



پیش بینی نشست شمع ها تحت اثر بار محوری به کمک شبکه های عصبی مصنوعی و بر اساس نتایج حاصل از آزمایش SPT

فریدون پویا نژاد^۱، محمد رضا کاخی^۲
۱- استادیار گروه عمران دانشکده مهندسی دانشگاه فردوسی مشهد
۲- دانشیار گروه عمران دانشکده مهندسی دانشگاه فردوسی مشهد

pooyaf@um.ac.ir
drkakhi@yahoo.com

خلاصه

نشست فنداسیون های عمیق (شمع ها) در اثر کاهش حجم لایه های زیرین خاک، ناشی از افزایش تنش ایجاد می شود. نشست های آبی فنداسیون ها که بلافاصله پس از اعمال بار ایجاد می شوند باعث ایجاد تغییر شکل های سریع در سازه متصل به آن ها شده و در نهایت ممکن است باعث انهدام سازه شوند، لذا علاوه بر محاسبه ظرفیت باربری شمع ها پیش بینی نشست شمع ها نیز عامل مؤثر در طراحی خواهد بود. اغلب روش های موجود برای محاسبه نشست شمع ها با یکسان نمودن فرضیاتی که در نشست مؤثر می باشند مسئله را ساده تر کرده اند. بنابراین در روش های متفاوت پیش بینی نشست، سازگاری وجود ندارد. در نتیجه روش های دیگری مورد نیاز بوده که بتواند به محدودیت های روش های موجود غلبه نموده و دقت کافی را در پیش بینی نشست دارا باشد. در این مقاله یک روش برای پیش بینی دقیق تر نشست شمع ها که فقط بر اساس داده ها استوار است، ارائه شده است. روشی که به طور موفقیت آمیز در مسایل ژئوتکنیک مورد استفاده قرار گرفته و به شبکه های عصبی مصنوعی (ANNs) معروف است. مدل ارائه شده بر اساس داده های حاصل از آزمایش SPT آموزش داده می شود.

کلمات کلیدی: نشست شمع، آزمایش SPT، آزمایش بار گذاری شمع، شبکه عصبی

۱. مقدمه

نشست های آبی فنداسیون ها که بلافاصله پس از اعمال بار ایجاد می شوند باعث ایجاد تغییر شکل های سریع در سازه متصل به آن ها شده و در نهایت ممکن است باعث انهدام سازه شوند [Sowers, 1970]. هم چنین این نشست ها می تواند از نوع ارتجاعی و یا غیر ارتجاعی باشند. در حالت نشست غیر ارتجاعی شمع وارد مرحله گسیختگی شده و حتی با برداشتن بار، نشست صفر نشده و نشست ماندگار ایجاد می شود. لذا علاوه بر محاسبه ظرفیت باربری شمع ها پیش بینی نشست شمع ها نیز عامل مؤثر در طراحی خواهد بود.

از آن جا که تعیین عواملی که در نشست شمع ها دخالت دارند مشکل و در بعضی موارد نامعین می باشند لذا پیش بینی نشست آن ها بسیار دشوار است. از میان این عوامل می توان نحوه توزیع تنش در شمع، خواص تنش - کرنش خاک، تراکم پذیری خاک و دشواری در بدست آوردن نمونه دست نخورده خاک برای انجام آزمایش های آزمایشگاهی را نام برد. در این ارتباط روش های تئوری و تجربی نسبتاً زیادی ارائه شده است که هر کدام بر اساس فرضیات خاص خود نشست شمع ها را پیش بینی نموده اند.

در این تحقیق از شبکه های عصبی مصنوعی (ANNs) برای پیش بینی دقیق تر نشست شمع ها استفاده شده است. ANNs یک تکنیک عددی بوده که عملکرد آن از سیستم مغز انسان شبیه سازی می شوند. در واقع ANNs از یک سری داده به تنهایی برای تعیین ساختار مدل استفاده می کند. ANNs به طور موفقیت آمیزی در مسائل زیادی در مهندسی ژئوتکنیک به کار گرفته شده است. شبکه مورد استفاده برای مدل از نوع پرسپترون چند لایه (MLPs) پیش خور است، که با الگوریتم پس انتشار خطا آموزش داده می شود، هم چنین از نتایج آزمایش SPT به عنوان مقاومت مشخصه خاک استفاده شده است. داده های مورد استفاده برای طراحی مدل های ANN از نتایج آزمایش های بار گذاری شمع ها در مقیاس واقعی که در مناطق مختلف دنیا انجام شده اند، به دست آمده اند. در هر آزمایش اطلاعات مربوط به بار و تغییر مکان وابسته، از نمودار بار-نشست حاصل از انجام آزمایش برداشت شده است. اهداف این تحقیق به شرح زیر می باشند:



- کاربرد شبکه عصبی برای پیش‌بینی نشست شمع‌ها.
- روش ارزیابی مدل که قدرت توانایی پیش‌بینی مدل‌های شبکه عصبی را آزمایش نماید.
- مطالعه اثر هندسه شبکه عصبی بر بهبودی مدل‌های شبکه عصبی.

۲. داده‌های ورودی در مدل‌های شبکه عصبی

داده‌های مورد استفاده برای آموزش و ارزیابی مدل‌های شبکه عصبی از آزمایش‌های انجام شده بر روی شمع‌ها در مقیاس واقعی که در مکان‌های مختلف صورت گرفته، به دست آمده‌اند. این اطلاعات شامل اندازه‌گیری نشست شمع و بار وارده نظیر (که از منحنی بار-تغییر مکان حاصل از بارگذاری شمع تا مرحله گسیختگی برداشت شده‌اند)، مشخصات خاک شامل نتایج آزمایش SPT و هندسه شمع است. داده‌ها دامنه وسیعی از ابعاد شمع و خواص خاک را شامل می‌شود. کل داده‌ها شامل ۱۰۳۲ از مجموع ۷۸ آزمایش بارگذاری شمع حاصل گردیده است. هم چنین نرم‌افزار تجاری مورد استفاده Neuframe 4.0 [Neuframe, 2000] می‌باشد. ورودی‌ها و مقادیر حداکثر آن‌ها که در مدل سازی شبکه عصبی استفاده شده‌اند، به شرح زیر خواهند بود:

- نوع بار [بار ماندگار (ML) یا بار با نرخ نفوذ ثابت (CRP)]،
- نوع مصالح شمع [بتن (Concrete)، فولاد (Steel)، مرکب (Composite) یا پلاستیک (Plastic)]،
- نوع اجرای شمع [کوبیدنی (Driven) یا غیر کوبیدنی (Bored)]،
- شرایط انتهای شمع [بسته (Closed) یا باز (Open)]،
- صلبیت محوری معادل در طول شمع (EA) با حداکثر مقدار 247400 MN،
- سطح مقطع انتهای شمع (A_{tip}) با حداکثر مقدار 70685 cm²،
- پیرامون شمع در تماس با خاک (O) با حداکثر مقدار 1137 cm،
- طول شمع (L) با حداکثر مقدار 81 m،
- طول مدفون شده شمع (L_{embed}) با حداکثر مقدار 81،
- نتایج آزمایش SPT در پنج لایه یکسان در طول شمع (N_1, N_2, N_3, N_4, N_5) با محدودیت‌های زیر:
$$N_5 \leq 250, N_4 \leq 195, N_1, N_2, N_3 \leq 161$$
- نتیجه آزمایش SPT در انتهای شمع تا عمق مؤثر (N_{tip}) با حداکثر مقدار 300، و
- بار قائم اعمالی (P) با حداکثر مقدار 40000 kN،

خروجی مدل، نشست اندازه‌گیری شده شمع S_m با حداکثر مقدار 185 mm است. به دلیل درون یاب بودن شبکه‌های عصبی، محدوده متغیرهای ورودی باید در بازه داده‌های ورودی باشند.

از آن جا که روش Cross-Validation [Stone, 1974] به عنوان معیار توقف در این پژوهش استفاده شده است، در نتیجه داده‌ها به سه مجموعه آموزشی، آزمایشی و ارزیابی تقسیم می‌شوند، به گونه‌ای که در مجموع ۸۹/۲٪ داده‌ها (۹۲۱ مورد) برای آموزش و ۱۱٪ داده‌ها (۱۱۱ مورد) برای ارزیابی استفاده شده‌اند. داده‌های آموزش خود به ۸۷٪ برای مجموعه آموزشی و ۱۳٪ برای مجموعه آزمایشی تقسیم گردیده‌اند. مجموعه‌های آموزشی، آزمایشی و ارزیابی به گونه‌ای تقسیم‌بندی شده‌اند که خصوصیات آماری تقریباً یکسانی داشته باشند. از سعی و خطا برای رسیدن به این هدف در یکسان‌سازی خواص آماری مجموعه‌های آموزشی، آزمایشی و ارزیابی استفاده شده است. جدول (۱) خصوصیات آماری مجموعه‌های آموزشی، آزمایشی و ارزیابی را نشان می‌دهد. پارامترهای آماری شامل میانگین، انحراف از معیار، ماکزیمم، می‌نیمم و دامنه است.



جدول ۱- مشخصات آماری متغیرهای ورودی و خروجی شبکه عصبی

Model variables and data sets	Statistical parameters				
	Mean	Std. Dev. ^a	Maximum	Minimum	Range
Axial rigidity of pile, EA (MN)					
Training set	23036.57	24310.12	247400.00	1692.00	245708.00
Testing set	21522.56	5949.85	32386.63	4815.30	27571.33
Validation set	11827.86	7863.36	22719.87	3906.92	18812.95
Cross sectional area of pile tip, A_{tip} (cm²)					
Training set	5899.95	7512.47	70685.83	229.30	70456.53
Testing set	2566.04	2253.18	7296.59	229.30	7067.29
Validation set	2529.98	2335.31	7328.99	229.30	7099.69
Perimeter of pile, O (cm)					
Training set	545.42	260.05	1137.10	78.54	1058.56
Testing set	775.03	195.27	957.56	179.20	778.36
Validation set	406.33	287.71	782.01	114.00	668.01
Length of pile, L (m)					
Training set	30.25	14.36	81.10	8.24	72.86
Testing set	41.28	12.83	53.34	14.60	38.74
Validation set	29.13	14.48	52.43	11.40	41.03
Embedded length of pile, L_{embed} (m)					
Training set	23.24	13.89	81.10	6.45	74.65
Testing set	32.45	10.97	40.29	8.23	32.06
Validation set	27.06	11.18	44.23	11.40	32.83
Average SPT blow, N_1					
Training set	18.81	29.76	161.00	0.00	161.00
Testing set	3.95	6.67	22.00	0.00	22.00
Validation set	6.77	6.54	19.33	0.00	19.33
Average SPT blow, N_2					
Training set	26.10	29.59	161.00	0.00	161.00
Testing set	8.09	6.32	19.00	3.40	15.60
Validation set	11.63	8.15	22.00	0.00	22.00
Average SPT blow, N_3					
Training set	36.93	36.45	161.00	0.00	161.00
Testing set	30.25	11.00	41.00	4.60	36.40
Validation set	24.37	7.45	33.20	10.00	23.20
Average SPT blow, N_4					
Training set	47.89	38.59	195.00	2.50	192.50
Testing set	37.52	17.34	52.00	10.00	42.00
Validation set	32.21	15.18	66.50	16.00	50.50

^aStd. Dev. indicates standard deviation.



ادامه جدول ۱

Model Variables and data sets	Statistical parameters				
	Mean	Std. Dev. ^a	Maximum	Minimum	Range
Average SPT blow, N_5					
Training set	59.93	45.55	250.00	9.00	241.00
Testing set	59.11	26.70	92.00	11.25	80.75
Validation set	38.53	20.84	83.10	14.00	69.10
Average SPT blow, N_{tip}					
Training set	74.20	65.01	300.00	0.00	300.00
Testing set	56.28	20.88	116.00	32.00	84.00
Validation set	46.97	49.50	186.00	16.00	170.00
Applied load, P (kN)					
Training set	5759.97	5778.18	40000.00	0.00	40000.00
Testing set	6602.42	4377.05	14640.00	0.00	14640.00
Validation set	2298.26	2110.89	7250.00	0.00	7250.00
Measured settlement, s_m (mm)					
Training set	11.18	17.92	185.00	0.00	185.00
Testing set	15.25	14.99	71.49	0.00	71.49
Validation set	8.82	18.55	137.50	0.00	137.50

^aStd. Dev. indicates standard deviation.

پس از تقسیم داده‌ها به زیر مجموعه‌ها، متغیرهای خروجی با حذف ابعادشان هم‌مقیاس می‌شوند. روش متداولی که بیشتر استفاده می‌شود یک رابطه خطی ساده بین حدود واقعی متغیرها با حدود شبکه عصبی برای نرمالیزه کردن است [Masters, 1993].

۳. معماری مدل

تعداد لایه و تعداد گره‌ها در هر لایه، معماری مدل را تشکیل می‌دهد. به عبارت دیگر معماری مدل تعیین تعداد لایه بهینه و تعداد گره‌ها در هر لایه است. برای تعیین معماری بهینه شبکه عصبی، تئوری مشخصی وجود ندارد. عموماً معماری مدل با ثابت کردن تعداد لایه‌ها و انتخاب تعداد گره‌ها در هر لایه قابل دسترسی است. از آنجا که نرم‌افزار Neuframe 4.0 قادر به تولید معماری بهینه شبکه نمی‌باشد لذا به کمک سعی و خطا معماری بهینه شبکه را می‌توان به دست آورد در این پژوهش ابتدا شبکه با یک لایه مخفی و سپس شبکه‌های با چند لایه مخفی نیز مورد ارزیابی قرار گرفته‌اند. به این منظور ابتدا شبکه‌های یک لایه‌ای با پارامترهای داخلی پیش فرض نرم‌افزار Neuframe 4.0 و تعداد ۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۵، ۲۰، ۲۵، ۳۰، ۳۵، ۴۰، ۴۳، ۴۴ و ۴۵ گره در لایه مخفی آزمون می‌شوند. سپس شبکه‌های با چند لایه مخفی مورد بررسی قرار می‌گیرند.

۴. ارزیابی مدل

منظور از ارزیابی مدل اطمینان از توانایی مدل در کلیت بخشی در محدوده داده‌های آموزشی است. این روش که عموماً پذیرفته شده است، آزمایش کارایی شبکه آموزش داده شده توسط مجموعه داده‌های ارزیابی است، که در فرآیند ساخت مدل استفاده نشده‌اند. چنانچه کارایی کافی باشد مدل قادر به کلیت بخشی بوده و قدرتمند خواهد بود.



ضریب همبستگی r و جذر میانگین مربعات خطا RMSE معیارهای اصلی هستند که اغلب به منظور پیش‌بینی بهبود شبکه‌های عصبی مورد استفاده قرار می‌گیرند. ضریب همبستگی ارتباط بین مقادیر پیش‌بینی شده حاصل از ANNs و مقادیر واقعی را تعیین می‌کند که به شرح زیر قابل محاسبه است.

$$r = \frac{C_{y_j d_j}}{\sigma_{y_j} \sigma_{d_j}} \quad (1)$$

$$C_{y_j d_j} = \frac{1}{n-1} \sum_{j=1}^n (y_j - \bar{y})(d_j - \bar{d}) = \frac{1}{n-1} \left(\sum_{j=1}^n y_j d_j - \frac{\sum_{j=1}^n y_j \sum_{j=1}^n d_j}{n} \right) \quad (2)$$

$$\sigma_{y_j} = \sqrt{\frac{\sum_{j=1}^n (y_j - \bar{y})^2}{n-1}} \quad (3)$$

$$\sigma_{d_j} = \sqrt{\frac{\sum_{j=1}^n (d_j - \bar{d})^2}{n-1}} \quad (4)$$

$$\bar{y} = \frac{\sum_{j=1}^n y_j}{n} \quad (5)$$

$$\bar{d} = \frac{\sum_{j=1}^n d_j}{n} \quad (6)$$

در این روابط

$$y_j = \text{خروجی مدل}$$

$$d_j = \text{خروجی مطلوب}$$

$$\sigma_{y_j} = \text{انحراف استاندارد خروجی مدل } y_j$$

$$\sigma_{d_j} = \text{انحراف استاندارد خروجی مطلوب}$$

$$\bar{y} = \text{میانگین خروجی مدل}$$

$$\bar{d} = \text{میانگین خروجی مطلوب}$$

$$n = \text{تعداد داده‌ها}$$

هم‌چنین مقدار RMSE نیز به شکل زیر محاسبه می‌شوند.

$$\text{RMSE} = \left\{ \frac{1}{n} \sum_{j=1}^n (y_j - d_j)^2 \right\}^{\frac{1}{2}} \quad (7)$$

۵. نتایج

نتایج حاصل از آموزش شبکه یک لایه‌ای با گره‌های متفاوت برای مجموعه داده‌های ارزیابی در جدول (۲) نشان داده شده است.



جدول ۲- نتایج مدل شبکه عصبی با یک لایه مخفی و مقادیر متفاوت گره
برای مجموعه داده‌های ارزیابی

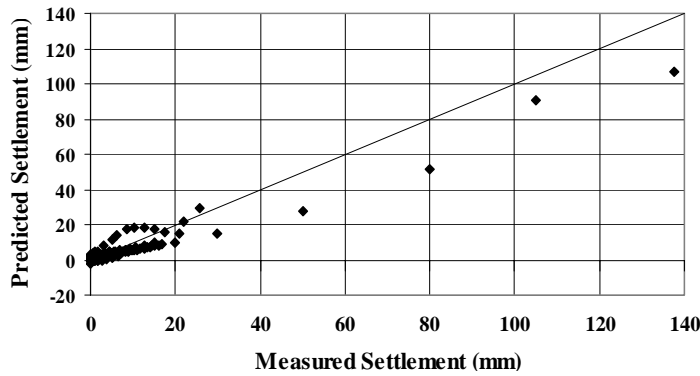
No. of Nodes in hidden layer	Correlation coefficient, r	RMSE(mm)
3	0.846	11.62
4	0.835	12.59
5	0.808	13.83
6	0.799	12.63
7	0.828	11.76
8	0.857	10.92
9	0.834	11.97
10	0.824	11.10
15	0.826	11.83
20	0.833	12.00
25	0.831	11.33
30	0.475	24.48
35	0.852	11.30
40	0.748	12.70
43	0.626	16.22
44	0.747	12.80
45	0.829	10.99

با توجه به جدول (۲) مشاهده می‌شود که مدل ۸ گرهی دارای بیشترین ضریب همبستگی و کمترین مقدار خطا است یعنی (0.857, 10.92) پس از این مدل، مدل ۳۵ گرهی بهترین ضریب همبستگی را دارا می‌باشد. نکته دیگری که از جدول (۲) حاصل می‌شود آن است که ضریب همبستگی r و خطای RMSE برای اکثر مدل‌های موجود تغییرات قابل توجهی ندارد که این نشان گر عدم شکل‌گیری مسئله بیش آموزشی است، زیرا همان‌گونه که گفته شد در حالت استفاده از روش Cross-Validation این مشکل ایجاد نمی‌شود. هم چنین نتایج آموزش شبکه‌های بهینه چند لایه مخفی در جدول ۳ خلاصه شده است.


جدول ۳- نتایج مدل های بهینه چند لایه مخفی

Optimum multiple hidden layer models	Correlation coefficient, r	RMSE(mm)
13-8-3		
Training	0.987	3.11
Testing	0.915	12.35
Validation	0.970	6.01
15-13-5-2		
Training	0.993	2.21
Testing	0.912	11.47
Validation	0.988	3.62

با مقایسه جداول ۲ و ۳ دیده می‌شود که مدل های 13-8-3 و 15-13-5-2 نسبت به مدل های تک لایه مخفی دارای ضریب همبستگی بالاتر و خطای کمتری باشند. اشکال ۱ و ۲ نشست اندازه‌گیری شده در برابر نشست پیش‌بینی شده مدل های 13-8-3 و 15-13-5-2 را برای داده‌های ارزیابی نشان می‌دهند.




شکل ۱- نشست اندازه گیری شده در برابر نشست پیش بینی شده مدل 13-8-3 برای داده های ارزیابی



شکل ۲- نشست اندازه گیری شده در برابر نشست پیش بینی شده مدل 15-13-5-2 برای داده های ارزیابی

با مقایسه دیده می شود که در مدل 15-13-5-2 پراکندگی نقاط نسبت به سایر مدل ها کمتر است. در این مدل نیز ضریب همبستگی مجموعه داده های ارزیابی و آموزشی نسبت به سایر مدل ها بیشتر بوده (0.988 و 0.993) و هم چنین خطای مجموعه داده های آموزشی و ارزیابی نیز کم ترین است (3.62 mm و 2.21 mm) سطح خطا و ضریب همبستگی مجموعه داده های آزمایشی نیز در این مدل مناسب است (0.912 و 11.47 mm). لذا مدل 15-13-5-2 نسبت به مدل های دیگر قابلیت مناسبی در پیش بینی نشست دارد. برای ارزیابی بهتر این مدل حساسیت آن مطابق شکل (۳) نسبت به طول شمع مورد بررسی قرار می گیرد. در این جا نیز دیده می شود که نشست شمع با افزایش طول شمع کاهش می یابد. این تغییرات با رفتار واقعی شمع هماهنگ است. شکل (۳) برای شمع بتنی به قطر ثابت 96.6 cm و بار ثابت $P = 3500$ kN ترسیم شده است.



شکل ۳- حساسیت مدل 15-13-5-2 نسبت به طول شمع



۶. نتیجه گیری

شبکه پرسپترون چند لایه‌ای MLPs که با الگوریتم پس انتشار خطا آموزش داده شد برای پیش‌بینی نشست شمع‌ها به کار گرفته شد. مجموعه داده‌ها شامل ۱۰۳۲ مورد از نتایج آزمایش‌های واقعی که در مکان‌های مختلف انجام شده جهت آموزش شبکه مورد استفاده قرار گرفت. اثر تعداد وزن‌های اتصال و نیز تعداد لایه مخفی در شبکه و نیز حساسیت مدل بهینه مورد ارزیابی قرار گرفت. هم چنین با مقایسه نتایج حاصل از شبکه عصبی و مقادیر واقعی مشخص گردید که مدل بهینه 2-5-13-15 توانایی خوبی در پیش‌بینی نشست شمع‌ها در محدوده ۰/۰ تا ۱۸۵ میلی‌متر دارند.

۱۲. مراجع

1. Sowers, G. F. (1970). *Introductory soil mechanics and foundations: Geotechnical engineering*, Macmillan Publishing Company, New York.
2. Neosciences. (2000). Neufame Version 4.0, Neosciences Corp., Southampton, Hampshire.
3. Stone, M. (1974). "Cross-validatory choice and assessment of statistical predictions." *J. R. Stat. Soc.*, B 36, 111–147.
4. Masters, T. (1993). *Practical neural network recipes in C++*, Academic Press, San Diego, California.