

Application of Artificial Intelligence Methods to Estimate Shear Strength of Reinforced Concrete Shear Wall

Hosein Naderpour¹, Mohammadreza Sharei², Pouyan Fakharian³

1. Associate Professor, Faculty of Civil Engineering, Semnan University, Semnan, Iran

2. M.Sc. Student, Faculty of Civil Engineering, Semnan University, Semnan, Iran

3. Ph.D. Candidate, Faculty of Civil Engineering, Semnan University, Semnan, Iran

mreza.sharei88@gmail.com

Abstract

Shear walls are the type of structural systems that provide the lateral resistance to a building or structure. Lateral loads are applied on one plate and along the vertical dimension of the wall. These type of loads are usually transmitted to the wall collectors. Concrete shear walls have a considerable resistance to lateral seismic loading. Model prediction is required for the shear capacity of these walls to ensure the seismic security of the building. Therefore, a model is proposed to estimate the shear strength of concrete walls using an artificial intelligence algorithm. The input parameters of the neural network include the thickness of the reinforced concrete shear wall, the wall length, the vertical reinforcement ratio, the transverse reinforcement ratio, the compressive strength of the concrete, the stresses of the transverse reinforcement, the stresses of the vertical reinforcement, the ratio of the dimensions. The target parameter is the shear strength of the reinforced concrete shear wall. A total of 58 laboratory data was collected on concrete shear walls. The results of the research show that optimum artificial neural network with a specific number of hidden neurons can accurately estimate the shear capacity of reinforced concrete shear walls. The results indicate that the highest percentage of effect and the lowest percentage of effect have a target function. Additionally, the error rate obtained for predicting shear capacity is 7%, which is an acceptable error in this regard.

Keywords: Reinforced concrete shear wall; Shear strength; Artificial neural network

How to cite this article: Naderpour H, Sharei M, Fakharian P, Application of Artificial Intelligence Methods to Estimate Shear Strength of Reinforced Concrete Shear Wall, In: 10th National Conference on Concrete, Tehran, Iran, 7-8 October 2018.

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

حسین نادرپور^۱، محمدرضا شاری^{۲*} و پویان فخاریان^۳

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 ρ_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.

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

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

$$EC08 \quad V_c = \left[C_{Rd,c} k (100 \rho_1 f_{ck})^{\frac{1}{3}} + k_1 \sigma_{cp} \right] b_w d \geq \left(0.035 k^{\frac{2}{3}} f_{ck}^{\frac{1}{2}} + k_1 \sigma_{cp} \right) b_w d \quad (3)$$

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

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

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

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

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
ρ_t	نسبت آرماتورهای عرضی
ρ_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 γ
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 پردازی 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 [8-15].


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 [16]، Maier و Thurliamann در سال ۱۹۸۵ با ۹ نمونه [17]، Kabeasawa و همکاران در سال ۱۹۹۳ با ۱۲ نمونه [18]، Mo در سال ۱۹۹۳ با ۱۷ نمونه [19]، Gupta در سال ۱۹۹۶ با ۶ نمونه [20]، 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	ρ_t	ρ_v	f_{yt}	f_{yt}	f_c	γ	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 [21] Milne 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 J ، Q_{ik} 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 بیشترین درصد تاثیر و ρ_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. نتیجه گیری

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 تاثیر و ρ_v کمترین درصد تاثیر 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, Ghodrati Amiri G. 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.jobe.2018.01.007.
- [10] Alavi SA, Naderpour H, Fakharian P. An Approach for Estimating the Rotation Capacity of Wide Flange Beams using Bayesian Regularized Artificial Neural Networks (BRANN). Modares Civ Eng J 2018;18:157–69.
- [11] Naderpour H, Fakharian P. Predicting the Torsional Strength of Reinforced Concrete Beams Strengthened with FRP Sheets in terms of Artificial Neural Networks. J Struct Constr Eng 2017;10:20–35. doi:10.22065/jsce.2017.70668.1023.
- [12] Naderpour H, Fakharian P, Rafiean AH, Yourtchi E. Estimation of the Shear Strength Capacity of Masonry Walls Improved with Fiber Reinforced Mortars (FRM) Using ANN-GMDH Approach. J Concr Struct Mater 2016;1:47–59. doi:10.30478/JCSM.2016.48988.
- [13] Heidari A, Tavakoli D, Fakharian P. Approximate Eigenvalue of Plate by Artificial Neural Networks. J Model Eng 2014;11:49–62. doi:10.22075/jme.2017.1658.
- [14] Naderpour H, Fakharian P, Hosseini F. Prediction of Behavior of FRP-Confined Circular Reinforced Concrete Columns using Artificial Neural Network. 8th Natl Conf Concr, Tehran, Iran: 2016. doi:10.13140/RG.2.2.11714.58568.
- [15] Naderpour H, Gholami M, Fakharian P. Application of Artificial Neural Network in Punching Shear Capacity of FRP-Reinforced Slabs. 8th Natl Conf Concr, 2016.
- [16] Oesterle RG, Aristizabal-Ochoa JD, Shiu KN, Corley WG. Web crushing of reinforced concrete structural walls. J Proc, vol. 81, 1984, p. 231–41.
- [17] Maier J, Thürlimann B. Bruchversuche an stahlbetonscheiben. Bericht/Institut Für Baustatik Und Konstr ETH Zürich 1985;8003.
- [18] 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.
- [19] Mo YL, Shiau W. Effect of concrete strengths on dynamic response of framed shearwalls 1995.
- [20] Gupta A. Behaviour of high strength concrete structural walls. School of Civil Engineering, Curtin University of Technology; 1996.
- [21] Milne L. Feature selection using neural networks with contribution measures. Aust Conf Artif Intell AI'95, Citeseer; 1995, p. 1–8.