

## کاربرد روش‌های هوش مصنوعی جهت تخمین مقاومت برشی دیوار برشی بتن آرمه

حسین نادریپور<sup>۱</sup>، محمدرضا شاری<sup>۲\*</sup> و پویان فخاریان<sup>۳</sup>

۱- دانشیار، دانشکده مهندسی عمران، دانشگاه سمنان

۲- دانشجوی کارشناسی ارشد سازه، دانشکده مهندسی عمران، دانشگاه سمنان

۳- دانشجوی دکتری سازه، دانشکده مهندسی عمران، دانشگاه سمنان

mreza.sharei88@gmail.com

### چکیده

دیوارهای برشی نوعی از سیستم‌های سازه‌ای است که مقاومت جانبی ساختمان یا سازه را تأمین می‌کند. بارهای جانبی در یک صفحه و در طول بعد قائم دیوار اعمال می‌شوند. این نوع از بارها، معمولاً به وسیله اعضای دیافراگم یا جمع‌کننده، به دیوار منتقل می‌گردند. سازه‌های دیوار برشی بتنی مقاومت قابل توجهی در برابر بارگذاری لرزه‌ای جانبی دارند. پیش‌بینی مدل برای ظرفیت برشی این دیوارها برای تضمین امنیت لرزه‌ای ساختمان ضروری است. بنابراین، یک مدل برای تخمین مقاومت برشی دیوارهای بتنی با استفاده از الگوریتم هوش مصنوعی پیشنهاد شده است. پارامترهای ورودی شبکه عصبی شامل ضخامت دیوار برشی بتن آرمه، طول دیوار، نسبت آرماتورگذاری قائم، نسبت آرماتورگذاری عرضی، مقاومت فشاری بتن، تنش تسلیم آرماتورهای عرضی، تنش تسلیم آرماتورهای قائم، نسبت ابعاد در نظر گرفته شده‌اند. پارامتر هدف، مقاومت برشی دیوار برشی بتن آرمه می‌باشد. در مجموع ۵۸ داده آزمایشگاهی دیوار برشی بتنی جمع‌آوری شده است. نتایج تحقیق نشان می‌دهد شبکه عصبی مصنوعی بهینه با تعداد مشخص نورون در لایه پنهان، با دقت مناسبی می‌تواند ظرفیت برشی دیوار برشی بتن آرمه را تخمین بزند که نتایج حاصل نشان‌دهنده آن است که بیشترین درصد تأثیر و  $\rho_v$  کمترین درصد تأثیر در تابع هدف را داشته‌اند. از طرفی درصد خطا بدست آمده برای پیش‌بینی ظرفیت برشی ۷ درصد می‌باشد که خطای قابل قبولی در این زمینه است.

کلمات کلیدی: دیوار برشی بتنی، مقاومت برشی، شبکه عصبی مصنوعی.

### ۱. مقدمه

دیوارهای بتنی به طور گسترده‌ای برای ساخت ساختمان‌های متعارف در بسیاری از مناطق با خطر لرزه‌ای بالا مورد استفاده قرار گرفته است. دیوار بتن مسلح (RC) به طور کلی به عنوان دیوار با نسبت ارتفاع به عرض کمتر از ۲ تعریف شده است و به خاطر توانایی آن‌ها در مقاومت در برابر بارهای لرزه‌ای جانبی شناخته شده است [1]. بسیاری از تحقیقات بر روی مدل حداکثر ظرفیت برشی برای دیوارهای بتنی مسلح، از جمله مدل‌های فیزیکی، تجربی، عددی و آماری انجام شده است. این نتایج تحقیق در آیین‌نامه‌های ساختمان، دستورالعمل‌های مهندسی و استانداردهای ساخت و ساز گنجانده شده است [2-4]. بر اساس نتایج تجربی قبلی، یک روش با استفاده از شبکه‌های عصبی مصنوعی

(ANN) پیشنهاد داده شده است که می‌تواند پیش‌بینی دقیق از حداکثر ظرفیت برشی دیوارهای برشی بتنی باشد که مجموعه‌ای بزرگ از واحدهای عصبی را در مدل‌سازی توابع و ساختار مغز انسان برای حل مشکلات پیچیده‌ای که به عنوان مجموعه‌ای از ورودی‌ها و یک خروجی مطلوب مدل‌سازی می‌شود [5-7].

معادلات برای محاسبه ظرفیت برشی دیوار برشی بتنی در زیر آمده است. برای تمام معادلات زیر مقاومت برشی وابسته به مقاومت فشاری بتن، نسبت ابعاد، نیروی محوری، نسبت آرماتور عمودی و افقی تقویت شده و سطح مقطع دیوار است.

$$ACI318-14-11 \quad V_c = \min \left\{ \begin{array}{l} \left( 0.274\lambda' \sqrt{f'_c} + \frac{N_u}{4L_w d} \right) hd \\ \left[ 0.05\lambda' \sqrt{f'_c} + \frac{\left( 0.104\lambda' \sqrt{f'_c} + 0.2 \frac{N_u}{L_w h} \right)}{\frac{M_u}{V_u L_w} - \frac{1}{2}} \right] hd \end{array} \right\}, V_s = \frac{A_v f_{yt} d}{S} \quad (1)$$

$$ACI318-14-18 \quad V_u = V_c + V_s \quad V_c = A_{cw} \times \alpha_c \lambda' \sqrt{f'_c} \quad V_s = A_{cw} \times \rho_t f_{yt} \quad (2)$$

$$EC08 \quad V_c = \left[ C_{Rd,c} k (100 \rho_{l,ck})^{\frac{1}{3}} + k_1 \sigma_{cp} \right] b_w d \geq \left( 0.035 k^{\frac{2}{3}} f_{ck}^{\frac{1}{2}} + k_1 \sigma_{cp} \right) b_w d \quad (3)$$

$$V_s = \frac{A_{sw}}{S} z f_{yw} \cot \alpha$$

$$CSA \quad V_c = Q_c \lambda' \beta \sqrt{f'_c} hd \quad V_s = \frac{Q_s A_{sw} f_{yt} d \cot \theta}{S} \quad (4)$$

$$GB50010-2010 \quad V_c = \frac{1}{\gamma_{RE}} \left[ \frac{1}{\gamma - 0.5} \left( 0.4 f_t b d + 0.1 N_u \frac{A_w}{A} \right) \right] \quad V_s = \frac{1}{\gamma_{RE}} \times 0.8 f_{yt} \frac{A_{sh}}{S} d \quad (5)$$

$$Wood \quad A_{cv} \frac{\sqrt{f'_c}}{2} \leq \frac{A_v f_{yv}}{2} \leq \frac{5}{6} \sqrt{f'_c} A_{cv} \quad (6)$$

این پارامترهای موثر در ظرفیت برشی در جدول ۱ آورده شده است.

جدول ۱- پارامترهای موثر در ظرفیت برشی دیوار برشی بتنی

پارامتر	توضیح
$t$	ضخامت دیوار برشی
$f'_c$	مقاومت فشاری بتن
$L_w$	طول دیوار
$\rho_t$	نسبت آرماتورهای عرضی
$\rho_v$	نسبت آرماتورهای عمودی
$f_{yt}$	مقاومت تسلیم آرماتورهای عرضی
$f_{yv}$	مقاومت تسلیم آرماتورهای عمودی
$\frac{N_u}{L_w t f'_c}$	نسبت $\gamma$
$a_w$	نسبت ابعاد

## ۲. شبکه‌های عصبی مصنوعی

شبکه عصبی نوعی ساختار ریاضی است که بر اساس مدل بیولوژیکی مغز انسان به وجود آمده است. هر شبکه عصبی مشتمل بر مجموعه‌ای از اجزاء کوچک داده پردازشی به نام نورون می‌باشد که هر نورون به نورون‌های دیگر از طریق یک رابطه جهت‌دار که دارای وزن مختص به خود است مرتبط می‌گردد. وزن‌ها نمایش دهنده اطلاعات مورد نیاز شبکه برای حل یک مسئله هستند. یک نورون بیولوژیکی دارای ۳ جزء دندریت، سوما و آکسون است. تعداد زیادی دندریت علائم دریافتی از سایر نورون‌ها را اصلاح می‌کنند و سوما (بدنه واحد پردازشگر)، علائم ورودی را جمع می‌نماید. اگر مقدار مجموع ورودی‌ها از یک حد آستانه فراتر رود، در آن صورت پردازشگر فعال شده و از طریق آکسون علائمی را به سلول بعدی انتقال می‌دهد. مکانیزم سلول‌های عصبی به صورت سری و موازی می‌باشد، بدین گونه که مجموعه سلول‌های عصبی موازی هم که هر یک دارای ورودی مخصوص به خود است، پس از انجام عمل پردازش، مجموعه‌ای از خروجی‌ها را تولید می‌کند. این خروجی‌ها به نوبه خود می‌تواند به عنوان ورودی‌های مجموعه دیگر از سلول‌های عصبی که به طور سری به مجموعه سلول‌های اولیه متصل هستند بکار رود. بنابراین خروجی هر نورون در ضرایب وزنی ضرب و به تابع تحریک غیرخطی به عنوان ورودی داده می‌شود. به طور کلی مجموعه سلول‌های عصبی موازی تشکیل یک لایه را می‌دهند. هر شبکه عصبی برای تولید خروجی خود می‌تواند یک یا چند لایه داشته باشد که معمولاً از این لایه‌ها تحت عنوان لایه‌های پنهان یاد می‌شود. آخرین لایه که در حقیقت خروجی شبکه را تولید می‌کند، لایه خروجی نام دارد. از انواع شبکه‌های قابل استفاده جهت پیش‌بینی، می‌توان به شبکه‌های انتشار برگشتی، پس انتشار، دلتا و ... اشاره کرد که در ادامه برای مدل‌سازی رفتار دیوار برشی بتن آرمه از شبکه پس انتشار برگشتی استفاده شده است. شبکه‌های پس انتشار برگشتی یکی از معروف‌ترین، مؤثرترین و آسان‌ترین مدل‌ها برای پیش‌بینی و پیش‌گویی چندین هدف در میان شبکه‌های پیچیده و چند لایه هستند [۸-۱۰].

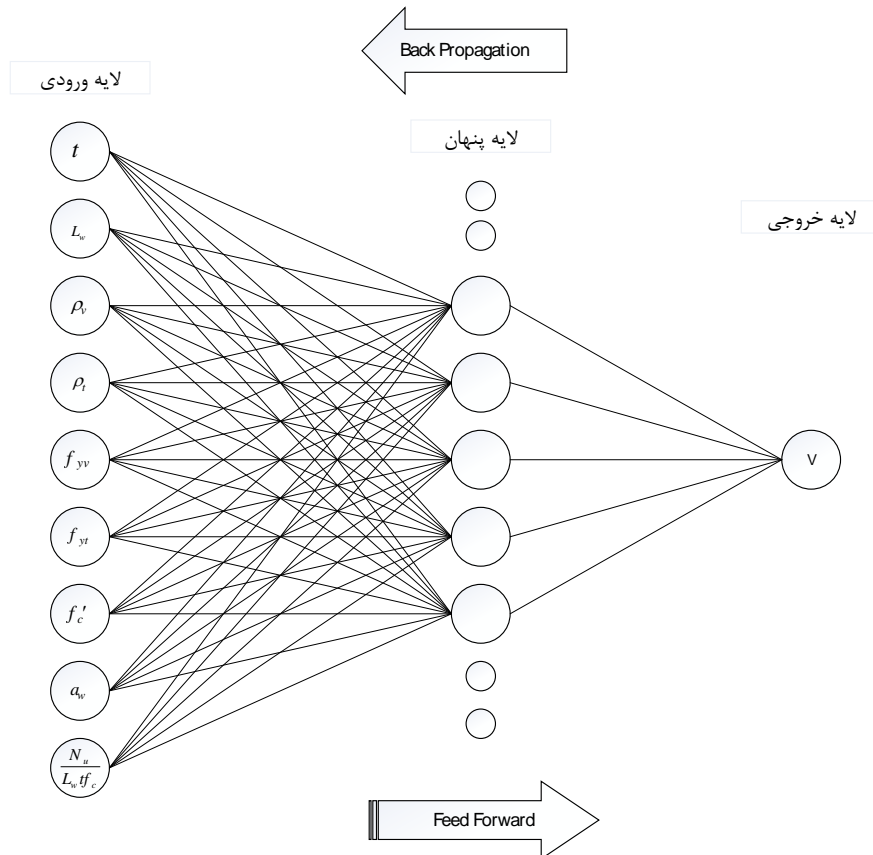
## ۳. مدل‌سازی

برای آموزش شبکه عصبی از اطلاعات آزمایشات انجام شده در موضوع دیوار برشی بتن آرمه استفاده شده است. طبق این مطالعات، در سال ۱۹۸۴، Oesterle و همکاران با ۵ نمونه [10]، Maier و Thurliamann در سال ۱۹۸۵ با ۹ نمونه [11]، Kabeasawa و همکاران در سال ۱۹۹۳ با ۱۲ نمونه [12]، Mo در سال ۱۹۹۳ با ۱۷ نمونه [13]، Gupta در سال ۱۹۹۶ با ۶ نمونه [14]، پژوهش کرده‌اند. در این مقاله با مجموعاً ۵۸ نمونه آزمایشگاهی فوق به آموزش شبکه عصبی مصنوعی ژرداخته شده است. در ادامه مشخصات آماری برای ورودی‌ها و نتیجه مطالعات به صورت آماری در جدول بیان شده است. تمامی پارامترها باید برای معرفی به شبکه با توجه به رابطه ۷ مقیاس شوند.

$$X_{i,nor} = \left[ (0.9 - 0.1) \times \frac{(X_i - X_{min})}{(X_{max} - X_{min})} \right] + 0.1 \quad (7)$$

جدول ۲- مشخصات آماری داده‌های ورودی و خروجی

گروه ورودی	$t$	$L_w$	$\rho_t$	$\rho_v$	$f_{yt}$	$f_{yt}$	$f_c$	$\gamma$	$a_w$	$V_{exp}$
میانگین	15.14	131.84	0.71	1.08	565.95	660.21	52.99	0.01	1.17	775.64
مینیمم	7	86	0	0.58	0	302	18	0.00	0.76	193
ماکزیمم	75	190.5	1.38	2.46	1079	2147	137.5	0.04	2.40	1719
ضریب تغییرات	20.37	39.68	0.25	0.43	240.20	370.63	23.72	0.01	0.47	461.03




شکل ۱- نمونه شماتیک شبکه عصبی


#### ۴. پیشنهاد مدل شبکه بهینه

شبکه پس انتشار برگشتی دارای یک لایه ورودی است که تعداد ورودی‌های شبکه، بیان‌گر تعداد پارامترهای موجود در بخش ورودی می‌باشد. همچنین دارای یک یا چند لایه پنهان با تعدادی نورون می‌باشد. در این مدل، یک لایه پنهان با ۱۱ نورون در نظر گرفته شده است. از تابع تانژانت سیگموئید در لایه پنهان و در لایه خروجی از تابع خطی ساده استفاده شده است.

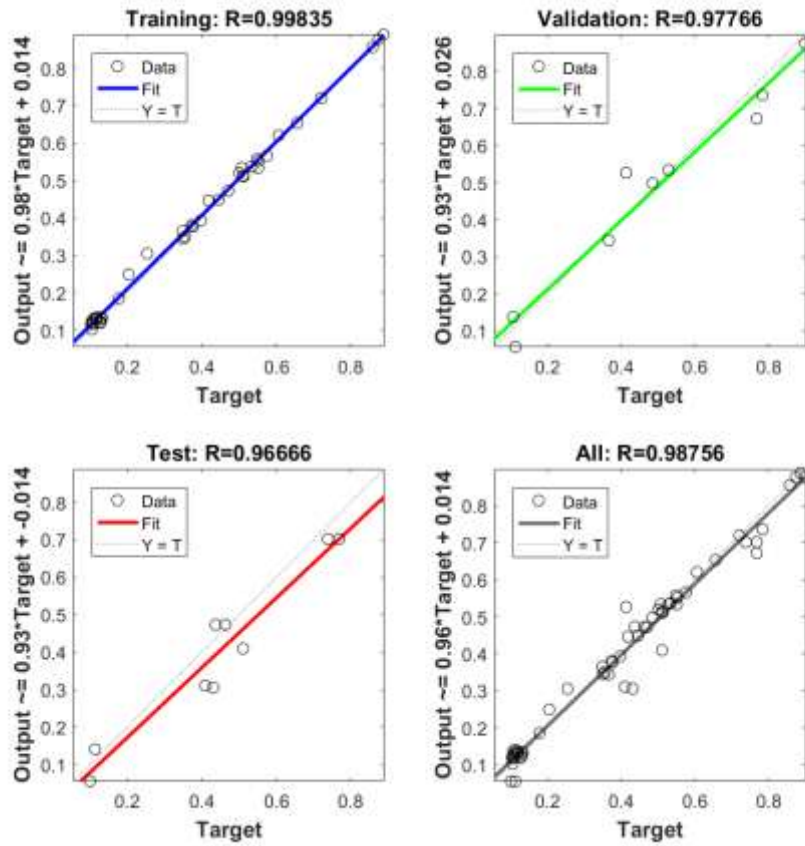
در شکل ۲، میانگین مربع خطاها (MSE) در اپوک‌های مختلف یادگیری آورده شده است که با توجه به معیار همگرایی در نظر گرفته شده، مشاهده می‌شود یادگیری در اپوک ۹ به خوبی انجام شده است. شکل ۳، روند تغییرات شبکه طی اپوک‌های مختلف را نشان می‌دهد. در شکل ۴، مقادیر R به ازای چهار حالت آموزش، صحت سنجی، آزمایش و کل داده‌ها به دست آمده است. هر چه تمرکز این نقاط بر روی نیمساز ربع اول بیشتر باشد، نشانگر دقت بالاتر آن می‌باشد. شکل ۵ مقایسه نتایج آزمایشگاهی با پیش‌بینی شبکه عصبی را نشان می‌دهد.



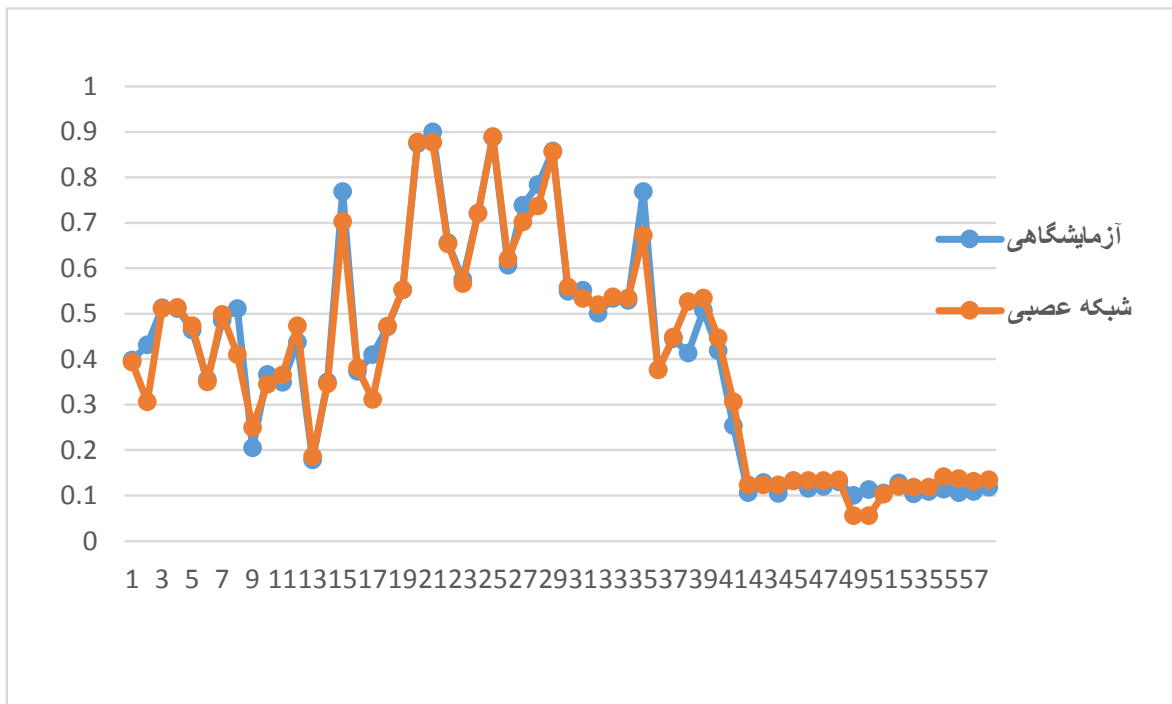
شکل ۲- نمودار میانگین مربعات خطا در فرآیند آموزش شبکه



شکل ۳- روند تغییرات شبکه در مراحل آموزش شبکه



شکل ۴- نمودار رگرسیون شبکه پس از آموزش



شکل ۵- مقایسه نتایج آزمایشگاهی و شبکه عصبی

## ۵. آنالیز حساسیت پارامترهای ورودی

در طول سال‌های گذشته روش‌های مختلفی برای تحلیل اثر متغیرهای ورودی بر خروجی شبکه عصبی پیش‌خورنده پیشنهاد شده‌اند. آنالیز بر اساس مقادیر وزن، منحصر بر مبنای مقادیر ذخیره شده در ماتریس استاتیک وزن‌ها برای تعیین تاثیر نسبی هر یک از داده‌های ورودی بر داده‌های خروجی شبکه می‌باشد. معادلات مختلفی مبتنی بر مقادیر وزن‌ها ارائه شده است. یکی از کاربردی‌ترین معادلات، معادله Milne [15] می‌باشد. این رابطه با محاسبه حاصل ضرب وزن‌ها  $w_{ji}$  (وزن اتصال بین نورون ورودی  $i$  و نورون مخفی  $j$ ) و  $w_{oj}$  (وزن اتصال بین نورون مخفی  $j$  و نورون خروجی  $o$ ) برای هر یک از نورون‌های مخفی شبکه به صورت مجموع حاصل ضرب‌های محاسبه شده بدست می‌آید.


$$Q_{ik} = \frac{\sum_{j=1}^{n_{hidden}} \frac{w_{ji}}{\sum_{l=1}^{n_{inputs}} |w_{jl}|} \cdot w_{oj}}{\sum_{k=1}^{n_{inputs}} \left( \sum_{j=1}^{n_{hidden}} \frac{w_{jk}}{\sum_{l=1}^{n_{inputs}} |w_{jl}|} \cdot w_{oj} \right)} \quad (8)$$

در رابطه (۸)،  $\sum_{l=1}^{n_{inputs}} |w_{jl}|$  مجموع وزن‌های اتصال بین نورون‌های ورودی  $N$  و نورون‌های مخفی  $L$  درصد تاثیر متغیر ورودی  $x_i$  بر متغیر خروجی  $y_k$  می‌باشد. با استفاده از این روش نسبت‌های صحیحی برای هر دو وزن مثبت و منفی بدست می‌آید. وزن پارامترهای ورودی و  $iw\{2,1\}$  وزن خروجی می‌باشد. نتایج آنالیز حساسیت در شکل ۶ بیانگر این است که  $\frac{N_u}{L_w t f_c}$  بیشترین درصد تاثیر و  $\rho_v$  دارای کمترین درصد تاثیر بر روی تابع هدف را داشته‌اند.

$$iw\{1,1\} = \begin{bmatrix} -0.58996 & -0.63883 & -0.72251 & -0.16955 & -0.7519 & -0.60504 & 0.60943 & 0.80398 & -0.74494 \\ 0.40807 & -0.13976 & -0.30715 & 0.92278 & 1.5025 & 0.44235 & -0.4719 & 0.68145 & 0.095635 \\ -0.23432 & 0.40285 & -0.78616 & 0.21965 & -0.45472 & 0.49181 & 0.068336 & 1.6319 & -0.51224 \\ -0.15228 & -0.4508 & 0.30787 & 0.54754 & -0.6832 & -0.6449 & 1.2768 & -0.76189 & 0.43594 \\ 0.86428 & 0.5466 & -0.52066 & -0.46803 & -0.03189 & -0.2667 & -1.4449 & 0.23232 & 1.0025 \\ -1.1343 & 0.44901 & 0.68009 & 0.34151 & 0.77253 & -0.08277 & 0.60375 & -0.78506 & 0.28683 \\ -1.0269 & -0.20036 & 0.50367 & 0.48123 & -0.18074 & 0.32187 & 0.93554 & 0.43051 & -0.67735 \\ -0.74916 & -0.05724 & -0.9549 & 0.070089 & -0.59305 & -0.80298 & 0.37746 & -0.37132 & -0.8777 \\ -0.28043 & -1.1488 & 0.26027 & 0.43107 & -0.19394 & 0.4622 & -0.69502 & -1.0757 & -0.33838 \\ 0.76856 & 1.1137 & -0.55017 & 0.37254 & -0.09787 & -0.63385 & 0.15443 & -0.77725 & 0.072397 \\ 0.47877 & -0.73427 & -0.67761 & -0.38665 & 0.89563 & -0.31461 & -1.3409 & 0.55955 & -0.10191 \end{bmatrix}$$

$$iw\{2,1\} = [-0.49558 \quad 0.61838 \quad 0.50489 \quad 0.69408 \quad -0.64499 \quad -0.163 \quad -0.2526 \quad -0.09836 \quad -0.6975 \quad -0.2098 \quad -0.46528]$$





شکل ۶- تاثیر پارامترهای ورودی

## ۶. نتیجه‌گیری

در این مقاله ظرفیت برشی دیوار برشی بتن آرمه با استفاده از ۵۸ داده حاصل از آزمون آزمایشگاهی، مورد مطالعه قرار گرفته و در نهایت با استفاده از شبکه عصبی، مقدار  $V$  پیش‌بینی گردیده است. شبکه عصبی پیشنهادی در این مقاله از نوع انتشار برگشتی (BPNN) با ساختار ۱-۱۱-۹ می‌باشد که تابع انتقال آن در لایه پنهان از نوع تانژانت سیگموئید و در لایه خروجی از نوع خطی ساده است. نتایج بدست آمده از این مقاله شامل:

۱- به منظور مشخص شدن میزان تاثیر هر یک از پارامترهای ورودی بر ظرفیت برشی دیوار برشی بتنی، آنالیز حساسیت با استفاده از روش میلن با وزن‌های تنظیم شده و حاصل از شبکه عصبی ایده‌آل انجام شد که نتایج حاصل از آن نشان‌دهنده

آن است که  $\frac{N_u}{L_w t f_c}$  بیشترین درصد تأثیر و  $\rho_v$  کمترین درصد تأثیر در تابع هدف را داشته‌اند.

۲- مقدار خطا در محاسبه ظرفیت برشی حدود ۷ درصد بدست آمده است که مقدار خطا قابل قبولی می‌باشد.

## مراجع

- [1] Gulec CK, Whittaker AS, Stojadinovic B. Shear Strength of Squat Rectangular Reinforced Concrete Walls 2009.
- [2] GB50011. Code for seismic design of Building 2010.



- [3] Code P. Eurocode 8: Design of structures for earthquake resistance-part 1: general rules, seismic actions and rules for buildings. Brussels Eur Comm Stand 2005.
- [4] Association CS. Design of concrete structures. Mississauga, Ont.: Canadian Standards Association; 2004.
- [5] Chithra S, Kumar SRRS, Chinnaraju K, Alfin Ashmita F. A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks. *Constr Build Mater* 2016;114:528–35. doi:10.1016/j.conbuildmat.2016.03.214.
- [6] Kişi Ö. Streamflow forecasting using different artificial neural network algorithms. *J Hydrol Eng* 2007;12:532–9.
- [7] Gao W, Chen D, Dai S, Wang X. Back analysis for mechanical parameters of surrounding rock for underground roadways based on new neural network. *Eng Comput* 2018;34:25–36. doi:10.1007/s00366-017-0518-x.
- [8] Naderpour H, Kheyroddin A, Amiri GG. Prediction of FRP-confined compressive strength of concrete using artificial neural networks. *Compos Struct* 2010;92:2817–29. doi:10.1016/j.compstruct.2010.04.008.
- [9] Naderpour H, Rafiean AH, Fakharian P. Compressive strength prediction of environmentally friendly concrete using artificial neural networks. *J Build Eng* 2018;16:213–9. doi:10.1016/j.jobbe.2018.01.007.
- [10] Oesterle RG, Aristizabal-Ochoa JD, Shiu KN, Corley WG. Web crushing of reinforced concrete structural walls. *J Proc*, vol. 81, 1984, p. 231–41.
- [11] Maier J, Thürlimann B. Bruchversuche an stahlbetonscheiben. Bericht/Institut Für Baustatik Und Konstr ETH Zürich 1985;8003.
- [12] Kabeyasawa T, Kuramoto H, Matsumoto K. Tests and analyses of high strength shear walls. *Proc First Meet Multilater Proj Use High Strength Concr*, 1993, p. 1–26.
- [13] Mo YL, Shiau W. Effect of concrete strengths on dynamic response of framed shearwalls 1995.
- [14] Gupta A. Behaviour of high strength concrete structural walls. School of Civil Engineering, Curtin University of Technology; 1996.
- [15] Milne L. Feature selection using neural networks with contribution measures. *Aust Conf Artif Intell AI'95, Citeseer*; 1995, p. 1–8.