

# ارائه مدل هوشمند تعیین رفتار تغییرات سطح آب زیرزمینی با لحاظ نمودن وضعیت دینامیکی سیستم آبخوان

رضا مکnoon<sup>۱</sup>

تقی عبادی<sup>۲</sup>

محمود محمد رضایپور طبری<sup>۱</sup>

(دریافت ۸۷/۶/۳۱ پذیرش ۸۹/۶/۱)

## چکیده

با توجه به خشکسالی‌های اخیر و افزایش میزان تراکنش، استفاده از منابع آب زیرزمینی در بیشتر مناطق کشور در اولویت قرار گرفته است. در این راستا برداشت‌های بی‌رویه منجر به بروز مشکلاتی برای آبخوان داشت‌ها شده است. با توجه به اینکه به منظور اعمال محدودیت‌های برداشت در اغلب مدل‌های مدیریت منابع آب، لازم است آبخوان به صورت پیوسته و زمان‌مند شبیه‌سازی شود و از طرفی استفاده از این مدل‌ها در فرایند بهینه‌سازی منجر به افزایش زمان اجرا می‌شود، لازم است مدل هوشمندی جایگزین مدل عددی شبیه‌سازی آبخوان شود. در این تحقیق با توجه به خصوصیات هیدرولوژیکی آبخوان و مقادیر اندازه‌گیری شده برای پارامترهای کمی آبخوان، مدل کمی عددی آبخوان تهیه شده و سپس با استفاده از نتایج آن و به کارگیری مدل شبیه‌ساز شبکه عصبی دینامیکی، تغییرات تراز سطح آب زیرزمینی برای افق برنامه‌ریزی به صورت معادلاتی ارائه گردید. میزان کل تغذیه و تخلیه آبخوان و تراز سطح آب زیرزمینی در گام زمانی قبل به عنوان پارامترهای ورودی و تراز سطح آب زیرزمینی در انتهای دوره شبیه‌سازی به عنوان پارامتر خروجی در مدل شبیه‌ساز استفاده شد. به منظور تدوین مدل شبیه‌ساز، چهار مرحله در نظر گرفته شد که عبارت‌اند از تدوین مدل شبیه‌سازی آبخوان و واسنجی نمودن آن، تولید مجموعه داده‌های ورودی- خروجی برای آموزش مدل شبیه‌ساز، آموزش مدل شبیه‌ساز برای ساختارهای گوناگون، صحبت‌سنگی و استخراج مدل شبیه‌ساز برتر برای ارتباط با مدل بهینه‌سازی. نتایج ارائه شده نشان‌دهنده کارایی مدل پیشنهادی به منظور شبیه‌سازی و پیش‌بینی رفتار تغییرات تراز سطح آب زیرزمینی در مقایسه با مدل‌های شبکه عصبی استاتیکی بود.

**واژه‌های کلیدی:** شبیه‌سازی، آبخوان، شبکه‌های عصبی دینامیکی و استاتیکی، مدل‌سازی، پیش‌بینی

## Development of a Smart Model for Groundwater Level Prediction Based on Aquifer Dynamic Conditions

Mahmoud Mohammad Rezapour Tabari<sup>1</sup>

Taghi Ebadi<sup>2</sup>

Reza Maknoon<sup>3</sup>

(Received Sep. 22, 2009 Accepted Aug. 23, 2010)

### Abstract

In recent years, drought and demand growth in most parts of the county have caused a dramatic increase in using groundwater for water supply purposes. Besides, unplanned excessive discharges from aquifers have led to aquifer degradation. In most integrated water resources management models, groundwater simulation is used for taking into account discharge constraints, however, the most cases the optimal solution is not achievable. Hence, artificial neural network models may be replaced by groundwater numerical simulation models. In this paper, a methodology based on dynamic artificial neural networks (DANN) is developed for simulating groundwater table. Karaj aquifer is used as the case study and its groundwater numerical model (PMWIN) is calibrated using such measured groundwater characteristics as hydraulic conductivity and specific storage. The results of the numerical model are presented to DANN for training. In the proposed procedure, the total recharge, discharge, and groundwater level in previous time intervals are used as the inputs to the DANN model. The model output is the groundwater level at the end of the time interval. In this study, the development of the model is accomplished in four steps that consist of developing the aquifer simulation model and its calibration, producing the input-output data set for DANN training, training the DANN model for various structures, and selecting the best structure for use in the optimization model. The result shows that the proposed DANN model is more efficient in simulating groundwater level fluctuations than the static artificial neural network (SANN) models.

**Keywords:** Simulation, Aquifer, Static and Dynamic Artificial Neural Networks, Modeling, Forecast.

1. Assist. Prof. of Civil Eng., Dept. of Eng., Shahrekord University, (+98 21) 55391429 (Corresponding Author) mrtabari@eng.sku.ac.ir
2. Assist. Prof., Dept. of Civil and Environmental Eng., Amirkabir University of Tech., Tehran

۱- استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه شهرکرد (نویسنده مسئول) (۰۲۱) ۵۵۴۹۱۴۲۹  
۲- استادیار دانشکده عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر، تهران  
mrtabari@eng.sku.ac.ir

## ۱- مقدمه

شبکه‌های عصبی مصنوعی استفاده نمودند. در تحقیق مذکور، متغیرهای ورودی مدل شبیه‌سازی شامل بارش ۵ ماه قبل، درجه حرارت، جریان پایه رودخانه و تراز سطح آب در ماه جاری بوده است. نتایج نشان می‌دهد که مدل لونبرگ- مارگارت از دقت بالاتری در پیش‌بینی برخوردار است [۷].

چاندرامولی و همکاران<sup>۹</sup> در سال ۲۰۰۷ معیاری را جهت تعیین میزان تکرار برای آموزش شبکه‌های عصبی انتشار به عقب<sup>۱۰</sup> ارائه دادند. این مطالعه نشان می‌دهد که آموزش زیاد و یا کمتر از مقدار می‌تواند منجر به عبور از مقدار مناسب و یا نرسیدن به جواب مطلوب برای تعیین ارتباط بین داده‌های ورودی و خروجی شود [۸].

کارآموز و همکاران در سال ۲۰۰۷ مدل بهره‌برداری تلفیقی را با توجه به محدودیتهای کمی توسعه دادند. در این تحقیق معادلات پاسخ آبخوان در قالب مدل شبیه‌سازی شبکه عصبی تدوین گردید و در مدل بهینه‌سازی مورد استفاده قرار گرفت [۹].

با توجه به سوابق ارائه شده می‌توان دریافت که شبکه‌های عصبی مصنوعی تا کنون به طور گسترده‌ای در حل مسائل مختلف از جمله شبیه‌سازی و پیش‌بینی‌های رفتار آبخوان مورد مطالعه قرار گرفته و به کار برده شده‌اند. شبکه‌های عصبی، گزینه‌ای کارا در مدل‌سازی متغیرهای کمی و کیفی منابع آب به شمار می‌رود [۱۰-۱۶].

با توجه به اینکه در مدل مدیریتی بهره‌برداری تلفیقی از منابع آبهای سطحی و زیرزمینی، نیاز به مدل‌سازی آبخوان داشت و اطلاع از نحوه تغییرات تراز سطح آب زیرزمینی برای دوره زمانی مشخص است، برای برقراری ارتباط بین دو مدل بهینه‌سازی و شبیه‌سازی (مدل ریاضی آبخوان) لازم است از شبیه‌ساز مناسب استفاده شود.

در این تحقیق با توجه به دینامیک بودن سیستم جریان آب زیرزمینی، از مدل‌های شبکه عصبی دینامیکی به دلیل کارایی و قابلیت بالای آن در مدل‌سازی و شبیه‌سازی سیستم‌های غیرخطی پیچیده مبتنی بر زمان استفاده شد. نتایج شبیه‌سازی با استفاده از مدل دینامیکی در مقایسه با مدل‌های استاتیکی نشان داد که مدل دینامیکی پیشنهادی در ارائه رفتار سیستم آب زیرزمینی در بلندمدت، قابلیت بالای دارد.

## ۲- مواد و روشها

### ۲-۱- منطقه مورد مطالعه

تهیه مدل شبیه‌سازی آبخوان برای مطالعه وضعیت آبهای زیرزمینی یک منطقه، این امکان را فراهم می‌سازد که رفتار آبخوان مورد نظر

مفهوم شبکه‌های عصبی برای نخستین بار در سال ۱۹۱۱ توسط سگال<sup>۱</sup> بیان گردید [۱]. راجرز<sup>۲</sup> و دوولا<sup>۳</sup> در سال ۱۹۹۴ از مدل شبیه‌سازی شبکه عصبی در مدل بهینه‌سازی احیای آبخوان استفاده نمودند [۲]. کیم<sup>۴</sup> در سال ۱۹۹۸ شبکه‌های عصبی برگشتی با تأخیر زمانی را به منظور پیش‌بینی ارائه داد. در این مدل تأخیرهای زمانی تطبیقی به صورت اطلاعات ورودی برای شبکه تعریف می‌گردد. نتایج شبیه‌سازی نشان می‌دهد که این شبکه، وابستگی‌های زمانی و پیش‌بینی نسبت به سایر شبکه‌های پیشنهادی همچون شبکه‌های عصبی چند برگشتی و شبکه عصبی با تأخیر زمانی را با دقت بالای در نظر می‌گیرد [۳].

یزدی زاده و خراسانی در سال ۲۰۰۲ چهار ساختار کلی به منظور شناسایی سیستم‌های غیرخطی ارائه دادند. در تحقیق مذکور با استفاده از اطلاعات موجود برای متغیرهای ورودی و خروجی، ساختار دینامیکی نرون‌ها برای شناسایی روابط غیرخطی بین آنها پیشنهاد گردید. نتایج شبیه‌سازی با استفاده از این ساختار، نشان دهنده کارایی مؤثر شبکه‌های عصبی دینامیکی در شناسایی سیستم‌های غیرخطی است [۴].

شیجیدی<sup>۵</sup> و گارسیا<sup>۶</sup> در سال ۲۰۰۳ از مدل شبیه‌سازی شبکه‌های عصبی برای تخمین پارامترهای معادله آب زیرزمینی استفاده نمودند. آنها با توجه به رابطه بین ضریب انتقال و تراز سطح آب زیرزمینی، ساختار مدل شبیه‌سازی شبکه عصبی را با توجه به داده‌های اندازه‌گیری شده ضریب انتقال و تراز سطح آب زیرزمینی تعیین کرده و سپس با استفاده از مدل آموزش داده شده، مقادیر پارامتر ضریب انتقال برای سایر نقاطی که داده موجود نبود را محاسبه کردند [۵]. کوپولا و همکاران<sup>۷</sup> در سال ۲۰۰۳ از مدل شبیه‌سازی شبکه عصبی برای پیش‌بینی تراز سطح آب زیرزمینی استفاده نمودند. در این مدل، ورودی‌ها شامل تراز سطح آب در ابتدای دوره، میزان پمپاژ از هفت چاه در حال بهره‌برداری، بارش، درجه حرارت، نقطه شبنم و طول گام زمانی و خروجی عبارت است از تراز سطح آب در انتهای دوره زمانی. نتایج این مدل شبیه‌سازی نشان می‌دهد که مدل شبکه عصبی با دقت بالای نسبت به مدل‌های عددی آب زیرزمینی می‌تواند تراز سطح آب را برای افق بلند مدت پیش‌بینی نماید [۶]. دالیاکوپولوس و همکاران<sup>۸</sup> در سال ۲۰۰۵ برای پیش‌بینی تراز سطح آب زیرزمینی از ساختارهای مختلف

<sup>1</sup> Segal

<sup>2</sup> Rogers

<sup>3</sup> Dowla

<sup>4</sup> Kim

<sup>5</sup> Shigidi

<sup>6</sup> Garcia

<sup>7</sup> Coppola et al.

<sup>8</sup> Daliakopoulos et al.

<sup>9</sup> Chandramouli et al.

<sup>10</sup> Back-Propagation ANNs

آبخوان را انجام داد، تعداد سلول‌های حاوی آبخوان دشت کرج برابر با ۶۴۳ با ابعاد ۱ کیلومتر در ۱ کیلومتر است. به منظور افزایش دقیق در پیش‌بینی تغییرات تراز سطح آب زیرزمینی آبخوان، دشت به شش منطقه تقسیم شد. با توجه به محدوده شبکه‌بندی شده و با استفاده از خصوصیات هیدرودینامیکی آبخوان و اطلاعات هیدرولوژیکی منطقه اقدام به واسنجی و صحت‌سنجی مدل شبیه‌سازی گردید (شکل ۲).

فرایند کالبیراسیون مدل برای تعیین دقیق ضریب انتقال T و ضریب آبدی ویژه  $S_y$  از اهمیت ویژه‌ای برخوردار است. در این مطالعه زمان اجرای مدل برای کالبیراسیون مدل در شرایط پایدار و ناپایدار به ترتیب ۱ ماه (۳۰ روز) و ۶ ماه (۱۸۰ روز) در نظر گرفته شد. در شرایط ناپایدار، دوره شبیه‌سازی به شش گام زمانی با طول ۳۰ روز تقسیم می‌گردد تا سطح آب در پایان هر بازه زمانی (ماه) مشخص شود. برای صحت‌سنجی مدل کالبیره شد، آماربرداری و مشخص بودن مقادیر تخلیه و تغذیه آبخوان برای یک دوره زمانی، قابل قبول که حتی الامکان تغییرات بلندمدت ورودی و خروجی را نشان می‌دهد، ضروری است. تغییر پارامترها در زمان واسنجی، منطقه به منطقه و یا حتی سلول به سلول انجام می‌شود. برای نشان دادن نتایج صحت‌سنجی مدل از ترازهای سطح آب مشاهداتی و محاسباتی دشت استفاده شد.

بر اساس آمار و اطلاعات موجود، شبیه‌سازی شده و با استفاده از آن در صورت اعمال هر گونه تغییر در شرایط تخلیه، تغذیه و شرایط مرزی، وضعیت آینده آبخوان در هر نقطه و هر زمان تعیین شود. در این تحقیق با توجه به وضعیت بحرانی آبخوان دشت کرج به دلیل برداشت بیش از ظرفیت ذخایر زیرزمینی که منجر به افت تصاعدی در تراز سطح آب زیرزمینی شده است، این محدوده به منظور بررسی رفتار آبخوان و ارائه مدل دینامیکی برای آن در نظر گرفته شد (شکل ۱).

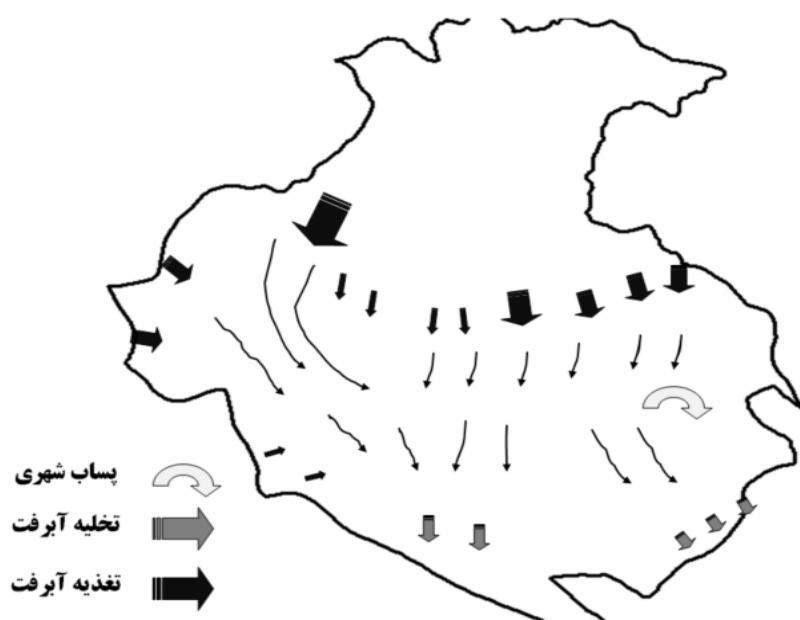
در این مطالعه به منظور تدوین مدل شبیه‌ساز، مراحل زیر مورد توجه قرار گرفت:

- ۱- تدوین مدل شبیه‌سازی آبخوان و کالبیره نمودن آن
- ۲- تولید مجموعه داده‌های ورودی - خروجی برای آموزش مدل شبکه عصبی

۳- آموزش مدل شبکه عصبی برای ساختارهای گوناگون

- ۴- صحت‌سنجی و استخراج مدل شبکه عصبی برتر برای برقراری ارتباط با مدل بهینه‌سازی.

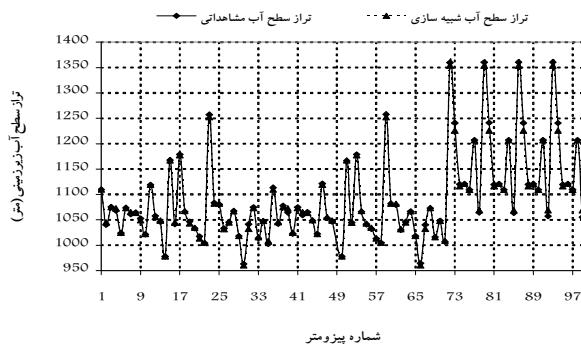
در این تحقیق به منظور شبیه‌سازی کمی آبخوان از مدل سه‌بعدی PMWIN نسخه ۵/۳ (۲۰۰۳) استفاده شد. این مدل قادر است با توجه به پارامترهای ورودی داده شده، به بررسی رفتار آبخوان پردازد. لذا شناخت رفتار آبخوان برای حالت‌های مختلف از پارامترهای ورودی، نیاز به اجرای مکرر مدل دارد. مدل با توجه به بیلان و اطلاعات موجود مربوط به سال ۸۲-۸۳، شبیه‌سازی



شکل ۱- شماتیک مرازهای آبرفت دشت تهران-کرج (محدوده مورد مطالعه بخش غربی دشت می‌باشد)

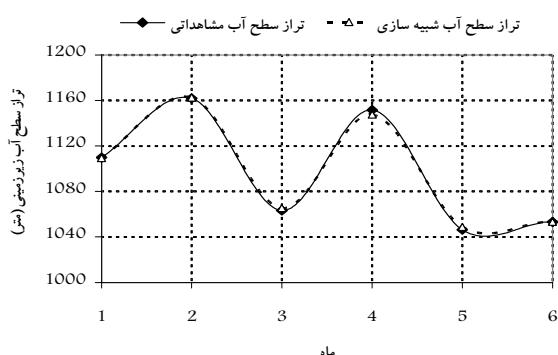
چاههای مشاهده‌ای است. به عبارت دیگر، مدلی قابل قبول است که نتایج در نقاط اندازه‌گیری شده و همچنین روند تغییرات سطح آب زیرزمینی، با مقادیر و روند تغییرات سطح آب چاههای مشاهده‌ای اختلاف قابل ملاحظه‌ای نداشته باشد. نشانه‌های تطبیق مدل کالیبره شده عبارت‌اند از تطابق تراز سطح آب در چاههای مشاهده‌ای، تطابق هیدروگراف چاههای مشاهده‌ای و نمودار پراکندگی نقاط<sup>۱</sup>.

در شکل ۳ به عنوان نمونه مقایسه‌ای بین مقادیر تراز سطح آب زیرزمینی مشاهداتی و شبیه‌سازی در پیزومترهای موجود، برای ماه آبان نشان داده شده است. لازم به ذکر است به منظور کالیبراسیون، کل دشت تهران-کرج به دلیل یکپارچگی آبخوان آن در نظر گرفته شد و به همین دلیل در شکلهای ارائه شده، مقایسه‌ها برای کل پیزومترهای موجود در دشت ارائه گردیده است.

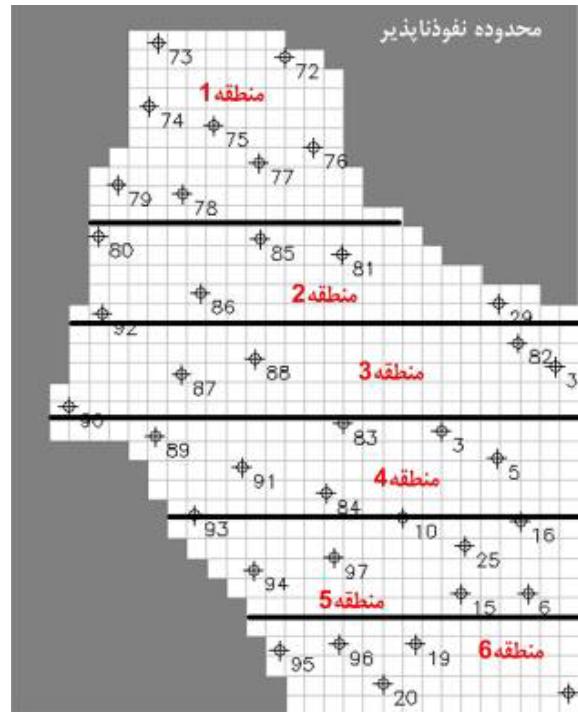


شکل ۳- مقایسه تراز سطح آب مشاهداتی با مقادیر شبیه‌سازی شده در شرایط پایدار (مهر ۸۲)

یکی دیگر از نشانه‌های صحت مدل کالیبره شده، تطابق هیدروگراف چاههای مشاهده‌ای است که به عنوان نمونه هیدروگراف‌های مرتبط با پیزومترهای شماره ۱ و ۱۵ در شکلهای ۴ و ۵ ارائه شده است.



شکل ۴- هیدروگراف تراز سطح آب زیرزمینی مشاهداتی با مقادیر شبیه‌سازی پیزومتر شماره ۱- شرایط ناپایدار

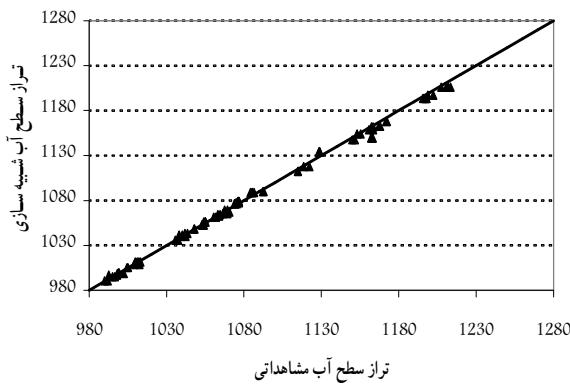


شکل ۲- شماتیک محدوده شبکه‌بندی منطقه مورد مطالعه

در این مطالعه، کالیبراسیون (تطابق بین مقادیر مشاهده‌ای با مقادیر شبیه‌سازی شده) به دو طریق مستقیم یا روش سعی و خطأ و خودکار انجام شد. در روش مستقیم ضرایب  $T$  و  $S_y$  به صورت دستی برای هر سلول تغییر داده شده و مدل شبیه‌سازی به ازای هر بار تغییر، اجرا می‌شود. اما در روش خودکار با مشخص نمودن بازه تغییرات ضرایب فوق، نرم‌افزار PMWIN به صورت خودکار اقدام به تغییر مقادیر ضریب در سلول‌های واقع در محیط آبخوان می‌نماید به گونه‌ای که کمترین میزان خطأ در شبیه‌سازی تراز سطح آب زیرزمینی در مقایسه با داده‌های پیزومتری اندازه‌گیری شده، حاصل شود. به منظور تعیین ضریب  $T$ ، مدل در شرایط پایدار و برای تعیین ضریب  $S_y$ ، مدل در شرایط ناپایدار اجرا و کالیبره شد. با توجه به داده‌های هیدروژئولوژی به دست آمده از محدوده مورد مطالعه، مدل شبیه‌سازی آبخوان برای شرایط پایدار و ناپایدار تهیه گردید و ضرایب هیدرودینامیکی آبخوان، کالیبره شد. تعداد مجهولاتی که در فرایند کالیبراسیون مورد توجه هستند، عبارت‌اند از مقدار ضریب  $T$  برای هر سلول و مقدار ضریب  $S_y$  به طور یکسان برای تمامی سلول‌ها. لازم به ذکر است مجهولات ذکر شده متغیر با زمان نیستند. ضریب آبدی و یزره ( $S_y$ ) مقدار ثابتی است و برای تعیین ضریب ذخیره ( $S$ ) در هر سلول لازم است ضخامت اشباع آبخوان در هر سلول در این ضریب ضرب گردد.

مهم‌ترین نشانه دقت و صحت مدل، میزان تطابق نوسان سطح آب زیرزمینی و روند تغییرات آن در مدل با نقاط مشابه در

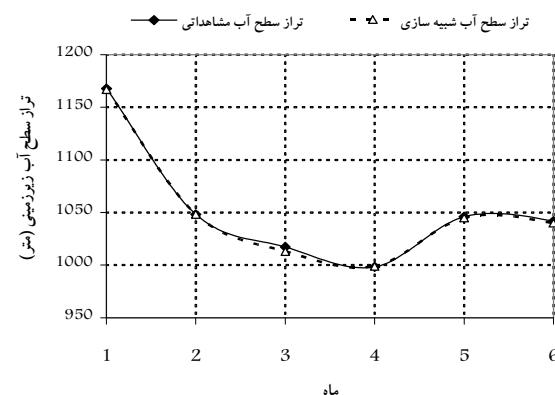
<sup>1</sup> Scatter Diagram



شکل ۶-نمودار پراکندگی تراز سطح آب مشاهداتی با مقادیر شبیه‌سازی شده پیزومترها در ماه بهمن ۸۲ (دوره کالیبراسیون) شرایط ناپایدار

از دقت خوبی در شبیه‌سازی تراز سطح آب زیرزمینی برخوردار است. مشخصات ضرایب هیدرودینامیکی کالیبره شده برای مناطق مورد مطالعه در جدول ۲ ارائه شده است. لازم به ذکر است که برای ضریب ذخیره ویژه، بدلیل تغییرات اندک در مناطق مورد مطالعه، یک بازه برای کل محدوده ارائه شد. با توجه به اینکه تولید مجموعه داده‌های ورودی - خروجی با استفاده از این مدل برای آموزش مدل شبکه عصبی زمان بر بود، در این مطالعه اقدام به تهیه کدی برای حل معادلات سیستم آب زیرزمینی شد. صحت نتایج حاصل از این کد با مقادیر خروجی از مدل شبیه‌سازی PMWIN مورد بررسی قرار گرفت. شکل ۷ مقایسه تراز سطح آب زیرزمینی شبیه‌سازی شده در ماه آبان را توسط دو مدل PMWIN و مدل عددی تدوین شده، نشان می‌دهد.

نتایج ارائه شده در این شکل نشان‌دهنده کارایی و دقت بالای مدل عددی در پیش‌بینی تراز سطح آب زیرزمینی به عنوان جایگزین مناسبی از مدل PMWIN است.



شکل ۵-هیدروگراف تراز سطح آب زیرزمینی مشاهداتی با مقادیر شبیه‌سازی پیزومتر شماره ۱۵-شرایط ناپایدار

در نمودار پراکندگی نقاط، هر چاه مشاهده‌ای به صورت یک نقطه در نمودار نمایش داده می‌شود. طول این نقطه برابر تراز سطح آب زیرزمینی مشاهده شده و عرض آن برابر تراز سطح آب زیرزمینی شبیه‌سازی شده است. چنانچه مقادیر سطح آب شبیه‌سازی شده و مشاهده شده برابر باشند، نقطه مزبور روی خطی با زاویه ۴۵ درجه قرار می‌گیرد. با توجه به ناهمگنی آبخوان، معمولاً انطباق کامل و صد درصد امکان پذیر نبوده و عملأً نقاط مزبور به صورت پراکنده در اطراف خطی با زاویه ۴۵ درجه قرار می‌گیرند. هر چه این نقاط مقایسه در این حالت از نظر عددی، پارامتر واریانس است. هر چه واریانس پراکندگی نقاط کوچک‌تر باشد نتایج واسنجی دقیق‌تر است (شکل ۶).

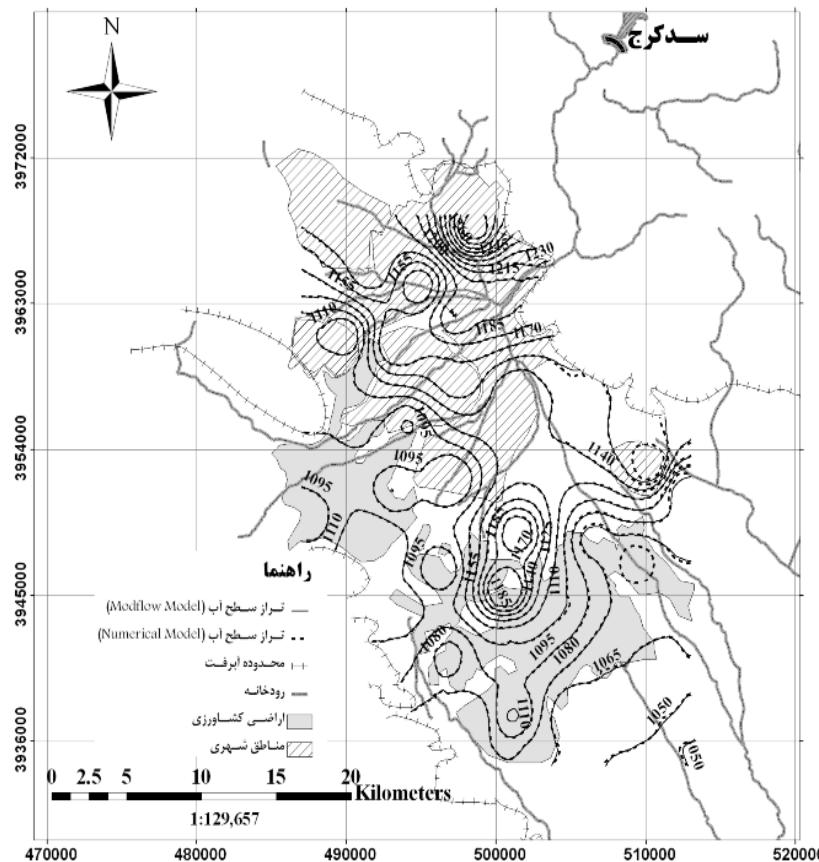
برای صحت‌سنجی مدل کالیبره شده، شش ماه در نظر گرفته شد. مشخصهای صحت مدل در دو دوره در جدول ۱ ارائه شده است. همان‌طور که از نتایج ارائه شده بالا بر می‌آید، مدل کالیبره شده

جدول ۱-شاخص خطای RMSE ماهانه برای دوره‌های کالیبراسیون و صحت‌سنجی

دوره کالیبراسیون										ماه	مهر	آبان	آذر	دی	بهمن	اسفند	فروردین	اردیبهشت	خرداد	تیر	مرداد	شهریور	RMSE
۳/۲۳	۳/۱۷	۲/۹	۴/۶	۳/۵	۴/۴	۳/۱	۴/۴۹	۲/۳	۴/۵	۲/۹	۴/۶	۴/۶											

جدول ۲-مشخصات ضرایب هیدرودینامیکی مناطق مورد مطالعه

منطقه ۶	منطقه ۵	منطقه ۴	منطقه ۳	منطقه ۲	منطقه ۱	ضرایب هیدرودینامیکی آبخوان
۶۰۰-۱۷۰۰	۱۰۰۰-۲۶۰۰	۹۰۰-۳۰۰۰	۷۰۰-۲۷۵۰	۶۵۰-۱۷۵۰	۵۰۰-۱۰۰۰	ضریب انتقال (متر مربع بر روز) ضریب آبدهی ویژه (درصد)



شکل ۷- مقایسه تراز سطح آب زیرزمینی شبیه‌سازی شده در ماه آبان توسط دو مدل PMWIN و مدل عددی تفاضل‌های محدود

صورت گرفت. با توجه به مقادیر تولید شده برای پارامترهای ورودی، مدل شبیه‌سازی عددی آب زیرزمینی اجرا می‌گردد و میزان تراز سطحی آب زیرزمینی در انتهای هر دوره شبیه‌سازی و برای هر منطقه ذخیره می‌شود. منظور از هر منطقه، تعداد سلول‌هایی است که در مدل نیمه‌گسترده<sup>۱</sup> در نظر گرفته می‌شود. این روند تا تکمیل تعداد مجموعه آموزشی مورد نیاز، ادامه می‌پاید.

مدت زمان شبیه‌سازی مدل عددی برای تولید داده‌های آموزشی  
برابر با ۱۰ سال و تعداد داده‌های تولیدی (مجموعه ورودی-  
خروجی) برابر با ۵۰۰ است. به منظور ارائه ساختاری که بتواند  
رفتار دینامیکی آبخوان را نشان دهد، مدل‌های دینامیکی و  
استاتیکی متفاوتی مورد آموزش و بررسی قرار گرفت که نحوه  
شبیه‌سازی این مدل‌ها با ساختارهای متفاوت در بخش بعدی ارائه  
نمی‌گردد.

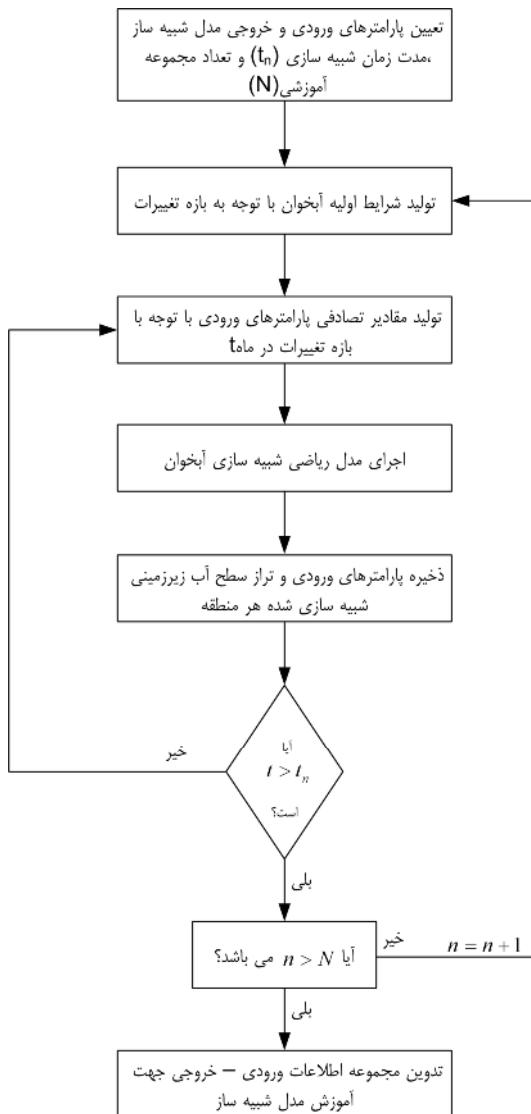
## ۲-۲- ساختار شبکه‌های عصبی استاتیکی و دینامیکی

بر اساس الگوریتم یادگیری و همچنین معماری شبکه، انواع گوناگونی از شبکه‌های عصبی ابداع و به کار گرفته شده‌اند. انتخاب

پس از انتخاب مدل شبیه‌ساز، برای تولید داده‌های مورد نیاز مدل شبکه عصبی دینامیکی و استاتیکی، گام اول در شبیه‌سازی، معرفی و تعیین پارامترهای ورودی و خروجی بیانگر رفتار سیستم آب زیرزمینی است. با توجه به اینکه عدمه ترین پارامترهای تأثیرگذار در آبخوان مشتمل بر میزان جریان ورودی و خروجی از مرز، میزان برداشت از آبخوان برای تأمین نیازهای شرب و کشاورزی و تراز سطح آب زیرزمینی در ابتدای دوره شبیه‌سازی است لذا از این پارامترها به عنوان اطلاعات ورودی به مدل شبیه‌ساز استفاده شد. از آنجایی که تراز سطح آب زیرزمینی در انتهای دوره شبیه‌سازی به عنوان مهم ترین عامل بررسی رفتار آبخوان، قابل توجه است، از آن به عنوان پارامتر خروجی در مدل شبیه‌ساز استفاده گردید.

برای تولید مجموعه داده‌های ورودی - خروجی به منظور آموزش مدل شبیه‌سازی، مطابق فلوچارت ارائه شده در شکل ۸ عمل شد. مطابق این فلوچارت، ابتدا پارامترهای ورودی، خروجی، مدت زمان شبیه‌سازی و تعداد مجموعه‌های آموزشی مشخص می‌شود. سپس شرایط اولیه تراز سطح آب زیرزمینی برای هر سل و با توجه به بازه تغییرات متناظر با هر پارامتر به صورت تصادفی تولید می‌شود. این روند تولید داده برای پارامترهای ورودی نیز

1 Semi-Distributed



شکل ۸- مراحل تولید مجموعه داده‌های ورودی-خروجی جهت آموزش مدل شبیه‌ساز

فراوانی دارند. ولی در مسائلی همانند شبکه‌های آدالین و پرسپترون چند لایه که طبیعت آنها پویا و متغیر با زمان است، قابلیت چندانی ندارند.

در این تحقیق با توجه به پارامترهای ورودی و خروجی ارائه شده در بخش قبل، مدل شبکه عصبی استاتیکی برای ساختارهای مختلف مورد آموزش قرار گرفت. ساختار مدل‌های مورد بررسی در شکل‌های ۵ تا ۷ ارائه شده است. همان‌طور که در این شکل‌ها مشخص است، پارامترهای ورودی و خروجی مدل شبکه عصبی عبارت‌اند از میزان جریان ورودی و خروجی زیرزمینی آبخوان ماهانه، مقادیر برداشت ماهانه توسط بخش شرب و کشاورزی، میزان تراز سطح آب زیرزمینی در ابتدای ماه و برای شش منطقه مشخص شده. با توجه به هم‌جنس نبودن پارامترهای ورودی (منظور مقادیر برداشت، ورودی و خروجی با مقادیر تراز سطح آب زیرزمینی)

نوع و چگونگی آموزش شبکه عصبی برای یک مسئله خاص، مستلزم بررسی طبیعت و قوانین حاکم بر مسئله مورد نظر است. به‌طور کلی شبکه‌های عصبی در قالب دو گروه شبکه‌های عصبی استاتیکی (بدون حافظه) و شبکه‌های عصبی دینامیکی (با حافظه و زمانمند) معرفی می‌گردند.

**۱-۲-۱- ساختار شبکه عصبی استاتیکی**  
شبکه‌های عصبی استاتیکی، شبکه‌هایی هستند بدون حافظه که در ساختار آنها زمان و پویایی وجود ندارد. در واقع این شبکه‌ها پردازش زمان‌دار انجام نمی‌دهند و خروجی این شبکه‌ها در هر لحظه، فقط به ورودی آن در همان لحظه بستگی دارد. شبکه‌های استاتیکی در مسائل پیچیده‌ای که هدف، تخمین یک نگاشت خطی یا غیرخطی بین مجموعه‌های ورودی- خروجی باشد، کاربردهای

مناسب و مطلوب با توجه به شاخص میانگین مربع خطای MSE<sup>۴</sup> در نظر گرفته شده است. در مدل ۱، شبکه‌ای که در آن مقادیر خروجی از لایه انتها بای تخصیص وزنی به آن وارد لایه ابتدایی می‌گردد مورد توجه قرار گرفته است.

در ساختار مدل ۲، میزان برگشت داده شده از لایه خروجی با اعمال وزن وارد لایه دوم می‌گردد. مجزا نمودن پارامتر خروجی برگشت داده شده در قالب یک لایه جدا، ساختاری مشابه مدل ۳ را ایجاد می‌نماید. با افزایش تعداد لایه به ساختار مدل ۳، می‌توان مدل ۴ را ارائه نمود.

### ۳- ارائه نتایج

با توجه به ساختارهای تعیین شده برای شبکه استاتیکی و دینامیکی و آموزش آنها با استفاده از مجموعه داده‌های تولیدی می‌توان میزان دقت آنها را در ارائه پیش‌بینی صحیح از رفتار آبخوان برای بهره‌برداری در شرایط واقعی تعیین نمود. با آموزش مدل‌های تهیه شده و ارزیابی آنها با استفاده از شاخص خطای MSE، ساختارهای برتر برای پیش‌بینی مشخص می‌شوند که نتایج مقادیر خطای برای حالت‌های آموزش، آزمایش و صحت‌سنجی دو استاتیکی و دینامیکی به ترتیب در جدول ۳ ارائه شده است.

نتایج ارزیابی مدل‌های مختلف نشان می‌دهد که در شبکه‌های استاتیکی، مدل ۲ از قابلیت بالاتری در پیش‌بینی ماهانه تراز سطح آب زیرزمینی برخوردار است. همچنین ارزیابی‌ها نشان می‌دهد که افزایش تعداد لایه، تأثیری قابل توجهی در کاهش خطای آموزش ندارد. در مدل دینامیکی نیز با توجه به اینکه ساختار مدل ۱ از دقت بالاتری در آموزش نسبت به سایر مدل‌ها برخوردار است و همچنین قابلیت بهتری را در پیش‌بینی با استفاده از داده‌های آزمایش و صحت‌سنجی نشان می‌دهد لذا ساختار ارائه شده در مدل ۱ به عنوان ساختار برتر مدل دینامیکی معرفی گردید. نتایج ارائه شده در شکل‌های ۹ و ۱۰ تراز سطح آب زیرزمینی پیش‌بینی شده با استفاده از ساختار برتر مدل‌های استاتیکی و دینامیکی را در مقایسه با مقادیر پیش‌بینی شده توسط مدل عددی نشان می‌دهد.

با توجه به ساختارهای آموزش داده شده دو مدل استاتیکی و دینامیکی لازم است میزان دقت آنها در پیش‌بینی بلندمدت تراز سطح آب زیرزمینی مورد مقایسه و ارزیابی قرار گیرد. برای این منظور با استفاده از مدل عددی تهیه شده، مجموعه داده‌های ورودی-خروجی به صورت تصادفی و برای یک دوره ۱۰ ساله تولید گردید.

<sup>4</sup> Mean Square Error

ساختارهای مورد بررسی به گونه‌ای تدوین شد که تأثیر آنها به نحوه مطلوبی در شبیه‌سازی دیده شود. در تمامی ساختارهای تهیه شده در مدل شبکه عصبی استاتیکی، آموزش به صورت ماهانه بود. به عبارت دیگر برای هر ساختار، ۱۲ مدل ماهانه مورد آموزش قرار گرفت.

به منظور وضوح بیشتر ارتباطات درونی مدل‌ها، توضیحاتی در مورد هر ساختار ارائه می‌گردد. در ساختار مدل ۱، تمامی پارامترهای ورودی به صورت یکجا به مدل وارد شده و شبکه با داشتن دو لایه و تعداد نمونه‌های لایه اول برابر با ۵ و لایه آخر برابر با ۶ آموزش دیدند. برای تعیین میزان حساسیت شبکه به پارامتر تراز سطح آب زیرزمینی، این پارامتر ورودی به صورت مجزا و تحت یک لایه مشخص به مدل وارد شد و ساختار مدل ۲ را ایجاد کرد. به منظور ارائه میزان تأثیر افزایش لایه در فرایند آموزش ساختار، مدل ۳ تدوین گردید.

### ۲-۲-۲- ساختار شبکه عصبی دینامیکی

با وجود کارایی و قابلیت‌های فراوان شبکه‌های عصبی استاتیکی در حل مسائل مختلف، محدودیتها زیادی نیز در استفاده از آن وجود دارد که مهم‌ترین آنها عدم توانایی رویارویی این شبکه‌ها با مسائلی است که طبیعت آنها پویا و متغیر با زمان است. یکی از روشهای زمانمند کردن یک شبکه عصبی استفاده از اپراتورهای تأخیر زمانی است. هر اپراتور تأخیر زمانی با دریافت سیگنال ورودی، آن را تا یک گام زمانی در خود حفظ نموده و در گام زمانی بعد به عنوان خروجی خود نتیجه می‌دهد. شبکه آدالاین تطبیقی، شبکه عصبی بازگشته (RNN)<sup>۱</sup>، شبکه عصبی با ورودی‌های تأخیر یافته (IDNN)<sup>۲</sup> و شبکه عصبی تأخیر زمانی (TDNN)<sup>۳</sup> به عنوان شبکه‌های دینامیکی معرفی می‌شوند. در این شبکه‌ها نیز همانند شبکه‌های عصبی استاتیکی، برای ارائه ساختار برتر، مدل‌های متفاوتی در نظر گرفته شده است. پارامترهای ورودی و خروجی مورد استفاده در این مدل‌ها مشابه شبکه‌های استاتیکی بوده با این تفاوت که مقادیر خروجی به صورت برگشتی و به عنوان ورودی در فرایند آموزش در نظر گرفته می‌شود. در مدل دینامیکی، مجموعه داده‌های ورودی- خروجی به صورت یکجا و برای تمامی ماهها، به صورت پیوسته وارد ساختار تعریف شده، می‌گردد و مورد آموزش قرار می‌گیرند. در این حالت مقدار شبیه‌سازی شده در انتهای هر ماه به عنوان ورودی و شرایط اولیه ماه بعد، وارد شبکه می‌شود.

در مدل دینامیکی نیز ساختارهای گوناگونی برای تعیین شبکه

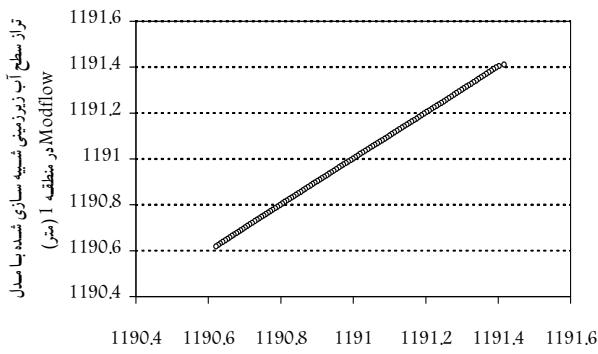
<sup>1</sup> Recurrent Neural Network

<sup>2</sup> Input Delay Neural Network

<sup>3</sup> Time Delay Neural Network

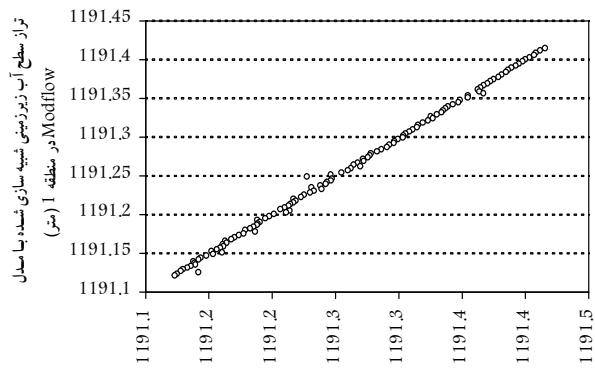
جدول ۳- مقایسه شاخص MSE مدل های مختلف شبکه عصبی استاتیکی

مدل دینامیکی	مدل استاتیکی	مدل
صحت سنجی	صحت سنجی	آموزش
$4/78 \times 10^{-2}$	$4/6 \times 10^{-2}$	$4/25 \times 10^{-7}$
$1/92 \times 10^{37}$	$1/92 \times 10^{37}$	$1/93 \times 10^{37}$
$5/22 \times 10^{-6}$	$5/14 \times 10^{-6}$	$5/77 \times 10^{-5}$
$3/39 \times 10^{-2}$	$3/46 \times 10^{-2}$	$2/84 \times 10^{-4}$
		-
		-
		-



شکل ۱۰- مقایسه تراز سطح آب زیرزمینی شبیه‌سازی شده با دو مدل DANN و مدل عددی در منطقه ۱ (وضعیت آموزش)

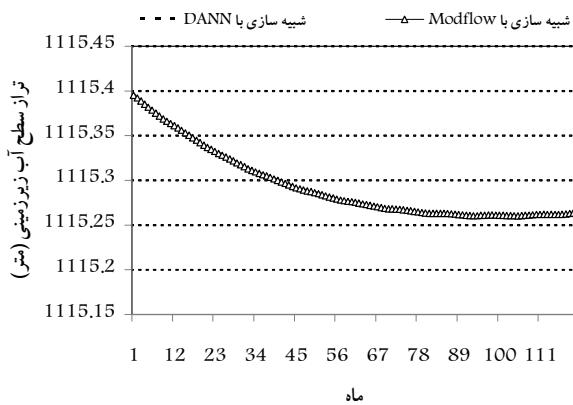
هر ماه پیش‌بینی نمایند. همان طور که در شکل ۱۱ نشان داده شده است، به دلیل اینکه شبکه‌های استاتیکی به صورت ماهانه مورد آموزش قرار می‌گیرند، شبیه‌سازی به صورت پیوسته و بر اساس داده‌های شبیه‌سازی شده ماههای قبل منجر به ارائه مقادیر صحیحی از تراز سطح آب زیرزمینی نمی‌شود. علت این امر این است که در ماه اول با توجه به شرایط تراز اول ماه و مقادیر برداشت، شبیه‌سازی تراز به درستی صورت می‌گیرد اما برای ماه دوم، شرایط اولیه این ماه را مقادیر شبیه‌سازی شده ماه قبل مشخص می‌کند و اگر این شرایط ابتدای ماه به درستی شبیه‌سازی نشده باشد و همراه با مقداری خطا باشد، شبیه‌سازی انتهای ماه را دچار اشکال می‌کند و باعث بروز تغییراتی بعضًا قابل توجه در تراز سطح آب زیرزمینی می‌شود. لازم به ذکر است که بروز این خطاهای در تراز، به طور پیوسته بر تراز سطح آب زیرزمینی اثر گذاشته و نوساناتی را بر خلاف نوساناتی که باید آبخوان به طور واقعی در نتیجه برداشت‌های ماهانه داشته باشد، ایجاد می‌نماید که در برخی از ماهها این نوسانات شدیدتر است. همچنین به دلیل روابط غیرخطی که در شبیه‌سازی شبکه‌های عصبی وجود دارد، به طور مشخص خطای زیاد در شرایط ابتدای ماه ممکن است منجر به نوسانات زیاد در شبیه‌سازی انتهای ماه نشود و یا بالعکس.



**شکل ۹- مقایسه تراز سطح آب زیرزمینی شبیه‌سازی شده با مدل SANN و مدل عددی در منطقه ۱ (وضعیت آموزش)**

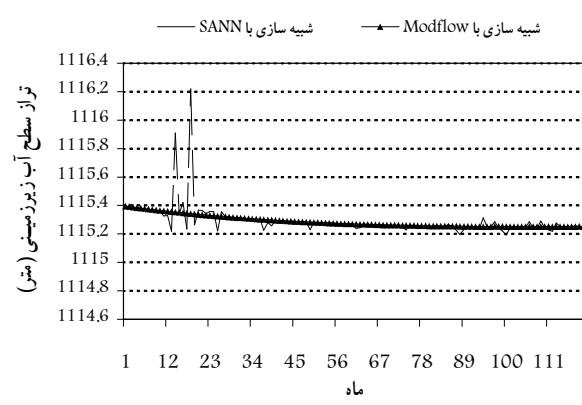
با اعمال پارامترهای ورودی به ساختارهای برتر دو مدل استاتیکی و دینامیکی و اجرای آنها به صورت پیوسته، تراز سطح آب زیرزمینی در طول دوره ۱۰ ساله پیش‌بینی گردید. منظور از اجرای پیوسته این است که مقادیر پیش‌بینی شده در هر ماه به عنوان شرایط اولیه ماه بعد در مدل شبکه عصبی در نظر گرفته شود. به عبارت دیگر در مدل استاتیکی با آغاز شبیه‌سازی از ماه مهر و با استفاده از تراز ابتدایی این ماه و مقادیر برداشت، شبکه آموزش داده شده و مقدار پیش‌بینی شده در انتهای این ماه به عنوان شرایط اولیه تراز برای ماه آبان مشخص می‌شود. این پیش‌بینی‌ها تا پایان دوره مورد نظر (۱۲۰ ماه) ادامه می‌یابد. این روند برای مدل دینامیکی به این صورت است که تنها شرایط اولیه ابتدایی ماه و مقادیر برداشت سایر ماهها به ساختار برتر آموزش داده شده، وارد می‌شود و به صورت پیوسته تا انتهای دوره مورد نظر، مقادیر تراز سطح آب زیرزمینی به صورت ماهانه ارائه می‌گردد. نتایج ارائه شده توسط ساختارهای برتر دو مدل استاتیکی و دینامیکی که در شکل‌های ۱۱ و ۱۲ نشان داده شده است بیانگر این مطلب است که ساختارهای استاتیکی نمی‌توانند شرایط دینامیکی آبخوان را به نحوه مطلوبی

این مدل‌ها تنها قادرند با مشخص بودن شرایط ابتدایی تراز سطح آب زیرزمینی و مقادیر برداشت‌ها، مقادیر تراز را در انتهای



شکل ۱۲- مقایسه تراز سطح آب زیرزمینی شبیه‌سازی شده با دو مدل DANN و مدل عددی برای یک دوره ۱۰ ساله و به صورت پیوسته در منطقه ۳ (وضعیت صحت‌سنگی)

تغییرات تراز آبخوان، مقادیر قابل توجهی از پارامترهای ورودی و خروجی به صورت تصادفی تولید گردید. این مجموعه اطلاعات ورودی و خروجی، اساس آموزش مدل‌های شبیه‌ساز شبکه عصبی استاتیکی و دینامیکی است. علت استفاده از مدل‌های شبکه عصبی را می‌توان در آموزش سریع، ارتباط مناسب با مدل‌های بهینه‌سازی، کاهش زمان همگرایی و داشتن دقت مناسب در پیش‌بینی تغییرات تراز سطح آب زیرزمینی دانست. با توجه به اینکه سیستم حرکت جریان در آبخوان به صورت دینامیک بوده و تابعی از تراز سطح آب زیرزمینی شرایط گذشته است، لذا در این تحقیق برای اثبات این موضوع از دو مدل شبکه عصبی استاتیکی و دینامیکی استفاده شد. نتایج این تحقیق نشان داد که علی‌رغم آموزش با دقت مطلوب هر دو ساختار، مدل‌های استاتیکی به دلیل عدم دخالت زمان در فرایند آموزش قادر به پیش‌بینی متوالی به صورت ماهانه نخواهند بود. در این مدل‌ها چنانچه شرایط اولیه آبخوان و مقادیر برداشت ماه مورد بررسی مشخص باشد، با استفاده از مدل آموزش داده شده برای آن ماه، می‌توان شرایط انتهایی ماه را با دقت مناسبی پیش‌بینی نمود. مدل شبیه‌سازی شبکه عصبی دینامیکی به دلیل برگشت اطلاعات شرایط گام زمانی قبل در آموزش، در پیش‌بینی بلندمدت تغییرات تراز سطح آب زیرزمینی کارایی و دقت مناسبی دارد. با استفاده از مدل‌های دینامیکی، می‌توان رفتار تراز سطح آب زیرزمینی را در قالب معادله‌ای ارائه داد و در مدل‌های مدیریتی استفاده نمود.



شکل ۱۱- مقایسه تراز سطح آب زیرزمینی شبیه‌سازی شده با دو مدل SANN و مدل عددی برای یک دوره ۱۰ ساله و به صورت پیوسته در منطقه ۳ (وضعیت صحت‌سنگی)

نتیجه دیگری که از این مطالعه می‌توان گرفت این است که برخلاف مدل‌های استاتیکی، ساختارهای مدل دینامیکی قادرند با دقت بسیاری تراز سطح آب زیرزمینی را برای افق برنامه‌ریزی بدون نیاز به مشخص بودن شرایط اولیه هر ماه (به استثنای ماه اول) پیش‌بینی نمایند. علت این امر دخالت زمان در طی فرایند آموزش مدل‌های دینامیکی است.

#### ۴- نتیجه‌گیری

در مدل‌های مدیریت منابع آب که به صورت تلفیقی منابع آب سطحی و زیرزمینی مورد توجه قرار می‌گیرد، برای تعیین مقادیر بهینه تخصیص از منابع، رعایت محدودیتهای برداشت الزامی است که این امر در مورد منابع آب زیرزمینی با کنترل تغییرات تراز میسر می‌شود. بهمنظور آگاهی از رفتار سیستم آب زیرزمینی لازم است با استفاده از مدل‌های شبیه‌سازی موجود، وضعیت آبخوان مورد شبیه‌سازی قرار گیرد. با توجه به اینکه استفاده از مدل‌های شبیه‌سازی همچون PMWIN، که به صورت نرم‌افزار قابل استفاده هستند، در مدل بهینه‌سازی منجر به افزایش زمان اجرا و در نتیجه همگرایی به سمت مقادیر بهینه کلی می‌گردد لذا در این تحقیق به منظور بر طرف نمودن این مشکل، اقدام به تهیی مدل عددی برای شبیه‌سازی تغییرات تراز آبخوان شد تا با استفاده از آن، زمینه برای تولید داده‌های مورد نیاز مدل‌های شبیه‌ساز شبکه عصبی فراهم شود. با استفاده از این مدل عددی و بازه تغییرات مؤلفه‌های تأثیرگذار در

#### ۵- مراجع

- 1- Menhaj, M. B. (2002). *Computational intelligence, vol 1: Fundamentals neural networks*, Amirkabir University Press, Tehran.(In Persian)

- 2- Das, A., and Datta, B., (2001). "Application of optimisation techniques in groundwater quantity and quality management." *Academy Proc. In Eng., Sciences*, 24 (4), 293-316
- 3- Kim, S.S. (1998). "Time-delay recurrent neural network for temporal correlations and prediction." *Neurocomputing*, 20, 253-263.
- 4- Yazdizadeh, A., and Khorasani, K. (2002). "Adaptive time delay neural network structures for nonlinear system identification." *Neurocomputing*, 47, 207-240.
- 5- Shigidi, A., and Garcia, L.A. (2003). "Parameter estimation in groundwater hydrology using artificial neural networks." *J. of Computing in Civil Engineering*, 17(4), 281-289.
- 6- Coppola, Jr. E., Szidarovszky, F., Poulton, M., and Charles, E. (2003). "Artificial neural network approach for predicting transient water levels in a multilayered groundwater system under variable state, pumping, and climate conditions." *J. of Hydrologic Engineering*, 8(6), 348-360.
- 7- Daliakopoulos, I.N., Coulibaly, P., and Tsanis, I.K. (2005). "Groundwater level forecasting using artificial neural networks." *J. of Hydrology*, 309, 229-240.
- 8- Chandramouli, V., Lingireddy, S., and Brion, G.M. (2007). "Robust training termination criterion for back-propagation ANNs applicable to small data sets." *J. of Computing in Civil Engineering*, 21(1), 39-46.
- 9- Karamouz, M., Mohammad Rezapour Tabari, M., and Kerachian, R. (2007), "Application of genetic algorithms and artificial neural networks in conjunctive use of surface and groundwater resources." *J. of Water International*, 32(1), 163-176.
- 10- Shamseldin, A.Y. (1997). "Application of neural network technique to rainfall-runoff modelling." *J. of Hydrology*, 199, 272-294.
- 11- Maier, H.R., and Dandy, G.C. (1996). "Use of artificial neural networks for prediction of water quality parameters." *Water Resour. Res.*, 32(4), 1013-1022.
- 12- Clair, T.A., and Ehrman, J.M. (1998). "Using neural networks to assess the influence of changing seasonal climates in modifying discharge, dissolved organic carbon, and nitrogen export in eastern Canadian rivers." *Water Res. Res.*, 34(3), 447-455.
- 13- Smith, J., and Eli, R.N. (1995). "Neural-network models of rainfall-runoff process." *J. Water Resour. Plng. and Mang.*, 121(6), 499-508.
- 14- Karunanithi, N., Grenney, W.J., Whitley, D., and Bovee, K. (1994). "Neural networks for river flow prediction." *J. Comp. Civ. Engrg.*, 8(2), 201-220.
- 15- Razavi, S. S. (2004). "Application of neural networks in hydrological and hydraulic routing." M.Sc. Thesis, Dept. of Civil Eng., Amirkabir University, Tehran. (In Persian)
- 16- Karamouz, M., Tabesh, T., Nazif, S., and Moridi, A. (2005). "Estimation of hydraulic pressure in water networks and fuzzy logic." *J. of Water and Wastewater*, 53, 3-14. (In Persian)