

ارزیابی دقت روش‌های تجربی و الگوریتم‌های یادگیری ماشین در تعیین ظرفیت باربری شمع‌های کوبشی جنوب ایران

مقاله علمی-پژوهشی

محمد مهدی بیات ترک، دانشجوی دکتری، گروه مهندسی عمران، دانشکده فنی و مهندسی،

دانشگاه آزاد اسلامی واحد تهران مرکزی، تهران، ایران

*امیرعلی زاد (نویسنده مسئول)، دانشیار، گروه مهندسی عمران، دانشکده فنی و مهندسی،

دانشگاه آزاد اسلامی واحد تهران مرکزی، تهران، ایران

بابک ابراهیمیان، استادیار، گروه مهندسی ژئوتکنیک، دانشکده مهندسی عمران، آب و محیط زیست،

دانشگاه شهید بهشتی، تهران، ایران

*پست الکترونیکی نویسنده مسئول: amir.zad@iaau.ac.ir

دریافت: ۱۴۰۵/۰۲/۱۱ - پذیرش: ۱۴۰۵/۰۵/۰۵

صفحه ۷۲-۴۹

چکیده

شمع‌های فراساحلی از ارکان کلیدی در پروژه‌های ساخت‌وساز دریایی به شمار می‌روند و تأمین استحکام و پایداری سازه‌ها در برابر بارهای اعمالی بر عهده آن‌هاست. از این رو، پیش‌بینی دقیق ظرفیت باربری این شمع‌ها نقشی تعیین‌کننده در طراحی و اجرای مطمئن سازه‌های فراساحلی دارد. در پژوهش حاضر، دقت روش‌های مختلف پیش‌بینی ظرفیت باربری شمع‌های فولادی نصب‌شده در رسوبات خاکی فراساحلی جنوب ایران مورد مقایسه قرار گرفته است. برای این منظور، علاوه بر استفاده از روش‌های تجربی طراحی استاتیکی API و رویکردهای مبتنی بر آزمایش نفوذ مخروط (CPT) شامل *UWA*، *ICP*، *NGI* و *Fugro*، هفت الگوریتم یادگیری ماشین (ML) شامل درخت تصمیم (DT)، رگرسیون خطی (LR)، نزدیک‌ترین همسایه (KNN)، شبکه‌های عصبی (NN)، رگرسیون بردار پشتیبان (SVR)، گرادیران بوسستینگ سبک (LGBM) و نایبو بیز (NB) نیز مورد ارزیابی قرار گرفتند. نتایج نشان می‌دهد که الگوریتم رگرسیون خطی (LR) بالاترین دقت را در پیش‌بینی ظرفیت باربری نوک شمع‌ها داشته و پس از آن الگوریتم NB و روش API قرار دارند. در خصوص پیش‌بینی ظرفیت باربری جدار شمع‌ها، روش *Fugro* بهترین عملکرد را ارائه می‌دهد و الگوریتم NB و روش‌های *UWA* و *API* به ترتیب در رده‌های بعدی قرار می‌گیرند.

واژه‌های کلیدی: ظرفیت باربری شمع‌های فراساحلی، الگوریتم‌های یادگیری ماشین، رگرسیون خطی، شبکه‌های عصبی، رگرسیون بردار پشتیبان، تحلیل PDA، روش‌های تجربی، پارس جنوبی

۱- مقدمه

در این حوزه، چالش‌های زیادی برای پژوهشگران و طراحان در تعیین دقیق ظرفیت باربری شمع‌های دریایی همچنان باقی مانده است (پایکوسکی و همکاران، ۱۹۸۹؛ فتاحی و همکاران، ۲۰۲۴؛ ژانگ و همکاران، ۲۰۲۴). یکی از مهم‌ترین موانع در این زمینه، فقدان دستورالعمل‌های روشن و جامع برای کمک به مهندسان

ارزیابی دقیق ظرفیت باربری فشاری محوری شمع‌های باربر، عامل حیاتی برای طراحی و نصب موفقیت‌آمیز سازه‌های جکت ثابت دریایی به شمار می‌آید. این شمع‌ها تحت نیروی قابل توجهی به لایه‌های خاک بستر دریا کوبیده می‌شوند (مصطفی و الناگر، ۲۰۰۴؛ اشنایدر، ۲۰۰۷). با وجود پیشرفت‌های چشمگیر

به ترتیب حدود ۷۰٪، ۶۳٪ و ۳۵٪ بیشتر از مقادیر به دست آمده از آزمایش‌های دینامیکی شمع برای دوره‌های کوتاه مدت، میان مدت و بلند مدت هستند (شمشیرگران و ابراهیمیان، ۲۰۲۱). این اختلاف، نیاز به استفاده از روش‌های تکمیلی را برای پیش‌بینی ظرفیت باربری شمع‌ها به شیوه‌ای اقتصادی‌تر برجسته می‌کند (بن بوراس و همکاران، ۲۰۲۱).

روش‌های مبتنی بر تحلیل استاتیک بیش از ۵۰ سال است که در صنعت فراساحلی استفاده می‌شوند و در شیوه‌های پیشنهادی انجمن نفت آمریکا (API) برای سازه‌های ثابت فراساحلی (RP2A) گنجانده شده‌اند (فین و داوینگ، ۲۰۱۶؛ وانگ و همکاران، ۲۰۱۸). با این حال، چندین پژوهشگر دقت پیش‌بینی محدود روش API را مورد تأکید قرار داده‌اند (یاردین و همکاران، ۲۰۰۵؛ لهانه و همکاران، ۲۰۰۵؛ اشنایدر و همکاران، ۲۰۰۸؛ گاوین و همکاران، ۲۰۱۱؛ چو و کیم، ۲۰۱۵؛ وانگ و همکاران، ۲۰۱۸؛ هیداری گلفزانی و همکاران، ۲۰۲۰). با مقایسه پیش‌بینی‌های API با پایگاه داده‌ای از آزمایش‌های بارگذاری استاتیکی، این نویسندگان سوگیری‌های قابل توجهی در پیش‌بینی ظرفیت‌ها شناسایی کرده‌اند، به ویژه در مورد باریک بودن شمع (نسبت طول شمع به قطر آن) و دانسیته نسبی خاک. این سوگیری‌ها در روش API از مدت‌ها پیش شناخته شده است و تلاش‌ها برای اصلاح روش‌های طراحی شمع را برانگیخته است (وانگ و همکاران، ۲۰۱۸).

در سال‌های اخیر، روش‌های آزمایش درجا به دلیل چالش‌های موجود در شبیه‌سازی شرایط دنیای واقعی در آزمایشگاه و دشواری‌های به دست آوردن نمونه‌های دست‌نخورده خاک، محبوبیت زیادی در طراحی شمع پیدا کرده‌اند.

پیشرفت‌های فناوری آزمایشگاه و امکان ارسال تجهیزات آزمایشی به طور مستقیم به محل پروژه‌ها، آزمایش‌های درجا را بیشتر ترویج کرده است (ابراهیمیان و موحد، ۲۰۱۶؛ وانگ و همکاران، ۲۰۱۸). آزمایش‌های معمول درجا شامل آزمایش نفوذ استاندارد (SPT)، آزمایش نفوذ مخروط (CPT) و آزمایش فشارسنج (PMT) هستند که ظرفیت‌های باربری محوری و جانبی را ارزیابی می‌کنند. به طور کلی، این آزمایش‌ها به عنوان روش‌های مکمل و جایگزین برای تحلیل استاتیک عمل می‌کنند (کای و همکاران، ۲۰۰۸؛ ابراهیمیان و موحد، ۲۰۱۶؛ وی و همکاران، ۲۰۲۰).

آزمایش‌های درجا معمولاً از طریق روش‌های مستقیم و غیرمستقیم تحلیل می‌شوند. در روش‌های مستقیم، نتایج آزمایش برای محاسبه مقاومت‌های شفت و نوک شمع از طریق معادلات

در انتخاب روش طراحی مناسب است. روش‌های فعلی برای محاسبه مقاومت بار محوری شمع‌های کوبشی دریایی، نتایج ناسازگاری را در میان شیوه‌های مختلف طراحی به همراه دارند که موجب تفاوت‌های چشمگیر در طول مورد نیاز شمع‌ها می‌شود و این امر نیاز به توجه ویژه دارد (راندولف، ۲۰۰۳؛ گاوین و همکاران، ۲۰۱۱؛ تانگ و فون، ۲۰۱۷؛ حیدری گلفزانی و همکاران، ۲۰۲۰). بنابراین، نیازهای فزاینده صنعت دریایی ایجاب می‌کند که تکنیک‌های تجزیه و تحلیل ظرفیت باربری شمع‌ها به طور مداوم توسعه یابند تا کارایی طراحی بهبود یابد (راندولف، ۲۰۰۳).

در طول سال‌ها، روش‌های مختلفی برای برآورد ظرفیت باربری شمع‌های فراساحلی توسعه یافته است (زو و همکاران، ۲۰۲۰؛ حیدری گلفزانی و همکاران، ۲۰۲۰). این روش‌ها شامل تحلیل‌های استاتیک مبتنی بر نتایج آزمایش‌های آزمایشگاهی، نتایج آزمایش‌های درجا، و آزمایش‌های بارگذاری استاتیک و دینامیکی می‌باشند (اسلامی و همکاران، ۲۰۱۱؛ فاتح و همکاران، ۲۰۱۶؛ ژو و همکاران، ۲۰۱۹). به طور کلی، این تکنیک‌ها عمدتاً بر روابط تجربی و تحلیلی استوارند که عوامل پیچیده‌ای نظیر نوع خاک، روش نصب، خواص مواد، هندسه شمع و شرایط بارگذاری را در نظر می‌گیرند (لاکاس و همکاران، ۲۰۱۳؛ چن و همکاران، ۲۰۲۳؛ لیو و همکاران، ۲۰۲۴). تحقیقات در سه دهه گذشته نشان داده است که این روش‌ها تحت شرایط یکسان، نتایج بسیار متفاوتی تولید می‌کنند (گاوین و همکاران، ۲۰۱۱؛ وانگ و همکاران، ۲۰۱۷؛ وانگ و همکاران، ۲۰۱۸؛ حیدری گلفزانی و همکاران، ۲۰۲۰). در نتیجه، پژوهشگران بر انتخاب مناسب‌ترین رویکردها تمرکز کرده‌اند و پیش‌بینی‌های آن‌ها را با آزمایش‌های مرجع، از جمله آزمایش‌های بارگذاری استاتیک و دینامیکی شمع، مقایسه کرده‌اند (گاوین و همکاران، ۲۰۱۱؛ ابراهیمیان و همکاران، ۲۰۱۵؛ فاتح و همکاران، ۲۰۱۶؛ هیداری گلفزانی و همکاران، ۲۰۲۰؛ شمشیرگران و ابراهیمیان، ۲۰۲۱).

در حالی که تحلیل استاتیک به طور گسترده‌ای به عنوان رایج‌ترین روش استفاده شده و معمولاً یکی از اولین مراحل در طراحی پی‌های شمع به شمار می‌آید، فرضیات زیربنایی این روش‌ها نیاز به استفاده از ضرایب اطمینان بزرگ‌تری دارند (وانگ و همکاران، ۲۰۱۸). با این حال، این روش‌ها اغلب قادر به در نظر گرفتن کامل پیچیدگی‌های شرایط واقعی میدان نیستند، که منجر به کاهش دقت و مصرف بیشتر منابع مواد می‌شود (فاتح و همکاران، ۲۰۱۶). شمشیرگران و ابراهیمیان (۲۰۲۱) نشان دادند که مقادیر ظرفیت باربری به دست آمده از تحلیل استاتیک

تجربی استفاده می‌شود (ابو-فارساخ و تی تی، ۲۰۰۴؛ نیازی و ماینی، ۲۰۱۳). در حالی که روش‌های غیرمستقیم شامل استخراج پارامترهای مقاومت برشی خاک از نتایج آزمایش و انجام تحلیل استاتیک برای برآورد ظرفیت باربری شمع هستند (مایر هوف، ۱۹۷۶؛ بریود و تاکر، ۱۹۸۸؛ لونه و همکاران، ۲۰۰۲). اخیراً، آزمایش نفوذ مخروط (CPT) و CPT همراه با اندازه‌گیری فشار منفذی (CPTu) در طراحی شمع‌های فراساحلی توجه زیادی را به خود جلب کرده‌اند، زیرا این روش‌ها از نظر هزینه، دقت، قابلیت تکرار و توانایی برآورد ظرفیت شمع قبل از کوبش، مؤثر هستند (کای و همکاران، ۲۰۰۸؛ اشنایدر و همکاران، ۲۰۰۸؛ کای و همکاران، ۲۰۱۲؛ فاتح و همکاران، ۲۰۱۶). بر این اساس، CPT و CPTu به عنوان جایگزین‌های معتبر برای روش‌های تحلیل استاتیک شناخته شده‌اند (شاهین، ۲۰۱۰؛ نیازی و ماینی، ۲۰۱۳؛ ابراهیمیان و شمشیرگران، ۲۰۱۸، ۲۰۲۱).

استفاده از داده‌های آزمایش نفوذ مخروط (CPTu) به ویژه در محیط‌های دریایی مفید است و ارزیابی‌های دقیقی از رفتار شمع فراهم می‌کند و درک بهتری در مورد عملکرد شالوده‌های عمیق در شرایط زیرسطحی پیچیده ارائه می‌دهد (ابراهیمی پور و اسلامی، ۲۰۲۴).

تلاش‌هایی برای توسعه همبستگی‌های مستقیم بین خوانش‌های CPT و اجزای ظرفیت شمع، مانند مقاومت شفت و مقاومت پایه، بر اساس روش‌های پیشنهادی اشمرتمن (۱۹۷۸)، دو روتر و بیرینگن (۱۹۷۹)، بوستانامته و جیانزلی (۱۹۸۲)، اسلامی و فلیینیوس (۱۹۹۷)، کای و همکاران (۲۰۱۲)، و نیازی و ماینی (۲۰۱۶) انجام شده است. اگرچه آزمایش‌های بارگذاری استاتیکی شمع (SPLT) به عنوان معتبرترین روش برای تعیین ظرفیت باربری شناخته می‌شوند، اما هزینه‌بر و اغلب غیرقابل اجرا هستند، به ویژه در عملیات‌های فراساحلی (بن بوراس و همکاران، ۲۰۲۱).

آزمایش‌های بارگذاری دینامیکی که پارامترها را در حین کوبش شمع اندازه‌گیری کرده و آن‌ها را با نتایج تحلیل CAPWAP مقایسه می‌کنند، به عنوان یک روش اقتصادی و سریع، به ویژه در محیط‌های فراساحلی، معرفی شده‌اند (فلیینیوس و همکاران، ۱۹۸۹؛ مسعود و همکاران، ۲۰۲۳). ترکیب CPTu و آزمایش‌های بارگذاری دینامیکی به عنوان مؤثرترین روش برای پیش‌بینی ظرفیت باربری محوری در محیط‌های فراساحلی پیشنهاد شده است (الوالان و الناکر، ۲۰۲۰). آزمایش‌های بارگذاری استاتیکی و دینامیکی شمع هر دو به عنوان روش‌های کنترل کیفیت برای بهبود دقت تحلیل استاتیک و آزمایش‌های درجا استفاده می‌شوند.

(فاتح و همکاران، ۲۰۱۶؛ کتی و همکاران، ۲۰۲۳). با این حال، این آزمایش‌ها عمدتاً ظرفیت فعلی را اندازه‌گیری می‌کنند و نه ظرفیت باربری بلندمدت، به ویژه در خاک‌های چسبنده (کیم و همکاران، ۲۰۰۹).

تغییرات ظرفیت‌های باربری در طول زمان یکی از چالش‌های اصلی ژئوتکنیکی در شمع‌های کوبشی است. شمع‌های پیش‌ساخته کوبشی ممکن است افزایش (ست‌آپ) یا کاهش (وادادگی) ظرفیت باربری را تجربه کنند که بستگی به نوع خاک دارد (سمسون و آتیر، ۱۹۸۶؛ کتی و همکاران، ۲۰۲۳). اگرچه این تغییرات در مراحل اولیه سریع است، اما با گذشت زمان به طور قابل توجهی کند می‌شود (حسین‌زاده عطار و فخاریان، ۲۰۱۳؛ کتی و همکاران، ۲۰۲۳). پدیده ست‌آپ شمع ابتدا توسط تاواناس و آودی (۱۹۷۲) در خاک‌های غیرچسبنده مشاهده شد. مطالعات بعدی نشان داده است که ست‌آپ در خاک‌های ریزدانه چسبنده بیشتر نمایان می‌شود که به شدت به فرآیند تراکم در این خاک‌ها مرتبط است (سمسون و آتیر، ۱۹۸۶؛ تراونه و امام، ۲۰۱۴؛ فخاریان و همکاران، ۲۰۲۲؛ کتی و همکاران، ۲۰۲۳).

برای ارزیابی ست‌آپ خاک، باید آزمایش‌های بارگذاری دینامیکی شمع حداقل دو بار انجام شود: یک‌بار بلافاصله پس از کوبش و دوباره پس از گذشت مدت زمان طولانی.

با این حال، آزمایش‌های بارگذاری دینامیکی طولانی‌مدت، به ویژه در محیط‌های فراساحلی، اغلب غیرقابل اجرا و پرهزینه هستند (فو و شی، ۲۰۱۹؛ چن و همکاران، ۲۰۲۳؛ الف و ب) که منجر به کمبود داده‌های آزمایش دینامیکی بلندمدت برای شمع‌های فراساحلی می‌شود (تراونه و امام، ۲۰۱۴؛ کتی و همکاران، ۲۰۲۳).

عملکرد بلندمدت شمع‌ها، به ویژه در خاک‌های چسبنده، برای تعیین ظرفیت باربری نهایی آن‌ها حیاتی است. در حالی که CPT معمولاً از تحلیل تنش کل برای برآورد ظرفیت باربری کوتاه‌مدت استفاده می‌کند، تحلیل تنش مؤثر برای ارزیابی رفتار بلندمدت مناسب‌تر است. در خاک‌های غیرچسبنده، فشار اضافی آب منفذی معمولاً ناچیز است. در مقابل، در خاک‌های چسبنده مانند رس که به آرامی توسعه می‌یابد، ضروری است که هنگام محاسبه ظرفیت باربری بلندمدت، آن را مد نظر قرار داد (کای و همکاران، ۲۰۱۲؛ وانگ و همکاران، ۲۰۲۳).

درک زمان لازم برای اینکه یک شمع فراساحلی کوبشی به ظرفیت باربری بلندمدت خود برسد، برای عملکرد سازه‌های فوقانی مرتبط حیاتی است (شیانگ و همکاران، ۲۰۲۴). کد API، که به طور گسترده‌ای در طراحی شمع‌های فراساحلی استفاده

بررسی ادبیات فنی نشان می‌دهد، تاکنون پژوهشی به مقایسه دقت الگوریتم‌های یادگیری ماشین (ML) برای برآورد ظرفیت باربری شمع‌های فراساحلی جنوب ایران با روش طراحی تجربی نپرداخته است. در پژوهش حاضر عملکرد روش‌های طراحی تجربی مبتنی بر استاتیک (روش اصلی API)، روش‌های طراحی مبتنی بر CPT (NGI، ICP، UWA، و فوگرو) و هفت الگوریتم مختلف یادگیری ماشین درخت تصمیم (DT)، رگرسیون خطی (LR)، نزدیک‌ترین همسایه (KNN)، شبکه‌های عصبی (NN) و رگرسیون بردار پشتیبان (SVR)، گرادریان بوستینگ سبک (LGBM) و نایو بیز (NB)، بر مبنای آزمون‌های بارگذاری دینامیکی شمع با یکدیگر مقایسه می‌شوند.

در بخش پایانی این پژوهش، تلاش شده است با استفاده از داده‌های آزمایشگاهی و آزمایش‌های صحرایی، همراه با روابط تجربی ارائه شده در مطالعات پیشین، زمان ست‌آپ خاک در محیط‌های فراساحلی جنوب ایران برآورد شود. یافته‌های این تحقیق می‌تواند به عنوان یک راهنمای عملی برای مهندسان، پژوهشگران حرفه‌ای‌های صنعت در پروژه‌های ساخت و ساز فراساحلی در جنوب ایران عمل کرده و به آن‌ها در انتخاب مناسب‌ترین روش طراحی برای کاربردهای خاص خود کمک کند.

۲- مشخصات ناحیه مورد مطالعه

از دهه ۱۹۹۰، تحقیقات جامع ژئوتکنیکی و ژئوفیزیکی بسیاری برای پشتیبانی از پروژه‌های توسعه نفت و گاز فراساحلی در محیط‌های دریایی جنوب ایران انجام شده است که تا عمق تقریباً ۱۱۰ متر زیر بستر دریا ادامه یافته‌اند (ابراهیمیان و همکاران، ۲۰۱۲؛ ۲۰۱۴). این تحقیقات شامل آزمایش‌های آزمایشگاهی خاک برای ارزیابی ترکیب شیمیایی، تراکم‌پذیری، سختی و ویژگی‌های مقاومتی نمونه‌های استخراج شده از حفره‌ها بوده است. همچنین، آزمایش‌های نفوذ مخروط الکتریکی با اندازه‌گیری فشار منفذی (CPTu) و آزمایش‌های برش ورنی برای شبیه‌سازی رفتار خاک درجا اجرا شدند.

در راستای برنامه آزمایش‌های آزمایشگاهی و درجا، مقاومت برشی نمونه‌ها نیز با استفاده از آزمایش‌های کشتی‌مانند پترومتر جیبی و ورنی مینیاتوری ارزیابی گردید. این آزمایش‌ها در فواصل ۲-۳ متر از نمونه‌های حفره انجام شدند (ابراهیمیان و همکاران،

۲۰۱۲؛ ۲۰۱۴). میدان پارس جنوبی، که با مساحتی بالغ بر ۳۷۰۰ کیلومتر مربع، یکی از بزرگ‌ترین ذخایر گاز در جهان است و

می‌شود، شامل چندین روش برای تعیین ظرفیت باربری محوری شمع‌های لوله‌ای فولادی فراساحلی کوبشی است. این روش‌ها شامل روش طراحی استاتیک سنتی "API متن اصلی" و چهار تکنیک جدید مبتنی بر آزمایش نفوذ مخروط (CPT) هستند که توسط موسسه ژئوتکنیکی نروژی (NGI-05)، کالج سلطنتی امپریال (ICP-05)، دانشگاه غرب استرالیا (UWA-05) و فوگرو (Fugro-05) توسعه یافته‌اند. این روش‌های مبتنی بر CPT اکنون بخشی از ویرایش بیست و دوم شیوه‌های پیشنهادی API برای سازه‌های ثابت فراساحلی هستند (API, 2008). در سال‌های اخیر، طراحی شمع‌های فراساحلی در محیط‌های دریایی جنوب ایران عمدتاً بر اساس روش متن اصلی API انجام شده است که به طور گسترده‌ای به عنوان یک روش استاندارد و قابل دسترس در نظر گرفته می‌شود (زفرجو و امیرآبادی، ۲۰۲۳). با این حال، مطالعات متعدد نشان داده‌اند که این روش ممکن است از دقت کافی برخوردار نباشد و منجر به انحرافات قابل توجهی از ظرفیت‌های باربری اندازه‌گیری شده در میدان شود. تجزیه و تحلیل داده‌های کوبش شمع از پروژه‌های فراساحلی در جنوب ایران، به همراه دیدگاه‌هایی از عملیات نصب سکوی دریایی، ناهم‌آهنگی‌هایی را بین پیش‌بینی‌های روش متن اصلی و نتایج آزمایش‌های دینامیکی شمع نشان می‌دهد. در چندین مورد، این اختلافات قابل توجه نه تنها فرآیندهای کوبش شمع و نصب سکو را پیچیده می‌کند، بلکه ممکن است خطرات بلندمدتی برای یکپارچگی سازه‌ای سکوه‌های فراساحلی تحت بارهای اعمالی ایجاد کند.

طبق مطالعات قبلی، روش طراحی متن اصلی API اغلب ظرفیت باربری شمع‌ها را در رسوبات خاکی چسبنده فراساحلی هنگام مقایسه با اندازه‌گیری‌های میدانی، بیش از حد ارزیابی می‌کند (چو و کیم، ۲۰۱۵؛ فاتح و همکاران، ۲۰۱۶؛ وانگ و همکاران، ۲۰۱۸؛ زو و همکاران، ۲۰۱۹). تحقیقات بعدی نشان داده‌اند که درک محدود اندرکنش شمع و خاک در خاک‌های چسبنده، به ویژه در خصوص اثرات کوبش شمع و مساحت واقعی تماس بین شمع و خاک اطراف، عدم قطعیت‌های قابل توجهی را در برآورد مقاومت شمع ایجاد می‌کند (چاکرابورتی و کومار، ۲۰۱۳؛ سای و همکاران، ۲۰۱۶؛ زو و همکاران، ۲۰۲۰). وابستگی به فرضیات ساده‌سازی شده و حذف عوامل کلیدی تأثیرگذار (مانند ناهمگنی خاک، هندسه شمع، روش نصب و نفوذپذیری خاک) دقت و عملکرد پیش‌بینی روش متن اصلی API را در مقایسه با روش‌های جایگزین کاهش می‌دهد (اشنایدر و همکاران، ۲۰۰۸؛ فاتح و همکاران، ۲۰۱۶).

شمع فراساحلی تحلیل شده را ارائه می‌دهد. مکان‌های تقریبی شمع‌ها در شکل ۱ نمایش داده شده است.

۳- طبقه‌بندی لایه‌های خاک بستر دریا

در طول سه دهه گذشته، چندین روش برای طبقه‌بندی لایه‌های خاک بر اساس داده‌های آزمایش نفوذ مخروط (CPT) توسعه یافته است. در این مطالعه، آزمایش‌های درجا با استفاده از دستگاه پیروکون نفوذ مخروط (CPTu) انجام و نمونه‌های خاک تکمیلی از گمانه‌های حفاری شده جمع‌آوری گردید. طبقه‌بندی خاک با استفاده از دو روش معتبر USCS و AASHTO صورت گرفت، و روش پیشنهادی رابرتسون (۱۹۹۰) و اسلامی و فلیپینوس (۲۰۰۴) برای تفسیر نتایج CPTu به کار گرفته شد. در میدان پارس جنوبی، شمع‌ها معمولاً به عمق ۱۵ تا ۲۵ متر در بستر دریا تحت وزن خود نفوذ می‌کنند، که به دلیل شرایط نسبتاً شل و مقاومت پایین لایه‌های بستر دریا در اعماق کم است (ابراهیمیان و همکاران، ۲۰۱۴). پس از این مرحله، نصب شمع با استفاده از چکش هیدرولیکی MHU 270T با خروجی انرژی ۳۰۰ کیلوژول ادامه می‌یابد که شمع‌ها را تا عمق ۴۰ متر زیر بستر دریا می‌راند. برای نفوذ بیشتر و رسیدن به عمق نهایی نصب، از چکش‌های هیدرولیکی بزرگ‌تری مانند MHU 500T (۵۵۰ کیلوژول) یا IHC S600 (۶۰۰ کیلوژول) استفاده می‌شود.

حدود ۶ درصد از ذخایر گاز طبیعی جهانی را در خود جای داده است، در عمق‌های آبی بین ۷۰ تا ۸۵ متر قرار دارد (عالی و همکاران، ۲۰۰۶؛ اسرافیلی‌دیزجی و رحیم‌پوربناب، ۲۰۰۹، ابراهیمیان و همکاران ۲۰۱۵).

این تحقیق به طور کلی بر توسعه یک پایگاه داده ژئوتکنیکی جامع تمرکز دارد که شامل پارامترهای مهندسی خاک از آزمایش‌های آزمایشگاهی و درجا در نزدیکی شمع‌های فراساحلی، همچنین نتایج آزمایش‌های دینامیکی شمع در فواصل زمانی مختلف در منطقه مورد مطالعه است. داده‌های حاصل شامل بیش از ۳۵,۰۰۰ نقطه داده ژئوتکنیکی از تحقیقات آزمایشگاهی و میدانی، به علاوه نتایج ۱۰ آزمایش CPTu در نزدیکی ۳۳ شمع و ۳۳ آزمایش دینامیکی شمع در دوره‌های کوتاه‌مدت، میان‌مدت و بلندمدت می‌باشد.

برای هر شمع فراساحلی و حفرة مرتبط آن، شناسه‌های منحصر به فردی اختصاص یافته که با پیشوندهای «OP» و «BH» مشخص می‌شوند. این شناسه‌ها از یک پیشوند دوحرفی و یک عدد دو رقمی تشکیل شده‌اند که شماره‌گذاری شمع‌ها از ۰۱ تا ۳۳ و حفرة‌ها از ۰۱ تا ۱۰ متغیر است.


این بخش داده‌های مربوط به ۱۰ حفرة را ارائه می‌دهد که شامل اطلاعاتی در مورد انواع خاک بستر دریا و پارامترهای مهندسی مرتبط با آن‌ها، به همراه نتایج آزمایش‌های CPTu انجام‌شده در نزدیکی ۳۳ شمع فراساحلی کوبیده شده است. تمامی شمع‌های مورد بررسی در این مطالعه، شمع‌های لوله‌ای فولادی باز هستند. جدول ۱ ویژگی‌ها و مشخصات جغرافیایی گمانه‌ها را به صورت خلاصه نشان می‌دهد. همچنین، جدول ۲ مشخصات هندسی هر

جدول ۱. مشخصات گمانه‌های مورد مطالعه

نام گمانه	مختصات		عمق آب (متر)	عمق نهایی گمانه (متر)
	عرض جغرافیایی N (متر)	طول جغرافیایی E (متر)		
BH-01	۲۹۷۱۵۴۳	۶۲۶۸۰۴	۶۳,۴۳	۸۰,۸۵
BH-02	۲۹۶۹۹۰۰	۶۳۶۶۰۵	۷۰,۲۱	۸۰,۱
BH-03	۲۹۷۵۷۳۹	۶۳۰۱۳۵	۶۶,۹۷	۸۰,۴
BH-04	۲۹۷۹۵۲۴	۶۳۴۱۶۳	۷۴,۶۱	۸۰,۳
BH-05	۲۹۷۹۶۰۷	۶۳۴۰۶۵	۷۳,۸۹	۱۱۰,۸
BH-06	۲۹۷۳۳۶۰	۶۱۷۷۴۴	۵۸,۹۹	۱۱۰,۴
BH-07	۲۹۸۳۳۴۷	۶۱۶۹۲۰	۶۱,۰۴	۱۱۰,۷
BH-08	۲۹۷۷۴۸۸	۶۲۱۲۴۵	۶۱,۵۹	۱۱۰,۰۵
BH-09	۲۹۵۶۳۶۱	۶۳۴۵۷۳	۶۵,۷۶	۱۱۰,۹
BH-10	۲۹۶۱۵۸۸	۶۳۸۹۰۰	۶۸,۰۵	۱۱۰,۴

جدول ۲. مشخصات هندسی شمع‌های فراساحلی منطقه مطالعه

نام گمانه	نام شمع	قطر (میلی‌متر)	ضخامت کیسینگ (میلی‌متر)	عمق نفوذ (متر)	زمان آزمایش بارگذاری دینامیکی
BH-01	OP-01	۱۲۲۰	۳۸,۱	۶۵,۵	پایان کوبش شمع
BH-02	OP-02	۱۲۲۰	۳۸,۱	۴۴,۸	۲۵۰ روز بعد از کوبش شمع
	OP-03	۱۲۲۰	۳۸,۱	۴۷,۵	۲۵۰ روز بعد از کوبش شمع
	OP-04	۱۲۲۰	۳۸,۱	۴۷,۸	۲۵۰ روز بعد از کوبش شمع
BH-03	OP-05	۱۲۲۰	۳۸,۱	۶۳,۷	پایان کوبش شمع
BH-04	OP-06	۱۲۲۰	۳۸,۱	۴۵,۸	۱ روز بعد از کوبش شمع
	OP-07	۱۲۲۰	۳۸,۱	۴۷,۸	۱ روز بعد از کوبش شمع
	OP-08	۱۲۲۰	۳۸,۱	۶۰,۸	پایان کوبش شمع
	OP-09	۱۲۲۰	۳۸,۱	۶۰	پایان کوبش شمع
BH-05	OP-10	۱۵۲۴	۸,۵	۴۴,۷	۵۰۰ روز بعد از کوبش شمع
	OP-11	۱۵۲۴	۸,۵	۴۴,۷	۵۰۰ روز بعد از کوبش شمع
	OP-12	۱۵۲۴	۸,۵	۴۴,۷	۵۰۰ روز بعد از کوبش شمع
	OP-13	۱۵۲۴	۸,۵	۴۴	۵۰۰ روز بعد از کوبش شمع
	OP-14	۱۵۲۴	۸,۵	۴۴,۳	۵۰۰ روز بعد از کوبش شمع
	OP-15	۱۵۲۴	۸,۵	۴۴,۵	۵۰۰ روز بعد از کوبش شمع
	OP-16	۱۵۲۴	۸,۵	۶۷,۳	پایان کوبش شمع
	OP-17	۱۵۲۴	۸,۵	۶۷,۳	۱ روز بعد از کوبش شمع
	OP-18	۱۵۲۴	۸,۵	۹۴,۵	۱ روز بعد از کوبش شمع
BH-06	OP-19	۱۵۲۴	۸,۵	۹۷	پایان کوبش شمع
	OP-20	۱۵۲۴	۸,۵	۱۰۱,۱	۱ روز بعد از کوبش شمع
	OP-21	۱۵۲۴	۸,۵	۱۰۱,۱	۱ روز بعد از کوبش شمع
BH-07	OP-22	۱۵۲۴	۸,۵	۹۶,۴	۱ روز بعد از کوبش شمع
	OP-23	۱۵۲۴	۸,۵	۹۷	۱ روز بعد از کوبش شمع
	OP-24	۱۵۲۴	۸,۵	۱۰۶,۵	۱ روز بعد از کوبش شمع
	OP-25	۱۵۲۴	۸,۵	۱۰۷,۷	پایان کوبش شمع
BH-08	OP-26	۱۵۲۴	۸,۵	۱۰۶,۵	۱ روز بعد از کوبش شمع
	OP-27	۱۵۲۴	۸,۵	۱۰۷,۷	۱ روز بعد از کوبش شمع
BH-09	OP-28	۱۵۲۴	۸,۵	۸۵	۱ روز بعد از کوبش شمع
	OP-29	۱۵۲۴	۸,۵	۹۳	۱ روز بعد از کوبش شمع
BH-10	OP-30	۱۵۲۴	۸,۵	۹۶,۴	۱ روز بعد از کوبش شمع
	OP-31	۱۵۲۴	۸,۵	۹۷	پایان کوبش شمع
	OP-32	۱۵۲۴	۸,۵	۱۰۵۰	۱ روز بعد از کوبش شمع
	OP-33	۱۵۲۴	۸,۵	۱۰۵	۱ روز بعد از کوبش شمع



شکل ۱. موقعیت تقریبی شمع‌ها

۴- پیش‌بینی ظرفیت باربری فشاری محوری

جدول ۳ معادلات حاکم بر روش‌های پیش‌بینی استفاده شده برای خاک رس و ماسه را خلاصه می‌کند. در این مطالعه، تنها روش‌های مستقیم برای برآورد ظرفیت باربری شمع بر اساس داده‌های آزمایش نفوذ مخروط در نظر گرفته شده است. ظرفیت باربری محوری شمع‌های لوله‌ای فولادی فراساحلی کوبیده شده در رسوبات خاک دریایی منطقه مطالعه با استفاده از روش طراحی استاتیکی API (API، ۱۹۹۰) و چهار رویکرد طراحی مبتنی بر CPT شامل NGI-05 (کلاوسن و همکاران، ۲۰۰۵؛ کارلسرود و همکاران، ۲۰۰۵)، ICP-05 (یاردین و همکاران، ۲۰۰۵)، UWA-05 (لهانه و همکاران، ۲۰۰۵) و Fugro-05 (کولک و همکاران، ۲۰۰۵) ارزیابی می‌شود.

نکته قابل توجه این است که تنها روش UWA در میان روش‌های ارزیابی شده به عامل "پلاگ خاک" توجه می‌کند. این عامل ممکن است به توضیح تفاوت‌های مشاهده شده در عملکرد، به ویژه در دقت و سازگاری پیش‌بینی‌های روش UWA کمک کند. طبق ادبیات موجود، تأثیر تأخیر زمانی بین کوبش اولیه شمع و آزمایش‌های بارگذاری بعدی که در فواصل زمانی مختلف انجام شده‌اند، به طور سیستماتیک در روش‌های پیش‌بینی مبتنی بر CPT و CPTu در نظر گرفته نشده است. با این حال، این عامل به طور ضمنی در برخی رویکردها گنجانده شده است. برای مثال، روش UWA تأخیر زمانی از ۲ تا ۶۸ روز را در نظر می‌گیرد، NGI تقریباً ۱۰۰ روز، ICP حدود ۵۰ روز و روش FBV تأخیری حدود ۳۰ روز دارد.

پس از برآورد ظرفیت‌های باربری شمع با استفاده از روش‌های پیشنهادی، مقادیر پیش‌بینی شده با ظرفیت‌های اندازه‌گیری شده از آزمایش‌های دینامیکی شمع مقایسه می‌شود.

از آنجا که داده‌های آزمایش دینامیکی شمع‌های فراساحلی در ایران محدود و اغلب سخت قابل دستیابی هستند، مجموعه داده‌ای که در این مطالعه جمع‌آوری شده است، برای طراحی و تحلیل شمع‌های فراساحلی ارزش زیادی دارد. داده‌های میدانی این مطالعه با استفاده از تکنیک‌های تطابق سیگنال در برنامه تحلیل موج شمع (CAPWAP) مورد تجزیه و تحلیل قرار گرفت. CAPWAP نرم‌افزاری است که نیروهای وارد بر شمع در حین کوبش را با تفسیر داده‌های جمع‌آوری شده از آنالیزگر کوبش شمع (PDA)، به ویژه اندازه‌گیری‌های نیرو و سرعت در سر شمع، تخمین می‌زند.

نرم‌افزار داده‌های مربوط به کرنش یا نیرو، شتاب یا سرعت، و جابجایی شمع تحت بارگذاری ضربه‌ای را پردازش کرده و برای ارزیابی پارامترهای مهمی همچون ظرفیت باربری شمع، یکپارچگی سازه، عملکرد چکش، تنش‌های وارد بر شمع، و ویژگی‌های دینامیکی خاک مانند میرایی و عوامل زلزله به کار می‌رود. تحلیل از طریق یک فرآیند تکراری انجام می‌شود که در آن پاسخ شمع پیش‌بینی شده توسط مدل معادله موج با پاسخ اندازه‌گیری شده در هر ضربه چکش مقایسه می‌شود. شتاب اندازه‌گیری شده به مدل شمع وارد می‌شود و پارامترهایی چون توزیع مقاومت خاک، زلزله و میرایی به طور مکرر تنظیم می‌شوند تا زمانی که تطابق رضایت‌بخشی میان سیگنال‌های نیرو-زمان اندازه‌گیری شده و محاسبه شده در سر شمع حاصل شود.

در این مطالعه، مقادیر عوامل زلزله و میرایی که در تحلیل‌های CAPWAP استفاده شده‌اند، به ترتیب از ۲٫۲ تا ۴٫۴ میلی‌متر و ۰٫۲ تا ۱ متغیر بودند.

جدول ۳. خلاصه‌ای از روش‌های استاتیکی و مبتنی بر CPT و CPTu

روش	مقاومت جدار (q_s) (مگاپاسکال)	مقاومت نوک (q_b) (مگاپاسکال)
API	$q_s = \alpha \frac{S_u}{\sigma'_{v0}}$ For $\psi \leq 1.0$; $\alpha = 0.5 \psi^{-0.5} \leq 1.0$ For $\psi > 1.0$; $\alpha = 0.5 \psi^{-0.25} \leq 1.0$	$q_b = N_e S_u$ $N_e = 9$
Fugro	$q_s = \alpha \frac{S_u}{\sigma'_{v0}}$ $\alpha = 0.9 \left(\frac{L-z}{D} \right)^{-0.2} \left(\frac{S_u}{\sigma'_{v0}} \right)^{-0.3} \leq 1.0$	$q_b = N_e S_u$
UWA	$\tau_f = \frac{0.23 q_t \left(\text{Max} \left[\left(\frac{H}{R^*} \right), 1 \right] \right)^{-0.2}}{\left(\frac{q_t}{\sigma'_{v0}} \right)^{0.15}} \tan \delta_f$ If δ_f is not available: $\tau_f = 0.055 q_t \left(\text{Max} \left[\left(\frac{H}{R^*} \right), 1 \right] \right)^{-0.2}$ $q_t = q_c + (1 - a) u_2$	$\sigma'_{rf} = \sigma'_{rc} + \sigma'_{rd} \tau_f = \sigma'_{rf} \tan(\delta_{cv})^{-0.5}$ $\sigma'_{rc} = 0.03 q_c (A_{rs}^*)^{0.3} \left(\text{Max} \left[\left(\frac{H}{D} \right), 2 \right] \right)^{-0.5}$ $A_{rs}^* = 1 - \text{IFR} \left(\frac{D_{1/2}}{D^2} \right)$ $\text{IFR}_{\text{mean}} = \min \left[1, \left(\frac{D_{1/2}(m)}{1.5(m)} \right)^{0.2} \right]$ $\Delta r = 0.02 (\text{mm}) \sigma'_{rd} = \frac{4G \Delta r}{D}$ $G = (185 q_{c1N}^{-0.75}) q_c \quad q_{c1N} = \left[\frac{\left(\frac{q_c}{P_a} \right)}{\left(\frac{\sigma'_{v0}}{P_a} \right)^{0.5}} \right]$
NGI	For NC clays with $\psi < 0.25$; $q_s = \alpha^{NC} S_u$ $\alpha^{NC} = 0.32 (I_p - 10)^{0.3} \leq 1.0$ $0.20 < \alpha^{NC} < 1.00$ For OC clays with $\psi > 1.0$; $q_s = \alpha S_u F_{tip}$ $\alpha = 0.5 \psi^{-0.3} \leq 1.0$ $F_{tip(open)} = 1.0$ $F_{tip(closed)} = 0.8 + 0.2 \psi^{0.5}$ $1.00 < F_{tip(closed)} < 1.25$ For clays with $0.25 \leq \psi \leq 1.0$; $q_s = \alpha S_u$ $\alpha = 0.5 + (0.83 - 1.66 \alpha^{NC}) \log_{10} \psi \leq 1.0$ should be $\geq \beta_{Min} \sigma'_{v0} q_s$ $\beta_{Min} = 0.06 (I_p - 12)^{0.33}$ $0.05 < \beta_{Min} < 0.20$	$q_b = N_e S_u$
ICP	$q_s = \sigma'_{rf} \tan \delta'_f$ $\sigma'_{rf} = 0.8 \sigma'_{rc}$ $\sigma'_{rc} = K_c \sigma'_{v0}$ $K_c = [2.2 + 0.016 \text{OCR} - 0.87 \log_{10}(S_r)] \text{OCR}^{0.42}$ $\text{Max} \left[\left(\frac{L-z}{R^*} \right)^{-0.2}, 0.8 \right]$ $R^* = (R_{OCR}^2 - R_{Min}^2)^{0.5}$	$q_b = N_e S_u$

کار گرفته می‌شود. در این مطالعه، پنج الگوریتم ML برای پیش‌بینی ظرفیت‌های باربری شمع‌های فراساحلی انتخاب شدند: درخت تصمیم (DT)، رگرسیون خطی (LR)، نزدیک‌ترین

انتخاب الگوریتم‌های یادگیری ماشین به ماهیت مسئله و روابط بین متغیرهای مستقل و وابسته بستگی دارد. هر الگوریتم با مزایای خاص خود، بسته به نوع داده‌ها و پیچیدگی وظیفه، به

دسته‌بندی‌شده بسیار انعطاف‌پذیر هستند و نیازی به مقیاس‌گذاری ویژگی‌ها ندارند. آن‌ها به‌طور طبیعی انتخاب ویژگی کرده و متغیرهای مؤثرتر را برجسته می‌کنند.

با این حال، درخت‌های تصمیم محدودیت‌هایی دارند. آن‌ها به‌ویژه در معرض خطر بیش‌برازش قرار دارند، به‌ویژه زمانی که درخت بسیار عمیق شود و توانایی تعمیم به داده‌های جدید کاهش یابد. علاوه بر این، درخت‌های تصمیم ممکن است ناپایدار باشند، به طوری که تغییرات کوچک در داده‌ها می‌تواند ساختارهای درختی متفاوتی ایجاد کند. همچنین، این الگوریتم‌ها تمایل دارند ویژگی‌های با مقادیر بیشتر را ترجیح دهند، که ممکن است باعث سوگیری شود مگر اینکه از تکنیک‌های تنظیم و هرس صحیح استفاده شود.

رگرسیون خطی یکی از الگوریتم‌های پایه در یادگیری ماشین است که برای پیش‌بینی نتایج پیوسته از رابطه بین متغیرهای مستقل (ویژگی‌ها) و متغیر وابسته (هدف) استفاده می‌شود. این تکنیک آماری فرض می‌کند که رابطه‌ای خطی بین متغیر هدف و ویژگی‌ها وجود دارد. هدف اصلی رگرسیون خطی مدل‌سازی این رابطه با شناسایی بهترین خط تطبیق (یا ابرصفحه در فضاهای چندبعدی) است که تفاوت بین مقادیر واقعی و پیش‌بینی‌شده را به حداقل می‌رساند. این هدف معمولاً از طریق روش کمترین مربعات حاصل می‌شود که مجموع مربعات باقی‌مانده‌ها را کاهش می‌دهد. به دلیل سادگی، کارایی و قابلیت تفسیر، رگرسیون خطی به عنوان مدل پایه‌ای ارزشمندی برای بسیاری از مسائل رگرسیونی شناخته می‌شود.

الگوریتم KNN یک روش ساده و شهودی است که برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. این الگوریتم غیرپارامتریک است و در حین آموزش، مدل داخلی مشخصی نمی‌سازد، بلکه داده‌ها را ذخیره کرده و پیش‌بینی‌ها را با شناسایی نزدیک‌ترین نمونه‌ها به ورودی جدید انجام می‌دهد. برای پیش‌بینی، KNN نزدیک‌ترین k نمونه آموزشی به نقطه درخواست را با استفاده از معیار فاصله (معمولاً فاصله اقلیدسی یا منهن) پیدا می‌کند. در مسائل طبقه‌بندی، الگوریتم کلاس پر تکرار میان همسایگان را اختصاص می‌دهد و در مسائل رگرسیونی، میانگین مقادیر همسایگان را محاسبه می‌کند.

سادگی، انعطاف‌پذیری و کارایی KNN آن را به روشی محبوب در داده‌های پیچیده و غیرخطی تبدیل کرده است، اما عملکرد آن به انتخاب k ، معیار فاصله و مقیاس‌گذاری ویژگی‌ها حساس

همسایه (KNN)، شبکه‌های عصبی (NN)، و رگرسیون بردار پشتیبان (SVR).

در این تحقیق، انتخاب ویژگی‌ها با ترکیبی از تخصص دامنه‌ای و روش‌های خودکار انجام می‌شود تا ویژگی‌های مرتبط با متغیر هدف شناسایی شوند. تنها پارامترهای مؤثر در فرآیند مدل‌سازی وارد مدل‌ها می‌شوند. برای تنظیم بهینه ابرپارامترها، از جستجوی شبکه‌ای همراه با اعتبارسنجی متقابل استفاده می‌شود که به بهبود دقت مدل‌ها کمک می‌کند. پارامترهای مستقل مور استفاده برای الگوریتم‌های یادگیری ماشین شامل طول و قطر شمع، مقاومت مخروطی (qc)، چگالی و مقاومت برشی خاک هستند. داده‌های موجود به نسبت ۷۷ درصد برای آموزش و ۲۳ درصد برای آزمون تقسیم می‌شوند.

الگوریتم درخت تصمیم (DT) به دلیل توانایی در مدل‌سازی روابط غیرخطی و قابلیت تفسیرپذیری که فرآیند تصمیم‌گیری را شفاف می‌کند، انتخاب شد. رگرسیون خطی (LR) به دلیل سادگی و کارایی در شبیه‌سازی وابستگی‌های خطی میان متغیرها به کار گرفته شد. الگوریتم نزدیک‌ترین همسایه (KNN) به خاطر قدرتش در مدیریت داده‌های پیچیده و ابعاد بالا و شناسایی الگوهای محلی انتخاب گردید. شبکه‌های عصبی (NN) به دلیل انعطاف‌پذیری در مدل‌سازی تعاملات پیچیده غیرخطی برای افزایش دقت پیش‌بینی به کار رفتند. در نهایت، رگرسیون بردار پشتیبان (SVR) به دلیل استحکام در فضاهای ویژگی با ابعاد بالا و عملکرد قابل اعتماد در پیش‌بینی متغیرهای پیوسته، به ویژه در شرایط داده‌های محدود، برگزیده شد.

این انتخاب الگوریتم‌ها رویکردی متعادل را نشان می‌دهد که ترکیبی از تکنیک‌های یادگیری ماشین سنتی و پیشرفته را برای پیش‌بینی دقیق ظرفیت باربری شمع‌های فراساحلی ادغام می‌کند. درخت تصمیم (DT) الگوریتمی است که برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. این الگوریتم با تقسیم داده‌ها به زیرمجموعه‌های کوچک‌تر بر اساس ویژگی‌های ورودی، ساختار درختی می‌سازد که هر گره داخلی نشان‌دهنده یک قاعده تصمیم‌گیری و هر گره برگ پیش‌بینی نهایی یا برجسب کلاس را مشخص می‌کند.

یکی از مزایای کلیدی درخت‌های تصمیم، تفسیرپذیری بالای آن‌ها است که فرآیند تصمیم‌گیری را به‌طور شفاف نمایان می‌کند، بنابراین کاربران به راحتی می‌توانند مسیر پیش‌بینی‌ها را ردیابی کنند. درخت‌های تصمیم در پردازش داده‌های عددی و

است. شبکه‌های عصبی (NN) مدل‌های قدرتمند یادگیری ماشین هستند که از عملکرد مغز انسان الهام گرفته‌اند. این الگوریتم‌ها به طور گسترده برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شوند، به‌ویژه در مواجهه با روابط پیچیده و غیرخطی در داده‌ها. شبکه عصبی از لایه‌هایی از گره‌های به هم متصل یا نورون‌ها تشکیل می‌شود که هر نورون ورودی‌ها را پردازش کرده و تابع فعال‌سازی را برای معرفی غیرخطی بودن اعمال می‌کند. این لایه‌ها معمولاً شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی هستند. با جریان داده‌ها از طریق شبکه، هر لایه ویژگی‌های انتزاعی‌تری استخراج می‌کند که به مدل این امکان را می‌دهد تا الگوها و روابط پیچیده در داده‌ها را بیاموزد. به همین دلیل، کیفیت آموزش شبکه عصبی به اندازه و تنوع پایگاه داده بستگی دارد، زیرا داده‌های بزرگ‌تر معمولاً عملکرد بهتر و تعمیم‌پذیری بالاتری دارند.

یک شبکه عصبی از سه نوع لایه اصلی تشکیل می‌شود. اولین لایه، لایه ورودی است که داده‌های خام را دریافت می‌کند و هر گره در این لایه به ویژگی‌های مختلف داده‌ها مرتبط می‌شود. پس از آن، لایه‌های پنهان قرار دارند که محاسبات را انجام می‌دهند و الگوها را یاد می‌گیرند. شبکه‌های عصبی عمیق‌تر معمولاً عملکرد بهتری در مسائل پیچیده دارند. در نهایت، لایه خروجی پیش‌بینی‌ها را تولید می‌کند؛ در مسائل طبقه‌بندی از توابع فعال‌سازی مانند softmax یا sigmoid استفاده می‌شود و در مسائل رگرسیونی، معمولاً از تابع خطی بهره می‌برند.

در طول آموزش، شبکه عصبی با به‌روزرسانی وزن‌ها و بایاس‌ها برای کاهش تفاوت بین پیش‌بینی‌ها و مقادیر واقعی می‌آموزد. این فرآیند با استفاده از الگوریتم‌های بهینه‌سازی مانند نزول گرادینت و تابع هزینه برای کمینه کردن خطا انجام می‌شود. سپس از طریق پس‌انتشار، گرادینت‌ها نسبت به هر پارامتر محاسبه و وزن‌ها به‌طور تکراری تنظیم می‌شوند.

رگرسیون بردار پشتیبان الگوریتمی است که از چارچوب ماشین بردار پشتیبان (SVM) استخراج شده و به‌ویژه برای مسائل رگرسیونی طراحی شده است. هدف SVR پیش‌بینی مقادیر پیوسته هدف از طریق شناسایی تابعی است که رابطه میان ویژگی‌های ورودی و خروجی را تقریب بزند. اصل این الگوریتم این است که یک تابع پیدا کند که از داده‌ها بیشتر از یک حد تحمل از پیش تعیین شده (ϵ) انحراف نداشته باشد و در عین حال پیچیدگی مدل را کمینه کند.


SVR به جای کمینه کردن خطای پیش‌بینی، بر حفظ پیش‌بینی‌ها در یک دامنه خطای قابل قبول تمرکز دارد و انحرافات خارج از این دامنه را جریمه می‌کند. این الگوریتم تعادلی میان پیچیدگی مدل و تحمل خطا برقرار می‌کند، که باعث می‌شود مدل مقاوم و انعطاف‌پذیر باشد. به‌طور کلی، SVR برای مدل‌سازی مجموعه داده‌های پیچیده و با ابعاد بالا و همچنین سناریوهایی که نیاز به مقاومت در برابر نقاط دورافتاده دارند، مؤثر است. با این حال، این الگوریتم معمولاً محاسباتی پرهزینه است و به انتخاب دقیق ابرپارامترها و تابع هزینه نیاز دارد.

گرادینت بوستینگ سبک یکی از الگوریتم‌های پیشرفته یادگیری ماشین مبتنی بر روش گرادینت بوستینگ است که برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. در این روش، مجموعه‌ای از درخت‌های تصمیم به‌صورت ترتیبی ساخته می‌شوند به‌طوری‌که هر درخت جدید تلاش می‌کند خطاهای درخت‌های قبلی را اصلاح کند. الگوریتم LightGBM با استفاده از تکنیک‌هایی مانند رشد برگ‌محور و باینری‌سازی ویژگی‌ها قادر است سرعت آموزش بالایی داشته باشد و در عین حال دقت مناسبی ارائه دهد. به همین دلیل این مدل در تحلیل داده‌های مهندسی، مسائل پیش‌بینی و مدل‌سازی داده‌های پیچیده بسیار مورد استفاده قرار می‌گیرد.


نایبو بیز (NB) یکی از روش‌های آماری پرکاربرد در یادگیری ماشین برای مسائل طبقه‌بندی است که بر پایه قضیه بیز عمل می‌کند. این الگوریتم با محاسبه احتمال تعلق یک نمونه به هر کلاس، بر اساس توزیع داده‌ها و بیشینه کردن احتمال پسین، تصمیم‌گیری می‌کند. ویژگی اصلی این روش، فرض استقلال شرطی بین ویژگی‌ها است؛ به این معنا که هر ویژگی به‌طور مستقل از سایر ویژگی‌ها در پیش‌بینی کلاس هدف مشارکت می‌کند. با وجود این فرض ساده‌کننده، مدل NB در بسیاری از مسائل عملی به دلیل سادگی، سرعت بالا در آموزش و نیاز کم به داده‌های آموزشی عملکرد مناسبی از خود نشان می‌دهد. در این مطالعه از نوع Gaussian Naive Bayes استفاده شده است که فرض می‌کند توزیع داده‌های هر ویژگی در هر کلاس از توزیع نرمال (گوسی) پیروی می‌کند.

بحث و نتایج


نتایج گزارش‌های آزمایش PDA عمدتاً از تحلیل موج نوسانی اولیه یا نهایی ثبت‌شده در شمع فلزی به دست می‌آید. یک موج حرکت به جلو، همراه با اجزای بازتابی جزئی آن، برای تحلیل انتخاب می‌شود که بر اساس انطباق آن با پارامترهای شبیه‌سازی



شکل ۲. میانگین متغیر مدل (Q_c/Q_m) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی



شکل ۳. انحراف معیار متغیر مدل (Q_c/Q_m) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی




شکل ۴. میانه متغیر مدل (Q_c/Q_m) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی

شده در نرم‌افزار GRLWEAP است. این تحلیل موجی امکان برآورد مقاومت نوک شمع و توزیع مقاومت در لایه‌های خاک را فراهم کرده و به طور مؤثر شمع را به نواحی مقاومتی مجزا تقسیم می‌کند. با استفاده از این روش، ظرفیت باربری بلندمدت شمع که از نتایج آزمایش بار دینامیکی (PDA) به دست آمده است، استخراج می‌شود و سپس با ظرفیت‌های باربری پیش‌بینی شده توسط روابط تجربی و الگوریتم‌های یادگیری ماشین مقایسه می‌شود. این تحلیل مقایسه‌ای، شناسایی دقیق‌ترین روش پیش‌بینی برای ارزیابی ظرفیت باربری شمع را ممکن می‌سازد. در نهایت، مطالعه رویکرد پیش‌بینی بهینه را با استفاده از شاخص‌های عملکرد آماری و ریاضی معرفی می‌کند.


برای تسهیل ارزیابی، یک متغیر به نام ضریب مدل تعریف می‌شود که به عنوان نسبت ظرفیت باربری پیش‌بینی شده (Q_c) به ظرفیت باربری اندازه‌گیری شده از آزمایش‌های دینامیکی شمع (Q_m) است. عملکرد پیش‌بینی ظرفیت باربری بر اساس ضریب مدل (Q_c/Q_m) با استفاده از ۱۵ شاخص آماری مطابق شکل‌های ۲ تا ۱۶ ارزیابی می‌شود. این شاخص‌ها شامل میانگین

(μ)، انحراف معیار (SD)، میانه، خطای مجذور میانگین ($RMSE$)، بازه اطمینان (CI)، واریانس، دامنه (R)، ضریب تغییرات (COV)، ضریب تعیین (R^2)، هیستوگرام فراوانی، خط بهترین تطبیق از مبدأ، دامنه میان‌چارکی (IQR)، و مقادیر مربوط به احتمالات ۵۰٪ و ۹۰٪ از هر دو تابع توزیع تجمعی (CDF) و تابع چگالی احتمال (PDF) هستند.


طبق نتایج به دست آمده از میانگین پیش‌بینی‌ها که در شکل ۲ ارائه شده است، الگوریتم NB و روش UWA با میانگین‌های به ترتیب ۱،۰۳۹ و ۰،۹۹۷ برای مقاومت نوک و جدار، بیش‌ترین تطابق را با نتایج آزمون‌های بارگذاری دینامیکی شمع از خود نشان داده‌اند. در مقابل الگوریتم SVR با میانگین‌های ۰،۴۱۹ برای مقاومت نوک و ۰،۶۴۸ برای مقاومت جدار، کمترین دقت را به لحاظ معیار میانگین داشته است.




شکل ۸. دامنه متغیر مدل (Qc/Qm) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی




شکل ۵. خطای جذر میانگین مربعات متغیر مدل (Qc/Qm) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی




شکل ۹. پراکندگی متغیر مدل (Qc/Qm) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی




شکل ۶. بازه اطمینان متغیر مدل (Qc/Qm) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی



شکل ۱۰. ضریب تعیین متغیر مدل (Qc/Qm) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی




شکل ۷. واریانس متغیر مدل (Qc/Qm) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی




(الف)


در ارزیابی انحراف معیار، که در شکل ۳ نشان داده شده، الگوریتم رگرسیون خطی (LR) و روش Fugro با انحراف معیارهای ۰,۱۳۴ و ۰,۱۵۹ برای مقاومت نوک و ۰,۱۵۹ و ۰,۱۳۴ برای مقاومت جدار کمترین پراکندگی را دارد، که به معنای پیش‌بینی‌های پایدارتر و متمرکزتر در این روش است. در مقابل، الگوریتم SVR با انحراف معیارهای ۰,۶۶ و ۱,۱۴۱ برای مقاومت نوک و جدار بیشترین پراکندگی را نشان می‌دهد، که به معنای نوسانات بیشتر در پیش‌بینی‌های این مدل‌ها است.




شکل ۱۳. دامنه چارکی متغیر مدل (Q_c/Q_m) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی




شکل ۱۴. تابع توزیع احتمال تجمعی (۵۰٪) متغیر مدل (Q_c/Q_m) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی



شکل ۱۵. تابع توزیع احتمال تجمعی (۹۰٪) متغیر مدل (Q_c/Q_m) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی




(ب)



(ج)

شکل ۱۱. هیستوگرام فراوانی متغیر مدل (Q_c/Q_m) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی:
(الف) هیستوگرام ظرفیت باربری نوک، (ب) هیستوگرام ظرفیت باربری جدار و (ج) تعداد داده در بازه ۰٫۸ تا ۱٫۲ متغیر مدل



شکل ۱۲. شیب خط گذرنده از مبدأ برازش داده شده از مقادیر متغیر مدل (Q_c/Q_m) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی

در مقایسه با آن، روش‌هایی چون SVR با بازه‌های ۰,۴۵۷ برای مقاومت نوک و ۰,۷۹۱ برای مقاومت جداری بالاترین مقادیر را دارند، که نشان‌دهنده عدم دقت در پیش‌بینی‌ها و نوسانات زیاد در نتایج این مدل‌ها است.

در ارزیابی واریانس پیش‌بینی‌ها، که در شکل ۷ ارائه شده است، الگوریتم LR با مقدار ۰,۰۱۸ برای مقاومت نوک و روش Fugro با واریانس ۰,۰۲۵ برای مقاومت جداری کمترین تنوع را نشان داد. این به معنای آن است که پیش‌بینی‌های این روش‌ها بیشتر ثابت و متمرکز هستند. در مقابل، روش SVR با واریانس‌های ۰,۴۳۵ برای مقاومت نوک و ۱,۳۰۳ برای مقاومت جداری بیشترین تنوع را از خود نشان داد.


در ارزیابی دامنه که در شکل ۸ نشان داده شده است، الگوریتم LR با دامنه ۰,۴۲۶ برای مقاومت نوک و الگوریتم NB با مقدار ۰,۴۷۷ برای مقاومت جداری کمترین دامنه را دارند، که نشان‌دهنده آن است که پیش‌بینی‌های این مدل‌ها در محدوده‌ای نسبتاً باریک قرار دارند و تغییرات زیادی در مقادیر پیش‌بینی شده مشاهده نمی‌شود. در مقایسه با آن، روش SVR با دامنه‌های ۱,۹۸۳ برای مقاومت نوک و ۳,۲۵۵ برای مقاومت جداری، بالاترین دامنه را از خود نشان داده که نشان‌دهنده تغییرات زیاد در پیش‌بینی‌ها است.

مطابق با شکل ۹ الگوریتم‌های LR و NB با پراکندگی ۰,۱۲۳ و ۰,۱۶۶ برای مقاومت به ترتیب نوک و جدار کمترین پراکندگی و بهترین عملکرد را در پیش‌بینی ظرفیت باربری شمع‌های فراساحلی مورد بررسی داشته‌اند. در مقابل الگوریتم NN با پراکندگی ۰,۴۷۱ برای مقاومت نوک و الگوریتم DT با پراکندگی ۰,۷۰۱ برای مقاومت جدار، غیر متمرکزترین پیش‌بینی‌ها را ارائه کرده‌اند.

شاخص ضریب تعیین (R^2) که در شکل ۱۰ آورده شده است، برای بررسی میزان تطابق پیش‌بینی‌ها با مقادیر واقعی استفاده

می‌شود. در اینجا، الگوریتم NB با R^2 برابر ۰,۹۶ برای مقاومت نوک و جداری بالاترین مقدار را دارد. این نشان می‌دهد که این الگوریتم توانسته پیش‌بینی‌هایی که با داده‌های واقعی همخوانی زیادی دارند، ارائه دهد. در مقابل، الگوریتم‌های SVR و NN با R^2 های کم‌تر از ۰,۵۲ برای مقاومت نوک و ۰,۱ برای مقاومت جداری عملکرد ضعیفی از خود نشان داده‌اند.

میان‌ه پیش‌بینی‌ها، که در شکل ۴ ارائه شده است، مقدار ۰,۹۸۷ برای الگوریتم NB در مقاومت نوک و مقدار ۰,۹۹ برای الگوریتم LGBM در مقاومت جداری را نشان می‌دهد. این مقادیر به طور کلی در مقایسه با سایر روش‌ها، نشان‌دهنده دقت بیشترین روش‌ها در حفظ پیش‌بینی‌های نزدیک به مقدار متوسط است. در مقابل، الگوریتم شبکه عصبی با میان‌ه ۰,۶۰۳ برای مقاومت نوک و الگوریتم SVR با میان‌ه ۱,۱۷۳ برای مقاومت جداری ضعیف‌ترین دقت پیش‌بینی را به لحاظ این معیار آماری داشته‌اند.



شکل ۱۶. تابع چگالی احتمال متغیر مدل (Qc/Qm) روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی

در ارزیابی دقت پیش‌بینی‌ها با استفاده از خطای جذر میانگین مربعات (RMSE)، که در شکل ۵ آمده است، نتایج نشان می‌دهند که روش API با RMSE برابر ۰,۰۳۴ برای مقاومت نوک و ۰,۰۳۰ برای مقاومت جداری کمترین خطای پیش‌بینی را دارد. همچنین روش Fugro با خطای ۰,۰۲۷ در پیش‌بینی ظرفیت باربری جداری عملکرد بسیار مطلوبی داشته است. در مقابل الگوریتم SVR با خطاهای به ترتیب ۰,۲۳۳ و ۰,۴۰۴ برای مقاومت نوک و جدار، کمترین دقت پیش‌بینی را ارائه می‌نماید.

یکی از شاخص‌های مهم در ارزیابی پیش‌بینی‌ها، بازه اطمینان است که در شکل ۶ ارائه شده است. این شاخص برای بررسی دقت پیش‌بینی‌ها در محدوده‌ای خاص به کار می‌رود. در اینجا، روش API با بازه اطمینان ۰,۰۶۶۷ برای مقاومت نوک و ۰,۰۵۹۷ برای مقاومت جداری کمترین بازه را دارد. این نشان‌دهنده آن است که پیش‌بینی‌های این روش دارای دقت بالایی در ارزیابی ظرفیت باربری هستند.

هیستوگرام فراوانی توزیع داده‌ها را با نمایش فراوانی یا فراوانی نسبی هر کلاس به صورت ستون‌هایی با ارتفاع‌های متغیر به تصویر می‌کشد.

این ابزار آماری برای ارزیابی دقت روش‌های پیش‌بینی، به‌ویژه در محدوده تحمل $\pm 20\%$ برای ظرفیت باربری، استفاده می‌شود. مطابق با شکل ۱۱ روش API با فرکانس ۳۰ در محدوده ۰٫۸ تا ۱٫۲ پارامتر مدل برای ظرفیت باربری نوک و روش Fugro با فرکانس ۳۴ برای ظرفیت باربری جداری متمرکزترین پیش‌بینی ظرفیت باربری شمع‌های مورد بررسی را ارائه نموده‌اند. نکته حائز توجه تمرکز بسیار بالای روش‌های تجربی (فرکانس بیش‌تر از ۲۵ برای تمامی روش‌ها در برآورد ظرفیت باربری نوک و جدار) و پراکندگی بالای کلیه الگوریتم‌های یادگیری ماشین مورد بررسی (فرکانس کم‌تر از ۷ برای تمامی الگوریتم‌ها در برآورد ظرفیت باربری نوک و جدار) است که مبین برتری روش‌های تجربی است.

مطابق شکل ۱۲ در خصوص شیب خط گذرنده از مبدأ برازش داده شده از مقادیر متغیر مدل، برای مقاومت نوک، الگوریتم SVR با شیب ۱٫۰۳ و برای مقاومت جدار روش ICP با شیب ۱٫۰۱۶ بهترین عملکرد را از خود نشان داده‌اند. در مقابل، NN (شبکه عصبی) با شیب به ترتیب ۰٫۵۵۸ و ۰٫۷۴۳ ضعیف‌ترین عملکرد را برای پیش‌بینی ظرفیت باربری نوک و جدار دارد که نشان‌دهنده نوسانات زیاد و دقت پایین این مدل در پیش‌بینی‌های ظرفیت باربری شمع‌های فراساحلی است.


مطابق با نتایج به‌دست‌آمده از دامنه میان‌چارکی (IQR) که در شکل ۱۳ ارائه شده است، برای ظرفیت باربری نوک، الگوریتم LGBM با IQR برابر ۰٫۱۱۱ و برای ظرفیت جداری الگوریتم NB با دامنه ۰٫۱۰۱، بهترین عملکرد را از خود نشان می‌دهند. این مقادیر کمترین دامنه میان‌چارکی را به نمایش می‌گذارد که نشان‌دهنده پیش‌بینی‌هایی با کمتر از نوسان و پراکندگی است. در مقابل، SVR با IQR به ترتیب ۰٫۸۱۵ و ۱٫۳۳ برای ظرفیت نوک و جدار بیشترین دامنه میان‌چارکی را برای مقاومت نوک دارد که نشان‌دهنده نوسانات بیشتر در پیش‌بینی‌ها و دقت پایین‌تر این مدل است.

طبق نتایج به‌دست‌آمده از تابع توزیع احتمال تجمعی (۵۰٪) که در شکل ۱۴ ارائه شده است، برای مقاومت نوک، الگوریتم DT با مقدار ۱٫۰۰۴ بهترین عملکرد را از خود نشان داده است. این مقدار نشان‌دهنده پیش‌بینی‌های دقیق و هم‌راستا با مقادیر واقعی





برای مقاومت نوک است، زیرا مقدار آن نزدیک به ۱ است. در مقابل، الگوریتم NN (شبکه عصبی) با مقدار ۰٫۵۴۶ ضعیف‌ترین عملکرد را برای پیش‌بینی مقاومت نوک دارد، که این مقدار پایین‌تر از دیگر مدل‌ها نشان‌دهنده پیش‌بینی‌های با دقت کمتر و نوسانات بیشتر در مقایسه با مقادیر واقعی است. برای مقاومت جدار، الگوریتم SVR با مقدار ۱٫۰۱۷ بهترین عملکرد را از خود نشان داده است. این مقدار مشابه با پیش‌بینی برای مقاومت نوک، نشان‌دهنده پیش‌بینی‌های دقیق و هم‌راستا با مقادیر واقعی برای مقاومت جدار است. همچنین، NN با مقدار ۰٫۶۶۶ پیش‌بینی‌های غیر دقیقی نسبت به دیگر مدل‌ها برای مقاومت جدار نشان می‌دهد.

مطابق توابع توزیع احتمال تجمعی (۹۰٪) روش‌ها و الگوریتم‌های مورد بررسی که در شکل ۱۵ ارائه شده است، الگوریتم NN و روش Fugro با مقدارهای ۰٫۹۲۵ و ۱٫۱۱ بهترین عملکرد را در پیش‌بینی ظرفیت باربری به ترتیب نوک و جدار از خود نشان داده‌اند. در مقابل، الگوریتم SVR با مقدار ۱٫۹۲۵ و ۲٫۶۷۳ برای ظرفیت نوک و جدار بدترین پیش‌بینی را دارد، که نشان‌دهنده پیش‌بینی‌هایی با انحرافات بیشتر از مقادیر واقعی است.

در خصوص تابع چگالی احتمال (PDF)، وضعیت ایده‌آل هنگامی است که نسبت پارامتر مدل برابر با ۱ باشد. با این حال، در عمل و به‌ویژه در کاربردهای ژئوتکنیکی که عدم قطعیت‌ها رایج است، دستیابی به این وضعیت بعید است. بنابراین، برای در نظر گرفتن تغییرپذیری نتایج، حدود بالایی و پایینی برای نسبت پارامتر تعیین می‌شود. تمرکز بیشتر داده‌ها در این حدود، نشان‌دهنده تغییرپذیری کمتر در روش و نزدیکی آن به شرایط ایده‌آل است. در این مطالعه، آستانه دقت $\pm 20\%$ انتخاب شده است و برای ارزیابی دقت روش‌ها و الگوریتم‌های مورد بررسی سطح زیر نمودار تابع در محدوده ۰٫۸ تا ۱٫۲ پارامتر مدل مطابق با شکل ۱۶ محاسبه می‌شود. مطابق شکل ۱۶ الگوریتم LR با سطح زیر منحنی ۲٫۰۵۶ برای ظرفیت نوک و الگوریتم NB با سطح زیر منحنی ۱٫۶۷۴ پیش‌بینی‌های دقیق و هم‌راستا با مقادیر واقعی ارائه کرده‌اند. در مقابل الگوریتم‌های DT و SVR با سطح زیر منحنی کم‌تر از ۰٫۲۱ برای ظرفیت‌های باربری محاسبه شده، کم‌ترین دقت پیش‌بینی را به لحاظ این معیار داشته‌اند.






شکل ۱۷. نمودار راداری روش‌های تجربی و الگوریتم‌های یادگیری ماشین مورد بررسی برای تخمین ظرفیت‌های باربری نوک و جداری: (الف) API، (ب) ICP، (ج) NGI، (د) Fugro، (هـ) UWA، (و) DT، (ز) LR، (ح) KNN، (ط) NN، (ی) BN، (ک) SVR، (ل) LGBM



مقایسه دقت روش‌ها بر مبنای معیارهای آماری مورد بررسی

امتیازهای مدل و نمودارهای راداری برای ارزیابی و رتبه‌بندی روش‌ها بر اساس دقت پیش‌بینی ظرفیت‌های باربری نوک و جدار استفاده می‌شوند. سیستم امتیازدهی به گونه‌ای تنظیم شده است که به دقت‌ترین روش پیش‌بینی برای هر معیار امتیاز ۱۲ اختصاص می‌دهد و روش‌هایی که دقت کمتری دارند، امتیاز کمتری دریافت می‌کنند. در خصوص معیار R^2 ، نتایج با مقادیر مشابه و نزدیک به یکدیگر (با دقت ۰,۰۵) معادل در نظر گرفته می‌شوند. بر اساس این امتیازها، نمودارهای راداری ساخته شده و در شکل ۱۷ نمایش داده می‌شوند که مقایسه بصری عملکرد پیش‌بینی در روش‌های مختلف را نشان می‌دهند. همچنین میانگین امتیازهای مدل روش‌ها و الگوریتم‌های مختلف مورد بررسی در جدول ۴ ارائه شده‌اند.



در خصوص پیش‌بینی ظرفیت باربری جدار، روش Fugro با میانگین امتیاز ۹٫۸۷ بالاترین دقت پیش‌بینی را به خود اختصاص داده است. پس از آن الگوریتم نایو بیز با میانگین امتیاز ۹٫۵۳ و روش‌های API و UWA با میانگین امتیاز یکسان ۹٫۲ عملکرد بسیار مناسبی در پیش‌بینی ظرفیت باربری جدار داشته‌اند. همچنین روش‌های ICP و NGI به ترتیب با میانگین امتیازهای ۷٫۷۳ و ۷٫۶۷ و الگوریتم LGBM با میانگین امتیاز ۷٫۱۳ در رده‌های بعدی قرار گرفته‌اند.


جدول ۴. میانگین امتیازهای مدل روش‌های تجربی و الگوریتم‌های

یادگیری ماشین مورد بررسی

روش	میانگین امتیاز مدل	
	ظرفیت باربری نوک	ظرفیت باربری جدار
API	۸٫۸۷	۹٫۲
ICP	۶	۷٫۷۳
NGI	۸٫۲۷	۷٫۶۷
Fugro	۵٫۸	۹٫۸۷
UWA	۶٫۱۳	۹٫۲
DT	۵٫۸	۳٫۰۷
LR	۹٫۸	۶٫۲۷
KNN	۷٫۳۳	۳٫۸
NN	۲٫۸	۲٫۸۷
SVR	۲٫۰۷	۲٫۴۷
LGBM	۶٫۴	۷٫۱۳
NB	۹٫۴	۹٫۵۳

در میان الگوریتم‌های یادگیری ماشین مورد بررسی، برخی الگوریتم‌ها عملکرد نسبتاً مناسبی از خود نشان داده‌اند، در حالی که برخی دیگر دقت پیش‌بینی پایینی داشته‌اند. به‌طور مشخص، الگوریتم‌های شبکه عصبی و ماشین بردار پشتیبان با میانگین امتیازهای کمتر از ۳ در هر دو حالت پیش‌بینی ظرفیت باربری نوک و جدار، ضعیف‌ترین عملکرد را در میان روش‌ها و الگوریتم‌های مورد بررسی داشته‌اند. همچنین الگوریتم درخت تصمیم و KNN نیز در پیش‌بینی ظرفیت باربری جدار دقت نسبتاً پایینی نشان داده‌اند.


یکی از نکات قابل توجه در تحلیل عملکرد الگوریتم‌های یادگیری ماشین در این پژوهش، محدودیت تعداد داده‌های موجود برای آموزش و ارزیابی مدل‌ها است. همان‌گونه که در بسیاری از مطالعات مرتبط با یادگیری ماشین مطرح شده است،



شکل ۱۷. (ادامه)

مطابق با شکل ۱۷ و جدول ۴، در خصوص پیش‌بینی ظرفیت باربری نوک، الگوریتم رگرسیون خطی با میانگین امتیاز ۹٫۸ بالاترین دقت پیش‌بینی را در میان روش‌ها و الگوریتم‌های مورد بررسی داشته است. پس از آن الگوریتم نایو بیز با میانگین امتیاز ۹٫۴ و روش API با میانگین امتیاز ۸٫۸۷ عملکرد بسیار مطلوبی در پیش‌بینی ظرفیت باربری نوک نشان داده‌اند. همچنین روش NGI با میانگین امتیاز ۸٫۲۷ و الگوریتم KNN با میانگین امتیاز ۷٫۳۳ در رده‌های بعدی از نظر دقت پیش‌بینی قرار دارند.

دینامیکی شمع در منطقه جنوب ایران بررسی شده است. روش‌های پیش‌بینی شامل روش‌های تجربی API، NGI، Fugro، UWA، ICP و همچنین هفت الگوریتم یادگیری ماشین شامل درخت تصمیم، رگرسیون خطی، نزدیک‌ترین همسایه (KNN)، شبکه‌های عصبی، رگرسیون بردار پشتیبان، گرادینان بوستینگ سبک و نایبو بیز بودند.



شکل ۱۸. تغییرات ظرفیت باربری جداری شمع‌های مورد مطالعه در پژوهش حاضر در طول زمان: (الف) کوتاه‌مدت و (ب) بلندمدت

۵- نتیجه‌گیری

نتایج حاصل از این پژوهش نشان می‌دهد که در پیش‌بینی ظرفیت باربری نوک شمع‌ها، الگوریتم رگرسیون خطی با بالاترین میانگین امتیاز، دقیق‌ترین عملکرد را در میان روش‌ها و الگوریتم‌های مورد بررسی داشته است. پس از آن، الگوریتم بیز ساده و روش API به ترتیب با دقت‌های بالا در رتبه‌های بعدی قرار می‌گیرند. همچنین روش NGI نیز عملکرد قابل قبولی در پیش‌بینی ظرفیت باربری نوک از خود نشان داده است. این نتایج بیانگر آن است که در شرایط داده‌ای محدود، مدل‌های ساده‌تر و مبتنی بر روابط خطی یا آماری می‌توانند عملکردی رقابتی و حتی برتر نسبت به برخی الگوریتم‌های پیچیده‌تر ارائه دهند. در خصوص پیش‌بینی ظرفیت باربری جدار، روش Fugro با بالاترین میانگین امتیاز، بهترین دقت پیش‌بینی را نشان داده است. پس از آن، الگوریتم بیز ساده و روش‌های API و بیانگر کار بسیار مطلوبی در پیش‌بینی ظرفیت باربری جدار داشته‌اند. این موضوع بیانگر کارایی بالای برخی روش‌های تجربی متداول و همچنین الگوریتم‌های آماری ساده در برآورد ظرفیت باربری جدار شمع‌ها در محیط‌های فراساحلی است. از سوی دیگر، نتایج نشان می‌دهد که الگوریتم‌های یادگیری ماشین پیچیده‌تری مانند

دقت و قابلیت تعمیم این الگوریتم‌ها تا حد زیادی به حجم داده‌های در دسترس وابسته است. در این پژوهش نیز تعداد داده‌های موجود نسبتاً محدود بوده و این موضوع می‌تواند بر عملکرد برخی از الگوریتم‌های پیچیده‌تر تأثیرگذار باشد. الگوریتم‌هایی مانند شبکه‌های عصبی و ماشین‌های بردار پشتیبان معمولاً برای دستیابی به عملکرد مطلوب نیازمند مجموعه داده‌های بزرگ‌تری هستند تا بتوانند الگوها و روابط غیرخطی موجود در داده‌ها را به درستی یاد بگیرند.

بنابراین محدود بودن تعداد داده‌ها می‌تواند یکی از دلایل اصلی عملکرد ضعیف‌تر برخی از الگوریتم‌های یادگیری ماشین در این مطالعه باشد. در چنین شرایطی، الگوریتم‌های ساده‌تر یا روش‌های تجربی که وابستگی کمتری به حجم زیاد داده‌های آموزشی دارند، ممکن است عملکرد بهتری از خود نشان دهند. از این رو، استفاده از مجموعه داده‌های گسترده‌تر در مطالعات آینده می‌تواند به بهبود دقت پیش‌بینی مدل‌های یادگیری ماشین و ارائه نتایج قابل اعتمادتر در پیش‌بینی ظرفیت باربری نوک و جدار منجر شود.

ضریب ست‌آپ شمع‌های فراساحلی

در خاک‌های رسی، ظرفیت باربری محوری شمع‌های کوبشی پس از نصب به صورت تدریجی و وابسته به زمان افزایش می‌یابد. این پدیده که با عنوان ست‌آپ شمع شناخته می‌شود، در نتیجه فرآیند تحکیم خاک، اتلاف فشار آب حفره‌ای اضافی و افزایش تنش مؤثر اطراف شمع رخ می‌دهد و معمولاً باعث افزایش قابل توجه مقاومت اصطکاکی جداره شمع می‌شود. اهمیت این پدیده در پروژه‌های فراساحلی بیشتر است، زیرا هزینه‌های بالای نصب و محدودیت‌های دسترسی لزوم پیش‌بینی دقیق ظرفیت باربری را افزایش می‌دهد. برای ارزیابی ست‌آپ، از آزمایش‌های دینامیکی PDA در فواصل زمانی مختلف (برای نمونه پس از ۱ روز، ۷ روز و ۳۰ روز) استفاده می‌شود تا تغییر ظرفیت باربری در طول زمان مشخص گردد.

بر اساس نتایج ارائه شده در شکل ۱۸، ظرفیت اصطکاکی جداره شمع‌های مورد بررسی در مقایسه بین نتایج کوتاه‌مدت و بلندمدت تا حدود ۴،۳۴ برابر افزایش یافته است که نشان‌دهنده بهبود چشمگیر عملکرد باربری شمع در طول زمان است.

در این تحقیق، عملکرد روش‌های مختلف پیش‌بینی ظرفیت باربری شمع‌های فراساحلی با استفاده از داده‌های آزمایش‌های

-Alwalan, M. F., & El Naggar, M. H. (2020). Analytical models of impact force-time response generated from high-strain dynamic load test on driven and helical piles. *Computers and Geotechnics*, 128, 103834.

-American Petroleum Institute (API). (2008). *API RP 2A-WSD: Recommended practice for planning, designing and constructing fixed offshore platforms—Working stress design (22nd ed.). API Publishing Services.

-API RP 2GEO. (2017). *Geotechnical and foundation design considerations*. American Petroleum Institute.

-ASTM. (2012). Standard test method for one-dimensional consolidation properties of saturated cohesive soils using controlled-strained loading. In *Standard D-4186. *ASTM International*.

-Benbouras, M. A., Lefilef, L., Zedira, H., Petrişor, A.-I., & Ghelani, L. (2021). Forecasting the bearing capacity of the driven piles using advanced machine-learning techniques. *Applied Sciences*, 11 (22), 10908.
doi.org/10.3390/app112210908

-Briaud, J. L., & Tucker, L. M. (1988). Measured and predicted axial response of 98 piles. *Journal of Geotechnical Engineering*, 114 (9), 984-1001.

-Bustamante, M., & Gianselli, L. (1982). Pile bearing capacity prediction by means of static penetrometer CPT. In *Proceedings of the 2nd European Symposium on Penetration Testing* (Vol. 2, 493–500).

-Cai, G., Liu, S., Tong, L., & Du, G. (2008). Assessment of direct CPT and CPTU methods for predicting the ultimate bearing capacity of single piles. *Engineering Geology*, 104 (3–4), 211–222.
doi.org/10.1016/j.enggeo.2008.10.010

-Cai, G., Liu, S., & Puppala, A. J. (2012). Reliability assessment of CPTU-based pile capacity predictions in soft clay deposits. *Engineering Geology*, 141–142, 84–91.
doi.org/10.1016/j.enggeo.2012.05.006

-Cathie, D., Jardine, R., Silvano, R., Kontoe, S., & Schroeder, F. (2023). Axial capacity ageing trends of large diameter tubular piles driven in sand. *Soils and Foundations*, 63 (6), 101401.
doi.org/10.1016/j.sandf.2023.101401

-Chakraborty, D., & Kumar, J. (2013). Bearing capacity of piles in soft clay underlain by cohesive frictional soil. *International Journal of Geomechanics*, 13, 311-317.
doi.org/10.1061/(ASCE)GM.1943-5622.0000211

-Chen, W., Zhang, T., Xu, L., Liu, C., Chen, G., & Wang, N. (2023-a). Vertical vibration characteristics of an offshore end-bearing pile embedded in saturated soils. *Applied Ocean Research*, *139*, 103688.
doi.org/10.1016/j.apor.2023.103688

شبکه عصبی و رگرسیون بردار پشتیبان در هر دو حالت پیش‌بینی ظرفیت باربری نوک و جدار، پایین‌ترین میانگین امتیازات را به خود اختصاص داده‌اند. عملکرد ضعیف این الگوریتم‌ها در مقایسه با روش‌های تجربی و برخی مدل‌های یادگیری ماشین ساده‌تر می‌تواند عمدتاً ناشی از محدودیت تعداد داده‌های موجود باشد، چرا که این الگوریتم‌ها برای یادگیری مؤثر الگوهای پیچیده به مجموعه داده‌های بزرگ‌تری نیاز دارند.

یکی از نتایج کلیدی این تحقیق، تأکید بر نقش تعیین‌کننده حجم داده‌های آموزشی و تست در دقت پیش‌بینی الگوریتم‌های یادگیری ماشین است. در این پژوهش، تنها ۳۶ داده برای پیش‌بینی در دسترس بوده که از این تعداد، ۲۸ داده برای آموزش و ۸ داده برای آزمون مدل‌ها مورد استفاده قرار گرفته است. چنین حجم محدودی از داده‌ها می‌تواند به‌ویژه برای الگوریتم‌های پیشرفته یادگیری ماشین منجر به کاهش قابلیت تعمیم و افت دقت پیش‌بینی شود. از این رو، افزایش حجم داده‌ها و توسعه پایگاه‌های داده جامع‌تر در مطالعات آینده می‌تواند به بهبود عملکرد این الگوریتم‌ها و دستیابی به نتایج دقیق‌تر منجر شود.

در نهایت، نتایج این مطالعه می‌تواند به عنوان یک راهنمای کاربردی برای مهندسان و پژوهشگران در انتخاب روش‌های مناسب جهت ارزیابی ظرفیت باربری شمع‌های فراساحلی، به‌ویژه در پروژه‌های عمرانی جنوب ایران و سایر مناطق با شرایط زمین‌شناسی مشابه، مورد استفاده قرار گیرد. همچنین این یافته‌ها می‌توانند زمینه‌ساز پژوهش‌های آتی در راستای بهبود و توسعه الگوریتم‌های یادگیری ماشین و ارائه روش‌های دقیق‌تر و قابل اعتمادتر برای پیش‌بینی ظرفیت باربری شمع‌ها در محیط‌های فراساحلی باشند.

۶- مراجع

-Aali, J., Rahimpour-Bonab, H., & Kamali, M. R. (2006). Geochemistry and origin of the world's largest gas field from Persian Gulf, Iran. *Journal of Petroleum Science and Engineering*, 50 (3–4), 161–175.
doi.org/10.1016/j.petrol.2005.12.004

-Abu-Farsakh, M. Y., & Titi, H. H. (2004). Assessment of direct cone penetration test methods for predicting the ultimate capacity of friction-driven piles. *Journal of Geotechnical and Geoenvironmental Engineering*, 130 (9), 935–944.
doi.org/10.1061/(asce)1090-0241(2004)130:9(935)

Persian Gulf. *Petroleum Geoscience*, 15 (4), 325–344.

doi.org/10.1144/1354-079309-817

-Fakharian, K., Shafiei, M., & Hafezan, S. (2022). Investigation of soil setup effects on pile response in clay considering overconsolidation ratio and installation method through physical modeling. *Canadian Geotechnical Journal*, 60 (4), 488–503.

-Fateh, A. M. A., Eslami, A., & Fahimifar, A. (2016). Direct CPT and CPTu methods for determining bearing capacity of helical piles. *Marine Georesources & Geotechnology*, 35 (2), 193–207.

doi.org/10.1080/1064119x.2015.1133741

-Fattahi, H., Ghaedi, H., Malekmahmoodi, F., & Armaghani, D. J. (2024). Optimizing pile bearing capacity prediction: Insights from dynamic testing and smart algorithms in geotechnical engineering. *Measurement*, 230, 114563.

doi.org/10.1016/j.measurement.2024.114563

-Fellenius, B. H., Tracy, G. R., Riker, R. E., & O'Brien, A. J. (1989). Dynamic and static testing in soil exhibiting set-up. *Journal of Geotechnical Engineering*, 115 (7), 984–1001.

doi.org/10.1061/(asce)0733-9410(1989)115:7(984)

-Finn, W. D. L., & Dowling, J. (2016). Modelling effects of pile diameter. *Canadian Geotechnical Journal*, 53 (1), 173–178.

doi.org/10.1139/cgj-2015-0119

-Fu, P., & Xie, K. (2019). Lateral vibration of offshore piles considering pile-water interaction. *International Journal of Structural Stability and Dynamics*, 19 (12), 1950147.

doi.org/10.1142/s0219455419501475

-Gavin, K., Igoe, D., & Doherty, P. (2011). Piles for offshore wind turbines: A state-of-the-art review. *Proceedings of the Institution of Civil Engineers - Geotechnical Engineering*, 64 (4), 245–256.

doi.org/10.1680/geng.2011.164.4.245

-Heidarie Golafzani, S., Jamshidi Chenari, R., & Eslami, A. (2020). Reliability based assessment of axial pile bearing capacity: Static analysis, SPT and CPT-based methods. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 14 (3), 216–230.

doi.org/10.1080/17499518.2019.1628281

-Hosseinzadeh Attar, I., & Fakharian, K. (2013). Influence of soil setup on shaft resistance variations of driven piles: Case study. *International Journal of Civil Engineering*, 11 (2), 112–121.

Jardine, R., Chow, F., Overy, R., & Standing, J. (2005). *ICP design methods for driven piles in sands and clays* (Vol. 112). Thomas Telford.

-Karlsrud, K., Clausen, C. J. F., & Aas, P. M. (2005). Bearing capacity of driven piles in clay, the NGI approach. In *Proceedings of the 1st International*

-Chen, L., Yao, Y., Liu, H., Liu, X., Wu, W., Mei, G., & El Naggar, M. H. (2023-b). Horizontal vibration characteristics of offshore twin-pile foundations. *Ocean Engineering*, 290, 116101.

doi.org/10.1016/j.oceaneng.2023.116101

-Choo, Y. W., & Kim, D. (2015). Experimental development of the p-y relationship for large-diameter offshore monopiles in sands: Centrifuge tests. *Journal of Geotechnical and Geoenvironmental Engineering*, 142 (1).

doi.org/10.1061/(asce)gt.1943-5606.0001373

Clausen, C. J. F., Aas, P. M., & Karlsrud, K. (2005). Bearing capacity of driven piles in sand, the NGI approach. In *Proceedings of the International Symposium on Frontiers in Offshore Geotechnics (ISFOG)*, Balkema. 677–681.

-de Ruiter, J., & Beringen, F. L. (1979). Pile foundations for large North Sea structures. *Marine Geotechnology*, 3 (3), 267–314.

-Ebrahimian, B., Movahed, V., & Nazari, A. (2014). Soil characterisation of South Pars field, Persian Gulf. *Environmental Geotechnics*, 1 (2), 96–107.

-Ebrahimian, B., Movahed, V., & Pasha, A. Y. (2012). Evaluation of undrained shear strength of marine clay using cone penetration resistance at South Pars field in Iran. *Ocean Engineering*, 54, 182–195.

-Ebrahimian, B., & Movahed, V. (2016). Application of an evolutionary-based approach in evaluating pile bearing capacity using CPT results. *Ships and Offshore Structures*, 12 (7), 937–953.

doi.org/10.1080/17445302.2015.1116243

-Ebrahimian, B., Nazari, A., & Pasha, A. Y. (2015). Evaluating ϵ_{50} for lateral load-displacement behavior of piles in clay. *Ocean Engineering*, 96, 149–160.

-Ebrahimipour, A., & Eslami, A. (2024). Analytical study of piles behavior for marine challenging substructures. *Ocean Engineering*, 292, 116514.

doi.org/10.1016/j.oceaneng.2023.116514

-Eslami, A., Aflaki, E., & Hosseini, B. (2011). Evaluating CPT and CPTu based pile bearing capacity estimation methods using Urmiyeh Lake Causeway piling records. *Scientia Iranica*, 18 (5), 1009–1019.

-Eslami, A., & Fellenius, B. H. (1997). Pile capacity by direct CPT and CPTu methods applied to 102 case histories. *Canadian Geotechnical Journal*, 34 (6), 886–904.

doi.org/10.1139/t97-056

-Eslami, A., & Fellenius, B. H. (2004). CPT and CPTu data for soil profile interpretation: Review of methods and a proposed new approach. *Iranian Journal of Science and Technology Transactions of Civil Engineering*, 28 (1), 69–86.

-Esrafil-Dizaji, B., & Rahimpour-Bonab, H. (2009). Effects of depositional and diagenetic characteristics on carbonate reservoir quality: A case study from the South Pars gas field in the

- Niazi, F. S., & Mayne, P. W. (2013). Cone penetration test based direct methods for evaluating static axial capacity of single piles. *Geotechnical and Geological Engineering*, 31 (4), 979–1009.
doi.org/10.1007/s10706-013-9662-2
- Niazi, F. S., & Mayne, P. W. (2016). CPTu-based enhanced UniCone method for pile capacity. *Engineering Geology*, 212, 21–34.
doi.org/10.1016/j.enggeo.2016.07.010
- Paikowsky, S. G., Baligh, M. M., & Whitman, R. V. (1989). A new look at the phenomenon of offshore pile plugging. *Marine Geotechnolgy*, 8 (3), 213–230.
doi.org/10.1080/10641198909379869
- Randolph, M. F. (2003). Science and empiricism in pile foundation design. *Géotechnique*, 53 (10), 847–875.
doi.org/10.1680/geot.53.10.847.37518
- Robertson, P. K. (1990). Soil classification using the cone penetration test. *Canadian Geotechnical Journal*, 27 (1), 151–158.
- Samson, L., & Authier, J. (1986). Change in pile capacity with time: Case histories. *Canadian Geotechnical Journal*, 23 (2), 174–180.
doi.org/10.1139/t86-027
- Sawant, V., Shukla, S., Sivakugan, N., & Das, B. (2013). Insight into pile set-up and load carrying capacity of driven piles. *International Journal of Geotechnical Engineering*, 7, 71–83.
doi.org/10.1179/1938636212Z.0000000004
- Saye, S., Lutenege, A., Brown, D., & Kumm, B. (2016). Influence of sample disturbance on estimated side resistance of driven piles in cohesive soils. *Journal of Geotechnical and Geoenvironmental Engineering*, 42, 04016043.
doi.org/10.1061/(ASCE)GT.1943-5606.0001517
- Schmertmann, J. H. (1978). *Guidelines for cone penetration test: Performance and design* (No. FHWA-TS-78-209). Federal Highway Administration.
- Schneider, J. A., Lehane, B. M., & Xu, X. (2008). Database assessment of CPT-based design methods for axial capacity of driven piles in siliceous sands. *Journal of Geotechnical and Geoenvironmental Engineering*, 134 (9), 1227–1244.
doi.org/10.1061/(asce)1090-0241(2008)134:9(1227)
- Schneider, J. A. (2007). *Analysis of piezocone data for displacement pile design* [Doctoral dissertation, University of Western Australia].
- Shahin, M. A. (2010). Intelligent computing for modeling axial capacity of pile foundations. *Canadian Geotechnical Journal*, 47 (2), 230–243.
doi.org/10.1139/t09-094
- Shamshirgaran, A. H., & Ebrahimian, B. (2018). Time effects on the axial compression bearing capacity of piles driven in offshore clays of Persian Gulf—A case study. In *The 3rd Iranian Conference on Geotechnical Engineering*. Tehran, Iran.
- Symposium on Frontiers in Offshore Geotechnics*, Taylor and Francis, 677–681.
- Kim, D., Lee, W., Salgado, R., Prezzi, M., & Bica, A. V. (2009). Load testing of a closed-ended pipe pile driven in multilayered soil. *Journal of Geotechnical and Geoenvironmental Engineering*, 135 (4), 463–473.
doi.org/10.1061/(asce)1090-0241(2009)135:4(463)
- Kolk, H. J., & Der Velde, E. (1996, May). A reliable method to determine friction capacity of piles driven into clays. In *Offshore Technology Conference* (OTC-7993). OTC.
- Kolk, H. J., & van der Velde, F. (2005). A reliable method to determine friction capacity of piles driven into clays. In *Proceedings Offshore Technology Conference*, 741–747.
- Lacasse, S., Nadim, F., Knudsen, S., Eidsvig, U. K., Liu, Z. Q., Yetginer, G., & Guttormsen, T. R. (2013). Reliability of axial pile capacity calculation methods. In *GéoMontréal 67th Canadian Geotechnical Conference* (Paper No. 699, Vol. 8).
- Lehane, B. M., Schneider, J. A., & Xu, X. (2005). The UWA-05 method for prediction of axial capacity of driven piles in sand. In *Frontiers in Offshore Geotechnics*, Balkema, 683–689.
- Liu, Y., Xu, P., Liu, X., Ma, S., & Huang, Z. (2024). Weakening characteristics of pile group foundations in clayey soil under vertical cyclic loading: Experimental and numerical investigation. *Ocean Engineering*, 313, 119317.
doi.org/10.1016/j.oceaneng.2024.119317
- Lunne, T., Powell, J. J. M., & Robertson, P. K. (2002). Cone penetration testing in geotechnical practice. *CRC Press*.
- Masud, N. B., Oluwatuyi, O. E., Wulff, S. S., Islam, M. S., Kalauni, H. K., & Ng, K. (2023). Evaluation of static load test systems for driven piles in intermediate geomaterials. *Transportation Research Record: Journal of the Transportation Research Board*, 2677 (10), 741–756.
doi.org/10.1177/03611981231163827
- Meyerhof, G. G. (1976). Bearing capacity and settlement of pile foundations. *Journal of the Geotechnical Engineering Division*, 102 (3), 197–228.
doi.org/10.1061/ajgeb6.0000243
- Moshfeghi, S., & Eslami, A. (2016). Study on pile ultimate capacity criteria and CPT-based direct methods. *International Journal of Geotechnical Engineering*, 12 (1), 28–39.
doi.org/10.1080/19386362.2016.1244150
- Mostafa, Y. E., & El Naggar, M. H. (2004). Response of fixed offshore platforms to wave and current loading including soil–structure interaction. *Soil Dynamics and Earthquake Engineering*, 24 (4), 357–368.
doi.org/10.1016/j.soildyn.2003.11.008
- Niazi, F. S. (2014). Static axial pile foundation response using seismic piezocone data [Doctoral dissertation, Georgia Institute of Technology].

-Wei, Y., Ke, Z., Wang, D., Wong, T., Li, J., Li, J., & Jie, Y. (2020). Evaluation of ultimate bearing capacity of pre-stressed high-strength concrete pipe pile embedded in saturated sandy soil based on in-situ test. *Applied Sciences*, 10 (18), 6269.

doi.org/10.3390/app10186269

-Xiong, W., Li, F., Li, Z., & Hu, D. (2024). Performance analysis of pile group installation in saturated clay. *Applied Sciences*, 14 (18), 8321.

doi.org/10.3390/app14188321

-Xu, D. S., Liu, Z. W., Chen, B., & Xu, X. Y. (2020). Bearing capacity analysis of offshore pipe piles with CPTs by considering uncertainly. *Computers and Geotechnics*, *126*, 103731.

-Xu, D.-S., Xu, X.-Y., Li, W., & Fatahi, B. (2019). Field experiments on laterally loaded piles for an offshore wind farm. *Marine Structures*, 69, 102684.

doi.org/10.1016/j.marstruc.2019.102684

-Yan, W., & Yuen, K. (2010). Prediction of pile set-up in clays and sands. *IOP Conference Series: Materials Science and Engineering*, 10, 012104.

doi.org/10.1088/1757-899X/10/1/012104

-Zafarjoo, A., & Amirabadi, R. (2023). Evaluation of seismic behavior of damaged offshore jacket platform under the environmental condition. *International Journal of Maritime Technology*, 18, 37-51.

-Zhang, B.-N., Han, B., He, B., & Guo, J. (2024). FDEM analysis of deep rock mass failure and its impact on horizontal bearing capacity in offshore wind turbine piles. *Ocean Engineering*, 302, 117638.

doi.org/10.1016/j.oceaneng.2024.117638

-Zhou, P., Li, J., Li, L., Liu, G., & Li, P. (2023). Investigation of the time-dependent bearing capacity of a jacked pile in saturated structured clays. *Computers and Geotechnics*, 61, 105599.

doi.org/10.1016/j.compgeo.2023.105599

-Zhou, Z., Han, D., Jiang, P., Dong, Y., & Liu, T. (2019). Calculation of pile side friction by multiparameter statistical analysis. *Advances in Civil Engineering*, 1-12.

doi.org/10.1155/2019/2638520

-Shamshirgaran, A. H., & Ebrahimian, B. (2021). Assessment of time effects on compressive bearing capacity of steel pipe piles driven in clay deposits of Persian Gulf. *International Journal of Maritime Technology*, 16, 1-12.

-Shoaib, M. M., & Abu-Farsakh, M. Y. (2023). Exploring tree-based machine learning models to estimate the ultimate pile capacity from cone penetration test data. *Transportation Research Record: Journal of the Transportation Research Board*, 2678 (1), 136-149.

doi.org/10.1177/03611981231170128

-Tavenas, F., & Audy, R. (1972). Limitations of the driving formulas for predicting the bearing capacities of piles in sand. *Canadian Geotechnical Journal*, 9 (1), 47-62.

-Tang, C., & Phoon, K. K. (2017). Model uncertainty of Eurocode 7 approach for bearing capacity of circular footings on dense sand. *International Journal of Geomechanics*, 17 (3), 04016069.

-Tarawneh, B., & Imam, R. (2014). Regression versus artificial neural networks: Predicting pile setup from empirical data. *KSCE Journal of Civil Engineering*, 18 (4), 1018-1027.

doi.org/10.1007/s12205-014-0072-7

-Wang, J., Zhou, D., Ji, T., & Wang, S. (2017). Horizontal dynamic stiffness and interaction factors of inclined piles. *International Journal of Geomechanics*, *17*(9), 04017075.

-Wang, X., Zeng, X., & Li, J. (2018). Assessment of bearing capacity of axially loaded monopiles based on centrifuge tests. *Ocean Engineering*, 167, 357-368.

doi.org/10.1016/j.oceaneng.2018.08.063

-Wang, Y., Jin, J., Han, B., Jiang, Y., Jeng, D., Liu, H., Liang, Z., & Cui, L. (2023). Distribution and dissipation laws of excess pore water pressure based on pile-soil interface during pile-sinking in saturated clay. *Soil Dynamics and Earthquake Engineering*, 167, 107807.

doi.org/10.1016/j.soildyn.2023.107807

Evaluation of the Accuracy of Empirical Methods and Machine Learning Algorithms in Determining the Bearing Capacity of Driven Piles in Southern Iran

*Mohammad Mehdi Bayat Tork, Ph.D., Student, Department of Civil Engineering,
CT.C., Islamic Azad University, Tehran, Iran.*

*Amirali Zad, Associate Professor, Department of Civil Engineering,
CT.C., Islamic Azad University, Tehran, Iran.*

*Babak Ebrahimian, Department of Geotechnical Engineering, Faculty of Civil,
Water and Environmental Engineering, Shahid Beheshti University (SBU), Tehran, Iran.*

E-mail: amir.zad@iaau.ac.ir

Received: March 2026- Accepted: August 2026

ABSTRACT

Offshore piles are one of the fundamental components in marine construction projects and are responsible for providing strength and stability to structures against applied loads. Therefore, accurate prediction of the bearing capacity of these piles is of great importance in the design and construction of offshore structures. In this study, the accuracy of different methods for predicting the bearing capacity of steel piles installed in offshore soil deposits of southern Iran is evaluated and compared. For this purpose, in addition to conventional empirical static design methods such as the API approach and cone penetration test (CPT)-based methods including NGI, ICP, UWA, and Fugro, seven machine learning (ML) algorithms were also assessed. These algorithms include Decision Tree (DT), Linear Regression (LR), K-Nearest Neighbors (KNN), Neural Networks (NN), Support Vector Regression (SVR), Light Gradient Boosting Machine (LGBM), and Naïve Bayes (NB). The results indicate that the Linear Regression (LR) algorithm provides the highest accuracy in predicting the pile tip bearing capacity, followed by the NB algorithm and the API method. Regarding the prediction of pile shaft bearing capacity, the Fugro method demonstrates the best performance, while the NB algorithm and the UWA and API methods rank in the subsequent positions.

Keywords: Offshore Pile Bearing Capacity, Machine Learning Algorithms, Linear Regression, Neural Networks, Support Vector Regression, PDA Analysis, Empirical Methods, South Pars