



افزایش دقت اکتشاف معدنی با مدل‌های داده-محور ژئوفیزیکی

تجربه عملی با RANDOM FOREST

۲	<u>چکیده اجرایی</u>
۳	<u>مقدمه: طرح مسئله و تصویر کلی پروژه</u>
۳	<u>پس‌زمینه و ضرورت پروژه</u>
۳	<u>چالش‌های فعلی و نیاز به نوآوری</u>
۳	<u>هدف و چشم‌انداز پروژه</u>
۴	<u>رویکرد و مسیر حل مسئله</u>
۴	<u>ساختار و جریان پروژه</u>
۴	<u>ارزش و تأثیر پروژه</u>
۵	<u>راه‌حل و طراحی فنی پروژه</u>
۵	<u>معماری راه‌حل و رویکرد فناورانه</u>
۵	<u>قیود اجرایی و چالش‌های عملی</u>
۶	<u>نقشه‌راه، زمان‌بندی و شاخص‌های موفقیت</u>
۶	<u>مراحل اجرایی پروژه</u>
۶	<u>شاخص‌های موفقیت و معیارهای ارزیابی</u>
۷	<u>چشم‌انداز و توسعه آینده</u>

چکیده اجرایی

اکتشاف معدن فرآیند جستجو، تعیین موقعیت و ارزیابی ذخایر معدنی با ارزش اقتصادی است که با هدف برآورد عیار و تناژ ماده معدنی برای تصمیم‌گیری‌های فنی و اقتصادی انجام می‌شود. این فرآیند از ترکیب مطالعات دفتری و دورسنجی با تصاویر ماهواره‌ای و هوایی، زمین‌شناسی صحرایی، ژئوشیمی، ژئوفیزیک، نمونه‌برداری و در نهایت حفاری اکتشافی برای جمع‌آوری داده‌های مستقیم استفاده می‌کند.

در زمینه اکتشاف معادن، هر تصمیم می‌تواند میلیون‌ها دلار هزینه یا درآمد داشته باشد و هر حفاری ناموفق، نه تنها هزینه‌ای سنگین بر دوش پروژه می‌گذارد، بلکه زمان و فرصت‌های سرمایه‌گذاری نیز از دست می‌رود. یکی از شرکت‌های پیشرو در صنعت معدن، با مسئله‌ای واقعی و چالش‌برانگیز روبرو شده بود که بسیاری از شرکت‌های مشابه نیز در حال حاضر با آن مواجه هستند. مسئله مطرح شده بدین شرح است:

"چگونه می‌توان از حجم عظیم داده‌های ژئوفیزیکی که در عملیات میدانی برداشت می‌شود، برای تصمیم‌گیری دقیق‌تر و کاهش ریسک استفاده کرد؟"

این شرکت، پس از برداشت داده‌های IP-Resistivity (اندازه‌گیری مقاومت الکتریکی و قطبش القایی) متوجه شد که روش‌های سنتی تفسیر و تحلیل این داده‌ها، علاوه بر اینکه زمان‌بر هستند، دقت کافی برای تصمیم‌گیری‌های حیاتی را ندارند. تحلیل دستی که معمولاً توسط کارشناسان مجرب انجام می‌شود اغلب بر اساس تجربه فردی و تفسیرهای ذهنی است و در بهترین حالت دقت آن به کمتر از شصت درصد می‌رسد.

این چالش به تیم ما سپرده شد: آیا می‌توان با استفاده از هوش مصنوعی و یادگیری ماشین، دقت پیش‌بینی "مقاومت ویژه" را به‌طور معناداری افزایش داد؟ آیا می‌توان زمان تحلیل را از هفته‌ها به چند روز کاهش داد و در عین حال، شفافیت و اعتماد به نتایج را برای مدیران و سرمایه‌گذاران تضمین کرد؟

ما این مسیر را با ساخت یک مدل پایه شروع کردیم. استفاده از الگوریتم Random Forest روی داده‌های خام ژئوفیزیکی، نتایج اولیه‌ای داد که اگرچه بهتر از روش‌های سنتی بود، اما هنوز برای تصمیم‌گیری‌های عملیاتی کافی نبود. دقت مدل اولیه روی داده‌های تست، ۵۵٪ بود، یعنی همچنان فاصله زیادی تا یک راه‌حل قابل اعتماد وجود داشت.

اما داستان اینجا پایان نیافت. با ترکیب دانش عمیق ژئوفیزیک، مهندسی ویژگی‌های پیشرفته و تکنیک‌های آماری، مسیری نوآورانه را طی کردیم. از چهل پارامتر اولیه، تعداد زیادی ویژگی هوشمند ساختیم که نه تنها داده‌های خام را توصیف می‌کردند، بلکه رفتار فیزیکی سیگنال‌ها، تعاملات بین پارامترها و حتی کیفیت داده‌ها را نیز در خود جای می‌دادند. نتیجه این تلاش، مدلی بود که دقت آن روی داده‌های تست به ۷۸-۸۰٪ رسید.

این بهبود عملکرد به معنای این است که از هر ده پیش‌بینی، هشت مورد دقیق است، خطای متوسط تقریباً سی درصد کاهش یافته و مدل به گونه‌ای طراحی شده که روی داده‌های جدید نیز عملکرد پایداری دارد. این تحول، نه تنها زمان تحلیل را به کمتر از چند روز کاهش داد، بلکه اعتماد مدیران و سرمایه‌گذاران را نیز جلب کرد، چرا که اکنون می‌توان با شفافیت کامل درک کرد که چرا مدل، یک نقطه را نسبت به نقطه دیگر اولویت‌بندی کرده است.

امروزه، این مدل نه تنها برای پیش‌بینی مقاومت ویژه، بلکه برای اولویت‌بندی هدف‌های حفاری، کنترل کیفیت خودکار داده‌ها، شناسایی نویزهای اندازه‌گیری و ... استفاده می‌شود. این مدل ثابت می‌کند که ترکیب هوشمندانه دانش تخصصی با قدرت یادگیری ماشین، می‌تواند تحولی واقعی در صنعت معدن ایجاد کند.

مقدمه: طرح مسئله و تصویر کلی پروژه

پس‌زمینه و ضرورت پروژه

داده‌های ژئوفیزیکی اگرچه غنی و پرمحتوا هستند، اما تفسیر آن‌ها همیشه چالش‌برانگیز بوده است. هر رکورد داده ممکن است شامل ده‌ها پارامتر باشد، از جمله ولتاژ، جریان، فاکتور هندسی، قطبش در پنجره‌های زمانی مختلف و موقعیت الکترودها. تفسیر این حجم از داده به صورت دستی، نه تنها هفته‌ها زمان می‌برد، بلکه در معرض خطای انسانی و تعصبات شناختی نیز قرار دارد. کارشناسان، اغلب بر اساس تجربه و شهود عمل می‌کنند و این تفسیرها ممکن است از فردی به فرد دیگر متفاوت باشد.

شرکت معدنی مورد نظر، با مجموعه‌ای از دویست و سیزده رکورد داده IP-Resistivity روبرو بود که هر کدام شامل چهار پارامتر اندازه‌گیری شده بودند. هدف این بود که بتوان از این داده‌ها برای پیش‌بینی دقیق مقاومت ویژه استفاده کرد، چرا که مقاومت ویژه یکی از شاخص‌های کلیدی برای تشخیص نوع سنگ، کانی‌سازی و کیفیت ذخیره معدنی است. اما سوال اصلی این بود: آیا می‌توان این فرآیند را خودکار کرد و دقت آن را به سطحی رساند که بتوان با اطمینان، تصمیمات حفاری را بر آن استوار کرد؟

چالش‌های فعلی و نیاز به نوآوری

روش‌های سنتی تفسیر داده‌ها، معمولاً شامل رسم نمودارهای دستی، مقایسه بصری الگوها و استفاده از نظر کارشناسان است. این رویکردها اگرچه مبتنی بر دانش تخصصی عمیق هستند، اما دارای محدودیت‌های جدی هستند که دو مورد اصلی آن به شرح زیر است:

۱. زمان بر بودن

۲. دقت پایین

از سوی دیگر، هزینه حفاری بسیار بالاست. بنابراین، هر تصمیم اشتباه، به معنای ضرر مالی قابل توجه و از دست رفتن فرصت‌های بهتر است. در چنین شرایطی، نیاز به راهکاری که بتواند دقت را افزایش دهد، زمان را کاهش دهد و شفافیت را تضمین کند، بیش از هر زمان دیگری احساس می‌شود.

هدف و چشم‌انداز پروژه

هدف اصلی این پروژه، توسعه یک سیستم پیش‌بینی مبتنی بر یادگیری ماشین بود که بتواند مقاومت ویژه را با دقتی بالاتر از هفتاد و پنج درصد پیش‌بینی کند. این هدف، نه به‌خاطر رقابت با روش‌های سنتی، بلکه به دلیل ضرورت عملی آن تعریف شد. با دقت بالاتر، می‌توان اولویت‌بندی هوشمندانه‌تری در حفاری‌ها داشت، هزینه‌ها را کاهش داد و ریسک سرمایه‌گذاری را به حداقل رساند.

علاوه بر افزایش دقت، هدف دیگر، کاهش زمان تحلیل بود. در دنیای امروز، سرعت در تصمیم‌گیری، می‌تواند تفاوت بین موفقیت و شکست پروژه باشد. مدیران و سرمایه‌گذاران، نیاز دارند که به سرعت بفهمند کدام هدف‌ها ارزش حفاری دارند و کدام‌ها نه. پس یکی دیگر از اهداف ما کاهش زمان بود.

همچنین، شفافیت و قابلیت تفسیر نتایج، از دیگر اهداف بود. مدل نهایی باید نه تنها دقیق باشد، بلکه بتواند توضیح دهد که چرا یک نقطه نسبت به نقطه دیگر اولویت دارد و کدام پارامترها بیشترین تأثیر را در پیش‌بینی دارند. این شفافیت، نه تنها به اعتماد مدیران کمک می‌کند، بلکه امکان بهبود مستمر مدل را نیز فراهم می‌آورد.

رویکرد و مسیر حل مسئله

برای رسیدن به این اهداف، تصمیم گرفتیم که از یادگیری ماشین، به ویژه الگوریتم Random Forest استفاده کنیم. این انتخاب بر اساس چندین دلیل بود. اول، Random Forest قادر است روابط غیرخطی پیچیده‌ای که در داده‌های ژئوفیزیکی وجود دارد را یاد بگیرد. دوم، این الگوریتم نسبت به داده‌های پرت و نویزی مقاوم است، که در داده‌های میدانی اغلب دیده می‌شود. سوم، Random Forest قابلیت تفسیر خوبی دارد، به این معنا که می‌توان فهمید کدام ویژگی‌ها مهم‌تر هستند و چرا.

مسیر حل مسئله، شامل سه مرحله اصلی بود. در مرحله اول، یک مدل پایه ساختیم که مستقیماً از داده‌های خام استفاده می‌کرد. این مدل، نقطه شروع ما بود و به ما کمک کرد تا پتانسیل و محدودیت‌های رویکرد یادگیری ماشین را بفهمیم. نتایج اولیه نشان داد که اگرچه مدل بهتر از روش‌های سنتی است، اما هنوز به دقت مورد نظر نرسیده است.

در مرحله دوم، به مهندسی ویژگی پرداختیم. این مرحله، قلب موفقیت پروژه بود. ما به این نتیجه رسیدیم که صرفاً استفاده از داده‌های خام کافی نیست، بلکه باید دانش تخصصی ژئوفیزیک را به مدل تزریق کنیم. برای این منظور، ویژگی‌های جدیدی ساختیم که نه تنها داده‌های خام را توصیف می‌کردند، بلکه رفتار فیزیکی سیگنال‌ها، تعاملات بین پارامترها و حتی کیفیت داده‌ها را نیز در خود جای می‌دادند. از فرمول کلاسیک مقاومت ویژه، نسبت‌های زمانی سیگنال IP، شاخص‌های آماری و ترکیبات هوشمند بین پارامترها استفاده کردیم.

در مرحله سوم، مدل پیشرفته را آموزش دادیم و نتایج را ارزیابی کردیم. این مرحله نشان داد که مهندسی ویژگی، تأثیر شگرفی بر عملکرد مدل دارد. دقت مدل به هفتاد و هشت تا هشتاد درصد رسید، خطای متوسط به شدت کاهش یافت و مدل توانست روی داده‌های جدید نیز عملکرد پایداری داشته باشد.

ساختار و جریان پروژه

پروژه به گونه‌ای طراحی شد که هر مرحله، بر پایه مرحله قبل بنا شود و یادگیری‌های هر مرحله، در مرحله بعد لحاظ شود. در ابتدا، داده‌های خام جمع‌آوری و پاکسازی شدند. سپس، مدل پایه ساخته شد تا بتوانیم عملکرد اولیه را ارزیابی کنیم. پس از آن، با استفاده از تحلیل اهمیت ویژگی‌ها و درک عمیق از فیزیک مسئله، ویژگی‌های جدید ساخته شدند. در نهایت، مدل پیشرفته آموزش داده شد و نتایج با معیارهای مختلف ارزیابی شدند.

یکی از نکات کلیدی در طراحی پروژه، توجه به overfitting بود. در دیتاست‌های کوچک، همیشه خطر این وجود دارد که مدل بیش از حد روی داده‌های آموزشی یاد بگیرد و روی داده‌های جدید عملکرد ضعیفی داشته باشد. برای جلوگیری از این مشکل، از تکنیک‌های مختلفی مانند Cross-Validation، Regularization و حذف ویژگی‌های تکراری استفاده شد. نتایج نشان داد که این رویکردها، موفق بوده‌اند و مدل نهایی، پایداری خوبی دارد.

ارزش و تأثیر پروژه

این پروژه، نه تنها یک دستاورد علمی است، بلکه تأثیر عملی و تجاری قابل توجهی نیز دارد. از نظر علمی، این پروژه نشان می‌دهد که چگونه می‌توان با ترکیب دانش تخصصی و یادگیری ماشین، به نتایجی برتر از روش‌های سنتی رسید. همچنین، این پروژه اهمیت مهندسی ویژگی را در مسائل دنیای واقعی برجسته می‌کند.

از نظر تجاری، این مدل می‌تواند هزینه‌های قابل توجهی را صرفه‌جویی کند. با افزایش دقت از پنجاه و پنج درصد به هفتاد و هشت درصد، تعداد حفاری‌های ناموفق به‌طور قابل توجهی کاهش می‌یابد. این یعنی کمتر هزینه کردن برای اهداف نادرست و بیشتر سرمایه‌گذاری روی اهداف امیدوارکننده. علاوه بر این، کاهش زمان تحلیل از هفته‌ها به چند روز، به معنای سرعت بیشتر در تصمیم‌گیری و در نتیجه، مزیت رقابتی در بازار است.

همچنین شفافیت مدل، این اطمینان را می‌دهد که تصمیمات بر اساس تحلیل‌های معتبر و قابل دفاع گرفته می‌شوند. این شفافیت، نه تنها به اعتماد کمک می‌کند، بلکه امکان بهبود مستمر و یادگیری از تجربه‌های گذشته را نیز فراهم می‌آورد.

در نهایت، تعریف دقیق مسأله و اهداف این پروژه بر محوریت خلق ارزش عملی برای شرکت‌های معدنی، افزایش بازدهی سرمایه‌گذاری در حفاری، تسریع تصمیم‌گیری‌های اجرایی و ارتقای اعتبار برند معدنی بنا شده است. هرچه داده بیشتر و با کیفیت‌تر باشد، این موتور تحلیلی هوشمند بهتر یاد می‌گیرد و بازده بیشتری خلق می‌کند؛ و این همان نقطه‌ای است که فناوری امروز می‌تواند سنت ده‌ها ساله اکتشاف را متحول کند.

راه‌حل و طراحی فنی پروژه

معماری راه‌حل و رویکرد فناورانه

راه‌حل ما بر پایه ترکیب هوشمندانه دو زمینه متفاوت اما مکمل استوار شده است؛ دانش عمیق ژئوفیزیک معدنی و قدرت یادگیری ماشین. انتخاب Random Forest به‌عنوان الگوریتم اصلی، نتیجه ارزیابی دقیق چندین رویکرد بود. الگوریتم‌های رگرسیون خطی، ساده اما محدود بودند و نمی‌توانستند روابط پیچیده غیرخطی بین پارامترهای ژئوفیزیکی را به‌درستی مدل کنند. شبکه‌های عصبی عمیق، اگرچه قدرتمند بودند، اما برای دیتاست‌های کوچک مقیاس مانند ما، مستعد overfitting شدید بودند و تفسیر نتایج آن‌ها بسیار دشوار است. اما Random Forest، توانایی یادگیری روابط غیرخطی را داشت، نسبت به نویز و داده‌های پرت مقاوم بود و مهم‌تر از همه، قابلیت تفسیر فوق‌العاده‌ای داشت که به ما امکان می‌داد بفهمیم کدام ویژگی‌ها چقدر در تصمیم‌گیری نهایی مؤثر هستند.

طراحی معماری پروژه به‌صورت مرحله‌ای و تکرارپذیر انجام شد. در لایه اول، داده‌های خام جمع‌آوری و پاکسازی شدند. این مرحله شامل حذف رکوردهای ناقص، تشخیص و رفع مقادیر پرت شدید و همچنین استانداردسازی فرمت داده‌ها بود. لایه دوم به ساخت مدل پایه اختصاص داشت که هدف آن ارزیابی سریع پتانسیل یادگیری ماشین روی داده‌های خام بود. این مدل، اگرچه دقت محدودی داشت، اما به ما کمک کرد تا درک اولیه‌ای از چالش‌ها و فرصت‌ها پیدا کنیم. سپس، لایه سوم که مهندسی ویژگی نام داشت، وارد عمل شد. در این مرحله، دانش تخصصی ژئوفیزیک با تکنیک‌های آماری و ریاضی ترکیب شد تا ویژگی‌های جدیدی ساخته شوند که نه تنها داده‌های خام را توصیف می‌کردند، بلکه رفتار فیزیکی سیگنال‌ها و تعاملات پنهان بین پارامترها را نیز آشکار می‌کردند.

یکی از نوآوری‌های کلیدی، استفاده از فرمول کلاسیک مقاومت ویژه به‌عنوان یک ویژگی محاسباتی بود. به جای آنکه منتظر بمانیم مدل خودش این رابطه را کشف کند، ما مستقیماً این دانش را به او تزریق کردیم. همچنین، تحلیل رفتار زمانی سیگنال IP در پنجره‌های مختلف، به ما اجازه داد تا نسبت‌هایی بسازیم که سرعت افت قطبش را اندازه‌گیری کنند؛ شاخصی که مستقیماً با نوع کانی مرتبط است. علاوه بر این، ویژگی‌هایی برای کنترل کیفیت داده‌ها ساختیم که بتوانند به‌طور خودکار داده‌های مشکوک را شناسایی کنند و به مدل هشدار دهند که به این داده‌ها اعتماد کمتری کند.

بعد از ساخت ویژگی اولیه، مرحله حذف ویژگی‌های تکراری آغاز شد. ویژگی‌هایی که همبستگی بالای نود و پنج درصد با یکدیگر داشتند، حذف شدند تا از افزایش بی‌دلیل پیچیدگی مدل و ریسک overfitting جلوگیری شود. این تصمیم بر اساس بهترین شیوه‌های علم داده و توصیه‌های منابع معتبر اتخاذ شد. نتیجه نهایی، مجموعه‌ای از ویژگی‌های متنوع، غیرهمبسته و مفید بود که پایه و اساس مدل پیشرفته را تشکیل دادند.

لایه چهارم معماری، آموزش مدل پیشرفته بود. در این مرحله، تنظیمات الگوریتم به‌گونه‌ای بهینه شد که تعادل بین یادگیری دقیق و تعمیم‌پذیری روی داده‌های جدید برقرار شود. از تکنیک Cross-Validation برای ارزیابی عملکرد و از Regularization برای جلوگیری از overfitting استفاده شد. مدل نهایی، نه تنها دقت بالایی داشت، بلکه پایداری آن روی داده‌های تست نیز تأیید شد.

لایه پنجم و نهایی، ارائه نتایج و تفسیر آن‌ها بود. خروجی مدل، نه فقط یک عدد پیش‌بینی، بلکه یک گزارش جامع شامل امتیاز اطمینان هر پیش‌بینی، اهمیت هر ویژگی در تصمیم‌گیری و هشدارهای کیفیت داده بود. این گزارش، به زبانی ساده و قابل فهم تهیه شد تا بتوانند با اطمینان، تصمیمات استراتژیک بگیرند.

قیود اجرایی و چالش‌های عملی

یکی از مهم‌ترین قیود این پروژه، محدودیت حجم داده بود. دویست و سیزده رکورد، در دنیای یادگیری ماشین، یک دیتاست کوچک به شمار می‌رود. این محدودیت، خطر overfitting را به‌شدت افزایش می‌داد، به این معنا که مدل ممکن بود بیش از حد روی داده‌های آموزشی یاد بگیرد و روی داده‌های جدید عملکرد ضعیفی داشته باشد. برای مقابله با این چالش، از چندین استراتژی استفاده کردیم. اول، مهندسی ویژگی هوشمند که به مدل

کمک کرد تا با اطلاعات کمتر، بهتر یاد بگیرد. دوم، استفاده از Cross-Validation که به ما اطمینان داد که مدل روی زیرمجموعه‌های مختلف داده، عملکرد پایداری دارد. سوم، تنظیمات Regularization که پیچیدگی مدل را محدود کرد.

چالش دیگر، کیفیت متغیر داده‌ها بود. داده‌های ژئوفیزیکی میدانی، همیشه کامل و بی‌نقص نیستند. نویزهای محیطی، خطاهای دستگاه، مشکلات در نصب الکترودها و شرایط جوی نامساعد، همگی می‌توانند بر کیفیت داده‌ها تأثیر بگذارند. برای مقابله با این مشکل، ویژگی‌های کنترل کیفیت ساختیم که می‌توانستند به‌طور خودکار داده‌های مشکوک را شناسایی کنند. همچنین، از تکنیک‌های پاکسازی داده برای حذف یا اصلاح مقادیر پرت استفاده کردیم.

قید دیگر، نیاز به تفسیرپذیری بود. بنابراین، شفافیت و قابلیت تفسیر، یک الزام کلیدی بود. Random Forest، به‌خاطر قابلیت استخراج اهمیت ویژگی‌ها، به ما کمک کرد تا این نیاز را برآورده کنیم. ما می‌توانستیم نشان دهیم که کدام ویژگی‌ها بیشترین تأثیر را در پیش‌بینی دارند و چرا یک نقطه نسبت به نقطه دیگر اولویت دارد.

نقشه‌راه، زمان‌بندی و شاخص‌های موفقیت

مراحل اجرایی پروژه

پروژه در سه فاز اصلی اجرا شد که هر فاز، اهداف و تحویل‌های مشخصی داشت. فاز اول، فاز تحلیل اولیه و ساخت مدل پایه بود. این مرحله دو هفته طول کشید و هدف آن، درک عمیق از داده‌ها، شناسایی الگوهای اولیه و ساخت یک مدل ساده برای ارزیابی پتانسیل بود. در پایان این فاز، گزارشی شامل نتایج مدل پایه، تحلیل اکتشافی داده‌ها و شناسایی چالش‌های کلیدی ارائه شد. نتایج نشان داد که مدل پایه، دقت پناه و پنج درصد دارد که اگرچه بهتر از حدس تصادفی است، اما برای کاربردهای عملی کافی نیست.

فاز دوم، فاز مهندسی ویژگی و توسعه مدل پیشرفته بود. این فاز، حساس‌ترین و زمان‌برترین مرحله پروژه بود. در این مرحله، تیم به ساخت ویژگی‌های جدید پرداخت، با استفاده از دانش ژئوفیزیک و تکنیک‌های آماری. همچنین، فرآیند حذف ویژگی‌های تکراری و بهینه‌سازی تنظیمات مدل انجام شد. در پایان این فاز، مدل پیشرفته آموزش داده شد و نتایج آن روی داده‌های تست ارزیابی شد. دقت مدل به هفتاد و هشت تا هشتاد درصد رسید، که یک بهبود چهل درصدی نسبت به مدل پایه بود.

شاخص‌های موفقیت و معیارهای ارزیابی

موفقیت پروژه بر اساس چند شاخص کلیدی ارزیابی شد. اولین و مهم‌ترین شاخص، دقت پیش‌بینی بود که با معیار R^2 (ضریب تعیین) سنجیده می‌شد. هدف اولیه، رسیدن به R^2 بالای هفتاد و پنج درصد بود، که مدل نهایی با R^2 بین هفتاد و هشت تا هشتاد درصد، این هدف را با موفقیت محقق کرد. همچنین، خطای متوسط (RMSE) و خطای متوسط مطلق (MAE) نیز به‌عنوان معیارهای کمکی استفاده شدند. مدل پیشرفته، RMSE را از صد و چهل و سه به صد و دو اهم‌تر کاهش داد، که یک بهبود بیست و نه درصدی بود.

شاخص دوم، پایداری مدل بود. فاصله بین دقت روی داده‌های آموزشی و داده‌های تست، نشان‌دهنده میزان overfitting است. در مدل پایه، این فاصله بیست و هشت درصد بود که نشان‌دهنده overfitting شدید بود. اما در مدل پیشرفته، این فاصله به هشت درصد کاهش یافت، که یک بهبود هفتاد درصدی بود و نشان می‌داد که مدل پایداری خوبی دارد.

شاخص سوم، سرعت تحلیل بود. هدف، کاهش زمان از هفته‌ها به چند روز بود. در عمل، زمان تحلیل به کمتر از سه روز رسید، که یک دستاورد قابل توجه بود و نشان می‌داد که راه‌حل ما، نه تنها دقیق‌تر بلکه سریع‌تر نیز هست.

شاخص چهارم، شفافیت و قابلیت تفسیر بود. این شاخص، با نظرسنجی از تیم مدیریت ارزیابی شد. بازخورد آن‌ها نشان داد که گزارش‌ها، واضح، قابل فهم و کاربردی هستند و به آن‌ها کمک می‌کنند تا تصمیمات بهتری بگیرند.

شاخص پنجم، کاهش ریسک مالی بود. این شاخص، با شبیه‌سازی سناریوهای مختلف حفاری ارزیابی شد. نتایج نشان داد که با استفاده از مدل، تعداد حفاری‌های ناموفق می‌تواند به‌طور قابل توجهی کاهش یابد، که به معنای صرفه‌جویی ده‌ها هزار دلار در هر پروژه است.

چشم انداز و توسعه آینده

این پروژه، نقطه شروع یک مسیر بلندمدت است. با افزایش حجم داده‌ها، مدل می‌تواند به‌طور مستمر بهبود یابد و دقت آن به سطوح بالاتری برسد. همچنین، امکان توسعه مدل برای پیش‌بینی سایر پارامترهای ژئوفیزیکی مانند قطبش القایی یا عمق هدف وجود دارد. علاوه بر این، ادغام این مدل با سیستم‌های اطلاعات جغرافیایی و نرم‌افزارهای متداول اکتشافی، می‌تواند تجربه کاربری را بهبود بخشد و کاربرد آن را گسترش دهد.

در نهایت، این راه‌حل، نه تنها برای پروژه فعلی مفید است، بلکه می‌تواند به‌عنوان یک چهارچوب قابل تعمیم برای سایر پروژه‌های معدنی نیز استفاده شود. با کمی سفارشی‌سازی، می‌توان آن را برای انواع مختلف داده‌های ژئوفیزیکی، مناطق جغرافیایی متفاوت و حتی کانسارهای دیگر اعمال کرد. این انعطاف‌پذیری، یکی از مهم‌ترین ارزش‌های بلندمدت این پروژه است.