

ارائه مدل‌هایی برای تخمین شاخص قابلیت فشردگی (C_c) در خاک‌های ریزدانه

محمد کاظم امیری^۱، غلامرضا لشکری پور^{۲*}، محمد غفوری^۲، ناصر حافظی مقدس^۲

تاریخ پذیرش: ۹۴/۵/۲۶

تاریخ دریافت: ۹۳/۰۶/۱۵

چکیده

قابلیت فشردگی (*Compressibility*) توده خاک یکی از مهمترین پارامترهای خاک می‌باشد که برای طراحی‌های ژئوتکنیک ضروری است. با توجه به اینکه تعیین شاخص قابلیت فشردگی از آزمایش تحکیم نسبتاً وقت‌گیر است محاسبه این شاخص از فرمول‌های تجربی بر اساس خصوصیات خاک می‌تواند مفید باشد. در طی دهه‌های اخیر، چندین رابطه تجربی برای تخمین قابلیت فشردگی با استفاده از پارامترهایی مانند درصد رطوبت طبیعی، حد روانی، شاخص خمیری، وزن مخصوص و دیگر پارامترهای خاک ارائه شده است. در این تحقیق ابتدا بر اساس داده‌های ۱۱۵ مورد مطالعه از ۸ سایت در نقاط مختلف کشور به کمک رگرسیون ساده و چند متغیره روابط تجربی برای ارتباط بین شاخص قابلیت فشردگی و دیگر پارامترهای خاک مانند حد روانی، حد خمیری، شاخص خمیری، نسبت پوکی در حد روانی و نسبت پوکی در حد خمیری پیشنهاد شد. سپس به عنوان روش جایگزین یک مدل شبکه عصبی مصنوعی برای تخمین شاخص قابلیت فشردگی ارائه گردید. شاخص قابلیت فشردگی به عنوان تابعی از ۵ پارامتر شامل شاخص خمیری، درصد ذرات ریزدانه، نسبت پوکی در حد روانی، نسبت پوکی در حد خمیری و وزن مخصوص مدل شد. در نهایت مدل‌های ارائه شده با هم مقایسه گردید. نتایج نشان داد که مدل شبکه عصبی از عملکرد بهتری نسبت به روابط تجربی دیگر برای پیش‌بینی شاخص قابلیت فشردگی خاک‌های ریزدانه برخوردار می‌باشد.

کلمات کلیدی: خاک‌های ریزدانه، شاخص قابلیت فشردگی، خصوصیات شاخص خاک، رگرسیون ساده و چند متغیره، شبکه عصبی

۱. دانشجوی دکتری زمین شناسی مهندسی، دانشگاه فردوسی مشهد

۲. استاد گروه زمین شناسی مهندسی، دانشگاه فردوسی مشهد lashkaripour@um.ac.ir

* مسئول مکاتبات

۱. مقدمه

یکی از فاکتورهای مهم در طراحی‌های ژئوتکنیکی پی، ارائه تخمینی قابل اعتماد از ویژگی‌های قابلیت فشردگی خاک است. ویژگی‌های قابلیت فشردگی خاک نقش کلیدی در تحلیل نشست لایه‌های خاک تحت بار اعمال شده دارد (Tiwari and Ajmera, 2012; Singh and Noor, 2012). قابلیت فشردگی خاک، کاهش حجم خاک تحت بار وارده در اثر زهکشی فشار آب منفذی می‌باشد. نرخ زهکشی آب منفذی یک فرآیند وابسته به زمان است چون تابعی از نفوذپذیری خاک است در نتیجه تحلیل قابلیت فشردگی خاک برای خاک‌های ریزدانه با نفوذپذیری پایین از اهمیت بالاتری برخوردار است. شاخص قابلیت فشردگی (C_c)، ضریب قابلیت فشردگی (a_v) و ضریب تحکیم (C_v) اندیس‌های اصلی قابلیت فشردگی خاک هستند. از میان این پارامترها C_c اغلب برای محاسبه مستقیم نشست استفاده می‌شود روش مرسوم در تعیین پارامترهای تحکیم خاک شامل حفاری و برداشت نمونه‌های دست نخورده و انجام آزمایش تحکیم یک بعدی (ادئومتری) می‌باشد. (Carter and Bentley, 1991; Gulhati and Datta, 2005; Singh and Noor, 2012, Mohammadzadeh et al., 2014). تعیین C_c از آزمایش تحکیم به خصوص برای خاک‌های ریزدانه فرآیندی پرهزینه و وقت‌گیر است و نیاز به دقت بسیار بالایی دارد. برای مثال در خاک‌های ریزدانه این آزمایش حدود سه هفته طول می‌کشد (Rani et al, 2013). برای پرهیز از بکارگیری آزمایش تحکیم چندین مطالعه بر روی پیش‌بینی قابلیت فشردگی خاکها با استفاده از خصوصیات فیزیکی پایه‌ای آنها انجام گرفته است. مدل‌های تجربی مختلفی برای ایجاد همبستگی بین C_c و خصوصیات شاخص خاکها مانند حد روانی، حد خمیری، شاخص خمیری، وزن مخصوص و نسبت پوکی ارائه شده است. (Skempton(1944) و Terzaghi & Peck(1967) روابطی برای محاسبه شاخص قابلیت فشردگی براساس حد روانی ارائه کردند. Wood & Wroth(1978) از مفهوم مکانیک خاک در شرایط بحرانی

برای یافتن رابطه بین شاخص قابلیت فشردگی، شاخص خمیری و وزن مخصوص رس استفاده کرد. Nagaraj & Murty(1985) معادله‌ای برای محاسبه شاخص قابلیت فشردگی با وزن مخصوص و نسبت پوکی در حد روانی خاک ارائه کردند. (Tiwari & Ajmera(2012، ۵۵ نمونه مختلف خاک با درصدهای مختلف کانی‌های مونت موریونیت، ایلیت، کائولینیت و کوآرتز در یک رطوبت اولیه برابر با حد روانی آماده کردند و سپس دو معادله برای محاسبه شاخص قابلیت فشردگی ارائه کردند، یکی برای خاکهایی با درجه فعالیت کمتر از یک و دیگری برای خاکهایی با فعالیت بیشتر از یک. بر اساس مطالعات گذشته روابطی بین شاخص قابلیت فشردگی و خصوصیات شاخص مانند حد روانی، حد خمیری، شاخص خمیری نسبت پوکی و... ارائه شده است (جدول ۱).

۱. پایگاه داده

۱۱۵ نمونه از ۸ سایت جمع‌آوری شد (جدول ۲) و آزمایش‌های دانه‌بندی حدود آتربرگ، تحکیم بر روی آنها انجام گرفت. وزن مخصوص (G_s)، حد روانی (LL)، حد خمیری (PL)، شاخص خمیری (PI)، درصد ذرات ریزدانه (CF)، نسبت پوکی در حد روانی (e_i)، نسبت پوکی در حد خمیری (e_p)، نسبت پوکی تحت بار ۱۰۰ کیلوپاسگال (e_{100}) و شاخص قابلیت فشردگی (C_c) در آزمایش‌ها اندازه‌گیری شده است. نمونه‌ها از تنوعی از خاک‌های ریزدانه شامل خاک‌های رسی (CH, CL)، سیلتی (ML)، رسی-سیلتی ($CL-$)، رس آلی (OH)، رس ماسه‌دار و سیلت ماسه‌دار تشکیل شده است (مجموعه گزارشات ژئوتکنیکی شرکت مهندسی مشاور راه و پل هامون). در شکل ۱ موقعیت سایت‌های نمونه‌برداری شده ارائه شده است. آمار توصیفی داده‌ها در جدول ۳ آورده شده است.

جدول ۱. روابط ارائه شده برای پیش‌بینی شاخص قابلیت فشردگی

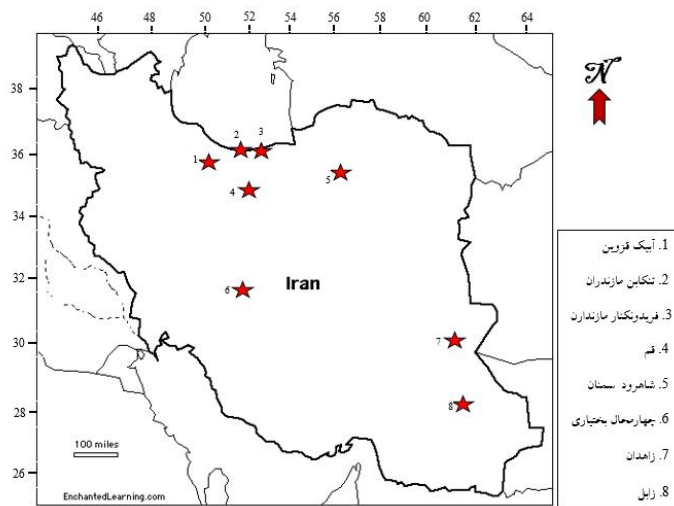
Reference	Equation	کاربرد
Skempton (1944)	$C_c = 0.007(LL - 10)$	رس‌ها ریمولد شده
Nishida (1956)	$C_c = 1/15 (e_0 - 0.35)$	همه رس‌ها
Cozzolino (1961)	$C_c = 0.43(e_0 - 0.11)$	رس‌های برزیلی
Terzaghi & Peck (1967)	$C_c = 0.009(LL - 10)$	رس‌های عادی تحکیم‌یافته
Sowers(1970)	$C_c = 0.75(e_0 - 0.50)$	خاک‌هایی با پلاستیسیته پایین
Azzouz et al.(1976)	$C_c = 0.40(e_0 - 0.25)$ $C_c = 0.01(\omega - 5)$ $C_c = 0.006(LL - 9)$	همه خاک‌های طبیعی
Wroth & Wood (1978)	$C_c = 0.50 \times PI \times G_s$	همه رس‌های عادی تحکیم یافته ریمولد شده
Mayne (1980)	$C_c = (LL - 15) / 109$	همه رس‌ها
Koppula (1981)	$C_c = 0.01\omega$	رس شیکاگو و آلبرتا
Herrero (1983)	$C_c = 0.01\omega - 0.075$	رس‌های عادی تحکیم‌یافته
Nagaraj & Murty(1985)	$C_c = 0.2343(LL/100)G_s$	رس‌های غیرآلی
Park & Lee(2011)	$C_c = 0.49(e_0 - 0.11)$ $C_c = 0.014(LL - 0.168)$	خاک‌های طبیعی کره

جدول ۲. نام سایت‌ها و تعداد نمونه‌ها

زابل	زاهدان	چهارمحال و بختیاری	شاهرود سمنان	قم	فریدونکنار	تنکابن	آبیک قزوین
۱۰ نمونه	۱۰ نمونه	۱۵ نمونه	۱۵ نمونه	۲۰ نمونه	۱۰ نمونه	۱۵ نمونه	۲۰ نمونه

جدول ۳. آمار توصیفی داده‌ها

پارامتر	میانگین	انحراف از معیار	واریانس نمونه	دامنه تغییرات	چولگی	کشیدگی	بیشینه	کمینه
LL	۶۴/۹۰۴	۲۹/۸۳۹	۸۹۰/۳۵۰	۱۳۷/۰۰	۱/۰۹۵	۰/۹۰۹	۱۵۹/۰۰	۲۲/۰۰
PL	۲۸/۱۶۵	۹/۹۱۳	۹۸/۲۶۲	۵۳/۰۰	۱/۰۲۰	۱/۴۷۸	۶۴/۰۰	۱۱/۰۰
PI	۳۶/۷۸۲	۲۳/۱۳۶	۵۳۵/۲۵۹	۱۰۵/۰۰	۱/۲۱۳	۱/۱۲۳	۱۱۳/۰۰	۸/۰۰
Gs	۲/۶۷۵	۰/۰۸۲	۰/۰۰۷	۰/۵۶	-۱/۰۰۸	۳/۶۲۲	۲/۸۶	۲/۳۰
CF	۴/۴۷۸	۱۵/۹۰۳	۲۵۲/۹۰۱	۶۹/۰۰	۰/۰۰۹	-۰/۶۹۴	۹۴/۰۰	۲۵/۰۰
Cc	۰/۴۲۵	۰/۲۳۸	۰/۰۵۶	۱/۱۱	۱/۱۶۳	۱/۰۹۴	۱/۱۹	۰/۰۸
el	۱/۷۳۶	۰/۸۰۷	۰/۶۵۱	۳/۹۱	۱/۲۰۴	۱/۳۴۶	۴/۵۰	۰/۵۹
ep	۰/۷۵۳	۰/۲۵۷	۰/۰۶۶	۱/۳۹	۰/۸۲۶	۰/۸۷۹	۱/۶۸	۰/۳۰
e ₁₀₀	۱/۱۴۰	۰/۴۰۹	۰/۱۶۸	۱/۹۵	۰/۷۶۸	۰/۲۹۰	۲/۴۰	۰/۴۵



شکل ۱. موقعیت سایت‌های نمونه برداری

۲. روش انجام مطالعه

ابتدا بر روی داده‌ها رگرسیون ساده و رگرسیون چند متغیره صورت گرفت، سپس یک مدل شبکه عصبی برای پیش‌بینی شاخص قابلیت فشردگی ارائه شد.

۱-۱-۲. رگرسیون ساده

در رگرسیون ساده امکان وجود مجموعه روابط ۱ بین متغیرهای کنترل و متغیر پاسخ تحقیق می‌گردد:

(۱)

$$y_i = \alpha + \beta x_i + e_i$$

$$y_i = \alpha + \beta \log x_i + e_i$$

$$y_i = \alpha \exp(\beta x_i) + e_i$$

۲-۱-۲. رگرسیون خطی

چند متغیره هدف برازش مدل زیر به داده‌ها با استفاده از روش کمترین مربعات خطا می‌باشد.

(۲)

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik}, \quad i = 1, 2, \dots, n$$

مدل‌ها در سطح اعتماد ۹۵ درصد بررسی شد. بنابراین برای بررسی معناداری مدل، ساخت مدل و ارزیابی ضرایب مدل، باید فرضیه‌های آماری زیر مورد بررسی قرار گیرد (روابط ۳، ۴ و ۵).

(۳)

$$\begin{cases} H_0: \beta = 0 & \text{مدل معنادار نیست} \\ H_1: \beta \neq 0 & \text{مدل معنادار است} \end{cases}$$

۱-۲. رگرسیون

به کمک نرم‌افزار SPSS دو نوع تحلیل رگرسیون بر روی داده‌ها صورت گرفت. ابتدا تحلیل رگرسیون ساده بر روی نمونه‌ها انجام گرفت و روابطی بین شاخص قابلیت فشردگی و سایر پارامترها بدست آمد سپس تحلیل رگرسیون خطی چند متغیره انجام گرفت. وقتی که وجود رابطه بین متغیرها تأیید شد، بایستی مدلی را برازش داد. منظور از برازش مدل مناسب تعیین رابطه رگرسیون موجود بین متغیرهای کنترل (X) و پاسخ (Y) می‌باشد. در صورتی که رابطه فقط شامل یک متغیر کنترل باشد، تحت عنوان معادله رگرسیون ساده و اگر دو یا بیش از دو متغیر کنترل را شامل شود به عنوان معادله رگرسیون چند متغیره شناخته می‌شود. رگرسیون اعم از ساده یا چند متغیره به شکل خطی و یا غیرخطی تعیین می‌شود (رابطه ۱ و ۲).

(۴)

$$\begin{cases} H_0: \beta = 0 & \text{مدل به عرض مبدا یا آن ضریب نیاز دارد} \\ H_1: \beta \neq 0 & \text{مدل به عرض مبدا یا آن ضریب نیاز دارد} \end{cases} \quad (5)$$

$$\begin{cases} \text{sig.}(p\text{-value}) > \alpha = 0.05 \rightarrow H_0 & \text{قبول} \\ \text{sig.}(p\text{-value}) < \alpha = 0.05 \rightarrow H_1 & \text{قبول} \end{cases}$$

مقدار Sig.(p-value) از آزمون فیشر بدست می آید.

۲-۲. مدل شبکه عصبی

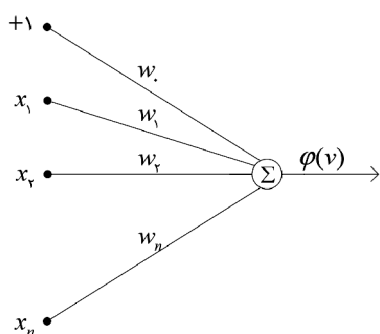
تعداد ۱۱۵ عدد برای ورود به مرحله مدل سازی به وسیله شبکه های مصنوعی آماده شد. شبکه عصبی به کار رفته در این تحقیق از نوع پرسپترون به عنوان شبکه ای با ناظر می باشد. در مرحله اولیه ۴ ورودی و در مراحل بعد ورودی های دیگری به عنوان متغیر مستقل به شبکه داده شد و پیش بینی انجام گردید و در هر مرحله نیز خطا اندازه گیری شد. در مراحل بعد پارامترهای ورودی بیشتر شده و دقت مقاومت نهایی پیش بینی شده و مقدار خطا در هر مرحله نیز تعیین گردید. در ادامه با توجه به مقدار حداقل خطای خروجی از هر مدل، مدل بهینه انتخاب شده است.

۲-۲-۱. شبکه عصبی پرسپترون

یکی از انواع شبکه های عصبی، پرسپترون می باشد که به صورت پرسپترون های تک لایه و چند لایه موجود می باشد. پرسپترون تک لایه تنها می تواند مسایل مجزای خطی را دسته بندی کند و برای مسایل پیچیده لازم است که از تعداد بیشتری لایه استفاده شود. شبکه های عصبی پرسپترون جز شبکه های عصبی پیشخور (Feedforward) طبقه بندی می شوند. شبکه های پیشخور چند لایه از یک یا تعداد بیشتری لایه های میانی تشکیل شده است. این شبکه ها یک شبکه مرتبط می باشد چرا که هر نرون در یک لایه به تمامی نرون های لایه بعدی مرتبط می باشد. شبکه های عصبی بر اساس نوع مجموعه آموزش نیز به دو نوع آموزش با ناظر (Supervised Learning) و آموزش بدون ناظر طبقه بندی

می شوند (منهاج، ۱۳۷۹). پرسپترون، نوعی از شبکه های عصبی مصنوعی با ناظر است که برای پیش بینی یا تخمین توابع پیچیده به کار گرفته می شود. ساختار یک شبکه پرسپترون یک لایه با n ورودی و یک خروجی به صورت شکل ۲ می باشد (Haykin, 1999). در این تحقیق شبکه عصبی پرسپترون به عنوان شبکه با ناظر مورد بررسی قرار گرفته است.

در لایه ورودی مقادیر بردار ورودی X، در هر مرحله به صورت رابطه ۶ در نظر گرفته می شود و بردار وزن های اتصالات شبکه w در هر مرحله با بردار رابطه ۷ نمایش داده می شود. خروجی شبکه $\varphi(v(t))$ تابعی از $v(t)$ می باشد که طبق خروجی مورد انتظار شبکه تعیین می گردد (رابطه ۸).



شکل ۲. ساختار یک شبکه پرسپترون یک لایه

(۶)

$$X(t) = [+1, x_1(t), x_2(t), \dots, x_n(t)] \quad (7)$$

(۷)

$$W(t) = [w_0(t), w_1, \dots, w_n(t)] \quad (8)$$

(۸)

$$v(t) = \sum_{i=0}^n w_i(t)x_i(t)$$

متغیرها عبارتند از $x(t)$ بردار ورودی با $n+1$ درایه $w(t)$ بردار وزن با $N+1$ درایه η پارامتر آموزش که یک عدد ثابت مثبت کوچکتر یا مساوی واحد می باشد $(0 < \eta \leq 1)$.

۲-۲-۲. فرآیند آموزش شبکه پرسپترون

در ادبیات شبکه های عصبی، به جای اصطلاح تخمین ضرایب از اصطلاح یادگیری یا آموزش برای پیدا کردن

تمام بردارهای ورودی به صورت یکجا به برنامه معرفی شده و به ازای وزن‌های ثابت، خطای تمامی آنها محاسبه می‌گردد. در پایان بر اساس متوسط خطای تک تک ورودی‌ها، تصحیح وزن‌ها انجام می‌شود. تجربه نشان داده که روش دوم به نتایج بهتری می‌رسد. در آغاز آموزش، لازم است مقدار اولیه‌ای برای وزن‌های اتصال شبکه در نظر گرفته شود که این وزن‌ها می‌توانند هر مقدار دلخواهی باشند. ولی بهتر است این مقادیر به گونه‌ای گزینش شوند که باعث سرعت بیشتر آموزش و همگرایی بهتر مسئله مورد نظر گردد. لازم به ذکر است که الگوریتم یادگیری پس انتشار خطا از نوع یادگیری با ناظر می‌باشد (Haykin, 1999).

برای اجرای آموزش طی ۴ مرحله اقدام می‌شود، که ابتدا شبکه به صورت اولیه مقدار دهی می‌شود. مقدار دهی به صورت تصادفی با مقادیر کوچک انجام شده و یا این که صفر در نظر گرفته می‌شود. مرحله بعد نمونه‌های آموزش طوری به شبکه معرفی می‌شود که در هر مرحله $X(t)$ بردار ورودی، $d(t)$ ، خروجی مطلوب و $y(t)$ خروجی شبکه می‌باشد (رابطه ۹ و ۱۰).

(۹)

$$y(t) = \begin{cases} +1, & v(t) \geq 0 \\ -1, & v(t) < 0 \end{cases}$$

(۱۰)

$$d(t) = \begin{cases} +1, & X(t) \in \text{pos} \\ -1, & X(t) \in \text{neg} \end{cases}$$

pos و neg به ترتیب خروجی مطلوب و خروجی نامطلوب هستند. تغییر وزن‌های اتصالات شبکه جز مرحله سوم می‌باشد (رابطه ۱۱).

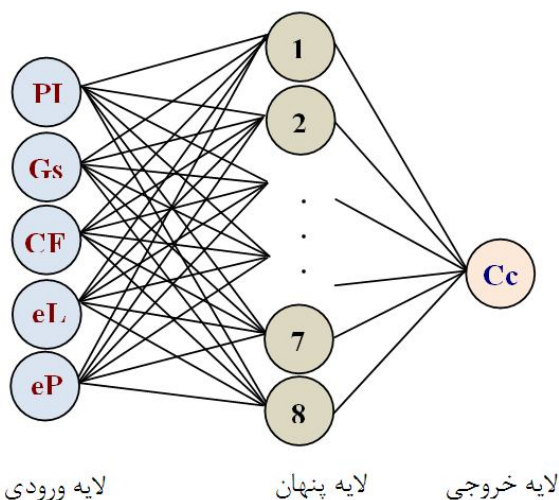
(۱۱)

$$W(t+1) = [w(t) + \eta[d(t) - y(t)]X(t)]$$

متغیرها عبارتند از $x(t)$ بردار ورودی با $n+1$ درایه $w(t)$ بردار وزن با $N+1$ درایه η پارامتر آموزش که یک عدد ثابت مثبت کوچکتر یا مساوی واحد می‌باشد ($0 < \eta \leq 1$).

ارزش‌های وزن‌های شبکه استفاده می‌شود. دو نوع یادگیری در این ادبیات مورد بحث قرار می‌گیرد، یادگیری تحت نظارت و یادگیری بدون نظارت. یادگیری با نظارت که به یادگیری با معلم نیز معروف است، ارزش‌های متغیر هدف که شبکه باید بر اساس ارزش‌های متغیرهای ورودی از طریق محاسباتش آنها را دوباره تولید کند، مشخص و سپس، خطای پیش‌بینی برای هر مشاهده، به وسیله محاسبه اختلاف خروجی شبکه با ارزش‌های متغیرهای هدف اندازه‌گیری می‌شود (شریفی و همکاران، ۱۳۹۰، شریفی و نیکودل، ۱۳۹۴). در این یادگیری هنگامی که ورودی به شبکه اعمال می‌شود جواب شبکه با جواب هدفی که تعیین شده است مقایسه شده و سپس خطای یادگیری محاسبه می‌شود و در ادامه از آن برای تنظیم شبکه استفاده می‌شود، به گونه‌ای که اگر در دفعه بعد به شبکه همان ورودی اعمال شود خروجی شبکه به هدف نزدیک‌تر می‌شود. این الگوریتم یک قانون یادگیری برای پرسپترون‌های چند لایه می‌باشد که بر پایه قانون دلتا و با استفاده از مجموع اندازه مجذور خطا برای نرون‌های خارجی طراحی گردیده است. در این روش وزن‌های شبکه با استفاده از الگوریتم‌های مختلف تکرار (که مشهورترین آنها انواع الگوریتم‌های پس انتشار خطا است) تعدیل می‌شود (یعنی شبکه آموزش داده می‌شود). همین طور که وزن‌ها با هر تکرار تغییر می‌کند (شبکه آموزش داده می‌شود) اصطلاحاً گفته می‌شود که شبکه در حال یادگیری است. الگوریتم پس انتشار خطا (Back Propagation) یکی از روش‌های مفید آموزش شبکه عصبی پرسپترون چند لایه است که اول بار توسط شخصی به نام ورباس (۱۹۷۴) ارائه شد (به نقل از مهنج، ۱۳۷۹) و سپس طی پژوهش‌های متعدد تکمیل گردید. اساس این روش به حداقل رساندن تابع خطا است. در روش مزبور، روند آموزش شبکه به طور معمول به دو گونه متفاوت نمونه‌ای (الگو به الگو یا متوالی) و گروهی (دسته‌ای) انجام می‌شود. در روش اول، بردارهای ورودی به صورت تک تک به برنامه معرفی شده سپس خطای آن در هر حالت محاسبه و در نهایت تصحیح وزن‌ها صورت می‌گیرد. اما در روش دوم،

جز شبکه‌های عصبی پیشخور طبقه‌بندی می‌شوند. الگوریتم انتشار برگشتی خطا (Back Propagation) نیز یکی از روش‌های مفید آموزش شبکه عصبی پرسپترون چند لایه است. روند آموزش شبکه به صورت گروهمی (دسته‌ای) انجام شده است که تمام بردارهای ورودی به صورت یکجا به برنامه معرفی شده و به ازای وزن‌های ثابت، خطای تمامی آنها محاسبه می‌گردد. در پایان بر اساس متوسط خطای تک تک ورودی‌ها، تصحیح و انطباق وزن‌ها انجام می‌شود (شریفی و نیکودل، ۱۳۹۴). مدل‌های شبکه عصبی انتخاب شده پس از بررسی‌های سعی و خطا در این تحقیق، دارای سه لایه بوده که پنج نرون در لایه ورودی، هشت نرون در لایه پنهان و یک نرون در لایه خروجی بکار رفته است. در نهایت نرون لایه خروجی نتیجه شبکه را تولید می‌کند. همه نرون‌های مجاور در مدل به وسیله بردار وزن‌ها، در ارتباط با دیگر لایه‌ها می‌باشند (Miguel Rocha et.al, 2007). همچنین در این مرحله نیز تعداد نرون در لایه پنهان نیز به عنوان یک پارامتر متغیر در نظر گرفته شده و شبکه‌هایی با تعداد نرون‌های مختلف در لایه پنهان طراحی و میزان خطا مورد مقایسه قرار گرفت. لازم به ذکر است که این مدل پس از چرخه‌های سعی و خطا بهینه شده و خروجی آن دارای خطا نسبتاً پایینی در مقایسه با دیگر مدل‌های طراحی شده می‌باشد.



شکل ۳. معماری شبکه پرسپترون بهینه جهت این تحقیق

مرحله چهارم اضافه کردن یک واحد به متغیر t و تکرار الگوریتم از مرحله ۲، به تعداد ثابت، یا تا جایی که مقادیر وزن‌های شبکه تغییرات ناچیزی داشته باشند. جهت به کارگیری شبکه پرسپترون لازم است یک سری نمونه ورودی و خروجی متناظر با آنها مشخص گردد و جهت آموزش به شبکه معرفی شود. در شبکه ناظر مساله اصلی تعیین نمونه‌های مجموعه آموزش می‌باشد (Haykin, 1999). برای حل مساله تصمیم‌گیری نمونه‌های مجموعه آموزش باید طوری باشند که همه حالت‌های مختلف گزینه‌ها را در بر بگیرند. خروجی شبکه پرسپترون متناظر با لیست مرتب گزینه‌ها می‌باشد و بنابراین تعداد نرون‌ها در لایه خروجی شبکه برابر با تعداد حالت‌هایی است که گزینه‌ها نسبت بهم خواهند داشت (Hong-Guang and Ji-Zong, 2000).

۲-۲-۳. ساخت مدل و پیش‌بینی

معمولاً در پیش‌بینی‌ها، متغیرهای راهنما یا اندکس طوری انتخاب می‌شود که اندازه‌گیری آنها آسان و هزینه کمی در برداشته باشد و نتیجه پیش‌بینی نیز بستگی به انتخاب پارامترها داشته و از دقت بدست آمده مطلوب بودن پیش‌بینی مورد بررسی قرار می‌گیرد (شریفی و همکاران، ۱۳۹۰). با علم به موارد فوق، در این تحقیق در مرحله اول سعی شد که متغیرهای انتخاب شده به راحتی توسط آزمایش‌های آزمایشگاهی قابل تعیین بوده و نتایج آن با کمترین هزینه در دسترس واقع شود. پارامترهای ورودی نهایی و بهینه شده جهت پیش‌بینی شاخص قابلیت فشردگی خاک شامل پارامترهای شاخص خمیری (PI)، درصد ذرات ریزدانه (CF)، نسبت پوکی در حد روانی (e_i)، نسبت پوکی در حد خمیری (e_p) و وزن مخصوص (G_s) به عنوان ورودی استفاده شده است. پارامتر خروجی یا هدف، شاخص قابلیت فشردگی (C_c) می‌باشد.

در این مطالعه از شبکه پرسپترون پیشخور سه لایه با الگوریتم آموزشی انتشار برگشتی خطا و انطباقی استفاده شده است (شکل ۳). لازم به ذکر است که شبکه‌های عصبی پرسپترون

۳. بحث و بررسی نتایج

۱-۳. مدل‌های رگرسیونی

پس انجام رگرسیون ساده بر روی داده‌ها، روابطی برای تخمین مقدار C_c ، براساس حدروانی، نسبت پوکی در حدروانی، شاخص خمیری، نسبت پوکی تحت سربار ۱۰۰ کیلوپاسگال، حدخمیری و نسبت پوکی در حدخمیری بدست آورده شد. در مدل‌های ۱ تا ۶ مقدار $\text{Sig. (p-value)} < 0/05$ و در مدل ۷ و ۸ مقدار $\text{Sig. (p-value)} > 0/05$ است با توجه به روابط ۳ تا ۵ مدل‌های ۱ تا ۶ معنادار می‌باشند و مدل ۷ و ۸ معنادار نمی‌باشند. بنابراین روابط معناداری بین مقدار C_c با وزن مخصوص و درصد ذرات ریزدانه یافت نشد. در بین

روابط ارائه شده بیشترین همبستگی بین مقدار C_c و حدروانی وجود داشت.

رگرسیون خطی چند متغیره با دو دسته داده ورودی بر روی داده‌ها انجام گرفت. در مدل ۹ داده‌های ورودی مدل شامل C_c ، PL، LL و PI و در مدل ۱۰ داده‌های ورودی شامل C_c ، e_i ، e_p و e_{100} بود. دو مدل برای پیش‌بینی مقدار C_c بدست آورده شد (جدول ۴). با توجه به مقدار $\text{Sig. (p-value)} < 0/05$ بدست آمده از آزمون فیشر، هر دو مدل معنادار می‌باشند، در مدل ۹ مقدار p-value مربوط به حدروانی و در مدل ۱۰ مقدار p-value مربوط به نسبت پوکی در حد خمیری بیشتر از ۰/۰۵ است بنابراین پارامترهای مذکور از مدل‌های ۹ و ۱۰ کنار گذاشته شد.

جدول ۴: مدل‌های رگرسیون ساده و خطی چند متغیره پیشنهادی برای تخمین مقدار C_c

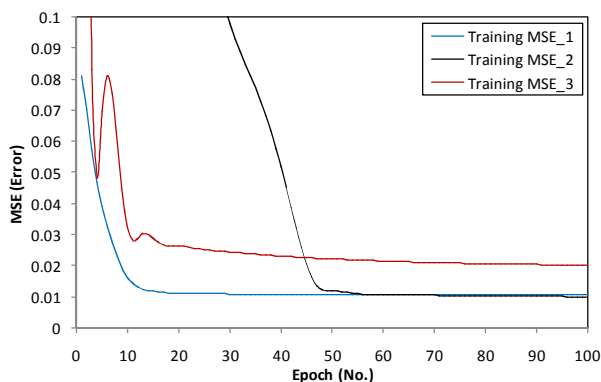
مدل	معناداری مدل Sig.(p-value)	β_0	ضرایب	Sig.(p-value)	رابطه	R ²
مدل ۱	۰/۰۰۰	Costant LL	-۰/۰۶۰۲ ۰/۰۰۷۵	۰/۰۰۱ ۰/۰۰۰	$C_c = 0/0075LL - 0/0602$	۰/۸۸۱
مدل ۲	۰/۰۰۰	Costant e_i	-۰/۰۵۲ ۰/۲۷۵	۰/۰۰۸ ۰/۰۰۰	$C_c = 0/275 e_i - 0/052$	۰/۸۶۹
مدل ۳	۰/۰۰۰	Costant PI	۰/۰۸۲۵ ۰/۰۰۹۳	۰/۰۰۰ ۰/۰۰۰	$C_c = 0/0093PI + 0/0825$	۰/۸۲۲
مدل ۴	۰/۰۰۰	Power e_{100}	۱/۳۲۲ ۰/۳۳۵	۰/۰۰۱ ۰/۰۰۲	$C_c = 0/335 (e_{100})^{1/322}$	۰/۷۲۷
مدل ۵	۰/۰۰۰	Power PL	۱/۲۱۴ ۰/۰۰۶۸	۰/۰۰۰ ۰/۰۰۰	$C_c = 0/0068 (PL)^{1/214}$	۰/۵۶۲
مدل ۶	۰/۰۰۰	Power e_p	۱/۹۲۱ ۰/۵۵۰	۰/۰۰۷ ۰/۰۰۳	$C_c = 0/55 (e_p)^{1/921}$	۰/۵۳۶
مدل ۷	۰/۸۳۳	Costant G_s	۰/۵۷۹ -۰/۰۵۷	۰/۴۲۸ ۰/۸۳۳	رابطه معناداری وجود ندارد	۰/۰۰۰
مدل ۸	۰/۰۶۰	Costant CF	۰/۱۶۲ ۰/۰۰۴	۰/۰۵۳ ۰/۰۶۰	رابطه معناداری وجود ندارد	۰/۰۸۰
مدل ۹	۰/۰۰۰	Costant PL PI LL	۰/۰۰۷ ۰/۰۰۸ ۰/۰۰۷	۰/۰۰۰ ۰/۰۰۰ ۰/۴۶۱	$C_c = 0/007PL + 0/008PI - 0/054$	۰/۸۸۱
مدل ۱۰	۰/۰۰۰	Costant e_i e_{100} e_p	-۰/۰۸۳ ۰/۲۴ ۰/۰۸۳ -۰/۰۴۳	۰/۰۰۰ ۰/۰۰۰ ۰/۰۱۰ ۰/۳۶۴	$C_c = 0/24 e_i + 0/083 e_{100} - 0/083$	۰/۸۷۷

۲-۳. نتایج شبکه عصبی

از ۱۱۵ داده، در مرحله آموزش تعداد ۸۰ نمونه وارد شده و بقیه بعنوان مجموعه آزمایش مورد استفاده قرار گرفت. فرآیند آموزش و یادگیری بعد از این که حلقه تکرار دوره‌های آموزش به ۱۰۰۰ دور با مقدار خطای ۰/۰۰۵۲ رسید متوقف شده است. شکل ۴ خطای شبکه (MSE) و تعداد دوره‌های آموزش (Epoch) در مدل ساخته شده را نشان می‌دهد. همچنین شکل ۵ مراحل ابتدایی محاسبه خطا را نشان می‌دهد، که مشاهده می‌شود بعد از مرحله ۶۰، تغییرات خطا کمتر شده و مقدار پارامتر هدف (C_c) با مقدار پیش‌بینی شده بهم نزدیک شده است. جهت محاسبه خطا در شکل ۴ و ۵ از رابطه ۱۲ استفاده شده است. همچنین جزئیات نتایج آماری مدل ساخته شده در جدول ۵ نشان داده شده است.

$$MSE = \frac{1}{N} \sum_{i=1}^N (C_{ci_measured} - C_{ci_estimated})^2 \quad (12)$$

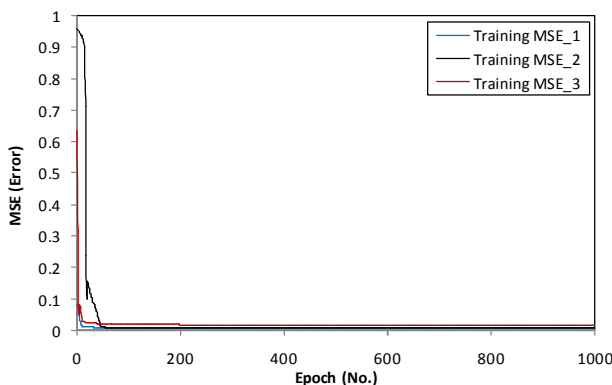
N تعداد کل داده‌ها و C_c نیز شاخص قابلیت فشرده‌گی می‌باشد.



شکل ۵. محاسبه مربعات متوسط خط با بزرگنمایی زیاد

جدول ۵. نتایج آماری مدل

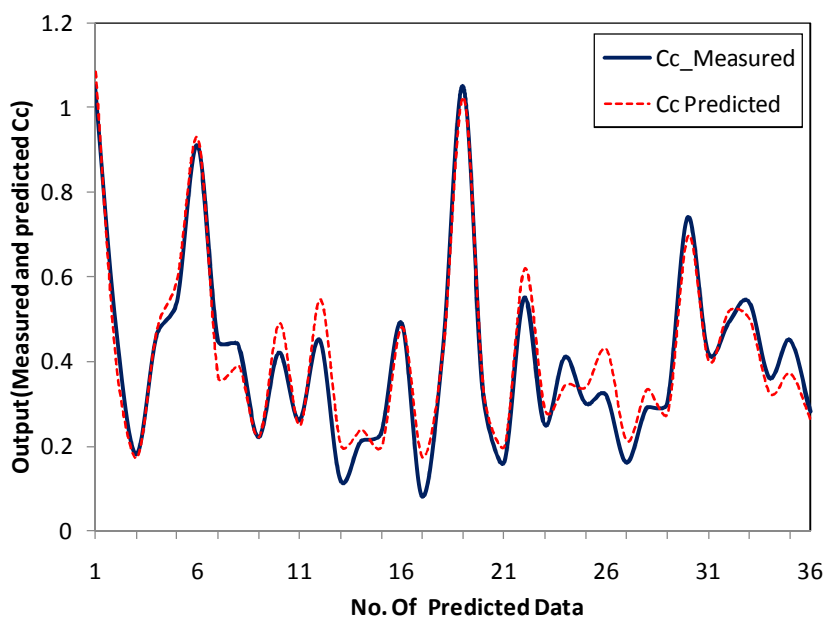
Parameter	Value
MSE	۰/۰۰۵۲۷
NMSE	۰/۱۰۲۱۱
MAE	۰/۰۵۴۷۷
Min Abs Error	۰/۰۰۰۰۷
Max Abs Error	۰/۲۳۲۶۹
R	۰/۹۷۳۶۵
R ²	۰/۹۴۸۰۰



شکل ۴. محاسبه مربعات متوسط خطا

در چند مرحله سعی و خطا مدل‌های دیگری با استفاده از توابع مختلف ساخته شده و دقت نهایی پارامتر C_c پیش‌بینی

شده و همچنین خطای مدل ساخته شده مورد ارزیابی قرار گرفت. بدین صورت که نتایج پیش‌بینی شده حاصل از هر مدل با مقدار پارامتر هدف مقایسه شده و درصد خطای آن تعیین گردید. در مراحل بعد فرایند سعی و خطا منتهی به تولید مدلی شده که خطای آن پایین بوده و دقت زیادی در پیش بینی پارامتر C_c دارد. پس از مراحل آموزش و آزمون شبکه، نتایج تجزیه و تحلیل شده و دقت محاسبه و کارایی شبکه مورد ارزیابی قرار گرفته است. بدین ترتیب که مقادیر هدف که در آزمایش بدست آمده و مقادیر حاصل از پیش‌بینی بر روی یک نمودار رسم گردید (شکل ۶). همچنین جدول ۶ برخی از پارامترهای ورودی و خروجی مدل ساخته شده را نشان می‌دهد.



شکل ۶. کارایی شبکه (نتایج مدل در مرحله آزمون)

جدول ۶. تعدادی از پارامترهای ورودی و خروجی شبکه

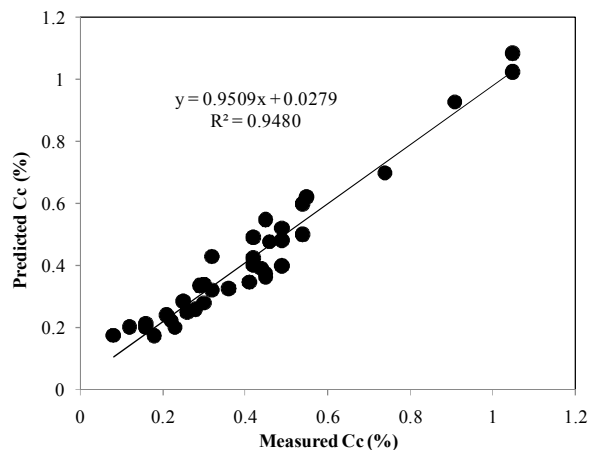
PI (%)	Gs	CF (%)	eL	eP	Cc Measured	Cc Predicted
113	2.83	50	4.50	1.30	1.05	1.08
35	2.75	75	1.73	0.77	0.49	0.40
14	2.59	25	0.70	0.34	0.18	0.17
46	2.67	53	2.00	0.77	0.46	0.48
58	2.74	78	2.38	0.79	0.54	0.60
91	2.77	77	3.52	1.00	0.91	0.93
27	2.78	86	1.56	0.81	0.45	0.36
25	2.67	60	1.28	0.61	0.44	0.39
21	2.68	42	1.02	0.46	0.22	0.22
22	2.58	68	1.88	1.34	0.42	0.49
22	2.6	48	1.07	0.49	0.26	0.25
41	2.59	73	2.07	1.01	0.45	0.55
14	2.69	69	0.75	0.38	0.12	0.20
16	2.78	65	1.08	0.64	0.21	0.24
10	2.72	75	0.73	0.46	0.23	0.20
49	2.71	46	2.09	0.76	0.49	0.48
13	2.71	55	0.65	0.30	0.08	0.17
41	2.77	58	1.91	0.78	0.42	0.42
72	2.63	91	3.58	1.68	1.05	1.02
32	2.85	42	1.65	0.74	0.32	0.32
16	2.67	35	0.91	0.48	0.16	0.20
56	2.61	80	2.30	0.84	0.55	0.62
14	2.65	82	1.56	1.20	0.25	0.28
34	2.59	56	1.45	0.57	0.41	0.34
24	2.64	62	1.45	0.83	0.30	0.34
37	2.66	68	1.78	0.80	0.32	0.43
16	2.72	65	0.87	0.44	0.16	0.21
35	2.73	32	1.64	0.68	0.29	0.33
27	2.72	46	1.33	0.60	0.30	0.28
53	2.75	60	2.17	0.72	0.74	0.70
38	2.68	41	1.80	0.78	0.42	0.40
46	2.67	80	2.06	0.83	0.49	0.52
45	2.53	87	1.82	0.68	0.54	0.50
31	2.74	35	1.59	0.74	0.36	0.32
38	2.73	55	1.69	0.66	0.45	0.37
26	2.72	43	1.25	0.54	0.28	0.26

بنابراین مدل شبکه عصبی از این مشکلات مستثنی است و پاسخ قابل اعتمادتری می‌دهد. با توجه به احتمال وجود برخی از پارامترهای مبهم و شناخته نشده در پیش بینی و تخمین شاخص قابلیت فشردگی، شبکه‌های عصبی در صورتی که با توابع و پارامترهای مناسب مورد تعلیم قرار گیرد می‌تواند پیش بینی و تخمین مناسبی انجام دهد. برای این منظور در این تحقیق در مراحل اولیه به دلیل بالا بودن خطا، شبکه با تغییراتی در پارامترهای ورودی و همچنین تغییر در لایه‌های ورودی و پنهان، دوباره ساخته شده و محاسبات انجام گردید. در نهایت با عمل سعی و خطا، شبکه بهینه طراحی شده و پیش‌بینی شاخص قابلیت فشردگی خاک انجام گردید. طبق نتایج بدست آمده، شبکه عصبی جهت پیش‌بینی قابلیت فشردگی خاک توانسته تا همبستگی ۹۴ درصد رابطه‌ای بین داده‌های تجربی و عددی برقرار کند و اصطلاحاً پیش‌بینی مناسبی انجام دهد.

۵. نتیجه‌گیری

هدف این مقاله ارائه مدلی برای برای پیش‌بینی شاخص قابلیت فشردگی خاک‌های ریزدانه با استفاده از خصوصیات شاخص خاک می‌باشد. ۱۱۵ نمونه از ۸ سایت از نقاط مختلف کشور جمع‌آوری گردید. ابتدا براساس انجام رگرسیون ساده و خطی چند متغیره روابطی برای پیش‌بینی مقدار شاخص قابلیت فشردگی ارائه شد. از بین روابط ارائه شده بر اساس رگرسیون ساده، بیشترین همبستگی بین شاخص قابلیت فشردگی و حد روانی با ضریب همبستگی ۰/۸۸۱ وجود داشت و روابط معناداری بین مقدار C_c با وزن مخصوص و درصد ذرات ریزدانه یافت نشد. از بین روابط ارائه شده بر اساس رگرسیون خطی چند متغیره بیشترین همبستگی بین شاخص قابلیت فشردگی خاک با حد خمیری و شاخص خمیری، به ضریب همبستگی ۰/۸۸۱، وجود داشت. در این مطالعه برای غلبه بر محدودیت‌های فرمول‌های تجربی بدست آمده از تحلیل رگرسیونی از شبکه عصبی برای

در ادامه مقادیر شاخص قابلیت فشردگی بدست آمده از آزمایش و مقادیر پیش بینی شده توسط شبکه بر روی نموداری نشان داده شده و همبستگی بین این نتایج بدست آمده است (شکل ۷). همبستگی بدست آمده نشان دهنده قابلیت مناسب پیش بینی به وسیله شبکه‌های عصبی مصنوعی می‌باشد.



شکل ۷. همبستگی بین نتایج تجربی و پیش‌بینی

در مرحله آزمون

۴. مقایسه مدل‌ها

در بین مدل‌های رگرسیونی ساده بیشترین همبستگی بین شاخص قابلیت فشردگی و حد روانی، و در بین مدل‌های رگرسیونی خطی چند متغیره بیشترین همبستگی بین شاخص قابلیت فشردگی با حد خمیری و شاخص خمیری وجود داشت. نقد اصلی مدل‌های تجربی این است که این مدل‌ها پیچیدگی‌های مکانیزم تحکیم را بسیار ساده در نظر می‌گیرد و پارامترهای متنوع خاک که در تحکیم تاثیرگذارند را در نظر نمی‌گیرد. وقتی از متغیرهای چندگانه برای بهبود قابلیت پیش‌بینی شاخص قابلیت فشردگی استفاده می‌شود، متغیرهایی که در فرمول‌های رگرسیونی به کار می‌رود منجر به ایجاد مشکل هم خطی بین متغیرهای مستقل (*multicollinearity*) می‌شود، از اینرو فرمولی که پیچیدگی‌های بین شاخص قابلیت فشردگی و پارامترهای وابسته را حل کند مورد نیاز است.

متغیرهای کنترل ذکر شده، استفاده از این روابط در برآورد اولیه از پارامتر شاخص قابلیت فشردگی مناسب به نظر می‌رسد.

تشکر و قدردانی:

بدین وسیله از آقای مهندس جواد شریفی و شرکت مهندسی مشاور راه و پل هامون، به جهت همکاری صمیمانه در ارائه داده‌های مورد نیاز تشکر و قدردانی می‌گردد.

پیش‌بینی شاخص قابلیت فشردگی استفاده شد. شبکه عصبی مقادیری با همبستگی بالاتر حدود ۹۴ درصد را نشان داد. نتایج این مطالعه نشان داد که مدل شبکه عصبی نسبت به مدل‌های رگرسیون ساده و خطی چندمتغیره نتایج دقیق‌تری برای پیش‌بینی شاخص قابلیت فشردگی خاک‌های ریزدانه می‌دهد. در ضمن مشکل هم خطی بین متغیرهای مستقل در روش شبکه عصبی مطرح نمی‌باشد. اما با توجه به در دسترس بودن و ساده بودن استفاده از مدل‌های رگرسیونی و ضریب همبستگی بالای بدست آمده بین شاخص قابلیت فشردگی و

منابع

- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی مرکز پیش دانشگاهی راه زینب زابل، آبان ۱۳۸۹.
- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی مرحوم سارانی زاهدان، تیر ۱۳۸۷.
- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی دبستان بعثت فردانیه چهارمحال و بختیاری، تیر ۱۳۸۷.
- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی مدرسه فدک شاهرود، شهریور ۱۳۸۷.
- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی دبستان خانم بیهان شیرازی قم، تیر ۱۳۸۹.
- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی مدرسه انبیاء قم، تیر ۱۳۸۹.
- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی مدرسه راهنمایی شاهد تنکابن، خرداد ۱۳۸۸.
- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی هنرستان کارودانش شهیدان کارگران فریدونکنار، خرداد ۱۳۸۸.
- شرکت مهندسی مشاور راه و پل هامون، گزارش مطالعات ژئوتکنیکی مدرسه راهنمایی شبانه‌روزی سمائیان آبیک، مهر ۱۳۹۰.
- شریفی، ج.، نیکودل، م.ر.، ایزدی، ه.، ۱۳۹۰. مدل سازی اعداد چکش اشmitt با استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی دقیق‌تر مقاومت بتن، مجموعه مقالات ششمین کنگره ملی مهندسی عمران، دانشگاه سمنان، ۶ تا ۷ اردیبهشت، ۱۱۱-۱۱۹.
- شریفی، ج.، نیکودل، م.ر.، پیش‌بینی مقاومت بتن حاوی سنگدانه‌های مختلف با استفاده از آزمون‌های غیرمخرب از طریق مدل‌سازی در شبکه‌های عصبی مصنوعی، دوره ۹، شماره ۳، پاییز ۱۳۹۴، صفحه ۱-۲.
- منهاج، م.ب.، ۱۳۷۹. هوش محاسباتی، جلد اول: مبانی شبکه‌های عصبی، ویرایش اول، انتشارات دانشگاه صنعتی امیرکبیر، تهران.
- Azzouz, A.S., Krizek, R.J., Corotis, R.B., 1976. Regression analysis of soil compressibility. *Soils Found* 16(2), 19-29
- Carter, M., Bentley, S.P., 1991. *Correlation soft Soil Properties*. Pentech Press, London.
- Cozzolino, V.M., 1961. Statistical forecasting of compression index. In: *Proceedings of the Fifth International Conference on Soil Mechanics and Foundation Engineering, Paris, vol.1, pp.51-53*.
- Gregory, A.S., Whalley, W.R., Watts, C.W., Hallett, P.D., Whitmore, A.P., Bird, N.R., 2006. Calculation of the compression index and precompression stress from soil compression test data. *Soil Tillage Res.* 89, 45-57.
- Gulhati, S.K., Datta, M., 2005. *Geotechnical Engineering*. Tata McGraw Hill Publishing Company Limited, New Delhi.
- Haykin, S., (1999), "Neural Networks a Comprehensive Foundation", Prentice Hall, 2nd Edition
- Herrero, O. R., 1983. Universal compression index equation; closure. *J. Geotech. Eng. Div. ASCE* 109 (5), 755-761.
- Hong-Guang, N., Ji-Zong W., (2000), "Prediction of compressive strength of concrete by neural networks", *Cement and Concrete Research* 30, 1245- 1250

- Koppula, S.D., 1981. Statistical estimation of compression index. *Geotech. Test. J.* 4 (2), 68–73.
- Mayne, P.W., 1980. Cam-clay predictions of undrained strength. *J. Geotech. Eng. Div. ASCE* 106(11), 1219–1242.
- Mohammadzadeh S, D., Bolouri Bazaz, J., Alavi, A., 2014. An evolutionary computational approach for formulation of compression index of fine-grained soils, *Engineering Applications of Artificial Intelligence*, 33(1), 58-68.
- Miguel Rocha, P.C., and Neves, J., Manicom-Ramsamy, J., 2007- Evolution of neural networks for classification and regression, *Neurocomputing*, 70p.
- Nagaraj, T.S., Murty, B.R.S., 1985. Prediction of the preconsolidation pressure and recompression index of soils. *Geotech. Test. J.* 8(4), 199–202.
- Nishida, Y., 1956. A brief note on compression index of soils. *J. Soil Mech. Found. Div., ASCE* 82 (SM3) (1027-1-1027-14).
- Park, H., Lee, S.R., 2011. Evaluation of the compression index of soils using an artificial neural network. *Comput. Geotech.* 38, 472–481.
- Rani, C.H.S., Kumar, V.P., Togati, V.K., 2013. Artificial neural networks (ANNS) for prediction of engineering properties of soils. *Int. J. Innov. Technol. Explor. Eng. (IJITEE)* 3(1), 123–130.
- Singh, A., Noor, S., 2012. Soil compression index prediction model for fine grained soils. *Int. J. Innov. Eng. Technol. (IJJET)* 1 (4), 34–37.
- Skempton, A.W., 1944. Notes on the compressibility of clays. *Quart. J. Geol. Soc. Lond.* 100, 119–135
- Sower, G.B., 1970. *Introductory Soil Mechanics and Foundation*, 3rd ed. The Macmillan Company of Collier-Macmillan Ltd, London.
- Terzaghi, K., Peck, R.B., 1967. *Soil Mechanics in Engineering Practice*. John Wiley & Sons Inc., New York.
- Tiwari, B.T., Ajmera, B., 2012. New correlation equations for compression index of remolded clays. *J. Geotech. Geoenviron. Eng.* 138(6), 757–762.
- Wroth, C.P., Wood, D.M., 1978. The correlation of index properties with some basic engineering properties of soils. *Can. Geotech. J.* 15, 137–145.