فیزیک زمین و فضا، دوره ۴۱، شماره ۳، پاییز ۱۳۹۴، صفحهٔ ۴۳۹- ۴۵۲

تخمین شکل و عمق گنبدهای نمکی با استفاده از تفسیر داده‌های گرانی‌سنجی به روش شبکه‌های عصبی مصنوعی چندلایه

امید الفتی[۱]، حمید آقاجانی[۲] و علیرضا حاجیان[۳*]

۱. دانشجوی کارشناسی ارشد ژئوفیزیک، دانشگاه آزاد اسلامی واحد همدان، ایران
۲. دانشیار، دانشکده معدن نفت وژئوفیزیک، دانشگاه صنعتی شاهرود، ایران
۳. استادیار، گروه فیزیک، دانشکدهٔ مهندسی هسته ای و علوم پایه، دانشگاه آزاد اسلامی واحد نجف‌آباد، ایران

(دریافت: ۹۳/۶/۸، پذیرش نهایی: ۹۴/۳/۱۲)

چکیده

در ژئوفیزیک کاربردی برای نشان‌دادن توزیع اجرام زیرزمینی اغلب از اجسامی مانند کره، استوانهٔ قائم، منشور قائم، استوانهٔ افقی، گسل قائم، تاقدیس و ناودیس استفاده می‌شود. در این مقاله برای پیداکردن یک مدل محتمل‌تر برای گنبد نمکی از شبکه‌های عصبی مصنوعی استفاده می‌شود. بدین منظور یک شبکهٔ عصبی چندلایه با بی‌هنجاری‌هایی آموزش داده شد که از دو جسم با توزیع‌های جرمی متفاوت به دست آمده‌اند و بی‌هنجاری‌های مشابهی تولید می‌کنند. این شبکهٔ آموزش‌دیده قادر است نوع جسمی که بی‌هنجاری معینی را تولید کرده است، تشخیص دهد. با استفاده از این تکنیک می‌توان ابهام میان بی‌هنجاری‌های مشابهی را که از توزیع جرم‌های متفاوت تولید می‌شود، بدون استفاده از چگالی رفع کرد. هیچ روش تفسیری وجود ندارد که بدون اینکه برای شکل و تباین چگالی هدف فرضی در نظر بگیرد، مثلاً میان یک تاقدیس و یک ناودیس تمایز قائل شود. در اینجا نشان داده می‌شود که این کار را می‌توان با استفاده از شبکه‌های عصبی مصنوعی برای تفسیر کیفی گرانی انجام داد. با استفاده از آموزش شبکه‌های عصبی مصنوعی چندلایه می‌توان تفسیر کیفی و کمی گرانی انجام داد که در این مقاله آموزش شبکه بر اساس الگوریتم مرسوم پیشرو پس‌انتشار خطا انجام گرفته است. تفسیر کیفی به معنی رفع ابهام میان اجسامی است که بی‌هنجاری مشابهی تولید می‌کنند، ولی در تفسیر کمی با شبکه‌های عصبی چندلایه، پارامترهای مدل (عمق، شعاع، گسترش عمودی و ...) به دست می‌آیند. مدل‌های کره و استوانهٔ قائم بهترین مدل‌ها برای نشان‌دادن گنبدهای نمکی‌اند؛ بنابراین از آنجا که از داده‌های واقعی گنبد نمکی هومبل استفاده شد، از مدل کره و استوانهٔ قائم استفاده کردیم. با استفاده از مدل‌های کره و استوانهٔ قائم، مجموعه‌ای از مشخصه‌های (feature) مناسب تهیه و نرمالایز شده و به عنوان ورودی به شبکهٔ عصبی به کار رفتند. از آنجا که قاعدهٔ خاصی برای مشخص‌کردن تعداد نورون‌های مناسب لایهٔ پنهان وجود ندارد، با تغییر تعداد نورون‌های لایهٔ پنهان و مقایسهٔ مجموع مربعات خطا (SSE) در هر حالت، بهترین تعداد نورون‌های این لایه به دست آمد. پس از تشخیص تعداد مناسب نورون‌های لایهٔ پنهان شبکه، با داده‌های مصنوعی به‌دست‌آمده از مدل‌های مصنوعی کره و استوانهٔ قائم به آموزش شبکه پرداختیم و در نهایت با استفاده از خروجی‌های شبکهٔ مورد استفاده برای تشخیص شکل بی‌هنجاری و شبکهٔ مورد استفاده برای تعیین پارامترهای بی‌هنجاری، شکل و پارامترهای گنبد نمکی هومبل را به دست آوردیم.

واژه‌های کلیدی: داده‌های گرانی، شبکه‌های عصبی چندلایه، گنبد نمکی، مجموع مربعات خطا

۱. مقدمه

در تفسیر داده‌های گرانی خیلی مهم است مدلی پیدا کنیم که درکی دربارهٔ زمین‌شناسی ایجاد کند و محاسبهٔ آن هم به حد کافی ساده باشد. در ژئوفیزیک کاربردی اجسامی با هندسهٔ ساده برای نشان‌دادن توزیع جرم‌های زیرزمینی به کار می‌روند. این اجسام عبارتند از: کره، استوانهٔ قائم، منشور قائم، استوانهٔ افقی، گسل عمودی، تاقدیس و ناودیس.

مقایسهٔ بین داده‌های عملی و نظری کار مشکلی است که نمی‌توان آن را با دست انجام داد و مدتی طولانی است که این کار با کامپیوترها انجام می‌گیرد؛ هرچند مقایسه به تبدیل منحنی عملی و ذخیرهٔ تعداد زیادی از بی‌هنجاری‌های مصنوعی به صورت دیجیتال نیاز دارد. در

*نگارنده رابط: E- mail: dralirezahajian@gmail.com

این مقاله نشان داده می‌شود که ظرفیت شبکه‌های عصبی مصنوعی برای دسته‌بندی اشیا به گروه، منجر به این پدیده می‌شود که یک شبکهٔ عصبی مصنوعی را می‌توان با یک‌سری از بی‌هنجاری‌هایی که برای اجسام مختلفی محاسبه شده‌اند، آموزش داده و سپس مدلی برای سایر بی‌هنجاری‌ها ارائه کرد. یک شبکهٔ عصبی مصنوعی می‌تواند مثلاً با یکصد پروفیل بی‌هنجاری برای کره و استوانهٔ قائم با اعماق و مکان‌های مختلف، آموزش داده شود. بعد از اینکه آموزش با موفقیت انجام گرفت، این شبکهٔ آموزش‌دیده می‌تواند شکل جسم را فقط از شکل بی‌هنجاری تشخیص دهد(حاجیان و همکاران، ۲۰۱۱).

کاربرد دوم و معروف شبکه‌های عصبی مصنوعی، آموزش از طریق مثال‌ها و بنابراین نتیجه‌گیری برای شباهت است. به این معنی که یک شبکهٔ عصبی مصنوعی می‌تواند با یک‌سری از بی‌هنجاری‌های مصنوعی و پارامترهای هدف متناظر با آن‌ها آموزش ببیند و پارامترهای مدل متناظر را پیدا کند. این کاربرد در حقیقت وارون‌سازی کمی حقیقی و کاملی است. در زمینهٔ شبکه‌های عصبی مصنوعی افراد زیادی کار کرده‌اند. در سال‌های اخیر، کاربرد شبکه‌های عصبی گوناگون برای مدل‌سازی داده‌های گرانی و مغناطیس افزایش یافته است. به عنوان مثال محل کپسول‌های فلزی به کمک روش شبکه‌های عصبی با سرپرست از روی دوقطبی مغناطیسی تعیین شده است (سالم و یوشیجیما، ۲۰۰۱). همچنین عمق و شعاع حفره‌های زیرزمینی از روی داده‌های ریزگرانی‌سنجی با استفاده از شبکه‌های عصبی مصنوعی و روش پس‌انتشار خطا مدل‌سازی شده است (سالم و یوشیجیما، ۲۰۰۱ و حاجیان و همکاران، ۱۳۸۸). روش شبکهٔ عصبی سلولی برای جداسازی بی‌هنجاری محلی از منطقه‌ای نیز به کار رفته است (آلبورا و همکاران، ۲۰۰۱). تا کنون روش‌های مختلفی برای تفسیر داده‌های مغناطیس و گرانی ارائه شده که هرکدام معایب و مزایایی دارند (نبیقیان و همکاران، ۲۰۰۵). شبکه‌های عصبی مصنوعی شاخه‌ای از هوش مصنوعی به حساب می‌آید که دارای الگوریتم‌های کامپیوتری در زمینه‌های مختلف طبقه‌بندی و تشخیص الگوها، تخمین پارامتر و غیره است. در جنبه‌های گوناگون تفسیر و مدل‌سازی داده‌های ژئوفیزیکی از این ابزار استفاده شده است (عثمان و همکاران، ۲۰۰۷). شبکه‌های عصبی مصنوعی کاربرد زیادی در ژئوفیزیک و نیز گرانی‌سنجی یافته‌اند (گرت و کلینگل، ۱۹۹۸).

۲. شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی از بیولوژی الهام گرفته‌اند و از عناصری تشکیل شده‌اند که روش اجرای آن‌ها شبیه به بیشتر توابع مقدماتی نورون بیولوژیکی است (مک کلوچ و پیتز، ۱۹۴۳). این عناصر به طریقی سازمان‌دهی شده‌اند که می‌توانند با آناتومی مغز مرتبط باشند. بر خلاف این شباهت ظاهری، شبکه‌های عصبی مصنوعی تعداد غافلگیرکننده‌ای از مشخصات مغز را به همراه خود دارند. مثلاً از طریق تجربه یاد می‌گیرند، از مثال‌های قبلی تعمیم می‌یابند و مشخصات اساسی را از ورودی‌هایی که حاوی داده‌های نامشخصی هستند، استخراج می‌کنند. یک شبکه می‌تواند آموزش ببیند که متن را به صوت تبدیل کند که سپس با روش‌های دیگر به سخنرانی تبدیل می‌شود (سنوسکی و روزنبرگ، ۱۹۸۷). با شبکهٔ دیگری می‌توان خطوط دست‌نویس را تشخیص داد (بار، ۱۹۸۷). می‌توان شبکهٔ مصنوعی دیگری ساخت که بر اساس سیستم تراکم تصویر استوار باشد (کاترل و مانرو، ۱۹۸۷). در تمام این کاربردها، از شبکهٔ پیش‌خور استفاده می‌شود که شاید از مفیدترین الگوریتم‌هایی است که اخیراً استفاده شده است.

شبکه‌های عصبی مصنوعی مزایایی دارند که می‌توان از میان آن‌ها به این موارد اشاره کرد:

۱. شبکهٔ عصبی به دلیل پردازش‌های موازی، از سرعت پردازش زیادی برخوردار است.

۲. شبکه‌های عصبی توان بالقوه‌ای برای حل مسائلی دارند که شبیه‌سازی آن‌ها از طریق منطقی و سایر روش‌ها،

مشکل یا غیرممکن است.

۳. شبکه‌های عصبی همانند مغز انسان به‌طور پیوسته در حال یادگیری و انطباق با محیط هستند؛ به این معنی که اگر شبکه برای وضعیتی خاص آموزش دید و تغییر کوچکی در شرایط محیط آن رخ داد، می‌تواند با آموزش مختصر، برای شرایط جدید هم مفید باشد.

۴. در شبکهٔ عصبی عملکرد نداشتن قسمتی از نورون‌ها، موجب از کارافتادگی کامل مغز نمی‌شود و امکان تصمیم‌گیری صحیح نیز وجود دارد.

۵. این روش قادر است برای داده‌ها در شرایط عدم اطمینان (اعم از اینکه به طور فازی باشند یا ناقص و توأم با نویز دریافت شده باشند)، جواب منطقی ارائه دهد (حاجیان و همکاران، ۱۳۸۸). در این مقاله از شبکهٔ عصبی از نوع پرسپترون چندلایه و به صورت با سرپرست استفاده خواهد شد و الگوریتم استفاده‌شده، الگوریتم پس‌انتشار خواهد بود. علت انتخاب شبکهٔ عصبی چندلایه وجود داده‌های آموزشی حاصل از روش‌های مدل‌سازی مستقیم کره و استوانه است که به‌راحتی با روابط تحلیلی موجود می‌توان آن‌ها را با نرم‌افزار Matlab کدنویسی کرده وداده‌های آموزشی را با تنوع لازم و در محدودهٔ عمقی وشعاعی مورد نیاز فراهم ساخت.

۳. داده‌های آموزش

مشخصه‌های مختلفی را که شکل یک جسم بی‌هنجار را تعیین می‌کنند، می‌توان از یک بی‌هنجاری در امتداد یک پروفیل اصلی به دست آورد (تانژانت نقطه‌ای که نمودار خم می‌شود، مقدار ماکزیمم‌ها و ...). شکل بی‌هنجاری فقط به شکل جسم بستگی دارد و به ابعاد آن وابسته نیست. در نتیجه به مقادیر مطلق بی‌هنجاری نیازی نیست زیرا هنگامی که شبکهٔ عصبی مصنوعی حجیم می‌شود، زمان آموزش خیلی سریع زیاد می‌شود؛ پس تعداد مشخصه‌ها باید تا حد امکان کم باشند. برای تشخیص یک کره یا یک استوانهٔ قائم فقط دو مشخصه مورد نیاز است؛ در حالی که برای یک استوانهٔ افقی یا یک دایک قائم سه مشخصه مورد نیاز است.

هیچ قانون کلی‌ای برای فهمیدن تعداد مشخصه‌های مورد نیاز وجود ندارد. شبکه‌ای که با چهار مشخصه آموزش داده شده، ممکن است مشابه یا حتی بهتر از شبکه‌ای کار کند که با سه مشخصه آموزش دیده است اما زمان آموزش به‌طور حتم افزایش می‌یابد. تقریباً هر مشخصه‌ای که شکل یک بی‌هنجاری را توصیف می‌کند، می‌تواند برای آموزش یک شبکهٔ عصبی مصنوعی استفاده شود چون محدودیت کمی برای طراحی مشخصه‌ها وجود دارد. پیداکردن کمترین تعداد ممکن مشخصه‌ها برای توصیف بی‌هنجاری که دقت کافی هم داشته باشد، کار مشکلی است. این دقت کار برای این است که شبکهٔ عصبی مصنوعی بتواند مسئله را حل کند. یک جفت مشخصه برای یک جسم متناظر با آن‌ها هرگز نمی‌توانند جسم دیگری را نشان دهند. این محدودیتی دست‌وپاگیر است، چون در غیر این صورت شبکهٔ عصبی مصنوعی هیچ جوابی پیدا نخواهد کرد. این موضوع واضح به نظر می‌رسد اما وقتی یک شبکه با بی‌هنجاری‌های زیادی آموزش ببیند، کنترل و تنظیم‌کردن آن مشکل خواهد بود. به علاوه خطاهای محاسبات حتی اگر بی‌هنجاری‌ها اختلاف کمی داشته باشند، می‌توانند به مشخصه‌های مشابهی برای اجسام متفاوت منجر شوند.

اگر یک شبکهٔ عصبی مصنوعی با کمترین تعداد ممکن از مشخصه‌ها آموزش ببیند، این خصایص باید به صورت خطی مستقل باشند، چون در غیر این صورت کمبود اطلاعات وجود داشته و شبکهٔ عصبی مصنوعی قابل آموزش‌دادن نخواهد بود. یک شبکهٔ عصبی مصنوعی که با دو مشخصهٔ مستقل خطی به‌خوبی کار می‌کند، توان اضافه‌ای از مشخصهٔ سوم که به‌صورت خطی به خصایص دیگر وابسته است، به دست نمی‌آورد. در این حالت شبکهٔ عصبی مصنوعی جوابی پیدا نمی‌کند و به‌خوبی حالت قبل هم کار خواهد کرد، اما مسلماً زمان آموزش افزایش خواهد یافت و فرایند آموزش متزلزل‌تر خواهد شد. خصایص متفاوتی که برای تشخیص

بی‌هنجاری‌ها به کار می‌روند، در شکل ۱ تعریف شده‌اند. باید دانست که انتخاب خصایص اختیاری هستند و اینکه خصایص دیگر شاید نتایج مشابهی بدهند.

مشخصه‌های مورد استفاده برای تعریف شکل بی‌هنجاری که در تفسیر کیفی و کمی به کار می‌روند، عبارتند از:

$$f_1 = \frac{xg_{50}}{xg_{75}} \quad (۱)$$

$$f_2 = \frac{(xg_{25}-xg_{66})}{(xg_{66}-xg_{75})} \quad (۲)$$

$$f_3 = \frac{xg_{75}}{xg_{50}} \quad (۳)$$

$$f_4 = \frac{(xg_{50}-xg_{75})}{(xg_{25}-xg_{50})} \quad (۴)$$

$$f_5 = \frac{xg_{25}}{xg_{50}} \quad (۵)$$

$$f_6 = \int g(x)dx \quad (۶)$$

$$f_7 = xg50 \quad (۷)$$

$$f_8 = xg75 \quad (۸)$$

$$f_9 = g_{max} \quad (۹)$$

که در روابط (۱) تا (۹)، f_1 تا f_5 مشخصه‌هایی برای توصیف بی‌هنجاری‌ها، g_y مقدار g در y درصد از g_{max} و xg_y مقدار (فاصلهٔ افقی) x مربوط به g_y هستند (گرت وکلینگل، ۱۹۹۸). شکل ۲ این ارتباط بین بردار ورودی، خروجی و هدف را نشان می‌دهد. توجه کنید که برای هر جسمی شبکهٔ عصبی مصنوعی متفاوتی آموزش می‌بیند.

با شبکه‌های عصبی مصنوعی می‌توان هم تفسیر کیفی و هم تفسیر کمی ارائه داد. تفسیر کیفی به معنی تشخیص شکل بی‌هنجاری و تفسیر کمی به معنی یافتن پارامترهای بی‌هنجاری (عمق، شعاع و ...) است. مثلاً در تفسیر کیفی برای نشان‌دادن الگوی کره، بردار هدف (۰و۱) و برای الگوی استوانهٔ قائم، بردار هدف (۱و۰) را در نظر می‌گیریم و چون جواب فقط می‌تواند ۰ یا ۱ باشد، در لایهٔ خروجی از دو نورون استفاده خواهد شد. تصویر شماتیک تفسیر کیفی و کمی با این شبکه‌های عصبی مصنوعی به ترتیب در شکل‌های ۳ و ۴ نشان داده شده است.

با مدل‌هایی که از کره و استوانه ساخته شدند، ورودی‌های شبکهٔ عصبی مصنوعی محاسبه شدند. با این ورودی‌ها به آموزش شبکهٔ عصبی مصنوعی پرداختیم. ساختار شبکهٔ عصبی مصنوعی برای تشخیص شکل بی‌هنجاری (تفسیر کیفی) بدین صورت بود که در لایهٔ پنهان اول ۶ نورون و در لایهٔ پنهان دوم ۲ نورون در نظر گرفتیم. نمودار طبقه‌بندی خروجی‌ها در حالت‌های train، test و validation به صورت شکل ۵ است. چنان‌که از شکل پیداست، ۹۹/۶ درصد از خروجی‌های شبکه برای کل داده‌های مصنوعی، جواب درست را حدس زده است که نتیجهٔ قابل قبولی است. در جدول ۱ پارامترهای دسته‌ای از این مدل‌ها که برای آموزش شبکه به کار رفتند وخروجی متناظر با هر مدل لیست شده‌اند. خروجی شبکه (a1,a2) و خطای محاسبه‌شده توسط شبکه در سمت راست جدول ۱ نشان داده شده است. این نتایج با احتمال زیادی صحیح هستند زیرا مجموع خروجی‌های نورون‌های اول و دوم در لایهٔ خروجی برای هر مدل نزدیک به ۱ است که این دلیل خوبی برای رد بعضی از نتایج خواهد بود.

لازم به ذکر است که بدون یک تفسیر کیفی خوب نمی‌توان تفسیر کمی مناسبی داشت. بنابراین برای تفسیر کمی (یافتن پارامترها)، تمام بی‌هنجاری‌ها با تباین چگالی ۳۰۰ کیلوگرم بر مترمکعب محاسبه شدند. این مقدار، متناظر است با تباین چگالی میانگین برای گنبدهای نمکی که از اشکال زمین‌شناسی‌ای است که می‌تواند با مدل کروی مدل‌سازی شود. یک شبکهٔ عصبی مصنوعی پرسپترون با ۵ نورون در لایهٔ پنهان اول، ۳ نورون در لایهٔ پنهان دوم و ۲ نورون در لایهٔ خروجی آموزش داده شد. مقدار مجموع مربعات خطا (Sum Squared Error: SSE) در این حالت برابر است با ۰/۱۰۸۶۳. پارامترهای به‌دست‌آمده از شبکهٔ عصبی برای مدل کروی در جدول ۲ ارائه شده‌اند.

چون برای تعریف شکل مدل مصنوعی استوانهٔ قائم

به سه پارامتر نیاز است، لایهٔ خروجی ۳ نورون خواهد داشت. در این حالت شبکه را ملزم کردیم که در اجرای کد مقادیری از SSE را که کمتر از ۰/۷ هستند، به ما بدهد. بنابراین مکرراً با تغییر نورون‌های لایهٔ پنهان مقادیر به‌دست‌آمده برای SSE در هر حالت برای چند مورد بر اساس جدول ۳ به دست آمد.

بنابراین بر اساس جدول ۳، شبکهٔ عصبی مصنوعی‌ای با ۴ نورون در لایهٔ ورودی، ۱۵ نورون در لایهٔ پنهان اول، ۱۲ نورون در لایهٔ پنهان دوم و ۳ نورون در لایهٔ خروجی در نظر می‌گیریم که مقدار SSE در این حالت ۰/۳۴۹۹۲۶ خواهد بود. توابع انتقال برای لایه‌های پنهان، تابع purelin در نظر گرفته شد. در نهایت پارامترهای به‌دست‌آمده از این شبکهٔ عصبی مصنوعی برای مدل استوانهٔ قائم در جدول ۴ ارائه شده است.

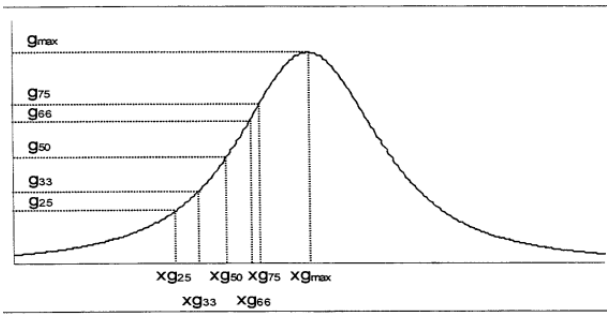

شکل ۱. تعریف خصایصی که شکل بی‌هنجاری‌ها را تعریف می‌کنند (گرت وکلینگل، ۱۹۹۸).

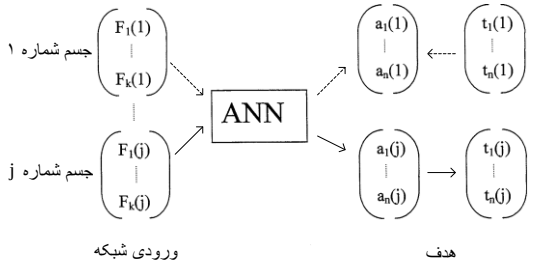

شکل ۲. توصیف شماتیک ارتباط ورودی–خروجی یک شبکهٔ عصبی مصنوعی که برای وارون‌سازی استفاده می‌شود. در شکل J تعداد اجسام در یک سری، f مشخصه، K تعداد مشخصه‌ها، J تعداد اجسام در یک سری، a خروجی شبکه، N تعداد نورون‌های لایهٔ خروجی و t پارامتر هدف است (گرت وکلینگل، ۱۹۹۸).

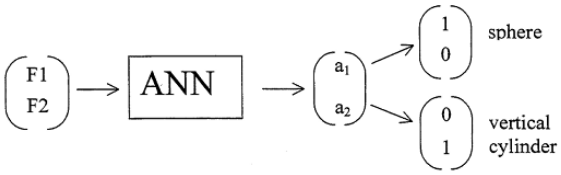

شکل ۳. توصیف شماتیک ارتباط ورودی و خروجی در شبکهٔ عصبی مصنوعی برای تشخیص شکل بی‌هنجاری (تفسیر کیفی). در شکل، a_1 خروجی شبکه از نورون اول در لایهٔ خروجی و a_2 خروجی شبکه از نورون دوم در لایهٔ خروجی است (گرت و کلینگل، ۱۹۹۸).

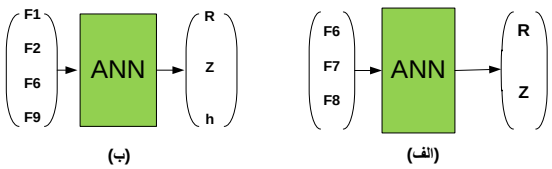

شکل ۴. توصیف شماتیک ارتباط ورودی و خروجی در شبکهٔ عصبی مصنوعی برای تعیین پارامترهای بی‌هنجاری؛ (الف) کره و (ب) استوانهٔ قائم (چنان‌که می‌بینید برای هر بی‌هنجاری، یک شبکهٔ خاص آموزش می‌بیند).

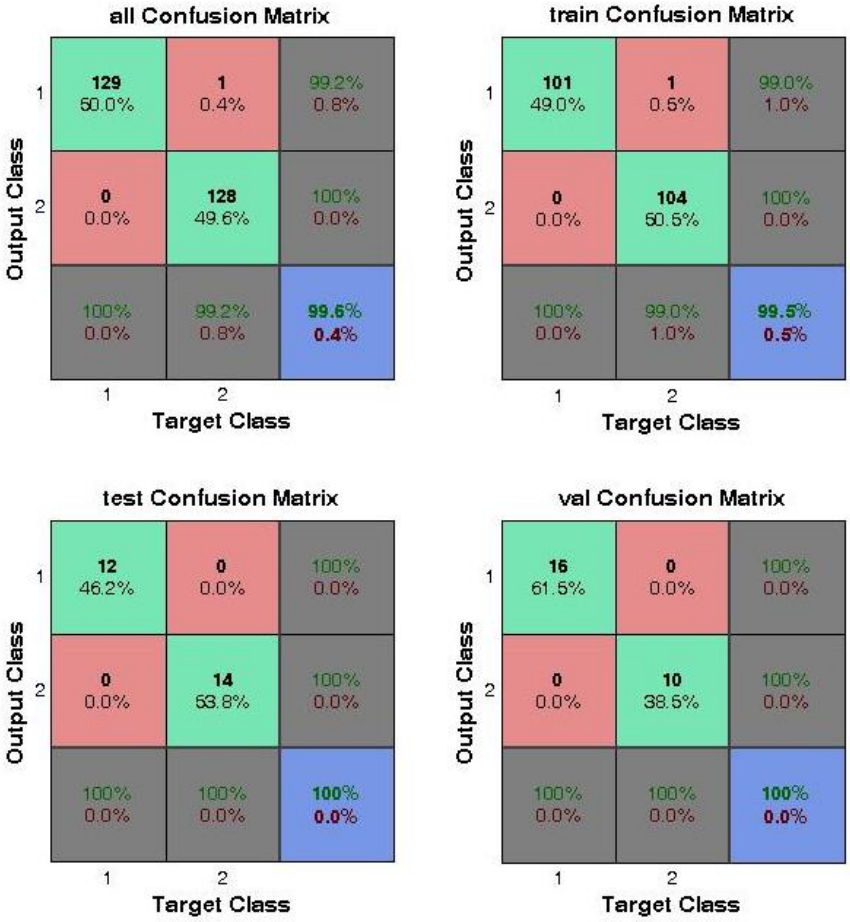

شکل ۵. نمودار خروجی شبکه در طبقه‌بندی الگوها در حالت‌های train، test و validation.

جدول ۱. مدل‌ها و پارامترهای آن‌ها و نتایج محاسبه‌شده توسط شبکهٔ عصبی مصنوعی. C استوانهٔ قائم وS نشان دهندهٔ کره است. عمق، گسترش عمودی استوانه و شعاع همگی بر حسب متر هستند و تباین چگالی بر حسب کیلوگرم بر متر مکعب است.

جسم	عمق Z	ارتفاع H	شعاع R	تباین چگالی	خروجی نورون اول در لایهٔ خروجی	خروجی نورون دوم در لایهٔ خروجی	خطای خروجی نورون اول در لایهٔ خروجی	خطای خروجی نورون دوم در لایهٔ خروجی
S	۵۰۰	۴۰۰۰	۱۰۰	۱۰۰۰	۰/۹۹۶۱۷	۰/۰۰۳۸۱	۰/۰۰۳۸۲	-۰/۰۰۳۸۱
C	۵۰۰	۴۰۰۰	۱۰۰	۱۰۰۰	۰/۰۸۴۲۳	۰/۹۱۵۷۸	-۰/۰۸۴۲۳	۰/۰۸۴۲۱
S	۱۰۰۰	۴۰۰۰	۲۰۰	۱۰۰۰	۰/۹۸۲۳۹	۰/۰۱۷۶۰	۰/۰۱۷۶۰	-۰/۰۱۷۶۰
C	۱۰۰۰	۴۰۰۰	۲۰۰	۱۰۰۰	۰/۰۰۰۱۷	۰/۹۹۹۸۲	-۰/۰۰۰۱۷	۰/۰۰۰۱۷
S	۱۵۰۰	۴۰۰۰	۳۰۰	۱۰۰۰	۰/۹۹۸۰۸	۰/۰۰۱۹۱	۰/۰۰۱۹۱	-۰/۰۰۱۹۱
C	۱۵۰۰	۴۰۰۰	۳۰۰	۱۰۰۰	۰/۰۰۲۳۵	۰/۹۹۷۶۴	-۰/۰۰۲۳۵	۰/۰۰۲۳۵
S	۳۰۰۰	۴۰۰۰	۶۰۰	۱۰۰۰	۰/۹۹۷۵۳	۰/۰۰۲۴۶	۰/۰۰۲۴۶	-۰/۰۰۲۴۶
C	۳۰۰۰	۴۰۰۰	۶۰۰	۱۰۰۰	۰/۰۰۰۰۷	۰/۹۹۹۹۲	۰/۰۰۰۰۷	-۰/۰۰۰۰۷
S	۵۲۵	۵۰۰۰	۱۰۵	۱۰۰۰	۰/۹۹۶۳۰	۰/۰۰۳۶۹	۰/۰۰۳۶۹	-۰/۰۰۳۶۹
C	۵۲۵	۵۰۰۰	۱۰۵	۱۰۰۰	۰/۰۰۰۳۶	۰/۹۹۹۶۳	-۰/۰۰۰۳۶	۰/۰۰۰۳۶
S	۱۵۲۵	۴۸۰۰	۳۰۵	۱۰۰۰	۰/۹۹۸۷۳	۰/۰۰۱۲۶	۰/۰۰۱۲۶	-۰/۰۰۱۲۶
C	۱۵۲۵	۴۸۰۰	۳۰۵	۱۰۰۰	۰/۰۰۸۳۱	۰/۹۹۱۶۸	-۰/۰۰۸۳۱	۰/۰۰۸۳۱

جدول ۲. پارامترهای به‌دست‌آمده از شبکهٔ عصبی مصنوعی برای مدل کروی.

خطای عمق	خطای شعاع	عمق به‌دست‌آمده از شبکهٔ عصبی طراحی‌شده	شعاع به‌دست‌آمده از شبکهٔ عصبی طراحی‌شده	عمق واقعی	شعاع واقعی
-۰/۰۰۷۴	-۰/۰۰۸۸	۲۸۰۷/۴۶	۵۰۸/۸۴	۲۸۰۰	۵۰۰
۰/۰۰۹۵	-۰/۰۰۶۰	۲۷۹۰/۵۵	۹۰۶/۰۵	۲۸۰۰	۹۰۰
۰/۰۱۰۷	۰/۰۰۲۶	۲۷۸۹/۲۹	۱۳۹۷/۳۵	۲۸۰۰	۱۴۰۰
-۰/۰۷۶۴	-۰/۰۰۹۲	۱۰۷۶/۴۳	۵۰۹/۲۵	۱۰۰۰	۵۰۰
-۰/۰۰۲۲	۰/۰۰۱۰	۲۰۰۲/۲۸	۴۹۸/۹۴	۲۰۰۰	۵۰۰
-۰/۰۰۷۲	-۰/۰۰۹۶	۳۰۰۷/۲۹	۵۰۹/۶۱	۳۰۰۰	۵۰۰
-۰/۰۰۱۰	۰/۰۱۵۰	۳۳۵۳/۲۰	۵۰۸/۶۴	۳۵۰۰	۵۰۵
-۰/۰۰۳۹	۰/۰۰۲۸	۳۵۰۳/۹۳	۹۰۲/۱۶	۳۵۰۰	۹۰۵
۰/۰۳۶۸	۰/۰۵۳۴	۳۴۶۳/۱۳	۱۲۵۱/۵۶	۳۵۰۰	۱۳۰۵
۰/۰۴۸۴	۰/۰۰۲۱	۶۰۲۶/۵۱	۵۰۲/۸۷	۶۰۷۵	۵۰۵

جدول ۳. مقادیر مجموع مربعات خطای چند شبکه با تعداد نورون‌های لایهٔ میانی مختلف.

شماره	تعداد نورون‌های لایهٔ پنهان اول	تعداد نورون‌های لایهٔ پنهان دوم	بهترین مقدار SSE
۱	۱۳	۷	۰/۵۳۸۳۸
۲	۱۳	۱۰	۰/۴۱۳۸۹
۳	۱۰	۷	۰/۶۲۸۵۴
۴	۱۵	۱۲	۰/۳۴۹۹۲۶
۵	۱۱	۹	۰/۴۴۷۲۹

۴. تست شبکه برای داده‌های مصنوعی در حضور نویز

برای امتحان شبکهٔ عصبی چندلایهٔ طراحی‌شده در تخمین عمق گنبدهای نمکی با مدل‌های سادهٔ کره واستوانهٔ قائم، برای مقادیر مختلفی از عمق وشعاع مدل‌های کره واستوانهٔ قائم، مقدار اثر گرانی با استفاده از روابط تحلیلی اثر کره واستوانه محاسبه گردید. به این سیگنال گرانی (با استفاده از دستور awgn در نرم‌افزار MATLB)، ۵ و ۱۰و ۱۵ درصد نویز گوسی سفید به عنوان نمونه‌ای از حضور نویز در داده‌های واقعی که در میدان اندازه‌گیری می‌شود، افزوده شد. شایان گفتن است ۵ درصد سطح نویز کم، ۱۰ درصد سطح نویز متوسط و ۱۵ درصد سطح نویز نسبتا بالا در نظر گرفته شده است. سپس مشخصه‌های مربوطه از سیگنال گرانی به‌دست‌آمده استخراج شد و به‌عنوان ورودی به شبکهٔ عصبی اعمال گردید و مقادیر عمق، شعاع وگسترش به‌دست‌آمده با مقادیر واقعی آن‌ها مقایسه شد. این کار را برای ۲۰ مدل کره و۲۰ مدل استوانه با عمق‌ها و شعاع‌های مختلفی که در محدودهٔ عمقی وشعاعی آموزش داده‌شده به شبکه قرار دارد (البته نه خود عمق‌ها و شعاع‌های آموزش داده شده بلکه در همان بازهٔ شعاعی وعمقی) انجام دادیم. نتایج در جدول‌های ۵ و۶ ارائه شده است. با دقت در این جدول‌ها به‌خوبی می‌توان دید که با افزایش سطح نویز موجود در داده‌های گرانی مصنوعی، دقت شبکه در تخمین مقادیر عمقی و شعاعی کاهش چندانی نداشته است. این موضوع نشان می‌دهد شبکهٔ عصبی طراحی‌شده دارای مقاومت خوبی در برابر حضور نویز در داده‌های گرانی تا سطح ۱۵ درصد است.

جدول ۴. پارامترهای به‌دست‌آمده از شبکهٔ عصبی مصنوعی برای مدل مصنوعی استوانهٔ قائم.

خطای ارتفاع	خطای عمق	خطای شعاع	گسترش عمودی به‌دست آمده از شبکهٔ عصبی طراحی‌شده	عمق به‌دست آمده از شبکهٔ عصبی طراحی‌شده	شعاع به‌دست آمده از شبکهٔ عصبی طراحی‌شده	گسترش عمودی واقعی (متر)	عمق اقعی (متر)	شعاع واقعی (متر)
۰/۰۷۱۵	-۰/۰۱۲۵	-۰/۰۱۳۳	۶۱۲۸/۴۰	۲۸۱۲/۵۳	۵۱۳/۳۸	۶۲۰۰	۲۸۰۰	۵۰۰
۰/۰۴۶۷۴	-۰/۰۲۳۵	-۰/۰۰۷۱	۶۱۵۳/۲۳	۲۸۲۳/۵۹	۱۰۰۷/۱۷	۶۲۰۰	۲۸۰۰	۱۰۰۰
۰/۰۰۶۲	-۰/۰۸۶۳	۰/۰۰۲۰	۶۱۹۳/۷۱	۱۰۸۶/۳۱	۴۹۷/۹۰	۶۲۰۰	۱۰۰۰	۵۰۰
۰/۰۶۰۲	۰/۰۰۵۰	-۰/۰۱۳۸	۶۱۳۹/۷۸	۱۹۹۴/۹۷	۵۱۳/۸۲	۶۲۰۰	۲۰۰۰	۵۰۰
۰/۱۰۴۳	-۰/۰۵۵۲	-۰/۰۰۴۱	۶۰۵۹/۶۵	۳۰۵۵/۲۲	۵۰۴/۱۹	۶۲۰۰	۳۰۰۰	۵۰۰
۰/۰۱۹۱	-۰/۰۳۶۴	۰/۰۰۲۱	۶۱۸۰/۸۶	۴۰۳۶/۴۰	۴۹۷/۸۸	۶۲۰۰	۴۰۰۰	۵۰۰
۰/۱۲۹۴	-۰/۰۸۲۴	-۰/۰۱۲۷	۲۳۷۰/۵۹	۲۰۸۲/۴۶	۱۰۱۲/۷۹	۲۵۰۰	۲۰۰۰	۱۰۰۰
۰/۰۱۹۸	۰/۰۲۲۱	-۰/۰۱۷۷	۳۹۸۰/۱۷	۱۹۷۷/۸۹	۱۰۱۷/۷۵	۴۰۰۰	۲۰۰۰	۱۰۰۰
-۰/۰۷۴۴	۰/۰۰۱۷	۰/۰۰۹۸	۲۵۹۹/۴۹	۱۹۹۸/۲۳	۱۵۰۹/۸۲	۲۵۲۵	۲۰۰۰	۱۵۰۰
-۰/۰۴۰۵	-۰/۰۰۰۷	۰/۰۰۲۲	۱۰۰۱۵/۵۷	۲۰۰۰/۷۶	۱۴۹۷/۷۲	۹۹۷۵	۲۰۰۰	۱۵۰۰

جدول ۵. نتایج شبکهٔ عصبی طراحی‌شده در حضور داده‌های مصنوعی با سطوح نویز متفاوت برای ۲۰ نمونه مدل کره.

خطای میانگین مربعات در تخمین عمق (متر)	خطای میانگین مربعات در تخمین شعاع (متر)	سطح نویز
۱۰/۲۱	۱۵/۶۷	۵ درصد
۱۶/۵۴	۳۴/۱۳	۱۰ درصد
۳۴/۷۹	۴۵/۶۸	۱۵ درصد

۵. داده‌های واقعی

تمام مدل‌های استفاده‌شده برای آموزش شبکه‌های عصبی، مدل‌های مصنوعی بودند و برای تمام آن‌ها هم نتایج خوبی از شبکهٔ عصبی مصنوعی برای تفسیر کیفی و کمی گرفته شد، ولی ذکر این نکته حائز اهمیت است که نمی‌توان فقط به نتایج حاصل از این مدل‌های مصنوعی اکتفا کرد؛ بلکه باید اعتبار شبکه را با استفاده از داده‌های واقعی نیز سنجید. از این‌رو برای اعتبارسنجی شبکه، از داده‌های واقعی گنبد نمکی هومبل استفاده خواهد شد.

۵. ۱. گنبد نمکی هومبل

میدان نفتی گنبد نمکی هومبل، میدان تولید نفتی در آمریکاست که در ۲ کیلومتری شهر هومبل در ساحل شمالی خلیج تگزاس در منطقهٔ کانزاس آمریکا واقع شده

است(شکل۶). سنگ مخزن این میدان نفتی که مقدار ناچیزی گاز دارد، سنگ‌های آنیدریتی و آهکی سازندهای مربوط به دوره‌های ائوسن، میوسن، الیگوسن و پلیوسن است (آقاجانی وهمکاران،a ۲۰۰۹). تله‌های نفتی گنبد نمکی هومبل هم در بخش سنگ پوشش و هم در بخش دامنهٔ آن دیده می‌شود. هومبل دارای ذخیرهٔ قابل ملاحظه‌ای بوده که نزدیک به یک قرن از مخازن آن نفت استخراج می‌شود. نقشهٔ بوگه به‌دست‌آمده پس از تصحیحات گرانی به شکل‌های ۷ و ۸ درآمده است (در دو نما). ۱۲ پروفیل از منطقه با استفاده از نرم‌افزار سورفر (surfer) برداشت کرده و با این پروفیل‌ها جهت کسب نتایج لازم به آموزش شبکه پرداختیم. پروفیل‌های ۱ تا ۱۰ پروفیل‌های اصلی هستند. از هرکدام از پروفیل‌های برداشت‌شده، مشخصه‌ها (hf) را محاسبه کرده و به عنوان ورودی به شبکه دادیم. لازم به ذکر است که پروفیل‌های ۱۱ و ۱۲ دقیقاً از روی مرکز بی‌هنجاری عبور نمی‌کنند و پروفیل‌های غیراصلی هستند (شکل‌های ۹- الف و ۹- ب). کل پروفیل‌ها در شکل ۹-ج آورده شده‌اند.

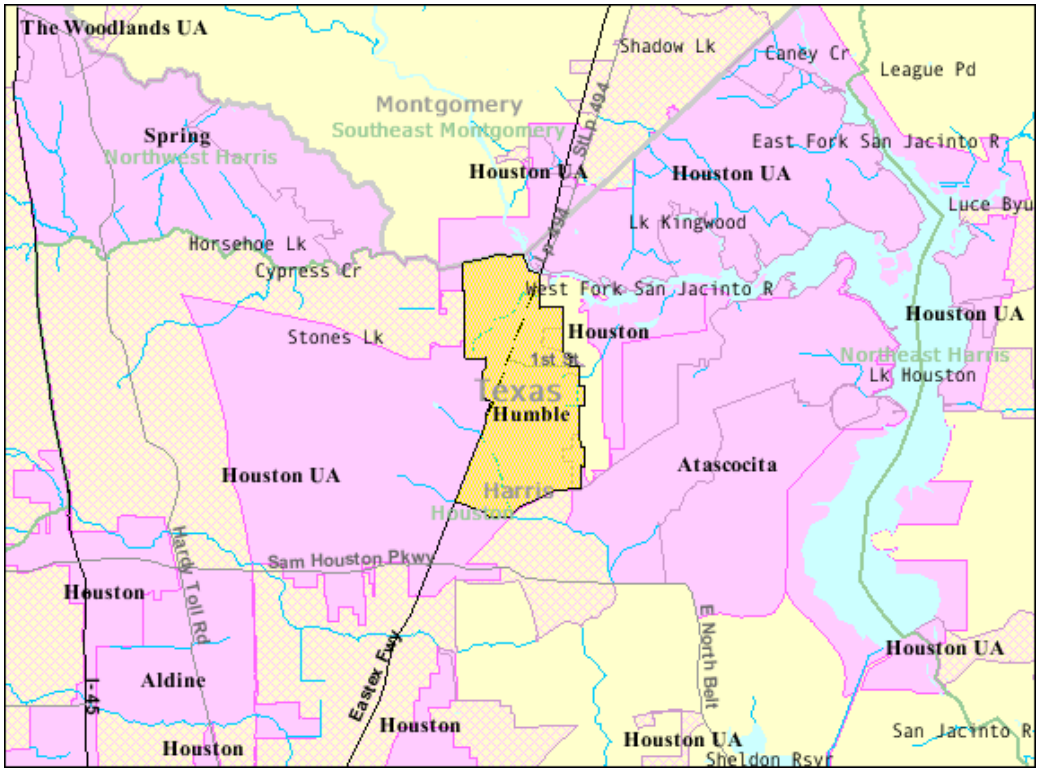

شکل ۶. نقشهٔ موقعیت جغرافیایی گنبد هومبل.

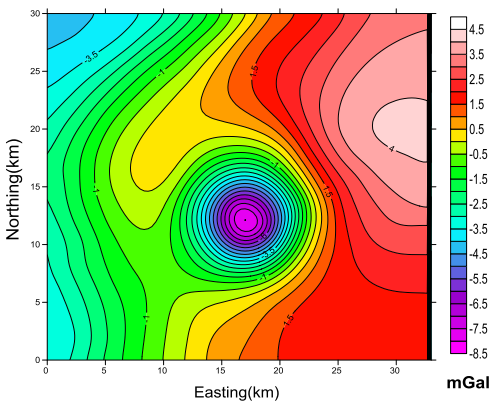

شکل ۷. بی‌هنجاری‌های گرانی باقیماندهٔ گنبد نمکی هومبل.

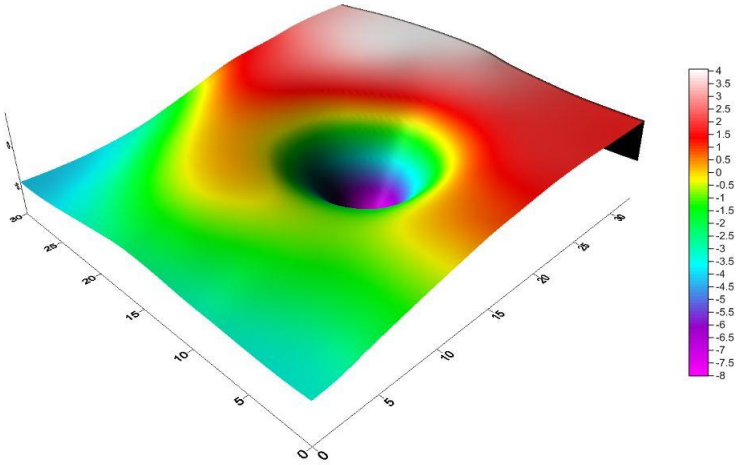

شکل ۸. نقشهٔ سه‌بعدی بی‌هنجاری بوگهٔ به‌دست‌آمده از داده‌های گرانی‌سنجی گنبد نمکی هومبل بر حسب میلی‌گال.

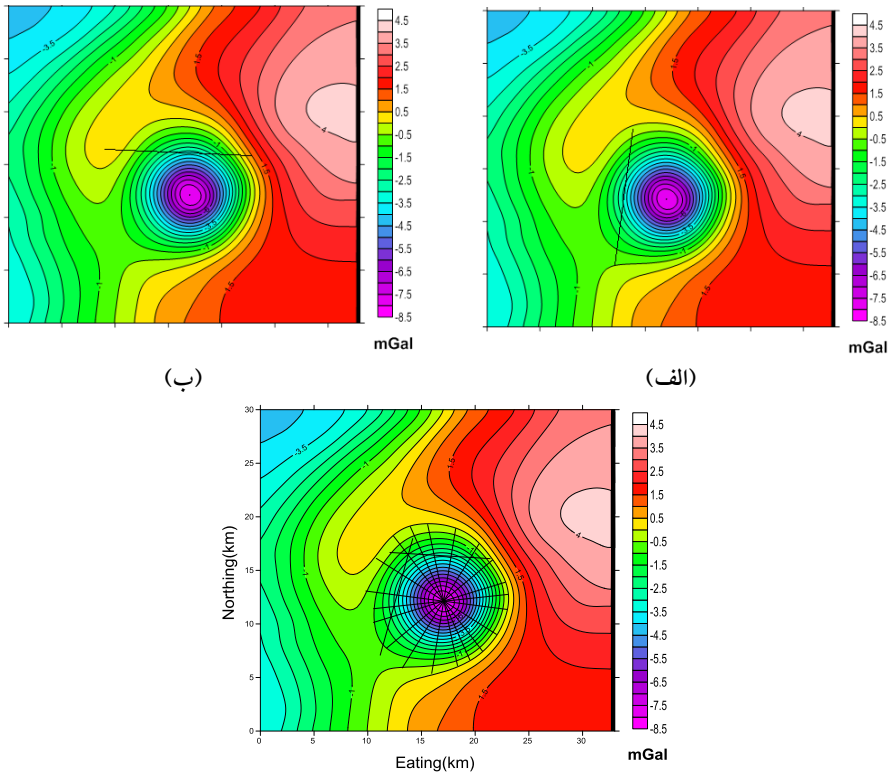

شکل ۹. (الف) پروفیل غیراصلی شمارهٔ ۱۱ که از روی مرکز بی‌هنجاری گنبد هومبل عبور نمی‌کند، (ب) پروفیل غیراصلی شمارهٔ ۱۲ که از روی مرکز بی‌هنجاری گنبد هومبل نمی‌گذرد (میلی گال) و (ج) کل پروفیل‌های عبوری از روی بی‌هنجاری گنبد هومبل.

جدول ۶. نتایج شبکهٔ عصبی طراحی‌شده در حضور داده‌های مصنوعی با سطوح نویز متفاوت برای مدل استوانهٔ قائم.

سطح نویز	خطای میانگین مربعات در تخمین شعاع (متر)	خطای میانگین مربعات در تخمین عمق (متر)	خطای میانگین مربعات در تخمین ارتفاع استوانه (متر)
۵درصد	۲۰/۳۳	۱۲/۳۴	۱۱/۵۰
۱۰درصد	۳۵/۹۷	۱۹/۵۲	۱۷/۲۳
۱۵درصد	۴۰/۴۵	۴۵/۰۶	۳۷/۳۴

چنانکه قبلاً ذکر شد چون مدل‌های کروی و استوانهٔ قائم از ابتدا بررسی شدند؛ بنابراین فقط مشخصه‌های مربوط به این مدل‌ها در جدول‌ها ذکر شده‌اند. بر این اساس مشخصه‌های به‌دست‌آمده و نرمالایزشده (بین صفر و یک) و پارامترهای به‌دست‌آمده از شبکه برای گنبد نمکی هومبل بر اساس جدول‌های ۷ و ۸ هستند.

بر اساس این داده‌ها می‌توان تفسیر کیفی و کمی انجام داد. برای تفسیر کیفی اگر f1 و f2 نرمالایزشده را برای تشخیص شکل بی‌هنجاری به عنوان ورودی به شبکهٔ آموزش‌دیده بدهیم، خروجی شبکه به صورت جدول ۹ خواهد بود.

ملاحظه می‌کنیم که بر اساس نتایج، شبکهٔ آموزش‌دیده پروفیل‌های ۳، ۴، ۵، ۷، ۹ و ۱۱ را به صورت کره (S) و پروفیل‌های ۶، ۸، ۱۰ و ۱۲ را به صورت استوانه تشخیص داده و برای پروفیل‌های ۱ و ۲ جواب مبهمی داده است. از آن‌جایی که قبلاً ذکر شد بدون یک تفسیر کیفی خوب نمی‌توان تفسیر کمی انجام داد؛ بنابراین پارامترهای پروفیل‌های ۳، ۴، ۵، ۷، ۹ و ۱۱ را که شبکه آن‌ها را به صورت کره تشخیص داده، از شبیه‌سازی در مدل کروی و پارامترهای پروفیل‌های ۶، ۸، ۱۰ و ۱۲ که شبکه آن‌ها را به صورت استوانه تشخیص داده، از شبیه‌سازی در مدل استوانهٔ قائم به دست آوردیم و نتایج در جدول ۱۰ ارائه شده‌اند.

جدول ۷. مشخصه‌های به‌دست‌آمده از ۱۲ پروفیل اصلی و غیراصلی عبوری از روی گنبد نمکی هومبل با استفاده از مدل استوانهٔ قائم.

شمارهٔ پروفیل	f_1	f_2	f_6	f_9
۱	۰/۵۰۰۸	۰	۰/۵۰۰۴	۰/۴۹۷۱
۲	۰/۰۱۸۷	۰/۳۴۳۰	۰/۰۱۹۴	۰/۰۲۷۹
۳	۰/۰۲۴۱	۰/۱۰۸۹	۰/۰۲۴۵	۰/۰۹۷۸
۴	۰/۰۲۱۹	۰/۱۱۰۷	۰/۰۲۳۷	۰/۰۹۸۶
۵	۰/۹۲۰۷	۰	۰/۹۲۰۸	۰/۹۲۱۳
۶	۰/۰۱۹۰	۰/۴۱۰۷	۰/۰۱۹۹	۰/۰۳۴۲
۷	۰/۰۱۳۰	۰/۲۷۱۴	۰/۰۱۳۶	۰/۰۳۲۵
۸	۰/۲۵۰۲	۰	۰/۲۵۰۵	۰/۲۴۶۹
۹	۰/۰۱۷۵	۰/۲۷۶۱۱	۰/۰۱۸۲	۰/۰۲۹۸
۱۰	۰/۱۴۸۲۷	۰/۱۴۷۴۴	۰/۱۴۸۴	۰/۱۰۷۹
۱۱	۰/۰۴۴۸	۱	۰/۰۴۱۶۶	۰/۱۵۳۴
۱۲	۰/۲۹۱۷	۰	۰/۲۹۱۸۶	۰/۲۲۷۴

جدول ۸. مشخصه‌های به‌دست‌آمده از ۱۲ پروفیل اصلی و غیراصلی عبوری از گنبد نمکی هومبل با استفاده از مدل کروی.

شمارهٔ پروفیل	f_6	f_7	f_8
۱	۰/۵۰۰۴	۰/۵۰۱۳	۰/۵۰۵۴
۲	۰/۰۱۹۴	۰/۰۱۸	۰/۰۱۲۰
۳	۰/۰۲۴۵	۰/۰۲۴۴	۰
۴	۰/۰۲۳۷	۰/۰۲۳۱	۰
۵	۰/۹۲۰۸	۰/۹۲۰۷	۰/۹۲۰۳
۶	۰/۰۱۹۰	۰/۰۱۹۱	۰/۰۰۹۰
۷	۰/۰۱۳۶	۰/۰۱۳۲	۰/۰۰۰۹
۸	۰/۲۵۰۵	۰/۲۴۹۹	۰/۲۵۳۹
۹	۰/۰۱۸۲	۰/۰۱۷۶	۰/۰۰۸۹
۱۰	۰/۱۴۸۴	۰/۱۴۸۱۱	۰
۱۱	۰/۰۴۱۶۶	۰/۰۴۳۸	۰
۱۲	۰/۲۹۱۸	۰/۲۸۹۹	۰/۵۴۸۰

جدول ۹. خروجی شبکهٔ تشخیص شکل بی‌هنجاری برای ۱۲ پروفیل عبوری از روی گنبد نمکی هومبل.

تشخیص شبکه	خروجی نورون دوم در لایهٔ خروجی	خروجی نورون اول در لایهٔ خروجی	شمارهٔ پروفیل
-	۰/۴۰۹	۰/۵۹۰	۱
-	۰/۶۰۵	۰/۳۹۴	۲
S	۰/۰۲۴	۰/۹۷۵	۳
S	۰/۰۱۹	۰/۹۸۰	۴
S	۰/۰۰۰۵	۰/۹۹۹	۵
C	۰/۹۶۶	۰/۰۳۳	۶
S	۰/۰۸۳	۰/۹۱۶	۷
C	۰/۹۹۹	۰/۰۰۰۱	۸
S	۰/۰۹۸	۰/۹۰۱	۹
C	۰/۹۹۹	۰/۰۰۰۲	۱۰
S	۰/۰۰۰۰۳	۰/۹۹۹	۱۱
C	۰/۹۹۷	۰/۰۰۲	۱۲

جدول ۱۰. پارامترهای به‌دست‌آمده از شبکه برای ۱۲ پروفیل عبوری از روی گنبد نمکی هومبل با استفاده از مدل‌هایی که شبکه تشخیص داده است (برای مدل کره ستون گسترش عمودی به صورت – نشان داده شده است زیرا منظور از گسترش عمودی ارتفاع استوانهٔ قائم است).

شمارهٔ پروفیل	شعاع (کیلومتر)	عمق (کیلومتر)	گسترش عمودی (کیلومتر)
۱	–	–	–
۲	–	–	–
۳	۰/۵۲۵	۶/۰۵۷	–
۴	۰/۵۲۳	۶/۰۵۶	–
۵	۱/۵۰۲	۲/۱۴۱	–
۶	۰/۲۸۰	۵/۰۴۲	۶/۶۰۹
۷	۰/۴۹۳	۶/۰۳۵	–
۸	۰/۸۳۷	۴/۳۲۰	۷/۱۰۴
۹	۰/۵۰۸	۶/۰۱۶	–
۱۰	۰/۴۵۲	۴/۷۱۸	۶/۸۶۴
۱۱	۰/۵۷۷	۶/۰۸۳	–
۱۲	۰/۸۲۷	۳/۹۵۱	۷/۲۲۰

جدول ۱۱. مقایسهٔ نتایج حاصل از روش‌های تفسیری مختلف گنبد نمکی هومبل.

روش	نویسندهٔ مقاله	مدل	عمق مرکز کره (کیلومتر)
منحنی‌های شاخص	نتلتون (۱۹۷۶)	کره	۴/۹۷
تبدیل ملین	موهان و همکاران (۱۹۸۶)	کره	۴/۹۶
تبدیل والش	شاو و اگراوا (۱۹۹۰)	کره	۴/۹۸
کمترین مربعات	عبدالرحمان و ت. م. العربی (۱۹۹۳)	کره	۴/۹۲
میانگین متحرک	عبدالرحمان و ت. م. العربی (۱۹۹۶)	کره	۴/۶۰
روش عددی تخمین عمق	عبدالرحمان و همکاران (۱۹۹۹)	کره	۳/۰۵
کمینه‌سازی کمترین مربعات سوم	عبدالرحمان و همکاران (۲۰۰۱a)	کره	۴/۹۶
روش جدید تخمین عمق	عبدالرحمان و همکاران (۲۰۰۱b)	کره	۴/۹۵
فرمول ساده	سالم (۲۰۰۳)	کره	۵/۱۵
متوسط عمق	بر اساس روش‌های فوق	کره	۴/۷۳
روش گرادیان کل نرمال	آقاجانی و همکاران (۲۰۰۹b)	کره	۴/۸۰
روش شبکه‌های عصبی چندلایه	ارائه‌شده در این مقاله	کره	۴/۷۲

جدول ۱۲. مقادیر قدر مطلق اختلاف تخمین عمق به سایر روش‌های مرسوم با روش شبکهٔ عصبی چندلایه.

روش	قدر مطلق اختلاف تخمین عمق روش موجود با روش شبکهٔ عصبی چندلایه (کیلومتر)
منحنی‌های شاخص	۰/۲۵
تبدیل ملین	۰/۲۴
تبدیل والش	۰/۲۶
کمترین مربعات	۰/۲۰
میانگین متحرک	۰/۱۲
روش عددی تخمین عمق	۱/۶۷
کمینه‌سازی کمترین مربعات سوم	۰/۲۴
روش جدید تخمین عمق	۰/۲۳
فرمول ساده	۰/۴۳
متوسط عمق	۰/۰۱
روش گرادیان کل نرمال	۰/۰۸
جذر میانگین مربعات خطاهای مطلق **(RMSE)** همهٔ روش‌ها	۰/۵۵

۶. نتیجه‌گیری

استفاده از الگوریتم‌های آموزشی پیشرفته، تفسیر را ساده می‌کند و زمان کمتری صرف می‌شود. تفسیر کمی با شبکه‌های عصبی مصنوعی دشوارتر از تفسیر کیفی است اما با روشی که در این مقاله به کار رفت، می‌توان به‌سادگی از آن استفاده کرد. گنبدهای نمکی از اشکال زمین‌شناسی هستند که با مدل‌های کروی و استوانهٔ قائم مدل‌سازی می‌شوند؛ بنابراین از آنجا که از داده‌های واقعی گنبد نمکی هومبل استفاده کردیم، از این مدل‌های مصنوعی استفاده شد. افراد دیگری برای به‌دست‌آوردن پارامترهای گنبد نمکی هومبل با روش‌های دیگر کار کرده‌اند که در جدول ۱۱ به نتایج آن‌ها اشاره شده است.

بر اساس جدول ۸، پروفیل اصلی شمارهٔ ۱۰، بی‌هنجاری را به صورت یک استوانهٔ قائم تشخیص داده و پارامترهای به‌دست‌آمده از شبکه، عمق ۴۷۱۸ متری، شعاع ۴۵۲ متری و گسترش عمودی ۶۸۶۴ متری را نشان می‌دهد. مقایسهٔ نتایج شبکهٔ عصبی چندلایه با روش‌های مختلف از جمله روش گرادیان کل نرمال (آقاجانی و همکاران، ۲۰۰۹b) در جدول ۱۱ ارائه شده است. در این جدول مقایسهٔ قدرمطلق اختلاف مقدار عمق تخمینی گنبد نمکی انواع روش‌ها، از جمله روش عصبی ارائه شده است. با در نظر گرفتن عمق به‌دست‌آمده از روش گرادیان کل نرمال، اختلاف تخمین عمق به روش عصبی ارائه‌شده در این مقاله تنها ۸۰ متر است که در اشل عمقی مربوط به گنبد نمکی هومبل خطای کمی است. همچنین در مقام مقایسهٔ کلی با متوسط عمق *به‌دست‌آمده* از سایر روش‌ها (به جز روش گرادیان کل نرمال) اختلافی برابر با ۱۰ متر وجود دارد که از لحاظ دقت تخمین در خور توجه است. بنابراین در مجموع مقایسه با نتایج سایر روش‌های موجود در جدول ۸ به‌خوبی نشان می‌دهدکه روش شبکهٔ عصبی چندلایه با دقت مناسبی می‌تواند عمق گنبد نمکی را از روی آنومالی گرانی مربوطه به دست آورد. قدر مطلق اختلاف بین عمق تخمینی هر یک از روش‌ها در مقایسه با روش ارائه‌شده در این مقاله در جدول ۱۲ آمده است.

مراجع

حاجیان، ع. ر.، ابراهیم‌زاده اردستانی، و.، لوکس،ک. و سقاییان‌نژاد، م.، ۱۳۸۸، اکتشاف قنات‌های زیرزمینی

مدفون از طریق شبکه‌های عصبی مصنوعی و با استفاده از داده‌های میکروگرانی‌سنجی، م. فیزیک زمین و فضا ۳۵(۱)، ۹-۱۵.

Abdelrahman, E. M., El-Araby, T. M. and Abo-Ezz, E. R. 2001a, Three least-squares minimization approach to depth, shape, and amplitude coefficient determination from gravity data, Geophysics, 66, 1105-1109.

Abdelrahman, E. M., El-Araby, T. M. and Abo-Ezz, E. R., 2001b, A new method for shape and depth determinations from gravity data, Geophysics, 66(6), 1774-1780.

Aghajani, H., Moradzadeh, A. and Zeng, H., 2009a, Normalizd full gradient of gravity anomaly method and its application to the Mobrunsulfide body, Canada. World Applied Science Journal, 6(3), 392-400 .

Aghajani, H. Moradzadeh, A. and Zeng, H., 2009b, Estimation of depth to anomalous body from normalized full gradient of gravity anomaly, Journal of Earth Science, 20(6), 1012-1016.

Albora, A. M., Uçan, O. M., Özmen, A., Özkan, T., 2001, Separation of Bouguer anomaly map using cellular neural network, Journal of Applied Geophysics, 46, 129-142.

Burr, D. J., 1987, Experiments with a connectionist text reader, in proceedings of a first international conference on neural networks, San Diego, C A., 4, 717-724.

Cottrel G. W., Munro, p. and Zipser, D., 1987, Image compression by backpropagation, an example of extensional programing, Advances in cognitive science, 3, 78-89.

Gret, A. A. and Klingele, E. E., 1998, Application of artificial neural networks for gravity interpretation in two dimension, Report No. 279, Institute of Geodesy and Photogrammetery, Swiss Federal Institute of Technology, Zurich.

Hajian, A., Ardestani, V. E. and Lucas C., 2011, Depth estimation of gravity anomalies using Hopfield Neural Networks, journal of the earth & space physics, 37(2), 1-9.

McCuloch, W. and Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical Biophysics, 5, 115-133.

Mohan, N. L., Anandadabu, L. and Roa, S., 1986, Gravity interpretation using Mellin transform, Geophysics, 52, 114-122.

Nabighian, M. N., Grauch, V. J. S, Hansen, R. O., Lafehr, T. R., Li1, Y., PeirceJ, W., Phillips, J. D. and RuderM, E., 2005, The historical development of the magnetic method in exploration, Geophysics, 70(6), 33-61.

Osman, O., AlboraA, M., UcanO, N., 2007, Forward modelling with forced neural networks for gravity anomaly profile, Journal of Mathematical Geology, 39, 593-605.

Salem, A. and Ushijima, K., 2001, Detection of cavities and tunnels from gravity data using a neural network, Exploration Geophysics, 32, 204-208.

Salem, A., Elawadi, E. and Ushijima, K., 2003, Short note: depth determination from residual gravity anomaly using a simple formula; Computer and Geosciences, 29, 801-804.

Sejnovski, T. J. and Rosenberg, C. R., 1987, Parallel networks that learn to pronounce English text: Complex systems, 3, 145-168.

Shaw R.K. and Agarwal P. 1990 .The application of Walsh transforms to interpret gravity anomalies due to some simple geometrical shaped causative sources: A feasibility study . Geophysics 55,843-850.