



Applications of artificial neural network in geotechnical engineering - a review study

Morteza Mobalegh¹

Abstract

Over the past years, the use of artificial neural networks has increased in many engineering fields. In particular, artificial neural networks have been applied to many geotechnical engineering problems and remarkable results have been obtained. The review of the background of the subject shows that artificial neural networks have been successfully used in predicting pile bearing capacity, soil retaining structures, settlement of structures, stability of slopes, design of tunnels and underground openings, liquefaction, soil compaction, swelling and classification of soils. The purpose of this article is to provide an overview of some applications of artificial neural network to solve some geotechnical engineering problems; Also, the strengths and weaknesses of this method will be examined in comparison with other modeling solutions.

Keywords: artificial neural network, geotechnical engineering, pile, settlement, liquefaction.

¹ Master's degree in geotechnical engineering, Shahid Rajaei University, Tehran, Iran
(mortezamobaleghm2@gmail.com)



فصلنامه علمی - تحقیقی علوم فنی

پوهنتون خاتم النبیین (ص)

سال دوم ، شماره دوم، بهار ۱۴۰۳

صفحه ۷۱ - ۸۶



کاربردهای شبکه عصبی مصنوعی در مهندسی ژئوتکنیک: مطالعه مروری

مرتضی مبلغ^۱

چکیده

طی سالیان گذشته، استفاده از شبکه‌های عصبی مصنوعی در بسیاری از حوزه‌های مهندسی افزایش یافته است. به طور خاص، شبکه‌های عصبی مصنوعی در بسیاری از مسائل مهندسی ژئوتکنیک به کار گرفته شده است و نتایج قابل ملاحظه‌ای به دست آمده‌اند. بررسی پیشینه موضوع نشان می‌دهد که شبکه‌های عصبی مصنوعی با موفقیت در پیش‌بینی ظرفیت باربری شمع، سازه‌های نگهدارنده خاک، نشست سازه‌ها، پایداری شیب‌ها، طراحی تونل‌ها و بازشوهای زیرزمین، روان‌گرایی، تراکم خاک، تورم و طبقه‌بندی خاک‌ها به کار گرفته شده‌اند. هدف این مقاله، ارائه‌ی نمای کلی از برخی کاربردهای شبکه عصبی مصنوعی برای حل برخی مسائل مهندسی ژئوتکنیک است؛ همچنین نقاط قوت و ضعف این روش در مقایسه با سایر راهکارهای مدل‌سازی بررسی خواهد شد.

واژگان کلیدی: شبکه عصبی مصنوعی، مهندسی ژئوتکنیک، شمع، نشست، روان‌گرایی.

^۱ دانش‌آموخته کارشناسی ارشد مهندسی ژئوتکنیک، دانشگاه تربیت‌دبیر شهید رجایی، تهران، ایران

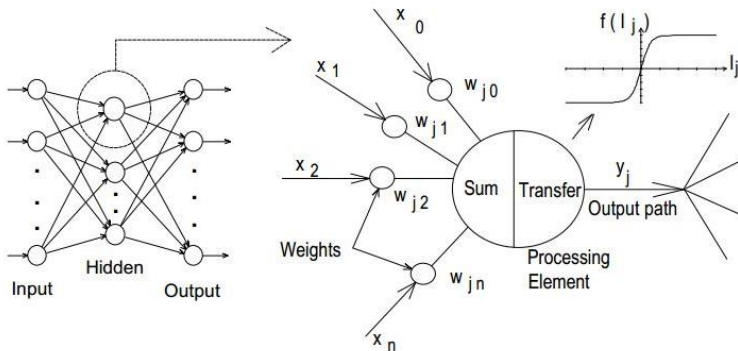
(mortezamobaleghm2@gmail.com)

۱. مقدمه

مصالح مهندسی، نظیر خاک و سنگ، به دلیل فرایند پیچیده و مبهم تشکیل، رفتار متفاوت و نامطمئنی دارند [۱]. این موضوع، برخلاف بیشتر مصالح مهندسی دیگر- مانند فلز، بتن و چوب- است که همگنی و همسان‌گردی بسیار بیشتری از خود نشان می‌دهند؛ به همین منظور، برای مقابله با پیچیدگی رفتار ژئوتکنیکی، روش‌های طراحی سنتی به‌طور موجهی ساده شده‌اند. رویکرد جایگزینی، که موفقیت‌آمیز بوده است، ساختار و پارامترهای مدل را براساس داده‌ها تعیین می‌کند. این تکنیک که شبکه عصبی مصنوعی^۱ گفته می‌شود، به‌منظور مدل‌سازی مسائل پیچیده، که برقراری ارتباط بین متغیرهای مدل در آن دشوار است، طراحی شده است [۲]. هدف این مقاله، بررسی برخی ویژگی‌های ANNs و کاربرد آن در مهندسی ژئوتکنیک است.

۲. پیشینه تحقیق

امروزه، شبکه‌های عصبی مصنوعی مدلی از هوش مصنوعی هستند که سعی در تقلید رفتار مغز انسان و سیستم‌های عصبی دارند. بسیاری از محققان، ساختار و عملکرد ANNs را تعریف کرده‌اند. ساختار ANNs از تعدادی عناصر و یا گره، که معمولاً در لایه‌ها (لایه ورودی، لایه خروجی و لایه‌های مخفی) مرتب می‌شوند، تشکیل می‌شود (شکل ۱).



شکل ۱: فرایند تشکیل شبکه عصبی مصنوعی [۳ و ۴]

ورودی از هر عنصر پردازش در لایه قبلی (X_i) با وزن قابل تنظیم (W_{ji}) ضرب می‌شود. در هر عنصر، سیگنال‌های ورودی وزن‌دار با هم جمع شده و با مقدار آستانه‌ای (θ_i) اضافه می‌شوند؛ سپس این ورودی ترکیب‌شده (I_j) از تابعی غیرخطی ($f(I_j)$) عبور داده می‌شود تا خروجی عنصر پردازشی (Y_i) تولید شود. خروجی حاصل از یک عنصر ورودی، سایر عناصر پردازش در لایه‌های بعدی را تولید می‌کند. این روند در معادلات ۱ و ۲ خلاصه شده است که در شکل ۱ قابل مشاهده هستند.

$$I_j = \sum w_{ji} + x_i + \theta_i \quad (1)$$

$$y_i = f(I_j) \quad (2)$$

¹ Artificial neural networks (ANNs)



انتشار اطلاعات در شبکه‌های عصبی مصنوعی از لایه ورودی، که داده‌های ورودی در آن ارائه می‌شوند، شروع می‌شود. شبکه در ابتدا وزن‌های خود را روی ارائه داده‌های آموزشی تنظیم می‌کند و از قوانین آموزشی برای پیدا کردن مجموعه‌ای از وزن‌هایی که نقشه‌های ورودی و خروجی را تولید می‌کند و کمتر احتمال خطا خواهد داشت، استفاده می‌کند؛ به این فرایند، یادگیری یا آموزش گفته می‌شود. زمانی که فاز آموزشی مدل با موفقیت به پایان رسید، باید عملکرد مدل آزمایشی با استفاده از مجموعه‌ای از آزمایش‌های مستقل اعتبارسنجی شود. مطابق روند شرح داده‌شده، ANNs فرایند یادگیری را از داده‌هایی که به آن ارائه شده شروع و از این داده‌ها برای وزن‌دهی به عناصر پردازش استفاده می‌کند تا رابطه بین متغیرهای ورودی و خروجی‌های مربوط را به دست آورد؛ در نتیجه، شبکه‌های عصبی مصنوعی به دانش قبلی درباره ماهیت رابطه بین متغیرهای ورودی/خروجی نیاز ندارند که یکی از مزایای شبکه‌های عصبی مصنوعی، که با بیشتر روش‌های تجربی و آماری مقایسه کرده‌اند، است.

۳. کاربردهای ANNs در مهندسی ژئوتکنیک

۱/۱. تعیین ظرفیت باربری شمع‌ها

پیش‌بینی ظرفیت باربری شمع‌ها، به‌خصوص شمع‌هایی که براساس داده‌های حفاری به‌دست آمده‌اند، توسط چندین پژوهشگر حوزه ANN بررسی شده است. پیش‌بینی ظرفیت شکست شمع‌ها در خاک‌های رسی با یک شبکه عصبی توسط گاه^۱ ارائه شد که این شبکه عصبی با داده‌های میدانی پروژه‌ای آزمایش شد. طول شمع، قطر شمع، تنش مؤثر و تنش برشی زهکشی نشده، ورودی‌های مدل و مقاومت اصطکاکی پوسته، خروجی این مدل بودند [۵]. نتایج به‌دست آمده از شبکه عصبی با نتایج حاصل از مدل سمپل و ریگدن^۲ و روش a از طریق تجزیه و تحلیل رگرسیون مقایسه شدند که درصد خطاها در جدول ۱ نشان داده شده‌اند. طبق جدول ۱، ANNs از نتایج بهتری برخوردار است؛ همچنین، این مطالعه نشان می‌دهد ضعف اصلی روش ANNs، ناتوانی در تشریح منطقی نحوه رسیدن به خروجی از ورودی‌ها است.

جدول ۱: خلاصه ضرایب همبستگی و میزان خطا برای ظرفیت شمع اصطکاکی [۷۶]

نرخ خطا (کیلوپاسکال)		ضریب همبستگی		روش
		آموزش	آزمایش	
آموزش	آزمایش	آموزش	آزمایش	شبکه عصبی
۱/۰۱۶	۱/۱۹۴	۰/۹۸۵	۰/۹۵۶	
۱/۳۱۸	۱/۸۹۴	۰/۹۷۶	۰/۸۸۵	سمپل و ریگدن
۴/۸۲۴	۳/۰۹۶	۰/۷۳۱	۰/۷۰۴	روش a

¹ Goh

² Semple and Regden

پس از این مطالعه، شبکه عصبی دیگری توسط گاه گسترش یافت که ظرفیت بار نهایی شمع در خاک‌های غیرچسبنده در آن بررسی شد [۸]. در این تحقیق، داده‌های استفاده‌شده از نتایج آزمایش‌های بارگذاری واقعی روی چوب، بتن و شمع فولادی در خاک‌های ماسه‌ای استفاده شد. ورودی‌های مؤثر در این مدل شبکه عصبی شامل وزن چکش، چکش افتان، طول شمع، وزن شمع، سطح مقطع شمع، مدول الاستیسیته شمع و نوع چکش و خروجی مدل نیز ظرفیت باربری شمع بود. زمانی که مدل آزمایش شد، دیده شد که شبکه عصبی ظرفیت باربری شمع را با موفقیت مدل‌سازی کرده و مهم‌ترین ورودی‌های عناصر پردازش، وزن و نوع چکش بودند. جدول ۲ خلاصه‌ای از مقایسه شبکه عصبی با سایر روش‌های سنتی، با استفاده از تجزیه و تحلیل رگرسیون را نشان می‌دهد. طبق جدول ۲، نتایج حاصل از شبکه عصبی موفقیت قابل ملاحظه‌ای نسبت به سایر روش‌ها از خود نشان داده است.

جدول ۲: خلاصه نتایج تجزیه و تحلیل رگرسیون پیش‌بینی ظرفیت باربری شمع [۹ و ۱۰]

ضریب همبستگی		روش
آموزش	داده‌های آزمایش	
۰/۹۶	۰/۹۷	شبکه عصبی
۰/۶۹	۰/۶۱	اخبار مهندسی ^۱
۰/۴۸	۰/۷۶	هایلی ^۲
۰/۸۲	۰/۸۹	جانبو ^۳

چان و همکارانش^۴ شبکه عصبی‌ای را به‌عنوان جایگزینی برای فرمول‌های شمع کوبی توسعه دادند [۱۱]. این شبکه با پارامترهای ورودی مشابهی که در فرمول ساده‌شده هایلی فهرست شده‌اند [۱۲]، آموزش داده شد که شامل فشار الاستیک شمع و خاک، تنظیم شمع و انرژی رانشی اعمال‌شده به شمع بود. خروجی مدل، ظرفیت باربری شمع بود. مقدار خروجی مطلوب ظرفیت شمع، که در فرایند آموزش استفاده شد، با استفاده از کد کامپیوتری تجاری‌ای به نام CAPWAP یا روش CASE تخمین زده شد [۱۳ و ۱۴]. خطای میانگین مربعات ریشه میانگین درصدی شبکه عصبی برای مجموعه آموزش ۱۳/۵٪ و برای مجموعه آزمایشی ۱۲٪ بود.

لی^۵ از شبکه‌های عصبی برای پیش‌بینی ظرفیت باربری نهایی شمع‌ها استفاده کرد [۱۵]. مسئله لی با استفاده از داده‌های مدل آزمایش‌های بار شمع، با استفاده از اتاق کالیبراسیون و نتایج آزمایش‌های بارگذاری شمع در محل، شبیه‌سازی شد. برای شبیه‌سازی با استفاده

¹ Engineering News

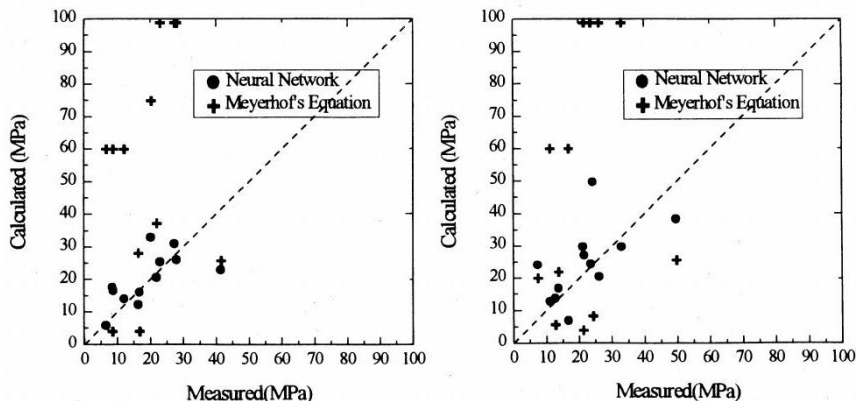
² Hiley

³ Janbu

⁴ Chan et al.

⁵ Lee

از داده‌های مدل آزمایش‌های بار شمع، ورودی‌های مدل شامل نسبت عمق نفوذ (عمق نفوذ شمع/قطر شمع)، فشار متوسط محفظه کالیبراسیون و تعداد ضربات بودند. ظرفیت بارگیری نهایی، خروجی مدل بود. پیش‌بینی مدل شبکه عصبی حداکثر خطا را کمتر از ۲۰٪ و خطای مجموع مربعات میانگین را کمتر از ۱۵٪ نشان داد. برای شبیه‌سازی با استفاده از داده‌های آزمایش بار شمع در محل، پنج متغیر ورودی استفاده شدند که نسبت عمق نفوذ، متوسط شماره نفوذ استاندارد در طول بدنه شمع، متوسط شماره نفوذ استاندارد نزدیک نوک شمع، تنظیم شمع و انرژی چکش را نشان می‌دهند. دو مدل شبکه عصبی توسعه داده شدند. نتایج این مدل‌ها با معادله مایرهاف، براساس مقدار متوسط شماره نفوذ استاندارد، مقایسه شدند [۱۶]. شکل ۴، نمودارهای نتایج مجموعه آزمایشی از بارگذاری شمع تخمینی در مقابل بارگذاری اندازه‌گیری شده به دست آمده از مدل‌های شبکه عصبی و معادله مایرهاف را نشان می‌دهد. نمودارها در شکل ۴ نشان می‌دهند مقادیر پیش‌بینی شده از شبکه‌های عصبی مطابقت بهتری نسبت به مقادیر اندازه‌گیری شده معادله مایرهاف دارند.

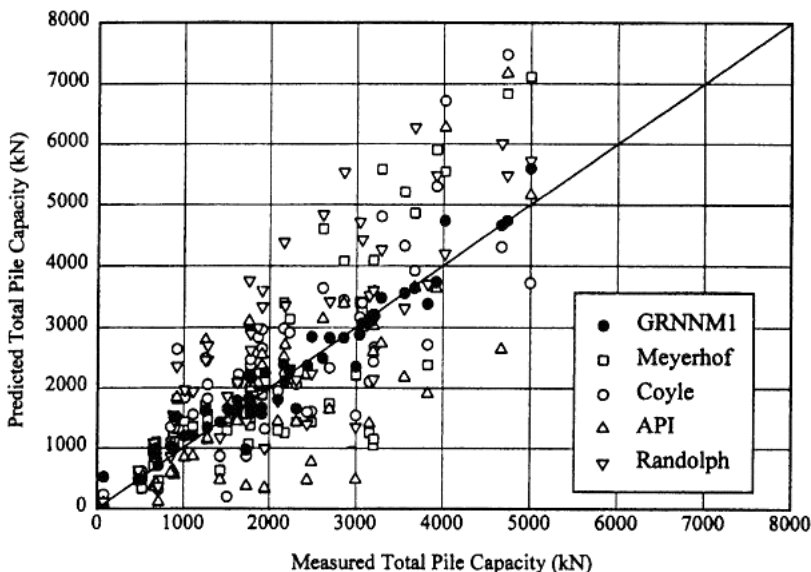


شکل ۴: نتایج آزمایش ظرفیت باربری شمع پیش‌بینی شده در مقابل اندازه‌گیری شده از آزمایش بار شمع در جا [۱۵]

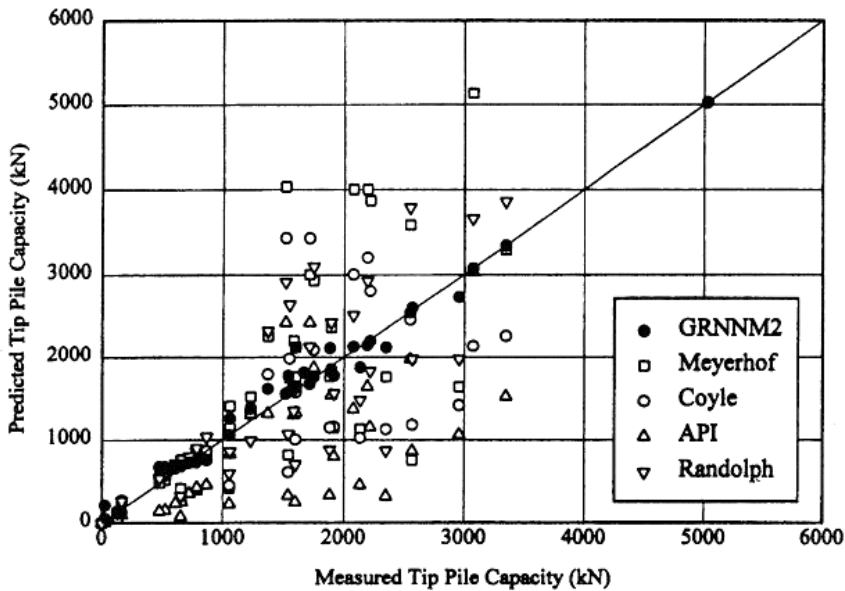
ابوکیف سه مدل شبکه عصبی (معروف به مدل‌های GRNNM1، GRNNM2 و GRNNM3) را برای پیش‌بینی ظرفیت شمع‌های کوبیده شده در خاک‌های غیرچسبنده معرفی کرد [۱۷]. مدل اول برای برآورد ظرفیت کل شمع توسعه داده شد. مدل دوم برای برآورد ظرفیت نوک شمع استفاده شد؛ در حالی که مدل نهایی برای برآورد ظرفیت بدنه شمع استفاده شد. در مدل اول، پنج متغیر برای ورودی مدل انتخاب شدند؛ این ورودی‌ها شامل زاویه مقاومت برشی خاک در اطراف بدنه، زاویه مقاومت برشی در نوک شمع، فشار برشی مؤثر در نوک شمع، طول و سطح مقطع معادل شمع بود. مدل اول، یک خروجی داشت که نمایانگر ظرفیت کل شمع بود. در مدل استفاده شده برای ارزیابی ظرفیت نوک شمع، متغیرهای ورودی ذکر شده استفاده شدند. متغیرهای ورودی استفاده شده برای پیش‌بینی



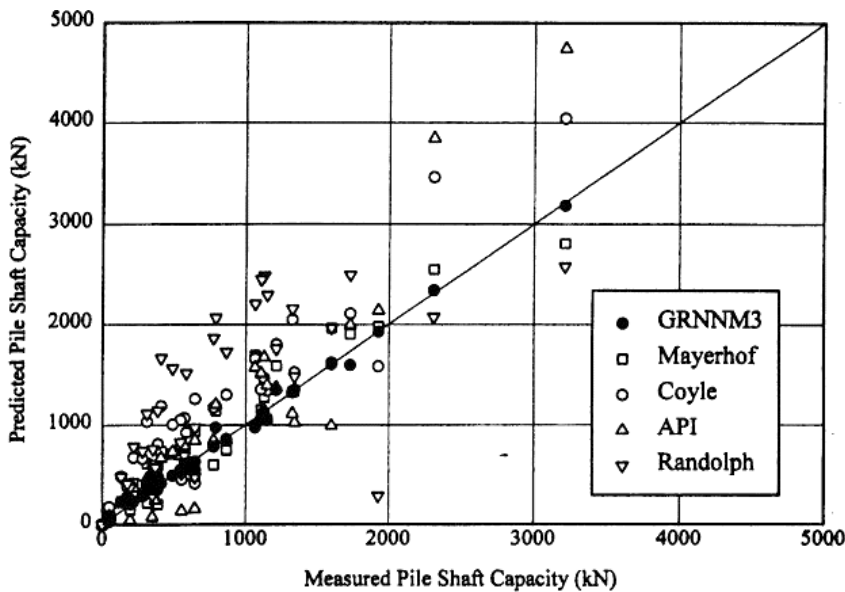
ظرفیت بدنه شمع، چهار متغیر بودند که نمایانگر میانگین شماره نفوذ استاندارد اطراف بدنه، زاویه مقاومت برشی اطراف بدنه، طول و قطر شمع بودند. نتایج شبکه‌های حاصل از این مطالعه با چهار روش تجربی دیگر مقایسه شدند؛ این روش‌ها شامل آنچه توسط مایرهاف، کوپل و کاستلو، انستیتوت نفت آمریکا و راندلف پیشنهاد شده‌اند، بود [۲۰-۱۶]. نتایج پیش‌بینی ظرفیت کل شمع برای همه داده‌های به‌دست‌آمده از شبکه عصبی ضرایب اطمینان بالایی (۰/۹۵) را نشان داد. در حالی‌که برای روش‌های دیگر بین ۰/۵۲ تا ۰/۶۳ متغیر بودند. شکل‌های ۵ تا ۷، مقادیر اندازه‌گیری‌شده در مقابل مقادیر پیش‌بینی‌شده به ترتیب برای ظرفیت بارگیری، نوک و بدنه شمع را نشان می‌دهند. با توجه به نتایج به‌دست‌آمده از این شکل‌ها، پراکندگی پیش‌بینی‌های شبکه‌های عصبی کمتر از پیش‌بینی‌های تمامی روش‌های دیگر بوده؛ بنابراین، بهترین پیش‌بینی ظرفیت بارگیری، نوک و بدنه شمع را ارائه می‌دهند.



شکل ۵: مقایسه ظرفیت باربری پیش‌بینی‌شده با مدل GRNNM1 و مدل اندازه‌گیری‌شده [۱۹]




شکل ۶: مقایسه ظرفیت باربری پیش‌بینی شده با مدل GRNNM2 و مدل اندازه‌گیری شده [۱۹]



شکل ۷: مقایسه ظرفیت باربری پیش‌بینی شده با مدل GRNNM3 و مدل اندازه‌گیری شده [۱۹]

ته و همکارانش شبکه‌ای عصبی را برای برآورد ظرفیت شمع‌های استاتیکی - با استفاده از داده‌های موج تنشی دینامیک برای شمع‌های بتنی تقویت شده پیش‌ساخته با مقطع مربعی - پیشنهاد دادند [۲۱]. شبکه‌ها برای ارتباط دادن داده‌های موج تنشی ورودی با ظرفیت‌های به‌دست‌آمده از کد کامپیوتری تجاری CAPWAP آموزش داده شدند [۱۳]. این مطالعه به‌جای

ظرفیت واقعی باربری شمع، به پیش‌بینی «ظرفیت پیش‌بینی شده توسط CAPWAP» توجه داشت. این شبکه عصبی، پیش‌بینی ظرفیت کل شمع‌های استاتیکی با خطای میانگین مربعات ریشه کمتر از ۰/۰۰۰۳ را انجام داد. شکل ۸ پیش‌بینی‌های دقیق صورت گرفته برای ۷ شمع از ۱۰ شمع را نشان می‌دهد.

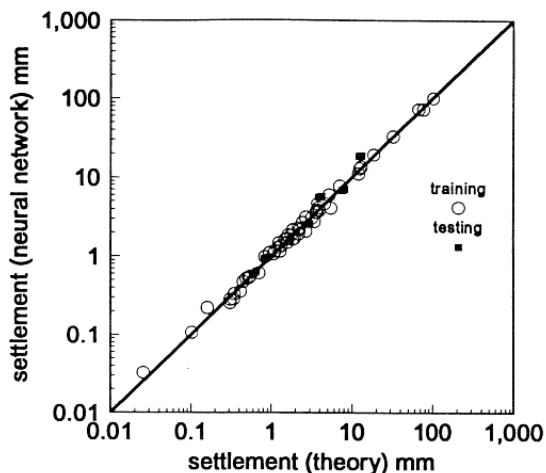


شکل ۸: ظرفیت ایستای پیش‌بینی شده توسط CAPWAP و شبکه عصبی برای مجموعه آزمایش‌ها [۲۱]

۱/۲. نشست فونداسیون‌ها


طراحی شمع‌ها معمولاً با معیارهای ظرفیت باربری و نشست کنترل می‌شود که در بیشتر مواقع نشست حاکم است. مسئله تخمین نشست شمع‌ها بسیار پیچیده، نامعلوم و هنوز کاملاً درک نشده است و به همین دلیل، برخی از پژوهشگران به سمت پیش‌بینی نشست با استفاده از شبکه مصنوعی عصبی سوق پیدا کرده‌اند. گاه، شبکه‌ای عصبی را برای پیش‌بینی نشست شمع عمودی در یک لایه خاک یکنواخت توسعه داد [۵]. متغیرهای ورودی شبکه عصبی پیشنهادی گاه شامل نسبت مدول الاستیک شمع به مدول برشی خاک، طول شمع، بار شمع، مدول برشی خاک، نسبت پواسون خاک و شعاع شمع و متغیر خروجی نیز نشست شمع بود. خروجی مورد نیاز برای آموزش مدل شبکه عصبی با استفاده از تجزیه و تحلیل‌های امان محدود و معادله انتگرال توسط رندوف و ورث^۱ به دست آمده بود [۲۰]. مقایسه‌ای از نشست‌های نظری و پیش‌بینی شده برای مجموعه‌های آموزش و آزمایش در شکل ۹ آورده شده است. نتایج شکل ۹ نشان می‌دهند که شبکه عصبی قادر به مدل‌سازی موفقیت‌آمیز نشست شمع‌ها بوده است.

^۱ Randolph and Wroth



شکل ۹: مقایسه نشست‌های تئوری و پیش‌بینی‌شده با شبکه عصبی [۵]

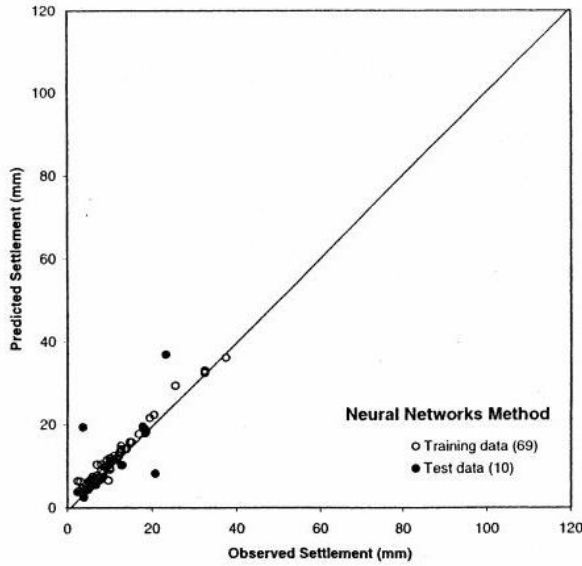
سیواکوگان و همکارانش^۱ امکان استفاده از شبکه‌های عصبی برای پیش‌بینی نشست شمع‌های کم‌عمق در خاک‌های دانه‌ای را بررسی کردند [۲۲]. این شبکه عصبی با پنج ورودی که فشار اعمالی اصلی، متوسط شماره ضربه از آزمایش نفوذ استاندارد، عرض شمع، شکل شمع و عمق شمع را نمایش می‌دهد، آموزش داده شد و در نهایت، خروجی آن، نشست شمع بود. نتایج حاصل از شبکه عصبی با روش ترزاقی^۲ و پک^۳ و روش شمترمن^۴ مقایسه شد [۲۳ و ۲۴]. براساس نتایج به دست آمده، که در شکل ۱۰ نشان داده شده‌اند، روش سنتی ترزاقی و پک و روش شمترمن به ترتیب نشست را حدود ۲/۱۸ و ۳/۳۹ بار بیش‌تر از حد مورد انتظار تخمین زده‌اند؛ در مقابل، پیش‌بینی‌ها با استفاده از مدل شبکه عصبی بسیار خوب بودند (شکل ۱۱).



شکل ۱۰: نشست‌های پیش‌بینی‌شده با استفاده از روش‌های متداول [۲۲]

- 1 Sivakugan et al.
- 2 Terzaghi
- 3 Peck
- 4 Schmertman





شکل ۱۱: نشست‌های پیش‌بینی شده با استفاده از شبکه عصبی مصنوعی [۲۲]

اخیراً، شاهین و همکارانش^۱ کار مشابهی برای پیش‌بینی نشست شمع‌های کم‌عمق در خاک‌های بدون چسبندگی انجام دادند [۲۵]؛ در این تحقیق از ۲۷۲ تاریخچه داده برای مدل‌سازی استفاده شد. متغیرهای ورودی- که تأثیر مهمی بر تخمین نشست داشتند- عرض شمع، طول شمع، فشار اعمال‌شده زمین و تراکم‌پذیری خاک بودند. نتایج شبکه عصبی با سه روش سنتی و معمولی مقایسه شدند؛ این روش‌ها شامل مایر هاف^۲، شولتز و شریف^۳ و شمترمن و همکارانش بودند. نتایج این مطالعه تأیید کردند که شبکه عصبی قادر به پیش‌بینی نشست بوده و عملکرد بهتری نسبت به روش‌های سنتی دارد. همان‌طور که در جدول ۳ نشان داده شده است، شبکه عصبی دارای ضرایب همبستگی بالا (r)، خطاهای میانگین مربعات ریشه‌ای کم (RMSE) و خطاهای مطلق میانگین کمتر (MAE) نسبت به سایر روش‌ها بوده است.

جدول ۳: مقایسه نشست‌های پیش‌بینی شده و اندازه‌گیری شده [۲۵]

دسته‌بندی	ANN	Meyerhof (1965)	Schultze & Sherif (1973)	Schmertman et al. (1978)
همبستگی (r)	۰/۹۹	۰/۳۳	۰/۸۶	۰/۷۰
RMSE (mm)	۳/۹	۲۷	۲۳/۸	۴۵/۲
MAE (mm)	۲/۶	۲۰/۸	۱۱/۱	۲۹/۵

¹ Shahin et al.

² Meyerhof

³ Schultze and Sherif

روان‌گرایی پدیده‌ای است عمدتاً ناشی از زلزله که در ماسه‌های کم‌تراکم و اشباع به وجود می‌آید؛ در این پدیده، به دلیل افزایش فشار آب منفذی، مقاومت برشی خاک از بین می‌رود و اغلب منجر به بروز خسارت زیادی در بیشتر سازه‌های مهندسی شهری می‌شود. تعیین پتانسیل روان‌گرایی ناشی از زلزله، مسئله‌ای پیچیده در مهندسی ژئوتکنیک است. گاه^۱ از شبکه‌های عصبی برای مدل‌سازی رابطه پیچیده بین پارامترهای زلزله و خاک استفاده کرد تا پتانسیل روان‌گرایی را بررسی کند [۲۶]. شبکه عصبی استفاده‌شده در مطالعه گاه با استفاده از ۱۳ زلزله- که در سال‌های ۱۸۹۱ تا ۱۹۸۰ میلادی در ژاپن، ایالات متحده و پان‌آمریکا^۲ رخ داده بودند- آموزش داده شد و هشت متغیر ورودی و فقط یک متغیر خروجی داشت. متغیرهای ورودی شامل مقادیر آزمایش SPT^۳، خصوصیات ذرات ریز خاک، اندازه میانگین ذرات، فشار کل، تنش مؤثر، تنش برشی دینامیک معادل، بزرگی زلزله و بیشینه شتاب افقی در سطح زمین بودند. مقدار خروجی به مقدار دودویی یک برای مکان‌هایی که دارای روان‌گرایی فراوان یا متوسط بودند و مقدار صفر برای روان‌گرایی کم یا عدم روان‌گرایی اختصاص داده شد. نتایج به‌دست‌آمده از مدل شبکه عصبی با روش سید و همکاران^۴ مقایسه شدند [۲۷]. این مطالعه نشان داد شبکه عصبی در ۹۵٪ موارد پیش‌بینی‌های صحیحی داشته است؛ درحالی‌که نرخ موفقیت روش سید برابر با ۸۴٪ بوده است. گاه نیز از شبکه‌های عصبی برای ارزیابی پتانسیل روان‌گرایی از داده‌های مقاومت آزمایش پرندۀ مخروط^۵ استفاده کرد [۲۸]. سوابق داده‌شده برای مناطق ذخیره ماسه و ماسه‌ای لومی در ژاپن، چین، ایالات متحده و رومانی مربوط به پنج زلزله در سال‌های ۱۹۶۴ تا ۱۹۸۳ میلادی بودند. استراتژی مدل‌سازی مشابه شبکه‌های عصبی، مانند استفاده‌شده در گاه، برای این مطالعه استفاده شد و نتایج آن با روش شیباتا و تپارکسا^۶ مقایسه شد [۲۹]. شبکه عصبی نرخ موفقیت ۹۴٪ را نشان داد که معادل تعداد پیش‌بینی‌های اشتباه به روش معمول شیباتا و تپارکسا بود.

دو پژوهش دیگر نیز از داده‌های آزمایش CPT برای ارزیابی پتانسیل روان‌گرایی خاک و مقاومت آن استفاده کردند [۳۰ و ۳۱]؛ در تحقیق اول، از شبکه‌های عصبی برای توصیف مقاومت روان‌گرایی خاک با استفاده از مجموعه داده‌های میدانی از جهان استفاده شد. مدل شبکه عصبی‌ای که در تحقیق اول توسعه یافت، برای تولید نمودار ارزیابی پتانسیل روان‌گرایی ساخته شد که می‌تواند توسط مهندسان ژئوتکنیک در وظایف ارزیابی روان‌گرایی استفاده شود.

¹ Goh

² Pan-America

³ Standard penetration test

⁴ Seed et al.

⁵ Cone penetration test

⁶ Shibata and Teparaksa



کاربردهای دیگر شبکه‌های عصبی برای پیش‌بینی روان‌گرایی شامل پیش‌بینی مقاومت و پتانسیل روان‌گرایی، بررسی دقت پیش‌بینی روان‌گرایی توسط شبکه‌های عصبی نسبت به منطق فازی و روش‌های آماری است [۳۰ و ۳۲].

۴/۱. پایداری شیب‌ها

نی و همکارانش^۱ روشی برای ارزیابی پایداری شیب‌ها ارائه دادند که از تئوری مجموعه‌های فازی با شبکه‌های عصبی مصنوعی ترکیب شده است [۳۳]؛ در این روش، پارامترهای ورودی شامل شیب، پروفیل افقی، پروفیل عمودی، موقعیت، ارتفاع، منشأ زمین‌شناسی، بافت خاک، تغییرات آب‌وهوایی، جهت شیب‌ها، گیاهان، استفاده از زمین، بیشترین بارش روزانه و بیشترین بارش ساعتی و خروجی نیز پتانسیل شکست شیب بود. تعدادی از شیب‌های طبیعی فرضی به‌وسیله هر دو شبکه‌های عصبی و یک مدل تحلیلی ارزیابی شدند و نتایج روش شبکه‌های عصبی با نتایج حاصل از مدل تحلیلی در تطابق خوبی بودند.

۵/۱. ونل‌ها و بازشوهای زیرزمین

شی و همکارانش^۲ مطالعه‌ای درباره شبکه‌های عصبی برای پیش‌بینی مناطق پرتراکم تونل‌ها ارائه دادند [۳۴]؛ در این تحقیق، مدلی کلی از شبکه عصبی آموزش داده‌شده با داده‌های تونلی در برزیل به طول ۶/۵ کیلومتر آزمایش شد. بسیاری از عوامل در تحقیق شی و همکارانش از ورودی‌های مدل بودند و سه پارامتر نشست، خروجی‌های مدل شناسایی شدند. پارامترهای ورودی شامل طول حفاری از زمان شروع حفاری، عمق پوشش خاک بالای تونل، مساحت مقطع تونل، عمق سطح آب زیرزمینی، نرخ پیشرفت حفاری، روش ساخت، میانگین تعداد ضربه‌ها در سطح تاج تونل و میانگین تعداد ضربه‌ها از آزمایش نفوذ استاندارد در سطح کف تونل بود. سه پارامتر خروجی این مدل نیز شامل نشست در صورت تونل، نشست در کف تونل و نشست نهایی پس از پایداری تونل بود.

نتایج نشان دادند مدل شبکه عصبی به موفقیت چندانی دست پیدا نکرد. برای بهبود دقت پیش‌بینی، مطالعه مدل شبکه عصبی براساس مفهوم یکپارچه‌سازی چندین شبکه عصبی در یک سیستم ارائه کرد؛ به‌طوری‌که هر بخش، محدود به کار در شرایط خاصی از مسئله پیچیده واقعی بود که منجر به بهبود در هم‌گرایی مدل و پیش‌بینی دقیق‌تر شد.

قابلیت بهبود مدل‌های توسعه‌یافته در این مطالعه بعداً توسط پژوهشگر دیگری با استفاده از تبدیل داده‌های ورودی افزایش یافت [۳۵]. این مطالعه توسعه‌یافته نشان داد که تبدیل توزیع متغیرهای ورودی با کاهش خطا در پیش‌بینی بیش از ۱۳٪ منجر به بهبود شده است. در مطالعه دیگری برای شناسایی حالت‌های شکست احتمالی بازشوهای زیرزمینی از اطلاعات تاریخی قبلی استفاده کرده‌اند؛ این مطالعه از دانش به‌دست‌آمده توسط شبکه عصبی برای تولید ابزار طراحی تونل استفاده کرد [۳۶].

¹ Ni et al.

² Shi et al.



۴. نتیجه‌گیری

از مطالعات مرور شده می‌توان استنباط کرد که شبکه‌های عصبی مصنوعی در بسیاری از زمینه‌های مهندسی ژئوتکنیک با موفقیت استفاده شده‌اند؛ این موارد شامل پیش‌بینی ظرفیت باربری شمع‌ها، روان‌گرایی، پایداری شیب، نشست فونداسیون‌ها و طراحی تونل‌ها و بازشوهای زیرمینی است. شبکه‌های عصبی در موارد ذکر شده، بهتر یا مانند روش‌های سنتی پیشین عمل می‌کند؛ زیرا در بسیاری از موارد در مهندسی ژئوتکنیک امکان مواجهه با مسائل بسیار پیچیده وجود دارد که درک آن‌ها به‌خوبی امکان‌پذیر نیست و شبکه‌های عصبی با مدل‌سازی مناسب بر پایه داده‌های ورودی قادر به حل این مسائل است. با وجود عملکرد قابل قبول شبکه‌های عصبی در بسیاری از موارد، آن‌ها محدودیت‌هایی نیز دارند. در مسائل مدل‌سازی، صرفاً نمی‌توان با استفاده از شبکه‌های عصبی به فیزیک مسئله پی برد؛ به عبارت دیگر، مرتبط ساختن پارامترها یا ساختار شبکه به پارامترهای فرایند معمولاً با سختی انجام می‌شود؛ همچنین، پیش‌بینی عملکرد آینده شبکه به‌سادگی امکان‌پذیر نیست. در نهایت با توجه به آنکه نتایج شبکه‌های عصبی براساس درون‌یابی حاصل می‌شوند، در صورتی که داده‌های ورودی از داده‌های آموزشی شبکه‌های عصبی خارج باشند، نتایج حاصل معتبر نیستند. به‌طور کلی، با وجود محدودیت‌های شبکه‌های عصبی، مزایای این روش باعث می‌شود مهندسان راه‌حل بسیاری از مشکلات مهندسی ژئوتکنیک را با ابزاری قدرتمند و عملی پیدا کنند.



- [1] Jaksa, M. B. (1995). "The influence of spatial variability on the geotechnical design properties of a stiff, overconsolidated clay," PhD thesis, The University of Adelaide, Adelaide.
- [2] Hubick, K. T. (1992). Artificial neural networks in Australia, Department of Industry, Technology and Commerce, Commonwealth of Australia, Canberra.
- [3] Hecht-Nielsen, R. (1990). Neurocomputing, Addison-Wesely Publishing Company.
- [4] Maren, A., Harston, C., and Pap, R. (1990). Handbook of neural computing applications, Academic Press, Inc., San Diego, California.
- [5] Goh, A. T. C. (1994a). "Nonlinear modelling in geotechnical engineering using neural networks." Australian Civil Engineering Transactions, CE36(4), 293-29.
- [6] Semple, R. M., and Rigden, W. J. (1986). "Shaft capacity of driven pipe piles in clay." Ground Engineering, 19(1), 11- 17.
- [7] Burland, J. B. (1973). "Shaft friction of piles in clay." Ground Engineering, 6(3), 1-15.
- [8] Goh, A. T. C. (1996b). "Pile driving records reanalyzed using neural networks." J. Geotech. Engrg., ASCE, 122(6), 492-495.
- [9] Hiley, A. (1922). "The efficiency of the hammer blow, and its effects with reference to piling." Engineering, 2, 673.
- [10] Janbu, N. (1953). "Une analyse energetique du battage des pieux a l'aide de parametres sans dimension." Norwegian Geotech. Inst., Oslo, Norway, 3, 63-64.
- [11] Chan, W. T., Chow, y. K., and Liu, L. F. (1995). "Neural network: An alternative to pile driving formulas." J. Computers and Geotechnics, 17, 135-156.
- [12] Broms, B. B., and Lim, P. C. (1988). "A simple pile driving formula based on stress-wave measurements." Proc., The 3rd Int. Conf. on the Application of Stress-Wave Theory to Piles, B. H. Fellenius, ed., Vancouver, 591-600.
- [13] Rausche, F., Moses, F., and Goble, G. G. (1972). "Soil resistance predictions from pile dynamics." J. Soil Mech. and Found. Div., ASCE, 98, 917-937.
- [14] Goble, G. G., Likins, G. E., and Rausche, F. (1975). "Bearing capacity of piles from dynamic measurements." Final Report, Dept. of Civil Engineering, Case Western University.
- [15] Lee, I. M., and Lee, J. H. (1996). "Prediction of pile bearing capacity using artificial neural networks." Computers and Geotechnics, 18(3), 189-200.
- [16] Meyrehof, G. G. (1976). "Bearing capacity and settlement of pile foundations." J. Geotech. Engrg., ASCE, 102(3), 196-228.
- [17] Abu-Kiefa, M. A. (1998). "General regression neural networks for driven piles in cohesionless soils." J. Geotech. & Geoenv. Engrg., ASCE, 124(12), 1177-1185.
- [18] Coyle, H. M., and Castello, R. R. (1981). "New design correlations for piles in sand." J. Geotech. Engrg., ASCE, 107(7), 965-986.
- [19] American Petroleum Institute. (1984). RP2A: Recommended practice for planning, designing and constructing fixed offshore platforms, Washington, D.C.
- [20] Randolph, M. F., and Wroth, C. P. (1978). "Analysis of deformation of vertically loaded piles." J. Geotech. Engrg., ASCE, 104(12), 1465-1488.
- [21] Teh, C. I., Wong, K. S., Goh, A. T. C., and Jaritngam, S. (1997). "Prediction of pile capacity using neural networks." J. Computing in Civil Engineering, ASCE, 11(2), 129-138.



[22] Sivakugan, N., Eckersley, J. D., and Li, H. (1998). "Settlement predictions using neural networks." *Australian Civil Engineering Transactions*, CE40, 49-52.

[23] Terzaghi, K., and Peck, R. B. (1967). *Soil mechanics in engineering practice* John Wiley & Son, Inc., New York.

[24] Schmertmann, J. H., Hartman, J. P., and Brown, P. B. (1978). "Improved strain influence factor diagrams." *J. Geotech. Engrg., ASCE*, 104(GT8), 1131-1135.

[25] Shahin, M. A., Jaksa, M. B., and Maier, H. R. (2000). "Predicting the settlement of shallow foundations on cohesionless soils using back-propagation neural networks." *Research Report No. R 167*, The University of Adelaide, Adelaide.

[26] Goh, A. T. C. (1994b). "Seismic liquefaction potential assessed by neural network." *J. Geotech. & Geoenv. Engrg., ASCE*, 120(9), 1467-1480.

[27] Seed, H. B., Tokimatsu, H., Harder, L. F., and Chung, R. M. (1985). "Influence of SPT procedure in seismic liquefaction resistance evaluations." *J. Geotech. Engrg., ASCE*, 111(12), 1425-1445.

[28] Goh, A. T. C. (1996a). "Neural-network modeling of CPT seismic liquefaction data." *J. Geotech. Engrg., ASCE*, 122(1), 70-73.

[29] Shibata, T., and Teparaksa, W. (1988). "Evaluation of liquefaction potentials of soils using cone penetration tests." *Soils and Foundations*, 28(2), 49-60.

[30] Ali, H. E., and Najjar, Y. M. (1998). "Neuronet-based approach for assessing liquefaction potential of soils." *Transportation Research Record No. 1633*, 3-8.

[31] Ural, D. N., and Saka, H. (1998). "Liquefaction assessment by neural networks." *Electronic Journal of Geotechnical Engrg.*, <http://geotech.civen.okstate.edu/ejge/ppr9803/index.html>

[32] Juang, C. H., and Chen, C. J. (1999). "CPT-based liquefaction evaluation using artificial neural networks." *ComputerAided Civil and Infrastructure Engineering*, 14(3), 221-229.

[33] Ni, S. H., Lu, P. C., and Juang, C. H. (1996). "A fuzzy neural network approach to evaluation of slope failure potential." *J. Microcomputers in Civil Engineering*, 11, 59-66.

[34] Shi, J., Ortigao, J. A. R., and Bai, J. (1998). "Modular neural networks for predicting settlement during tunneling." *J. Geotech. & Geoenv. Engrg., ASCE*, 124(5), 389-395.

[35] Shi, J. J. (2000). "Reducing prediction error by transforming input data for neural networks." *J. Computing in Civil Engrg., ASCE*, 14(2), 109-116.

[36] Sterling, R. L., and Lee, C. A. (1992). "A neural network - expert system hybrid approach for tunnel design." *Proc., 33rd United-States Symp. Rock Mechanics*, J. R. Tillerson and W. R. Wawerisk, eds., Brookfield VT: Balkema, 501-510.

