



Simultaneous Optimization of Effective Factors on Artificial Neural Network Performance Using Box-Behnken Design and Fuzzy Programming

M. Bashiri* & A. Farshbaf-Geranmayeh

Mahdi Bashiri Associate professor of Industrial Eng-Shahed University, bashiri@shahed.ac.ir
Amir Farshbaf-Geranmayeh MSc student of Industrial Eng-Shahed University

Keywords

Artificial Neural Network,
parameter tuning,
Box-Behnken design,
Fuzzy programming

ABSTRACT

Tuning parameters has the most important effect in performance of Neural Network. Main problem in using of ANN is parameter tuning because there is no definite and explicit method to select optimal parameters for the ANN parameters. In this study, three artificial neural network performance criteria and also three important factors which affect the selected criteria have been introduced. Moreover, Box-Behnken design has been applied to analyze the ANN structure parameters and its performance. The proposed approach has been implemented for a simulated process according to a complex mathematical function. After extracting relation between controllable factors and performance criteria, fuzzy programming is used for finding the optimal combination of controllable factors in order the best performance of Neural Network. Results attained from the numerical example show efficiency of the proposed method. Generally, proposed approach can be used for tuning of neural network's parameters in other problems.

© 2013 IUST Publication, IJIEPM. Vol. 24, No. 1, All Rights Reserved

*
Corresponding author. Mahdi Bashiri
Email: Bashiri@shahed.ac.ir

بهینه سازی همزمان عوامل تاثیرگذار بر عملکرد شبکه عصبی مصنوعی با استفاده از طرح باکس - بنکن و برنامه ریزی فازی

مهدی بشیری* و امیر فرشباف گرانیماه

چکیده:

اندازه و همچنین پارامترهای آموزش شبکه عصبی تاثیر مهمی در عملکرد آن دارد. تاکنون هیچ روش ثابت و یا خط مشی سیستماتیک برای طراحی ساختار بهینه ی شبکه عصبی وجود ندارد. در این مطالعه، سه معیار به عنوان معیارهای عملکرد شبکه عصبی مصنوعی و سه عامل کنترلی که بیشترین تاثیر را روی معیارهای عملکرد دارند، معرفی شده اند. علاوه بر آن طرح باکس- بنکن برای طراحی آزمایشات مربوط به تنظیم پارامترها بکار برده شده است. بررسی یک فرآیند واقعی برای چنین موضوعاتی از اهمیت ویژه ای برخوردار می باشد، لیکن به منظور بررسی و پیش بینی عملکرد روش پیشنهادی، فرض شده است که متغیر خروجی فرآیند شبیه سازی شده دارای یک تابع نسبتا پیچیده اما معین با متغیرهای ورودی می باشد. بعد از استخراج روابط عوامل کنترلی و معیارهای عملکرد تعیین شده مرتبط با شبکه عصبی طراحی شده، روش برنامه ریزی فازی برای یافتن بهینه ترین ترکیب عوامل کنترلی جهت بهترین عملکرد شبکه عصبی مصنوعی بکار گرفته شده است. نتایج حاصل از مقایسه روش پیشنهادی با روش تنظیم پارامترها با استفاده از الگوریتم ژنتیک، نشانگر کارایی روش پیشنهادی است. این رویکرد می تواند برای تنظیم پارامترها در حل انواع مختلف مسائل با استفاده از شبکه عصبی مصنوعی استفاده شود.

کلمات کلیدی

شبکه عصبی مصنوعی ،
تنظیم پارامترها ،
طرح باکس - بنکن ،
برنامه ریزی فازی.

۱. مقدمه

امروزه از شبکه های عصبی مصنوعی بطور گسترده ای برای حل مسائل پیچیده استفاده می شود. از جمله کاربردهایی شبکه عصبی مصنوعی می توان به کاربرد آن در هوا و فضا ، حمل و نقل ، امور مالی ، امور دفاعی ، ساخت و تولید ، رباتیک ، تشخیص

گفتار ، الکترونیک و پزشکی اشاره کرد [۱]. بطور کلی روش پس انتشار خطا برای آموزش شبکه عصبی مصنوعی بکار می رود [۲]. برای مطالعه بیشتر در مورد نحوه محاسبات در روش پس انتشار خطا به [۳] رجوع شود.

یکی دیگر از کاربردهای مهم شبکه عصبی مصنوعی، حل مسائل چند پاسخ می باشد که در دهه اخیر مطالعات زیادی در این حوزه صورت گرفته است [۴-۶]. در اغلب این مطالعات از شبکه عصبی مصنوعی برای تخمین روابط بین متغیرهای قابل کنترل و متغیرهای پاسخ استفاده شده است که برای دستیابی به تخمین دقیق این روابط نیاز مبرمی به تنظیم پارامترهای شبکه عصبی مصنوعی وجود دارد.

تاریخ وصول: ۹۰/۴/۵

تاریخ تصویب: ۹۰/۱۰/۱۳

*نویسنده مسئول مقاله: دکتر مهدی بشیری، دانشیار گروه مهندسی صنایع

دانشکده فنی و مهندسی دانشگاه شاهد ، Bashiri@shahed.ac.ir

امیر فرشباف گرانیماه، دانشجوی کارشناسی ارشد مهندسی صنایع دانشگاه

شاهد ، Farshbaf@shahed.ac.ir

آزمایشات تاگوچی، به تنظیم پارامترهای الگوریتم ژنتیک (GA)^۳، الگوریتم انجماد تدریجی (SA)^۴ و الگوریتم جستجوی ممنوعه پرداختند [۹]. بشیری و کریمی [۱۰] از طرحهای عامل کلی جهت تنظیم پارامترهای الگوریتم جستجوی ممنوعه در حل مسئله تخصیص مضاعف^۵ استفاده نمودند.

برخی از نویسندگان از روش های فراابتکاری برای تنظیم ساختار و پارامترهای شبکه عصبی مصنوعی استفاده نمودند. آریفویچ و گنچای [۱۱] از الگوریتم ژنتیک برای تعیین ساختار شبکه عصبی پیشخور استفاده نمود. لوانگ و همکاران [۱۲] با استفاده از الگوریتم ژنتیک بهبود داده شده به تنظیم پارامترها و ساختار شبکه عصبی پرداختند. سپس تسای و همکاران [۱۳] با بهره گیری از مدلی که توسط لوانگ پیشنهاد شده بود، ترکیب الگوریتم ژنتیک و روش تاگوچی را برای بهبود روش قبلی ارائه داد. در ادامه ژاو و کیان [۱۴] برای این منظور از الگوریتم باینری هوش جمعی ذرات استفاده نموده است.

خوب یا بد بودن نتایج حاصل از روش های فرا ابتکاری وابسته به تنظیم مناسب پارامترهای مربوط به خود الگوریتم های فرا ابتکاری می باشد [۱۵]. همچنین بدلیل زمانبر بودن این روش ها نسبت به روش های طراحی آزمایشات، برای تعیین بهترین ترکیب پارامترهای تاثیرگذار در عملکرد شبکه عصبی مصنوعی استفاده کرده اند. خاو و همکاران [۱۶] از روش تاگوچی و همچنین از دو مجموعه داده شبیه سازی شده برای تعیین پارامترهای اثرگذار شبکه عصبی مصنوعی که سبب افزایش سرعت و همگرایی الگوریتم پس انتشار خطا می شود، استفاده کرده است. پترسون و همکاران [۱۷] روش تاگوچی را برای جستجوی خطاها در روش پس انتشار خطا بکارگرفته اند. یانگ ولی [۱۸] با استفاده از روش تاگوچی به حداقل کردن زمان آموزش در شبکه عصبی مصنوعی پرداخته است. پاکیانانتر و همکاران [۱۹] برای نشان دادن اثر طراحی پارامترها و همچنین رفتار شبکه عصبی مصنوعی در بازرسی روکش چوبی از روش تاگوچی استفاده کرده است. یام و کیم [۲۰] با در نظر گرفتن عامل اغتشاش از روش پویای تاگوچی برای طراحی شبکه عصبی پیش خور استفاده کرده است. سوکتومیا و تانوک [۲۱] با بکارگیری روش تاگوچی به شناسایی بهترین ترکیب عوامل کنترلی در شبکه عصبی مصنوعی پرداخته و استفاده از این رویکرد را در تولید نشان داده است. تور توم و همکاران [۲۲] از روش تاگوچی برای یافتن بهترین ترکیب عوامل تاثیرگذار در شبکه عصبی استفاده کرده و همچنین به تحلیل

در روش های سنتی، پارامترهای شبکه عصبی با استفاده از سعی و خطا تنظیم می شود که معمولاً روش زمانبری است. بنابراین، یافتن روشی برای تعیین بهترین ترکیب پارامترهای کنترلی که بر روی عملکرد شبکه عصبی مصنوعی تاثیرگذارند، ضروری به نظر میرسد.

در این مقاله، پس از شناسایی معیارهای عملکرد شبکه عصبی مصنوعی و عوامل قابل کنترل تاثیرگذار در آنها، طراحی آزمایشات با استفاده از روش باکس-بنکن صورت می پذیرد. پس از ثبت آزمایشات انجام داده شده، آنالیز واریانس روی آنها صورت گرفته و عوامل غیراثرگذار حذف می گردند. سپس به یافتن رابطه رگرسیون بین عوامل کنترلی شناسایی شده و معیارهای عملکرد تعیین شده برای شبکه عصبی مصنوعی پرداخته می شود. در ادامه روش برنامه ریزی فازی به منظور یافتن ترکیبی از عوامل کنترلی که موجب بهترین عملکرد شبکه عصبی شود، بکار گرفته می شود.

همانگونه که ذکر شد، در اغلب مطالعات انجام شده مرتبط، از شبکه عصبی برای بهینه سازی متغیرهای کنترلی در مسائل چند پاسخی استفاده می شود در حالیکه مطالعه حاضر از رویکرد بهینه سازی چند پاسخی در تنظیم پارامترهای شبکه عصبی استفاده می نماید. ساختار مقاله بدین صورت میباشد که در بخش دوم بصورت اجمالی مروری بر رویکردهای مختلفی که به تنظیم پارامترها پرداخته اند، صورت می گیرد. در بخش سوم رویکرد پیشنهاد شده این مطالعه مبتنی بر برنامه ریزی فازی در بهینه سازی چند پاسخی برای تنظیم پارامترهای شبکه عصبی معرفی می گردد. در ادامه، یک مثال عددی برای تشریح روش پیشنهادی مورد بررسی و تحلیل قرار گرفته و در نهایت نتایج بدست آمده، در بخش پنجم بیان می شود.

۲. مرور ادبیات

بعلت اهمیت موضوع تنظیم پارامترها در عملکرد الگوریتمها، محققان بسیاری روشهای مختلفی را برای تنظیم پارامترهای الگوریتمهای فرا ابتکاری بکاربرده اند. شی و ابرهات [۷] خط مشی هایی برای انتخاب پارامترهای الگوریتم بهینه سازی تجمع ذرات^۱ ارائه کرده و برای تائید این خطوط مشی از طراحی آزمایشات استفاده نمودند. خو و همکاران [۸] با استفاده از تست های آماری به تنظیم پارامترهای الگوریتم جستجوی ممنوعه (TS)^۲ پرداختند. زندیه و همکاران با استفاده از روش طراحی

³ Genetic Algorithm

⁴ Simulated Annealing

⁵ Quadratic Assignment Problem (QAP)

¹ Particle Swarm Optimization (PSO)

² Tabu Search

تاثیر هریک از پارامترها در عملکرد شبکه عصبی پرداخته اند. متغیرهای قابل کنترل در نظر گرفته شده، نشان می دهد. جدول ۱ این مطالعات را به تفکیک معیارهای عملکرد و

جدول ۱. مطالعات تنظیم پارامترهای شبکه عصبی با استفاده از طراحی آزمایشات به تفکیک معیارهای عملکرد و متغیرهای قابل کنترل در نظر گرفته شده

نویسندگان	متغیرهای قابل کنترل	متغیرهای نوین	معیارهای عملکرد	روش استفاده شده برای طراحی آزمایشات
خاو و همکاران (۱۹۹۵)	<ul style="list-style-type: none"> تعداد لایه های پنهان تعداد نورونها در لایه پنهان اول تعداد نورونها در لایه پنهان دوم رویه ارائه ورودیها اندازه مجموعه داده های آموزش نرخ یادگیری 	<ul style="list-style-type: none"> وزنهای اولیه 	<ul style="list-style-type: none"> دقت تخمین زمان آموزش 	تاگوچی
پترسون و همکاران (۱۹۹۵)	<ul style="list-style-type: none"> اندازه مجموعه داده های آموزش مقدار نویز در داده های آموزش مقدار نویز در داده های تست ساختار شبکه 	<ul style="list-style-type: none"> انتخاب تصادفی داده های آموزش 	<ul style="list-style-type: none"> دقت تخمین (میانگین جذر میانگین مربعات خطا) 	تاگوچی
یانگ ولی (۱۹۹۹)	<ul style="list-style-type: none"> نرخ خطا تعداد نورونهای لایه پنهان اندازه مجموعه داده های آموزش مومنتم بازه وزنهای اولیه افزایش نرخ یادگیری کاهش نرخ یادگیری 	<ul style="list-style-type: none"> زمان آموزش (نسبت سیگنال به نویز) 		تاگوچی
پاکیانتر و همکاران (۲۰۰۰)	<ul style="list-style-type: none"> نرخ آموزش مومنتم تعداد نورونها در لایه پنهان اول تعداد نورونها در لایه پنهان دوم 	<ul style="list-style-type: none"> وزنهای اولیه انتخاب تصادفی داده های آموزش 	<ul style="list-style-type: none"> دقت تخمین (نسبت سیگنال به نویز) 	تاگوچی
یام و کیم (۲۰۰۴)	<ul style="list-style-type: none"> تعداد نورونها در لایه پنهان اول تعداد نورونها در لایه پنهان دوم نرخ یادگیری مومنتم 	<ul style="list-style-type: none"> وزنهای اولیه نسبت داده های آموزش در مقابل نسبت داده های تست انتخاب مجموعه داده های تست و آموزش 	<ul style="list-style-type: none"> دقت تخمین (نسبت سیگنال به نویز) 	تاگوچی
سوکنومیا و تانوک (۲۰۰۵)	<ul style="list-style-type: none"> الگوریتم یادگیری تعداد لایه ها تعداد نورونها تابع فعالسازی درصد داده های تست اشاره^۱ 	<ul style="list-style-type: none"> ضریب همبستگی 		تاگوچی
تورتوم و همکاران (۲۰۰۷)	<ul style="list-style-type: none"> نحوه ارائه داده های ورودی تعداد نورونها در لایه پنهان اول تعداد نورونها در لایه پنهان دوم تابع فعالسازی 	<ul style="list-style-type: none"> معیار اطلاعات آکایک (AIC)^۲ نرمال میانگین مربعات خطا (NMSE)^۳ جذر میانگین مربعات خطا (RMSE)^۴ زمان آموزش (TT)^۵ 	<ul style="list-style-type: none"> معیار اطلاعات آکایک (AIC)^۲ نرمال میانگین مربعات خطا (NMSE)^۳ جذر میانگین مربعات خطا (RMSE)^۴ زمان آموزش (TT)^۵ 	تاگوچی

1 hint

2 Akaike's Information Criterion

3 Normalized Mean Square Error

4 Root Mean Square Error

5 Training Time

اولین معیار عملکرد در نظر گرفته شده، میانگین مجموع مربعات خطای بین خروجی شبکه عصبی مصنوعی به ازای داده های مورد استفاده در تست شبکه و خروجی واقعی متناظر با همان ورودیهاست. بدیهیست که این متغیر پاسخ از نوع هرچه کوچکتر بهتر (STB) میباشد.

دومین معیار عملکرد مورد استفاده در این مطالعه، ضریب همبستگی (R-Value) بین خروجی شبکه عصبی مصنوعی و خروجی واقعی میباشد. این متغیر مقداری بین صفر و یک می گیرد که نزدیکی مقدار این متغیر به عدد یک نشاندهنده وجود همبستگی مناسب بین خروجی واقعی و خروجی شبکه عصبی مصنوعی و همچنین نزدیکی مقدار این متغیر به عدد صفر نشاندهنده وجود همبستگی ضعیف است. بنابراین نوع این متغیر پاسخ هرچه بزرگتر بهتر (LTB) میباشد.

زمانی که طول می کشد تا شبکه عصبی مصنوعی آموزش ببیند (TT)؛ سومین معیار عملکرد بکار رفته در این مطالعه می باشد. بدیهیست که نوع این متغیر پاسخ نیز همچون متغیر پاسخ اول، هرچه کوچکتر بهتر (STB) میباشد. همانطور که در جدول ۱ نیز مشاهده می شود، در هیچکدام از رویکردهای پیشین این سه معیار بصورت همزمان به عنوان معیارهای عملکرد شبکه عصبی مصنوعی در نظر گرفته نشده اند.

باتوجه به اهمیت هر یک از متغیرهای پاسخ، برای هر یک از آنها وزن تخصیص داده می شود. در مورد اهمیت هر یک از متغیرهای پاسخ و همچنین نحوه بکارگیری وزنها تخصیص داده شده، در بخش های آتی به تفصیل توضیح داده خواهد شد.

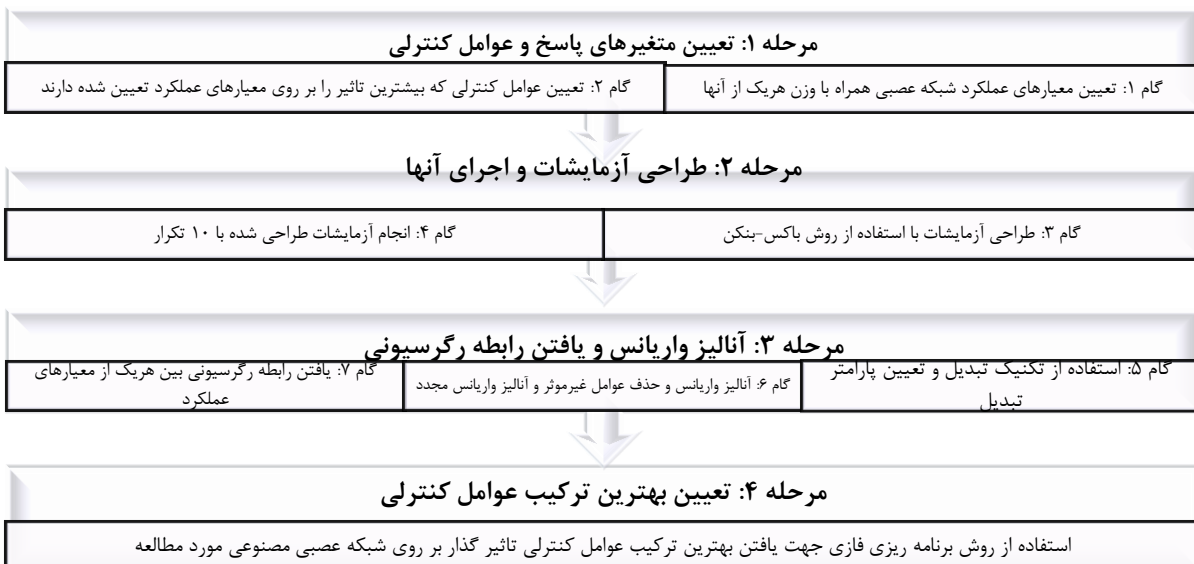
همانگونه که در جدول ۱ ملاحظه می شود، تمامی رویکردهای بکار رفته در مطالعات پیشین، از روش تاگوچی برای تنظیم پارامترهای شبکه عصبی مصنوعی و همچنین یافتن بهترین ترکیب پارامترهای تاثیرگذار استفاده کرده اند. میرز و همکاران [۲۳] نشان داده اند که روش سطح پاسخ جایگزین مناسبی برای روش تاگوچی میباشد. بدیهیست که در روش تاگوچی جواب بهینه هر یک از پارامترها بر روی یکی از سطوح از پیش تعیین شده برای آن پارامتر واقع است. بنابراین برای دستیابی به پاسخی دقیقتر، استفاده از روشهای دیگر طراحی آزمایشات که بتوان فواصل بین سطوح تعیین شده برای هر یک از پارامترها را نیز در نظر گرفت، ضروری به نظر میرسد. همانطور که پیشتر نیز بیان شد، در این مقاله از یک رویکرد پیشنهادی مبتنی بر روش بهینه سازی سطوح چند پاسخ و برنامه ریزی فازی برای تنظیم ساختار شبکه عصبی استفاده شده است.

۳. رویکرد پیشنهادی

۳-۱. تعیین معیارهای عملکرد شبکه عصبی مصنوعی

همراه با وزن هر یک از آنها

مراحل رویکرد پیشنهادی در شکل ۱ نشان داده شده است. اولین مرحله در این رویکرد را تعیین معیارهای عملکرد شبکه عصبی مصنوعی تشکیل می دهد. در این مرحله بایستی معیارهایی انتخاب شوند که عملکرد شبکه عصبی مصنوعی را بدرستی نشان می دهند. معیارهایی که در این مطالعه مورد استفاده قرار گرفته اند، در جدول ۲ نشان داده شده اند.



شکل ۱. فلوچارت رویکرد پیشنهادی تنظیم پارامترهای یک شبکه عصبی مصنوعی

جدول ۲. معیارهای عملکرد شبکه عصبی مصنوعی

میانگین مجموع مربعات خطای داده های تست	میانگین مجموع مربعات خطای بین خروجی شبکه عصبی مصنوعی به ازای داده های مورد استفاده در تست شبکه و خروجی واقعی متناظر با همان ورودیها
ضریب همبستگی	ضریب همبستگی بین خروجی شبکه عصبی مصنوعی و خروجی واقعی
زمان آموزش	زمانی که طول می کشد تا شبکه عصبی مصنوعی آموزش ببیند.

کنترلی در نظر گرفته شده اند. به عبارت دیگر اگر مثلا در آزمایشی داده های آموزش ۷۵ درصد کل داده ها را تشکیل دهد بدین معنی است که ۵ درصد کل داده ها برای تصدیق و ۲۰ درصد باقیمانده برای تست شبکه بکار می رود.

ب - تعداد نورونها در اولین لایه پنهان:

تعداد نورونها در اولین لایه پنهان را بدلیل اینکه اکثر توابع را میتوان با شبکه عصبی مصنوعی با یک لایه پنهان آموزش داد، مهمترین عامل کنترلی تاثیرگذار در عملکرد شبکه عصبی مصنوعی نامید. اگرچه تعداد نورون زیاد مستلزم محاسبات پیچیده تری نیز میباشد لیکن ممکن است موجب کارتر بودن نتایج شود.

ج - تعداد نورونها در دومین لایه پنهان:

در مواقعی که روابط نسبتا پیچیده تری بین داده های ورودی و خروجی وجود دارد، ممکن است مجبور به استفاده از شبکه عصبی مصنوعی با دو لایه پنهان برای آموزش شبکه باشیم. در اینصورت تعیین تعداد نورون در لایه پنهان دوم نیز ضروریست. آزمایشهایی که تعداد نورونها در لایه دوم پنهان صفر در نظر گرفته شده اند بدین معنی است که از شبکه عصبی مصنوعی با فقط یک لایه پنهان برای آموزش شبکه استفاده شود. اولین و دومین عامل کنترلی در نظر گرفته شده بزرگی شبکه را تعیین می کنند. برای مسئله مشخص باید شبکه به اندازه کافی بزرگ باشد. اگر تعداد نورونها خیلی کم باشند، شبکه نمی تواند بصورت مناسب روابط بین ورودیها و خروجیها را یادگیری کند. همچنین اگر تعداد نورونها بسیار زیاد باشند شبکه بجای یادگیری روابط بین ورودیها و خروجیها، آنها را ذخیره می کند [۲۴-۲۵].

۳-۲. تعیین عوامل کنترلی که بیشترین تاثیر را بر روی معیارهای عملکرد تعیین شده دارند

مهمترین هدف در این مطالعه، یافتن ترکیبی از عوامل کنترلی است که در آن شرایط شبکه عصبی مصنوعی بهترین عملکرد را داشته باشد. بدین منظور بایستی عوامل کنترلی برای مطالعه انتخاب شوند که بیشترین تاثیر را بر روی عملکرد شبکه عصبی مصنوعی داشته باشند. عوامل کنترلی مورد استفاده قرار گرفته در این مطالعه و همچنین سطوح هر یک در جدول ۳ نشان داده شده اند. هر یک از این عوامل بصورت تفصیلی در ادامه توضیح داده شده اند:

الف - درصد داده های مورد استفاده قرار گرفته جهت آموزش شبکه عصبی مصنوعی:

داده های ورودی به شبکه عصبی مصنوعی به سه دسته داده های آموزش، داده های تست و داده های تصدیق تقسیم میشوند. اولین دسته که داده های آموزش نامیده می شوند، برای محاسبه شیب و همچنین برای بروزرسانی وزنها و بایاسها در شبکه عصبی مصنوعی بکار می روند. داده های تصدیق در حین فرآیند آموزش بررسی می شوند. اگر شبکه شروع به انطباق بیش از حد داده ها کند، خطای تصدیق افزایش پیدا می کند. وقتی که خطای تصدیق به تعداد تکرار مشخصی افزایش پیدا کند، فرآیند آموزش متوقف میشود و وزنها و بایاسهای مربوط به تکراری که در آن خطای تصدیق کمترین مقدار خود را دارد به عنوان وزن و بایاس نهایی بازگردانده میشوند.


در این مقاله، ۵ درصد از کل داده ها به عنوان داده های تصدیق مورد استفاده قرار گرفته است و درصدی از داده ها که به داده های آموزش و تست تخصیص پیدا می کند، عامل

جدول ۳. عوامل کنترلی و سطوح آنها در آزمایشها

عوامل	سطح	
	بالا	پایین
الف) درصد داده های مورد استفاده قرار گرفته جهت آموزش شبکه عصبی مصنوعی	0.9	0.6
ب) تعداد نورونها در اولین لایه پنهان	65	1
ج) تعداد نورونها در دومین لایه پنهان	60	0

توسط زیمرمن [۲۸] توسعه داده شده است. سپس چنگ و همکاران [۲۹] روش زیمرمن را جهت بهینه سازی مسائل چندپاسخه آماری توسعه دادند. یکی از مزایای روش برنامه ریزی فازی جواب های بسیار خوب و مناسبی است که برای مساله بدست می آورد. مراحل اجرای این روش شامل قدمهای زیر می باشد:

قدم: ابتدا تابع هدف هر یک از متغیرهای پاسخ را بطور جداگانه حل می نماییم و جواب ها را بدست می آوریم، این جواب ها را در توابع هدف مربوط به سایر متغیرهای پاسخ قرار می دهیم و در نتیجه برای هر متغیر پاسخ دو مقدار حد بالا و حد پایینی بعنوان بهترین حالت و بدترین حالت بدست میاید. متغیر $\mu(Z_i)$ را به عنوان تابع عضویت فازی متغیر پاسخ Z_j یا سطح دسترسی و یا درصد نزدیکی به حالت بهینه هر یک از اهداف تعریف می کنیم. این تابع عضویت برای متغیر پاسخ از نوع LTB^۱ در شکل ۳ و روابط ریاضی مربوط به آن در معادله ۱ نشان داده شده است.



شکل ۳. تابع عضویت تابع U_k

$$\mu(z_i) = \begin{cases} 1 & \text{اگر } Z_j \leq U_j - \Delta_j \\ \frac{Z_j - (U_j - \Delta_j)}{\Delta_j} & \text{اگر } U_j - \Delta_j \leq Z_j \leq U_j \\ 0 & \text{اگر } Z_j \geq U_j \end{cases} \quad (1)$$

$$\Delta_j = U_j - L_j \quad \text{تولرانس تابع هدف } Z_i$$


اگر متغیر α را به عنوان درصدی که هرمتغیر پاسخ به حالت بهینه خود رسیده باشد، تعریف کنیم روابط زیر صادق خواهند بود.

$$\alpha = \min(\mu(z_1), \mu(z_2), \dots, \mu(z_k)) \quad (2)$$

$$\alpha \leq \mu(z_i) \quad (3)$$

۳-۳. طراحی آزمایشات با استفاده از باکس-بنکن

باکس-بنکن [۲۶] برخی طراحی سه سطحی برای انطباق سطح پاسخ ارائه داده است. این طراحی از ترکیب طرح عاملی 2^k با طرح بلوک ناقص شکل گرفته است. نتایج این طراحی معمولاً با توجه به تعداد آزمایشهای صورت گرفته، کارا میباشد [۲۷]. در این مقاله، ۳ عامل کنترلی در نظر گرفته شده است. طراحی باکس-بنکن برای سه عامل کنترلی در شکل ۲ نشان داده شده است.



شکل ۲. نمودار طرح باکس-بنکن برای ۳ عامل کنترلی

طرح باکس-بنکن یک طرح کروی است که تمامی نقاط روی کره ای به شعاع $\sqrt{2}$ قرار دارند. همچنین در این طرح هیچ نقطه ای روی گوشه مکعب وجود ندارد. به عبارت دیگر ترکیبهایی از سطوح عوامل کنترلی که از ترکیب سطوح بالا و پایین ساخته میشوند، وجود ندارد.

۳-۴. آنالیز واریانس هر یک از معیارهای عملکرد بصورت جداگانه و یافتن رابطه رگرسیونی متغیرهای پاسخ نسبت به عوامل تاثیرگذار

در این مرحله آنالیز واریانس بر روی هر یک از متغیرهای پاسخ صورت می گیرد. آنالیز واریانس مشخص می کند که کدامیک از عوامل کنترلی در هر یک از معیارهای عملکرد شبکه عصبی مصنوعی تاثیرگذار است. بعد از انجام آنالیز واریانس بر روی هر یک از متغیرهای پاسخ، عوامل غیرموثر حذف و آنالیز واریانس دوباره صورت می گیرد. بر اساس ضرایب رگرسیونی حاصل از آنالیز واریانس، روابط رگرسیونی هر یک از متغیرهای پاسخ نسبت به عوامل کنترلی بدست می آید.

۳-۵. استفاده از روش برنامه ریزی فازی جهت یافتن بهترین ترکیب عوامل کنترلی تاثیرگذار

یکی از تکنیکهایی که برای حل مسائل چند هدفی مورد استفاده قرار می گیرد استفاده از برنامه ریزی فازی می باشد، این تکنیک

¹ The larger the better

گرفته است. بطور کلی، الگوریتم پس انتشار لون برگ-مارکورت^۱ ویژگی همگرایی بهتری نسبت به سایر الگوریتم های پس انتشار دارد [۳۱-۳۲]. بنابراین این الگوریتم برای آموزش داده های ورودی و داده های خروجی متناظر آن مورد استفاده قرار گرفته است.

۴-۱. تعیین معیارهای عملکرد شبکه عصبی مصنوعی همراه با وزن هریک از آنها

معیارهای عملکرد شبکه عصبی مصنوعی در قسمت رویکرد پیشنهادی به تفصیل بیان شد. وزن تعیین شده برای هریک از متغیرهای پاسخ در این مثال، در جدول ۴ نشان داده شده اند. بدلیل نسبتا پیچیده بودن تابع مورد استفاده در این مثال، آموزش مناسب نیازمند زمان بیشتری می باشد. در این مثال هدف پیدا کردن بهینه ترین ترکیب پارامترها جهت داشتن کمترین میانگین مجموع مربعات خطای داده های تست و همچنین بیشترین مقدار ضریب همبستگی درضمن خیلی طولانی نبودن زمان آموزش حل است. به عبارت دیگر، توجه زیاد به زمان آموزش سبب پایین بودن عملکرد شبکه عصبی مصنوعی خواهد بود. بنابراین در این مثال، وزن دو معیار میانگین مجموع مربعات خطای داده های تست و ضریب همبستگی دو برابر وزن معیار زمان آموزش در نظر گرفته شده است.

۴-۲. تعیین عوامل کنترلی که بیشترین تاثیر را بر روی معیارهای عملکرد تعیین شده دارند

عوامل کنترلی که بیشترین تاثیر را بر روی معیارهای عملکرد تعیین شده دارند در قسمت رویکرد پیشنهادی همراه با سطوح هریک از آنها به تفصیل توضیح و در جدول ۲ نشان داده شده است.

۴-۳. طراحی آزمایشات با استفاده از باکس-بنکن

پس از تعیین معیارهای عملکرد و عوامل کنترلی و سطوح آنها می توان از روش باکس-بنکن برای طراحی آزمایشات استفاده کرد. در این مثال از نرم افزار آماری مینی تب^۲ برای طراحی آزمایشات استفاده شده است. آزمایشات طراحی شده توسط روش باکس-بنکن برای این مثال در جدول ۵ نشان داده شده اند. تعداد کل آزمایشات طراحی شده ۱۵ آزمایش میباشد که هرکدام از آزمایش ها ۱۰ بار تکرار شده است. تمامی آزمایشات توسط نرم افزار متلب انجام گرفته است. نتایج آزمایشات برای هریک متغیرهای پاسخ در پیوست الف-ج نشان داده شده اند.

در نهایت با حل مدل زیرجواب بهینه مساله بدست می آید.

$$\begin{aligned} \text{Max: } & \alpha \\ \alpha \leq & \frac{Z_i - L_i}{U_i - L_i} \quad i = 1, 2, \dots, k \end{aligned} \quad (4)$$

$$g_i(x_1, x_2, \dots, x_n) \leq b_i \quad i = 1, 2, \dots, m \quad (5)$$

همچنین در صورتی که توابع پاسخ نسبت به همدیگر از اولویت برخوردار باشند می توانیم مدل را بصورت وزنی مطرح نماییم که در معادله ۶ نشان داده شده است.

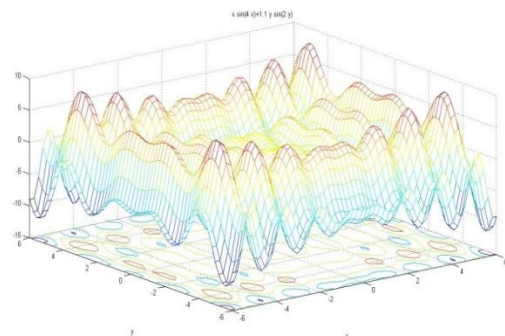
$$\text{Max} Z = \sum w_k \alpha_k \quad (6)$$

که در آن w_k میزان وزن هر یک از متغیرهای پاسخ می باشد. [۳۰]

۴. مثال عددی

بررسی یک فرآیند واقعی برای بررسی کارایی روش پیشنهادی، از اهمیت ویژه ای برخوردار می باشد، لیکن برای این منظور، فرض شده است که متغیر خروجی فرآیند شبیه سازی شده دارای یک تابع نسبتا پیچیده معین با متغیرهای ورودی می باشد. تابع مورد نظر در معادله ۷ و نمودار سطح آن در شکل ۳ نشان داده شده است. همانطور که در شکل ۳ مشاهده می شود، روابط بین متغیرهای ورودی و متغیرهای خروجی متناظر آن، به دلیل وجود نقاط اکسترمم نسبی فراوان در تابع، نسبتا پیچیده می باشد. بنابراین، برای بررسی و پیش بینی عملکرد روش پیشنهادی، این تابع در نظر گرفته شده است.

$$f(x, y) = x \sin(4x) + 1.1y \sin(2y) \quad (7)$$



شکل ۴. نمودار سطح تابع مورد استفاده مربوط به معادله (۷)

برای این مثال، ۱۰۰۰ داده که بصورت یکنواخت در بازه بین ۶- و ۶ توزیع شده اند، به عنوان داده های ورودی مورد استفاده قرار

^۱ Levenberg-Marquardt backpropagation algorithm

^۲ MINITAB statistical software

جدول ۴. وزن متغیرهای پاسخ

متغیرهای پاسخ	میانگین مجموع مربعات خطا	ضریب همبستگی	زمان آموزش
وزنها	۲	۲	۱

جدول ۵. آزمایشات طراحی شده با روش باکس-بنکن

شماره آزمایش	عوامل کنترلی و سطوح آنها		
	الف	ب	ج
۱	۰,۶	۱۰	۳۰
۲	۰,۶	۳۵	۰
۳	۰,۶	۳۵	۶۰
۴	۰,۶	۶۰	۳۰
۵	۰,۷۵	۱۰	۰
۶	۰,۷۵	۱۰	۶۰
۷	۰,۷۵	۳۵	۳۰
۸	۰,۷۵	۳۵	۳۰
۹	۰,۷۵	۳۵	۳۰
۱۰	۰,۷۵	۶۰	۰
۱۱	۰,۷۵	۶۰	۶۰
۱۲	۰,۹	۱۰	۳۰
۱۳	۰,۹	۳۵	۰
۱۴	۰,۹	۳۵	۶۰
۱۵	۰,۹	۶۰	۳۰

این مثال، این ضریب به ازای مقادیر متفاوت λ که با سعی و خطا تغییر داده شده است، محاسبه و مقدار λ متناظر با کمترین مقدار ضریب KS به عنوان پارامتر تبدیل هر متغیر پاسخ انتخاب شده است. پارامتر تبدیل و ضریب KS متناظر با آن برای هر یک از متغیرهای پاسخ در جدول ۶ نشان داده شده است.

جدول ۶. مقدار پارامتر تبدیل و ضریب KS متناظر با آن

متغیر پاسخ	مناسب ترین پارامتر تبدیل λ	ضریب KS
MSE	۱۱/۴۰	۰,۰۹
R-value	۲۴	۰,۱۷
TT	۱/۱۵	۰,۰۸۴

پس از برآورده کردن پیش شرط لازم، آنالیز واریانس بر روی هر یک از متغیرهای پاسخ بصورت جداگانه صورت می گیرد. در اولین مرحله از آنالیز واریانس بر روی هر یک از متغیرهای پاسخ، عوامل کنترلی یا اثرات متقابل عوامل کنترلی که بر روی متغیر پاسخ تاثیرگذار نیستند حذف و آنالیز واریانس مجدداً انجام پذیرفته و روابط متغیرهای پاسخ با عوامل تاثیرگذار بر روی آنها

۴-۴. آنالیز واریانس هر یک از معیارهای عملکرد بصورت جداگانه و یافتن رابطه رگرسیونی متغیرهای پاسخ نسبت به عوامل تاثیرگذار

پس از انجام آزمایشات، آنالیز واریانس روی نتایج آزمایشات صورت گرفته انجام می پذیرد. باید در نظر داشت که برای انجام آنالیز واریانس شروطی از جمله نرمال بودن باقیمانده ها باید ارضا شوند. در این مثال، برای این منظور از تکنیک تبدیل استفاده شده است.

تکنیک تبدیل سه هدف را دنبال می کند:

۱. ثابت کردن واریانس پاسخ
۲. نزدیک کردن توزیع متغیر پاسخ به توزیع نرمال
۳. بهبود برازندگی مدل به داده ها [۲۷]

تبدیل با استفاده از به توان رساندن ($y' = y^{\lambda}$) برای این منظور یکی از روشهای مفید می باشد، که λ پارامتر تبدیل است که باید تعیین شود. تست کولموگروف-اسمیرنوف^۱ (KS) یکی از روشهای نیکویی برازش است که در آن کمتر بودن ضریب KS نشاندهنده نزدیکی توزیع متغیر پاسخ مورد نظر به توزیع نرمال می باشد. در

^۱ Kolmogorov-Smirnov test

نرم افزار آماری مینی تب صورت گرفته است. روابط رگرسیونی بدست آمده در معادلات ۱۰-۸ نشان داده شده اند.

تعیین می گردد. در این مثال مرحله آنالیز واریانس و یافتن رابطه رگرسیونی متغیرهای پاسخ و عوامل تاثیرگذار بر روی آنها توسط

$$\hat{y}_1 = (5.30558 - 9.14947 x_1 - 0.00569 x_2 - 0.01277 x_3 + 5.42049 x_1^2 + 0.00019 x_2 x_3)^{40/11} \quad (۸)$$

$$\hat{y}_2 = (-3.7436 + 10.2448 x_1 - 0.0051 x_2 + 0.0141 x_3 - 6.8673 x_1^2 - 0.0002 x_2^2 - 0.0001 x_3^2 + 0.027 x_1 x_2)^{1/24} \quad (۹)$$

$$\hat{y}_3 = (0.34264 + 1.54863 x_1 + 0.00477 x_2 + 0.00586 x_3 - 0.95708 x_1^2 - 0.00004 x_2^2 - 0.00004 x_3^2 + 0.00004 x_2 x_3)^{15} \quad (۱۰)$$

جدول ۷. مقدار بهینه هر تابع هدف و مقادیر توابع هدف سایر متغیرهای پاسخ به ازای مقادیر بهینه

(ماتریس بهره وری)				
(x_1^*, x_2^*, x_3^*)	\hat{y}_3	\hat{y}_2	\hat{y}_1	
(۰.۸۴۴, ۱۰.۶۰)	۲۶,۱۹۵۵	۰,۹۸۲۵	*۰,۳۲۷۳	\hat{y}_1
(۰.۸۳, ۴۳, ۶۰)	۱۷۴,۲۴۲	*۰,۹۹۵۱	۰,۷۵۳۲	\hat{y}_2
(۰.۶, ۱۰, ۰)	*۶۴۲۸, ۰	۰,۸۵۳۱	۷,۰۴۰۵	\hat{y}_3
	۰,۶۴۲۸	۰,۹۹۵۱	۷,۰۴۰۵	حد بالا
	۱۷۴,۲۴۲	۰,۸۵۳۱	۰,۳۲۷۳	حد پایین

$$\alpha_1 \leq \mu(\hat{y}_1) = \begin{cases} 1 & \text{اگر } \hat{y}_1 \leq 0.3273 \\ \frac{7.0405 - \hat{y}_1}{7.0405 - 0.3273} & \text{اگر } 0.3273 \leq \hat{y}_1 \leq 7.040513 \\ 0 & \text{اگر } \hat{y}_1 \geq 7.0405 \end{cases} \quad (۱۱)$$

که در آن:

Y_1 : میانگین مجموع مربعات خطای مربوط به داده های تست

Y_2 : ضریب همبستگی

Y_3 : زمان آموزش

x_1 : درصد داده های مورد استفاده قرار گرفته جهت آموزش شبکه عصبی مصنوعی

x_2 : تعداد نورونها در اولین لایه پنهان

x_3 : تعداد نورونها در اولین لایه پنهان

$$\alpha_2 \leq \mu(\hat{y}_2) = \begin{cases} 1 & \text{اگر } \hat{y}_2 \leq 0.8531 \\ \frac{Z_2 - 0.8531}{0.9951 - 0.8531} & \text{اگر } 0.8531 \leq \hat{y}_2 \leq 0.9951 \quad (۱۲) \\ 0 & \text{اگر } \hat{y}_2 \geq 0.9951 \end{cases}$$

$$\alpha_3 \leq \mu(\hat{y}_3) = \begin{cases} 1 & \text{اگر } \hat{y}_3 \leq 0.6428 \\ \frac{174.242 - \hat{y}_3}{174.242 - 0.6428} & \text{اگر } 0.6428 \leq \hat{y}_3 \leq 174.242 \quad (۱۳) \\ 0 & \text{اگر } \hat{y}_3 \geq 174.242 \end{cases}$$

باتوجه به معادلات فوق و همچنین وزنهای هریک از متغیرهای پاسخ می توان برنامه ریزی فازی مثال فوق را بصورت معادلات ۲۱-۱۴ نوشت:

$$Z = 2\alpha_1 + 2\alpha_2 + \alpha_3 \quad \text{Max} \quad (۱۴)$$

$$(5.30558 - 9.14947 x_1 - 0.00569 x_2 - 0.01277 x_3 + 5.42049 x_1^2 + 0.00019 x_2 x_3)^{40/11} \leq 7.0405 - 6.7132 \alpha_1 \quad (۱۵)$$

۴-۵. استفاده از روش برنامه ریزی فازی جهت یافتن بهترین ترکیب عوامل کنترلی تاثیرگذار

پس از مشخص شدن روابط رگرسیونی بین متغیرهای پاسخ و عوامل کنترلی تاثیرگذار در آن، با استفاده از روش برنامه ریزی فازی بهترین ترکیب از عوامل کنترلی برای آموزش شبکه عصبی مصنوعی تعیین می شود. برای این منظور ابتدا مقادیر بهینه هریک از معادلات ۴-۲ را یافته و در معادلات دیگر قرار می دهیم. نتایج این مرحله از حل در جدول ۶ نشان داده شده است. در این مثال برای حل تمامی برنامه ریزی ها از نرم افزار لینگو استفاده شده است. بعد از این مرحله با توجه به جدول ۶ حدود بالا و پایین برای هریک از متغیرهای پاسخ مشخص شده است. حالت کلی تابع عضویت برای متغیر پاسخ از نوع LTB در معادله ۱ نشان داده شد. برای این مثال نیز باتوجه به معادله فوق و همچنین نوع آنها (هرچه کمتر بهتر یا هرچه بیشتر بهتر) می توان معادلات ۱۳-۱۱ را نوشت.

$$(-3.7436 + 10.2448x_1 - 0.0051x_2 + 0.0141x_3 - 6.8673x_1^2 - 0.0002x_2^2 - 0.0001x_3^2 + 0.027x_1x_2)^{1/24} \geq 0.142\alpha_2 + 0.8531 \quad (16)$$

$$(0.34264 + 1.54863x_1 + 0.00477x_2 + 0.00586x_3 - 0.95708x_1^2 - 0.00004x_2^2 - 0.00004x_3^2 + 0.00004x_2x_3)^{15} \leq 174.242 - 173.5992\alpha_3 \quad (17)$$

$$0.6 \leq x_1 \leq 0.9 \quad (18)$$

$$10 \leq x_2 \leq 60 \quad (19)$$

$$0 \leq x_3 \leq 60 \quad (20)$$

$$x_2, x_3 \in Z \quad (21)$$

تکرار انجام شده و در جدول ۸ نشان داده شده است. هدف ما در این مطالعه پیدا کردن بهینه ترین ترکیب پارامترها جهت داشتن کمترین میانگین مجموع مربعات خطای داده های تست و همچنین بیشترین مقدار ضریب همبستگی درضمن خیلی طولانی نبودن زمان آموزش حل بود و همانطور که در جدول ۸ مشاهده می شود این هدف ارضا گردیده است و همچنان که مشاهده می گردد، میانگین نتایج آزمایش در شرایط بهینه در متغیرهای پاسخ میانگین مربعات خطای داده های تست و ضریب همبستگی از میانگین این متغیرهای پاسخ در آزمایشات طراحی شده بهتر می باشد.

معادلات ۲۰-۱۸ به دلیل سطوح تعیین شده برای عوامل کنترلی به مدل برنامه ریزی اضافه شده اند. از آنجائیکه تعداد نوروها بایستی عددی صحیح باشد، محدودیت ۲۱ به مدل برنامه ریزی اضافه شده است. نتیجه حل این مدل برنامه ریزی در جدول ۷ نشان داده شده است. برای تأیید صحت مطالعه در شرایط بهینه بدست آمده طبق رویکرد پیشنهادی، فرآیند آموزش تابع با ۵ بار

جدول ۸. مقادیر بهینه عاملهای کنترلی با استفاده از رویکرد پیشنهادی


درصد داده های مورد استفاده قرار گرفته جهت آموزش شبکه عصبی مصنوعی	تعداد نوروها در اولین لایه	تعداد نوروها در دومین لایه پنهان
۰.۷۹	۱۰	۶۰

جدول ۹. نتایج آزمایشات انجام گرفته تحت شرایط بهینه بدست آمده از رویکرد پیشنهادی

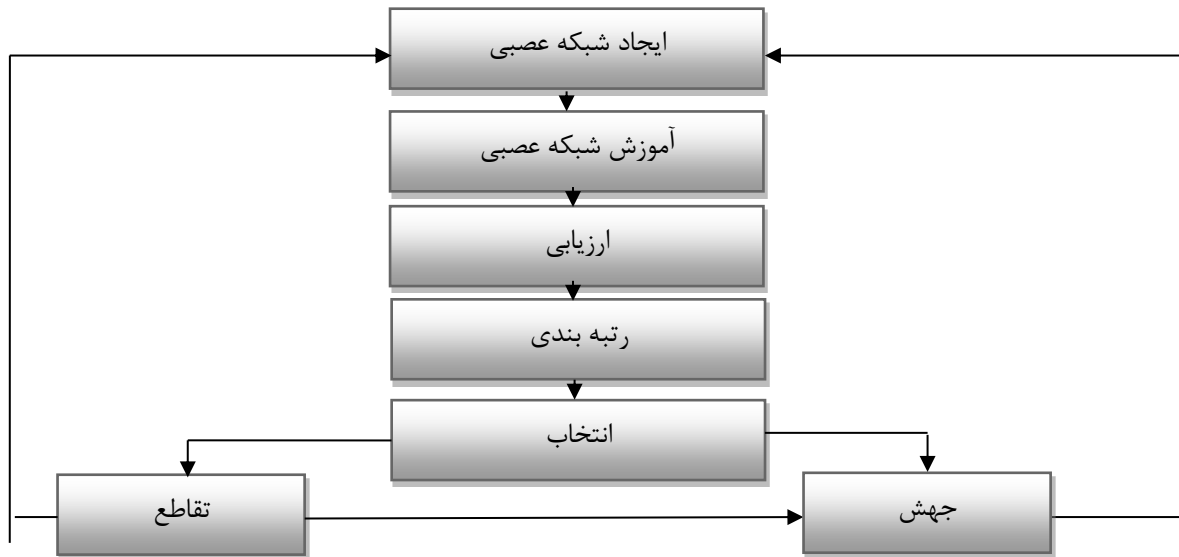
متغیرهای پاسخ	اولین تکرار	دومین تکرار	سومین تکرار	چهارمین تکرار	پنجمین تکرار	میانگین
میانگین مجموع مربعات خطا	۰.۰۰۲۳	۰.۰۰۲۷	۰.۰۰۱۰	۰.۰۰۲۷	۰.۰۰۱۶	۰.۰۰۲۴
ضریب همبستگی	۱	۱	۱	۱	۱	۱
زمان آموزش	۱۸۱.۳۲	۱۵۱.۱	۹۹.۵۴	۱۳۳.۲۷	۱۲۲.۰۶	۱۳۰.۲۶

برای مقایسه روش پیشنهادی با الگوریتم های فرا ابتکاری، مثال فوق یکبار نیز توسط الگوریتم ژنتیک انجام می شود. بدلیل در نظر گرفتن ۳ معیار عملکرد برای شبکه عصبی مصنوعی، مجموع وزنی نرمالایز شده ی معیارهای عملکرد به عنوان تابع هدف الگوریتم ژنتیک تعریف شده است. مراحل انجام این روش در شکل ۶ نشان داده شده است. برای نرمالایز کردن داده ها از روابط ۲۲-۲۳ استفاده شده است. رابطه ۲۴ تابع هدف تعیین شده برای الگوریتم ژنتیک را نشان می دهد. نتایج الگوریتم ژنتیک برای تنظیم پارامترهای مثال عددی در جدول ۱۱ نشان داده شده است. برای اینکه بتوان مقایسه ای بین دو روش انجام داد تابع هدف ذکر شده برای ۵ تکرار که در حالت بهینه روش پیشنهادی بدست آمده اند نیز محاسبه و در جدول ۱۲ نشان داده شده اند.

شکل ۵ نمودار سطح خروجی شبکه عصبی مصنوعی نسبت به ورودیها برای مثال مورد بررسی را در شرایطی که شبکه تحت ساختار بهینه بدست آمده آموزش دیده است، نشان می دهد.



شکل ۵. نمودار سطح خروجی شبکه عصبی مصنوعی نسبت به ورودیها



شکل ۶. روش کلی تنظیم پارامترهای شبکه عصبی با استفاده از الگوریتم ژنتیک

ضریب همبستگی و r_3 مقدار نرمالایز شده متغیر پاسخ زمان آموزش می باشد. ضرایب موجود در رابطه ۲۴ مربوط به وزنه‌های تعریف شده برای متغیرهای پاسخ می باشد که در جدول نشان داده شده است.

$$(22) \quad \text{برای حالتی که در صدد پیشینه کردن هدف هستیم.} \quad r = \frac{x-l}{u-l}$$

$$(23) \quad \text{برای حالتی که در صدد کمینه کردن هدف هستیم.} \quad r = \frac{u-x}{u-l}$$

که در آن r نرمالایز شده، u حد بالای متغیر پاسخ و l حد بالای متغیر پاسخ و x مقدار متغیر پاسخ می باشد. حدود بالا و پایین تعیین شده برای متغیرهای پاسخ در جدول ۱۰ نشان داده شده‌اند.

$$(24) \quad f = 2r_1 + 2r_2 + r_3$$

که در آن f مقدار تابع هدف، r_1 مقدار نرمالایز شده متغیر پاسخ میانگین مجموع مربعات خطا، r_2 مقدار نرمالایز شده متغیر پاسخ

جدول ۱۰. حدود بالا و پایین تعیین شده برای

متغیرهای پاسخ

متغیر پاسخ	میانگین مجموع مربعات خطا	ضریب همبستگی	زمان آموزش
حد پایین	۰	۰	۰
حد بالا	۱	۱	۳۰۰

جدول ۱۱. نتایج حاصل از تنظیم پارامترهای شبکه عصبی برای مثال فوق با استفاده از شبکه عصبی مصنوعی

پارامترهای مؤثر از عملکرد شبکه عصبی	معیارهای عملکرد شبکه عصبی	مقدار تابع هدف
درصد داده های مورد استفاده قرار گرفته جهت آموزش شبکه	تعداد نورونها در اولین لایه پنهان	۴,۴۴
تعداد نورونها در دومین لایه پنهان	میانگین مجموع مربعات خطای داده های تست	۰,۹۹۶۶
۱۹	ضریب همبستگی	۰,۲۶۲۶
۲۱	زمان آموزش	۱۷
۰,۶۷		

جدول ۱۲. مقدار تابع هدف به ازای نتایج آزمایشات انجام گرفته تحت شرایط بهینه رویکرد پیشنهادی

تکرار	۱	۲	۳	۴	۵
مقدار تابع هدف	۴,۵۲	۴,۴۸	۴,۶۷	۴,۵۵	۴,۵۹

کنترلی در نظر گرفته شده و بنا به مسائل مختلف تأثیر هر یک مورد تحلیل قرار گیرد.

مراجع

- [۱] بشیری، م. حسینی نژاد، س. ج.، «بهینه سازی فرآیند با چندسطح پاسخ به وسیله شبکه های عصبی بر مبنای مفهوم مطلوبیت»، نشریه بین المللی مهندسی صنایع و مدیریت تولید دانشگاه علم و صنعت ایران، جلد ۲۰، شماره ۴، صفحه ۶۳-۵۳، ۱۳۸۸.
- [2] Hagan, M.T., Demuth, H.B., Beale, M.H., *Neural Network Design*, PWS Boston MA, 1996.
- [3] Werbos, P., "Backpropagation Through Time: What it Does and How to Do it", *Proceedings of the IEEE*, Vol. 78, 2002, pp. 1550-1560.
- [4] Hertz, J., Krogh, A., Palmer, R.G., *Introduction to the Theory of Neural Computation*, Westview press, 1991.
- [5] Hsieh, K., "Employing Artificial Neural Networks Into Achieving Parameter Optimization of Multi-Response Problem with Different Importance Degree Consideration", *Information technology journal*, Vol. 9, No. 5, 2010, pp. 918-926.
- [6] Noorossana, R., Davanloo Tajbakhsh, S., Saghaei, A., "An Artificial Neural Network Approach to Multiple-Response Optimization", *The International Journal of Advanced Manufacturing Technology*, Vol. 40, No. 11, 2009, pp. 1227-1238.
- [7] Shi, Y., Eberhart, R., "Parameter Selection in Particle Swarm Optimization", *Evolutionary Programming VII*, 1998, pp. 591-600.
- [8] Xu, J., Chiu, S.Y., Glover F., "Fine-tuning a tabu search algorithm with statistical tests", *International Transactions in Operational Research*, Vol. 5, No. 3, 1998, pp. 233-244.
- [9] Zandieh M., Amiri M., Vahdani B., & Soltani R., "A robust parameter design for multi-response problems", *Journal of computational and applied mathematics*, Vol. 230, No. 2, 2009, pp. 463-476.
- [10] Bashiri M., & Karimi H., "Tabu Search parameters selection for Quadratic Assignment Problem", 24th European Conference on Operational Research, Lisbon, 2010.
- [11] Arifovic J., & Gencay R., "Using Genetic algorithms to Select Architecture of a Feedforward Artificial Neural Network", *Physica A: Statistical Mechanics and its Applications*, Vol. 289, No. 3, 2001, pp. 574-594.
- [12] Leung, F.H.F., Lam, H.K., Ling, S.H., Tam, P.K.S., "Tuning of the Structure and Parameters of a Neural Network Using an Improved Genetic Algorithm", *IEEE*

نتایج نشاندهنده ی عملکرد مناسب روش پیشنهادی نسبت به روش الگوریتم ژنتیک می باشد. این در حالیست که زمان مورد نیاز برای الگوریتم ژنتیک ۳۱۴۲۷ ثانیه بوده که در مقایسه با روش پیشنهادی بسیار زیاد می باشد. دلیل عملکرد بهتر روش پیشنهادی را می توان وابستگی عملکرد الگوریتم ژنتیک به تنظیم مناسب پارامترهای خود الگوریتم عنوان کرد. بعبارت دیگر در صورت تغییر مناسب پارامترهای الگوریتم ژنتیک، پارامترهای تعیین شده برای شبکه عصبی نیز تغییر خواهد یافت.

۵. نتیجه گیری

تنظیم پارامترهای شبکه عصبی مصنوعی را می توان به عنوان یکی از مهمترین مشکلات استفاده از آن عنوان کرد. در مطالعاتی که از طراحی آزمایشات برای تنظیم پارامترهای شبکه عصبی استفاده شده است، اغلب از روش تاگوچی برای این منظور بهره جسته اند، لیکن از مهمترین معایب این روش میتوان به حل مسئله در فضای گسسته و همچنین عدم قابلیت مناسب این روش برای در نظر گرفتن چندین معیار عملکرد اشاره نمود. از سویی دیگر، در مطالعاتی که الگوریتم های فرا ابتکاری برای این منظور بکار برده شده اند، نتایج نشاندهنده ی وابستگی کیفیت جواب نهایی به نحوه انتخاب پارامترهای خود الگوریتم ها می باشد. در این مقاله برای جبران عیب روش های حاصل از طراحی آزمایشات، از روش باکس-بنکن برای این منظور استفاده شده است که می توان مسئله را در فضای کاملتری بررسی نمود. همچنین روش پیشنهادی در مقابل روشهای فرا ابتکاری زمان بسیار کمتری برای تنظیم پارامترها نیاز داشته و می تواند جنبه کاربردی تری داشته باشد.

در این مقاله برای تأیید صحت رویکرد پیشنهادی، مثالی با بکارگیری از آن ارائه گردیده و با نتیجه حاصل از الگوریتم ژنتیک مقایسه گردید. نتایج این مثال نشان می دهد که در صورت تنظیم پارامترها با استفاده از رویکرد پیشنهادی، شبکه عصبی مصنوعی عملکرد بسیار مناسبی از خود نشان می دهد.

این رویکرد می تواند برای تنظیم پارامترها در حل انواع مختلف مسائل با استفاده از شبکه عصبی مصنوعی مورد استفاده قرار گیرد. استفاده از روشهای دیگر آماری برای طراحی آزمایشات و همچنین مطالعه سایر عوامل از جمله توابع انتقال، وزن آغازین برای آموزش و همچنین الگوریتمهای آموزش شبکه عصبی به عنوان عوامل کنترلی می تواند در مطالعات آتی مورد استفاده قرار گیرد. برای مثال الگوریتمهای گرادیان توأم، لون برگ-مارکورت، الگوریتمهای فرا ابتکاری و ترکیب الگوریتمهای پس انتشار خطا و الگوریتمهای فرا ابتکاری می توانند به عنوان سطوح این عامل

- [24] Klimasauskas, C.C., "An Introduction to Neural Networks, Part III: Training a Neural Network", PC AI, 1989, pp. 20-24.
- [25] LiMin, F., *Neural Network in Computer Intelligence*, McGraw-Hill, NewYork, 1994.
- [26] Box, G. E. P., Behnken, D. W., "Some New Three Level Designs for the Study of Quantitative Variables." *Technometrics*, Vol. 2, 1960, pp. 455-476.
- [27] Montgomery, D.C., *Design and Analysis of Experiments*, John Wiley&Sons Inc, 2008.
- [28] Zimmermann H.J. , "Fuzzy Programming and Linear Programming with Several Objective Functions", *Fuzzy sets and Systems*, 1978, pp. 45-55.
- [29] Cheng, C.B. , Cheng C.J., Lee, E.S., "Neuro-Fuzzy and Genetic Algorithm in Multiple Response optimization", *Computers and Mathematics with Applications*, Vol. 44, No. 12, 2002, pp. 1503-1514.
- [30] Lai, Y.J., Hwang, C.L., *Fuzzy Multiple Objective Decision Making:(Methods and Applications)*, Springer, 1994.
- [31] Ngia L.S., & Sjöberg, J., "Efficient Training of Neural Nets for Nonlinear Adaptive Filtering using a Recursive Levenberg-Marquardt Algorithm", *IEEE Transactions on Signal Processing*, Vol. 48, 2002, pp. 1915-1927.
- [32] Hagan, M., Menhaj, M., "Training Feedforward Networks with the Marquardt Algorithm", *IEEE Transactions on Neural Networks*, Vol. 5, 2002, pp. 989-993.
- [13] Tsai, J.T., Chou, J.H., Liu, T.K., "Tuning the Structure and Parameters of a Neural Network by using Hybrid Taguchi-genetic Algorithm", *IEEE Transactions on Neural Networks*, Vol. 17, No. 1, 2006, pp. 69-80.
- [14] Zhao, L., Qian, F., "Tuning the Structure and Parameters of a Neural Network using Cooperative Binary-Real Particle Swarm Optimization", *Expert Systems with Applications*, Vol. 38, No. 5, 2011, pp. 4972-4977.
- [15] Ortiz-Rodriguez, J.M., Martinez-Blanco, M.R., Vega-Carrillo, H.R., "ARTIFICIAL NEURALNETWORKS APPLICATION", Chapter 24, Intech, 2011.
- [16] Khaw, J.F.C., Lim, BS, Lim, L.E.N., "Optimal Design of Neural Networks using the Taguchi Method", *Neurocomputing*, Vol. 7, No. 3, 1995, pp. 225-245.
- [17] Peterson G.E., St Clair D.C., Aylward S.R., & Bond W.E., "Using Taguchi's Method of Experimental Design to Control Errors in Layered Perceptrons", *IEEE Transactions on Neural Networks*, Vol. 6, No. 1, 1995, pp. 949-961.
- [18] Yang, S., Lee, G., "Neural Network Design by Using Taguchi Method", *Journal of Dynamic Systems Measurement and Control*, Vol. 121, No. 3, 1999, pp. 560-563.
- [19] Packianather, M.S., Drake, P.R., Rowlands, H., "Optimizing the Parameters of Multilayered Feedforward Neural Networks Through Taguchi Design of Experiments", *Quality and Reliability Engineering International*, Vol. 16, No. 6, 2000, pp. 461-473.
- [20] Kim Y., & Yum B., "Robust Design of Multilayer Feedforward Neural Networks: an Experimental Approach", *Engineering Applications of Artificial Intelligence*, Vol. 17, No. 3, 2004, pp. 249-263.
- [21] Sukthomya W., & Tannock J., "The Optimisation of Neural Network Parameters using Taguchi's Design of Experiments Approach: an Application in Manufacturing Process Modelling", *Neural Computing & Applications*, Vol. 14, 2005, pp. 337-344.
- [22] Tortum, A., Yayla, N., Çelik, C., Gökdağ, M., "The Investigation of Model Selection Criteria in Artificial Neural Networks by the Taguchi Method", *Physica A: Statistical Mechanics and its Applications*, Vol. 386, 2007, pp. 446-468.
- [23] Myers, R.H., Khuri, A.I., Vining, G., "Response Surface Alternatives to the Taguchi Robust Parameter Design Approach", *American Statistician*, Vol. 46, No. 2, 1992, pp. 131-139.