

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

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 مصنوعی 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 الگ های شماره 200، 50، 30، 8، 4، و 1/2 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 (3، 6، 8، 10) 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 8 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

1. 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 مقايسه خروجى هاى شبكه و مقادير واقعى، مقدار خطا محاسبه مى شود و سپس با پس انتشار خطا از نرونهاى خروجى به سمت ورودى وزن هاى شبكه اصلاح مى شوند، به گونه اى كه خطاى آموزش شبكه کاهش يابد. به همين دليل اين روش، انتشار به عقب ناميده مى شود [2 و 3 و 4]. چرخه هاى رفت و برگشت آن قدر تكرر مى شود تا MSE كمينه شود. الگوريتم انتشار به عقب همانند قانون آموزش كمينه ميانگين مربعات (LMS⁴) يك الگوريتم بيشتريين کاهش (SD⁵) است.

اين الگوريتم در واقع روش LMS را به شبكه هاى چند لايه اى با توابع غيرخطى تعميم مى دهد [2]. طى فرايند آموزش در اين روش دسته اى از نمونه هاى رفتار درست و دلخواه شبكه به آن، ارايه مى شود:

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

كه در آن:

p_q بردار ورودى شبكه و t_q بردار هدف نظير آن است. هنگامى كه يك ورودى به شبكه داده مى شود، خروجى شبكه با هدف مقايسه مى شود.

الگوريتم بايد با پس انتشار خطا پارامترهاى شبكه را به گونه اى تنظيم كند كه MSE كمينه شود [2].

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

در رابطه 2، x بردار وزن ها و باياس ها است. در صورتى كه شبكه چندين خروجى داشته باشد رابطه به صورت زير تعميم مى يابد:

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

كه در آن:

$$x = \text{بردار وزن ها و باياس ها}$$

$$e = \text{بردار خطا}$$

$$t = \text{بردار هدف}$$

$$a = \text{بردار خروجى}$$

همانند الگوريتم LMS، ميانگين مربع خطا به صورت زير تخمين زده مى شود [3]:

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

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

كه در رابطه 4:

مصالح سنگى درشت دانه، ريز دانه و فيلر است. يكي از عوامل مؤثر در مقاومت مارشال و قابليت باربرى لايه هاى آسفالتى در صد شكستگى مصالح سنگى درشت دانه است [1]. هرچه اين پارامتر بيشتتر باشد، زاويه اصطكاك داخلى بين مصالح سنگى افزايش يافته و دانه هاى آنها بيشتتر در يكدیگر قفل و بست شده و در نتيجه مقاومت مارشال بتن آسفالتى افزايش مى يابد. بنابراین در صد مصالح شكسته يكي از معيار هاى مهم در طرح و كنترل كيفى آسفالت است و به نظر مى رسد كه مدل رياضى خاصى براى تأثير آن در مقاومت مارشال ارايه نشده است. در اين تحقيق تأثير آن در مقاومت مارشال، به كمك شبكه هاى عصبى مصنوعى مدل سازى شده است.

استفاده از شبكه هاى عصبى مصنوعى (ANNs¹) در زمينه هاى مختلف مهندسى راه و ترابرى مانند طراحى روسازى، طرح اختلاط، مديريت تعمير و نگهدارى راه، مهندسى ترافيك و ساير زمينه ها در حال حاضر در حال توسعه و پيشرفت است. گروه تحقيقاتى آيين نامه آشتو 2002 كه ادامه توسعه پروژه شارپ 1-37A بر مبنای طراحى مكانیستیک است، شبكه هاى عصبى مصنوعى را براى راهنمای طراحى روسازى بننى آشتو 2002 مورد استفاده قرار داده است.

شبكه هاى عصبى مصنوعى مورد استفاده در اين تحقيق از نوع پرسپترون چندين لايه پيشرو با الگوريتم آموزش انتشار به عقب لونبرگ - ماركوآت (LMBP²) است [2]. براى مدل سازى تغييرات مقاومت مارشال نسبت به درصد مصالح شكسته، ابتدا يك مدل شبكه عصبى مصنوعى براى تخمين مقاومت مارشال آسفالت بر اساس عوامل مؤثر در آن ايجاد شده است. سپس روند تغييرات مقاومت مارشال با درصد مصالح سنگى شكسته، با انجام تحليل حساسيت، شبیه سازى شده است.

كليه آناليزها به كمك جعبه ابزار شبكه هاى عصبى مصنوعى نرم افزار MATLAB⁷ انجام اند.

2. الگوريتم انتشار به عقب

آموزش شبكه فرايندى است كه طى آن وزن ها و باياس هاى شبكه به گونه اى تغيير مى كنند كه خطاى آموزش MSE³ كمينه شود. اين فرايند از سه مرحله تشكيل شده است. مرحله اول انتشار ورودى ها از نرون هاى ورودى به سمت نرونهاى خروجى است.

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

(9)

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

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

در روابط 9 و 10:

\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 μ_k افزایش می یابد، الگوریتم لونبرگ - مارکوات به عملکرد الگوریتم بیشترین کاهش (SD) با نرخ آموزش کم، نزدیک می شود:

(11) برای مقادیر بزرگ μ_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 μ_k به صفر کاهش می یابد، الگوریتم تبدیل به روش گوس نیوتن می شود [2]. برای شروع μ_k مقدار کوچکی مثلاً $0.001 = \mu_k$ در گرفته می شود.

این پارامتر در کد نویسی با μ نشان داده می شود. اگر مقدار $F(\mathbf{x})$ پس از اولین مرحله کمتر نشده باشد، این مرحله به جای μ_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 μ_k را بر μ 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 لونبرگ - 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 5 و 6:

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

$m-1$ را دریافت می کند

b_i = بایاس نرون i ام لایه m

α = 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:

1- الگوریتم بیشترین کاهش

2- روش نیوتن

3- 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 7 و 8، بردار \mathbf{p}_k بیانگر جهت جستجو و مقدار عددی مثبت α_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 لونبرگ- مارکوات استفاده شده است [2].

2-1 الگوریتم انتشار به عقب لونبرگ- مارکوات

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

3. تهیه داده ها

به منظور تهیه داده های مورد نیاز برای آموزش و ارزیابی توان تعمیم پذیری شبکه ها، نمونه های بتن آسفالتی از آسفالت پخش شده در سطح راه و قبل از تراکم، جمع آوری شده است. نمونه ها شامل 86 نمونه بیندر با حداکثر اندازه اسمی 19 و 24 میلیمتر نمونه توپکا با حداکثر اندازه اسمی 12/5 میلیمتر و قیر آنها از نوع خالص با درجه نفوذ 60-70 است. با انجام 110 آزمایش مقاومت مارشال و 110 آزمایش جداسازی و 110 آزمایش تعیین درصد مصالح شکسته بر روی این نمونه ها، مقاومت مارشال، درصد قیر، منحنی دانه بندی، و درصد مصالح سنگی شکسته آنها تعیین شده است. 85 سری از داده های به دست آمده برای آموزش شبکه ها و 25 سری برای ارزیابی توان تعمیم پذیری آنها مورد استفاده قرار گرفته است [5].

4. مدل شبکه عصبی مصنوعی

مقاومت مارشال بتن آسفالتی به عوامل مختلفی چون خصوصیات و دانه بندی مصالح سنگی، نوع و درصد قیر مصرفی بستگی دارد. برای ایجاد مدل، درصد های عبوری از الک های 30، 200، 50، 8، 4 و 1/2 اینچ، درصد مصالح سنگی شکسته و درصد قیر مجموعاً 8 متغیر، به عنوان ورودی های شبکه و مقاومت مارشال به عنوان خروجی شبکه در نظر گرفته شده است، بنابراین تعداد نرونهای لایه 0 یا لایه ورودی 8 عدد و تعداد نرونهای لایه خروجی 1 عدد است [5]. ورودی ها و خروجی شبکه و محدوده تغییرات آنها در جدول (1) نشان داده شده است. برای نرونهای لایه میانی از تابع انتقال تانژانت سیگموئید و نرونهای لایه پنهان از تابع انتقال خطی استفاده شده است. برای عملکرد بهتر شبکه، تمامی داده های ورودی و خروجی بین 1 و 1- نرمال شده اند.

برای تعیین تعداد مناسب نرونها در لایه میانی شبکه های متعدد با تعداد مختلف نرون در لایه پنهان طراحی شده و توان شبیه سازی هر شبکه با تعداد مشخص نرون در لایه پنهان در سطوح مختلف آموزش، مورد ارزیابی قرار گرفته است که روند آن در قسمت های 1-4 و 2-4 تشریح شده است.

4-1 آموزش و تعمیم پذیری

در این تحقیق شبکه هایی با 3، 5، 8 و 10 نرون در لایه پنهان طراحی شده اند. 85 عدد از داده ها برای آموزش این شبکه ها و 25 عدد دیگر برای ارزیابی توان تعمیم پذیری آنها مورد استفاده قرار گرفته اند. فرآیند تعیین شبکه ای که دارای بیشترین توان تعمیم پذیری یا شبیه سازی است به شرح زیر است:

1- در مرحله اول برای هر شبکه با تعداد مشخص نرون در لایه پنهان، تغییرات توان تعمیم پذیری با خطای آموزش (MSE) ارزیابی شده و نتایج حاصل در جدولهای 2 تا 5 و نمودارهای 2 تا 5 در قسمت 4-2 ارایه شده اند. برای هر شبکه با تعداد معین نرون در لایه پنهان، بیشینه توان تعمیم پذیری به کمک نمودارهای فوق تعیین شده است.

2- در مرحله دوم با مقایسه بیشینه مقادیر تعمیم پذیری فوق، شبکه ای که دارای بیشترین توان تعمیم پذیری است تعیین و برای انجام تحلیل حساسیت در قسمت 5 مورد استفاده قرار گرفته است. برای ارزیابی ملموس تر، فرآیند آموزش شبکه با سه نرون در لایه پنهان در نمودار 1 نشان داده شده است. خط پیوسته نشان دهنده خطای آموزش است. همان طور که دیده می شود با افزایش چرخه های آموزش (epochs)، خطای آموزش کاهش می یابد.

خط منقطع نشان دهنده خطای شبیه سازی 25 داده جدید است. همان طور که مشاهده می شود با شروع آموزش، خطای شبیه سازی آغاز به کاهش می کند تا به کمینه مقدار خود می رسد که در این نقطه شبکه دارای بیشترین توان تعمیم پذیری است. پس از آن با ادامه آموزش، خطای شبیه سازی افزایش یافته و توان شبیه سازی کاهش می یابد و اصطلاحاً شبکه، آموزش بیش از حد¹ پیدا می کند [6].

فرآیند تغییرات خطای شبیه سازی با نوسانات موضعی همراه است. همان طور که در شکل 1 مشاهده می شود بیشترین توان تعمیم پذیری شبکه در چرخه های نخستین آموزش حاصل می شود.

4-2 نمودارهای تعمیم پذیری

در این قسمت برای شبکه های دارای 3، 6، 8 و 10 نرون در لایه پنهان حداکثر توان تعمیم پذیری تعیین شده است. به این منظور برای هر شبکه با تعداد مشخص نرون در لایه پنهان، توان

تعمیم پذیری در سطوح مختلف آموزش (خطای آموزش) تعیین شده و نتایج در جدولهای 2 تا 5 ارایه شده اند. در این جدولها اولین ستون از سمت چپ نشان دهنده نام شبکه است. ستون دوم مقدار اولیه انتخاب شده برای پارامتر μ است که در قسمت 1-2 تشریح شد و در کد های برنامه با μ نشان داده می شود. ستونهای سوم و چهارم، μ -inc و μ -dec، پارامتر های تنظیم کننده سرعت آموزش شبکه هستند که در قسمت 1-2 تشریح شده اند. ستون پنجم پارامتر GOAL، خطای آموزش تعیین شده برای توقف آموزش است. ستون ششم یا MSE، نشان دهنده خطای آموزشی است که شبکه در آن متوقف شده است و performance نیز نامیده می شود. همان گونه که در شکل 1 مشاهده می شود، بیشترین توان تعمیم پذیری در چرخه های اولیه آموزش حاصل می شود، بنابراین برای متوقف کردن آموزش در سطح مورد نظر (MSE=GOAL)، در بسیاری از موارد سرعت آموزش باید تا حد امکان کند شود که برای این منظور پارامتر های μ -inc و μ -dec نزدیک به 1 در نظر گرفته شده اند. تحلیل های انجام شده نشان می دهند که توان تعمیم پذیری شبکه ها به خطای آموزش بسیار حساس است و روند آموزش به مقدار اولیه وزنها نیز بستگی دارد.


با توجه به این که مقدار دهی اولیه وزنها به صورت اتفاقی است و نیز بیشترین توان تعمیم پذیری در چرخ های اولیه آموزش حاصل می شود و با توجه به حساس بودن توان تعمیم پذیری شبکه ها به خطای آموزش، با وجود کند کردن روند آموزش، توقف آموزش در حدود نزدیک به خطای مورد نظر (GOAL) دشوار بوده و برای هر شبکه مستلزم آموزش مجدد برای دفعات متعدد با مقادیر مختلف وزن های اولیه است.

ستون آخر نشان دهنده ضریب همبستگی است که نشان دهنده توان تعمیم پذیری شبکه است. نحوه محاسبه آن به این گونه است که پس از اتمام آموزش هر شبکه با 85 داده، 25 داده جدید به شبکه ارایه می شود. سپس با انجام رگرسیون خطی بین نتایج شبیه سازی شبکه و مقادیر واقعی یا هدف، ضریب همبستگی R محاسبه شده است.

هر چه این ضریب به 1 نزدیک تر باشد توان تعمیم پذیری شبکه بیشتر است. برای ارزیابی تغییرات توان شبیه سازی هر شبکه با تعداد مشخص نرون در لایه پنهان، نمودار تغییرات ضریب همبستگی در برابر خطای آموزش ترسیم و نتایج در نمودارهای شماره 2 تا 5 ارایه شده است.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

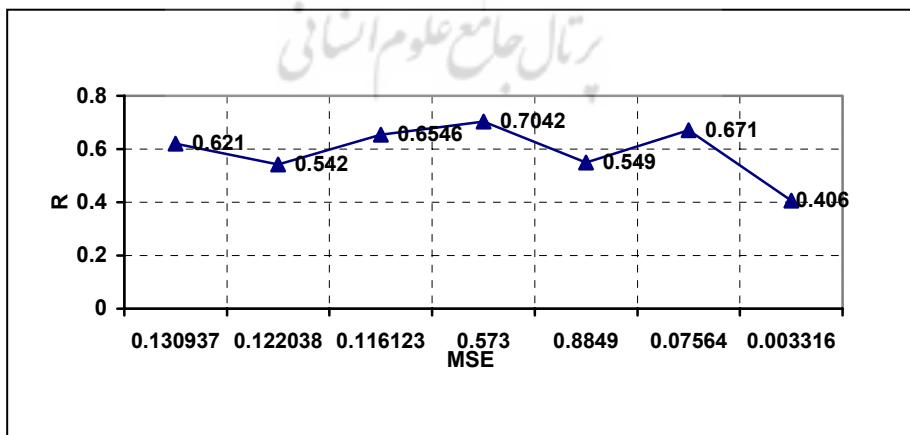
Performance is 0.112456 – Goal is 0.099



نمودار 1. روند آموزش و تغییرات خطای شبیه سازی برای شبکه دارای 3 نرون در لایه پنهان

جدول 2. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای 3 نرون در لایه پنهان


Network	μ	mu_inc	mu_dec	Goal	MSE	R
RT3P11	1/5	1/5	0/5	0/14	0/141081	0/561
RT3P10	1/5	1/5	0/5	0/1	0/130937	0/621
RT3P3	1/5	1/5	0/5	0/1	0/122038	0/542
RT3P4	1/5	1/5	0/5	0/11	0/0116123	0/6546
RT3P5	1/5	1/5	0/5	0/07	0/05730	0/7042
RT3P6	0/001	10	0/1	0/9	0/08849	0/549
RT3P7	1/5	1/5	0/5	0/099	0/0756395	0/671
RT3P8	2	0/01	0/98	0/9	0/00331591	0/406



نمودار 2. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای 3 نرون در لایه پنهان

جدول 3. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای 6 نرون در لایه پنهان


Network	μ	mu_inc	mu_dec	Goal	MSE	R
RT6P1	2	0,98	1/01	0,099	0,0866831	0,388
RT6P7	2	0,9	1/1	0,4	0,09186	0,6373
RT6P3	2	0,9	1/1	0,97	0,0933005	0,695
RT6P4	2	0,9	1/1	0,097	0,0941276	0,713
RT6P6	2	0,9	1/1	0,098	0,095434	0,519
RT6P2	2	0,9	1/1	0,099	0,0972685	0,571
RT6P5	2	0,9	1/1	0,098	0,0975381	0,699
RT6P8	2	0,9	1/1	0,1	0,0983244	0,709
RT6P9	2	0,9	1/1	0,11	0,105976	0,61
RT6P10	2	0,9	1/1	0,11	0,119323	0,634



نمودار 3. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای 6 نرون در لایه پنهان

جدول 4. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای 8 نرون در لایه پنهان


Network	μ	mu_inc	mu_dec	Goal	MSE	R
RT8P1	0,001	0,1	10	3.709e-29	3.709e-29	0,0109
RT8P11	2	0,98	1/01	0,08	0,07899970	0,48
RT8P10	2	0,98	1/01	0,09	0,085589	0,7561
RT8P3	2	0,98	1/01	0,091	0,0869996	0,684
RT8P4	2	0,98	1/01	0,091	0,0880123	0,586
RT8P5	2	0,98	1/01	0,09	0,0890116	0,768
RT8P6	2	0,98	1/01	0,092	0,0904684	0,726
RT8P7	2	0,98	1/01	0,1	0,096805	0,578
RT8P8	2	0,98	1/01	0,095	0,0941677	0,737



نمودار 4. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای 8 نرون در لایه پنهان

جدول 5. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای 10 نرون در لایه پنهان


Network	μ	mu_inc	mu_dec	Goal	MSE	R
RT10P1	1/5	1/01	0/99	0	0/0640925	0/585
RT10P4	1/5	1/01	0/99	0/08	0/07732	0/488
RT10P5	1/5	1/01	0/99	0/08	0/087095	0/68
RT10P3	1/5	1/01	0/99	0/08	0/09095	0/743
RT10P7	1/5	1/01	0/99	0/093	0/0926634	0/65
RT10P5	1/5	1/01	0/99	0/093	0/0983409	0/683
RT10P6	1/5	1/01	0/99	0/08	0/101197	0/683



نمودار 5. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای 10 نرون در لایه پنهان

جدول 6. تغییرات مقاومت مارشال یک نمونه بتن آسفالتی برای در صد های مختلف مصالح سنگی شکسته

شماره 200	شماره 50	شماره 30	شماره 8	شماره 4	1/2 اینچ	قیر (درصد)	شکستگی (در صد)	مقاومت فشاری (کیلوگرم)
5	13	23	43	66	93	4/79	45	1258/9
"	"	"	"	"	"	"	50	1262/1
"	"	"	"	"	"	"	55	1264/8
"	"	"	"	"	"	"	60	1267
"	"	"	"	"	"	"	65	1268/8
"	"	"	"	"	"	"	70	1270/7
"	"	"	"	"	"	"	75	1273/5
"	"	"	"	"	"	"	81	1279/6
"	"	"	"	"	"	"	85	1286/5
"	"	"	"	"	"	"	90	1299/1
"	"	"	"	"	"	"	95	1316/7
"	"	"	"	"	"	"	100	1338/5



نمودار 6. تغییرات مقاومت مارشال نمونه بتن آسفالتی به صورت تابعی از تغییرات در صد مصالح سنگی شکسته

5. تحلیل حساسیت

$R=0/0109$ ضریب همبستگی $3/71 \times 10^{-29}$ حاصل می شود.

2- 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.

3- برای مدل سازی انجام شده در این تحقیق، افزایش تعداد نرونها تا 8 عدد توان تعمیم پذیری شبکه را افزایش داده و افزایش بیشتر، تغییر قابل توجهی در آن ایجاد نمی کند. با استفاده از 8 نرون در لایه پنهان، بیشینه توان شبیه سازی برای شبکه RT8P5 با ضریب همبستگی $R=0/768$ در خطای آموزش 0/0890116 حاصل می شود که با توجه به تعداد کم داده های آموزشی و تعدد عوامل مؤثر، مناسب است.

4- 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.

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 درصد های عبوری از الک های 200، 50، 30، 8، 4 و 1/2 ثابت در نظر گرفته شده و مقاومت مارشال نمونه برای این ورودی ها و درصد های مختلف مصالح شکسته شده، توسط شبکه RT8P5 محاسبه شده است که نتایج در جدول 6 و نمودار 6 نشان داده شده اند. همان طور که در نمودار 6 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 با روند نظری مطابقت دارد.

6. نتایج

در این تحقیق ابتدا یک مدل شبکه عصبی مصنوعی LMBP برای تخمین مقاومت مارشال آسفالت ارایه شده که برای آموزش آن از 85 و برای ارزیابی آن از 25 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:

1- 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 8 نرون در لایه پنهان، در خطای آموزش

7. 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., 7th. edition.

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

3. كاوه ع., ثروتى، ه. (1378) "شبكة هاى عصبى مصنوعى در تحليل و طراحى سازه ها"، مركز تحقيقات ساختمان و مسكن، نشریه شماره ك-320، 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

