

کنترل آلودگی نترات در آب زیرزمینی با استفاده از مدل بهینه‌سازی

کوروش محمدی^۲

مجید خیاط خلقی^۲

الهه پور فرح‌آبادی^۱

(پذیرش ۹۲/۸/۵)

(دریافت ۹۱/۱۱/۳۰)

چکیده

نیتрат یکی از مهم‌ترین آلاینده‌هایی است که از منابع مختلف مانند کودهای شیمیایی، آفت‌کش‌ها و یا فاضلاب‌های خانگی و صنعتی وارد آب‌های زیرزمینی می‌شود. در این پژوهش به منظور مدیریت بهینه آبخوان‌های آلوده به نیترات، از مدل شبکه عصبی مصنوعی برای شبیه‌سازی تغییرات غلظت نیترات استفاده شد و به منظور استخراج مقادیر بهینه برداشت از آبخوان آب زیرزمینی، با حفظ محدودیت غلظت نیترات در حد استاندارد، از یک مدل بهینه‌ساز استفاده شد. برای دستیابی به این هدف از مدل بهینه‌سازی مجموعه ذرات بهره گرفته شد. با توجه به این که در سال‌های اخیر، آلودگی غلظت نیترات در آبخوان کرج افزایش یافته است، بخشی از این آبخوان به عنوان مطالعه موردی در نظر گرفته شد. پارامترهای ورودی مدل شبکه عصبی مصنوعی، شامل میزان برداشت در طول فصل بررسی و فصل قبل، مقادیر غلظت نیترات در فصل قبل، ضخامت لایه اشباع و طول و عرض جغرافیایی هر ناحیه بود؛ این پارامترها پس از آنالیز حساسیت، انتخاب شدند. نتایج این پژوهش نشان می‌دهد که بر اساس الگوریتم بهینه‌سازی مجموعه ذرات، مدیریت بهینه غلظت نیترات، مستلزم کاهش و یا افزایش برداشت از نواحی مختلف نسبت به شرایط فعلی برداشت در منطقه است. لذا با ثابت نگه داشتن کل برداشت از محدوده و با اندکی تغییرات منطقه‌ای در میزان برداشت در آبخوان آلوده کرج، می‌توان از افزایش غلظت نیترات در نواحی بحرانی جلوگیری نمود.

واژه‌های کلیدی: غلظت نیترات، آبخوان کرج، شبکه عصبی مصنوعی، بهینه‌سازی مجموعه ذرات

Development of Operation Management Model of Groundwater According to Nitrate Contamination

E. Poorfarahabadi¹

M. Khayat Kholghi²

K. Mohammadi³

(Received Feb. 18, 2013 Accepted Oct. 27, 2013)

Abstract

Nitrate is one of the most important groundwater pollutants with such different sources as chemical fertilizers, pesticides, or domestic and industrial wastewater. In this research, the optimal operation of groundwater wells in aquifers with nitrate pollution is investigated using simulation and optimization techniques. For the simulation part, an artificial neural network (ANN) model is developed, and for the optimization model, the particle swarm optimization (PSO) is used. Considering the high nitrate concentration in Karaj area and its increase in recent years, the northern part of this aquifer is selected as a case study to apply the proposed methodology. A seasonal ANN model is developed with input layers including well discharge in the current and previous seasons, nitrate concentration in the previous season, aquifer thickness, and well coordinates, all selected based on sensitivity analysis. The results of PSO algorithm shows that nitrate concentration can be controlled by increasing or decreasing well discharge in different zones. Therefore, it is possible to reduce nitrate concentration in critical areas by changing the spatial distribution of groundwater extractions in different zones keeping the total discharge constant.

Keywords: Nitrate Concentration, Karaj Aquifer, Artificial Neural Network, Particle Swarm Optimization.

1. M.Sc. of Irrigation and Reclamation, Dept. of Water and Soil Eng., College of Agriculture and Natural Resources, Tehran University, Tehran
(Corresponding Author) 09122263421 e.poorfarahabadi@yahoo.com
2. Assoc. Prof. of Irrigation and Reclamation, Dept. of Water and Soil Eng., College of Agriculture and Natural Resources, Tehran University, Tehran
3. Assoc. Prof. of Irrigation and Drainage, Tarbiat Modares University, Tehran

- ۱- کارشناسی ارشد گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی آب و خاک، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران (نویسنده مسئول) ۰۹۱۲۲۲۶۳۴۲۱ e.poorfarahabadi@yahoo.com
- ۲- دانشیار گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی آب و خاک، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران
- ۳- دانشیار گروه مهندسی آبیاری و زهکشی، دانشگاه تربیت مدرس، تهران

در چند دهه اخیر، مصرف بی‌رویه کودهای شیمیایی نیتروژن دار و فعالیت‌های انسانی و صنعتی، اثر نامطلوبی بر خصوصیات خاک و منابع آب زیرزمینی گذاشته و باعث آلودگی محیط زیست شده‌اند. وجود مقادیر بیش از حد نیترات در آب مصرفی برای انسان، دام و گیاه خطرناک است. از طرفی آب‌های زیرزمینی به دلیل کیفیت مطلوب و بهره‌برداری آسان، مهم‌ترین منابع آب، به خصوص در مناطق خشک و نیمه خشک محسوب می‌شوند. هرگونه بهره‌برداری از آب زیرزمینی می‌تواند تأثیر مستقیمی روی غلظت نیترات در آبخوان‌های آلوده داشته باشد. بنابراین مدیریت بهینه برداشت از آب زیرزمینی می‌تواند در کنترل غلظت نیترات بسیار مؤثر باشد.

برای استفاده از مدل‌های عددی پیشرفته به منظور شبیه‌سازی انتقال آلودگی، ابتدا باید به مدل شبیه‌سازی جریان آب زیرزمینی پرداخته شود. این فرایند بسیار پیچیده و وقت‌گیر بوده و کالیبراسیون مناسب آن نیازمند آمار گسترده از وضعیت کمی و کیفی آبخوان است و همچنین در شرایطی که آمار و اطلاعات کافی برای مدل‌سازی عددی موجود نباشد، شبیه‌سازی عددی امکان‌پذیر نیست و یا با محدودیت‌های قابل توجهی همراه است. از این رو امروزه کاربرد مدل‌های شبکه‌های عصبی مصنوعی توسعه گسترده‌ای یافته است. اگرچه این مدل‌ها نسبت به مدل‌های عددی از دقت کمتری برخوردارند، اما در بعضی مواقع به دلایل مختلف از جمله کمبود اطلاعات و بار محاسباتی کمتر، مورد استفاده قرار گرفته‌اند.

لازم به ذکر است که حداکثر غلظت مجاز نیتروژن نیتراتی^۱ برای آب آشامیدنی، از نظر سازمان بهداشت جهانی^۲ ۱۰ میلی‌گرم در لیتر که تقریباً معادل ۴۵ میلی‌گرم در لیتر نیترات است، می‌باشد. این حد از نظر اتحادیه اروپا^۳ ۵۰ میلی‌گرم در لیتر نیترات در نظر گرفته شده است [۲ و ۱].

در زمینه مدل‌های کمی و کیفی آب زیرزمینی، تحقیقات زیادی صورت گرفته است. ایماندل و همکاران در سال ۱۳۷۷، روند فزونی غلظت نیترات در آب چاههای آبخوان جنوب غرب تهران را مورد بررسی قرار داده‌اند [۳]. لی و همکاران در سال ۲۰۰۳، مدل‌های تصادفی برای ارزیابی آلودگی نیترات در آب زیرزمینی را با استفاده از GIS بررسی نموده‌اند [۴]. الماسری و کالوارچی در سال ۲۰۰۴، آنالیز تصمیم چند معیاره برای بهینه کردن مدیریت آبخوان‌های آلوده به نیترات را مورد بررسی قرار داده‌اند [۵]. پراکاسا روا و پوتانا در سال ۲۰۰۶، نشت نیترات و استراتژی‌هایی برای کاهش آن را مورد بحث قرار داده‌اند و همچنین ضرورت

اندازه‌گیری نیترات و مدل‌های اندازه‌گیری آن را بررسی کرده‌اند [۶]. رگرس و دولا در سال ۱۹۹۴، روشهای شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک^۴ را برای تعیین جریان آلودگی غیر نقطه‌ای آب زیرزمینی بررسی نموده‌اند [۷]. وانگ و ژنگ در سال ۱۹۹۸، دو مدل بهینه‌سازی الگوریتم ژنتیک و نورد شبیه‌سازی شده را همراه با مدل مادفلو^۵ برای مدیریت بهینه منابع آب زیرزمینی در شرایط عمومی به کار برده‌اند [۸]. رماسامی و همکاران در سال ۲۰۰۳، غلظت نیترات در آب زیرزمینی را با استفاده از دو مدل رگرسیون و شبکه عصبی مصنوعی تخمین زده‌اند [۹]. یسیناکار و همکاران در سال ۲۰۰۷، یک مدل شبکه عصبی مصنوعی برای پیشگویی غلظت نیترات را بررسی نموده‌اند [۱۰]. ناصری و همکاران در سال ۱۳۹۲، با استفاده از ترکیب روش نروفازی، بهینه‌بندی شاخص‌های کیفی چند متغیره آب زیرزمینی را انجام داده‌اند. آنها اطلاعات ۱۲ پارامتر شیمیایی کیفی آب چاههای دشت قزوین را مورد مطالعه قرار داده و در نتیجه شاخص کیفی فازی جدید را با استفاده از مدل بهینه الگوریتم ژنتیک به کل دشت قزوین تعمیم داده‌اند [۱۱]. معاشری و همکاران در سال ۲۰۱۲، با استفاده از مدل شبکه عصبی و بهینه کردن نتایج این مدل بر اساس مدل بهینه‌سازی الگوریتم ژنتیک، مقادیر نیترات را در دشت بیرجند پیش‌بینی نموده‌اند. نتایج این تحقیق نشان داده است که مقادیر پیش‌بینی شده با ضریب همبستگی ۰/۸۳، بین مقادیر آزمایشگاهی و مقادیر واقعی نیترات قرار گرفته که نشان از قابل اطمینان بودن این مدل دارد [۱۲]. ایبانه و همکاران در سال ۲۰۱۱، مدل شبکه عصبی را برای تخمین غلظت نیترات در دشت بهار همدان و مقایسه نتایج حاصل با مقادیر اندازه‌گیری شده را مورد بررسی قرار داده‌اند [۱۳]. تاپگلو و همکاران در سال ۲۰۱۲، مدل شبکه عصبی مصنوعی را برای پیش‌بینی سطح آب زیرزمینی به کار برده‌اند. آنها از مدل بهینه‌سازی مجموعه ذرات برای آموزش شبکه عصبی بهره گرفته‌اند [۱۴].

با بررسی مطالعات گذشته، به نظر می‌رسد پژوهش‌های کیفی آب زیرزمینی، به ویژه پارامتر کیفی نیترات، با گذر زمان اهمیت بیشتری پیدا نموده است و مطالعات شبیه‌سازی-بهینه‌سازی پارامترهای کمی و کیفی آب زیرزمینی، جایگاه خاصی داشته است. علاوه بر آن مدل شبیه‌سازی شبکه عصبی و روش‌های بهینه‌سازی نوین که از اهمیت بالایی برخوردارند، مورد توجه بوده‌اند و بیشتر برای پیش‌بینی غلظت آلاینده‌ها در آب زیرزمینی مورد مطالعه قرار گرفته‌اند. در مورد کنترل آلودگی نیترات و مدیریت بهینه آن در آب زیرزمینی، مطالعات کمتری صورت گرفته است. در این پژوهش

⁴ Genetic algorithm (GA)

⁵ Modflow

¹ CNO3-N

² World Health Organization (WHO)

³ European Union (EU)

برای کنترل آلودگی نیترات در آبخوان کرج ابتدا با یک مدل شبیه سازی شبکه عصبی تغییرات غلظت نیترات در این آبخوان تخمین زده شد. به این منظور، آبخوان کرج به ۱۳ ناحیه بر مبنای شبکه پایش پیرومتری تقسیم شد. شبیه سازی بر اساس نمونه های مشاهداتی از چاه های شرب در طی سال های ۱۳۸۱ تا ۱۳۸۴ صورت پذیرفته و بازه زمانی فصلی انتخاب شد. در نهایت مدل شبیه سازی درون یک مدل بهینه سازی قرار گرفت تا مقادیر برداشت بهینه از سفره، برای قرار گرفتن مقادیر غلظت نیترات در حد مجاز مشخص شود.

۲- الگوریتم مجموعه ذرات

این الگوریتم اولین بار در سال ۱۹۹۵ توسط کندی و ابرهارت بیان شده است [۱۵]. این روش از حرکات منظم جمعی پرندگان و ماهی ها در طبیعت الهام گرفته است که به صورت روابط ریاضی زیر بیان شود.

$$v_i^{n+1} = \chi(w \cdot v_i^n + c_1 r_1^n (p_i^n - x_i^n) + c_2 r_2^n (p_g^n - x_i^n)) \quad (1)$$

$$x_i^{n+1} = x_i^n + v_i^{n+1} \quad (2)$$


رابطه اول، سرعت جدید برای هر یک از ذرات و رابطه دوم، نحوه تغییر موقعیت مکانی ذرات با استفاده از سرعت محاسبه شده را نشان می دهند. در این روابط n شمارنده تعداد تکرار^۱،

^۱ Iteration

۳- منطقه مورد مطالعه

محدوده مورد مطالعه، بخشی از آبرفت تهران-کرج است که مساحتی بالغ بر ۲۱۰ کیلومتر مربع را در بر می گیرد. آبخوان مورد مطالعه در حد فاصل طول های جغرافیایی ۵۲°-۵۰° تا ۳°-۵۱° شرقی و عرض های جغرافیایی ۴۱°-۳۵° تا ۳۵°-۳۴° شمالی واقع شده است. شکل ۱ موقعیت آبخوان مورد مطالعه را در آبرفت تهران-کرج و کشور نمایش می دهد. همچنین محدوده آبخوان بر اساس شبکه پایش پیرومتری به ۱۳ ناحیه تقسیم شده است که در شکل ۱ نمایش داده شده است.

- ^۲ Cognitive
^۳ Social
^۴ Random
^۵ Inertia Weight
^۶ Constriction Factor



شکل ۱- موقعیت محدوده مورد مطالعه در داخل آبرفت تهران-کرج و کشور

۴- نتایج مدل شبکه عصبی

برای تولید ورودی‌های مدل شبکه عصبی، پارامترهای مختلفی از قبیل میزان برداشت، افت سطح آب، ضخامت لایه اشباع و موقعیت جغرافیایی x و y در هر ۱۳ ناحیه محدوده مورد مطالعه در مقیاس فصلی استخراج شدند. در نهایت پارامترهای متغیر میزان برداشت در فصل بررسی (Q_t) و فصل قبل (Q_{t-1})، افت سطح آب dh و مقدار غلظت نیترات در فصل قبل C_{NO_3} ، در هر ناحیه به عنوان بهترین و تخمین‌زننده‌ها انتخاب و تخمین‌زننده‌های ثابت موقعیت جغرافیایی x و y هر ناحیه و ضخامت لایه اشباع (T) به منظور اعمال محل مورد نظر به مدل لحاظ شدند.

داده‌ها به طور تصادفی به دو دسته برای کالیبراسیون و صحت‌سنجی تقسیم شدند. ۷۰ درصد داده‌ها برای کالیبراسیون و ۳۰ درصد برای صحت‌سنجی شبکه عصبی به کار گرفته شدند. شبکه‌های گوناگون با تعداد نرون‌های مختلف و تعداد تکرارهای

مختلف تشکیل شدند. نتایج این شبکه‌ها با تعداد تکرار بهینه ۳۰۰۰۰ در جدول ۱ گزارش شده است.


برای ارزیابی عملکرد و دقت مدل‌های ارائه شده در مراحل کالیبراسیون و صحت‌سنجی، از معیارهای ارزیابی ریشه میانگین مربعات خطا و ضریب رگرسیونی (R^2) استفاده شد. معیار ارزیابی RMSE از جنس تابع هدف آموزش شبکه‌های عصبی MSE است. بر اساس دو معیار ارزیابی R^2 و RMSE مناسب‌ترین مدل انتخاب شد. نتیجه انتخاب بهترین مدل در جدول ۱ ارائه شده است.

مدل تهیه شده دارای دقت خوبی برای شبیه‌سازی غلظت نیترات، با معیار ارزیابی ریشه میانگین مجذور خطا برابر ۷/۶۴۸ در مرحله صحت‌سنجی بود. شکل ۲ نتایج شبیه‌سازی تغییرات غلظت نیترات را در مدل پیشنهادی انتخاب شده در مراحل کالیبراسیون و صحت‌سنجی نمایش می‌دهد.


جدول ۱- مدل‌های پیشنهادی با تعداد نرون‌های مختلف

نرون	کالیبراسیون		صحت‌سنجی	
	R^2	RMSE	R^2	RMSE
۱	۰/۶۰۱۳	۷/۱۸۶۳	۰/۵۶۷۲	۸/۱۱۸۳
۲	۰/۶۲۵۱	۶/۷۷۱۴	۰/۵۶۳۵	۸/۱۳۳۸
۳	۰/۶۸۴۰	۶/۲۱۷۷	۰/۶۰۵۱	۷/۹۵۲۴
۴*	۰/۷۹۵۶	۵/۰۷۹۹	۰/۶۲۰۹	۷/۶۴۸۳
۵	۰/۷۲۱۵	۵/۸۴۸۰	۰/۵۲۸۲	۸/۶۸۴۷
۶	۰/۷۸۴۰	۵/۱۴۴۰	۰/۵۲۹۰	۹/۲۴۰۱
۷	۰/۸۴۸۹	۴/۳۰۷۴	۰/۴۴۶۹	۱۱/۵۸۷۲
۸	۰/۸۸۷۸	۳/۷۰۵۳	۰/۳۳۱۵	۱۳/۳۸۸۰
۹	۰/۸۶۵۰	۴/۱۳۲۱	۰/۳۷۶۱	۱۳/۵۴۰۱

*مدل انتخاب شده از بین مدل‌های بررسی شده



شکل ۲- نتایج شبیه‌سازی غلظت نیترات از مدل پیشنهادی



شکل ۳- حساسیت مدل شبکه عصبی انتخابی نسبت به پارامترهای ورودی

$$\min OF = \sum_{t=1}^{nseason} \left(\left(\sum_{z=1}^{nz} Q_t^z \right) - D_t \right)^2 + \text{LossFunction} \quad (3)$$

که در آن

t گام زمانی مدل سازی در مقیاس فصلی در طی سال های ۱۳۸۱ تا ۱۳۸۴، nz تعداد ناحیه (۱۳ ناحیه بر مبنای شبکه پایش پیژومترها)، Q_t^z میزان برداشت بهینه از هر ناحیه در هر گام زمانی مدل سازی، D_t نیاز محدوده مورد مطالعه در هر گام زمانی مدل سازی و LossFunction میزان جریمه است.

قیدهای در نظر گرفته شده برای این مسئله به صورت زیر است

$$C_{NO_3}^z \leq C_{NO_3}^{Es \tan dart} \quad (\text{for } z = (1, \dots, nz)) \quad (4)$$

که در این رابطه

$C_{NO_3}^z$ غلظت نیترات در هر ناحیه و $C_{NO_3}^{Es \tan dart}$ غلظت نیترات استاندارد است. میزان غلظت نیترات استاندارد با توجه به توصیه سازمان بهداشت جهانی و اتحادیه اروپا، در این تحقیق ۵۰ میلی گرم در لیتر نیترات در نظر گرفته شد.

$$\sum_{t=1}^{nseason} \left(\sum_{z=1}^{nz} Q_t^z \right) \leq Q \quad (5)$$

که Q کل برداشت فعلی در منطقه مورد مطالعه است.

در مدل بهینه سازی، دستیابی به تابع هدف به معنای ارضای تمام قیدهایی تعریف شده در مسئله است. بنابراین در صورت عدم برقراری قیدها، میزان جریمه ای به تابع هدف اعمال می شود. در این

۴-۱- آنالیز حساسیت

پس از انتخاب بهترین مدل برای تخمین غلظت نیترات در آبخوان کرج، حساسیت خروجی مدل نسبت به هر یک از پارامترهای ورودی مورد بررسی قرار گرفت. در این پژوهش از روش پیشنهادی یوتانز استفاده شد [۱۹ و ۲۰]. در این روش، پارامتر ورودی مورد نظر، به اندازه مقدار میانگین آن افزایش می یابد و دیگر پارامترها ثابت باقی می ماند. سپس مقدار MSE مدل با تغییر یک پارامتر، به دست آمده و با مقدار MSE بهترین مدل انتخاب شده مقایسه می شود. هر چه این اختلاف بیشتر باشد، نشان دهنده حساسیت خروجی مدل، نسبت به پارامتر ورودی است. همچنین شکل ۳ نتایج آنالیز حساسیت مدل، را به ازای پارامترهای ورودی مختلف نشان می دهد. همانطور که در این شکل ملاحظه می شود، بیشترین حساسیت مدل شبکه عصبی توسعه داده شده، نسبت به پارامتر غلظت نیترات در فصل قبل است، سپس به ترتیب مقدار برداشت در فصل بررسی، مقدار برداشت در فصل ماقبل و موقعیت طول جغرافیایی هر ناحیه حساسیت بیشتری دارند. کمترین حساسیت نیز مربوط به پارامتر افت سطح آب است.

۵- نتایج مدل بهینه سازی

پس از تهیه یک مدل شبیه سازی برای تخمین غلظت نیترات، اقدام به تهیه یک مدل بهینه ساز شد تا با تلفیق دو مدل، میزان برداشت بهینه از سفره آب زیرزمینی تعیین شود. تابع هدف در این مسئله به صورت زیر تعریف می شود

مسئله به ازای دو قید تعریف شده در بالا، جریمه‌ای در نظر گرفته شده است که به صورت زیر تعریف می‌شود

$$\text{LossFunction} = \sum_{t=1}^{\text{nseason}} \sum_{z=1}^{nz} \left(\text{MAX} \left(\left(\frac{C_{\text{NO}_3}^{\text{tz}}}{C_{\text{NO}_3}^{\text{Estan dart}}} - 1 \right), 0 \right) + \text{MAX} \left(\left(\frac{\sum_{t=1}^{\text{nseason}} \sum_{z=1}^{nz} Q_t^z}{Q} - 1 \right), 0 \right) \right) * a \quad (6)$$

که a عدد ثابتی است که وزن جریمه را تعیین می‌کند و در این مسئله برابر 10^5 انتخاب شده است.

پس از معرفی پارامترهای الگوریتم و لینک آن با مدل شبکه عصبی، به تعداد ذرات الگوریتم، مجموعه‌های تصادفی در حدود تعیین شده برای برداشت‌ها (متغیر تصمیم) تولید شد. سپس تابع هدف محاسبه شد و مدل شبکه عصبی برای هر مجموعه اجرا و غلظت نیترات تخمین زده شد. در ادامه، قیودات تعریف شده مدل بررسی شد و در صورت تخطی، جریمه مورد نظر به تابع هدف افزوده شد. به این ترتیب جواب‌های نامطلوب از مجموعه‌های ذرات حذف نشد، بلکه برای هر یک از آن‌ها جریمه‌ای متناسب با مقدار تخلف در نظر گرفته شد.

در این الگوریتم بهینه‌سازی، هر ذره یک موقعیت و سرعتی دارد که در هر مرحله اجرای الگوریتم به‌هنگام‌سازی می‌شود. بنابراین پس از بررسی مراحل مذکور، مجموعه ذرات تصادفی به‌هنگام‌سازی شده و دوباره به ابتدای الگوریتم وارد، و تابع هدف آن محاسبه می‌شود. این روند به ازای بیشترین تعداد تکرار تعریف شده اجرا می‌شود. در نهایت بهترین مجموعه با ارضای قیودات و کمترین تابع هدف حاصل می‌شود.

مقدار مطلوب پارامترهای الگوریتم در جدول ۲ گزارش شده است. همانطور که در این جدول مشاهده می‌شود، تعداد ذرات ۲۰۰ و تعداد تکرار ۱۵۶۰ در نظر گرفته شد. همچنین ضرایب شناختی (C_1) و اجتماعی (C_2) برابر ۰/۸ لحاظ شد. مدل بهینه‌سازی توسعه داده شده، ۱۰ بار اجرا شد. برای مقایسه و انتخاب بهترین حالت از میان ۱۰ بار اجرای برنامه، از معیار تابع هدف بهره گرفته شد. معیار تابع هدف، براساس مقدار نهایی تابع هدف در آخرین تکرار اجرای برنامه است. نتایج حاصل از ۱۰ بار اجرای الگوریتم در جدول ۳ آمده است. طبق جدول ۳، حداقل مقدار تابع هدف برای این مسئله پس از ۱۰ بار اجرا، ۳۰/۴۲۹۳۳ و میانگین تابع هدف آن پس از ۱۰ بار اجرا، ۳۰/۴۳۴۸۱ به‌دست آمد.

۶- ارزیابی نتایج

در جدول ۴ مقادیر برداشت‌های فعلی و بهینه حاصل از این الگوریتم در ۱۳ ناحیه ارائه شده است. همانطور که در این جدول ملاحظه می‌شود، با در نظر گرفتن سیاست برداشت‌های بهینه برای

جدول ۲- مقدار مطلوب پارامترهای الگوریتم مجموعه ذرات

C_1	C_2	تعداد ذرات	$V_{\min}$	$V_{\max}$	$W_{\min}$	$W_{\max}$	n
۰/۸	۰/۸	۲۰۰	-۱	۱	۰/۴	۰/۹	۱۵۶۰

جدول ۳- نتایج حاصل از ۱۰ بار اجرای الگوریتم بهینه‌سازی مجموعه ذرات

شماره اجرای برنامه	مقدار تابع هدف
۱	۳۰/۴۳۱۹۶
۲	۳۰/۴۳۰۱۳
۳	۳۰/۴۳۰۴۳
۴	۳۰/۴۲۹۳۳
۵	۳۰/۴۲۹۸۳
۶	۳۰/۴۲۹۹۷
۷	۳۰/۴۲۹۷۴
۸	۳۰/۴۳۰۸۸
۹	۳۰/۴۳۱۳۰
۱۰	۳۰/۴۳۴۸۱
میانگین	۳۰/۴۳۰۸۴
انحراف معیار	۰/۰۰۱۶۱
حداقل	۳۰/۴۲۹۳۳
حداکثر	۳۰/۴۳۴۸۱

جدول ۴- مقادیر برداشت در شرایط فعلی و بهینه حاصل از روش مجموعه ذرات برای هر ناحیه

ناحیه	مقدار برداشت فعلی (MCM)	مقدار برداشت بهینه (MCM)	میزان افزایش یا کاهش برداشت	سیاست برداشت
۱	۱۹/۵۲	۱۳/۰۲	-۰/۱۵۵	کاهش برداشت
۲	۲۰/۵۳	۱۳/۴۹	-۰/۱۶۸	کاهش برداشت
۳	۱۱/۵۱	۱۳/۷۷	۰/۰۵۴	افزایش برداشت
۴	۱۵/۶۷	۱۵/۳۴	-۰/۰۰۸	کاهش برداشت
۵	۱۴/۱۱	۱۴/۵۱	۰/۰۱۰	افزایش برداشت
۶	۱۶/۶۶	۱۳/۵۸	-۰/۰۷۳	کاهش برداشت
۷	۶/۴۴	۱۳/۶۷	۰/۱۷۳	افزایش برداشت
۸	۹/۸۴	۱۲/۹۰	۰/۰۷۳	افزایش برداشت
۹	۱۴/۱۸	۱۵/۰۶	۰/۰۲۱	افزایش برداشت
۱۰	۱۴/۶۰	۱۳/۸۶	-۰/۰۱۸	کاهش برداشت
۱۱	۵/۹۰	۱۳/۰۲	۰/۱۷۰	افزایش برداشت
۱۲	۱۷/۶۲	۱۵/۳۵	-۰/۰۵۴	کاهش برداشت
۱۳	۱۵/۴۲	۱۴/۴۴	-۰/۰۲۳	کاهش برداشت
مجموع	۱۸۲/۰۰	۱۸۲/۰۰		


نمایش داده شده است. همانطور که در این شکل ملاحظه می شود، این مدل بهینه سازی به خوبی توانسته مقادیر برداشت را به مقادیر نیاز نزدیک ساخته و فاصله بین برداشت و نیاز را به حداقل برساند.

۷- نتیجه گیری

در پژوهش حاضر، ابتدا با تهیه یک مدل شبکه عصبی مصنوعی، غلظت نیترات تخمین زده شد و در قالب یکی از قیود وارد مدل بهینه سازی شد و به این ترتیب با ارضای این قید که باید کمتر از غلظت نیترات در حد استاندارد باشد، برداشت های بهینه در منطقه به دست آمد. لذا با تغییر در سیاست برداشت، می توان غلظت نیترات را کنترل نمود تا در حد مجاز باقی بماند. سیاست برداشت بهینه ای که از این روش به دست می آید، حاکی از کاهش برداشت به ترتیب برابر ۵/۶، ۰/۴، ۷/۰۳۳، ۰/۰۸۳، ۰/۷۴، ۲/۲۷ و ۰/۹۸ میلیون مترمکعب، از ناحیه های ۱، ۲، ۴، ۶، ۱۰، ۱۲، ۱۳ و به تبع آن افزایش برداشت به ترتیب برابر ۲/۲۶، ۰/۴، ۷/۲۳، ۳/۰۶، ۰/۸۸ و ۷/۱۲ میلیون مترمکعب از ناحیه های ۳، ۵، ۷، ۸، ۹ و ۱۱ است تا غلظت نیترات از حد استاندارد تخطی ننماید. این نتایج در حالی است که کل برداشت از محدوده در حد برداشت فعلی و ثابت نگه داشته شود، زیرا آبخوان کرج در سال های اخیر با افزایش برداشت بی رویه و نیز کسری مخزن مواجه شده است.

هر ناحیه در منطقه، باید برداشت ها در هفت ناحیه ۴، ۶، ۱۰، ۱۲، ۱، ۲ و ۱۳ کاهش و در ناحیه های ۳، ۷، ۸، ۵، ۹ و ۱۱ افزایش یابد تا غلظت نیترات از استاندارد تخطی ننماید. بنابراین به کمک مدل شبیه سازی، ناحیه هایی که آلودگی بالایی از نیترات دارند، شناسایی شده و برای کاهش این آلودگی، مقدار برداشت بهینه از هر ناحیه به کمک مدل بهینه سازی به دست آمد. این نتایج با ثابت نگه داشتن برداشت کلی از منطقه انجام شد.

برای توصیف بهتر تابع هدف در این مسئله، در شکل ۴ مقدار کل نیاز منطقه مورد مطالعه در طول فصل های مدل سازی، در برابر بهترین سیاست برداشت بهینه حاصل از الگوریتم مجموعه ذرات



شکل ۴- نمایش نیاز آبی و برداشت بهینه از روش مجموعه ذرات برای کل محدوده در طول فصل های مدل سازی

۸- مراجع

1. World Health Organization. (2007). *Guidelines for drinking water quality*, Vol 1, recommendations, 3rd Ed., WHO, Geneva.

2. Institute of Standards and Industrial Research of Iran. (2007). *Potable water the physical and chemical characteristics*, 5th Ed., The National Iranian Standard in 1053, Tehran, Iran. (In Persian)
3. Imandel, K. (1998). "Ascending trend of nitrate contamination in wells of Tehran west aquifer." *J. Iran Biomedical*, 196, 1-4. (In Persian)
4. Lee, S.M., Min, K.D., Woo, N.C., Kin, Y.J., and Ahn, C.H. (2003). "Statistical models for the assessment of nitrate contamination in urban groundwater using GIS." *J. Environmental Geology*, 44, 210-221.
5. Almasri, M.N., and Kaluarachchi, J. (2004). "Multi-criteria decision analysis for the optimal management of nitrate contamination of aquifers." *J. Environmental Management*, 74(4), 365-381.
6. Prakasa Roa, E. V. S., and Puttanna, K. (2006). "Strategies for combating nitrate pollution." *J. Current Science*, 91(10), 1335-1339
7. Rogers, L. L., and Dowla, F. U. (1994). "Optimization of groundwater remediation using artificial neural networks and parallel solute transport modeling." *J. Water Resources*, 30(2), 457-481.
8. Wang, M., and Zheng, C. (1998). "Groundwater management optimization using genetic algorithms and simulated annealing formulation and comparison." *J. Water Resources*, 34(3), 519-530.
9. Ramasamy, N., Krishnan, P., Bernard, J.C., and Ritter, W. F. (2003). "Modeling nitrate concentration in groundwater using regression and neural networks." Department of Food and Resource Economics, University of Delaware, New York.
10. Yesilnacar, M.I., Sahinkaya, E., Naz, M., and Ozkaya, B. (2008). "Neural network prediction of nitrate in groundwater of Harran Plain, Turkey." *J. Environmental Geology*, 56, 19-25.
11. Nasserli, M., Tajrishy, M., Nikoo, M.R., and Zaherpour, J. (2011). "Recognition and spatial mapping of multivariate groundwater quality index using combined fuzzy method." *J. Water and Wastewater*, 85, 82-93. (In Persian)
12. Moashrei, S.A., Tabatabaie, S.M., Razaghi, P., Sarani, N., and Eslami Mahdi Abadi, S.H. (2012). "Estimating the groundwater nitrate by using artificial neural network and optimizing it by genetic algorithm." *Proc. Environment and Civil Engineering*, Kuala Lumpur, Malaysia, 85-92.
13. Zare Abyaneh, H., Bayat Varkeshi, M., Akhavan, S., and Mohammadi, M. (2011). "Estimation of nitrate in hamedan-bahar plain groundwater using artificial neural network and effect of data resolution on prediction accuracy." *J. Environmental Studies*, 37(58), 129-140.
14. Tapoglou, E., Trichakis, I.C., Dokou, Z., and Karatzas, G.P. (2012). "Groundwater level forecasting using an artificial neural network trained with particle swarm optimization." *Proc. Geophysical Research*, Brono-kreisky-platzl, Vienna, Austria, 2405.
15. Kennedy, J., and Eberhart, R. C. (1998). "Particle swarm optimization." *Proc. Neural Network*, Piscataway, Perth. Australia, 1942-1948.
16. Fallah Mehdipoor, E. (2008). "Application multipurpose evolutionary optimization method in multi reservoir system operation." M.S. Thesis, University of Tehran, Iran. (In Persian)
17. Parsopoulos, K.E., and Vrahatis, M.N. (2002). "Recent approaches to global optimization problems through particle swarm optimization." *J. Natural Computing*, 1(2-3), 235-306.
18. Tang, Y., and Guan, X. (2007). "Parameter estimation for time-delay chaotic system by particle swarm optimization." *J. Chaos, Solitons and Fractals*, 44, 198-207.
19. Redondo, M.F., and Espinosa, C.H. (1999). "Input selection by multilayer feed forward trained networks." *Proc. Neural Networks*, Washington, DC., 3, 1834-1839.
20. Utans, J., Moody, J., Rehfsuss, S., and Siegelmann, H. (1995). "Input variable selection for neural networks: Application to prediction the U.S Business cycle." *Proc. Computational Intelligence for Financial Engineering*, New York, 118-122.