یازدهمین کنگره ملی سراسری
فناوریهای نوین در حوزه توسعه پایدار ایران
11th National Congress of
the New Technologies in Sustainable Development of Iran
senaconf.ir

ارزیابی هوشمند مشخصات مکانیکی خاک های آلوده با استفاده از یادگیری عمیق

مریم کاظم زاده[۱]، احمد حسن زاده[۲]، علی بیگلری*[۳].

[۱]دانشجوی کارشناسی، دانشکده فنی مهندسی گرگان، دانشگاه گلستان

[2]دانش آموخته کارشناسی ارشد، دانشکده فنی مهندسی گرگان، دانشگاه گلستان

[۳]*استادیار گروه مهندسی عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان، Biglari.a@gmail.com

چکیده

آلودگی خاک به عنوان بخشی از تخریب زمین ناشی از وجود مواد شیمیایی ساخته دست بشر است. رایج ترین مواد شیمیایی شامل هیدروکربن های نفتی، مواد شیمیایی در صنایع مختلف، فلزات سنگین، ضایعات صنعتی و شهری و همچنین مواد پایدار ساز است. آلودگی با میزان صنعتی شدن و شدت ماده شیمیایی ارتباط مستقیمی دارد. علاوه بر خطرات سلامتی ناشی از این آلودگی، تاثیرات آلودگی ها بر خصوصیات مکانیکی خاک از موضوعات با اهمیت در حوزه مهندسی می باشد. براورد دقیق خواص ژئوتکنیکی خاک ها یک موضوع قابل توجه در مهندسی ژئوتکنیک به ویژه در حضور آلودگی های مختلف می باشد. اصلاح این خواص ژئوتکنیکی که در معرض اشکال مختلف آلودگی قرار گرفته اند از دیگر موضوعات با اهمیت در حوزه ژئوتکنیک می باشد. پیش بینی مشخصه های مکانیکی خاک، خاک های آلوده شده و یا خاک های بهسازی شده در کوتاهترین زمان ممکن از اهمیت ویژه ای برخوردار است. یکی از ابزار های موثر در این حوزه، هوش مصنوعی می باشد. در این پژوهش قابلیت شبکه های عصبی مبتنی بر یادگیری عمیق در ارزیابی خصوصیات مکانیکی خاک مورد بررسی قرار می گیرد.

کلید واژه ها: آلودگی، خصوصیات رفتارمکانیکی خاک، هوش مصنوعی، یادگیری عمیق.

مقدمه

توسعه اقتصادی، رشد چشم گیر جمعیت، افزایش رفاه نسبی و گسترش تکنولوژی در جوامع بشری منجر به افزایش میزان تولید ضایعات شهری و صنعتی گردیده است. طبق گزارش منتشر شده در سال ۲۰۱۲، در شهرهای جهان تنها حدود ۱/۳ میلیارد تن ضایعات شهری در سال تولید می‌شود که انتظار می‌رود این مقدار تا سال ۲۰۲۵ به ۲/۲ میلیارد تن افزایش یابد. لذا این حجم بالا از تولید ضایعات، منجر به توسعه سریع فن‌آوری‌های مرتبط با مدیریت ضایعات گشته است. با وجود آنکه چگونگی روش دفع ضایعات با توجه به سطح در آمد کشورها متفاوت است، اطلاعات مختلف بدست آمده نشان می‌دهد که به صورت تقریبی ۷۰ میلیون تن ضایعات در سال انباشته می‌گردند و ۳۴۰ میلیون تن

در سال در مراکز دفن ضایعات شهری مدفون می‌گردند(هورنوگ و بدا تاتا، ۲۰۱۲). روش دفن در مدیریت ضایعات به دلیل کم هزینه بودن در بسیاری از کشورها به طور گسترده استفاده می‌گردد (الفادل و همکاران، ۱۹۹۷)، که این موضوع نشان دهنده اهمیت بررسی اثرات این روش بر روی محیط اطراف محل دفن می‌باشد (جیانگوئو و همکاران، ۲۰۱۰) (حسن زاده، ۲۰۱۸).

درک و پیش بینی خواص مکانیکی خاک ها در حوزه مهندسی از اهمیت حیاتی برخوردار است. اصلاح خواص مکانیکی خاک ها آلوده و یا آلوده نشده با بکارگیری مواد شیمیایی و یا زیستی از موضوعات حوزه مهندسی ژئوتکنیک می باشد. خصوصیات مکانیکی خاک ها می تواند به شدت تحت تاثیر این آلودگی ها قرار گیرد.

براورد دقیق خواص ژئوتکنیکی خاک ها یک موضوع قابل توجه در مهندسی ژئوتکنیک به ویژه در حضور آلودگی های مختلف می باشد. اصلاح این خواص ژئوتکنیکی که در معرض اشکال مختلف آلودگی قرار گرفته اند از دیگر موضوعات با اهمیت در حوزه ژئوتکنیک می باشد. این خصوصیات با اهمیت بصورت طبقه بندی شده در شکل ۱ نمایش داده شده است.

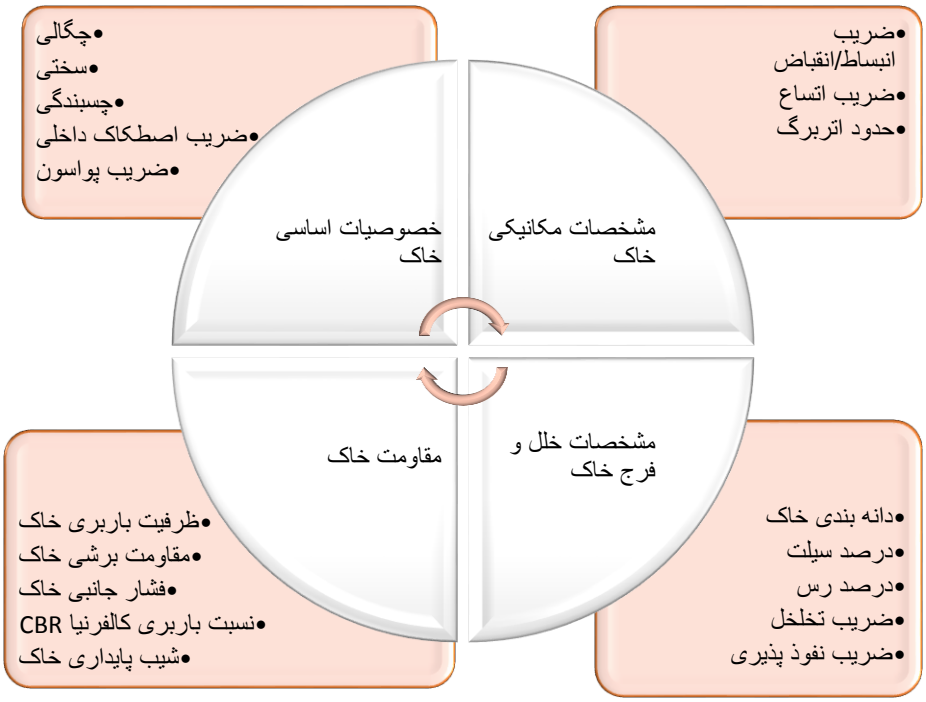

شکل 1. مشخصات طبقه بندی شده تعریف کننده خصوصیات خاک بمنظور ارزیابی رفتار خاک.

انباشت منابع مختلف ضایعات، مدت زمان، نوع آلودگی ها، و واکنشی که به سیستم آلوده کننده خاک رخ می دهد، بر خواص مکانیکی خاک تأثیر می گذارد. شیرابه ضایعات آلی، کودها و آلودگی های نفتی بحرانی ترین و جدی ترین آلاینده های موثر بر خواص مکانیکی خاک است که در شکل ۲ بصورت طبقه بندی ارایه شده اند. اصلاح خواص مکانیکی خاک ها به دلیل برهم کنش فیزیکی و یا فیزیکی-شیمیایی بین خاک و آلودگی نیز از دیگر مواردی می باشد که خصوصیات مکانیکی خاک ها را تحت تاثیر قرار می دهد و از موضوعات مورد توجه پژوهشگران می باشد.

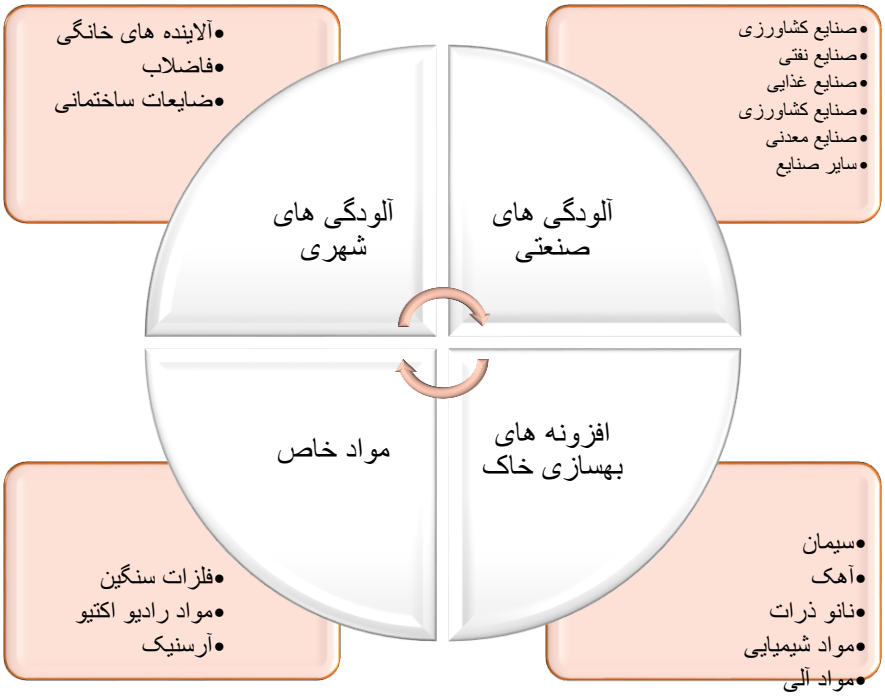

شکل 2. مواد شیمیایی موثر بر خصوصیات فیزیکی و مکانیکی خاک

آلودگی های با منشا گوناگون بر مشخصات فیزیکی و رفتاری خاک تاثیر گذار می باشند. اگرچه تحقیقات متعددی بر روی تاثیر این مواد شیمیایی گوناگون بر روی مشخصات مکانیکی خاک بمنظور ارزیابی و یا به جهت بهسازی خاک صورت گرفته است، اما بررسی کاربرد هوش مصنوعی در این حوزه بسیار محدود می باشد. در این مقاله ارزیابی تنش انحرافی حداکثری در نمونه های آلوده به مواد آلی با بکارگیری سیستم های هوشمند مبتنی بر آموزش عمیق مورد بررسی قرار می گیرد.

خاک

خاک مورد مطالعه از یکی از مرکز دفن ضایعات شهری تهیه گردید. پس از انجام آزمایشات اولیه طبق سیستم طبقه‌بندی متحد، خاک از نوع سیلتی-رسی با خاصیت خمیری کم بوده (CL-ML) و منحنی دانه‌بندی خاک در شکل ۳ قابل مشاهده است. تصاویر مربوط به مرکز دفن در شکل ۴ ارائه شده است.

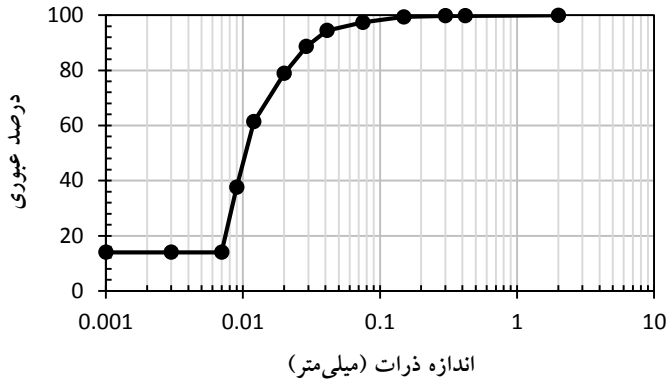

شکل 3. منحنی دانه‌بندی خاک مورد مطالعه

شکل 4. تصاویر مربوط به مرکز دفن ضایعات شهری، الف. تصویر هوایی مرکز دفن، ب و پ. محل دفن ضایعات.

مشخصات فیزیکی خاک مورد استفاده در آزمایش‌ها طبق روش‌های موجود در استاندارد ASTM اندازه‌گیری و در جدول۱ ارائه شده است.

جدول 1. مشخصات فیزیکی خاک مورد مطالعه

عنوان	مقدار
چگالی ویژه خاک	۲/۵٦
تراکم خشک حداکثر (γ_{dmax})	۱۸/۷٤ KN/m^3
میزان رطوبت بهینه (O.M.C)	۱۳/٤٪
ماسه	۲/٦۱٪
سیلت	۸۳/۳۷٪
رس	۱٤/۰۲٪
حد روانی (LL)	۲٤/۱۵٪
حد خمیری (PL)	۱۹٪
شاخص خمیری (PI)	٦/۱۵٪
طبقه‌بندی خاک	CL-ML

شبکه های عصبی

مفهوم شبکه های عصبی بمنظور اولین بار در سال ۱۹۴۳ توسط وارن مک کالچ مطرح شد. او یک متخصص مغز و اعصاب بود که مطالعه می کرد که چگونه مغز می تواند با استفاده از بسیاری از سلول های اساسی که به هم متصل شده اند، الگوهای بسیار پیچیده تولید کند. به این سلول های مغزی به عنوان نورون اشاره شد. مغز انسان از حدود ۱۰۰ میلیارد از این نورون ها تشکیل شده است. هر نورون از بدن سلولی، دندریت ها و آکسون تشکیل شده است. دندریت ها طرح هایی شبیه انگشت هستند که سیگنال های عصبی را دریافت کرده و به بدن سلول منتقل می کنند. سپس سیگنال عصبی به آکسون منتقل می شود و در آنجا سیگنال را به سلول عصبی دیگر ارسال می کند. هر نورونک با حداکثر ۲۰۰،۰۰۰ نورون دیگر ارتباط دارد. برخلاف بسیاری از سلولهای دیگر بدن، مغز مغز بازسازی نمی شود. تصور می شود که به همین دلیل است که ما می توانیم اطلاعاتی را که یاد گرفته ایم فکر کنیم، به خاطر بسپاریم و به کار گیریم (فاوست، ۱۹۹۴). این مفهوم است که بمنظور توسعه شبکه عصبی مصنوعی استفاده شد. شبکه عصبی مصنوعی (ANN) یک سیستم ریاضی پیچیده است که از بسیاری عناصر به هم پیوسته تشکیل شده است. نورون هایی که مورد استفاده قرار می گیرند رفتار مغز انسان را تقلید می کنند (ناجر و همکاران، ۱۹۹۸). ANN ها قادر به تشخیص روابط بین رویدادهای ورودی و خروجی هستند. مانند مغز، این برنامه با مثال و از تجربه قبلی یاد می گیرد. داده ها بمنظور "آموزش" برنامه وارد برنامه می شوند. پس از آموزش برنامه، می توان از آن بمنظور پیش بینی برخی نتایج استفاده کرد. این توانایی بمنظور پیش بینی یا شبیه سازی یک موقعیت خاص منجر به افزایش استفاده از شبکه های عصبی در زمینه های علم و مهندسی شده است. ساختار شبکه های عصبی در شکل ۵ نشان داده شده است.

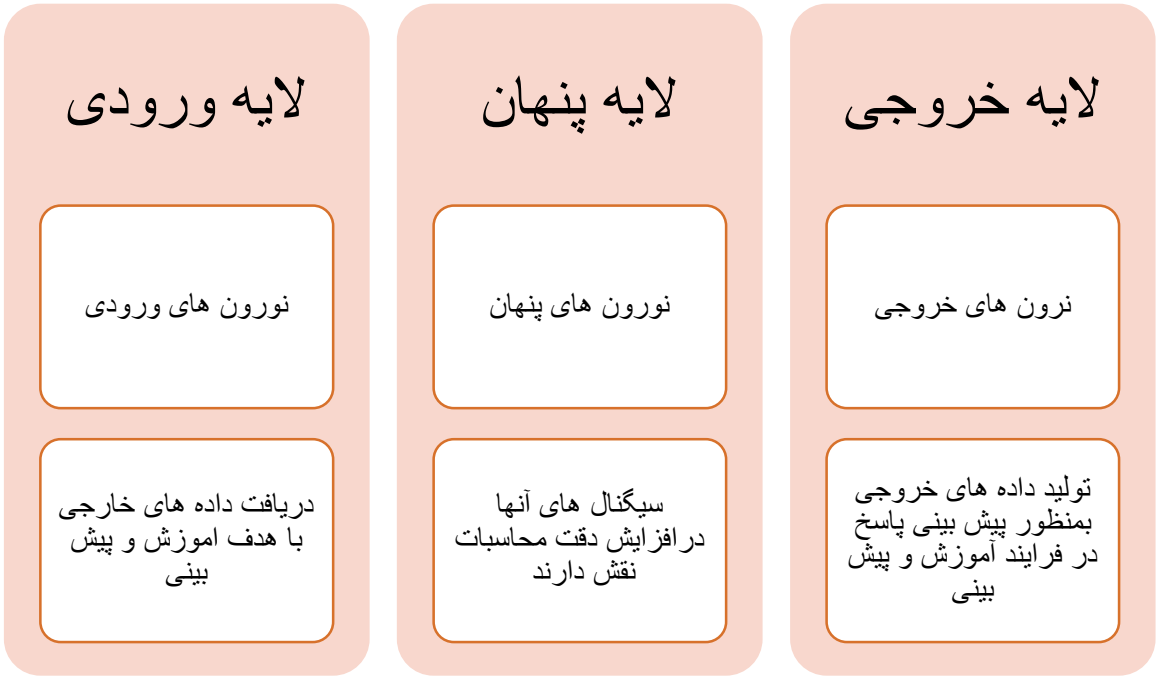

شکل 5. ساختار شبکه های عصبی

تعداد نرون ها در لایه ورودی بر اساس داده های موثر بر اساس فرضیه پژوهش انتخاب می گردد. پس از تعیین ورودی ها، داده های مربوط به آن ورودی ها وارد لایه پنهان می شوند. لایه های پنهان بسیار پیچیده تر هستند. در این لایه است که تمام محاسبات انجام می شود. تعداد لایه های پنهان متفاوت است اما همیشه حداقل یک لایه مخفی در هر شبکه وجود دارد. هر لایه از مجموعه ای از نورون ها تشکیل شده است. هر لایه به هم متصل است به نحوی که لایه اول اطلاعات را به لایه دوم، لایه دوم به لایه سوم و غیره منتقل می کند. این کار از طریق وزن اتصال انجام می شود. وزن های اتصال هر نورون را در یک لایه خاص به تک تک نورون های لایه بعدی متصل می کند. مقدار آن وزن بمنظور تنظیم مقدار خروجی نورون مسئول نیست(ایتانی و نجار، ۱۹۹۶و ۲۰۰۰).

پارامترهای مناسب مدل هستند. هدف بدست آوردن آمپلی از بردار ورودی به خروجی است. مطلوب است که تفاوت بین مقادیر پیش بینی شده و مشاهده شده (واقعی) در بردار خروجی تا حد ممکن کوچک باشد (هوانگ و همکاران ۱۹۹۸). پارامترهای برازش تا زمانی که معیار خطا بین ورودی و خروجی بر اساس توپولوژی ANN و تکنیک یادگیری برآورده نشود، اصلاح می شود. تنظیم وزن ها به عنوان فرایند یادگیری تعریف می شود. ANN توسعه یافته با مقادیر ورودی/خروجی که در آموزش استفاده نمی شود آزمایش می شود. پس از آموزش و آزمایش، کار بعدی آماده انجام وظایفی مانند تشخیص الگو، طبقه بندی یا تقریب عملکرد است. آخرین لایه، لایه خروجی است. لایه خروجی اطلاعات را از آخرین لایه های مخفی دریافت می کند و حاوی مقادیر پیش بینی شده محاسبه شده است. فرایند بهینه سازی لایه های پنهان

تا زمانی که معیار خطا بین ورودی و خروجی بر اساس توپولوژی ANN و تکنیک یادگیری ارضا شود، ادامه خواهد یافت. تنظیم وزنه ها به عنوان فرایند یادگیری تعریف می شود. ANN توسعه یافته مورد آزمایش قرار گرفته است با مقادیر ورودی/خروجی که در آموزش استفاده نمی شود. پس از آموزش و آزمایش ، شبکه آماده انجام وظایفی مانند تشخیص الگو ، طبقه بندی یا عملکرد است آخرین لایه ، لایه خروجی است. لایه خروجی اطلاعات را ازآخرین لایه های مخفی و شامل مقادیر پیش بینی شده محاسبه شده است.

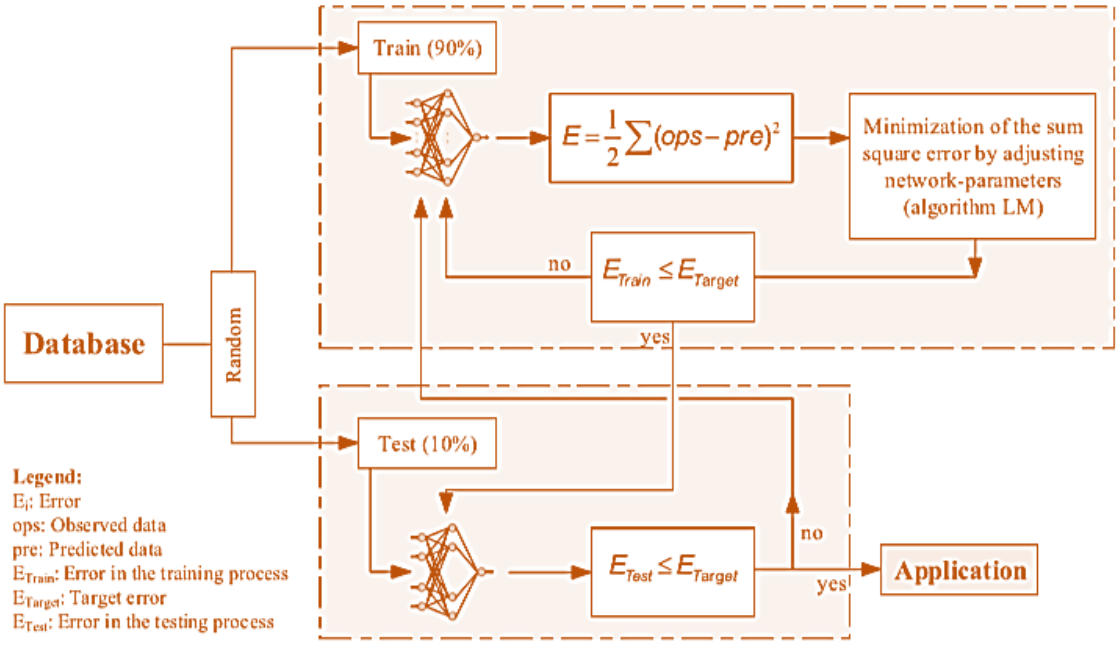

شکل 6. فرایند آموزش و آزمایش شبکه عصبی مصنوعی (Marquardt and Zenner 2015)

آموزش شبکه در این تحقیق

مراحل آموزش روش توسعه یافته، با استفاده از مدل شبکه های عصبی با یاد گیری عمیق از نرم افزار MATLAB به شرح زیر خلاصه می‌شود:

- خواندن و طبقه بندی داده های آموزش و همچنین تعیین متغیرهای ورودی و خروجی شبکه های عصبی با یاد گیری عمیق
- عادی سازی داده های آموزش مطابق با الگوریتم انتخاب شده
- تعیین ساختار شبکه با تعیین تعداد لایه های پنهان و تعداد نورون ها در لایه های ورودی، پنهان و خروجی
- تعیین توابع فعال سازی برای لایه های پنهان و خروجی (برای این لایه ها معمولاً از توابع سیگموئید و خطی استفاده می‌شود)
- تعیین الگوریتم آموزش با استفاده از الگوریتم لونبرگ-مارکات

- تعیین پارامترهای آموزشی مورد نیاز برای بهینه سازی مقادیر میانگین مربعات خطا(MSE) و دامنه حداکثر تعداد تکرارها
- آموزش شبکه های عصبی با یاد گیری عمیق مطابق تعاریف در مراحل فوق
- محاسبه متغیرهای عادی هدفمند و تبدیل آنها به واحدهای هدف اصلی
- ارزیابی کارآیی آموزش شبکه های عصبی با یاد گیری عمیق با مقایسه خروجی شبکه های عصبی با یاد گیری عمیق با مقادیر اصلی هدف

در این مطالعه مدل های مختلفی که در جدول ۲ ذکر شده است، برای تعیین شبکه با بهترین عملکرد ارزیابی حداکثر تنش انحرافی برای نمونه ها بکارگرفته شدند. در این مدل‌ها، برای بهینه سازی خطا در شبکه، حالت های مختلفی از تعداد لایه های میانی، تعداد سلولهای عصبی در هر لایه، الگوریتم های آموزش و توابع فعال سازی مورد بررسی قرار گرفت. سرانجام، همانطور که در جدول ۲ نشان داده شده است، مدل شماره ششم به عنوان بهترین مدل انتخاب شده است زیرا این مدل حداقل میانگین مجموع مربعات خطا یا MSE را در بین مدل‌های مورد بررسی برای فرآیندهای آموزش، تأیید و آزمایش بدست می‌آورد(به عنوان مثال: خطای ۴/۳٪ برای آموزش، خطای ۷/۴٪ برای تایید و ۴/۶۴٪ برای آزمایش). این نتایج تأیید می‌کند که مدل انتخابی قابل قبول است. مدل انتخاب شده با حداقل درصد خطا، ضریب همگرایی(R^2) برابر ۰/۹۹۳، ۰/۹۹۱ و ۰/۹۹۴ به ترتیب برای آموزش، تایید و آزمایش محاسبه شده است. این مدل دارای ۵ نورون در لایه ورودی، ۱۵ نورون در لایه پنهان و یک نورون در لایه خروجی است. در این مدل از الگوریتم لونبرگ-مارکات(LM) برای اهداف آموزشی استفاده می‌شود. تابع فعال سازی لایه پنهان، Logsig است.

جدول ۲ . کاراکتر های مدل های بررسی شده

مدل	نورون های لایه اول	نورون های لایه دوم	الگوریتم آموزش	تابع فعالسازی	مجموع مربعات خطا (MSE)		
					آموزش	تایید	آزمایش
۱	۵	۵۰	LM	Tansig-Tansig	۱۴/۶	۳۲/۳	۲۴/۷
۲	۵	۴۰	LM	Tansig-Tansig	۲/۳	۳۱/۳	۳۰/۴
۳	۵	۳۰	LM	Logsig-Logsig	۳/۲	۱۱/۱	۱۸/۳
۴	۵	۲۵	LM	Logsig-Logsig	۶/۵	۱۸/۵	۱۴/۲
۵	۵	۲۰	LM	Tansig-Tansig	۵/۳	۱۲/۲	۸/۲
۶	۵	۱۵	LM	Logsig	۴/۳	۷/۴	۴/۶
۷	۵	۱۰	LM	Logsig-Logsig	۶/۲	۸/۱	۱۱/۷
۸	۵	۵	LM	Tansig	۹/۵	۹/۳	۱۲/۶

مقدار بیشینه تنش انحرافی بر اساس این مدل بهینه شده مورد ارزیابی قرار گرفت. نتایج ارزیابی در کنار نتایج آزمایش برای فشار های جانبی ۱۰۰ و ۳۰۰ کیلو پاسکال در حالت بدون آلودگی و آلوده شده در فاصله زمانی ۷، ۱۴ و ۲۸ روز در شکل ۷ ارایه شده است.

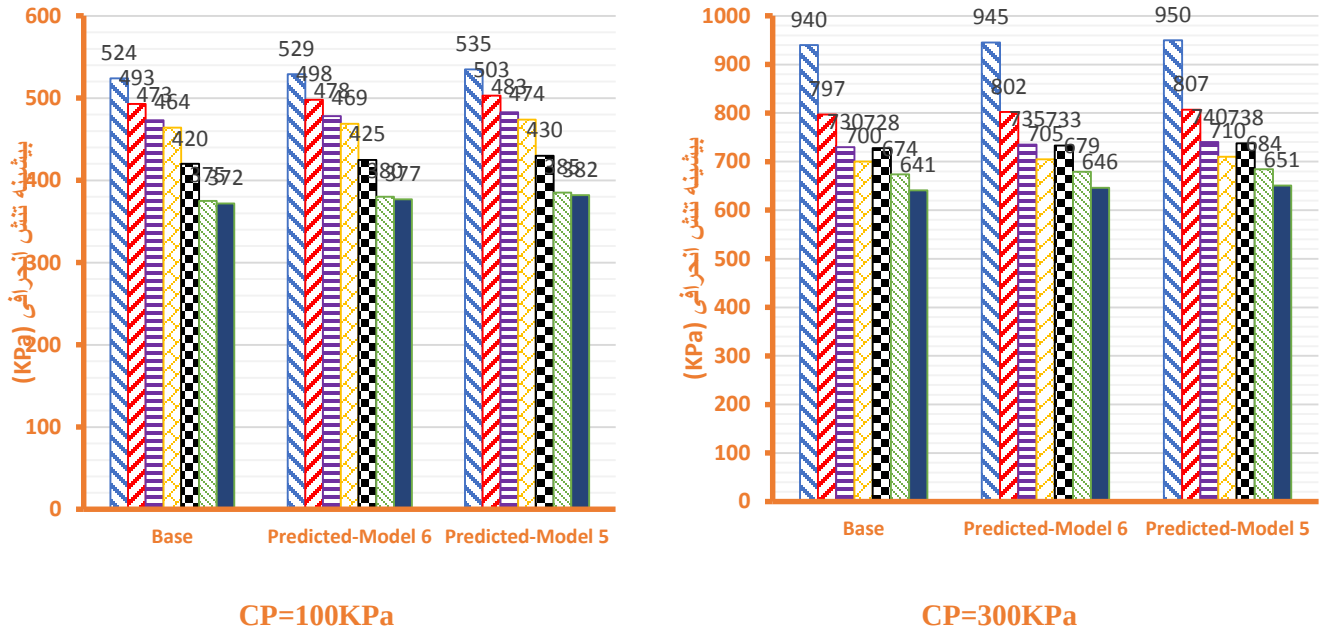

شکل 7. مقادیر بیشینه تنش انحرافی مربوط به شکل ٤-١، ٤-٢ و ٤-٣

نتایج

پیش بینی مشخصه های مکانیکی خاک، خاک های آلوده شده و یا خاک های بهسازی شده در کوتاهترین زمان ممکن از اهمیت ویژه ای برخوردار است. یکی از ابزار های موثر در این حوزه، هوش مصنوعی می باشد. بر اساس بکار گیری هوش مصنوعی امکان پیشبینی تنش انحرافی حداکثری در نمونه های خاک، نمونه های آلوده به ضایعات آلی در زمان های مختلف مورد ارزیابی قرار گرفت. نتایج گویای دقت مناسب در بکار گیری هوش مصنوعی در این فرایند ارزیابی می باشد. مقادیر بیشینه خطا نسبت به نتایج ازمایشگاهی در بازه ۲,۵ ٪ تا ۳,۸٪ قرار دارد.تحقیقات بیشتری بمنظور بینه سازی مدل ارزیابی بمنظور بررسی تاثیر سایر آلودگی ها بر سایر خصوصیات مکانیکی خاک مورد نیازاست.

مراجع

Fausett, L. (1994). "Fundamentals of Neural Networks (Architectures, Algorithms, and Applications". Boston, MA: Prentice Hall

Hasanazadeh, A.,"Nano-Lime Effect on Contaminated Soil Mechanical Behaviour Close to Landfill “, Master Thesis, Golestan University, (2018).

Itani, O., 1996, “A New Method for Site Characterization: Artificial Neural Network Approach,” Unpublished Master’s Thesis, School of Civil Engineering, Kansas State University.

Itani, O. and Najjar, Y., 2000, "3-D modeling of Spatial Properties Via Artificial Neural Networks," Transportation Research Records, No. 1709, pp. 50-59.

J. B. LI, G.H. Huang, Y. F. Hauang, A. Chakma, and M. Zeng (1998). Neural Network Modeling of Hydrocarbon Recovery at petroleum contaminated sites.

Najjar, Yacoub M. and Basheer, Imad A., 1996, A neural network approach for site characterization and uncertainty prediction, in uncertainty in the geological environment: from theory to practice, ASCE Geotechnical Special Publication No. 58, Shackelford, C. D. et. al. (Editors), Vol. 1, pp. 134-148.