



## Optimization of Multiple Response Process by Neural Networks Based on Desirability Concept

Mahdi Bashiri\* & Seyed Javad Hosseini-zhad

Mahdi Bashiri, Assistance professor of Industrial Eng- Shahed University  
Seyed Javad Hosseini-zhad, Phd student of Industrial Eng-Iran University of Science and Technology

### Keywords

Response Surface  
Methodology (RSM),  
Multiple Response  
Optimization (MRO),  
Desirability function,  
Feedforward backpropagation  
neural network

### ABSTRACT

In this paper, a method is proposed for Multiple Response Optimization (MRO) by neural networks and uses desirability of each response for forecasting. The used neural network is a feed forward back propagation one with two hidden layers. The numbers of neurons in the hidden layers are determined using MSE criterion for training and test data. The numbers on neurons of the first layer last layer are equal to the numbers of the factors and responses, respectively. After training the network, forecasting phase are done by giving different factor levels to calculate desirability of different experiments. Then total desirability is calculated. The optimal combination is which have the greatest total desirability. Finally, a numerical example is expressed to illustrate the capability of the neural network. The results of the research shows that although determining of suitable neural network is time consuming but have more accuracy than Response Surface Methodology (RSM). Also, the obtained optimal combination from RSM is one of optimal solution by neural network.

© (نشریه بین المللی مهندسی صنایع و مدیریت تولید) شماره ۴، جلد ۲۰، ۱۳۸۸

## بهینه سازی فرآیند با چند سطح پاسخ به وسیله شبکه های عصبی بر مبنای مفهوم مطلوبیت

مهدی بشیری و سید جواد حسینی نژاد

### چکیده:

در این مقاله، روشی برای بهینه سازی فرآیند با چند سطح پاسخ به وسیله شبکه های عصبی پیشنهاد می شود که در آن از مفهوم مطلوبیت مقدار هر متغیر پاسخ جهت پیش بینی استفاده می کند. در این پژوهش شبکه پس انتشار پیش خور با دو لایه پنهان استفاده می شود. تعداد نرونهای لایه پنهان با استفاده از معیار میانگین مربع خطا برای داده های آموزش و تست تعیین می گردد. تعداد نرون های لایه اول برابر تعداد فاکتورها و تعداد نرونهای لایه آخر برابر تعداد سطوح پاسخ می باشند. پس از آموزش شبکه، مرحله پیش بینی با دادن سطوح مختلف به فاکتورها برای محاسبه

### کلمات کلیدی

روش سطح پاسخ،  
بهینه سازی فرآیند با چند سطح  
پاسخ، تابع مطلوبیت،  
شبکه عصبی پس انتشار پیش خور

تاریخ وصول: ۸۸/۶/۲۲

تاریخ تصویب: ۸۸/۱۱/۱۲

دکتر مهدی بشیری، استادیار گروه مهندسی صنایع دانشکده فنی و مهندسی دانشگاه شاهد، Bashiri@shahed.ac.ir  
سید جواد حسینی نژاد، دانشجوی دکتری مهندسی صنایع دانشگاه علم و صنعت ایران، Hosseini-zhad@iust.ac.ir

مطلوبیت آزمایشهای مختلف به شبکه انجام می شود. در مرحله بعد مقادیر مطلوبیت کل محاسبه می گردد. آنگاه ترکیبی به عنوان بهینه انتخاب می شود که دارای بیشترین مطلوبیت کل باشد. در انتها برای نشان دادن قابلیت شبکه عصبی یک مثال عددی آورده می شود. نتایج این تحقیق نشان می دهد گرچه تعیین نوع شبکه عصبی مناسب زمان بر است ولی از لحاظ دقت نسبت به روش سطح پاسخ مناسب تر می باشد. در ضمن ترکیب بهینه به دست آمده از روش سطح پاسخ یکی از جوابهای بهینه به دست آمده از روش شبکه عصبی می باشد.

زمانی که انحنا در سیستم وجود داشته باشد یک مدل رگرسیونی درجه دوم مورد استفاده قرار می گیرد. اگر  $x_i$  سطح فاکتور  $i$  ام و  $Y$  سطح پاسخ باشد، آنگاه مدل رگرسیون درجه دوم به صورت (۱) بیان می گردد.

$$Y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i < j} \beta_{ij} x_i x_j + \varepsilon \quad (1)$$

جایی که  $\varepsilon$  بیانگر خطای مشاهده شده در مقدار پاسخ است. پس از به دست آوردن مدل مذکور، تحلیل سطح پاسخ بر روی مدل انجام می گیرد. بدین صورت که فاکتورهای موثر بر پاسخ و میزان اثر هر کدام شناسایی می گردند، اثر متقابل فاکتورها بر روی هم تعیین گشته و آنگاه نقاط بهینه که شرایط شدنی مساله را رعایت کنند، تعیین می گردند. در مرجع [۴] مطالعه ای بر وضعیت بکارگیری روش سطح پاسخ در حال و آینده انجام شده است. در این مطالعه اشاره شده است که طی سالیان اخیر بیشتر بر روی طراحی پارامترهای پایدار در روش سطح پاسخ برای کاهش واریانس و بهبود فرآیند تمرکز شده است.

### ۳. معرفی شبکه های عصبی

مفهوم شبکه های عصبی و استفاده از آن به علاقه نسبت به شبیه سازی مغز انسان بر می گردد. شبکه های عصبی شامل تعداد زیادی نرون هستند که هر کدام پردازش اطلاعات را به صورت مجزا و هم زمان انجام می دهند. همه نرونها به وسیله سیناپسها با وزنه های متفاوتی به هم متصل هستند. یک نرون، یک واحد پردازش در یک شبکه عصبی می باشد و گره ای است که بر روی آنچه از گره های دیگر دریافت می کند پردازش کرده و یک خروجی مطابق با یک تابع تبدیل به نام تابع فعالیت تولید می کند. تابع فعالیت یک نگاشت خطی یا غیر خطی از ورودی به خروجی ایجاد می کند که با نشان می دهند. یک نرون به وسیله سیناپس های متغیر (وزن) به نرون های دیگر ارتباط پیدا می کند شکل ۱ مدل نرون ساده پیشنهاد شده توسط مک کولوخ و پیت را نشان می دهد [۵]. خروجی نرون توسط (۲) داده می شود.

$$net = \sum_i^n w_i x_i - \theta \quad \text{و} \quad y = \phi(net) \quad (2)$$

$x_i$ ،  $i$  امین ورودی،  $w_i$  وزن ارتباطی از  $i$  امین ورودی و  $\theta$  یک آستانه و  $n$  تعداد ورودیها می باشد.  $\phi(\cdot)$  معمولاً نگاشتی است از

### ۱. مقدمه

طراحی آزمایشها، دنباله ای از آزمایشها است به گونه ای که بتوان با تغییراتی هدفمند در متغیرهای ورودی یک فرآیند یا سیستم، دلایل تغییراتی که در متغیرهای پاسخ به وجود می آیند را تشخیص داد و شامل طراحی و فرمولاسیون محصول، توسعه فرآیند ساخت و تولید و بهبود فرآیند و در خیلی از موارد توسعه یک فرآیند پایدار می باشد به گونه ای که تغییرات خارجی کمترین تاثیر را بر روی فرآیند بگذارد [۱].

در این مقاله، روشی برای بهینه سازی فرآیند با چند سطح پاسخ به وسیله شبکه های عصبی پیشنهاد می شود. ساختار مقاله بدین صورت می باشد. در بخش ۲ روش سطح پاسخ و بهینه سازی فرآیند با چند سطح پاسخ بیان می گردد. شبکه های عصبی در بخش ۳ معرفی می گردد. در بخش ۴ مروری بر پژوهشهای انجام شده صورت می پذیرد. در بخش ۵، روش پیشنهادی معرفی می گردد. یک مثال عددی برای تشریح روش پیشنهادی در بخش ۶ آورده می شود و نتایج در بخش ۷ بیان می شوند.

### ۲. روش سطح پاسخ و بهینه سازی فرآیند با چند سطح

#### پاسخ

یکی از مفاهیم طراحی آزمایشها روش سطح پاسخ می باشد که مجموعه ای از تکنیک های ریاضی و آماری برای مدل کردن و تحلیل مسائلی است که یک متغیر پاسخ توسط چندین متغیر تاثیر می پذیرد و هدف بهینه کردن این متغیر پاسخ است. در برخی موارد برای ارزیابی نهایی فرآیند باید چندین مشخصه خروجی را همزمان در نظر گرفت بدین ترتیب یک فرآیند با چند سطح پاسخ مطرح می شود.

بررسی همزمان چندین پاسخ شامل ابتدا ایجاد مدل سطح پاسخ مناسب برای هر متغیر پاسخ و سپس تلاش برای پیدا کردن مجموعه ای از شرایط عملیاتی می باشد که همه متغیرهای پاسخ را بهینه کند یا حداقل آنها را در یک محدوده مطلوب نگه دارد [۲]. روشهای گوناگونی برای این مساله بیان گشته اند. یکی از پرکاربردترین روشهای بهینه سازی با چندین سطح پاسخ روش Dual Response می باشد که شامل دو تابع هدف است که یکی متغیر پاسخ را در سطح مطلوب نگه داشته و دیگری انحراف متغیر پاسخ را می نیمم می کند [۳].

#### ۴. مروری بر مطالعات انجام گرفته


برای بهینه سازی مسائل سطح پاسخ تاکنون تکنیکهای مختلفی پیشنهاد شده است. در مرجع [۶] یک تابع مطلوبیت برای تبدیل چندین متغیر پاسخ به یک تک متغیر پاسخ تعریف می شود. در مرجع [۷] الگوریتمی برای بهینه سازی همزمان چند تابع پاسخ پیشنهاد شده که به مجموعه یکسانی از متغیرهای قابل کنترل بستگی دارند و به طور مناسب به وسیله مدل های رگرسیونی چندجمله ای بیان می شود. ابتدا یک تابع فاصله ای با در نظر گرفتن حل ایده آل تعریف شده و آنگاه شرایط بهینه با می نیم کردن این تابع تعیین می گردد. در مرجع [۸] روشهای موجود طبقه بندی شده است. در مرجع [۹] از یک برنامه ریزی غیر خطی بر مبنای روش GRG برای روش dual response استفاده شده است. روش پیشنهادی نسبت به روش dual response ساده تر بوده و در برخی موارد جواب های بهینه بهتری به دست می آورد. در مرجع [۱۰] استفاده از رگرسیون ناپارامتری را در تخمین واریانس فرآیند مورد بررسی قرار گرفته است. آنگاه تابع پاسخ با استفاده از یک روش نیمه پارامتری در چارچوب حداقل مربعات وزن دهی شده و رگرسیون ناپارامتری برای واریانس و متغیر پاسخ انجام گرفته است. در مرجع [۱۱] چارچوبی عمومی در مسائل با چند سطح پاسخ مطابق با برخی کارهای موجود و چند نوع تصمیم گیر مرتبط پیشنهاد داده شده که تلاش می کند همه مشخصه ها را در یک رویکرد تجمیع کند. در مرجع [۱۲] از تابع مطلوبیت برای ترکیب مدلها استفاده شده است. روش تابع مطلوبیت از لحاظ مفهومی ساده می باشد و در پاسخ های فردی وزن دهی شده انعطاف پذیری ایجاد می کند. در مرجع [۱۳] از روش ویکور (VIKOR) برای بهینه سازی مساله با چند سطح پاسخ استفاده شده است. روش پیشنهادی هم میانگین و هم واریانس زیانهای کیفیت مرتبط با چند متغیر پاسخ را در نظر گرفته و به دنبال واریانس کم بین متغیرهای پاسخ و میانگین زیان کیفیت کلی کم می باشد. در مرجع [۱۴] رویه جدیدی برای بهینه سازی مساله با چند سطح پاسخ پویا با استفاده از روش آنالیز جزء اصلی<sup>۳</sup> (PCA) و ارزیابی چند معیاره مدل رابطه خاکستری<sup>۴</sup> پیشنهاد شده است. آنالیز جزء اصلی می تواند همبستگی بین مشخصه های کیفیت چندگانه را مورد بررسی قرار دهد تا اجزاء غیر همبسته را به دست آورد. در مرجع [۱۵] رویه ای برای بهره برداری کردن از تحلیل رگرسیون آماری و تابع مطلوبیت برای بهینه سازی مساله با چند سطح پاسخ با ملاحظات سیستم پویای تاگوچی پیشنهاد داده شده است. ابتداء تحلیل رگرسیونی برای غربال سازی<sup>۵</sup> فاکتورهای کنترلی بکار برده می شود. آنگاه، تابع مطلوبیت برای بهینه سازی مساله استفاده می شود.

اعداد حقیقی به بازه (۰، ۱) یا (۱، ۰) و البته با توجه به نوع مدل برخی از انواع آن استفاده می شود. یکی از انواع آنها محدود کننده سخت می باشد که به توسط (۳) محاسبه می شود.


$$\phi(x) = \begin{cases} 1 & x \geq 0 \\ -1 & x \leq 0 \end{cases} \quad \text{یا} \quad (3)$$

$$\phi(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x \leq 0 \end{cases}$$

ماتریس اتصالات  $W = [w_{ij}]$  که در آن وزن اتصال بین گره  $i$  و گره  $j$  را نشان می دهد معماری شبکه را توصیف می کند. با قرار دادن وزنها اتصالات بین گره ها به صورت ۰ و ۱ توپولوژیهای شبکه ای مختلفی را می توان تشکیل داد. و مطابق با این معماری، شبکه های عصبی به شبکه های عصبی پیش خور<sup>۱</sup> (FNN) و شبکه های عصبی بازگشتی<sup>۲</sup> (RNN) و ترکیبات آنها تقسیم بندی می شود. در شبکه های FNN اتصالات بین نرونها به صورت پیش خور می باشد و شبکه لایه ای می باشد و هیچ اتصالی بین نرونها در یک لایه و هیچ بازخوری بین لایه ها وجود ندارد. اما شبکه های عصبی بازگشتی حداقل یک اتصال باز خور وجود دارد و یک سیستم پویایی غیر خطی را ارائه می دهند. شبکه های پرسپترون چند لایه و تابع شعاع مدار از نوع FNN و شبکه های هاپفیلد و ماشین بولتزمن از نوع RNN می باشند [۱۵]. شکل ۲ معماری شبکه های FNN و RNN را نشان می دهد.



شکل ۱. مدل نرون مک کولوخ - پیت - الف. نرون بیولوژیکی  
ب. مدل ریاضی



شکل ۲. معماری شبکه های عصبی الف. FNN ب. RNN  
دایره های کوچک گره های ورودی و دایره های شماره گذاری شده نرونها را نشان می دهد

<sup>3</sup> Principal Component Analysis

<sup>4</sup> Grey relation

<sup>5</sup> Screening

<sup>1</sup> Feedforward Neural Network

<sup>2</sup> Recurrent Neural Network

می‌باشد. در مرجع [۲۵] مقایسه ای بین روش سطح پاسخ و شبکه عصبی برای تحلیل قابلیت اطمینان ساختاری انجام شده است. در مرجع [۲۶] به مدلسازی مشخصه های کربن فعال شده<sup>۶</sup> با شبکه عصبی و روش سطح پاسخ پرداخته شده است. در این پژوهش سه روش مدلسازی مختلف بکار گرفته شده است. تا ارتباط بین پارامترهای کربن فعال شده و بالارفتن متان<sup>۷</sup> استخراج شود. اولین و دومین روش بر مبنای شبکه عصبی تابع شعاع مدار طراحی شده اند. در اولین الگوریتم شبکه عصبی با استفاده از تابع گوسین ایجاد شده است. دو نوع داده برای آموزش و تست به شبکه عصبی داده شده است. در دومین شبکه عصبی از جعبه ابزار Matlab برای طراحی شبکه عصبی استفاده شده است. مدل سومی روش سطح پاسخ می باشد. نتایج نشان دهنده قابلیت های هر سه روش می‌باشد ولی روش دوم دقت بالاتری دارد. در مرجع [۲۷] روشی برای توسعه یک شبکه عصبی و یک سطح پاسخ چند جمله ای برای تخمین سریع عملکرد اتصالات وسیله نقلیه پیشنهاد می‌شود. در مرجع [۲۸] رویکردی با بکارگیری شبکه عصبی برای بهینه سازی پارامترهای یک مساله بهینه سازی با چند سطح پاسخ پیشنهاد می‌شود. در این رویکرد از دو شبکه عصبی استفاده می‌شود. در شبکه اول، ورودی ها مقادیر متغیرهای پاسخ و میزان مطلوبیت هر کدام می باشد و فاکتورها متغیرهای خروجی می‌باشند. بهترین ترکیب فاکتورها با دادن مقادیر پاسخ به همراه میزان مطلوبیتشان به شبکه، پیش بینی می‌شوند. سپس شبکه دوم ایجاد می‌گردد که ورودیهای آن فاکتورها و خروجی متغیرهای پاسخ می‌باشد. پس از انتخاب بهترین شبکه و آموزش آن، بهترین ترکیب فاکتورهای به دست آمده به وسیله شبکه اول به این شبکه داده می‌شوند تا مقدار بهینه متغیرهای پاسخ به دست آید. در مرجع [۲۹] از روش سطح پاسخ و شبکه عصبی برای بهینه‌سازی و طراحی شکل ابزار فرم دهی<sup>۸</sup> استفاده شده است. مدل تقریب شبکه عصبی برای ایجاد سطح پاسخ بکارگرفته شده است تا بر محدودیت مدل چند جمله ای درجه دوم در حل مسائل غیرخطی غلبه کند. در این مقاله، روشی برای بهینه سازی فرآیند با چند سطح پاسخ به وسیله شبکه های عصبی پیشنهاد می‌دهد. پس از انجام آزمایشهای ساختاری پیشنهاد شده است. در مرجع [۲۴] روش سطح پاسخ و شبکه عصبی تابع شعاع مدار را برای پیش بینی عملیات مته کاری مواد کامپوزیت مقایسه شده است. در مرجع [۳] مقایسه ای بین روش سطح پاسخ و رویکرد شبکه عصبی-الگوریتم ژنتیک برای بهینه سازی محیط تخمیر<sup>۵</sup> انجام می‌شود. خطای پیش بینی به وسیله شبکه عصبی ۲ درصد و برای روش سطح پاسخ ۸ درصد

استفاده از شبکه های عصبی در روش سطح پاسخ نیز توسط برخی پژوهشگران مورد توجه بوده است. در مرجع [۱۶] به مقایسه روشهای پیش بینی از جمله درخت تصمیم و شبکه عصبی که از تکنیکهای پیش بینی در داده کاوی هستند با روش رگرسیون پرداخته شده است. در مرجع [۱۷] به بهینه سازی پاسخ های چندگانه کیفیت از نوع کمی و کیفی اشاره شده است. به این صورت دو شبکه عصبی ساخته می‌شود، یکی از آنها به منظور تعیین مجموعه پارامترهای ایده آل و دیگری برای تخمین مقادیر بهینه پاسخ های چندگانه کیفی و کمی به کاربرده شده است. در مرجع [۱۸] بهینه سازی همزمان طراحی پارامتری پاسخ های چندگانه پویا مورد بررسی قرار گرفته و یک رویکرد داده کاوی را ارائه می‌دهد که بر اساس شبکه عصبی مصنوعی، توابع مطلوبیت و الگوریتم بازپخت شبیه سازی شده (SA) عمل می‌کند. در مرجع [۱۹] کاربرد شبکه های عصبی برای مدلسازی سطح پاسخ در بهینه سازی HPLC بیان شده و آن را با روش های چند رگرسیونی مقایسه کرده است. نتایج نشان می‌دهد که شبکه های عصبی امکان پذیری های امیدوارکننده ای را در توسعه روش HPLC می‌دهند. در مرجع [۲۰] به مقایسه بهینه سازی تاب برداشتن در قالب گیری تزریقی پلاستیک با استفاده از آنالیز واریانس، مدل شبکه عصبی و الگوریتم ژنتیک پرداخته شده است. در مرجع [۲۱] مدل سطح پاسخ با شبکه عصبی در تعیین کیفیت سطح قطعات قالب گیری مقایسه شده است. در مرجع [۲۲] روشی بر مبنای تحلیل پوششی داده ها<sup>۱</sup> (DEA) و شبکه عصبی برای بهینه سازی مساله با چند سطح پاسخ در روش تاگوچی<sup>۲</sup> پیشنهاد شده است. در این پژوهش نسبتهای SN<sup>۳</sup> متغیرهای پاسخ به وسیله داده های کامل آزمایشی شناخته شده برای ترکیبات سطوح فاکتورها با بکارگیری شبکه عصبی تخمین زده شده اند. هر ترکیب سطوح یک واحد تصمیم گیری<sup>۴</sup> (DMU) نامیده می‌شود. آنگاه تحلیل پوششی داده ها برای محاسبه کارایی نسبی هر واحد تصمیم گیری استفاده می‌شود به گونه ای که ترکیبهای بهینه سطوح فاکتور که کارایی نسبی ۱۰۰٪ دارند، پیدا می‌شوند. در مرجع [۲۳] یک روش سطح پاسخ جدید بر مبنای شبکه عصبی برای تحلیل قابلیت اطمینان ساختاری پیشنهاد شده است. در مرجع [۲۴] روش سطح پاسخ و شبکه عصبی تابع شعاع مدار را برای پیش بینی عملیات مته کاری مواد کامپوزیت مقایسه شده است. در مرجع [۳] مقایسه ای بین روش سطح پاسخ و رویکرد شبکه عصبی-الگوریتم ژنتیک برای بهینه سازی محیط تخمیر<sup>۵</sup> انجام می‌شود. خطای پیش بینی به وسیله شبکه عصبی ۲ درصد و برای روش سطح پاسخ ۸ درصد

<sup>1</sup> Data Envelopment Analysis

<sup>2</sup> Taguchi

<sup>3</sup> Signal-to-Noise

<sup>4</sup> Decision-Making Unit

<sup>5</sup> Fermentation Media

<sup>6</sup> Activated Carbone

<sup>7</sup> Metane Updtake

<sup>8</sup> Preform Tool Shape

انتخاب می کنیم که دارای بیشترین مطلوبیت کل باشد جدول ۱- مقایسه بین کارهای انجام شده را نشان می دهد.

جدول ۱. مقایسه کارهای انجام شده در زمینه روش سطح پاسخ با بکارگیری شبکه های عصبی

مراجعه	نوع شبکه عصبی	تکنیک استفاده شده	ارائه چند جواب بهینه
Agatonovic و همکاران [۱۹]	پس انتشار پیش خور	پیش بینی	-
Nikolaidis و همکاران [۲۷]	پس انتشار پیش خور	پیش بینی	-
Tong و Hsieh [۱۷]	پس انتشار پیش خور	بهینه سازی با تابع مطلوبیت	-
Awruch و Gomez [۲۵]	پس انتشار پیش خور و تابع شعاع مدار	پیش بینی	-
Liao [۲۲]	پس انتشار پیش خور	بهینه سازی با کمک DEA	√
Erzurumlu و Ozcelik [۸]	پس انتشار پیش خور	بهینه سازی با کمک GA	-
Hsieh [۲۸]	پس انتشار پیش خور	بهینه سازی با تابع مطلوبیت	-
Kim [۱۶]	پس انتشار پیش خور	پیش بینی	-
Oktem و Erzurumlu [۲۱]	پس انتشار پیش خور	پیش بینی	-
Chang [۱۸]	پس انتشار پیش خور	بهینه سازی با SA و تابع مطلوبیت	-
Cheng و همکاران [۲۳]	پس انتشار پیش خور	پیش بینی	-
Tsao [۲۴]	تابع شعاع مدار	پیش بینی	-
Desai و همکاران [۳]	پس انتشار پیش خور	پیش بینی	-
Namvar-Asl و همکاران [۲۶]	تابع شعاع مدار	مدلسازی و پیش بینی	-
Tang و همکاران [۲۹]	پس انتشار پیش خور	بهینه سازی با روش PS	-
این مقاله	پس انتشار پیش خور	بهینه سازی با تابع مطلوبیت	√

جدول ۲. طرح آزمایش با چند سطح پاسخ

Run #	Factor Levels			Responses		
	$X_1$	...	$X_k$	$Y_1$	...	$Y_m$
1	$x_{11}$	...	$x_{1k}$	$y_{11}$	...	$y_{1m}$
...	...	...	...	...	...	...
n	$x_{n1}$	...	$x_{nk}$	$y_{n1}$	...	$y_{nm}$

جایی که  $x_{ij}$  و  $y_{ik}$  به ترتیب مقدار سطح فاکتور  $j$  ام و مقدار متغیر پاسخ  $k$  ام در  $i$  امین آزمایش می باشند.

گام ۲: به دست آوردن مطلوبیت سطوح پاسخ

در مرجع [۱۶] تابع مطلوبیت را برای بهینه سازی چند پاسخی معرفی کرده است. برای پاسخ های  $NTB^3$ ,  $LTB^4$ ,  $STB^5$  معرفی شده توسط تاگوچی، توابع مطلوبیت به ترتیب توسط (۴)، (۵) و (۶) محاسبه می شوند:

$$d_i = \begin{cases} \left( \frac{\hat{y}_i - y_{\min}}{T - y_{\min}} \right)^s, & y_{\min} \leq \hat{y}_i \leq T, s \geq 0 \\ \left( \frac{\hat{y}_i - y_{\max}}{T - y_{\max}} \right)^t, & T \leq \hat{y}_i \leq y_{\max}, t \geq 0 \\ 0, & \hat{y}_i < y_{\min} \text{ or } \hat{y}_i > y_{\max} \end{cases} \quad (4)$$

با توجه به جدول ۱- تفاوت های روش پیشنهادی با کارهای انجام شده به صورت زیر می باشد:

۱. استفاده از مفاهیم روش سطح پاسخ (تابع مطلوبیت) در بهینه سازی فرآیند با چند سطح پاسخ

۲. ارائه چندین گزینه بهینه به گونه ای که این امکان را فراهم می آورد که اگر شرایط آزمایشی اجازه ندهد یک ترکیب خاص از فاکتورها برای رسیدن به میزان بهینه فرآیند اجرا شود؛ روش پیشنهادی چندین گزینه را برای رسیدن به شرایط بهینه ارائه می دهد که موجب می شود این نقیصه تا آنجا که ممکن است برطرف شود. از آنجا که ممکن است حل بهینه به دست آمده، یک حل محلی<sup>۱</sup> باشد نه حل کلی<sup>۲</sup> با روش پیشنهادی چندین حل بهینه به دست می آید که این حالت را در نظر می گیرد.

### ۵. معرفی روش پیشنهادی

در این بخش، روشی برای بهینه سازی فرآیند با چند سطح پاسخ به وسیله شبکه های عصبی پیشنهاد می کند. گام های روش پیشنهادی به صورت زیر می باشند:

گام ۱: طراحی آزمایش یک فرآیند شامل بیش از یک متغیر پاسخ یک آزمایش با چند سطح پاسخ طراحی می شود که به فرآیندی مربوط می شود که شامل بیش از یک متغیر پاسخ با تکرار می باشد که در جدول ۲ نشان داده شد.

<sup>3</sup> Nominal-The-Best

<sup>4</sup> Larger-The-Best

<sup>5</sup> Smaller-The-Best

<sup>1</sup> Local Solution

<sup>2</sup> Global Solution

تست باشد. معیار مورد استفاده معیار میانگین مربع خطا<sup>۱</sup> (MSE) می باشد. همچنین برای مقایسه قابلیت شبکه عصبی با روش سطح پاسخ MSE داده های آموزش و تست شبکه عصبی انتخاب شده با روش سطح پاسخ مقایسه می گردد.

**گام ۴:** پیش بینی تمام ترکیبات سطوح فاکتورها پس از انتخاب شبکه، تمام ترکیبهای فاکتورهای ورودی در اختیار شبکه قرار می گیرند تا میزان مطلوبیت آنها محاسبه گردد.

**گام ۵:** به دست آوردن مطلوبیت کل هر آزمایش برای به دست آوردن مطلوبیت کل هر آزمایش پیش بینی شده، نیاز به جمع مقادیر مطلوبیت هر آزمایش می باشد. در مرجع [۱۶] میانگین هندسی را برای جمع مقادیر مطلوبیت معرفی کرده است. اگر آزمایشی دارای  $k$  متغیر پاسخ باشد، آنگاه (۷)

$$D = (d_1 \times d_1 \times \dots \times d_k)^{1/k} \quad (7)$$

مطلوبیت کل هر آزمایش را نشان می دهد.

**گام ۶:** تعیین سطوح بهینه فاکتورها بر مبنای مطلوبیت کل و مقایسه با روش سطح پاسخ برای تعیین سطوح بهینه فاکتورها، میزان مطلوبیت کل آزمایشهای پیش بینی شده را در نظر می گیریم. آزمایشهایی که دارای مقادیر مطلوبیت کل بیشتری نسبت به بقیه می باشند، به عنوان حل بهینه انتخاب می شوند. با توجه به میزان دقت شبکه های عصبی در پیش بینی، بیش از یک ترکیب آزمایش می تواند به عنوان ترکیب بهینه سطوح فاکتور انتخاب گردد. سپس حل بهینه به دست آمده به وسیله شبکه عصبی با حل بهینه به دست آمده از روش سطح پاسخ مقایسه می شود. الگوریتم روش پیشنهادی در شکل ۳- نشان داده شده است.



شکل ۳. الگوریتم روش پیشنهادی برای بهینه سازی چند پاسخ با استفاده از شبکه عصبی

$$d_i = \begin{cases} 0, & \hat{y}_i \leq y_{\min} \\ \left( \frac{\hat{y}_i - y_{\min}}{y_{\max} - y_{\min}} \right)^r, & y_{\min} \leq \hat{y}_i \leq y_{\max}, r \geq 0 \\ 1, & \hat{y}_i \geq y_{\max} \end{cases} \quad (5)$$

$$d_i = \begin{cases} 1, & \hat{y}_i \leq y_{\min} \\ \left( \frac{\hat{y}_i - y_{\max}}{y_{\min} - y_{\max}} \right)^r, & y_{\min} \leq \hat{y}_i \leq y_{\max}, r \geq 0 \\ 0, & \hat{y}_i \geq y_{\max} \end{cases} \quad (6)$$

جایی که  $\hat{y}_i$ ،  $d_i$ ،  $y_{\min}$ ،  $y_{\max}$  و  $T$  به ترتیب مقدار پیش بینی شده، مقدار مطلوبیت، حد پایین، حد بالا و مقدار هدف  $i$  امین متغیر پاسخ می باشند. ضمناً  $s$  و  $t$  و  $r$  وزن های مشخص شده توسط تصمیم گیرنده می باشند. در این مرحله با استفاده از رابطه های (۴)، (۵) و (۶) مقادیر مطلوبیت سطوح پاسخ در هر آزمایش محاسبه می شوند. از این پس متغیرهای پاسخ مقادیر مطلوبیت آنها می باشند که برای پیش بینی مورد استفاده قرار می گیرند.

**گام ۳:** تعیین شبکه عصبی مناسب برای پیش بینی مساله و مقایسه با روش سطح پاسخ

در این گام عصبی مناسب باید شناسایی شود. یکی از شبکه هایی که در زمینه پیش بینی در این گونه مسائل کاربرد زیادی دارد، شبکه پس انتشار پیش خور می باشد (جدول ۱). ما در این پژوهش از این نوع شبکه استفاده می کنیم.

از آنجا که در این مساله قرار است ارتباط بین فاکتورهای کنترل و متغیرهای پاسخ تعیین گردد و در یک شبکه عصبی تعداد نرونهای لایه ورودی و لایه خروجی به ترتیب برابر تعداد متغیرهای ورودی و خروجی می باشد [۵]، تعداد نرونهای لایه ورودی برابر تعداد فاکتورهای قابل کنترل ورودی و تعداد نرونهای خروجی برابر تعداد متغیرهای پاسخ می باشد. اما یکی از مهمترین فاکتورهای تاثیر گذار در انتخاب این گونه شبکه های عصبی، تعیین تعداد لایه های مخفی و تعداد نرونهای این لایه ها می باشد. در بیشتر موارد تعداد لایه های پنهان ۲ در نظر گرفته شده اند به این دلیل که این تعداد لایه توانایی بیان ارتباط غیرخطی بهتری بین نرونهای لایه ورودی و خروجی را دارند و خطای کمتری را ارائه می دهند. ما نیز همین تعداد لایه مخفی را بکار می بریم. اما برای تعیین تعداد نرونهای این دولایه تاکنون روش دقیقی معرفی نگردیده است.

برای تعیین تعداد نرونها، داده های آزمایشی به دو دسته داده های آموزشی و داده های تست طبقه بندی می شوند. آنگاه داده های آموزشی به شبکه عصبی داده می شوند تا شبکه آموزش ببیند و سپس برای مشخص شدن توانایی شبکه عصبی در پیش بینی سطوح پاسخ، داده های تست مورد استفاده قرار می گیرند. با تغییر تعداد نرونها در لایه های مخفی شبکه ای مناسب می باشد که دارای میزان خطای پیش بینی کمتری در رابطه با داده های آموزش و

<sup>1</sup> Mean Squared of Error

آزمایشهای شماره های ۶، ۱۱ و ۱۸ به صورت تصادفی به عنوان داده تست (۱۵ درصد کل داده ها) و بقیه به عنوان داده آموزش جهت تعیین سطح پاسخ مورد استفاده قرار گرفته اند. جدول ۵ میانگین مربع خطا برای ۸ شبکه عصبی مورد بررسی قرار گرفته را نشان می دهد. برای این شبکه ها، تعداد دوره (Epoch) آموزش برابر ۳۰۰۰۰ و نرخ یادگیری ۰.۰۰۱ انتخاب شد. همانطور که از جدول مشاهده می شود، شماره ۲ با تعداد نرونهای ۳ و ۴ در لایه های پنهان اول و دوم انتخاب می گردد. برای تعیین شبکه عصبی مناسب و آموزش آنها از جعبه ابزار Neural Network نرم افزار MATLAB استفاده گردید که به عنوان نمونه برای شبکه عصبی شماره ۱ در شکل ۴ نشان داده شده است. همچنین شکل ۵ معماری شبکه عصبی انتخاب شده را نشان می دهد.

حال از داده های آموزشی برای تعیین سطح پاسخ مناسب با استفاده از روش سطح پاسخ استفاده می شود. مدل رگرسیونی تابع مطلوبیت کل به صورت زیر می باشد. برای برآزش معادله مناسب، از نرم افزار MINITAB استفاده گردید.

$$\begin{aligned} Total\ Desiability = & 0.19652 + 0.07002x_1 + 0.07208x_2 + 0.08735x_3 \\ & - 0.01303x_4 - 0.28884x_5 + 0.00286x_1^2 + 0.13068x_3^2 \\ & - 0.01303x_1x_2 + 0.01051x_1x_3 + 0.10063x_1x_4 - 0.02880x_1x_5 \\ & - 0.10579x_2x_3 + 0.0307k_2x_4 \end{aligned}$$

## ۶. مثالی برای روش بهینه سازی فرآیند با چند سطح

### پاسخ به وسیله شبکه های عصبی

در این بخش یک مثال عددی برای بیان روش پیشنهادی در زمینه بهینه سازی فرآیند با چند سطح پاسخ به وسیله شبکه های عصبی ارائه می شود.


**گام ۱:** در مراجع [۲۹ و ۲] یک مثال با چهار سطح پاسخ معرفی شده است. از آنجا که سه متغیر پاسخ اول در این فرآیند بیشتر مد نظر بوده اند، این ۳ متغیر بررسی شده اند. چهارمین متغیر پاسخ درصد باکتریهای کشته شده در تولید یک محصول صابون می باشد. طرح به کار رفته  $2^{5-1}$  با چهار نقاط مرکزی است. تعداد سطوح فاکتورهای E, D, C, A و ۳، برای فاکتور B، ۲ می باشد. بنابراین تعداد کل ترکیبات فاکتورها برابر  $2^4 = 16$  می باشد. آزمایشهای انجام شده در جدول ۳ نشان داده شده است.

**گام ۲:** در این مرحله با استفاده از (۵، ۴ و ۶) مقادیر مطلوبیت سطوح پاسخ در هر آزمایش محاسبه می شوند. میزان مطلوبیت متغیرهای پاسخ و مطلوبیت کل در جدول ۴ محاسبه شده است

**گام ۳:** در این گام شبکه عصبی مناسب باید شناسایی شود. تعداد نرونهای لایه ورودی برابر ۵ و تعداد نرونهای خروجی برابر ۳ می باشد. تعداد لایه های پنهان ۲ در نظر گرفته شده اند. برای تعیین تعداد نرونهای این دو لایه، داده های آزمایشی به دو دسته داده های آموزشی و داده های تست طبقه بندی می شوند. داده های

جدول ۳. داده های آزمایش با سه سطح پاسخ

شماره آزمایش	فاکتور A	فاکتور B	فاکتور C	فاکتور D	فاکتور E	متغیر پاسخ ۱	متغیر پاسخ ۲	متغیر پاسخ ۳
۱	۰	-۱	۰	۰	۰	۲۵/۵۳	۱۸/۶۰	۸۸/۳۸
۲	-۱	-۱	-۱	۱	-۱	۵۴/۹۰	۱۲/۸۰	۹۹/۹۵
۳	۱	-۱	-۱	-۱	-۱	۳۶/۵۳	۳۲/۷۶	۹۹/۹۶
۴	۰	-۱	۱	۱	۱	۲۳/۴۷	۲۷/۴۷	۹۴/۳۱
۵	۱	۱	۱	۱	۱	۲۰/۹۲	۵۲/۰۵	۹۷/۴۷
۶	۰	۱	۰	۰	۰	۶۱/۷۰	۳۶/۶۳	۹۹/۹۰
۷	۱	-۱	-۱	۱	۱	۴۱/۴۸	۲۸/۳۴	۶۴/۶۲
۸	-۱	۱	-۱	-۱	-۱	۸۰/۲۳	۶۲/۵۷	۹۹/۹۹
۹	-۱	۱	۱	۱	-۱	۶۱/۷۰	۵۱/۰۷	۹۹/۹۹
۱۰	۰	۱	۰	۰	۰	۴۶/۱۳	۳۶/۳۶	۹۹/۱۷
۱۱	۱	-۱	۱	۱	-۱	۷۴/۴۴	۶۷/۴۴	۹۹/۵۲
۱۲	-۱	-۱	-۱	-۱	۱	۳۱/۸۹	۲۰/۴۹	۸۷/۸۶
۱۳	۱	۱	۱	-۱	-۱	۵۶/۷۷	۹۲/۲۳	۹۹/۹۹
۱۴	-۱	۱	-۱	۱	۱	۳/۳۳	۲۹/۵۱	۹۹/۸۲
۱۵	-۱	۱	۱	-۱	۱	۲۰/۰۰	۳۸/۹۰	۹۸/۵۰
۱۶	۱	۱	-۱	۱	-۱	۷۷/۶۲	۹۸/۷۶	۹۹/۹۹
۱۷	-۱	-۱	۱	۱	۱	۹/۴۶	-۸/۲۸	۹۳/۹۰
۱۸	-۱	-۱	۱	-۱	-۱	۸۰/۲۶	۴۷/۷۷	۹۹/۹۸
۱۹	۱	-۱	۱	-۱	۱	۳۵/۲۸	۲۴/۸۴	۹۵/۵۸
۲۰	۱	۱	-۱	-۱	۱	۳۸/۵۵	۱۳/۶۹	۹۹/۹۹



شکل ۵. شبکه عصبی استفاده شده با تعداد نرونهای ۳ و ۴ در لایه های پنهان اول و دوم

جدول ۶. جدول آنالیز واریانس


Analysis of Variance for total desirability						
Source	DF	Seq SS	Adj SS	Adj MS	F	P
Regression	13	1.42075	1.42075	0.109288	2.49	0.246
Linear	5	1.17697	1.32271	0.264542	6.02	0.085
Square	2	0.03694	0.03064	0.015322	0.35	0.731
Interaction	6	0.20684	0.20684	0.034473	0.78	0.635
Residual Error	3	0.13175	0.13175	0.043918		
Total	16	1.55250				

شکل ۶ نمودار اثرات اصلی فاکتورها را برای مطلوبیت کل نشان می دهد. این نمودار بیانگر میزان اثری است که با تغییر سطح فاکتور بر روی متغیر پاسخ اعمال می شود. به عنوان مثال با قرار دادن فاکتور A بر روی سطح بالای خود (سطح ۱) میزان مطلوبیت کل افزایش می یابد. شکل ۵ نمودار اثرات متقابل فاکتورها را برای مطلوبیت کل نشان می دهد. این نمودار بیانگر میزان اثر متقابلی است که فاکتورها به صورت دوجه دو بر روی متغیر پاسخ دارند. به عنوان مثال فاکتور A و فاکتور E اثر متقابلی بر روی هم دارند.

برای مقایسه دقت شبکه عصبی انتخاب شده با روش سطح پاسخ از معیار میانگین مربع خطا برای داده های آموزش و تست استفاده می شود. همانطور که در جدول ۶ نشان داده شده است، میزان دقت شبکه عصبی انتخاب شده هم برای داده آموزش و هم برای داده تست بالاتر از روش سطح پاسخ می باشد.

**گام ۴:** پس از انتخاب شبکه، تمام ترکیبهای فاکتورهای ورودی برای میزان مطلوبیت آنها پیش بینی می گردد.

**گام ۵:** برای به دست آوردن مطلوبیت کل هر آزمایش پیش بینی شده از (Y) استفاده می شود.



شکل ۶. نمودار اثرات اصلی برای مطلوبیت کل


جدول ۴. میزان مطلوبیت سطوح پاسخ

شماره آزمایش	مطلوبیت متغیر پاسخ ۱	مطلوبیت متغیر پاسخ ۲	مطلوبیت متغیر پاسخ ۳	مطلوبیت کل
۱	۰/۰۷	۰	۰	۰
۲	۰/۴۷	۰	۰/۹۹	۰
۳	۰/۲۱	۰/۱۶	۰/۹۹	۰/۳۲
۴	۰/۰۴	۰/۰۹	۰/۴۳	۰/۱۲
۵	۰/۰۱	۰/۴۰	۰/۷۵	۰/۱۴
۶	۰/۲۷	۰/۱۰	۰	۰
۸	۰/۷۵	۰/۵۳	۰/۹۹	۰/۷۳
۹	۰/۵۲	۰/۳۹	۰/۹۹	۰/۵۹
۱۰	۰/۳۳	۰/۲۰	۰/۹۲	۰/۳۹
۱۲	۰/۱۵	۰/۰۱	۰	۰
۱۳	۰/۴۶	۰/۹۰	۰/۹۹	۰/۷۴
۱۴	۰	۰/۱۲	۰/۹۸	۰
۱۵	۰	۰/۲۴	۰/۸۵	۰
۱۶	۰/۷۲	۰/۹۸	۰/۹۹	۰/۸۹
۱۷	۰	۰	۰/۳۹	۰
۱۹	۰/۱۹	۰/۰۶	۰/۵۶	۰/۱۹
۲۰	۰/۲۳	۰	۰/۹۹	۰

همچنین جدول ۶ بیانگر جدول آنالیز واریانس می باشد که میزان دقت مدل رگرسیونی را در برازش ارتباط خطی و درجه دوم بین متغیرهای ورودی و خروجی را نشان می دهد.

جدول ۵. مقایسه برای تعیین شبکه عصبی مناسب

ردیف	تعداد لایه های پنهان (لایه اول و دوم)	میانگین مربع خطا برای داده های آموزش	میانگین مربع خطا برای داده های تست
۱	۳ و ۳	۰/۰۰۸۰۶۹	۰/۲۶۸۲۵
۲	۴ و ۳	۸/۵۹۰۳۴ × ۱۰ <sup>-۵</sup>	۰/۰۲۱۹۰
۳	۵ و ۳	۷/۱۱۹۳۴ × ۱۰ <sup>-۵</sup>	۰/۲۴۳۲۵
۴	۴ و ۵	۳/۸۱۶۵۷ × ۱۰ <sup>-۲۵</sup>	۰/۲۷۷۷۷
۵	۵ و ۵	۲/۵۳۲۱۲ × ۱۰ <sup>-۲۵</sup>	۰/۳۲۸۹۶
۶	۶ و ۵	۶/۵۱۸۶۴ × ۱۰ <sup>-۲۹</sup>	۰/۲۷۰۰۷
۷	۵ و ۶	۶/۵۹۴۵۳ × ۱۰ <sup>-۲۵</sup>	۰/۳۰۸۰۸
۸	۶ و ۶	۱/۴۷۹۶۰ × ۱۰ <sup>-۲۶</sup>	۰/۳۷۰۳۸



شکل ۴. خروجی MATLAB برای شبکه شماره ۱




استفاده از شبکه های عصبی نسبت به روش سطح پاسخ به صورت زیر می باشند.

۱. هنگامی که داده های آزمایش زیاد باشد دقت شبکه های عصبی نسبت به روش سطح پاسخ هم برای داده آموزش و هم داده تست بالاتر است.
۲. تعداد حل بهینه به دست آمده از روش سطح پاسخ یکی است که ممکن است این حل محلی باشد نه حل کلی در حالی که با استفاده از روش شبکه عصبی چندین حل بهینه به دست می آید، که حل بهینه روش سطح پاسخ می تواند یکی از این حل ها باشد.
۳. از آنجا که شرایط آزمایشی ممکن است اجازه ندهد که یک ترکیب خاص از فاکتورها برای رسیدن به میزان بهینه فرآیند اجرا شود، روش شبکه های عصبی این امکان را فراهم می کند که چندین گزینه برای رسیدن به شرایط بهینه را ارائه می دهد در حالی که در روش سطح پاسخ فقط یک گزینه ارائه می شود.
۴. در مقایسه این پژوهش با کارهای انجام شده در زمینه شبکه های عصبی، استفاده از مفاهیم روش سطح پاسخ (تابع مطلوبیت) در بهینه سازی و ارائه چندین گزینه بهینه از قابلیت های روش پیشنهادی می باشد.

### ۷. نتیجه گیری

در این مقاله مقایسه ای بین روش سطح پاسخ با شبکه های عصبی در تعیین سطوح بهینه فرآیند با چند سطح پاسخ بر مبنای مفهوم مطلوبیت انجام گرفت. مقاله حاضر با کارگیری نقاط قوت روش های موجود در ادبیات موضوع مقاله حاضر هم مفهوم روش سطح پاسخ (تابع مطلوبیت) در بهینه سازی فرآیند با چند سطح پاسخ را به کار برده و هم از نقاط قوت شبکه عصبی استفاده کرده است که به عنوان یکی از جدیدترین تکنیک ها برای بیان پیچیدگی سیستمها مورد توجه می باشد. خروجی روش پیشنهادی به گونه ای است که با ارائه چندین گزینه این امکان را فراهم می آورد تا اگر شرایط آزمایشی اجازه ندهد یک ترکیب خاص از فاکتورها برای رسیدن به میزان بهینه فرآیند اجرا شود که متأسفانه تا کنون به آن توجه نشده است. همانطور که دیده شد گرچه تعیین نوع شبکه عصبی مناسب زمانبر است ولی از لحاظ دقت مناسب تر می باشد. در ضمن هنگام تعیین سطوح بهینه با استفاده از شبکه های عصبی با توجه به دقت بالای شبکه های عصبی در پیش بینی می توان چندین ترکیب بهینه برای سطوح فاکتور تعیین کرد تا با توجه به شرایط آزمایش یکی از آنها انتخاب گردد در حالی که با استفاده از روش سطح پاسخ فقط یک ترکیب بهینه انتخاب می گردد. همچنین ترکیب بهینه به دست آمده از روش سطح پاسخ می تواند یکی از جوابهای بهینه به دست آمده از روش شبکه عصبی می باشد که قابلیت دیگر استفاده از شبکه های عصبی را نشان می دهد. در آینده می توان از روشهایی چون سیستم استنتاج فازی برای به



شکل ۷. نمودار اثرات متقابل برای مطلوبیت کل

جدول ۷. محاسبه دقت شبکه عصبی با روش سطح

پاسخ	
میانگین مربع خطا برای داده های تست	میانگین مربع خطا برای داده های آموزش
۰/۰۲۱۹۰	۸/۵۹۰۳۴×۱۰ <sup>-۵</sup>
۰/۱۲۴۲۱	۰/۰۱۱۴۴

شبکه عصبی استفاده شده در این مقاله  
روش سطح پاسخ

**گام ۶:** برای تعیین سطوح بهینه فاکتورها، میزان مطلوبیت کل آزمایشهای پیش بینی شده را در نظر می گیریم. آزمایشهای با میزان مطلوبیت بالا در جدول ۸ آورده شده است. برای به دست آوردن سطح بهینه از روش گرادیان کاهششی تعمیم یافته (Generalized Reduced Gradient) استفاده شد [۳۰]. برای به کارگیری این روش می توان از Excel Solver استفاده کرد؛ در نهایت سطوح بهینه فاکتور به صورت زیر می باشند.

$$x_1^* = 1, x_2^* = 1, x_3^* = -1, x_4^* = 1, x_5^* = -1$$

میزان حل بهینه ۰/۹۰۳۰ می باشد. همانطور که مشاهده می شود حل بهینه به دست آمده از روش سطح پاسخ یکی از حل های بهینه به دست آمده از روش شبکه های عصبی (آزمایش شماره ۱۲۲) می باشد.

جدول ۸. تعیین سطوح بهینه فاکتورها

شماره آزمایش	فاکتور A	فاکتور B	فاکتور C	فاکتور D	فاکتور E	مطلوبیت کل
۱۲۸	۱	۱	۰	-۱	-۱	۰/۸۹۷۶
۵۶	۰	۱	-۱	-۱	-۱	۰/۸۹۷۳
۱۲۲	۱	۱	-۱	۱	-۱	۰/۸۸۹۱
۱۳۰	۱	۱	۰	-۱	۰	۰/۸۸۷۲
۱۵۰	۱	۱	۱	-۱	۱	۰/۸۸۵۵
۶۸	۰	۱	-۱	۱	-۱	۰/۸۸۴۸
۱۱۰	۱	۱	-۱	-۱	-۱	۰/۸۸۳۳
۱۶۰	۱	۱	۱	۱	۰	۰/۸۸۲۰

علیرغم اینکه ساخت شبکه عصبی مناسب برای یک فرآیند نسبت به روش سطح پاسخ زمانبر است، با توجه به مثال بیان شده مزایای

- دست آوردن مطلوبیت کل بهره گرفت و حتی با ارائه تکنیک هایی بین گزینه های بهینه ارائه شده توسط شبکه عصبی اولویت‌هایی بنابه شرایط آزمایش تعیین نمود. همچنین رویکرد شبکه عصبی معرفی شده می تواند برای بهینه سازی فرآیند با چند سطح پاسخ در طرح های پایدار مورد استفاده قرار گیرد.
- منابع**
- [14] Wang, C.H., "Dynamic Multi-Response Optimization Using Principal Component Analysis and Multiple criteria evaluation of the grey relation model", International Journal of Advanced Manufacturing Technology, 32, 2007, pp. 617-624.
- [15] Hsieh, K.L., Tong, L.H., Chiu, H.P., Yeh, H.Y., "Optimization of a Multi-Response Problem in Taguchi's Dynamic System", Computers & Industrial Engineering, 49, 2005, pp. 556-571.
- [16] Kim, Y.S., "Comparison of the Decision Tree, Artificial Neural Network, and Linear Regression Methods Based on the Number and Types of Independent Variables and Sample Size", Expert Systems with Applications, 2008, In Press.
- [17] Hsieh, K., Tong, L., "Optimization of Multiple Quality Responses Involving Qualitative and Quantitative Characteristics in IC Manufacturing Using Neural Networks", Computers in Industry, 46, 1-12, 2001.
- [18] Chang, H.H., "A Data Mining Approach to Dynamic Multiple Responses in Taguchi Experimental Design", Expert Systems with Applications, 2008, In Press.
- [19] Agatonovic-Kustrin, S., Zecevicb, M., Zivanovicb, Lj., Tucker, I.G., "Application of Neural Networks for Response Surface Modeling in HPLC Optimization", Analytica Chimica Acta, 364, 1998, pp. 265-273.
- [20] Ozcelik, B., Erzurumlu, T., "Comparison of the Warpage Optimization in the Plastic Injection Molding Using ANOVA, Neural Network Model and Genetic Algorithm", Journal of Materials Processing Technology, 171, 2006, pp. 437-445.
- [21] Erzurumlu, T., Oktem, H., "Comparison of Response Surface Model with Neural Network in Determining the Surface Quality of Moulded Parts", Materials and Design, 28, 2007, pp. 459-465.
- [22] Liao, H.C., "A Data Envelopment Analysis Method for Optimizing Multi-Response Problem with Censored Data in Taguchi Method", Computers & Industrial Engineering, 46, 2004, pp. 817-835.
- [23] Cheng, J., Li, Q.S., Xiao, R.C., "A New Artificial Neural Network-Based Response Surface Method for Structural Reliability Analysis", Probabilistic Engineering Mechanics, 23, 2008, pp. 51-63.
- [24] Tsao, C.C., "Comparison Between Response Surface Methodology and Radial Basis Function Network for Core-Center Drill in Drilling Composite Materials", International Journal of Advanced Manufacturing Technology, 2008, In Press.
- [25] Gomez, H.M., Awruch, A.M., "Comparison of Response Surface and Neural Network with Other Methods for Structural Reliability Analysis", Structural Safety, 26, 2004, pp. 49-67.
- [26] Namvar-Asl M., Soltanieh M., Rashidi A., Irandokht A., "Modeling and Preparation of Activated Carbon for Methane Storage: (I) Modeling of Activated Carbon Characteristics with Neural Networks and Response Surface Method", Energy Conversion and Management, DOI:10.1016/j.enconman.2008.01.039, 2009, In Press.
- [1] Montgomery, D.C., "Design and Analysis of Experiments", 6th Edition, John Wiley & Sons, 2006.
- [2] Ryan, T.P., "Modern Experimental Design", John Wiley & Sons, 2007
- [3] Desai, K.M., Survase, S.A., Saudgar, P.S., Lele, S.S., Singhal, R.S., "Comparison of Artificial Neural Network (ANN) and Response Surface Methodology (RSM) in Fermentation Media Optimization: Case Study of Fermentative Production of Scleroglucan", Biochemical Engineering Journal, 2009, In press.
- [4] Myers, R.H., "Response Surface Methodology- Current Status and Future Directions", Journal of Quality Technology, 31(1), 1999, pp. 30-44.
- [5] Du, K.L., Swamy, M.N.S., "Neural Networks in Softcomputing Framework", Springer, 2006.
- [6] Derringer, G., Suich, R., "Simultaneous Optimization of Several Response Variables", Journal of Quality Technology, 12, 1980, pp. 214-219.
- [7] Khuri, A., Conlon, M., "Simultaneous Optimization of Multiple Responses Represented by Polynomial Regression Functions", Technometrics, 23, 1981, pp. 363-375.
- [8] Oritz, F., Simpson, J.R, Pignatiello, J.J., Heredia-Langer, A., "A Genetic Algorithm Approach to Multiple-Response Optimization", Journal of Quality Technology, 36, 2004, pp. 432-450.
- [9] Del Castillo, E., Montgomery, D.C., "A Nonlinear Programming Solution to the Dual Response Problem", Journal of Quality Technology, 25(3), 1993, pp. 199-204.
- [10] Vining, G.G., Bohn L.L., "Response Surface for the Mean and Variance Using a Nonparametric Approach", Journal of Quality Technology, 30(3), 1998, pp. 282-291.
- [11] Kazemzadeh, R.B., Bashiri, M., Atkinson A., C., Noorossana, R., "A General Framework for Multiresponse Optimization Problems Based on Goal Programming", European Journal of Operational Research, 189, 2008, pp. 421-429.
- [12] Del Castillo, E., Montgomery, D.C., McCarville, D.R., "Modified Desirability Functions for Multiple Response Optimization", Journal of Quality Technology, 28(3), 1996, pp. 337-345.
- [13] Tong, L.I., Chen, C.C., Wang, C.H., "Optimization of Multi-Response Processes Using the VIKOR Method", International Journal of Advanced Manufacturing Technology, 31, 2007, pp. 1049-1057.

- [27] Nikolaidis, E., Long, L., Ling, Q., "Neural Networks and Response Surface Polynomials for Design of Vehicle Joints", Computers and Structures, 75, 2000, pp. 593-607.
- [28] Hsieh, K.L., "Parameter Optimization of a Multi-Response Process for Lead Frame Manufacturing by Employing Artificial Neural Networks", International Journal of Advanced Manufacturing Technology, 28, 2006, pp. 584-591.
- [29] Tang, Y.C., Zhou, X.H., Chen, J., "Preform Tool Shape Optimization and Redesign Based on Neural Network Response Surface Methodology", Finite Elements in Analysis and Design, 44, 2008, pp. 462 – 471.
- [30] Luenberger, D.C., "Linear and Nonlinear Programming", 2nd ed, Addison-Wesley, Reading, MA, 1989.