

مقایسه عملکرد روش‌های هوشمند شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان در شناسایی خودکار اهداف استوانه‌ای پنهان در تصاویر رادار نفوذی به زمین

رضا احمدی^{۱*}، نادر فتحیان‌پور^۲، غلامحسین نوروزی^۳

۱- دانشجوی دکترای مهندسی معدن دانشگاه تهران- عضو هیئت علمی دانشگاه صنعتی اراک، ایران

۲- دانشیار دانشکده مهندسی معدن دانشگاه صنعتی اصفهان، ایران

۳- استاد دانشکده مهندسی معدن دانشگاه تهران، ایران

(دریافت ۲۶ اردیبهشت ۱۳۹۳، پذیرش ۱۲ مهر ۱۳۹۳)

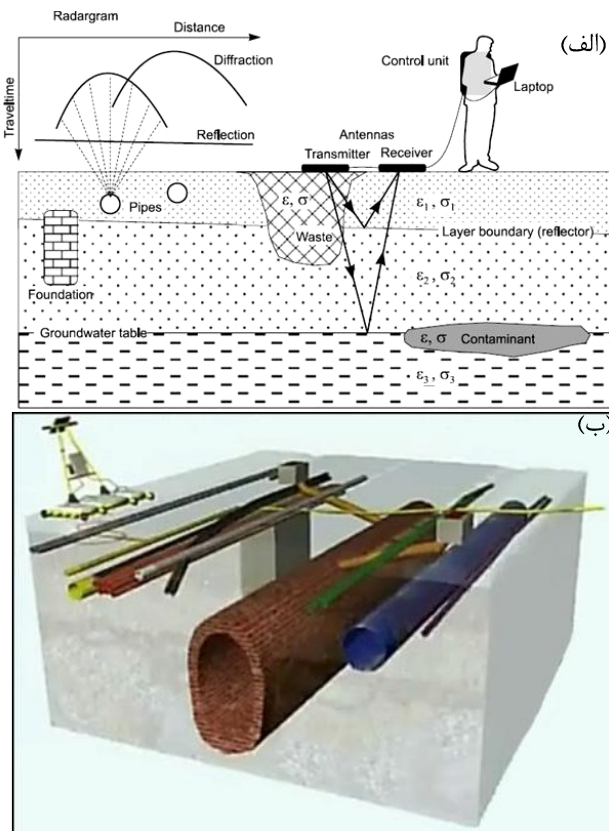
چکیده

در مطالعه حاضر از روش غیرمخرب و با قدرت تفکیک زیاد رادار نفوذی به زمین (GPR) جهت آشکارسازی و شناسایی مشخصات هندسی اهداف به شکل استوانه افقی مدفون همانند انواع ساختارهای تونلی، استفاده شده است. دستیابی به چنین مقصودی براساس تعیین ارتباط بین مشخصات هندسی اهداف استوانه‌ای مدفون و پارامترهای هذلولی پاسخ GPR مربوطه، با استفاده از روش‌های هوشمند شبکه‌های عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) صورت پذیرفته است. برای این منظور ابتدا پاسخ سیستم GPR برای ۱۹۴ مدل مصنوعی مختلف شامل اشیاء استوانه‌ای شکل متناظر با اهداف ژئوتکنیکی متداول (ساختارهای استوانه‌ای همچون تونل‌ها، کانال‌ها، قنات‌ها و خطوط لوله)، با استفاده از مدل‌سازی پیشرو به روش تفاضل محدود دوبعدی بهبودیافته، مدل‌سازی شد. سپس از نتایج آن با استفاده از الگوریتم تجزیه مقدار تکین، ویژگی‌های متمایز و منحصربه‌فرد شامل مقادیر ویژه و نرم مقادیر ویژه ماتریس تصاویر GPR در راستای افقی (فضای بین تریسی) و عمودی (فضای درون تریسی) استخراج گردید و به عنوان داده‌های ورودی در الگوریتم‌های ANN و SVM جهت تخمین مشخصات هندسی شامل شعاع، موقعیت افقی و موقعیت قائم (عمق دفن) اهداف استوانه‌ای مدفون، مورد استفاده قرار گرفت. عملکرد روش‌های استفاده شده، برای تصاویر واقعی GPR در حضور نوفه‌ها نیز ارزیابی شد و نتایج قابل قبولی حاصل گردید به گونه‌ای که ANN و SVM پارامترهای هندسی هدف معین مدفون را با متوسط خطای به ترتیب ۵ و ۹ درصد تخمین زدند. نتایج پژوهش حاضر نشان می‌دهد که هر دو روش هوشمند مورد استفاده، قابلیت کاربرد برجای، سریع، دقیق و خودکار را برای اهداف ژئوتکنیکی واقعی دارا می‌باشند هرچند در مجموع روش ANN نسبت به روش SVM از خطای کمتر و در نتیجه قدرت تخمین بالاتر پارامترهای هندسی اهداف استوانه‌ای مدفون برخوردار است.

کلمات کلیدی: رادار نفوذی به زمین (GPR)؛ اهداف استوانه‌ای؛ پارامترهای هندسی؛ شبکه عصبی مصنوعی (ANN)؛ ماشین بردار پشتیبان (SVM)

۱- مقدمه

برای تعیین موقعیت پیک آنومالی‌های هذلولوی مربوط به اهداف مدفون نظیر لوله و مین‌های زمینی، به کار بردند [۳].



شکل ۱: الف) اصول روش و برداشت داده‌های GPR به روش پروفیل-زنی بازتابی فاصله ثابت برای آشکارسازی اهداف مختلف [۱]، ب) بعضی از کاربردهای ژئوتکنیکی روش GPR.

آنها از داده‌های دو سایت آزمایشی برای آموزش شبکه عصبی استفاده کرده و نتایج را نیز بر روی همان سایت‌ها آزمایش نمودند. گامبا^{۱۰} و بلوتی^{۱۱} (۲۰۰۳) از دو رویکرد شبکه عصبی و تطبیق الگو^{۱۲} برای آشکارسازی و تحلیل داده‌های GPR با هدف شناسایی موقعیت لوله‌های مدفون در نواحی شهری استفاده کردند. ورودی شبکه عصبی بخشی از تصویر باینری شده است که از تصویر GPR پیش‌پردازش شده، اقتباس می‌شود. برای استفاده از تکنیک تطبیق الگو، یک پایگاه داده از هذلولی‌های با ابعاد مختلف تهیه شده؛ با انتخاب هریک از رخدادهای هذلولی شکل موجود در تصویر GPR به‌طور دستی توسط عملگر^{۱۳}، مناسب‌ترین هذلولی از پایگاه داده‌ها بر آن انطباق می‌یابد [۴]. بزرگ‌ترین محدودیت این روش، محدود بودن انتخاب، تنها به هذلولی‌های موجود در پایگاه داده و دستی (غیرخودکار) بودن آن است. پاسولی^{۱۴} و همکاران (۲۰۰۹) از یک فرآیند تکرار مبتنی بر سیستم ژنتیک الگوریتم

رادار نفوذی به زمین^۱ (GPR) یک روش ژئوفیزیکی با قدرت تفکیک زیاد است که با ارسال امواج الکترومغناطیسی^۲ (EM) با فرکانس زیاد (در محدوده فرکانس یک مگاهرتز تا بیش از یک گیگاهرتز) به درون زمین و دریافت امواج بازتابی حاصل، به آشکارسازی و شناسایی ویژگی‌های ساختارهای مدفون در درون زمین می‌پردازد. GPR دارای طیف وسیعی از کاربردها در اغلب زمینه‌های مهندسی است و یکی از مهمترین کاربردهای آن در زمینه مهندسی ژئوتکنیک است که به‌طور ویژه هدف آن آشکارسازی و شناسایی انواع ساختارهای استوانه‌ای (شامل انواع تونل‌ها، کانال‌ها، قنات‌ها و مجراهای عبور آب و فاضلاب که در اغلب موارد نیز در زیر شاهراه‌های نواحی شهری قرار دارند) می‌باشد.

شکل ۱ اصول روش GPR، شیوه برداشت داده‌ها، نحوه ارائه نتایج بصورت یک تصویر و بعضی از کاربردهای متداول آن را نشان می‌دهد. برداشت داده‌های GPR معمولاً از طریق سه مد صورت می‌گیرد که متداول‌ترین شیوه عملیات برداشت، مطابق شکل ۱ پروفیل‌زنی بازتابی فاصله ثابت تک حالت است. متداول‌ترین شیوه نمایش داده‌های GPR، نمایش دامنه سیگنال امواج الکترومغناطیسی بازتابی، در مقابل زمان تاخیر است که رد^۳ (تریس) نامیده می‌شود. در حالت کلی، نگاشت راداری^۴ یک برداشت پروفیلی داده‌های GPR، مجموعه‌ای از تریس‌های بازتابی می‌باشد و رخداد حاصل در تصویر نیز برای اغلب اهداف مدفون، به‌صورت هذلولی است (شکل ۱الف). برای آشکارسازی فرض می‌شود که دامنه سیگنال‌های بازتابیده از ناهمگنی‌های زیرسطحی، از سیگنال‌های زمینه بزرگتر می‌باشند.

به‌منظور استخراج اطلاعات مطلوب از داده‌های خام (تصاویر) GPR، علاوه بر پیش‌پردازش‌های معمول و متداول ضروری، نیاز به اعمال پردازش‌های پیشرفته، سریع و موثر از جمله تکنیک‌های شناخت الگو^۵ می‌باشد. تکنیک‌های شناخت الگو در موارد معدودی در ارتباط با تصاویر GPR بکار گرفته شده، هرچند که هر مورد دارای محدودیت‌ها و کاستی‌هایی است، در تمامی آنها نتایج قابل قبولی ارائه نموده است که از جمله آنها کپینری^۶ و همکاران (۱۹۹۸) از تبدیل کلاسیک هاف^۷ به منظور شناسایی بخش‌های خطی در تصویر GPR استفاده نمودند [۲]. ال-نوامی^۸ و همکاران (۲۰۰۰) یک طبقه‌بندی-کننده شبکه عصبی^۹ (ANN) را برای شناسایی نواحی بالقوه شامل هدف و تبدیل هاف را به عنوان یک تکنیک شناخت الگو،

واهمامیخت پیشگو^{۲۴} که یکی از روش‌های متداول حذف چندگانه‌ها (نوفه‌های چندگانه) در روش‌های لرزه‌ای و نیز بعضاً در روش‌های الکترومغناطیسی می‌باشد برای تضعیف امواج چندگانه ایجاد شده توسط میله‌های فولادی مدفون در ساختارهای بتن مسلح، در تصاویر مصنوعی ایجاد شده توسط روش تفاضل محدود حوزه زمان^{۲۵} (FDTD) استفاده کردند. سپس برای تشخیص خودکار حفرات در تصاویر پیش‌پردازش شده، از الگوریتم SVM استفاده نمودند [۱۱]. روش آنها صرفاً برای تصاویر مصنوعی آزمایش شده است.

در پژوهش حاضر با استفاده از روش‌های داده‌کاوی در شناسایی الگو، شامل روش‌های هوشمند ANN و رگرسیون ماشین بردار پشتیبان^{۲۶} (SVR)، براساس ایده‌های نو، اهداف پنهان در تصاویر رادار نفوذی به زمین، بطور کامل شناسایی می‌شوند.

۲- مدل‌سازی عددی پیشرو داده‌های GPR به روش تفاضل محدود

هدف از انجام پژوهش حاضر شناسایی اهداف استوانه‌ای مدفون، تحت شرایط مختلف محیطی براساس اطلاعات معقول داده‌های GPR می‌باشد. برای دستیابی به این هدف می‌توان از روش‌های عددی مختلفی نظیر ردیابی پرتو^{۲۷}، تکنیک‌های حجم محدود، تبدیل Z^{۲۸}، اجزاء گسسته^{۲۹} [۱۲]، و تکنیک‌های عبور-بازتاب یک تا سه‌بعدی تفاضل محدود [۱۳، ۱۴، ۱۵، ۱۶] به منظور مدل‌سازی و شبیه‌سازی، استفاده نمود که در همه آنها انتشار و بازتاب امواج GPR در درون زمین، براساس رفتار امواج الکترومغناطیسی و نحوه عملکرد آنها با مواد زیرسطحی، شبیه‌سازی می‌شود. روش تفاضل محدود به دلیل دارا بودن مزیت‌هایی نظیر درک نسبتاً ساده مفاهیم آن، انعطاف‌پذیری، قابلیت شبیه‌سازی و مدل‌سازی محیط‌های پیچیده و قابل قبول بودن پاسخ‌های آن در موارد بکار رفته، در میان روش‌های عددی مذکور، کاربرد بیشتری یافته و بنابراین در این پژوهش نیز از روش تفاضل محدود دوبعدی استفاده شده است.


برای مدل‌سازی پیشرو دوبعدی داده‌های GPR به روش تفاضل محدود، بازتاب امواج GPR ارسالی از سطح زمین (فرستنده و گیرنده هر دو بر روی سطح زمین)، با استفاده از فرمول‌بندی روش میدان مغناطیسی عرضی^{۳۰} (مد TM)، شبیه‌سازی می‌شود.

تئوری پایه کدهای مدل‌سازی پیشرو GPR، معادلات کرل ماکسول در حوزه فرکانس می‌باشند که عبارتند از:

$$\nabla \times E = -i\omega\mu H \quad (1)$$

$$\nabla \times H = \sigma E + i\omega\epsilon E \quad (2)$$

برای آشکارسازی اشیاء و یک طبقه‌بندی کننده ماشین بردار پشتیبان^{۱۵} (SVM) به عنوان یک سیستم شناخت الگو برای طبقه‌بندی (نوع اشیاء)، در مورد تصاویر مصنوعی و با هدف کار در زمینه باستان‌شناسی استفاده نمودند [۵]. الگوریتم آنها صرفاً برای تصاویر مصنوعی GPR آزمایش شده است. سانتوز^{۱۶} و همکاران (۲۰۰۹) یک طبقه‌بندی کننده پرسپترون چندلایه‌ای را براساس ویژگی‌های استخراج شده از اهداف مدفون در زیر خاک به منظور شناسایی اهداف فلزی از غیرفلزی طراحی کردند [۶]. این روش تنها قادر به شناسایی فلز از غیرفلز است. کوی^{۱۷} و همکاران (۲۰۱۰) یک سیستم آشکارسازی ویژگی و تطبیق الگو را برای شناسایی تصاویر GPR به کار گرفتند. استراتژی منطق فازی برای انطباق ویژگی‌های آشکار شده از تصویر بر ویژگی‌های موجود در پایگاه داده‌های الگو، برای شناسایی مورد استفاده قرار گرفت [۷]. در این مورد نیز یک پایگاه داده از یک سری ویژگی‌های الگوهای شناخته شده، ایجاد گردیده و کار تطبیق الگو با استفاده از منطق فازی و با استفاده از این ویژگی‌های الگوهای موجود در پایگاه داده، صورت می‌گیرد. کباشیگاوا^{۱۸} و همکاران (۲۰۱۱) از دو روش شبکه‌های عصبی و برنامه‌نویسی ژنتیکی برای طبقه‌بندی اشیاء از نوع مهمات منفجر نشده از سایر اشیاء دیگر، استفاده نمودند و نتیجه‌گیری کردند که روش برنامه‌نویسی ژنتیکی نسبت به شبکه عصبی، عملکرد بهتری داشته است. تابع هدف آنها، میزان خطای مربوط به عدم انطباق خروجی داده‌های آزمایش با طبقه واقعی تصاویر GPR (مهمات) می‌باشد [۸]. لیان^{۱۹} و لی^{۲۰} (۲۰۱۱) از یک روش کاهش نوفه آستانه‌ای مبتنی بر موجک برای پیش‌پردازش داده‌های GPR استفاده کرده و سپس از تبدیل هاف برای شبیه‌سازی هذلولی و تعیین موقعیت لوله‌های زیرسطحی استفاده نمودند. در نهایت از روش SVM برای طبقه‌بندی هذلولی‌های شبیه‌سازی شده، استفاده کرده و از نتایج آنها برای طبقه‌بندی قطر لوله‌ها بهره بردند. مولفین به منظور جداسازی پاسخ هذلولی‌گون از نوفه زمینه، از مولفه‌های ضرایب تبدیل موجک با عدد موج بالا (نوفه) و فیلتر پایین‌گذر هموارساز برای برجسته‌سازی پاسخ آنومالی‌های هذلولی‌گون استفاده کردند. آنها برای تایید روش خود از نتایج آزمایشگاهی نیز استفاده نمودند [۹]. هبسر^{۲۱} و همکاران (۲۰۱۳) از روش GPR و سیستم طبقه‌بندی با استفاده از روش SVM برای اکتشافات ژئوتکنیکی استفاده کردند. برای طبقه‌بندی SVM ورودی‌ها از طریق اعمال تبدیل هیلبرت^{۲۲} به دامنه‌های سیگنال بعد از انجام پردازش پیشرفته بر روی داده‌ها، حاصل شدند [۱۰]. زیونگ‌یانو^{۲۳} و همکاران (۲۰۱۳) از روش



شکل ۲. پاسخ نوعی سیستم GPR به صورت هذلولی، برای یک هدف مدفون به شکل استوانه افقی (در مقطع دوبعدی)، همراه با نمایش پارامترهای هندسی آن در حوزه مکانی.

۴- بکارگیری روش‌های شناخت الگو برای تصاویر GPR

مطابق تعریف واتاناب^{۳۱}، الگو درست مخالف بی‌نظمی تعریف می‌شود [۱۹]. مثلاً یک اثر انگشت دارای یک الگو می‌باشد. شناخت الگو شاخه‌ای از علم مهندسی برق است که موضوع بحث آن شامل مطالعه چگونگی مشاهدات محیطی توسط ماشین، نحوه یادگیری شناسایی الگوهای مورد نظر (هدف) از زمینه و تصمیم‌گیری معقول و مطمئن در خصوص طبقه الگوها می‌باشد. شناخت الگو به عنوان بهترین روش ممکن جهت به-کارگیری سنجنده‌های در دسترس، پردازش‌گرها و روابط موجود در محدوده تحت بررسی، جهت تصمیم‌سازی خودکار، به حساب می‌آید. انواع تکنیک‌های شناخت الگو با استفاده از الگوریتم‌های مختلف و با اعمال محدودیت‌های مناسب، قادر به حل مشکل هم‌ارزی پاسخ اهداف مختلف در تصاویر GPR می‌باشند. روش‌های هوشمند شناخت الگو در نیمه دوم قرن بیستم مطرح شده و به سرعت عمومیت پیدا کردند به گونه‌ای که در اواخر دهه هشتاد، کاربرد همه‌جانبه پیدا نمودند. این روش‌ها تکنیک‌های محاسباتی یادگیر هستند که به کمک آنها می‌توان یک نگاشت خاص را تقریب زد و یا داده‌های مختلف را طبقه‌بندی نمود. شبکه‌های عصبی و ماشین بردار پشتیبان از جمله روش‌های هوشمند، سریع و کاربردی شناخت الگو می‌باشند که در مطالعه حاضر به منظور شناسایی اهداف استوانه‌ای مدفون در تصاویر GPR مورد استفاده قرار می‌گیرند.

۴-۱- روش شبکه‌های عصبی مصنوعی (ANNs)

۴-۱-۱- مبانی شبکه‌های عصبی

شبکه‌های عصبی به منظور یافتن ارتباطات پنهان در میان داده‌های حجیمی که سازگار نیز باشند مورد استفاده قرار می‌گیرند و معمولاً به عنوان ابزاری برای طبقه‌بندی می‌باشند.

که در آن $i = \sqrt{-1}$ ، ω فرکانس زاویه‌ای، ϵ گذردهی دی-الکتریک، μ نفوذپذیری مغناطیسی و σ هدایت الکتریکی بوده، E و H نیز به ترتیب بردارهای شدت میدان الکتریکی و شدت میدان مغناطیسی می‌باشند.

از آنجایی که در عمل اغلب ساختارهای ژئوتکنیکی نظیر ساختارهای تونلی شامل انواع تونل‌ها، کانال‌ها و قنات‌ها، به صورت استوانه‌ای شکل می‌باشند بنابراین مدل‌سازی عددی پیشرو به روش تفاضل محدود دوبعدی بهبود یافته، جهت شبیه‌سازی پاسخ GPR برای اشیای مصنوعی فرضی به شکل استوانه افقی، با طراحی مناسب و کدنویسی‌های لازم، صورت گرفت تا علاوه بر سهولت و تسریع در عملیات ورود مشخصات هندسی و فیزیکی مدل به نرم‌افزار، سرعت اجرای برنامه الگوریتم‌های معمول را افزایش داده و در نتیجه زمان کل محاسبات کاهش یابد [۱۷، ۱۸]. تمام کدهای مورد نیاز توسط مولفین این مقاله، در محیط MATLAB آماده شده و کافی است که با اجرای این کدها و وارد نمودن مقادیر ویژگی‌های الکتریکی و مغناطیسی (نفوذپذیری مغناطیسی نسبی μ_r ، گذردهی دی الکتریک نسبی ϵ_r و هدایت الکتریکی σ) محیط میزبان و هدف، ابعاد مدل GPR (طول و عمق)، فواصل گسسته‌سازی مکانی و فرکانس مرکزی آنتن، مدل مورد نظر، انتخاب شود.

۳- پارامترهای هندسی و پاسخ GPR مدل استوانه‌ای

یکی از مهم‌ترین مسائل در طراحی‌ها و تصمیم‌گیری‌های مهندسی، شناسایی و استخراج پارامترهای هندسی ناهمگنی-های زیرسطحی مدفون است که تاحدودی با استفاده از روش-های ژئوفیزیکی نظیر GPR قابل حل می‌باشد. همان‌طور که قبلاً نیز آورده شد پاسخ سیستم GPR برای اغلب اشیاء مدفون (به‌ویژه اهداف استوانه‌ای) مطابق شکل ۲ به صورت هذلولی است که در این شکل شعاع استوانه افقی، X موقعیت مکانی افقی راس هذلولی و Z موقعیت مکانی قائم یا عمق دفن (فاصله از سطح زمین تا مرکز استوانه) می‌باشند.

در بخش‌های بعدی با استفاده از روش‌های ANN و SVR از روی پاسخ GPR مدل‌های مصنوعی استوانه‌ای شکل و براساس روابط پنهان موجود بین پاسخ هذلولی شکل با مشخصات هندسی مدل شامل شعاع، موقعیت افقی و عمق دفن، پارامترهای هندسی اهداف نامعین، بطور خودکار تخمین زده می‌شوند.

پر از هوا و محیط میزبان تمام مدل‌ها، همواره خاک رس سیلتی با مشخصات فیزیکی $\epsilon_r=6$ ، $\mu_r=1$ و $\sigma=6.67\text{mS/m}$ انتخاب شده است.

به منظور به‌کارگیری شبکه‌های عصبی لازم است تا داده‌های ورودی مناسب و پارامترهای هندسی اهداف معین توسط شبکه، آموزش داده شوند. داده‌های تولید شده در مرحله قبل، به روش مرتب - سازی بر حسب خروجی‌ها به سه بخش آموزشی (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون (۱۵ درصد) تقسیم شدند. از آنجایی که پاسخ GPR اغلب اهداف زیرسطحی در تصاویر نگاشت‌های راداری، به صورت هذلولی‌گون با ویژگی‌های آماری بسیار نزدیک و مشابه می‌باشند لذا باعث کاهش کارایی روش‌های تشخیص الگوی مبتنی بر آماره‌های توصیفی تصاویر می‌گردد. بنابراین لازم است که ابتدا ویژگی‌های مشخصه و منحصر به فرد تصاویر، استخراج گردیده و توسط شبکه، آموزش داده شوند. یادآوری می‌شود که یکی از خصوصیات مهم ویژگی‌های مورد نیاز در فرآیند آموزش شبکه عصبی، یکتا بودن آنها است.

مراحل پیش‌پردازش و مدل‌سازی داده‌های GPR به روش شبکه عصبی

از آنجایی که شبکه‌های عصبی متداول برای دریافت داده‌های ورودی، به صورت برداری طراحی شده‌اند بنابراین لازم است که ابتدا از روش‌هایی، به منظور استخراج ویژگی‌های موجود در تصاویر GPR به صورت برداری، استفاده نمود. بدین منظور پاسخ‌های مصنوعی GPR تعداد ۱۹۴ مدل مختلف حاوی اشیاء استوانه‌ای افقی در مقاطع دایره‌ای، به صورت تابعی از پارامترهای هندسی مدل، مورد استفاده قرار گرفت که پارامترهای هندسی با اهمیت به ترتیب شامل شعاع (R)، عمق دفن مرکز استوانه (Z) و موقعیت افقی (X) می‌باشند (شکل ۲). سپس ابعاد هندسی طول پروفیل‌ها و پنجره زمانی مقاطع GPR بی‌بعد گردیده و به محدوده صفر تا یک تبدیل یافتند. این عمل جهت قابلیت تعمیم و مقایسه با پروفیل‌های با ابعاد مختلف، ضروری می‌باشد.

به منظور بالا بردن قدرت تفکیک تابع تحریک شبکه عصبی که از نوع تانژانت سیگموئید^{۴۲} بوده و عمل نگاشت دامنه داده‌های ورودی، به دامنه $[-1, 1]$ را انجام می‌دهد و از آنجایی که در محدوده‌های انتهایی خروجی تابع تحریک (مقادیر نزدیک به حداقل و حداکثر تابع ورودی) شیب تغییرات تابع تحریک، بسیار کم می‌باشد بنابراین جهت نرمال‌سازی، محدوده داده‌های GPR با استفاده از رابطه (۳) به محدوده ۰/۱ تا ۰/۹ تبدیل

شبکه‌های عصبی از نوع پرسپترون چندلایه‌ای^{۴۳} (MLP)، از کاربردترین شبکه‌های عصبی به‌شمار می‌روند. این شبکه‌ها قادرند با انتخاب پارامترهای مناسب، تعداد لایه‌ها و سلول‌های عصبی، که اغلب زیاد هم نیستند یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. طبیعی‌ترین کاربرد پرسپترون چندلایه‌ای در طبقه‌بندی نظارت‌شده^{۴۴} است.

عملکرد کلی شبکه عصبی توسط ساختار^{۴۴} شبکه، خصوصیات عصب منفرد، روش یادگیری و داده‌های آموزشی، تعیین می‌شود. معمولاً فرآیند یادگیری^{۴۵} با استفاده از تعدادی مثال، مهم‌ترین فرآیند یا مرحله در شبکه‌های عصبی به حساب می‌آید. قابلیت آموختن یک شبکه عصبی از طریق به‌کارگیری یک الگوریتم یادگیری، میسر می‌شود که الگوریتم‌های آموزشی بطور کلی به سه دسته نظارت‌شده، بدون نظارت^{۴۶} و تقویتی^{۴۷} تقسیم‌بندی می‌شوند. چندین الگوریتم آموزشی نظارت‌شده متداول وجود دارد که در شبکه‌های عصبی، مورد استفاده قرار گرفته و تفاوت آنها در نحوه تغییر وزن‌های ارتباطی است که برخی از آنها، قاعده آموزش پرسپترون، آدالین^{۴۸} و الگوریتم پس‌انتشارخطا^{۴۹} می‌باشند [۲۱، ۲۰].

تقسیم‌بندی داده‌ها به سه بخش یادگیری یا آموزش، اعتبارسنجی^{۴۰} و آزمون یا آزمایش^{۴۱} بصورت تصادفی انجام می‌گیرد که معمولاً ۶۰ درصد از کل داده‌ها به داده‌های یادگیری، ۲۰ درصد به داده‌های اعتبارسنجی و ۲۰ درصد به داده‌های آزمون اختصاص داده می‌شود. برای جلوگیری از اشباع شدن نرون‌ها داده‌های اولیه (ورودی) حتماً باید به‌هنگار (نرمالیزه) شوند که در نتیجه این کار معمولاً طیف داده‌ها به ۱- تا ۱ و یا ۰ تا ۱ تغییر می‌یابد.

۴-۱-۲- شناسایی خودکار پارامترهای هندسی اهداف استوانه‌ای

هدف این بخش شناسایی و استخراج الگوهای موجود در داده‌های پاسخ GPR مدل‌های مصنوعی استوانه‌ای مشابه با ساختارهای تونلی متداول در کاربردهای ژئوتکنیکی، با استفاده از روش هوشمند شبکه‌های عصبی می‌باشد. در این پژوهش ابتدا با استفاده از روش مدل‌سازی عددی تفاضل محدود دایره‌ای، پاسخ GPR برای تعداد ۱۹۴ مدل مصنوعی مختلف حاوی اشیاء استوانه‌ای شکل (متناظر با ساختارهای ژئوتکنیکی واقعی) به شعاع ۱۰ تا ۷۵ سانتی‌متر، مدفون در اعماق ۴۰ سانتی‌متری تا ۲/۶ متری و واقع در فواصل افقی ۱ تا ۵ متری طول پروفیل، مدل‌سازی شد. قابل ذکر است که در تمام موارد، ابعاد مدل ۶*۳ متر بوده، تمام مدل‌های مصنوعی مورد استفاده

تصاویر GPR را به صورت نمودار جریان^{۴۹} (فلوچارت) شکل ۴ خلاصه نمود.

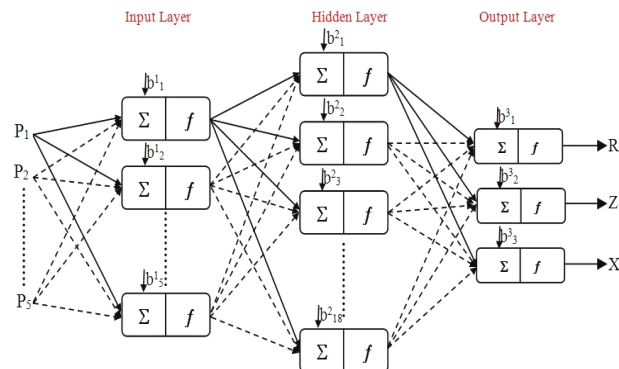
در این تحقیق به دو روش، هم به صورت مجزا با در نظر گرفتن یک خروجی برای هر شبکه و هم به صورت گروهی با داشتن سه خروجی همزمان برای شبکه، عمل شده است. نتایج نشان می‌دهند که شبکه‌های مجزا با دقت بالایی قادر به پیش‌بینی هر یک از پارامترهای هندسی به تنهایی و با درصد بسیار بالایی از درجه همبستگی می‌باشند به گونه‌ای که همبستگی داده‌های شبیه‌سازی شده با مقادیر هدف در مرحله آموزش، بیش از ۹۹ درصد و برای مرحله آزمون تا بیش از ۹۷ درصد به دست آمده که نتایج بسیار خوبی به حساب می‌آیند (شکل ۵). همچنین نتایج حاصل از آموزش یک شبکه با سه خروجی، به طور متوسط همبستگی بیش از ۹۷ درصد را برای داده‌های آزمون نشان می‌دهد (شکل ۶) که نتیجه بسیار مطلوبی می‌باشد. در شکل‌های ۵ و ۶ علاوه بر مقادیر ضریب همبستگی بین داده‌های مشاهده‌ای و تخمینی (r)، مجموع مربعات خطا^{۵۰} (SSE) و میانگین مربعات خطای تخمین شبکه (MSE) نیز نشان داده شده‌اند.

همچنین تمایز رفتار پاسخ‌های GPR اهداف استوانه‌ای افقی در شکل ۷ نشان داده شده است. در این شکل نمودارهای تغییرات مقادیر ویژه و نرم مقادیر ویژه بین تریسی (در راستای افقی) و نیز نرم مقادیر ویژه درون تریسی (در راستای قائم) برای اهداف استوانه‌ای با شعاع‌های مختلف، واقع در عمق یک و نیم متری و فاصله افقی سه متر، ترسیم شده است. همان‌گونه که از این شکل مشاهده می‌شود رفتار تغییرپذیری مقادیر ویژه پاسخ‌های متفاوت GPR، یکتا بوده و به خوبی می‌توان از آنها برای پیش-بینی پارامترهای هندسی بهره جست.

یافت که در این رابطه y_i داده تبدیل‌یافته، x_i ، آمین، x_{min} کوچک‌ترین و x_{max} بزرگ‌ترین داده ورودی می‌باشند.

$$y_i = 0.8 \times \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (3)$$

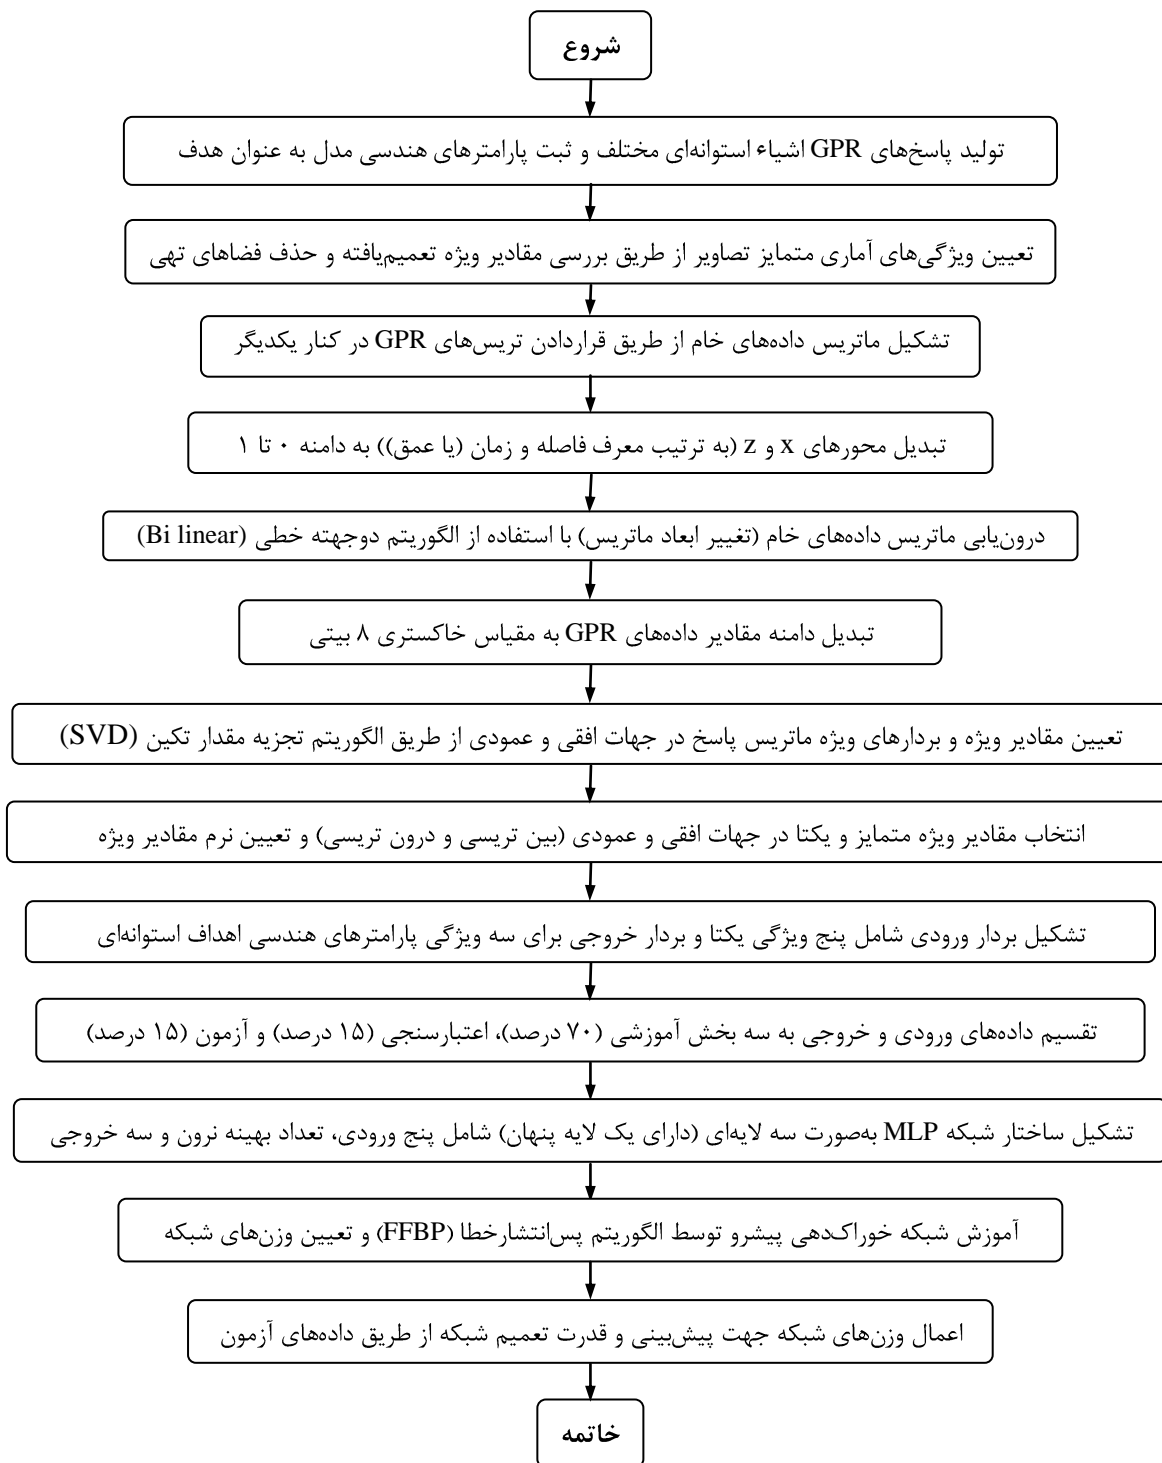
در این تحقیق با استفاده از الگوریتم تجزیه مقدار تکین^{۴۳} (SVD) آماره‌های توصیفی قطعه‌بندی شده تصویر GPR و مقادیر ویژه تعمیم یافته، مورد بررسی قرار گرفته و ویژگی‌های آماری متمایز تصاویر از طریق حذف فضاها^{۴۴} تهی تعیین گردید به گونه‌ای که از مقادیر ویژه متمایز و یکنای تعیین شده در راستاهای افقی (فضای بین تریسی) و عمودی (فضای درون تریسی)، سه مقدار ویژه اول راستای افقی، انتخاب و نرم مقادیر ویژه در جهات افقی و عمودی نیز تعیین گردید که این پنج مقدار به عنوان ورودی‌های شبکه عصبی برگزیده شدند. بدین ترتیب ساختار شبکه MLP سه لایه‌ای (دارای یک لایه پنهان) از نوع تغذیه پیشرو پس انتشار خطا با تابع آموزش لونیبرگ-مارکوارت^{۴۵} و تابع عملکرد میانگین مربعات خطا^{۴۶} (MSE)، با ۵ ورودی، تعداد نرون‌های بهینه‌سازی شده در لایه پنهان و ۳ خروجی مطابق شکل ۳ تشکیل شد.



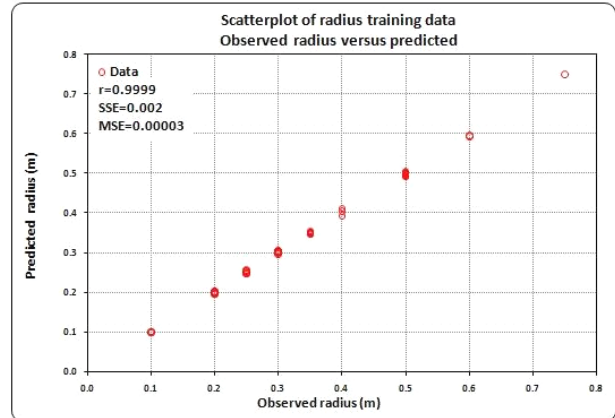
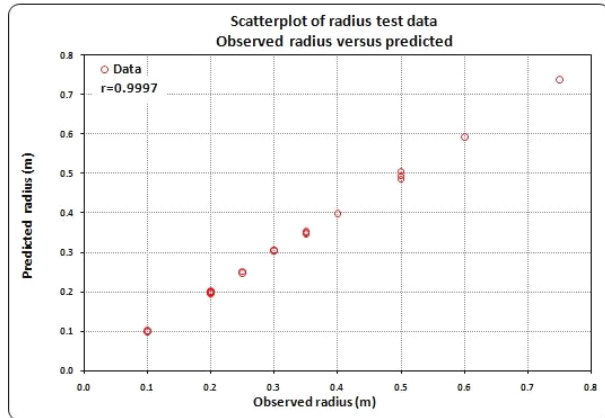
شکل ۳: شمایی از ساختار شبکه MLP سه لایه‌ای (دارای یک لایه پنهان) استفاده شده در پژوهش حاضر با ۵ ورودی، ۱۸ نرون در لایه پنهان و ۳ خروجی.

الگوریتم یادگیری شبکه نیز گرادیان نزولی با گشتاور^{۴۷} (Gdm) می‌باشد. تابع تحریک (انتقال) هر سه لایه نیز از نوع Tansig انتخاب گردید. تعداد دوره ها^{۴۸} برابر با ۲۰۰، پارامتر تعدیل مارکوارت (Mu) یا نرخ یادگیری برابر با ۰/۰۰۱ و فاکتور کاهش و افزایش این پارامتر نیز به ترتیب ۰/۱ و ۱۰ انتخاب شد.

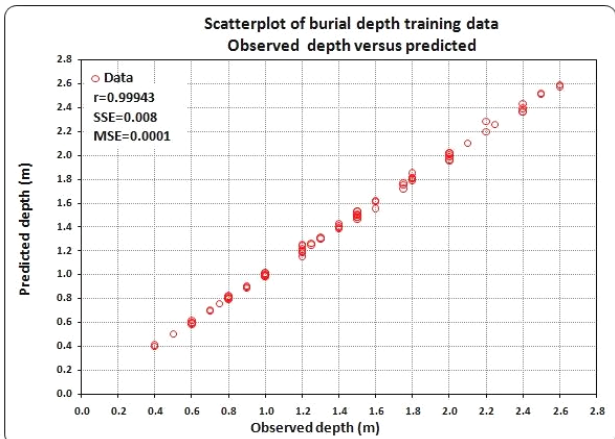
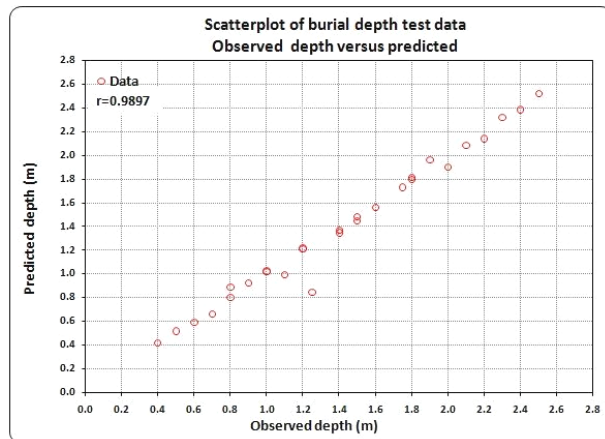
بعد از آموزش و تعیین وزن‌های شبکه، عملکرد آن، اعتبارسنجی گردید و قدرت تعمیم آن از طریق داده‌های آزمون تعیین شد. به طور کلی می‌توان مراحل عملیات پردازشی مورد نیاز جهت استخراج پارامترهای هندسی اشیای مدفون در



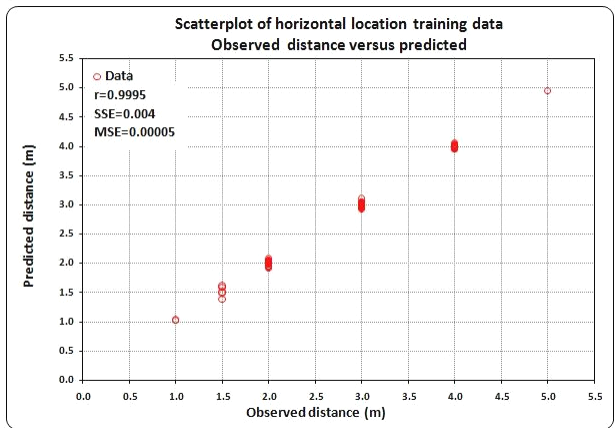
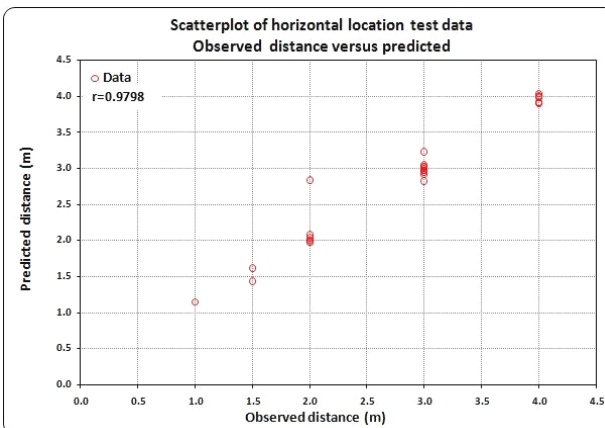
شکل ۴: نمودار جریان مراحل عملیات پردازشی داده های GPR توسط شبکه های عصبی.



(الف)

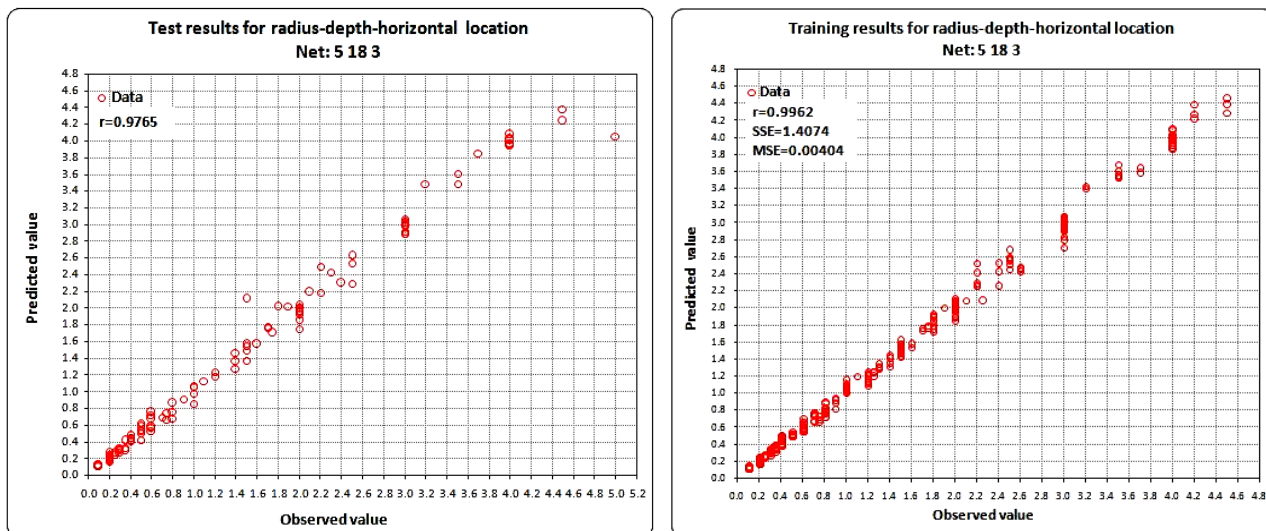


(ب)

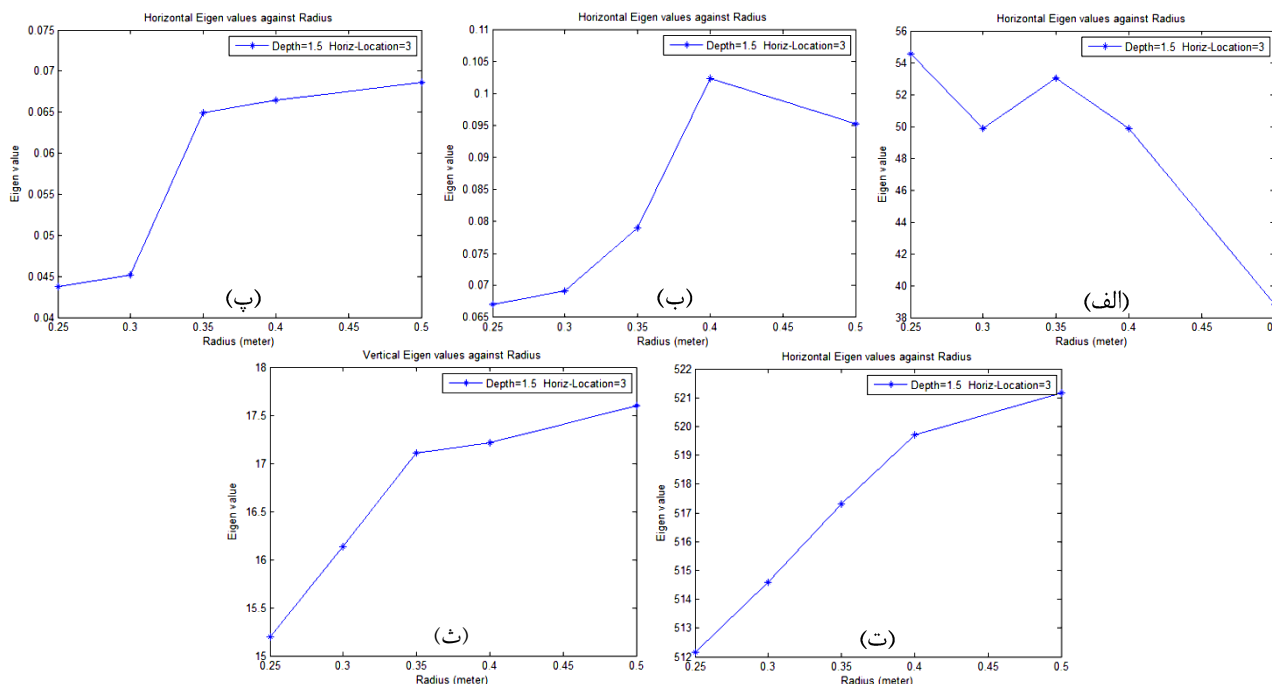


(ج)

شکل ۵: نمودار پراکندگی مقادیر پارامترهای هندسی مشاهده‌ای در مقابل تخمینی برای مراحل آموزش (راست) و آزمون (چپ) توسط شبکه عصبی بهینه. الف- تک خروجی شعاع با شبکه بهینه $4 \times 22 \times 1$ ، ب- تک خروجی عمق دفن با شبکه بهینه $4 \times 24 \times 1$ و ج- تک خروجی موقعیت افقی با شبکه بهینه $5 \times 7 \times 1$.



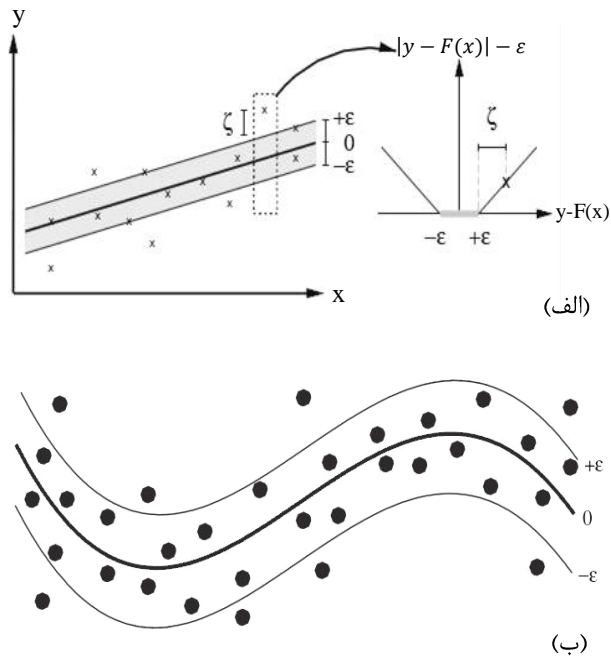
شکل ۶: نمودار پراکندگی مقادیر مشاهده‌ای پارامترهای هندسی (شعاع، عمق دفن و موقعیت افقی به‌طور همزمان) در مقابل مقادیر تخمینی برای مراحل آموزش (راست) و آزمون (چپ) توسط شبکه عصبی بهینه $3 \times 18 \times 5$.



شکل ۷: نمودارهای تغییرات مقادیر ویژه بین تریسی (الف تا پ)، نرم مقادیر ویژه بین تریسی (ت) و نرم مقادیر ویژه درون تریسی (ث) برای پارامتر هندسی شعاع.

چرونکیس^{۵۲} (VC) استفاده می‌نمایند. درحقیقت SRM یک حداقل کران بالا را بر ریسک مورد انتظار، اعمال می‌کند. یکی از اهداف مهم هر روش مبتنی بر یادگیری آماری، توان تعمیم-پذیری آن است که SVMها از توانایی تعمیم بالایی برخوردار هستند.

۴-۲- روش رگرسیون ماشین‌های بردار پشتیبان
 ۴-۲-۱- مبانی روش رگرسیون ماشین‌های بردار پشتیبان
 ماشین‌های بردار پشتیبان (SVMs) جزء روش‌های آموزش نظارت‌شده می‌باشند که برای حل مسائل طبقه‌بندی، رگرسیون و رتبه‌بندی مورد استفاده قرار می‌گیرند. روش‌های SVM مبتنی بر یادگیری آماری هستند که از اصل حداقل کردن ریسک ساختاری^{۵۱} (SRM) و نظریه کران وپنیک-



شکل ۸: الف) نمایش تابع SVR خطی [۲۳]، ب) نمایش تابع SVR غیرخطی که تیوبی به شعاع ϵ را بر داده‌ها برازش می‌دهد [۲۴].

از تعداد کل ۱۹۴ داده شبیه‌سازی شده در مراحل قبل، ۸۰ درصد (۱۵۵ عدد) به عنوان داده‌های آموزشی و ۲۰ درصد (۳۹ عدد) به عنوان داده‌های آزمون انتخاب شدند. به‌منظور بهینه‌سازی پارامترهای آموزش، از روش جستجو در فضای شبکه‌بندی شده پارامترهای بردار پشتیبان با تابع کرنل پایه شعاعی^{۵۵} (RBF) گوسی استفاده شد که برای دو متغیر a و b مطابق رابطه (۴) تعریف می‌شود [۲۲]:

$$K(a, b) = \exp(-\gamma \|a - b\|^2) = \exp\left(-\frac{\|a - b\|^2}{2\sigma^2}\right) \quad (4)$$

پارامتر γ با عکس مجذور عرض (پهنای) کرنل گوسی (σ) متناسب است که در پژوهش حاضر مقدار بهینه این پارامتر برابر با ۰/۱۲۵ بدست آمد. در جدول ۱ مشخصات و پارامترهای مدل‌های SVR مورد استفاده برای تعیین مشخصات هندسی مدل‌های استوانه‌ای شکل (شعاع، عمق دفن و موقعیت افقی) به عنوان خروجی‌های مدل خلاصه شده است. در این جدول ثابت مثبت C (پارامتر تنظیم برازش) پارامتر سبک‌وسنگین‌کردنی^{۵۶} بین اندازه حاشیه و میزان خطاها، و پارامتر ϵ معرف دقت تخمین یعنی اختلاف بین مقادیر واقعی و مقادیر تخمینی می‌باشد [۲۲]. هرچه مقدار C بزرگ‌تر انتخاب شود اندازه حاشیه کوچک‌تر خواهد بود و برعکس [۲۹، ۲۷]. مقدار پارامتر ϵ نیز معمولاً ۰/۱ انتخاب می‌شود [۲۳].

در شکل ۹ شمای کلی از ساختار (معماری) مدل SVR مورد استفاده در مطالعه حاضر نشان داده شده است. شکل ۱۰ نیز نتایج حاصل از شبیه‌سازی مراحل آموزش و آزمون داده‌ها با

SVMها به دو گروه SVC^{۵۳} و SVR تقسیم می‌شوند که SVC برای حل مسائل طبقه‌بندی و SVR برای حل مسائل رگرسیونی کاربرد دارد. اصول پایه این دو گروه یکی است. در روش SVC بردارهای ورودی به یک فضای چندبعدی نگاشت می‌شوند. سپس یک ابرصفحه ساخته می‌شود که بردارهای ورودی را با حداکثر فاصله ممکن، از یکدیگر جدا می‌کند. برای رفع مشکل انجام عملیات در فضای طبقه‌بندی با ابعاد زیاد، از یک تابع کرنل استفاده می‌شود. در این صورت عملیات می‌تواند با همان سرعت فضای داده‌های ورودی انجام گیرد. درواقع با استفاده از تابع کرنل، مشکل چندبعدی و غیرخطی بودن نگاشت، مرتفع می‌شود.

SVR روشی برای تخمین یک تابع است که براساس داده‌های آموزشی از یک شیء ورودی به یک عدد واقعی نگاشت می‌شود [۲۲]. همانند روش SVC در مسایل رگرسیون مرتبط با روش SVR، ویژگی‌های یکسانی برای حداکثر کردن حاشیه^{۵۴} وجود دارد که از بردار وزن‌های بهینه استفاده می‌شود. در این صورت فرایند بهینه‌سازی باید با یک تابع افت اصلاح شده همراه شود تا سنجش فاصله را دربر گیرد. درحقیقت هدف SVR، تخمین پارامترهای وزن‌ها و اریب تابعی است که بهترین انطباق را بر داده‌ها داشته باشد [۲۲]. تابع SVR می‌تواند خطی یا غیرخطی باشد (شکل ۸) و در حالت غیرخطی بودن، محاسبه تابع رگرسیون در یک فضای ویژگی با ابعاد بالا صورت می‌گیرد که داده‌های ورودی از طریق یک تابع غیرخطی، نگاشت می‌شوند. در مورد SVR نیز جهت رفع مشکل کار در بعد بالا برای نگاشت‌های غیرخطی، از توابع کرنل استفاده می‌شود. متون پایه مرتبط با این مباحث در مراجع [۲۳-۲۹] یافت می‌شوند.

۴-۲-۲- تعیین پارامترهای هندسی اهداف استوانه‌ای

به‌منظور به‌کارگیری روش ماشین‌های بردار پشتیبان همانند روش شبکه‌های عصبی لازم است که داده‌های ورودی مناسب و پارامترهای هندسی اهداف معین، توسط مدل آموزش داده شوند. در این روش ورودی‌ها شامل ۸ مقدار یعنی سه مقدار ویژه اول متمایز و یکتا در جهات افقی (بین تریسی) و عمودی (درون تریسی) و نرم مقادیر ویژه فضای بین تریسی و درون تریسی بوده و خروجی‌ها نیز همانند روش شبکه‌های عصبی شامل شعاع (R)، عمق دفن (Z) و موقعیت افقی (X) می‌باشند.


۵- مقایسه

در جدول ۲ نتایج میزان همبستگی بین داده های مشاهده ای و تخمینی (r)، مجموع مربعات خطا (SSE)، میانگین مربعات خطای تخمین (MSE) و خطای استاندارد نسبی (RSE)^{۵۷} برای مراحل آموزش و آزمون توسط روشهای SVR و ANN خلاصه شده است. یادآوری می شود که RSE به صورت نسبت مجذور میانگین مربعات خطا^{۵۸} (RMSE) به میانگین مقادیر مشاهده ای، تعریف می شود. با دقت در داده های این جدول ملاحظه می شود که مطابق انتظار میزان r برای داده های مرحله آموزش ANN از مقدار مربوطه برای داده های آزمون بیشتر است در حالی که این نتیجه برای داده های SVR برعکس می باشد. همچنین مقایسه مقادیر r برای دو روش SVR و ANN نشان می دهد که روش ANN هم در مرحله آموزش و هم در مرحله آزمون از دقت تخمین بالاتری نسبت به روش SVR برخوردار است. مقادیر SSE، MSE و RSE که همگی معرف خطا می باشند برای داده های آموزشی شبکه ANN برای تمام پارامترهای هندسی شعاع، عمق دفن و موقعیت افقی از مقادیر نظیر مدل SVR کمتر هستند. مقدار RSE که پارامتر شاخصی برای مقایسه خطای جوامع آماری مختلف می باشد برای داده های موقعیت افقی از داده های شعاع و عمق دفن هم در روش ANN و هم در روش SVR کمتر است.

استفاده از روش SVR را نشان می دهد. مقادیر ضریب همبستگی بین داده های مشاهده ای و تخمینی (r)، مجموع مربعات خطا (SSE) و میانگین مربعات خطا (MSE) نیز در شکل ها نشان داده شده اند.

جدول ۱: مشخصات مدل های SVR مورد استفاده برای تعیین مشخصات هندسی مدل های استوانه ای شکل.

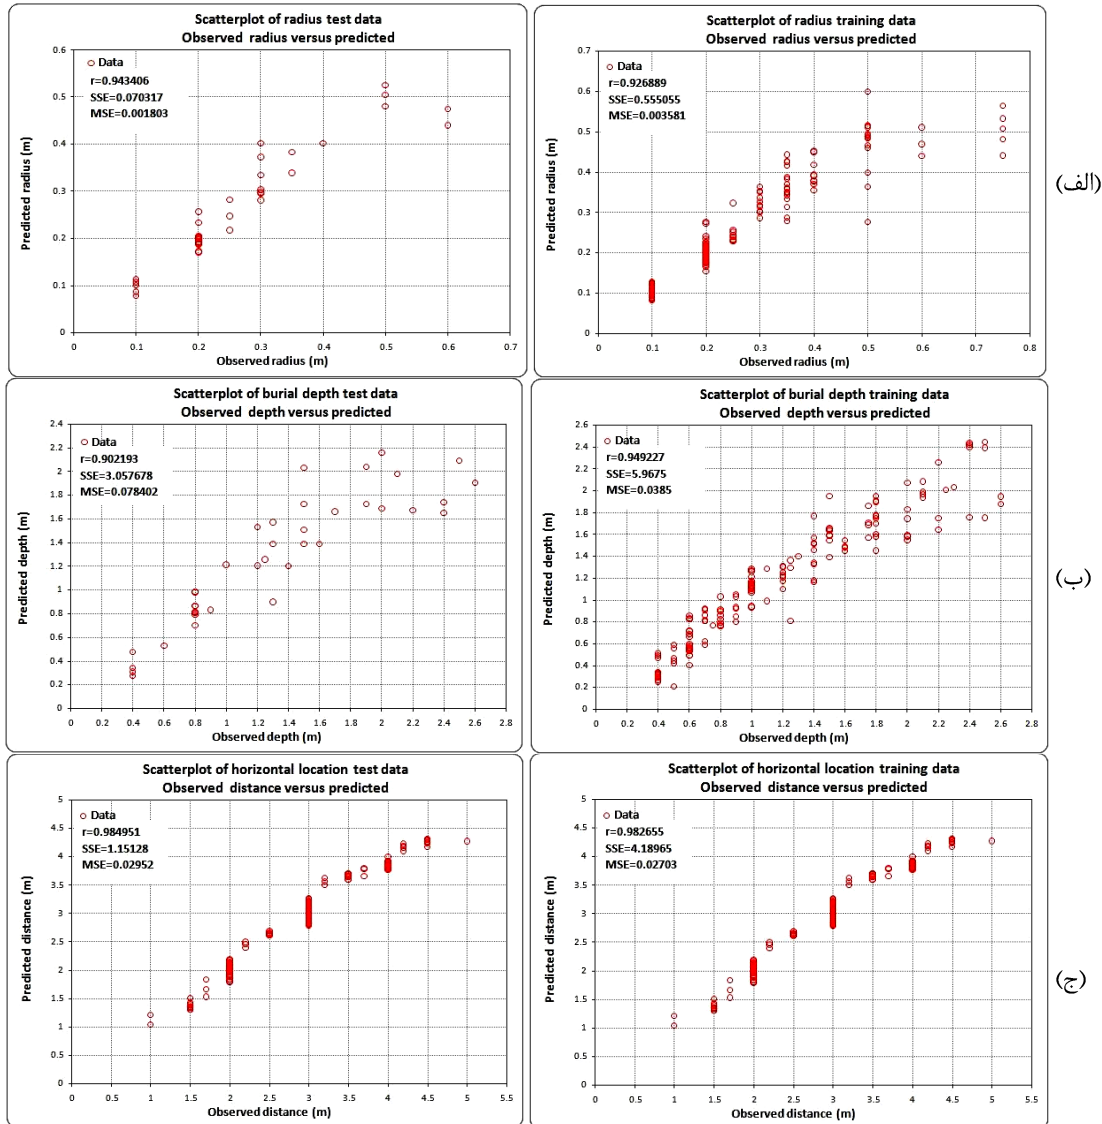
پارامتر مدل	ضریب تنظیم برآزش (C)	دقت تخمین (ε)	تعداد بردارهای پشتیبان (SV)	خطای اعتبارسنجی متقابل
شعاع	۹	۰/۵	۹۲	۰/۰۴۱
عمق دفن	۱۰	۰/۱	۷۹	۰/۰۳۷
موقعیت افقی	۱۰	۰/۱	۳۲	۰/۰۰۹



شکل ۹: شمایی از ساختار SVR استفاده شده در پژوهش حاضر با ۸ ورودی.

جدول ۲: مقایسه نتایج تخمین برای مراحل آموزش و آزمون توسط روش های SVR و ANN.

مرحله آزمون	مرحله آموزش				پارامتر هندسی خروجی	روش تخمین
	r	RSE	MSE	SSE		
	۰/۹۹۹۷	۰/۰۱۸۱	۰/۰۰۰۰۳	۰/۰۰۲	شعاع	ANN
	۰/۹۸۹۷	۰/۰۰۷	۰/۰۰۰۱	۰/۰۰۸	عمق دفن	
	۰/۹۷۹۸	۰/۰۰۲۵	۰/۰۰۰۰۵	۰/۰۰۴	موقعیت افقی	
	۰/۹۷۶۵	۰/۰۴۳۲	۰/۰۰۴۰	۱/۴۰۷۴	شعاع، عمق دفن و موقعیت افقی	ANN
	۰/۹۴۳۴	۰/۲۲۱۶	۰/۰۰۳۶	۰/۵۵۵۱	شعاع	SVR
	۰/۹۰۲۲	۰/۱۶۳۴	۰/۰۳۸۵	۵/۹۶۷۵	عمق دفن	
	۰/۹۸۵۰	۰/۰۵۶۰	۰/۰۲۷۰	۴/۱۸۹۷	موقعیت افقی	



شکل ۱۰: نمودار پراکندگی مقادیر پارامترهای هندسی مشاهده‌ای در مقابل تخمینی برای مراحل آموزش (راست) و آزمون (چپ) توسط روش SVR. الف- تک خروجی شعاع، ب- تک خروجی عمق دفن و ج- تک خروجی موقعیت افقی.

۶- مطالعات میدانی


به منظور بررسی کارایی و صحت‌سنجی عملکرد الگوریتم‌های مورد استفاده در این تحقیق برای داده‌های واقعی GPR، از داده‌های برداشت شده در خیابان چهارباغ شهر اصفهان در محدوده میدان امام حسین (ع) (روبروی شهرداری اصفهان) استفاده گردید. این داده‌ها در قالب یک پروژه به منظور شناسایی زیرسطحی کامل محدوده، از طریق برداشت تعداد ۱۴ پروفیل GPR به طول کلی ۷۸۹ متر با استفاده از یک سیستم GPR مجهز به آنتن‌های پوشش‌دار^{۵۹} با فرکانس مرکزی ۲۵۰ مگاهرتز [۳۰]، با روش پروفیل‌زنی بازتابی فاصله ثابت تک حالت برداشت شد.

الگوریتم‌های پژوهش حاضر بر روی نگاشت‌های راداری حاصل از این برداشت GPR به‌ویژه پاسخ انواع لوله‌های مدفون، پیاده‌سازی شد و نتایج مطلوبی به‌دست آمد. شکل ۱۱ مقطع GPR منطبق بر پروفیل به طول ۱۰ متر برداشت شده در راستای تقریباً شمال-جنوبی در محدوده مورد مطالعه را نشان می‌دهد. در شکل ۱۱ الف نگاشت راداری داده‌های خام، نمایش داده شده است. در این شکل محور قائم سمت چپ معرف زمان (بر حسب نانوثانیه) می‌باشد. شکل ۱۱ ب نیز نگاشت راداری را بعد از اعمال پیش‌پردازش‌های مورد نیاز شامل تصحیح زمان صفر^{۶۰}، فیلترینگ دی‌وای^{۶۱} (حذف روند فرکانس خیلی پایین از داده‌ها)، حذف شیفت جریان مستقیم^{۶۲}، حذف زمینه^{۶۳}، فیلتر میان‌گذر باترورث^{۶۴} و تقویت^{۶۵} دامنه امواج بازگشتی با

مشخصات هندسی واقعی این لوله با مقادیر پیش‌بینی شده توسط روش‌های ANN و SVR در جدول ۳ مقایسه شده و میزان درصد خطای مربوطه نیز محاسبه گردیده است. داده‌های این جدول نشان می‌دهند که متوسط خطای مقادیر پارامترهای هندسی لوله استوانه‌ای شکل پیش‌بینی شده توسط روش‌های ANN و SVR به ترتیب حدود ۵ و ۹ درصد بوده که با توجه به حضور انواع نوفه‌ها در داده‌های واقعی، نتایج قابل قبولی به حساب می‌آیند. در مورد اخیر نوفه از نوع تصادفی فرکانس بالا بوده و سطح آن براساس آماره‌های توصیفی مولفه‌های فرکانس بالا که به عنوان حد آستانه جداسازی مورد استفاده قرار گرفته‌اند حدود ۲۰ درصد برآورد گردید. معیار سنجش خطا نیز در این مورد مطابق رابطه (۵) به صورت نسبت قدرمطلق اختلاف مقادیر واقعی و مقادیر تخمینی به مقادیر واقعی پارامترهای هندسی اهداف معین مدفون بر حسب درصد می‌باشد.

$$(۵) \quad = \text{خطای تخمین پارامتر هندسی} \\ 100 \times (\text{مقدار واقعی} / \text{قدر مطلق اختلاف مقدار واقعی با مقدار تخمینی})$$

عمق با استفاده از نرم‌افزار Radexplorer نشان می‌دهد. تابع تقویت نهایی مورد استفاده برای داده‌ها از نوع کروی-نمایی^{۶۶} (SEC) می‌باشد تا اثر تضعیف ناشی از واگرایی کروی و گسترش هندسی موج را جبران نماید. البته انواع دیگر توابع تقویت از جمله نوع خودکار^{۶۷} (AGC) نیز به صورت سعی و خطا و مشاهده خروجی، بر روی داده‌ها آزمایش گردید که بهترین نتیجه به‌ویژه از نظر بصری، با تابع تقویت SEC حاصل شد. محور قائم سمت راست شکل ۱۱ ب معرف عمق (بر حسب متر) می‌باشد. به منظور تعیین سرعت بهینه محیط میزبان در محدوده مورد مطالعه، از روش کالیبره کردن استفاده شد بدین صورت که ابتدا برداشت بر روی اهداف با عمق معین، صورت گرفت و بر این اساس سرعت سیر امواج EM در محیط، حدود ۰/۱۲ متر بر نانوثانیه تعیین گردید. پاسخ GPR هدف مورد نظر که یک لوله فاضلاب استوانه‌ای شکل از جنس بتن با موقعیت و مشخصات هندسی معلوم می‌باشد با بیضی زردرنگ در تصاویر نشان داده شده است.



شکل ۱۱: الف) نگاشت راداری داده‌های خام، ب) بخشی از نگاشت راداری بعد از اعمال مراحل پردازشی مورد نیاز.

جدول ۳: مقایسه مقادیر واقعی پارامترهای هندسی (شعاع، عمق دفن و موقعیت افقی) لوله استوانه‌ای معلوم با مقادیر تخمینی توسط روش‌های ANN و SVR، و محاسبه میزان درصد خطای مربوطه.

خطای موقعیت افقی (درصد)	موقعیت افقی تخمینی (متر)	موقعیت افقی واقعی (متر)	خطای عمق دفن (درصد)	عمق دفن تخمینی (متر)	عمق دفن واقعی (متر)	خطای شعاع (درصد)	شعاع تخمینی (متر)	شعاع واقعی (متر)	مشخصات هندسی هدف روش تخمین
۲/۳	۶/۸۴	۷	۵/۳	۱	۰/۹۵	۸	۰/۴۶	۰/۵	ANN
۴/۲	۶/۷۱	۷	۹/۵	۱/۰۴	۰/۹۵	۱۲	۰/۴۴	۰/۵	SVR

with GPR using neural networks and pattern recognition”, Journal of Applied Geophysics, No. 43, pp 157-165.

[4] Gamba, P. and Belotti, V. (2003), “Two fast buried pipe detection schemes in ground penetrating radar images”, Int. J. Remote Sens., 24(12), pp 2467-2484.

[5] Pasolli, E., Melgani, F. and Donelli, M. (2009), “Automatic Analysis of GPR Images: A Pattern-Recognition Approach”, IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING, 47(7), pp 2206-2217.

[6] Santos, R.N. dos, V., Porsani, L., J. and Hirata, S.T.N. (2009), “Automatic classification of metallic targets using pattern recognition of GPR reflection: a study in the IAG-USP Test Site, Sao Paulo (Brazil)”, IEEE Conference Publications, pp 1-4.

[7] Cui, Y., Wang, L. and Xiao, J. (2010), “Automatic Feature Recognition for GPR Image Processing”, World Academy of Science, Engineering and Technology, 61, pp 176-179.

[8] Kobashigawa, J.S., Hyoun-gun Youn; Iskander, M.F.; Zhengqing Yun, (2011), “Classification of Buried Targets Using Ground Penetrating Radar: Comparison Between Genetic Programming and Neural Networks”, IEEE Antennas and Propagation Society, 10, PP: 971-974.

[9] Lian Fei-yu, Li Qing, (2011), “Recognition method based on SVM for underground pipe diameter size in GPR map, Information and Electronic Engineering”, 9 (4), pp: 403-408.

[10] Hebsur, A. V., Muniappan, N., Rao, E. P., Venkatachalam, G., (2013), “Application of ground penetrating radar for locating buried impediments to geotechnical exploration and piling”, Journal of Applied Geophysics, 7 (4), pp. 374-387.

[11] Xiongyao Xie, Hui Qin, Chao Yu, Lanbo Liu, (2013), “An automatic recognition algorithm for GPR images of RC structure voids”, Journal of Applied Geophysics, 99, pp: 125-134.

[12] Bourgeois, J.M. and Smith, G.S. (1996), “A fully three-dimensional simulation of a ground-penetrating radar: FDTD theory compared with experiment”, IEEE Transactions on Geoscience and Remote Sensing, 34 (1), pp 36-44.

[13] Cassidy, N.J. (2001), “The Application of Mathematical Modelling in the Interpretation of Ground

۷- نتیجه‌گیری

براساس نتایج به‌دست آمده، تکنیک‌های هوشمند شناخت الگوی آماری شامل شبکه‌های عصبی مصنوعی و رگرسیون ماشین بردار پشتیبان، قادر به تشخیص پاسخ‌های GPR اهداف استوانه‌ای مدفون بوده و برای شناسایی ویژگی‌های هندسی این اهداف شامل شعاع، موقعیت قائم (عمق دفن) و موقعیت افقی، از قدرت پیش‌بینی بالا و سرعت اجرای زیاد برخوردار می‌باشند. به‌هرجهت در این خصوص روش ANN نسبت به روش SVR از خطای تخمین کمتری برخوردار است.

الگوریتم‌های پیشنهادی به‌گونه‌ای طراحی شده‌اند که کلیه مراحل شناسایی و تخمین پارامترهای هندسی اشیاء مدفون، به‌طور خودکار و با حداقل دخالت کاربر تخمین زده می‌شوند. عملکرد روش‌های مورد استفاده، برای تصاویر واقعی GPR در حضور نوفه‌ها نیز مورد ارزیابی قرار گرفت و نتایج قابل قبولی حاصل شد به‌گونه‌ایکه روش‌های ANN و SVR پارامترهای هندسی هدف معین مدفون را با متوسط خطای به ترتیب ۵ و ۹ درصد تخمین زدند.

نتایج پژوهش حاضر برای شناسایی خودکار انواع ساختارهای استوانه‌ای مدفون به‌ویژه اهداف ژئوتکنیکی در نواحی شهری با دقت و سرعت عمل بالا در محل صحرایی و بدون دخالت و تفسیر مبتنی بر سلیقه شخصی عملگر، قابل استفاده می‌باشد.

۸- مراجع

[1] Knödel, K., Lange, G. and Voigt, H.J. (2007), “Environmental geology: handbook of field methods and case studies”, Google Books Result, 1357 pages, Chapter 4, Geophysics.

[2] Capineri, L., Grande, P. and Temple, J.A.G. (1998), “Advanced image-processing technique for real-time interpretation of ground-penetrating radar images”, International Journal of Imaging System Technology, 9(1), pp 51-59.

[3] Al-Nuaimy, W., Huang, Y., Nakhkash, M., Fang, M.T.C., Nguyen, V.T. and Eriksen, A. (2000), “Automatic detection of buried utilities and solid objects

Penetrating Radar Data”, Ph.D. Thesis, Keele University.

[14] Giannopoulos, A. (2005), “*Modelling ground penetrating radar by GprMax. Construction and Building Materials*”, 19, pp 755-762.

[15] Irving, J., and Knight, R. (2006), “*Numerical modeling of ground penetrating radar in 2-D using MATLAB*”, Computers & Geosciences, Vol 32, pp 1247–1258.

[16] Bergmann, T., Robertsson, J.O.A. and Holliger, K. (1996), “*Numerical properties of staggered finite-difference solutions of Maxwell’s equations for ground-penetrating radar modeling*”, Geophysical Research Letters, 23(1), pp 45-48.

[17] Ahmadi, R., Fathianpour, N., and Norouzi, G.H. (2012), “*A novel method to increase the forward modelling speed of GPR data in the frequency domain*”, 4th Iranian Mining Engineering Conference, Tehran University, 10-12 Oct, Tehran.

[18] Ahmadi, R., Fathianpour, N., and Norouzi, G.H. (2012), “*Simulation of response of GPR pulses using forward modelling by finite difference*”, The first Iranian Conference on Electromagnetic Engineering (ICEME), Iran University of Science and Technology, 26-27 Dec, Tehran.

[19] Watanabe, S. (1985), “*Pattern Recognition: Human and Mechanical*”, New York: Wiley.

[20] Menhaj, M.B., (2005), “*Principals of neural networks*”, 3rd edition, Amirkabir University of Technology publisher.

[21] Kasabov, N.K. (1998), “*Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering*”, The MIT Press.

[22] Yu, H., and Kim, S. (2012), “*SVM Tutorial: Classification, Regression, and Ranking*”, Handbook of Natural Computing, Springer Berlin Heidelberg, pp 479-506.

[23] Ivanciuc, O. (2007), “*Applications of Support Vector Machines in Chemistry*”, Reviews in Computational Chemistry, 23, pp 291–400.

[24] Smola, A.J., and Schölkopf, B. (2003), “*A tutorial on support vector regression*”, Statistics and Computing, 14(3), pp 199–222.

[25] Li, H.D., Liang, Y., Xu, Q., (2009), “*Support vector machines and its applications in chemistry*”, Chemometrics and Intelligent Laboratory Systems, 95, pp 188–198.

[26] Gunn S.R. (1998), “*Support Vector Machines for Classification and Regression*”, Technical Report, Faculty of engineering, science and mathematics, University of Southampton.

[27] Hastie T., Tibshirani R., and Friedman J. (2001), “*The Elements of Statistical Learning: Data Mining, Inference, and Prediction*”, Springer, New York.

[28] Basak D., srimanta Pal S., and Patranabis D.C. (2007), “*Support Vector Regression*”, neural information processing.

[29] Parrella, F. (2007), “*Online Support Vector Regression*”, A Thesis presented for the degree of Information Science, Department of Information Science, University of Genoa, Italy.

[30] www.malags.com

-
- | | |
|---|--|
| <p>54 Margin</p> <p>55 Radial Basis Function</p> <p>56 Trade-off</p> <p>57 Relative Standard Error</p> <p>58 Root Mean Squared Error</p> <p>59 Shielded</p> <p>60 Time zero correction</p> <p>61 Dewow</p> <p>62 DC shift removal</p> <p>63 Background Removal</p> <p>64 Butterworth</p> <p>65 Gain</p> <p>66 Spherical-Exponential Compensation</p> <p>67 Automatic Gain Control</p> | <p>1 Ground Penetrating Radar</p> <p>2 Electromagnetic</p> <p>3 Trace</p> <p>4 Radargram</p> <p>5 Pattern recognition</p> <p>6 Capineri</p> <p>7 Hough</p> <p>8 Al-Nuaimy</p> <p>9 Artificial Neural Network</p> <p>10 Gamba</p> <p>11 Belotti</p> <p>12 Template matching</p> <p>13 Operator</p> <p>14 Pasolli</p> <p>15 Support Vector Machine</p> <p>16 Santos</p> <p>17 Cui</p> <p>18 Kobashigawa</p> <p>19 Lian</p> <p>20 Li</p> <p>21 Hebsur</p> <p>22 Hilbert</p> <p>23 Xiongyao</p> <p>24 Predictive Deconvolution</p> <p>25 Finite-Difference Time-Domain</p> <p>26 Support Vector Regression</p> <p>27 Ray Tracing</p> <p>28 Z Transform</p> <p>29 Discrete Elements</p> <p>30 Transverse Magnetic Field</p> <p>31 Watanabe</p> <p>32 Multi-Layer Perceptron</p> <p>33 Supervised Classification</p> <p>34 Topology</p> <p>35 Training</p> <p>36 Unsupervised</p> <p>37 Reinforcement</p> <p>38 ADALINE</p> <p>39 Back Propagation Error</p> <p>40 Validation</p> <p>41 Test</p> <p>42 Tansig</p> <p>43 Singular Value Decomposition</p> <p>44 Null space</p> <p>45 Levenberg-Marquardt</p> <p>46 Mean Squared Error</p> <p>47 Gradient descent with momentum</p> <p>48 Epoch</p> <p>49 Flowchart</p> <p>50 Sum of Squared Error</p> <p>51 Structural Risk Minimization</p> <p>52 Vapnik-Chervonenkis</p> <p>53 SVM Classification</p> |
|---|--|