون جریان تعیین گردیده است. در این مقاله، سعی شده است که مرزهای محدوده مطالعاتی بر مرزهای فیزیکی منطبق باشند. با توجه به شکل ۵ و شکل ۶ روند عمومی جریان از ارتفاعات به سمت خروجی دشت که در قسمت شمال غربی قرار دارد، است. بر اساس شکل ۶، بیشترین شیب هیدرولیکی در محلهای تغذیه و محلهایی که شیب توپوگرافی زیاد است دیده می‌شود. مقدار شیب هیدرولیکی در قسمت‌های میانی دشت به سمت خروجی کاهش می‌یابد. مقدار بیشینه شیب هیدرولیکی در قسمت ورودی جنوبی دشت حدود ۲ درصد و مقدار کمینه آن مربوط به حاشیه غربی دشت حدود ۴ در هزار است. جهت جریان آب زیرزمینی به صورت پیکان‌هایی در این شکل نشان داده شده است. نزدیک بودن خطوط هم-پتانسیل در قسمت‌های جنوبی و غربی نشانگر گرادیان هیدرولیکی زیاد در این قسمت‌ها است. به طور کلی بر اساس خطوط جریان ترسیم شده، جهت کلی جریان آب زیرزمینی به سمت شمال غربی دشت بوده که به عنوان مرز خروجی در نظر گرفته شده و تقریباً از بقیه مرزها جریان به سمت آبخوان جاری می‌شوند که به عنوان مرز ورودی تعیین شده است. همان‌طور که در شکل ۶ نشان داده شده است، ۱۲ چاه مشاهده‌ای با موقعیت‌های نشان




شکل ۹. سطح ایستایی مشاهداتی شبیه‌سازی شده با بازه اطمینان ۹۵ درصد برای چاه مشاهده‌ای شماره ۲

Fig. 9. Observation and simulation head with 95 percent confidence interval in No.2 observation well


در معادله‌ی ۲۰، $(d - factor)_{Mean}$ و $(p - factor)_{Mean}$ به ترتیب میانگین ضرایب $d - factor$ و $p - factor$ برای هر تکرار؛ $(d - factor)_{Best}$ و $(p - factor)_{Best}$ به ترتیب صفر و یک در نظر گرفته شده‌است و همچنین $(d - factor)_{Worst}$ و $(p - factor)_{Worst}$ نیز به ترتیب برابر حداکثر مقدار ضریب $d - factor$ در هر تکرار و صفر تعیین شده‌است.

در شکل ۸ تا شکل ۱۱ شرایط غیر ماندگار محدوده اطمینان ۹۵ درصد برای چاه‌های مشاهداتی شماره ۱، ۲، ۶ و ۸ به همراه داده‌های مشاهداتی آبخوان اردبیل به صورت سری زمانی برای طول دوره مدل‌سازی محاسبه شده‌است. همان‌طور که در این اشکال دیده می‌شود، به نظر می‌رسد که الگوریتم SUFI-II توانسته است بازه تغییرات مقادیر کالیبراسیون را به نحو مناسبی پیش‌بینی نماید.



شکل ۱۰. سطح ایستایی مشاهداتی شبیه‌سازی شده با بازه اطمینان ۹۵ درصد برای چاه مشاهده‌ای شماره ۶

Fig. 10. Observation and simulation head with 95 percent confidence interval in No.6 observation well




شکل ۷. منحنی جستجوی مینیمم تابع هدف f

Fig. 7. Minimum objective function f searching curve

شکل ۶، حداقل مقدار تابع f در تکرار پنجم به دست می‌آید که در این حالت مقادیر $d - factor$ و $p - factor$ به ترتیب ۱/۷۷ و ۶۲ درصد است. بر اساس نتایج به دست آمده از این اجرا، مجذور میانگین مربعات خطا در این حالت ۱/۸۶ متر به دست می‌آید.

$$\min f = \left(\frac{(d - factor)_{Mean} - (d - factor)_{Best}}{(d - factor)_{Worst} - (d - factor)_{Best}} \right) \times W_1 + \left(1 - \frac{(p - factor)_{Mean} - (p - factor)_{Best}}{(p - factor)_{Best} - (p - factor)_{Worst}} \right) \times W_2 \quad (20)$$

$$W_1 = W_2 = 0.5$$




شکل ۸. سطح ایستایی مشاهداتی شبیه‌سازی شده با بازه اطمینان ۹۵ درصد برای چاه مشاهده‌ای شماره ۱

Fig. 8. Observation and simulation head with 95 percent confidence interval in No.1 observation well

جدول ۲. مقادیر معیارهای عدم قطعیت حاصل از کالیبراسیون مدل برای ۱۲ چاه مشاهداتی

Table 2. Calibration results for 12 observation wells

شماره چاه مشاهداتی	d-factor	p-factor (درصد)
۱	۱/۵۴	۴۱
۲	۲/۸۸	۱۰۰
۴	۰/۳۹	۶۶
۵	۲/۶۲	۴۲
۶	۱/۱۳	۵۰
۷	۲/۲۰	۴۲
۸	۱/۶۵	۴۲
۹	۲/۸۹	۳۳
۱۲	۰/۷۵	۳۳
۱۵	۴/۴	۵۰
۱۷	۱/۸	۱۷
۱۸	۱/۲۶	۴۲



شکل ۱۱. سطح ایستایی مشاهداتی شبیه‌سازی شده با بازه اطمینان ۹۵ درصد برای چاه مشاهده‌ای شماره ۸

Fig. 11. Observation and simulation head with 95 percent confidence interval in No.8 observation well

در اغلب موارد مقادیر مشاهده شده در بازه مقادیر پیش‌بینی شده توسط مدل MODFLOW با مقادیر پارامترهای پیش‌بینی شده توسط الگوریتم SUFI-II قرار گرفته‌اند. همچنین مقادیر مربوط به معیارهای سنجش عدم قطعیت نیز در جدول ۲ آمده است. با توجه به مقادیر این جدول مقادیر d-factor نسبتاً زیاد است. همان‌طور که قبلاً نیز ذکر شد، عوامل زیادی از جمله خطای اندازه‌گیری، عدم قطعیت در داده‌های ورودی، عدم قطعیت در ساختار مدل مفهومی و غیره می‌تواند در بزرگ بودن این مقادیر تأثیرگذار باشد. از طرف دیگر الگوریتم SUFI-II تمامی منابع ایجاد کننده عدم قطعیت را یکجا لحاظ می‌کند و نتایج مدل دارای درجات بیشتری از عدم قطعیت


جدول ۳: مقادیر بهینه پارامترهای هیدرودینامیکی بعد از کالیبراسیون با الگوریتم SUFI-II

Table 3: Optimum values of Hydrodynamic parameters after calibration with SUFI-II algorithm

نام پارامتر	هدایت هیدرولیکی (m/day)	
	مقدار بهینه	محدوده نهایی
HK1	۴/۴۱	۳/۹۵ - ۴/۸۸
HK2	۱۴/۹۵	۱۴/۴۲ - ۱۵/۴۹
HK3	۷/۷۹	۶/۶۴ - ۸/۹۴
HK4	۱۵/۰۴	۱۴/۳۸ - ۱۵/۷۲
آبدهی ویژه		
نام پارامتر	مقدار بهینه	
	مقدار بهینه	محدوده نهایی
Sy1	۰/۱۱	۰/۱ - ۰/۱۳
Sy2	۰/۱۵	۰/۱۴ - ۰/۱۵
Sy3	۰/۱۲	۰/۱۱ - ۰/۱۳
Sy4	۰/۰۷	۰/۰۶ - ۰/۰۸
Sy5	۰/۲۲	۰/۲۲ - ۰/۲۳

می‌شود؛ بنابراین با توجه به کمبود داده‌های مشاهداتی، عدم اطمینان از داده‌های مشاهداتی اندازه‌گیری شده برای آبخوان اردبیل، مقادیر محاسبه شده برای شاخص‌های عدم قطعیت می‌تواند قابل قبول باشد. با توجه به شکل ۸، هر چند انحراف کمی در سطح ایستایی مشاهداتی و نیز بازه اطمینان ۹۵ درصد مدل SUFI-II مشاهده می‌شود، لکن با توجه به تجربیات اجرایی و مطالعاتی و ضعف داده‌های اندازه‌گیری موجود، دقت مدل در حد قابل قبولی ارزیابی می‌شود.

در مورد شکل ۹، نیز می‌توان با اطمینان گفت که مقادیر مشاهداتی توانسته‌اند در بازه اطمینان ۹۵ درصد پارامترهای تعیین شده توسط



شکل ۱۲: هدایت هیدرولیکی آبخوان دشت اردبیل بعد از کالیبراسیون با استفاده از الگوریتم SUFI-II (m/day)

Fig. 12: Hydraulic conductivity of Ardabil plain aquifer after calibration with SUFI-II (m/day)

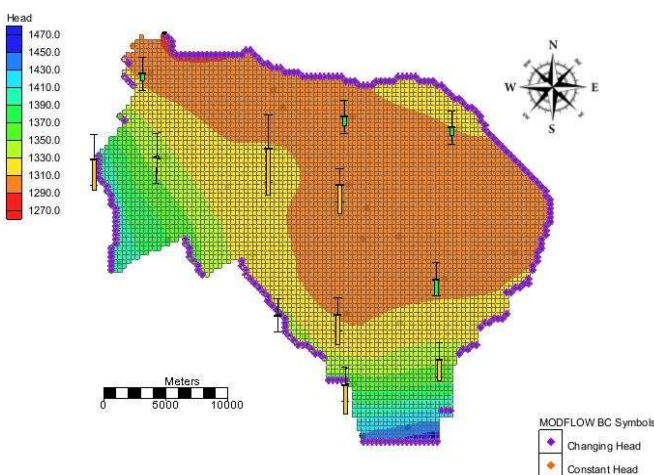
جدول ۴. مقدار اولیه محدوده اولیه و مقدار نهایی پارامترها در استفاده از بسته PEST

Table 4. Initial value, initial range and the final value of parameters in using the PEST package

هدایت هیدرولیکی (m/day)			نام پارامتر
مقدار نهایی	محدوده اولیه	مقدار اولیه	
۲/۲۶	۲۵-۲	۱۱	HK1
۲	۲۵-۲	۱۶	HK2
۲۵	۲۵-۲	۷	HK3
۴/۳۱	۲۵-۲	۸/۵	HK4
آبدهی ویژه			
مقدار نهایی	محدوده اولیه	مقدار اولیه	
۰/۰۹	۰/۰۱ - ۰/۲۲	۰/۰۶	Sy1
۰/۲۱	۰/۰۱ - ۰/۲۲	۰/۱۹	Sy2
۰/۰۲	۰/۰۱ - ۰/۲۲	۰/۱۶	Sy3
۰/۰۰۹	۰/۰۱ - ۰/۲۲	۰/۰۹	Sy4
۰/۱۴	۰/۰۱ - ۰/۲۲	۰/۱۷	Sy5


ویژه در محدوده‌ی آبخوان مطابق شکل ۱۲ و شکل ۱۳ می‌شود. بر اساس مشاهدات میدانی بیشتر قسمت‌های دشت اردبیل را خاک‌های ماسه‌ای متوسط تا درشت‌دانه تشکیل داده است همین امر باعث شده تا مقدار متوسط آبدهی ویژه عدد بالایی به دست آید. همچنین در قسمت جنوبی با توجه به اینکه بیشتر خاک ماسه‌ای و شنی وجود دارد، این مقادیر قابل توجه است. از طرفی در قسمت‌ها غربی و جنوب شرقی دشت بیشتر خاک‌های رسی وجود دارد که باعث کمتر شدن این ضریب شده‌است.

شکل ۱۴ و شکل ۱۵، به ترتیب تراز آب زیرزمینی آبخوان دشت اردبیل را بعد از کالیبراسیون با استفاده از الگوریتم SUFI-II برای



شکل ۱۵. تراز آب زیرزمینی آبخوان دشت اردبیل بعد از کالیبراسیون با استفاده از الگوریتم SUFI-II (خردادماه ۸۷)

Fig. 15. Groundwater level of Ardabil plain aquifer after calibration with SUFI-II algorithm (June 2008)




شکل ۱۳. آبدهی ویژه آبخوان دشت اردبیل بعد از کالیبراسیون با الگوریتم SUFI-II

Fig. 13. Specific yield of Ardabil plain aquifer after calibration with SUFI-II algorithm

مدل SUFI-II قرار بگیرند.


در مورد سطوح ایستایی چاه‌های مشاهداتی شماره ۶ و ۸ که به ترتیب در شکل ۱۰ و شکل ۱۱ نشان داده شده‌است، می‌توان با دقت نسبتاً خوبی قرارگیری داده‌های مشاهداتی در بازه محاسب شده توسط الگوریتم SUFI-II را مشاهده کرد.

بعد از کالیبراسیون مدل آب زیرزمینی آبخوان دشت اردبیل با استفاده از الگوریتم SUFI-II، مقادیر بهینه و بازه نهایی هر یک از پارامترها مطابق با جدول ۳ به دست می‌آید. بر اساس مقادیر بهینه‌ی پارامترها، توزیع پارامترهای هدایت هیدرولیکی و آبدهی



شکل ۱۴. تراز آب زیرزمینی آبخوان دشت اردبیل بعد از کالیبراسیون با استفاده از الگوریتم SUFI-II (مهرماه ۸۶)

Fig. 14. Groundwater level of Ardabil plain aquifer after calibration with SUFI-II algorithm (October 2007)



شکل ۱۶. خطای حاصل در تکرارهای مختلف حاصل از اجرای PEST برای کالیبراسیون مدل آب زیرزمینی

Fig. 16. Error in different iterations of PEST implementation for groundwater model calibration

آبدهی ویژه به صورت جدول ۴ انتخاب می‌شود. در مقایسه روش PEST با روش SUFI-II، همان‌طور که در قسمت‌های قبل محاسبه شد. روش PEST مجذور میانگین مربعات خطای (RMSE) بیشتری را نتیجه نسبت به روش SUFI-II نتیجه داده است که نشان دهنده‌ی عملکرد بهتر الگوریتم SUFI-II نسبت به این روش است. همچنین، برای مقایسه دو الگوریتم و ارزیابی عملکرد هر یک، از روابط مختلف موجود برای مجذور میانگین مربعات خطا نرمال شده استفاده شده که نتایج حاصل در جدول ۵ بر حسب درصد آورده شده است. از مهم‌ترین تفاوت‌های الگوریتم SUFI-II با دیگر روش‌ها نظیر PEST و روش‌های مختلف بهینه‌سازی این است که علاوه بر ارائه مقادیر بهینه پارامترها، این مقادیر را به صورت بازه‌ای نیز در انتها محاسبه می‌کند. در واقع این الگوریتم از جمله روش‌هایی است که کالیبراسیون و تحلیل عدم قطعیت را به صورت هم‌زمان انجام می‌دهد. همچنین از دیگر ویژگی‌های این الگوریتم می‌توان به سرعت همگرایی بالای این روش اشاره نمود.

۴- نتیجه‌گیری

در این تحقیق، به منظور تحلیل عدم قطعیت مدل عددی آبخوان اردبیل از مدل شبیه‌سازی آب زیرزمینی و الگوریتم SUFI-II استفاده شده است. مدل MODFLOW استفاده شده در این تحقیق به منظور شبیه‌سازی آب زیرزمینی، با استفاده از یک روش بر مبنای پایگاه داده سلسله مراتبی و توسعه داده شده در MATLAB به الگوریتم SUFI-II متصل شده است. این الگوریتم از جمله روش‌هایی است که کالیبراسیون و تحلیل عدم قطعیت را به طور هم‌زمان انجام می‌دهد. مزیت این روش، نسبت به دیگر روش‌ها در تعداد تکرار کم شبیه‌سازی

مهرماه ۸۶ و خردادماه ۸۷ نشان می‌دهد. همان‌طور که در این شکل نشان داده شده است، ۱۲ چاه مشاهداتی که داده‌های ثبت شده‌ی منظم‌تری داشته‌اند، به عنوان نقاط مشاهداتی انتخاب شده‌اند. میزان خطای بین مقادیر مشاهداتی و محاسباتی به وسیله میله‌های رنگی در این شکل‌ها نشان داده شده است. خطاهای کمتر از ۱ متر به رنگ سبز و خطاهای بین ۱ تا ۲ متر به رنگ زرد در میله‌ها نشان داده شده‌اند. خطای حاصل در تکرارهای مختلف حاصل از اجرای PEST در شکل ۱۶ نشان داده شده است. برای استفاده از این روش نیاز به مقدار اولیه و محدوده اولیه است که این مقادیر به شکلی که در جدول ۴ آمده، استفاده شده است. با توجه به نتایج به دست آمده از اجرای مدل و مطابق شکل ۱۶، فرآیند این الگوریتم در تکرار هشتم متوقف شده که در این حالت مجذور میانگین مربعات خطا ۳/۳۷ متر به دست می‌آید. در نهایت، مقادیر نهایی برای پارامترهای هدایت هیدرولیکی و

جدول ۵. مقایسه مقادیر مجذور میانگین مربعات خطا نرمال شده برای دو الگوریتم SUFI-II و PEST (بر حسب درصد)

Fig. 5. Comparison of normalized root mean squared error values for SUFI-II and PEST algorithms (Percent)

PEST	SUFI-II	
۳/۳۱	۱/۸۲	NRMSE1
۰/۲۵	۰/۱۴	NRMSE2
۰/۲۴	۰/۱۳	NRMSE3
۰/۲۵	۰/۱۴	NRMSE4

- abstraction under recharge uncertainty, *Water Resources Management*, 29(10) (2015) 3681–3695.
- [5] Y. Yihdego, G. Reta, R. Becht, Hydrological analysis as a technical tool to support strategic and economic development: A case study of Lake Navaisha, Kenya, *Water and Environment Journal*, 30(1–2) (2016) 40–48.
- [6] A. Kamali, M.H. Niksokhan, Multi-objective optimization for sustainable groundwater management by developing of coupled quantity-quality simulation-optimization model, *Journal of Hydroinformatics*, 19(6) (2017) 973–992.
- [7] J. Carrera, S.P. Neuman, Estimation of aquifer parameters under transient and steady state conditions: 2. uniqueness, stability, and solution algorithms, *Water Resources Research*, 22(2) (1986) 211–227.
- [8] Z. Dai, J. Samper, Inverse problem of multicomponent reactive chemical transport in porous media: Formulation and applications, *Water Resources Research*, 40(7) (2004).
- [9] Z. Dai, J. Samper, Inverse modeling of water flow and multicomponent reactive transport in coastal aquifer systems, *Journal of Hydrology*, 327(3–4) (2006) 447–461.
- [10] H. Shang, W. Wang, Z. Dai, L. Duan, Y. Zhao, J. Zhang, An ecology-oriented exploitation mode of groundwater resources in the northern Tianshan Mountains, China, *Journal of Hydrology*, 543 (2016) 386–394.
- [11] P. Droogers, H.R. Salemi, A.R. Mamanpoush, Exploring basin-scale salinity problems using a simplified water accounting model: the example of Zayandeh Rud basin, Iran, *Irrigation and Drainage*, 50(4) (2001) 335–348.
- [12] J. Doherty, L. Brebber, P. Whyte, PEST: Model-Independent Parameter Estimation. Watermark Computing, Corinda, Australia, 122 (1994) 1-336.
- [13] E. Poeter, M. Hill, Documentation of UCODE; a computer code for universal inverse modeling, DIANE Publishing, 1998.
- [14] M. Zambrano-Bigiarini, R. Rojas, A model-independent Particle Swarm Optimisation software for model calibration, *Environmental Modelling & Software*, 43 (2013) 5–25.
- است. بر اساس نتایج حاصل از اجرای الگوریتم SUFI-II، مقادیر p-factor و d-factor به ترتیب ۶۲ درصد و ۱/۷۷ محاسبه شده که مقدار ۱/۸۶ متر را نیز برای مجذور میانگین مربعات خطا نتیجه داده است. همچنین مجذور میانگین مربعات خطا در حالت اجرای مدل با استفاده از PEST، ۳/۳۷ متر به دست آمده است. در این مطالعه، هر چند تا حدودی d-factor مقدار بالایی محاسبه شده است که مقدار بزرگ بودن عدم قطعیت و خطا در ساختار مدل را نشان می‌دهد، لکن با توجه به وسعت و پیچیدگی آبخوان و کمبود داده‌ها نتایج قابل قبول به نظر می‌رسد. همچنین منابع عدم قطعیت فراوانی در پارامترهای ورودی مدل‌سازی وجود دارند که به تفکیک بررسی نشده‌اند. از طرفی استفاده از این الگوریتم سرعت همگرایی خوبی را نشان داده است. در نهایت با مقایسه الگوریتم SUFI-II با PEST می‌توان گفت که این الگوریتم عملکرد مناسبی در کالیبراسیون مدل آبخوان اردبیل داشته است.
- تشکر و قدردانی**
- این مقاله، مستخرج از طرح تحقیقاتی "کالیبراسیون خودکار مدل شبیه‌سازی آب‌های زیرزمینی (MODFLOW) با استفاده از الگوریتم غیرخطی SUFI-II" به کارفرمایی معاونت پژوهشی دانشگاه محقق اردبیلی است که بدین‌وسیله از حمایت‌های مادی و معنوی این نهاد سپاسگزاری به عمل می‌آید.
- ۵- مراجع**
- [1] S.V. Sarath Prasanth, N.S. Magesh, K.V. Jitheshlal, N. Chandrasekar, K. Gangadhar, Evaluation of groundwater quality and its suitability for drinking and agricultural use in the coastal stretch of Alappuzha District, Kerala, India, *Applied Water Science*, 2(3) (2012) 165–175.
- [2] Y. Wada, L.P.H. van Beek, C.M. van Kempen, J.W.T.M. Reckman, S. Vasak, M.F. P. Bierkens, Global depletion of groundwater resources, *Geophysical Research Letters*, 37(20) (2010).
- [3] A. Singh, Groundwater resources management through the applications of simulation modeling: A review, *Science of The Total Environment*, 499 (2014) 414–423.
- [4] S. Zekri, C. Triki, A. Al-Maktoumi, M.R. Bazargan-Lari, An optimization-simulation approach for groundwater

- using multimodel and multimethod, *Water Resources Research*, 45(9) (2009).
- [25] H. Yoon, D.B. Hart, S.A. McKenna, Parameter estimation and predictive uncertainty in stochastic inverse modeling of groundwater flow: Comparing null-space Monte Carlo and multiple starting point methods, *Water Resources Research*, 49(1) (2013) 536–553.
- [26] J.-C. Wu, L. Lu, T. Tang, Bayesian analysis for uncertainty and risk in a groundwater numerical model's predictions, *Human and Ecological Risk Assessment: An International Journal*, 17(6) (2011) 1310–1331.
- [27] M. Sadat Kahe, S. Javadi, A. Roozbahani, Uncertainty assesment of hydraulic conductivity parameter in MODFLOW model using monte carlo and RPEM method (case study: AliAbad plain of Qom), *Iran-Water Resources Research*, 14(2) (2018) 35–53. (In Persian)
- [28] K. Beven, How far can we go in distributed hydrological modelling?, *Hydrology and Earth System Sciences*, 5(1) (2001) 1–12.
- [29] K. Beven, A. Binley, The future of distributed models: Model calibration and uncertainty prediction, *Hydrological Processes*, 6(3) (1992) 279–298.
- [30] J. B. Jensen, Parameter and uncertainty estimation in groundwater modelling, Aalborg University, (2003).
- [31] R. Rojas, S. Kahunde, L. Peeters, O. Batelaan, L. Feyen, A. Dassargues, Application of a multimodel approach to account for conceptual model and scenario uncertainties in groundwater modelling, *Journal of Hydrology*, 394(3–4) (2010) 416–435.
- [32] A. Singh, S. Mishra, G. Ruskauff, Model averaging techniques for quantifying conceptual model uncertainty, *Ground Water*, 48(5) (2010) 701–715.
- [33] A. Inam, J. Adamowski, S. Prasher, R. Albano, Parameter estimation and uncertainty analysis of the Spatial Agro Hydro Salinity Model (SAHYSMOD) in the semi-arid climate of Rechna Doab, Pakistan, *Environmental Modelling & Software*, 94 (2017) 186–211.
- [34] R.S. Blasone, D. Rosbjerg, H. Madsen, Parameter estimation and uncertainty assessment in hydrological modelling, Technical University of Denmark, (2007).
- [35] B.L. Barnhart, K.A. Sawicz, D.L. Ficklin, G.W. [15] H. Delottier, A. Pryet, A. Dupuy, Why should practitioners be concerned about predictive uncertainty of groundwater management models?, *Water Resources Management*, 31(1) (2017) 61–73.
- [16] J. Wu, X. Zeng, Review of the uncertainty analysis of groundwater numerical simulation, *Chinese Science Bulletin*, 58(25) (2013) 3044–3052.
- [17] K.C. Abbaspour, J. Yang, I. Maximov, R. Siber, K. Bogner, J. Mieleitner, J. Zobrist, R. Srinivasan, Modelling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT, *Journal of Hydrology*, 333(2–4) (2007) 413–430.
- [18] A.E. Hassan, H.M. Bekhit, J.B. Chapman, Uncertainty assesment of a stochastic groundwater flow model using GLUE analysis, *Journal of Hydrology*, 362(1) (2008) 89–109.
- [19] R. Rojas, L. Feyen, A. Dassargues, Conceptual model uncertainty in groundwater modeling: Combining generalized likelihood uncertainty estimation and Bayesian model averaging, *Water Resources Research*, 44(12) (2008).
- [20] A.E. Hassan, H.M. Bekhit, J.B. Chapman, Using Markov Chain Monte Carlo to quantify parameter uncertainty and its effect on predictions of a groundwater flow model, *Environmental Modelling & Software*, 24(6) (2009) 749–763.
- [21] R.-S. Blasone, J.A. Vrugt, H. Madsen, D. Rosbjerg, B.A. Robinson, G.A. Zyvoloski, Generalized likelihood uncertainty estimation (GLUE) using adaptive Markov Chain Monte Carlo sampling, *Advances in Water Resources*, 31 (2008) 630–648.
- [22] J. Fu, J. Jaime Gómez-Hernández, Uncertainty assesment and data worth in groundwater flow and mass transport modeling using a blocking Markov chain Monte Carlo method, *Journal of Hydrology*, 364(3–4) (2009) 328–341.
- [23] N. Sepúlveda, J. Doherty, Uncertainty analysis of a groundwater flow model in east-central Florida, *Groundwater*, 53(3) (2015) 464–474.
- [24] X. Li, F.T.-C. Tsai, Bayesian model averaging for groundwater head prediction and uncertainty analysis

- using a sequential uncertainty fitting procedure, *Vadose Zone Journal*, 3(4) (2004) 1340-1352.
- [41] K.C. Abbaspour, M.T. van Genuchten, R. Schulin, E. Schläppi, A sequential uncertainty domain inverse procedure for estimating subsurface flow and transport parameters, *Water Resources Research*, 33(8) (1997) 1879–1892.
- [42] K.C. Abbaspour, *Swat-Cup2: SWAT Calibration and Uncertainty Programs Manual Version 2*, Duebendorf, Switzerland, (2008).
- [43] W. H. Press, B. P. Flannery, S. A. Teukolsky, W. T. Vetterling, *Numerical Recipe, The Art of Scientific Computation*, 2nd edition. Cambridge University Press, Cambridge, UK, (2007).
- [44] M.G. McDonald, A.W. Harbaugh, A modular three-dimensional finite-difference ground-water flow model, VA: US Geological Survey, 6 (1988).
- [45] D.K. Todd, L.W. Mays, *Groundwater Hydrology*, Third edition, John Wiley & Sons, Inc. New York, (2005).
- [46] M. Kord, Numerical modeling of the Ardabil plain aquifer and its management using optimization of Groundwater extraction. *Natural Science*, University of Tabriz, (2014). (In Persian)
- Whittaker, MOESHA: A genetic algorithm for automatic calibration and estimation of parameter uncertainty and sensitivity of hydrologic models, *Transactions of the ASABE*, 60(4) (2017) 1259–1269.
- [36] S.J. Mousavi, K.C. Abbaspour, B. Kamali, M. Amini, H. Yang, Uncertainty-based automatic calibration of HEC-HMS model using sequential uncertainty fitting approach, *Journal of Hydroinformatics*, 14(2) (2012) 286-309.
- [37] Y. Cao, J. Zhang, M. Yang, X. Lei, B. Guo, L. Yang, Z. Zeng, J. Qu, Application of SWAT model with CMADS data to estimate hydrological elements and parameter uncertainty based on SUFI-2 algorithm in the Lijiang river basin, China, *Water*, 10(6) (2018) 742.
- [38] J. Yang, P. Reichert, K.C. Abbaspour, J. Xia, H. Yang, Comparing uncertainty analysis techniques for a SWAT application to the Chaohe Basin in China, *Journal of Hydrology*, 358(1–2) (2008) 1–23.
- [39] B. Kamali, K. Abbaspour, A. Lehmann, B. Wehrli, H. Yang, Uncertainty-based auto-calibration for crop yield – the EPIC+ procedure for a case study in Sub-Saharan Africa, *European Journal of Agronomy*, 93 (2018) 57–72.
- [40] K.C. Abbaspour, A. Johnson, M.T. van Genuchten, Estimating uncertain flow and transport parameters

برای ارجاع به این مقاله از عبارت زیر استفاده کنید:

F. Masoumi, S. Najjar-Ghabe, A. Safarzadeh. Automatic Calibration of Groundwater Simulation Model (MODFLOW) by Indeterministic SUFI-II Algorithm, *Amirkabir J. Civil Eng.*, 53(4) (2021): 1507-1524.

DOI: [10.22060/ceej.2019.16990.6426](https://doi.org/10.22060/ceej.2019.16990.6426)



