

## مدل سازی تأثیر درصد مصالح سنگی شکسته در مقاومت مارشال آسفالت با بکارگیری شبکه های عصبی مصنوعی\*

ابوالفضل حسنی، دانشیار، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران  
علی حیدری پناه، دانشجوی دکتری، دانشکده فنی - مهندسی، دانشگاه تربیت مدرس، تهران، ایران  
E-mail: [hassani@modares.ac.ir](mailto:hassani@modares.ac.ir)

### چکیده

درصد مصالح سنگی شکسته یکی از مهم ترین عوامل مؤثر در مقاومت فشاری آسفالت و عملکرد آن است. تأثیر آن در مقاومت مارشال آسفالت به کمک آزمایش مارشال قابل ارزیابی است و به نظر می رسد که تاکنون مدل سازی ریاضی خاصی برای آن انجام نشده است. در این تحقیق تأثیر درصد مصالح سنگی شکسته در مقاومت فشاری بتن آسفالتی توسط شبکه های عصبی پرسپترون چند لایه پیشرو و الگوریتم آموزش انتشار به عقب، با تکنیک بهینه سازی عددی لونیگ-مارکوات، مدل سازی شده است.

به این منظور در صدهای عبوری از الک های شماره ۲۰۰.۵۰، ۳۰، ۸۰، ۴۰ و ۱/۲ اینچ، درصد مصالح سنگی شکسته و درصد قیر به عنوان ورودی های شبکه و مقاومت مارشال، خروجی شبکه در نظر گرفته شده است. سپس حداکثر توان تعمیم پذیری هر شبکه با تعداد مشخص نرون (۳،۶،۸،۱۰) در لایه پنهان برای شبیه سازی داده های جدید تعیین شده است. بررسی های انجام شده نشان می دهند که توان شبیه سازی شبکه ها به میزان آموزش بسیار حساس بوده و با افزایش آموزش از یک حد معین، شبکه دچار آموزش بیش از حد شده و توان تعمیم پذیری آن به شدت کاهش می یابد، بنابر این دستیابی به بیشترین توان شبیه سازی، مستلزم تلاش فراوان خواهد بود. مقایسه این مقادیر بیشینه نشان می دهد که با افزایش تعداد نرونهای لایه پنهان تا ۸ عدد، توان شبیه سازی شبکه ها به حداکثر رسیده و افزایش بیشتر نرونهای لایه پنهان تأثیر قابل توجهی بر توان شبیه سازی شبکه ندارد. در مرحله بعد با انجام تحلیل حساسیت توسط شبکه ای که بیشترین توان شبیه سازی را داراست، روند تغییرات مقاومت مارشال نسبت به درصد مصالح شکسته مدل سازی شده است. نتایج به دست آمده نشان می دهند که مقاومت مارشال آسفالت با افزایش درصد مصالح شکسته، افزایش می یابد که با روند نظری مطابقت دارد.

واژه های کلیدی: شبکه های عصبی مصنوعی، انتشار به عقب، تحلیل حساسیت، مقاومت مارشال، در صد مصالح سنگی شکسته

### ۱. مقدمه

آنها را به یکدیگر چسبانده است تشکیل شده و مرغوب ترین نوع آسفالت به شمار می رود. مصالح سنگی بتن آسفالتی شامل

بتن آسفالتی از یک استخوان بندی مصالح سنگی خوب دانه بندی شده با فضای خالی مناسب که قیر سطح دانه ها را اندود کرده و

در مرحله بعد با مقایسه خروجی های شبکه و مقادیر واقعی، مقدار خطا محاسبه می شود و سپس با پس انتشار خطا از نرونهای خروجی به سمت ورودی وزن های شبکه اصلاح می شوند، به گونه ای که خطای آموزش شبکه کاهش یابد. به همین دلیل این روش، انتشار به عقب نامیده می شود [۴ و ۳]. چرخه های رفت و برگشت آن قدر تکرار می شود تا MSE کمینه شود. الگوریتم انتشار به عقب همانند قانون آموزش کمینه میانگین مربعات (LMS) یک الگوریتم بیشترین کاهش (SD) است.

این الگوریتم در واقع روش LMS را به شبکه های چند لایه ای با توابع غیرخطی تعمیم می دهد [2]. طی فرآیند آموزش در این روش دسته ای از نمونه های رفتار درست و دلخواه شبکه به آن، ارائه می شود:

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_q, t_q\} \quad (1)$$

که در آن:

$p_q$  بردار ورودی شبکه و  $t_q$  بردار هدف نظیر آن است. هنگامی که یک ورودی به شبکه داده می شود، خروجی شبکه با هدف مقایسه می شود.

الگوریتم باید با پس انتشار خطا پارامترهای شبکه را به گونه ای تنظیم کند که MSE کمینه شود [2].

$$F(\mathbf{x}) = E[e^2] = E[(t-a)^2] \quad (2)$$

در رابطه ۲،  $X$  بردار وزن ها و بایاس ها است. در صورتی که شبکه چندین خروجی داشته باشد رابطه به صورت زیر تعمیم می یابد:

$$F(\mathbf{x}) = E[\mathbf{e}^T \mathbf{e}] = E[(\mathbf{t} - \mathbf{a})^T](\mathbf{t} - \mathbf{a}) \quad (3)$$

که در آن :

$$X = \text{بردار وزن ها و بایاس ها}$$

$$e = \text{بردار خطا}$$

$$t = \text{بردار هدف}$$

$$a = \text{بردار خروجی}$$

همانند الگوریتم LMS، میانگین مربع خطا به صورت زیر تخمین زده می شود [۳]:

$$\hat{F}(\mathbf{x}) = (\mathbf{t}(k) - \mathbf{a}(k))^T \quad (4)$$

$$(\mathbf{t}(k) - \mathbf{a}(k)) = \mathbf{e}^T(k) \mathbf{e}(k)$$

که در رابطه ۴ :

مصالح سنگی درشت دانه، ریز دانه و فیلر است. یکی از عوامل مؤثر در مقاومت مارشال و قابلیت باربری لایه های آسفالتی در صد شکستگی مصالح سنگی درشت دانه است [1]. هرچه این پارامتر بیشتر باشد، زاویه اصطکاک داخلی بین مصالح سنگی افزایش یافته و دانه های آنها بیشتر در یکدیگر قفل و بست شده و در نتیجه مقاومت مارشال بتن آسفالتی افزایش می یابد. بنابراین در صد مصالح شکسته یکی از معیار های مهم در طرح و کنترل کیفی آسفالت است و به نظر می رسد که مدل ریاضی خاصی برای تأثیر آن در مقاومت مارشال ارائه نشده است. در این تحقیق تأثیر آن در مقاومت مارشال، به کمک شبکه های عصبی مصنوعی مدل سازی شده است.

استفاده از شبکه های عصبی مصنوعی (ANNs) در زمینه های مختلف مهندسی راه و ترابری مانند طراحی روسازی، طرح اختلاط، مدیریت تعمیر و نگهداری راه، مهندسی ترافیک و سایر زمینه ها در حال حاضر در حال توسعه و پیشرفت است. گروه تحقیقاتی آیین نامه آشتو ۲۰۰۲ که ادامه توسعه پروژه شارپ 1-37A بر مبنای طراحی مکانیستیک است، شبکه های عصبی مصنوعی را برای راهنمای طراحی روسازی بتنی آشتو ۲۰۰۲ مورد استفاده قرار داده است.

شبکه های عصبی مصنوعی مورد استفاده در این تحقیق از نوع پرسپترون چندین لایه پیشرو با الگوریتم آموزش انتشار به عقب لونبرگ - مارکوات (LMBP) است [2]. برای مدل سازی تغییرات مقاومت مارشال نسبت به درصد مصالح شکسته، ابتدا یک مدل شبکه عصبی مصنوعی برای تخمین مقاومت مارشال آسفالت بر اساس عوامل مؤثر در آن ایجاد شده است. سپس روند تغییرات مقاومت مارشال با درصد مصالح سنگی شکسته، با انجام تحلیل حساسیت، شبیه سازی شده است.

کلیه آنالیزها به کمک جعبه ابزار شبکه های عصبی مصنوعی نرم افزار MATLAB انجام اند.

## ۲. الگوریتم انتشار به عقب

آموزش شبکه فرآیندی است که طی آن وزن ها و بایاس های شبکه به گونه ای تغییر می کنند که خطای آموزش MSE کمینه شود. این فرآیند از سه مرحله تشکیل شده است. مرحله اول انتشار ورودی ها از نرون های ورودی به سمت نرونهای خروجی است.

توابع غیر خطی هستند طراحی شده است. این تکنیک به صورت زیر شکل می گیرد:

(۹)

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T(\mathbf{x}_k)\mathbf{J}(\mathbf{x}_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}_k)\mathbf{v}(\mathbf{x}_k) \quad (10)$$

$$\Delta \mathbf{x}_k = -[\mathbf{J}^T(\mathbf{x}_k)\mathbf{J}(\mathbf{x}_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}_k)\mathbf{v}(\mathbf{x}_k)$$

در روابط ۹ و ۱۰:

$\mathbf{J}$  = ماتریس ژاکوبین

$\mathbf{I}$  = ماتریس واحد

$\mathbf{v}$  = بردار خطا

$\nabla F(\mathbf{x})$  = گرادیان  $F$

ویژگی بسیار مفید الگوریتم آن است که زمانی که  $\mu_k$  افزایش می یابد، الگوریتم لونیبرگ - مارکوات به عملکرد الگوریتم بیشترین کاهش (SD) با نرخ آموزش کم، نزدیک می شود:

(۱۱) برای مقادیر بزرگ  $\mu_k$

$$\mathbf{x}_{k+1} \cong \mathbf{x}_k - \frac{1}{\mu_k} \mathbf{J}^T(\mathbf{x}_k)$$

$$\mathbf{v}(\mathbf{x}_k) = \mathbf{x}_k - \frac{1}{2\mu_k} \nabla F(\mathbf{x})$$

و زمانی که  $\mu_k$  به صفر کاهش می یابد، الگوریتم تبدیل به روش گوس نیوتن می شود [۲]. برای شروع  $\mu_k$  مقدار کوچکی مثلاً  $\mu_k = 0.001$  در گرفته می شود.

این پارامتر در کد نویسی با  $\mu$  نشان داده می شود. اگر مقدار  $F(\mathbf{x})$  پس از اولین مرحله کمتر نشده باشد، این مرحله به جای  $\mu_k$ ، با حاصلضرب آن در یک عدد بزرگ تر از یک  $(\mu\text{-inc})$ ، مثلاً  $10 > \mu$  تکرار می شود.

نهایتاً  $F(\mathbf{x})$  باید کاهش یابد چون گام کوچکی در جهت بیشترین کاهش برداشته شده است. اگر  $F(\mathbf{x})$  کاهش نیافت، برای گام بعدی  $\mu_k$  را بر  $\mu$  تقسیم می کنیم ( $\mu\text{-dec}$ )، بنابراین الگوریتم به روش گوس- نیوتن نزدیک شده که این روش، همگرایی سریع تری را ایجاد می کند.

ویژگی قابل توجه و منحصر به فرد الگوریتم لونیبرگ - مارکوات آن است که سرعت روش نیوتن را با تضمین همگرایی روش بیشترین کاهش، همراه می کند [2].

خطا در تکرار  $k$  ام جایگزین برآورد خطا شده است. الگوریتم بیشترین کاهش SD برای MSE به صورت زیر است:

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial w_{i,j}^m} \quad (5)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m} \quad (6)$$

در روابط ۵ و ۶:

$w_{i,j}^m$  = وزن نرون  $i$ ام لایه  $m$  که خروجی نرون  $j$ ام لایه

$m-1$  را دریافت می کند

$b_i^m$  = بایاس نرون  $i$ ام لایه  $m$

$\alpha$  = نرخ آموزش

شاخص عملکرد شبکه MSE طی فرآیند آموزش بهینه می شود. در این جا منظور از بهینه کردن  $F(\mathbf{x})$  یافتن مقداری برای  $\mathbf{x}$  است که  $F(\mathbf{x})$  به ازای آن کمینه شود.

روشهای بهینه سازی عبارتند از:

۱- الگوریتم بیشترین کاهش

۲- روش نیوتن

۳- روش گرادیان مجازی

تمامی روشهای فوق بر مبنای تکرار شکل می گیرند. الگوریتم با یک حدس اولیه برای  $\mathbf{X}$  مانند  $\mathbf{X}_0$  آغاز می شود و با معادله ای به شکل زیر مقدار جدید  $\mathbf{X}$  به دست می آید.

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k \quad (7)$$

$$\Delta \mathbf{x}_k = (\mathbf{x}_{k+1} - \mathbf{x}_k) = \alpha_k \mathbf{p}_k \quad (8)$$

در روابط ۷ و ۸، بردار  $\mathbf{p}_k$  بیانگر جهت جستجو و مقدار عددی مثبت  $\alpha_k$  نرخ آموزش است که طول هر گام را مشخص می کند و  $\mathbf{x}_k$  بردار وزنها و بایاسهای شبکه در چرخه یا تکرار  $k$ ام است. الگوریتم های فوق در انتخاب جهت جستجو  $\mathbf{p}_k$  تفاوت دارند. در این تحقیق از روش بهینه سازی عددی لونیبرگ- مارکوات استفاده شده است [2].

## ۱-۲ الگوریتم انتشار به عقب لونیبرگ- مارکوات

الگوریتم لونیبرگ- مارکوات در واقع یک تغییر بر روی روش نیوتن است که برای کمینه کردن توابعی که جمع مربعات سایر

## ۳. تهيه داده ها

به منظور تهيه داده هاى مورد نياز براى آموزش و ارزيابى توان تعميم پذيرى شبكه ها، نمونه هاى بتن آسفالتى از آسفالت پخش شده در سطح راه و قبل از تراكم، جمع آورى شده است. نمونه ها شامل ۸۶ نمونه بيندر با حداكثر اندازه اسمى ۱۹ و ۲۴ ميليمتر نمونه توپكا با حداكثر اندازه اسمى ۱۲/۵ ميليمتر و قير آنها از نوع خالص با درجه نفوذ ۷۰-۶۰ است. با انجام ۱۱۰ آزمائش مقاومت مارشال و ۱۱۰ آزمائش جداسازى و ۱۱۰ آزمائش تعيين درصد مصالح شكسته بر روى اين نمونه ها، مقاومت مارشال، درصد قير، منحنى دانه بندى، و درصد مصالح سنگى شكسته آنها تعيين شده است.

۸۵ سرى از داده هاى به دست آمده براى آموزش شبكه ها و ۲۵ سرى براى ارزيابى توان تعميم پذيرى آنها مورد استفاده قرار گرفته است [5].

## ۴. مدل شبكه عصبى مصنوعى

مقاومت مارشال بتن آسفالتى به عوامل مختلفى چون خصوصيات و دانه بندى مصالح سنگى، نوع و درصد قير مصرفى بستگى دارد. براى ايجاد مدل، درصد هاى عبورى از الك هاى ۳۰، ۲۰۰، ۵۰، ۸، ۴، و ۱/۲ اينچ، درصد مصالح سنگى شكسته و درصد قير مجموعاً ۸ متغير، به عنوان ورودى هاى شبكه و مقاومت مارشال به عنوان خروجى شبكه در نظر گرفته شده است، بنا بر اين تعداد نرون هاى لايه ۰ يا لايه ورودى ۸ عدد و تعداد نرون هاى لايه خروجى ۱ عدد است [5]. ورودى ها و خروجى شبكه و محدوده تغييرات آنها در جدول (۱) نشان داده شده است.

براى نرون هاى لايه ميانى از تابع انتقال تانژانت سيگمويد و نرون هاى لايه پنهان از تابع انتقال خطى استفاده شده است. براى عملکرد بهتر شبكه، تمامى داده هاى ورودى و خروجى بين ۱ و ۱- نرمال شده اند.

براى تعيين تعداد مناسب نرون ها در لايه ميانى شبكه هاى متعدد با تعداد مختلف نرون در لايه پنهان طراحى شده و توان شبكه سازى هر شبكه با تعداد مشخص نرون در لايه پنهان در سطوح مختلف آموزش، مورد ارزيابى قرار گرفته است كه روندان در قسمت هاى ۴-۱ و ۴-۲ تشریح شده است.

## ۴-۱ آموزش و تعميم پذيرى

در اين تحقيق شبكه هاى با ۸، ۵، ۳ و ۱۰ نرون در لايه پنهان طراحى شده اند. ۸۵ عدد از داده ها براى آموزش اين شبكه ها و ۲۵ عدد ديگر براى ارزيابى توان تعميم پذيرى آنها مورد استفاده قرار گرفته اند. فرآيند تعيين شبكه اى كه داراى بيشترين توان تعميم پذيرى يا شبكه سازى است به شرح زير است:

۱- در مرحله اول براى هر شبكه با تعداد مشخص نرون در لايه پنهان، تغييرات توان تعميم پذيرى با خطاى آموزش (MSE) ارزيابى شده و نتايج حاصل در جدولهاى ۲ تا ۵ و نمودارهاى ۲ تا ۵ در قسمت ۴-۲ ارايه شده اند. براى هر شبكه با تعداد معين نرون در لايه پنهان، بيشينه توان تعميم پذيرى به كمك نمودارهاى فوق تعيين شده است.

۲- در مرحله دوم با مقايسه بيشينه مقادير تعميم پذيرى فوق، شبكه اى كه داراى بيشترين توان تعميم پذيرى است تعيين و براى انجام تحليل حساسيت در قسمت ۵ مورد استفاده قرار گرفته است. براى ارزيابى ملموس تر، فرآيند آموزش شبكه با سه نرون در لايه پنهان در نمودار ۱ نشان داده شده است. خط پيوسته نشان دهنده خطاى آموزش است. همان طور كه ديده مى شود با افزايش چرخه هاى آموزش (epochs)، خطاى آموزش كاهش مى يابد.

خط منقطع نشان دهنده خطاى شبكه سازى ۲۵ داده جديد است. همان طور كه مشاهده مى شود با شروع آموزش، خطاى شبكه سازى آغاز به كاهش مى كند تا به كمينه مقدار خود مى رسد كه در اين نقطه شبكه داراى بيشترين توان تعميم پذيرى است. پس از آن با ادامه آموزش، خطاى شبكه سازى افزايش يافته و توان شبكه سازى كاهش مى يابد و اصطلاحاً شبكه، آموزش بيش از حد<sup>۱</sup> پيدا مى كند [6].

فرآيند تغييرات خطاى شبكه سازى با نوسانات موضعى همراه است. همان طور كه در شكل ۱ مشاهده مى شود بيشترين توان تعميم پذيرى شبكه در چرخه هاى نخستين آموزش حاصل مى شود.

## ۴-۲ نمودارهاى تعميم پذيرى

در اين قسمت براى شبكه هاى داراى ۳، ۶، ۸ و ۱۰ نرون در لايه پنهان حداكثر توان تعميم پذيرى تعيين شده است. به اين منظور براى هر شبكه با تعداد مشخص نرون در لايه پنهان، توان

تعميم پذيرى در سطوح مختلف آموزش (خطاى آموزش) تعيين شده و نتايج در جدولهاى ۲ تا ۵ ارايه شده اند. در اين جدولها اولين ستون از سمت چپ نشان دهنده نام شبكه است. ستون دوم مقدار اوليه انتخاب شده براى پارامتر  $\mu$  است كه در قسمت ۲-۱ تشریح شد و در كد هاى برنامه با  $\mu$  نشان داده مى شود. ستونهاى سوم و چهارم،  $\mu$ -inc و  $\mu$ -dec، پارامتر هاى تنظيم كننده سرعت آموزش شبكه هستند كه در قسمت ۲-۱ تشریح شده اند. ستون پنجم پارامتر GOAL، خطاى آموزش تعيين شده براى توقف آموزش است. ستون ششم يا MSE، نشان دهنده خطاى آموزشى است كه شبكه در آن متوقف شده است و performance نيز ناميده مى شود. همان گونه كه در شكل ۱ مشاهده مى شود، بيشترين توان تعميم پذيرى در چرخه هاى اوليه آموزش حاصل مى شود، بنا بر اين براى متوقف كردن آموزش در سطح مورد نظر (MSE=GOAL)، در بسيارى از موارد سرعت آموزش بايد تا حد امكان كند شود كه براى اين منظور پارامتر هاى  $\mu$ \_inc و  $\mu$ \_dec نزديك به ۱ در نظر گرفته شده اند. تحليل هاى انجام شده نشان مى دهند كه توان تعميم پذيرى شبكه ها به خطاى آموزش بسيار حساس است و روند آموزش به مقدار اوليه وزنها نيز بستگى دارد.

با توجه به اين كه مقدار دهى اوليه وزنها به صورت اتفاقى است و نيز بيشترين توان تعميم پذيرى در چرخه هاى اوليه آموزش حاصل مى شود و با توجه به حساس بودن توان تعميم پذيرى شبكه ها به خطاى آموزش، با وجود كند كردن روند آموزش، توقف آموزش در حدود نزديك به خطاى مورد نظر (GOAL) دشوار بوده و براى هر شبكه مستلزم آموزش مجدد براى دفعات متعدد با مقادير مختلف وزن هاى اوليه است.

ستون آخر نشان دهنده ضريب همبستگى است كه نشان دهنده توان تعميم پذيرى شبكه است. نحوه محاسبه آن به اين گونه است كه پس از اتمام آموزش هر شبكه با ۸۵ داده، ۲۵ داده جديد به شبكه ارايه مى شود. سپس با انجام رگرسيون خطى بين نتايج شبكه سازى شبكه و مقادير واقعى يا هدف، ضريب همبستگى R محاسبه شده است.

هر چه اين ضريب به ۱ نزديك تر باشد توان تعميم پذيرى شبكه بيشتر است. براى ارزيابى تغييرات توان شبكه سازى هر شبكه با تعداد مشخص نرون در لايه پنهان، نمودار تغييرات ضريب همبستگى در برابر خطاى آموزش ترسيم و نتايج در نمودارهاى شماره ۲ تا ۵ ارايه شده است.

جدول ۱. ورودى ها و

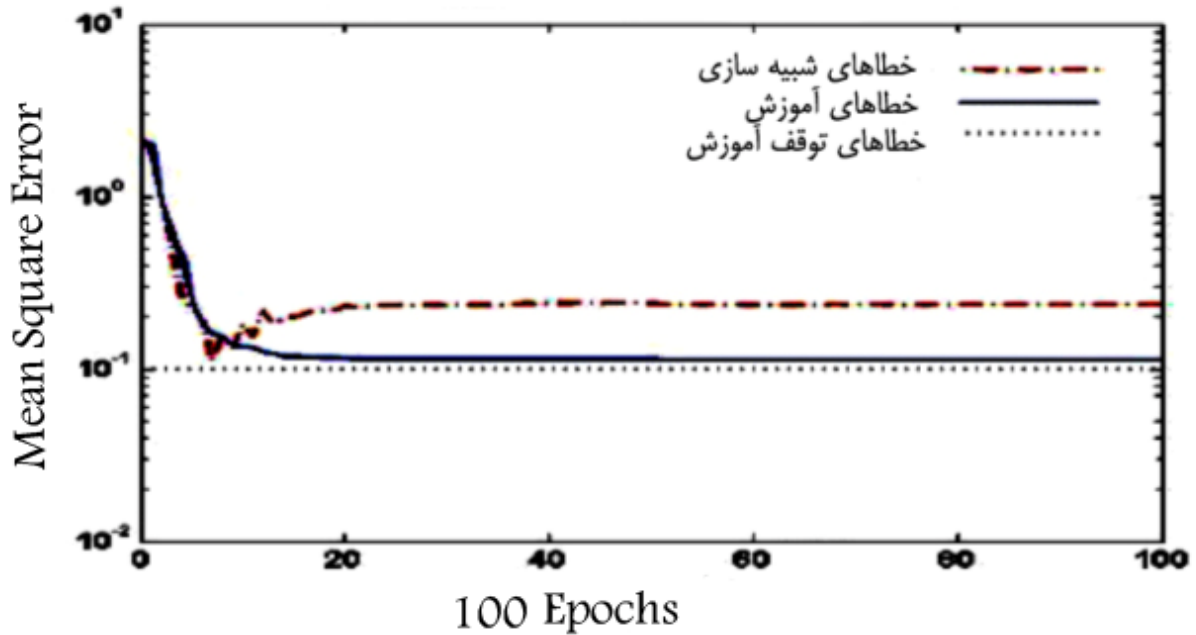
خروجى شبكه و محدوده تغييرات آنها

شماره ۴	
درصد عبورى از الك ۱/۲ اينچ	۸۶-۱۰۰
درصد مصالح سنگى شكسته	۵۰-۹۲
درصد قير	۳/۵۳-۵/۸۲
خروجى شبكه	محدوده تغيير
مقاومت مارشال (kg)	۸۶۶-۱۶۶۱

ورودى هاى شبكه	محدوده تغييرات
درصد عبورى از الك شماره ۲۰۰ (فيلر)	۲/۵-۱۰
درصد عبورى از الك شماره ۵۰	۸-۱۹
درصد عبورى از الك شماره ۳۰	۱۲-۳۱
درصد عبورى از الك شماره ۸	۳۱-۵۴
درصد عبورى از الك	۴۸-۷۷



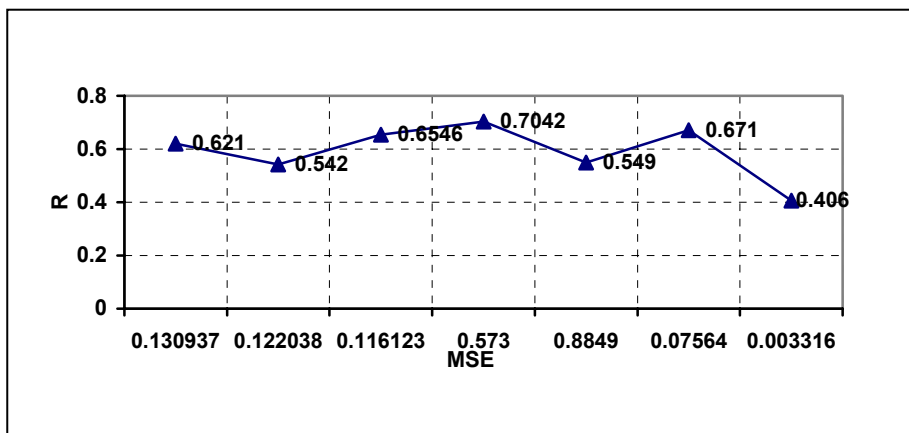
Performance is 0.112456 – Goal is 0.099



نمودار ۱. روند آموزش و تغييرات خطای شبیه سازی برای شبکه دارای ۳ نرون در لایه پنهان

جدول ۲. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای ۳ نرون در لایه پنهان


Network	$\mu$	mu_inc	mu_dec	Goal	MSE	R
RT3P11	۱/۵	۱/۵	۰/۵	۰/۱۴	۰/۱۴۱۰۸۱	۰/۵۶۱
RT3P10	۱/۵	۱/۵	۰/۵	۰/۱	۰/۱۳۰۹۳۷	۰/۶۲۱
RT3P3	۱/۵	۱/۵	۰/۵	۰/۱	۰/۱۲۲۰۳۸	۰/۵۴۲
RT3P4	۱/۵	۱/۵	۰/۵	۰/۱۱	۰/۱۱۶۱۲۳	۰/۶۵۴۶
RT3P5	۱/۵	۱/۵	۰/۵	۰/۰۷	۰/۰۵۷۳۰	۰/۷۰۴۲
RT3P6	۰/۰۰۱	۱۰	۰/۱	۰/۹	۰/۰۸۸۴۹	۰/۵۴۹
RT3P7	۱/۵	۱/۵	۰/۵	۰/۰۹۹	۰/۰۷۵۶۳۹۵	۰/۶۷۱
RT3P8	۲	۰/۰۱	۰/۹۸	۰/۹	۰/۰۳۳۱۵۹۱	۰/۴۰۶



نمودار ۲. تغييرات ضريب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای ۳ نرون در لایه پنهان

جدول ۳. پارامترهاى آموزش و نتايج شبیه سازی برای شبکه های دارای ۶ نرون در لایه پنهان


Network	$\mu$	mu_inc	mu_dec	Goal	MSE	R
RT6P1	۲	۰/۹۸	۱/۰۱	۰/۰۹۹	۰/۰۸۶۶۸۳۱	۰/۳۸۸
RT6P7	۲	۰/۹	۱/۱	۰/۴	۰/۰۹۱۸۶	۰/۶۳۷۳
RT6P3	۲	۰/۹	۱/۱	۰/۹۷	۰/۰۹۳۳۰۰۵	۰/۶۹۵
RT6P4	۲	۰/۹	۱/۱	۰/۰۹۷	۰/۰۹۴۱۲۷۶	۰/۷۱۳
RT6P6	۲	۰/۹	۱/۱	۰/۰۹۸	۰/۰۹۵۴۳۴	۰/۵۱۹
RT6P2	۲	۰/۹	۱/۱	۰/۰۹۹	۰/۰۹۷۲۶۸۵	۰/۵۷۱
RT6P5	۲	۰/۹	۱/۱	۰/۰۹۸	۰/۰۹۷۵۳۸۱	۰/۶۹۹
RT6P8	۲	۰/۹	۱/۱	۰/۱	۰/۰۹۸۳۲۴۴	۰/۷۰۹
RT6P9	۲	۰/۹	۱/۱	۰/۱۱	۰/۱۰۵۹۷۶	۰/۶۱
RT6P10	۲	۰/۹	۱/۱	۰/۱۱	۰/۱۱۹۳۲۳	۰/۶۳۴



نمودار ۳. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای ۶ نرون در لایه پنهان

جدول ۴. پارامترهاى آموزش و نتايج شبیه سازی برای شبکه های دارای ۸ نرون در لایه پنهان

Network	$\mu$	mu_inc	mu_dec	Goal	MSE	R
RT8P1	۰/۰۰۱	۰/۱	۱۰	۳,۷۰۹E-۲۹	۳,۷۰۹E-۲۹	۰/۰۱۰۹
RT8P11	۲	۰/۹۸	۱/۰۱	۰/۰۸	۰/۰۷۸۹۹۹۷۰	۰/۴۸
RT8P10	۲	۰/۹۸	۱/۰۱	۰/۰۹	۰/۰۸۵۵۸۹	۰/۷۵۶۱
RT8P3	۲	۰/۹۸	۱/۰۱	۰/۰۹۱	۰/۰۸۶۹۹۹۶	۰/۶۸۴
RT8P4	۲	۰/۹۸	۱/۰۱	۰/۰۹۱	۰/۰۸۸۰۱۲۳	۰/۵۸۶
RT8P5	۲	۰/۹۸	۱/۰۱	۰/۰۹	۰/۰۸۹۰۱۱۶	۰/۷۶۸
RT8P6	۲	۰/۹۸	۱/۰۱	۰/۰۹۲	۰/۰۹۰۴۶۸۴	۰/۷۲۶
RT8P7	۲	۰/۹۸	۱/۰۱	۰/۱	۰/۰۹۶۸۰۵	۰/۵۷۸
RT8P8	۲	۰/۹۸	۱/۰۱	۰/۰۹۵	۰/۰۹۴۱۶۷۷	۰/۷۳۷




نمودار ۴. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای ۸ نرون در لایه پنهان



جدول ۵. پارامترهاى آموزش و نتايج شبیه سازی برای شبکه های دارای ۱۰ نرون در لایه پنهان


Network	$\mu$	mu_inc	mu_dec	Goal	MSE	R
RT10P1	۱/۵	۱/۰۱	۰/۹۹	۰	۰/۰۶۴۰۹۲۵	۰/۵۸۵
RT10P4	۱/۵	۱/۰۱	۰/۹۹	۰/۰۸	۰/۰۷۷۳۲	۰/۴۸۸
RT10P5	۱/۵	۱/۰۱	۰/۹۹	۰/۰۸	۰/۰۸۷۰۹۵	۰/۶۸
RT10P3	۱/۵	۱/۰۱	۰/۹۹	۰/۰۸	۰/۰۹۰۹۵	۰/۷۴۳
RT10P7	۱/۵	۱/۰۱	۰/۹۹	۰/۰۹۳	۰/۰۹۲۶۶۳۴	۰/۶۵
RT10P5	۱/۵	۱/۰۱	۰/۹۹	۰/۰۹۳	۰/۰۹۸۳۴۰۹	۰/۶۸۳
RT10P6	۱/۵	۱/۰۱	۰/۹۹	۰/۰۸	۰/۱۰۱۱۹۷	۰/۶۸۳



نمودار ۵. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای ۱۰ نرون در لایه پنهان

جدول ۶. تغییرات مقاومت مارشال یک نمونه بتن آسفالتی برای در صد های مختلف مصالح سنگی شکسته

شماره ۲۰۰	شماره ۵۰	شماره ۳۰	شماره ۸	شماره ۴	۱/۲ اینچ	قیر (درصد)	شکستگی (درصد)	مقاومت فشاری (کیلوگرم)
۵	۱۳	۲۳	۴۳	۶۶	۹۳	۴/۷۹	۴۵	۱۲۵۸/۹
"	"	"	"	"	"	"	۵۰	۱۲۶۲/۱
"	"	"	"	"	"	"	۵۵	۱۲۶۴/۸
"	"	"	"	"	"	"	۶۰	۱۲۶۷
"	"	"	"	"	"	"	۶۵	۱۲۶۸/۸
"	"	"	"	"	"	"	۷۰	۱۲۷۰/۷
"	"	"	"	"	"	"	۷۵	۱۲۷۳/۵
"	"	"	"	"	"	"	۸۱	۱۲۷۹/۶
"	"	"	"	"	"	"	۸۵	۱۲۸۶/۵
"	"	"	"	"	"	"	۹۰	۱۲۹۹/۱
"	"	"	"	"	"	"	۹۵	۱۳۱۶/۷
"	"	"	"	"	"	"	۱۰۰	۱۳۳۸/۵



نمودار ۶. تغییرات مقاومت مارشال نمونه بتن آسفالتی به صورت تابعی از تغییرات در صد مصالح سنگی شکسته



## ۵. تحليل حساسيت

برای مدل سازی روند تغییرات مقاومت مارشال بتن آسفالتی با درصد مصالح سنگی شکسته، تحلیل حساسیت توسط شبکه RT8P5 که دارای بیشترین توان شبیه سازی است، انجام شده است. روند کار به این صورت است که برای یک نمونه آسفالتی، برای درصد های مختلف مصالح شکسته شده، سایر ورودی های شبکه مانند درصد قیر مصرفی و درصدهای عبوری از الک های ۲۰۰، ۵۰، ۳۰، ۸، ۴ و ۱/۲ ثابت در نظر گرفته شده و مقاومت مارشال نمونه برای این ورودی ها و درصدهای مختلف مصالح شکسته شده، توسط شبکه RT8P5 محاسبه شده است که نتایج در جدول ۶ و نمودار ۶ نشان داده شده اند. همان طور که در نمودار ۶ مشاهده می شود با افزایش درصد مصالح شکسته، مقاومت فشاری آسفالت نیز افزایش می یابد.

از دیدگاه نظری نیز افزایش درصد مصالح شکسته، موجب افزایش زاویه اصطکاک داخلی بین مصالح سنگی و در نتیجه افزایش مقاومت مارشال مخلوط آسفالتی می شود، بنابراین فرآیند شبیه سازی باروند نظری مطابقت دارد.

## ۶. نتایج

در این تحقیق ابتدا یک مدل شبکه عصبی مصنوعی LMBP برای تخمین مقاومت مارشال آسفالت ارایه شده که برای آموزش آن از ۸۵ و برای ارزیابی آن از ۲۵ سری داده استفاده شده است. سپس با انجام تحلیل حساسیت روند تغییرات مقاومت فشاری آسفالت با درصد مصالح شکسته مدل سازی شده که نتایج حاصل به شرح زیرند:

۱- برای هر شبکه با تعداد مشخص نرون در لایه پنهان، با افزایش چرخه ها و کاهش خطای آموزش، توان تعمیم پذیری شبکه، تا رسیدن به حداکثر مقدار خود افزایش می یابد و پس از آن، شبکه آموزش بیش از حد پیدا کرده و توان تعمیم پذیری آن کاهش می یابد، به گونه ای که برای شبکه RT8P1 با ۸ نرون در لایه پنهان، در خطای آموزش

۲۹-۱۰×۳/۷۱ ضریب همبستگی  $R=0/0109$  حاصل می شود.

۲- تحلیل های انجام شده نشان می دهند که توان تعمیم پذیری شبکه ها نسبت به تغییرات خطای آموزش بسیار حساس است. به علاوه حداکثر توان تعمیم پذیری در چرخه های اولیه آموزش حاصل می شود و از سوی دیگر روند آموزش به مقدار اولیه وزن ها نیز بستگی دارد.

بنابراین با وجود کند کردن روند آموزش، متوقف کردن آن در مقادیر نزدیک به مقدار مورد نظر، دشوار بوده و برای هر شبکه مستلزم آموزش مجدد با مقادیر مختلف وزنه های اولیه، برای دفعات متعدد است.

۳- برای مدل سازی انجام شده در این تحقیق، افزایش تعداد نرون ها تا ۸ عدد توان تعمیم پذیری شبکه را افزایش داده و افزایش بیشتر، تغییر قابل توجهی در آن ایجاد نمی کند. با استفاده از ۸ نرون در لایه پنهان، بیشینه توان شبیه سازی برای شبکه RT8P5 با ضریب همبستگی  $R=0/768$  در خطای آموزش ۰/۰۸۹۰۱۱۶ حاصل می شود که با توجه به تعداد کم داده های آموزشی و تعدد عوامل مؤثر، مناسب است.

۴- روند شبیه سازی شده تغییرات مقاومت مارشال آسفالت نسبت به درصد مصالح سنگی شکسته با انجام تحلیل حساسیت، نشان می دهد که با افزایش درصد مصالح شکسته، مقاومت مارشال آسفالت افزایش می یابد. از دیدگاه نظری، افزایش درصد مصالح شکسته موجب افزایش زاویه اصطکاک داخلی بین مصالح سنگی و در نتیجه افزایش مقاومت مارشال آسفالت می شود، بنابراین روند شبیه سازی شده با روند نظری مطابقت دارد.

۷. مراجع

5. Heidaripناه, A. (2003) "Estimation of Marshal stability of asphalt concrete using artificial neural networks", M.Sc. Thesis, University of Kerman, Iran.

6. MATLAB 7 (2004) "Neural network toolbox user's guide", Math Works Inc.

1. Wright, K Paul and Dixon, K Karen (2004) "Highway engineering", John Wiley & Sons Inc., 7<sup>th</sup>. edition.

2. Hagan, Martin, T. and Demuth, Howard B. (2000) "Neural network design", Mark Beale MHB, Inc. PWS Publishing Company.

۳. كاوه ع.، ثروتى، ه. (۱۳۷۸) "شبكة هاى عصبى مصنوعى در تحليل و طراحى سازه ها"، مركز تحقيقات ساختمان و مسكن، نشریه شماره ك- ۳۲۰، چاپ دوم.

4. Topping, B.H.V. and Bahreininejad, A. (1997) "Neural computing for structural mechanics", Sax-Coburg Publications.

پانویس ها:

1. Artificial Neural Networks
2. Levenberg - Marquadt Back Propagation
3. Mean Square Error
4. Least Mean Square
5. Steepest Decent
6. Overfitting