





دانشگاه صنعتی شاهرود

دانشکده مهندسی معدن، نفت و ژئوفیزیک

پایان نامه کارشناسی ارشد گرانی سنجی

تعیین شکل اجسام آنومال با استفاده از آنومالی های گرانی به روش

شبکه عصبی مصنوعی و تخمین عمق آنها

نگارنده:

مهین محمدزاده

اساتید راهنما:

دکتر حمید آقاجانی

دکتر امین روشندل کاهو

استاد مشاور:

دکتر بهزاد تخمچی

پایان نامه ارشد جهت اخذ درجه کارشناسی ارشد

شهریور ۱۳۹۴

دانشگاه صنعتی شاهرود

دانشکده : نفت، معدن و ژئوفیزیک

گروه : ژئوفیزیک

پایان نامه کارشناسی ارشد خانم مهین محمدزاده

تحت عنوان: تعیین شکل اجسام آنومال با استفاده از آنومالی های گرانی به روش شبکه

عصبی مصنوعی و تخمین عمق آنها

در تاریخ ۹۴/۰۶/۳۱ توسط کمیته تخصصی زیر جهت اخذ مدرک کارشناسی ارشد ژئوفیزیک-

گرانی سنجی مورد ارزیابی و با درجه مورد پذیرش قرار گرفت.

امضاء	اساتید مشاور	امضاء	اساتید راهنما
	نام و نام خانوادگی :		نام و نام خانوادگی :
	نام و نام خانوادگی :		نام و نام خانوادگی :

امضاء	نمایندة تحصیلات تکمیلی	امضاء	اساتید داور
	نام و نام خانوادگی :		نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :

تقدیم به

قلبهای پر مهر پدر و مادر بزرگوارم

هر چند که قابل تقدیم نیست

تشکر و قدردانی

از زحمات اساتید راهنما آقایان دکتر آقاجانی و دکتر روشندل و نیز استاد مشاور آقای دکتر تخم‌چی که در طول انجام این پایان‌نامه صبورانه و دلسوزانه مرا یاری نموده‌اند، کمال تشکر را دارم. از اساتید دوره کارشناسی ارشد آقایان دکتر نجاتی، دکتر کامکار روحانی، دکتر سلیمانی و دکتر پیروز بسیار سپاس‌گذارم. از آقای مهندس مرادی غریبوند، استاد مشاور صنعتی که از راهنمائی‌های گران‌بهای ایشان در به ثمر رسیدن این پایان‌نامه کمال استفاده را برده‌ام، تشکر و قدردانی می‌نمایم. همچنین از اداره محترم ژئوفیزیک مدیریت اکتشاف شرکت ملی نفت ایران به ویژه بخش غیرلرزه‌ای برای همکاری‌های بی‌دریغ ایشان سپاس‌گذاری می‌کنم.

تعهد نامه

اینجانب مهین محمدزاده دانشجوی دوره کارشناسی ارشد رشته ژئوفیزیک دانشکده معدن، نفت و ژئوفیزیک دانشگاه صنعتی شاهرود نویسنده پایان نامه تعیین شکل اجسام آنومال با استفاده از آنومالی های گرانی به روش شبکه عصبی مصنوعی و تخمین عمق آنها، تحت راهنمایی دکتر حمید آقاجانی و دکتر امین روشندل کاهو و مشاوره ی دکتر تخمچی متعهد می شوم .

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است .
- در استفاده از نتایج پژوهش های محققان دیگر به مرجع مورد استفاده استناد شده است .
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است .
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید .
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است .
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است

امضای دانشجو

تاریخ

مالکیت نتایج و حق نشر

کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه های رایانه ای ، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد . این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.

استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده

در ژئوفیزیک کاربرد از روش‌های مختلفی برای شناسایی ساختارهای زیرسطحی و تفسیر کمی و کیفی بی‌هنجاری‌های ناشی از چنین ساختارهایی استفاده می‌شود. شناسایی گسترش سطحی، عمقی و عمق قرارگیری اجسام، توده‌ها و پدیده‌های زمین‌شناسی از اهداف ژئوفیزیکی هستند. در بین روش‌های ژئوفیزیکی، روش گرانی‌سنجی برای شناسایی بی‌هنجاری‌های زمین‌شناسی در مقیاس‌های مختلف به کار برده می‌شود. برای تفسیر کیفی و کمی بی‌هنجاری‌ها، شناخت شکل و عمق آن‌ها با مدل‌سازی به روش‌های گوناگون استفاده می‌شود. به این منظور مدل‌های ساده مانند کره، استوانه و مدل‌های تلفیقی به کار برده می‌شود. یکی از روش‌های مورد استفاده در خصوص تفسیر کیفی و کمی روش شبکه عصبی مصنوعی است. در این تحقیق هدف استفاده از روش شبکه عصبی مصنوعی برای تخمین شکل ساختارهای زیرسطحی، تخمین عمق، شعاع و چگالی بی‌هنجاری‌های ناشی از آن‌ها است. بنابراین با تهیه مدل‌های مصنوعی و محاسبه اثر گرانی آن‌ها، به طراحی شبکه‌های عصبی پرداخته شده است. شبکه عصبی مورد استفاده در این تحقیق MLP بوده که با تعدادی مدل مصنوعی، بخشی برای آموزش و تعدادی برای اعتبارسنجی و ارزیابی، آموزش دیده است.

به منظور تخمین شکل، عمق، شعاع و چگالی آنومالی‌ها، چهار شبکه‌ی عصبی مجزا تهیه و ساخته شده است، که ابتدا شکل بی‌هنجاری‌ها شناسایی و سپس بر اساس آن تخمین عمق، شعاع و چگالی امکان‌پذیر شده است. برای این کار به جهت هماهنگ ساختن نتایج مدل‌سازی با واقعیت زمین، از مدل‌های ساده کره‌ای، مدل استوانه‌ای و مدل مصنوعی مرکب کره‌ای - استوانه قائم (گنبد نمکی) با ابعاد و پارامترهای مختلف استفاده شد. با توجه به این که شکل آنومالی گرانی وابسته به ابعاد، عمق و شکل ساختارهای زیرسطحی است، بنابراین از ویژگی‌های وابسته به نمودار اثر گرانی این پدیده‌ها به عنوان ورودی شبکه مصنوعی استفاده شده است. برای آموزش شبکه ابتدا تعدادی از نتایج مدل‌های مختلف جهت آموزش شبکه و سایر مدل‌ها به عنوان ارزیابی و اعتبارسنجی شبکه استفاده شد. برای تولید یک شبکه عصبی بهینه، شبکه‌ای با لایه‌ها و تعداد نرون‌های مختلف بررسی و نمودار عملکرد هر شبکه در حالت‌های متفاوت تهیه و برآورد شد تا مدل بهینه حاصل شود. بدین ترتیب با ساخت چند شبکه به تخمین شکل، عمق، شعاع و چگالی بی‌هنجاری‌های زیرسطحی پرداخته شد. در نهایت از شبکه بهینه شده برای تفسیر داده‌های گرانی واقعی، یعنی گنبد نمکی هرمز و گنبد نمکی هامبل

استفاده شد. نتایج بررسی‌ها نشان داد که شکل گنبد نمکی هامبل تا حد زیادی کروی شکل و عمق آن حدود ۵/۲ تخمین زده شد. همچنین از این روش در تخمین شکل و عمق آنومالی نمک هرمز در استان هرمزگان استفاده شد و نتایج این بررسی نشان می‌دهد که شکل این ساختار نمکی مرکب یعنی حالت دودکش و به همراه عرقچین کروی بوده است.

واژگان کلیدی: بی‌هنجاری گرانی، پرسپترون چندلایه (MLP)، تخمین شکل و عمق، شبکه عصبی مصنوعی، گرانی‌سنجی، گنبد نمکی.



این پایان نامه با حمایت های علمی و مالی مدیریت اکتشاف شرکت
ملی نفت ایران به انجام رسیده است.

فهرست مطالب:

<u>صفحه</u>	<u>عنوان</u>
۱	فصل اول: کلیات و اهداف
۲	۱-۱ مقدمه
۳	۲-۱ سابقه‌ی تحقیق و بکارگیری روش شبکه عصبی
۳	۱-۲-۱ ضرورت انجام تحقیق
۶	۳-۱ اهداف و مراحل انجام تحقیق
۷	۴-۱ ساختار تحقیق
۹	فصل دوم: شبکه‌های عصبی مصنوعی
۱۰	۱-۲ تعاریف و کلیات
۱۰	۲-۲ تاریخچه‌ی شبکه‌های عصبی مصنوعی
۱۲	۳-۲ معماری شبکه‌های عصبی مصنوعی
۱۲	۱-۳-۲ شبکه‌ی عصبی بیولوژیک
۱۳	۲-۳-۲ شبکه‌ی عصبی مصنوعی
۱۵	۴-۲ ویژگی‌های شبکه‌های عصبی مصنوعی
۱۷	۵-۲ ایرادات وارد به روش شبکه‌های عصبی مصنوعی
۱۷	۶-۲ ساختار شبکه‌های عصبی مصنوعی
۱۷	۱-۶-۲ شبکه‌های پیش‌خور
۱۷	۲-۶-۲ شبکه‌های پس‌خور
۱۸	۷-۲ الگوریتم‌های یادگیری در شبکه‌های عصبی مصنوعی
۱۸	۱-۷-۲ یادگیری عملکردی

۲۲	۲-۷-۲ یادگیری حافظه انجمنی
۲۳	۲-۷-۳ یادگیری رقابتی
۲۳	۲-۸ انواع شبکه عصبی مصنوعی
۲۳	۲-۸-۱ شبکه MLP
۲۷	۲-۹ مراحل یادگیری شبکه‌های عصبی
۲۸	۲-۱۰ مقادیر اولیه برای وزن‌ها و بایاس‌ها
۲۸	۲-۱۱ نرمالایز کردن داده‌های ورودی
۲۹	۲-۱۲ معیارهای پایان آموزش
۳۱	فصل سوم: تهیه‌ی داده‌های مصنوعی و ایجاد شبکه عصبی
۳۲	۳-۱ مدل‌سازی گرانی‌سنجی
۳۴	۳-۲ پاسخ گرانی بی‌هنجاری‌های با شکل منظم هندسی
۳۴	۳-۲-۱ اثر گرانی ناشی از یک کره‌ی مدفون
۳۵	۳-۲-۲ مدل استوانه‌ی قائم
۳۷	۳-۳ مدل گنبد نمکی
۴۱	۳-۴ به کار بردن داده‌های مصنوعی برای آموزش شبکه
۴۱	۳-۴-۱ تشخیص شکل توده‌های زیرسطحی
۴۳	۳-۴-۲ تشخیص پارامترهای توده‌های زیرسطحی
۴۷	۳-۴-۳ نمایش کلی مراحل کار و روند مدل‌سازی معکوس
۴۹	۳-۴-۴ آموزش شبکه‌ی عصبی
۵۳	فصل چهارم: به کار بردن روش شبکه‌ی عصبی مصنوعی بر روی داده‌ی واقعی
۵۴	۴-۱ گنبد نمکی هامبل

۵۵	۴-۱-۱ تعیین شکل گنبد نمکی هامبل
۵۸	۴-۱-۲ تخمین عمق گنبد نمکی هامبل
۶۴	۴-۱-۳ تخمین شعاع گنبد نمکی هامبل
۶۸	۴-۱-۴ تخمین چگالی گنبد نمکی هامبل
۷۵	۴-۲ نمک هرمرز
۷۷	۴-۲-۱ تعیین شکل نمک هرمرز
۸۰	۴-۲-۲ تخمین عمق نمک هرمرز
۸۵	۴-۲-۳ تخمین شعاع نمک هرمرز
۸۹	۴-۲-۴ تخمین چگالی نمک هرمرز
۹۵	فصل پنجم: نتیجه گیری و پیشنهادات
۹۸	مراجع

فهرست اشکال:

<u>صفحه</u>	<u>عنوان</u>
۵	شکل ۱-۲: مثالی از آنومالی گرانی برای یک کره و یک استوانه ی قائم
۱۳	شکل ۱-۲: اجزای اصلی نرون بیولوژیک
۱۴	شکل ۲-۲: ساختار یک نرون عصبی پردازش گر
۱۵	شکل ۳-۲: یک لایه از نرون های عصبی
۲۱	شکل ۴-۲: میانگین مربعات خطا به ازای وزن ها و بایاس ها
۲۴	شکل ۵-۲: تابع فعال سازی سیگموئید
۲۵	شکل ۶-۲: تابع فعال سازی تانژانت هایپربولیک
۲۵	شکل ۷-۲: تابع فعال سازی خطی
۲۷	شکل ۸-۲: ساختار یک شبکه ی عصبی سه لایه
۳۳	شکل ۱-۳: یک جسم سه بعدی با شکل دلخواه
۳۴	شکل ۲-۳: یک مدل کروی به همراه پارامترهای ساختاری
۳۵	شکل ۳-۳: اثر گرانی ناشی از یک کره ی مدفون
۳۶	شکل ۴-۳: یک استوانه ی قائم ضخیم
۳۸	شکل ۵-۳: پارامترهای ساختاری مدل گنبد نمکی
۳۸	شکل ۶-۳: اثر گرانی ناشی از یک استوانه ی عمودی طویل
۳۹	شکل ۷-۳: اثر گرانی ناشی از مدل گنبد نمکی
۴۰	شکل ۸-۳: اثر گرانی ناشی از پروفیل گذرنده از مرکز سه جسم بی هنجار
۴۰	شکل ۹-۳: اثر گرانی ناشی از پروفیل گذرنده از مرکز مدل های مختلف
۴۵	شکل ۱۰-۳: پارامترهای تعریف شده در معادلات مربوط به مشخصه ها
۴۶	شکل ۱۱-۳: حدود انتگرال برای محاسبه ی مشخصه ی سوم
۴۸	شکل ۱۲-۳: ترسیم روند کلی کار برای ایجاد یک شبکه ی عصبی تخمین گر

- شکل ۳-۱۳: ترسیم روند کلی کار برای مرحله‌ی تشخیص شکل ۴۸
- شکل ۳-۱۴: مراحل کلی کار در مدل‌سازی معکوس ۴۹
- شکل ۳-۱۵: طرح شماتیک ماتریس ورودی و خروجی شبکه‌عصبی ۴۹
- شکل ۴-۱: آنومالی گرانی بوگه ناشی از گنبد نمکی هامبل ۵۴
- شکل ۴-۲: نمایش حدود پارامترهای داده‌های مصنوعی ۵۵
- شکل ۴-۳: نمودار تابع کارایی شبکه‌ی تشخیص شکل ۵۶
- شکل ۴-۴: نمودار هیستوگرام خطا برای شبکه‌ی تخمین‌گر شکل ۵۷
- شکل ۴-۵: نمودار تابع کارایی برای تخمین عمق ۶۰
- شکل ۴-۶: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تخمین عمق ۶۰
- شکل ۴-۷: نمودار هیستوگرام خطا برای داده‌های فضای آموزشی ۶۱
- شکل ۴-۸: رگرسیون خطی بین خروجی‌های شبکه و مقادیر مورد انتظار ۶۲
- شکل ۴-۹: نمودار تابع کارایی برای تخمین شعاع ۶۶
- شکل ۴-۱۰: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تخمین شعاع ۶۶
- شکل ۴-۱۱: نمودار هیستوگرام خطا برای شبکه‌ی تخمین‌گر شعاع ۶۷
- شکل ۴-۱۲: رگرسیون خطی بین خروجی‌های شبکه و مقادیر مورد انتظار ۶۷
- شکل ۴-۱۳: نمودار تابع کارایی شبکه برای تخمین چگالی ۷۰
- شکل ۴-۱۴: نتایج تخمین زده شده توسط شبکه در مرحله‌ی آموزش ۷۱
- شکل ۴-۱۵: نتایج تخمین زده شده توسط شبکه در مرحله‌ی ارزیابی ۷۱
- شکل ۴-۱۶: نمودار هیستوگرام خطا برای شبکه‌ی تخمین‌گر چگالی ۷۲
- شکل ۴-۱۷: رگرسیون خطی بین خروجی‌های مورد انتظار از شبکه و خروجی‌های شبکه ۷۴
- شکل ۴-۱۸: بی‌هنجاری گرانی هامبل در برابر بی‌هنجاری به دست آمده از مدل‌سازی ۷۵
- شکل ۴-۱۹: بی‌هنجاری گرانی بوگه‌ی کامل مربوط به سازند نمک هرمرز ۷۶
- شکل ۴-۲۰: نمودار تابع کارایی شبکه‌ی تشخیص شکل ۷۷
- شکل ۴-۲۱: نمودار هیستوگرام خطا برای شبکه‌ی تخمین‌گر شکل ۷۹
- شکل ۴-۲۲: نمودار تابع کارایی شبکه‌ی تخمین‌گر عمق ۸۱

- شکل ۴-۲۳: خروجی‌های شبکه در مقابل خروجی‌های مورد انتظار از آن ۸۲
- شکل ۴-۲۴: نمودار هیستوگرام خطا در مرحله‌ی آموزش شبکه‌ی تخمین گر عمق ۸۳
- شکل ۴-۲۵: نمودار رگرسیون خطی بین خروجی‌های شبکه‌ی و خروجی‌های مورد انتظار ۸۵
- شکل ۴-۲۶: نمودار تابع کارایی شبکه‌ی تخمین گر شعاع ۸۶
- شکل ۴-۲۷: خروجی‌های شبکه در مقابل خروجی‌های مورد انتظار از آن ۸۶
- شکل ۴-۲۸: نمودار هیستوگرام خطا در مرحله‌ی آموزش شبکه‌ی تخمین گر شعاع ۸۷
- شکل ۴-۲۹: نمودار رگرسیون خطی بین خروجی‌های شبکه و خروجی‌های مورد انتظار ۸۹
- شکل ۴-۳۰: نمودار تابع کارایی شبکه‌ی تخمین گر چگالی ۹۰
- شکل ۴-۳۱: خروجی‌های شبکه در مقابل خروجی‌های مورد انتظار از آن ۹۰
- شکل ۴-۳۲: نمودار هیستوگرام خطا در مرحله‌ی آموزش شبکه‌ی تخمین گر چگالی ۹۱
- شکل ۴-۳۳: نمودار رگرسیون خطی بین خروجی‌های شبکه و خروجی‌های مورد انتظار ۹۳
- شکل ۴-۳۴: بی‌هنجاری گرانی نمک هرمز در برابر بی‌هنجاری به دست آمده از آن ۹۴

فهرست جداول

<u>صفحه</u>	<u>عنوان</u>
	فصل اول: کلیات و اهداف
۴۶	جدول ۱-۳: مشخصه‌های معرف دو مدل کروی و گنبدی شکل
۴۷	جدول ۲-۳: مشخصه‌های به کار رفته در تخمین شعاع
۴۷	جدول ۳-۳: مشخصه‌های به کار رفته در تخمین چگالی
۵۶	جدول ۱-۴: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تشخیص شکل
۵۸	جدول ۲-۴: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تعیین شکل
۵۹	جدول ۳-۴: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تخمین گر عمق
۶۳	جدول ۴-۴: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تخمین عمق
۶۴	جدول ۵-۴: نتایج عمق برای داده‌های گرانی نمک هامبل با روش‌های مختلف
۶۵	جدول ۶-۴: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تخمین گر شعاع
۶۸	جدول ۷-۴: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تخمین شعاع
۶۹	جدول ۸-۴: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تخمین گر چگالی
۷۳	جدول ۹-۴: خروجی‌های شبکه در مقابل خروجی‌های مورد انتظار از آن در تخمین چگالی
۷۸	جدول ۱۰-۴: حدود پارامترهای مدل‌های مصنوعی گنبدی
۷۸	جدول ۱۱-۴: حدود پارامترهای مدل‌های مصنوعی کروی
۸۰	جدول ۱۲-۴: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تعیین شکل
۸۱	جدول ۱۳-۴: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تخمین گر عمق
۸۴	جدول ۱۴-۴: خروجی‌های شبکه‌ی تخمین گر عمق در مقابل خروجی‌های مورد انتظار
۸۸	جدول ۱۵-۴: خروجی‌های شبکه‌ی تخمین گر عمق در مقابل خروجی‌های مورد انتظار
۹۲	جدول ۱۶-۴: خروجی‌های شبکه‌ی تخمین گر عمق در مقابل خروجی‌های مورد انتظار

فصل اول:

کلیات و اهداف

یکی از روش‌های ژئوفیزیکی برای مطالعات زیرسطحی، روش گرانی‌سنجی می باشد. در این روش تغییرات میدان گرانی زمین مورد توجه است، به این مفهوم که هر واحد سنگی زیرسطحی که دارای چگالی متفاوت از محیط دربرگیرنده‌ی خود باشد یک بی‌هنجاری گرانی است که موجب بهم‌ریختگی در میدان گرانی منطقه‌ای می‌شود. چگالی، عمق و ابعاد توده‌ی بی‌هنجار، عوامل تاثیر گذار بر مقدار بی‌هنجاری گرانی هستند. مهمترین مسئله در این روش، تفسیر درست بی‌هنجاری‌های گرانی می‌باشد. تفسیر بی‌هنجاری‌های گرانی امکان تخمین عمق، ابعاد و چگالی توده‌ی بی‌هنجار را فراهم می‌کند. روش‌های مختلفی برای شناسایی ساختارهای زیرسطحی و تفسیر کمی این ساختارها وجود دارد. از جمله‌ی اینها می‌توان به روش شبکه عصبی اشاره کرد. در تفسیر گرانی دو دسته روش وجود دارند: مستقیم و غیرمستقیم. روش مستقیم تفسیر عموماً به صورت مدل‌سازی وارون شناخته شده است. از عیوب این روش می‌توان به غیر یکتا بودن پاسخ و وابسته بودن نتیجه به یک مدل اولیه فرض شده، اشاره کرد. با انجام وارون‌سازی به کمک شبکه‌های عصبی مصنوعی رویه‌ی شرح داده شده تغییر می‌کند و دیگر با مشکلات موجود در وارون‌سازی که ذکر شد، روبرو نخواهیم بود [gret et al, 1998]. این بدان معنی است که هنگامی که یک شبکه‌ی عصبی برای تفسیر به کار برده می‌شود، می‌تواند پارامترها را برای یک مدل ارائه شده بدون هیچ‌گونه بهینه‌سازی پارامتری بیابد. هدف از این مطالعه، به کار بردن شبکه‌های عصبی برای مدل‌سازی معکوس داده‌های گرانی می‌باشد. در اینجا از شبکه‌های عصبی پرسپترون برای مدل‌سازی وارون استفاده شده است. برای تولید داده‌های اولیه از مدل‌سازی مستقیم در محیط متلب استفاده کرده و سپس الگوریتم مناسب مربوط به مدل‌سازی وارون داده‌های گرانی به روش شبکه‌های عصبی تهیه شده است. در ابتدا قابلیت این روش به کمک مدل‌های مصنوعی بررسی شده و میزان خطا و کیفیت روش مورد بحث قرار گرفته است و در نهایت این روش برای داده‌های واقعی به کار برده شده است. نتایج حاصل از این روش با نتایج حاصل از دیگر روش‌ها در تخمین عمق توافق خوبی داشت. در نهایت برای بررسی عملکرد روش شبکه عصبی، پارامترهای برآورد شده با این روش مدل‌سازی پیشرو شده و بی‌هنجاری گرانی حاصل با بی‌هنجاری گرانی واقعی مربوطه، مقایسه شده است.

۲-۱ سابقه‌ی تحقیق و بکارگیری روش شبکه عصبی

پژوهش‌های زیادی در تفسیر داده‌های گرانی به کمک شبکه‌های عصبی تاکنون انجام گرفته است. گرت و کلینگله^۱ (۱۹۹۸) کاربرد شبکه‌های عصبی را برای تفسیر آنومالی‌های گرانی در دو بعد بررسی کردند. گرت و کلینگله این توانمندی شبکه عصبی را با داده‌های مصنوعی مورد مطالعه قرار دادند. الاودی و همکاران^۲ (۲۰۰۱) از شبکه‌های عصبی به منظور آشکارسازی حفرات و تونل‌ها با داده‌های گرانی استفاده کردند. آلبورا^۳ و همکاران (۲۰۰۱) شبکه‌های عصبی سلولی را برای جدایش و تفکیک آنومالی بوگه به کار بردند. عثمان^۴ و همکاران (۲۰۰۶) روش جدیدی را برای تفسیر آنومالی گرانی باقیمانده معرفی کردند. آن‌ها شبکه‌های عصبی تحمیلی را برای تفسیر ارائه کردند. آلبورا و همکاران (۲۰۰۷) از شبکه‌های عصبی تحمیلی برای مدل‌سازی مستقیم بی‌هنجاری‌های گرانی استفاده کردند. در سال ۲۰۰۷ آیدوغان به منظور پردازش آنومالی‌های گرانی از روش شبکه‌های عصبی استفاده نمود. عثمان و همکاران (۲۰۰۷) مدل‌سازی مستقیم را با شبکه‌های عصبی برای آنومالی گرانی انجام دادند. گارنی^۵ (۲۰۱۱) مدل‌سازی معکوس آنومالی گرانی باقیمانده را با استفاده از شبکه عصبی به کار برد. کاften^۶ و همکاران (۲۰۱۱) داده‌های گرانی را با استفاده از شبکه‌های عصبی مصنوعی برای ناحیه‌ای در شرق ترکیه، مورد ارزیابی قرار دادند. در این تحقیق به منظور تعیین شکل و مدل‌سازی معکوس داده‌های بی‌هنجاری گرانی نمک، از روش ارائه شده توسط گرت و کلینگله استفاده شده است.

۱-۲-۱ ضرورت انجام تحقیق

تفسیر داده‌ها بعد از اتمام تصحیحات گرانی و حذف میدان‌های منطقه‌ای انجام می‌شود. روش‌های مختلفی برای تفسیر داده‌های گرانی وجود دارند که هدف کلی این روش‌ها مشخص کردن گسترش فضایی بی‌هنجاری مدنظر می‌باشد. این روش‌ها به طور کلی شامل جداسازی میدان‌های محلی و منطقه‌ای، برجسته‌سازی داده‌ها و مدل‌سازی بی‌هنجاری با استفاده از روش پیشرو و روش وارون می‌باشد.

¹ Gret and Klingele

² Elawdi

³ Albora

⁴ Osman

⁵ Garni

⁶ Kaftan

عموماً در گرانی‌سنجی هدف بررسی بی‌هنجاری‌های محلی می‌باشد، اما اغلب بی‌هنجاری‌های طول موج بلند منطقه‌ای با بی‌هنجاری‌های طول موج کوتاه محلی برهم‌نهی دارند. بنابراین در ابتدا حذف بی‌هنجاری‌های منطقه‌ای از بی‌هنجاری بوگه کامل و به دست آوردن بی‌هنجاری محلی ضروری می‌باشد. از جمله روش‌های مختلف برای این کار می‌توان به روش برازش چندجمله‌ای به داده‌ها و یا روش فیلتر پایین‌گذر اشاره کرد [Kearey et al, 2003].

در روش‌های برجسته‌سازی داده، پارامترهای مدل محاسبه نمی‌شوند. در این‌جا فقط برخی از ویژگی‌های توده بی‌هنجاری برجسته می‌شوند و به آسان‌تر شدن تفسیر کمک می‌کنند [Blakely, 1996]. انواع فیلترها مانند سیگنال تحلیلی، فاز محلی، مشتق عمودی و مشتق افقی جزو این روش‌ها هستند.

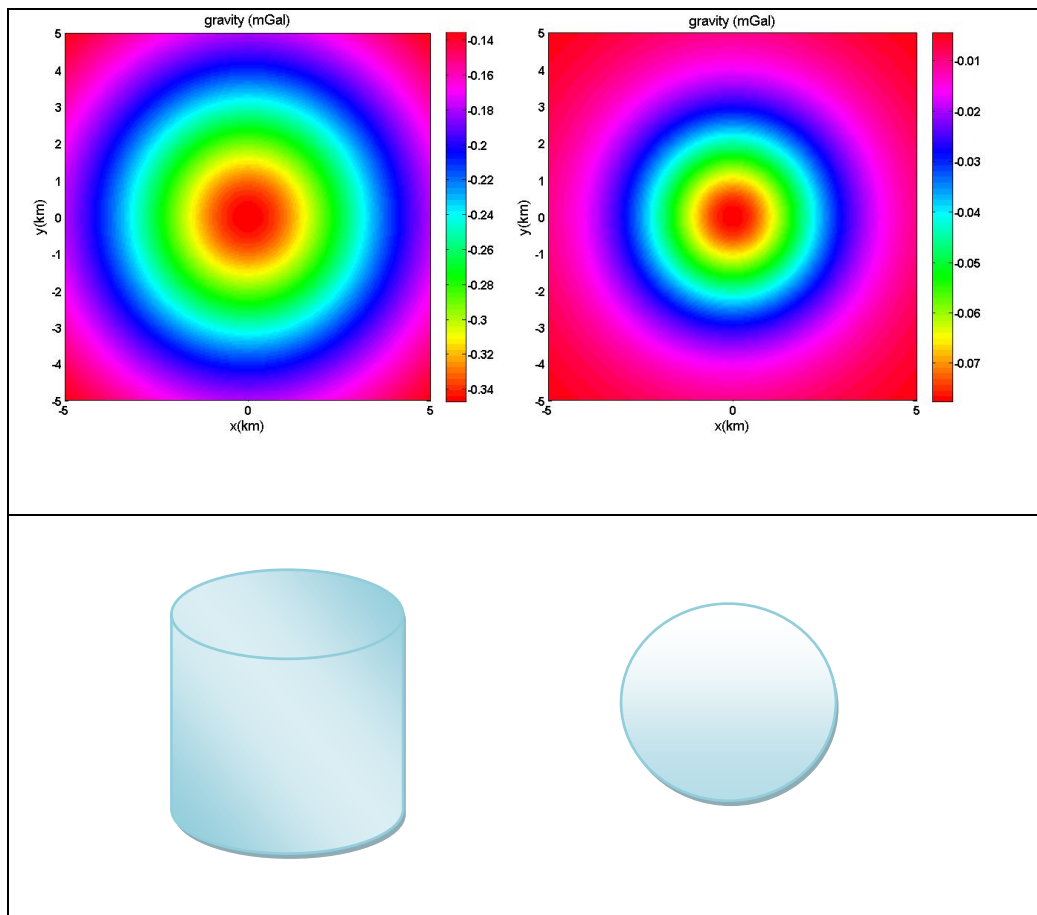
در روش مدل‌سازی پیشرو با استفاده از اطلاعات زمین‌شناسی و یا ژئوفیزیکی یک مدل اولیه در نظر گرفته می‌شود. در مرحله‌ی بعد بی‌هنجاری گرانی حاصل از این مدل محاسبه می‌شود. سپس این بی‌هنجاری به دست آمده با بی‌هنجاری گرانی مشاهده شده، مقایسه می‌شود و پارامترهای مدل تغییر داده می‌شود تا شباهت بیشتری بین این دو بی‌هنجاری به دست آید. این روند یعنی تغییر پارامترهای مدل، محاسبه‌ی بی‌هنجاری مدل و مقایسه‌ی آن با بی‌هنجاری مشاهده‌ای تا زمانی که بیشترین شباهت بین دو بی‌هنجاری به دست آید، ادامه خواهد داشت [Blakely, 1996].

در روش مدل‌سازی وارون پارامترهای توده‌ی بی‌هنجاری به طور مستقیم از بی‌هنجاری گرانی به دست می‌آیند. در این‌جا با استفاده از روش‌های ریاضی پارامترهای مدل مانند عمق، ضخامت و چگالی محاسبه می‌شوند.

در هر دو روش مدل‌سازی پیشرو یا وارون یک مشکل مهم وجود دارد که در ژئوفیزیک از آن با عنوان اصل عدم یکتایی نام برده می‌شود. در واقع با وجود این‌که در اینجا تنها یک چشمه‌ی بی‌هنجاری گرانی وجود دارد اما از یک بی‌هنجاری گرانی، چشمه‌های بی‌هنجاری متفاوتی می‌تواند به دست آید، بنابراین در این‌جا برای کاهش تعداد جواب‌ها از اطلاعات مستقل دیگر استفاده می‌شود. چنین اطلاعاتی می‌تواند شامل اطلاعات زمین‌شناسی سطحی، اطلاعات تکتونیکی، اطلاعات چاه و اطلاعات میدان‌های پتانسیل قبلی و غیره باشد [kearey et al, 2003].

همانطور که گفته شد تفسیر داده‌های گرانی به منظور تعیین شکل، عمق، ابعاد و چگالی اجسام

بی‌هنجار انجام می‌شود. البته تفسیر یکتا نیست و ممکن است دو یا چند جسم متفاوت، بی‌هنجاری‌هایی هم‌شکل ایجاد کند. در ساده‌ترین حالت، بی‌هنجاری دایره‌ای شکل هم می‌تواند توسط یک توزیع کروی شکل و هم به وسیله‌ی یک توزیع به شکل استوانه‌ی قائم ایجاد شود و یا بی‌هنجاری بیضی شکل می‌تواند هم به واسطه‌ی استوانه‌ی افقی و یا یک دایک قائم ایجاد شود. پس در مرحله‌ی اول باید تعیین گردد که شکل آنومالی مورد نظر به کدام حالت نزدیکتر است، در واقع با این کار یکی از مجهولات مساله کم می‌شود. برای مثال اگر شکل بی‌هنجاری گرانی که توسط یک جسم کروی و یک استوانه‌ی قائم را در نظر بگیریم می‌بینیم که تفاوت بسیار کمی در آنها وجود دارد (شکل ۱-۱).



شکل ۱-۱: مثالی از آنومالی گرانی برای یک کره و یک استوانه‌ی قائم

به کمک این تفاوت کوچک بین بی‌هنجاری‌ها، شبکه عصبی می‌تواند شکل جسم بی‌هنجار را تشخیص دهد [Gret et al, 1998]. اگر شبکه عصبی مصنوعی با مجموعه‌ای مناسب از این

بی‌هنجاری‌های مشابه آموزش ببینند می‌تواند تشخیص دهد که نوع جسم ایجاد کننده‌ی آنومالی کدام است. پس می‌توان ابتدا شکل کلی بی‌هنجاری گرانی به کمک آنچه که در روش گرت و همکاران (۱۹۹۸) ارائه شده است تعیین گردد و پس از آن به سراغ تعیین پارامترهای جسم مولد بی‌هنجاری مورد نظر رفت. در تفسیر ساختارهای نمک بررسی این موضوع که آیا گنبد نمکی تا سنگ بستر کشیدگی دارد و یا اینکه توسط ساختارهای دیگر از ریشه (پی سنگ) جدا شده باشد مفید است. می‌توان این دو حالت زمین‌شناسی را با دو مدل هندسی ساده‌ی کروی شکل و گنبدی شکل معرفی کرد. بی‌هنجاری‌های ناشی از این دو مدل در ابعاد و اعماق مختلف برای آموزش یک شبکه‌ی عصبی تخمین‌گر شکل به کار برده می‌شود.

پس از تعیین شکل بی‌هنجاری می‌توان شبکه‌ی عصبی دیگری برای آن شکل خاص در نظر گرفته شده و آموزش داده شود، برای تعیین پارامتر بی‌هنجاری مورد بررسی به کار برد. نکته‌ی بسیار مهمی که وجود دارد این است که هنگامی که از شبکه عصبی برای تفسیر استفاده می‌شود نیازی به اطلاعات اضافی هندسی جسم بی‌هنجار نیست.

گرت و همکاران (۱۹۹۸)، روش شبکه‌های عصبی در تفسیر بی‌هنجاری‌های گرانی را، تنها برای مدل‌های مصنوعی و در عمق‌های کم (در بیشینه‌ترین حالت ۷۵۰ متر) استفاده کردند. به علاوه آن‌ها در روش خود، اختلاف چگالی را برای همه‌ی مدل‌های آموزشی یک مقدار ثابت فرض کردند. در این تحقیق به روش شبکه‌های عصبی تخمین عمق اجسام بی‌هنجار گرانی در اعماق زیاد (تا عمق ۵.۵ کیلومتر) انجام شده است، چگالی برای مدل‌های مختلف متفاوت است و گستره‌ی مقادیر آن مشابه با ساختارهای واقعی نمک در نظر گرفته شده است. در نهایت، این روش بر روی داده‌های واقعی به کار برده شده و نتایج بسیار خوبی حاصل شده است. روش مطالعه شده در این تحقیق آسان، سریع و به طور قابل توجهی دقیق می‌باشد.

۳-۱ اهداف و مراحل انجام تحقیق

هدف نهایی بررسی بی‌هنجاری‌های گرانی تفسیر درست آن‌هاست. برای دستیابی به این مهم در این تحقیق تلاش بر این است تا ابهاماتی که در حوزه‌ی تفسیر وجود دارد، به کمک روش شبکه‌ی عصبی مصنوعی، برطرف شود. در این تحقیق این فرضیه بررسی می‌شود که با داشتن یک مجموعه‌ی آموزشی کامل و مناسب، شبکه‌ی عصبی می‌تواند اشکال و همین‌طور پارامترهای اجسام زیر سطحی را

تخمین بزند.

ابتدا برای مرحله‌ی آموزش شبکه‌ی عصبی، نیاز به ساخت یک سری مدل مصنوعی هست. به همین دلیل یک مجموعه‌ی کامل از مدل‌های موردنظر در محیط برنامه‌نویسی متلب تهیه شده است. در مرحله‌ی بعد ایجاد یک شبکه‌ی عصبی کار اصلی می‌باشد. به دلیل نبود قانونی برای تعیین ویژگی‌های اصلی شبکه مانند تعداد لایه‌های میانی، تعداد نرون‌ها در این لایه‌ها و تابع فعال‌سازی مورد استفاده در آن، این پارامترها به کمک روش سعی و خطا در مرحله‌ی آموزش تعیین می‌شوند و در نهایت بهترین مدل با کمترین خطا برای حل مساله‌ی موردنظر به دست می‌آید. در واقع باید یک الگوریتم آموزشی مناسب از بین الگوریتم‌های بهینه‌سازی شبکه برای آموزش انتخاب شده و تابع کارایی این الگوریتم برای شبکه‌های مختلف بررسی شود. در نهایت شبکه‌ای که به بهترین شکل آموزش دید، به عنوان شبکه‌ی نهایی در نظر گرفته می‌شود.

در مرحله‌ی بعد باید این مدل توسط یک سری مدل مصنوعی که در فرآیند آموزش حضور نداشته‌اند، ارزیابی شوند. اگر مدل برای این مجموعه نیز پاسخ قابل قبولی ارائه دهد، در نهایت از آن برای تفسیر داده‌های واقعی استفاده می‌شود، در غیر این صورت روال آموزش باید از اول طی شود. هدف این تحقیق بررسی میزان کارآمدی روش شبکه عصبی در تفسیر داده‌های گرانی‌سنجی و همچنین توانمندی آن نسبت به سایر روش‌ها در تخمین شکل و تخمین پارامترهای اجسام بی‌هنگار است. در نهایت از داده‌های گرانی میدان نفتی هامبل واقع در آمریکا و نیز داده‌های گرانی مربوط به سازند نمک هرمز در جنوب جزیره‌ی لارک در استان هرمزگان در این مطالعه برای تخمین شکل، عمق، شعاع و چگالی استفاده خواهد شد.

۴-۱ ساختار تحقیق

این تحقیق در پنج فصل نگارش شده است، در فصل اول به کلیاتی در مورد گرانی‌سنجی و روش‌های تفسیر در این علم، ضرورت انجام این تحقیق، مطالعات پیشین و اهداف تحقیق پرداخته شده است. فصل دوم به مبانی شبکه‌های عصبی مصنوعی، ساختار و انواع الگوریتم‌های آموزشی آن پرداخته است. در فصل سوم چگونگی تهیه‌ی داده‌های مصنوعی، تئوری روش تحقیق و چگونگی ایجاد یک شبکه‌ی عصبی مناسب شرح داده شده است. در فصل چهارم برای هر مجموعه داده‌ی واقعی چهار مرحله طی شده است. این مراحل به ترتیب مربوط به تعیین شکل، تخمین عمق، تخمین شعاع و

تخمین چگالی می‌باشند. در هر مرحله ابتدا نتایج حاصل از به کار بردن داده‌های مصنوعی در مرحله‌ی آموزش شبکه نمایش داده شده است. پس از آن شبکه‌ی آموزش دیده و اعتبارسنجی شده توسط مجموعه‌ای از مدل‌های مصنوعی ارزیابی شده و نتایج حاصل از آن ارائه و مورد بحث قرار گرفته است. در نهایت از مدل نهایی در تخمین پارامتر داده‌های واقعی استفاده شده است. پارامترهای تخمین زده شده توسط شبکه با استفاده از نسخه نه نرم‌افزار مدل‌ویژن مدل‌سازی (پیشرو) شده و بی‌هنجاری حاصل از آن با بی‌هنجاری داده‌های واقعی مقایسه شده است. در فصل پنجم پاره‌ای از نتیجه‌گیری‌های پس از انجام این تحقیق و ارائه‌ی پیشنهادهایی برای کارهای بهتر در آینده بیان شده است.

فصل دوم:

شبکه‌های عصبی مصنوعی

۱-۲ تعاریف و کلیات

در طی سالیان اخیر تحقیقات کاربردی بیشتری در حوزه‌ی پردازش اطلاعات برای مسائلی که برای آن‌ها راه‌حلی موجود نیست یا به راحتی قابل حل نیستند، انجام شده است. بر این اساس علاقه به توسعه‌ی سیستم‌های دینامیکی هوشمند مدل-آزاد که مبتنی بر داده‌های تجربی می‌باشند، افزایش یافته است. شبکه‌های عصبی مصنوعی از جمله‌ی این سیستم‌های دینامیکی به شمار می‌آیند. شبکه‌های عصبی مصنوعی^۱ بخشی از عرصه‌ی بزرگتری از علم، به نام هوش مصنوعی می‌باشند. هوش مصنوعی، در واقع الگوریتم‌هایی الهام گرفته از طبیعت هستند که در آن از رفتار و عملکردهای منظم الگوبرداری می‌شود. در شبکه‌های عصبی مصنوعی که ترکیبی از عناصر ساده عملیاتی هستند نیز، عملکرد نوروهای بیولوژیک مغز انسان مدل‌سازی ریاضی می‌شود. در واقع این شبکه‌ها سیستم پردازش توزیع موازی هستند که قابلیت یادگیری دارند. این شبکه‌ها با پذیرفتن داده‌های عددی به عنوان اطلاعات ورودی و انجام محاسبات و پردازش بر روی این داده‌ها آموزش دیده و طی این فرآیند دانش تجربی یا به عبارت دیگر قانون نهفته در ورای داده‌ها، را فرا گرفته و در نهایت از آن برای حل مسائل استفاده می‌کنند. به این دلیل که این شبکه‌ها بر اساس محاسبات روی داده‌های عددی قوانین کلی را فرا می‌گیرند، به این سیستم‌ها هوشمند می‌گویند. از شبکه‌های عصبی برای اهداف متفاوتی مانند تطبیق الگو، شبیه‌سازی، دسته‌بندی، طبقه‌بندی، مدل‌سازی و تخمین استفاده می‌شود.

شبکه‌های عصبی برای حل هر مساله سه مرحله‌ی آموزش، تعمیم و اجرا را طی می‌کند. در مرحله‌ی آموزش شبکه‌ی عصبی با به کارگیری یک مجموعه قوانین یادگیری، الگوی موجود در داده‌های ورودی به شبکه را باز می‌شناسد. پس از مرحله‌ی آموزش در مرحله‌ی تعمیم، شبکه باید برای ورودی‌هایی که در مجموعه‌ی آموزشی نبوده‌اند جواب قابل قبولی ارائه دهد و در نهایت در مرحله‌ی اجرا، شبکه برای عملکردی که طراحی شده است به کار گرفته می‌شود. هدف این فصل، ارائه‌ی مفاهیم کلی روش شبکه‌ی عصبی می‌باشد.

۲-۲ تاریخچه‌ی شبکه‌های عصبی مصنوعی

آغاز علم شبکه‌های عصبی مصنوعی را می‌توان به اواخر قرن نوزدهم و اوایل قرن بیستم نسبت داد.

^۱ Artificial Neural Network (ANN)

در این زمان مطالعات اولیه‌ی پاولف^۱ بیشتر بر طبیعت دینامیک رفتار هوشمندانه و شرطی شدگی^۲ تاکید داشتند و هنوز اشاره‌ای به مدل‌های ریاضی در این علم نشده بود. دیدگاه جدید شبکه‌های عصبی مصنوعی اولین بار در دهه‌ی ۱۹۴۰ توسط مک کالک^۳ و پیتس^۴ معرفی شد. آنها تابع منطقی نرون بیولوژیکی را طراحی کردند که یک مدل پردازش عمده‌ی موازی^۵ بود. در واقع آن دو ثابت کردند که می‌توان شبکه‌های عصبی مصنوعی را به وجود آورد که قادر به پردازش هر رفتار منطقی باشد. سپس دونالد هب^۶ (۱۹۴۶) عمل شرط‌گذاری کلاسیک را که پیشتر توسط پاولف مطرح شده بود به عنوان خواص نرون‌ها معرفی نمود و سپس قانون به‌روزشدن وزن‌های سیناپسی را برای یادگیری نرون‌های بیولوژیکی ارائه داد. پس از آن فرانک روزنبلات^۷ (۱۹۵۸) اولین شبکه‌ی عصبی را با نام شبکه‌ی پرسپترون شبیه‌سازی کرد. پرسپترون را می‌توان اولین شبکه‌ی عصبی دانست که با هدف محاسباتی ساخته شد. همچنین برنارد ویدرو^۸ و مارشن ای هوف^۹ (۱۹۶۰) شبکه‌ی خطی آدلاین^{۱۰} را با قانون یادگیری جدید مطرح کردند. در شبکه‌ی عصبی آدلاین که مخفف عبارت عنصر خطی سازگار می‌باشد، از روش‌های بهینه‌سازی بیشترین افت^{۱۱} و کمترین متوسط مربعات^{۱۲} در به‌روزرسانی وزن‌ها استفاده شد. قانون ویدرو هوف هم‌اکنون در بسیاری از شبکه‌های عصبی استفاده می‌شود و قانون پس‌انتشار خطا^{۱۳} که یک قانون پرکاربرد در یادگیری شبکه‌های عصبی می‌باشد نیز تعمیمی از این قانون است. پیشرفت شبکه‌های عصبی تا دهه‌ی ۷۰ قرن بیستم ادامه یافت. در این دهه کوهنن^{۱۴} (۱۹۷۲) و اندرسون^{۱۵} (۱۹۷۲) به طور مستقل شبکه‌های عصبی جدیدی را معرفی کردند که قادر بودند به عنوان عناصر ذخیره‌ساز عمل کنند. گروسبرگ^{۱۶} (۱۹۷۶) روی شبکه‌های

¹ Paoulf

² Conditioning

³ McCulloch

⁴ Pitts

⁵ Massively parallel processing

⁶ Donald O. Hebb

⁷ Frank Rosenblatt

⁸ Bernard Widrow

⁹ Marcian E. Hoff

¹⁰ ADAptive LINear Element = ADALINE

¹¹ Steepest Desecent

¹² Least Mean Squares

¹³ Error Back Propagation

¹⁴ Kohonen

¹⁵ Anderson

¹⁶ Grossberg

خودسازمانده کار کرد. در دهه‌ی ۸۰ با رشد تکنولوژی میکروپروسورها تحقیقات روی شبکه‌های عصبی افزایش یافت و ایده‌های جدیدی مطرح شد. در این دهه با بروز دو نگرش جدید شبکه‌های عصبی متحول شدند. اولین ایده که توسط هاپفیلد^۱ (۱۹۸۲) مطرح شد، استفاده از مکانیسم تصادفی جهت توضیح عملکرد طبقه‌ای وسیع از شبکه‌های برگشتی بود که می‌توان آن‌ها را جهت ذخیره‌سازی اطلاعات استفاده نمود. دومین ایده الگوریتم پس انتشار خطا می‌باشد که توسط راملهارت و مک کلند^۲ (۱۹۸۶) برای شبکه‌های عصبی چند لایه مطرح گردید. در دهه‌ی اخیر شبکه‌های عصبی در هر دو جهت توسعه‌ی تئوریک و عملی در حال رشد می‌باشند [منهاج، ۱۳۸۹].

۳-۲ معماری شبکه‌های عصبی مصنوعی

همانطور که اشاره شد شبکه‌های عصبی مصنوعی از شبکه‌ی عصبی مغز انسان الهام گرفته و در واقع تقلیدی ساده‌سازی شده از آن است. بنابراین در ابتدا اشاره‌ای به سازوکار شبکه‌های عصبی بیولوژیک ضروری به نظر می‌رسد.

۳-۲-۱ شبکه‌ی عصبی بیولوژیک

در سیستم عصبی کوچکترین واحد پردازشگر اطلاعات نرون یا سلول عصبی بیولوژیکی نام دارد که اساس عملکرد این سیستم‌ها را تشکیل می‌دهد. یک نرون از سه بخش اصلی تشکیل می‌شود:

۱. بدنه‌ی سلول^۳ شامل هسته^۴ و بخش‌های حفاظتی

۲. دندریت‌ها^۵

۳. آکسون‌ها^۶

شکل (۱-۲) یک شبکه‌ی عصبی بیولوژیک را نشان می‌دهد. نرون سیگنال ورودی را که به صورت یک تحریک الکتروشیمیایی می‌باشد، از نرون دیگر به وسیله‌ی سیناپس^۷ها دریافت می‌کند. نرون‌ها توسط دندریت‌ها با هم مرتبط هستند. به محل تلاقی یک آکسون از یک نرون به دندریت‌های نرون دیگر سیناپس می‌گویند که معمولاً ساختارهای کوچک شیمیایی هستند. هسته‌ی سلول ورودی‌های

^۱ Hopfield

^۲ Rummelhart and McClelland

^۳ Cell body

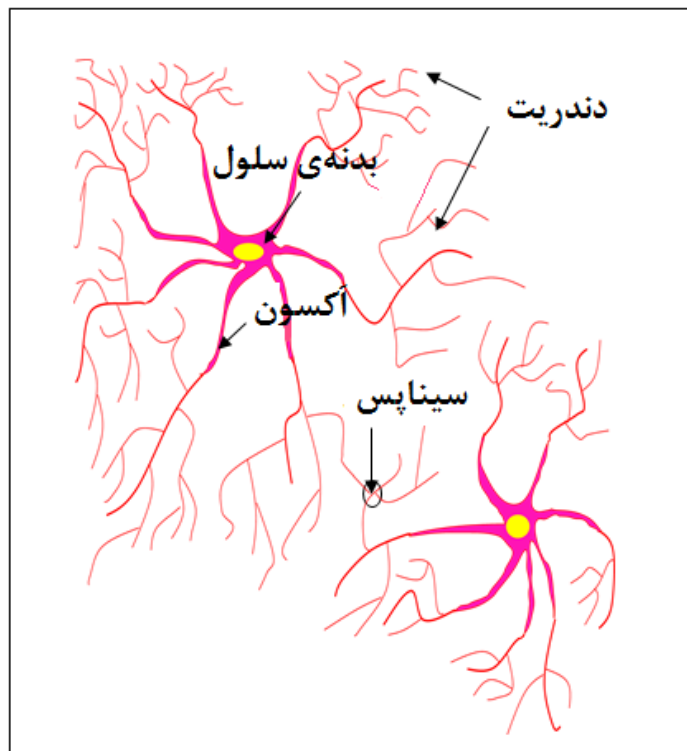
^۴ Nucleus

^۵ Dendrites

^۶ Axon

^۷ Synapse

دریافت شده از سیناپس را با هم مخلوط می‌کند و یک خروجی وابسته به کل ورودی‌ها ارائه می‌دهد. سیگنال خروجی به وسیله‌ی آکسون انتقال یافته و به وسیله‌ی سیناپس‌های واقع شده در انتهای آکسون به نرون بعدی فرستاده می‌شود. لازم به ذکر است که سیناپس‌ها تنها منتقل کننده‌ی اطلاعات نیستند بلکه اطلاعات ورودی را در این فرآیند وزن‌دهی می‌کنند. به این ترتیب یک سیگنال در طول یک شبکه‌ی عصبی انتشار می‌یابد.



شکل ۱-۲: اجزای اصلی نرون بیولوژیک [Haykin, 1994]

۲-۳-۲ شبکه‌ی عصبی مصنوعی

شبکه‌ی عصبی مصنوعی را می‌توان ترکیبی از نورون‌ها و لایه‌هایی که شامل این نرون‌ها هستند، دانست. نورون‌های ریاضی که آن‌ها را گره یا سلول نیز می‌نامند، ساختاری مشابه با نورون‌های بیولوژیک دارند. هر نورون ریاضی پردازش‌گر از دو بخش تشکیل شده است:

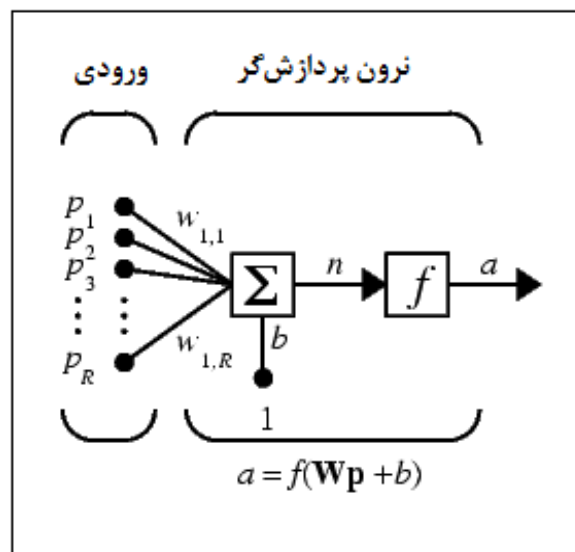
بخش اول، تابع ترکیب نام دارد به این دلیل که این تابع تمام ورودی‌ها را که مقادیری اسکالر هستند با هم ترکیب کرده و خروجی آن یک عدد می‌باشد. مشابه با نورون بیولوژیک که در آن اطلاعات در سیناپس‌ها وزن‌دهی می‌شوند، در نورون‌های مصنوعی نیز از یک تابع ترکیب وزن‌دار استفاده می‌شود که در آن به هر ورودی یک وزن اختصاص داده می‌شود. هر ورودی در وزن خود

ضرب شده و در نهایت همه‌ی این ورودی‌های وزن داده شده مطابق با فرمول (۱-۲) با هم جمع می‌شوند [منهاج، ۱۳۸۹].

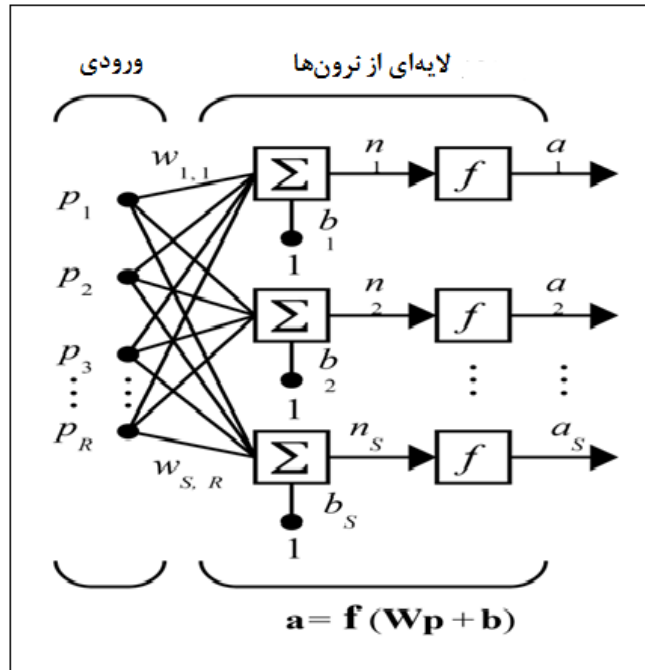
$$n = \sum_{i=0}^r p_i w_i + b \quad (1-2)$$

که در آن p ؛ ورودی سیستم، w ؛ وزن سیناپسی مربوط به هر ورودی، n ؛ خروجی سیستم، b ؛ بایاس و r ؛ تعداد کل ورودی‌هاست.

بخش دوم، تابع فعال‌سازی یا تابع انتقال نام دارد که یک حد آستانه‌ی معین دارد. تا زمانی که مقدار ورودی به حد آستانه نرسد مقدار خروجی بسیار کوچک یا نزدیک به صفر است اما همین‌که ورودی به حد آستانه رسید، خروجی مقداری بزرگ خواهد داشت و به اصطلاح نرون فعال یا تحریک شده است. توابع انتقال در نرون‌ها اگر نامشابه باشند نتیجه بهتر و دقیق‌تر خواهد بود، ولی به دلیل اینکه کار با توابع مختلف دشوار است و تعداد مجهولات مساله افزایش می‌یابد با در نظر گرفتن یک نوع تابع تحریک و وارد نمودن یک بایاس در واقع توابع تحریک متفاوتی ایجاد شده است. بایاس نسبت به وزن، اثر کم‌تری در آموزش مناسب شبکه دارد. تنظیم درست و مناسب بردار وزن و بایاس، باعث بوجود آمدن شبکه‌ای قوی و صحیح می‌شود. شکل (۲-۲) ساختار یک نرون ریاضی پردازش‌گر را نشان می‌دهد که در آن f تابع انتقال نرون می‌باشد و شکل (۲-۳) یک لایه از نرون‌های پردازش‌گر در شبکه‌ی عصبی را نشان می‌دهد.



شکل ۲-۲: ساختار یک نرون عصبی پردازش‌گر [Matlab, Manual help].



شکل ۲-۳: یک لایه از نرون‌های عصبی [Matlab, Manual Help].

۲-۴ ویژگی‌های شبکه‌های عصبی مصنوعی

امروزه شبکه‌های عصبی در حل مسائلی که پیچیدگی‌های فراوان دارند و دستیابی به حل فرمول آنها دشوار و یا غیرممکن می‌باشد، بسیار کاربرد دارند. کاربرد فراوان شبکه‌های عصبی در حوضه‌های مختلف علم و فناوری به دلیل ویژگی‌های خاص آن می‌باشد که در اینجا به آنها اشاره می‌شود:

الف- قابلیت یادگیری

قابلیت یادگیری یعنی توانایی تنظیم پارامترهای شبکه در مسیر زمان که شبکه شرایط جدیدی را تجربه می‌کند. قابلیت یادگیری این امکان را فراهم می‌سازد تا در حالتی که شبکه برای یک مسأله‌ی خاص آموزش دید، اگر تغییر کوچکی در شرایط آن رخ داد شبکه بتواند با مختصر آموزشی برای شرایط جدید نیز کارآمد باشد [منهاج، ۱۳۸۹].

به طور کلی هر جا نیاز به یادگیری یک نگاشت خطی یا غیرخطی باشد از شبکه‌های عصبی مصنوعی قادر به ایفای نقش هستند. استخراج نتایج تحلیلی از یک نگاشت غیرخطی که با چندین نمونه مشخص شده، نیازمند طراحی قوی ساختار شبکه است و کار ساده‌ای نیست [Haykin, 1994]. دلیل آن را می‌توان این‌چنین بیان کرد که نرون‌ها اکثراً یک دستگاه غیرخطی می‌باشند و بنابراین یک

شبکه عصبی که از به هم پیوستن این نرون‌ها تشکیل می‌شود نیز یک سیستم غیرخطی و پیچیده خواهد شود [Hangman et al, 1996]. توجه به این نکته نیز ضروری است که خاصیت غیرخطی نرون‌ها، در کل شبکه توزیع می‌گردد.

ب- پردازش اطلاعات به صورت متنی

در شبکه‌های عصبی هر وزن سیناپسی مربوط به کل ورودی‌های شبکه است و هر نرون از فعالیت سایر نرون‌ها متأثر می‌باشد. بنابراین اطلاعات و به عبارتی دانش شبکه در وزن‌های سیناپسی آن ذخیره می‌باشند و به عبارت دیگر بصورت متن^۱ توسط شبکه عصبی پردازش می‌شوند. با این اوصاف اگر تعدادی از سلول‌های شبکه حذف شوند و یا عملکرد اشتباه داشته باشند باز هم رسیدن به پاسخی صحیح، محتمل می‌باشد، اگرچه این احتمال برای تمام ورودی‌ها کاهش یافته ولی برای هیچ‌یک از بین نرفته است [منهاج، ۱۳۸۹].

پ- توانایی تعمیم‌پذیری

پس از آموزش، شبکه‌ی عصبی می‌تواند در قبال ورودی‌هایی که قبلاً در مجموعه‌ی آموزشی نبوده‌اند پاسخ مناسب ارائه دهد. این خروجی بر اساس مکانیسم تعمیم^۲ بوجود می‌آید. به عبارت دیگر شبکه تابع را یاد می‌گیرد، الگوریتم را می‌آموزد و رابطه تحلیلی مناسبی برای نقاط در فضا بدست می‌آورد [منهاج، ۱۳۸۹].

ث- توانایی پردازش موازی اطلاعات با سرعت بالا و به شکل توزیعی

نرون‌های موجود در هر لایه به طور همزمان به ورودی‌های آن لایه پاسخ می‌دهند، بنابراین سرعت پردازش بالا می‌رود. در واقع در سیستم شبکه عصبی وظیفه کلی پردازش، بین پردازنده‌های کوچکتر مستقل از یکدیگر توزیع می‌گردد [منهاج، ۱۳۸۹].

ج- مقاوم بودن در برابر خطا

عملکرد شبکه‌ی عصبی حاصل عملکردهای توأم همه‌ی نرون‌ها در لایه‌های شبکه است. در شبکه‌های عصبی نرون‌ها خطاهای همدیگر را تصحیح کرده و خروجی نهایی از خطاهای جزئی محلی مصون می‌ماند. این خصوصیت باعث افزایش قابلیت مقاوم بودن یا تحمل‌پذیری خطاها در سیستم

¹ Context

² Generalization

می‌گردد [منهاج، ۱۳۸۹].

۵-۲ ایرادات وارد به روش شبکه‌های عصبی مصنوعی

با وجود کارایی بالای شبکه‌های عصبی ایراداتی بر آن وارد است:

۱. ورودی‌های شبکه باید در دامنه‌ی صفر تا یک باشند.
۲. شبکه‌های عصبی توضیح و قوانین صریحی در مورد پاسخ‌ها ارائه نمی‌کنند.
۳. همواره احتمال ارائه‌ی یک پاسخ سریع و در نتیجه احتمال بروز خطا وجود دارد.

۶-۲ ساختار شبکه‌های عصبی مصنوعی

در یک تقسیم بندی کلی بر اساس چگونگی ارتباط نرون‌ها با همدیگر شبکه‌های عصبی را می‌توان به دو دسته‌ی زیر تقسیم بندی کرد [منهاج، ۱۳۸۹]:

۱-۶-۲ شبکه‌های پیش‌خور^۱

در این نوع شبکه‌ها حرکت اطلاعات از لایه‌ی ورودی به لایه‌ی خروجی می‌باشد و هیچ‌گونه سیگنال برگشتی اطلاعات وجود ندارد. این نوع شبکه‌ها ساده‌ترین و پرکاربردترین شبکه‌های عصبی می‌باشند. از این شبکه‌ها برای مدل کردن ویژگی‌های ایستا^۲ (ویژگی‌هایی وابسته به زمان تغییر نیستند) استفاده می‌شود، بنابراین در این تحقیق این نوع شبکه‌ها به کار برده می‌شوند. این دسته از شبکه‌ها انواع مختلفی دارند که در این جا تنها یکی از معروفترین آنها یعنی شبکه‌های پرسپترون چند لایه^۳ و الگوریتم‌های آموزش آن معرفی و به کار برده می‌شود.

۲-۶-۲ شبکه‌های پس‌خور^۴

در این نوع شبکه‌ها سیگنال برگشتی وجود دارد. به عبارتی سیگنال اطلاعات خروجی از یک نرون می‌تواند به همان نرون یا نرون‌های دیگر در همان لایه و یا حتی نرون‌های لایه‌های قبل، برگشت داده شود. این شبکه‌ها توانایی یادگیری بیشتری نسبت به شبکه‌های پیش‌خور دارند. از شبکه‌های پس‌خور برای مدل کردن ویژگی‌های پویا^۵ (ویژگی‌هایی که وابسته به زمان می‌باشند) استفاده می‌شود.

^۱ Feed forward networks

^۲ Static

^۳ MLP = Multi Layer Perceptron

^۴ Feedback networks

^۵ Dynamic property

۷-۲ الگوریتم‌های یادگیری در شبکه‌های عصبی مصنوعی

منظور از یادگیری (آموزش) شبکه‌های عصبی مصنوعی، فرآیندی است که در آن بهینه‌مقدارهای بایاس و وزن‌ها برای هر یک از نرون‌های شبکه به دست آید به طوری که خروجی شبکه تا حد ممکن به مقدار خروجی‌های مورد انتظار از شبکه، نزدیک شوند. الگوریتم‌های یادگیری متنوعی وجود دارند که هر کدام از آن‌ها تعیین‌کننده‌ی چگونگی عملکرد شبکه می‌باشند. به این معنی که این الگوریتم‌ها تعیین می‌کنند که هر نرون در شبکه چه نوع عملیات ریاضی انجام دهد، خطاها چگونه محاسبه شده و در نهایت وزن‌ها و بایاس‌ها چگونه تصحیح شوند. در همه‌ی این الگوریتم‌ها دو روش مختلف برای آموزش شبکه‌های پردازشی موازی بر اساس نحوه‌ی ورود اطلاعات وجود دارد:

الف- آموزش ترتیبی^۱

در این روش پس از این که اولین ورودی به شبکه ارائه شد، محاسبات انجام شده و پارامترهای شبکه تغییر می‌کنند. سپس به ترتیب ورودی‌های بعدی به شبکه عرضه و هر بار پارامترها تنظیم می‌شوند.

ب- آموزش دسته‌ای^۲

در این روش تنظیم پارامترهای شبکه پس از ارائه‌ی تمامی نمونه‌های آموزشی انجام می‌شود. روش ترتیبی بدلیل حافظه‌ی کمتری که برای وزن‌ها نیاز دارد، مخصوصاً هنگامی که تعداد داده‌های آموزشی زیاد هستند به روش دسته‌ای برتری دارد. به دلیل سرعت بالاتر روش دسته‌ای در آموزش و نیز عدم نیاز به حافظه‌ی بالا در این تحقیق، این روش برای آموزش شبکه انتخاب شده است.

الگوریتم‌های یادگیری به سه دسته‌ی کلی تقسیم‌بندی می‌شوند:

۱-۷-۲ یادگیری عملکردی

در یادگیری عملکردی پارامترهای شبکه طوری تنظیم می‌گردند که عملکرد یا کارایی آن بهینه شود. در این روش ابتدا یک معیار خاص تحت عنوان تابع کارایی^۳ که بیان‌گر عملکرد شبکه است، در نظر گرفته می‌شود. این معیار کمی بوده و شاخص عملکرد شبکه نام دارد. هنگامی که این معیار به

^۱ Sequential training

^۲ Batch training

^۳ Performance Function

حد کافی کوچک باشد عملکرد شبکه خوب و رضایت بخش تلقی می‌شود. در این‌جا برخی از انواع الگوریتم‌های یادگیری که در این دسته قرار می‌گیرند، شرح داده می‌شوند.

۲-۷-۱-۱ الگوریتم یادگیری ویدرو-هوف^۱

الگوریتم یادگیری ویدرو-هوف یا میانگین مربعات خطا اولین بار توسط ویدرو و هوف (۱۹۶۰) معرفی گردید. در این الگوریتم به منظور تنظیم پارامترهای شبکه، یک سری داده به عنوان خروجی مورد انتظار از شبکه در نظر گرفته می‌شود. در نهایت پارامترهای شبکه به گونه‌ای تنظیم می‌شوند که کمترین مقدار میانگین مربعات خطا بین خروجی مورد انتظار از شبکه و خروجی شبکه به دست آید.

۲-۷-۱-۲ الگوریتم پس انتشار خطا^۲

متداول‌ترین الگوریتم یادگیری، الگوریتم پس انتشار خطا می‌باشد که راملهات و مک لند (۱۹۸۶) معرفی گردید و قانونی برای یادگیری برای پرسپترون‌های چندلایه است. الگوریتم پس انتشار خطا استاندارد، یک الگوریتم کاهش شیب^۳ می‌باشد که در آن وزن‌های شبکه در جهت خلاف شیب تابع کارایی حرکت می‌کنند. این الگوریتم تعمیم یافته‌ی الگوریتم حداقل میانگین مربعات است و بر اساس قانون تصحیح خطا پایه‌گذاری شده است. در این الگوریتم ابتدا اختلاف خروجی شبکه با خروجی مورد انتظار از شبکه محاسبه می‌شود، سپس این مقدار خطا به صورت برگشتی به داخل شبکه انتشار داده می‌شود. در نهایت وزن‌ها و بایاس‌های شبکه به گونه‌ای تغییر داده می‌شوند که خروجی شبکه به خروجی مورد انتظار از شبکه نزدیکتر شود. الگوریتم‌های مختلفی بر مبنای این الگوریتم استاندارد عمل می‌کنند که از جمله‌ی آن‌ها می‌توان به الگوریتم گرادیان توام^۴، روش‌های گوسی - نیوتون^۵ و روش لوبنبرگ - مارکوارت^۶ اشاره کرد.

عموماً الگوریتم مورد استفاده برای هر مساله متناسب با ویژگی‌های آن مساله تعیین می‌شود. تعیین این‌که کدام الگوریتم برای مساله‌ی مورد نظر سریع‌تر عمل می‌کند کار مشکلی است و به عوامل زیادی، از جمله نوع و پیچیدگی مساله، تعداد داده‌های مجموعه‌ی آموزشی و تعداد وزن‌ها و

¹ Widrow-Houf learning

² Back propagation error

³ Gradient Descent Algorithm

⁴ Conjugate Gradient

⁵ Quasi-Newton

⁶ Levenberg-Marquardt

بایاس‌های شبکه بستگی دارد. برای مثال برای مساله‌ی تخمین تابع برای حالتی که تعداد پارامترهای شبکه کم باشند، الگوریتم لوبنبرگ - مارکوارت کارایی بسیار خوبی از خود نشان می‌دهند. این الگوریتم نیاز به نگهداری ماتریس‌های حجیم در حافظه داشته و بنابراین زمانی که ابعاد شبکه و در نتیجه حجم محاسبات بالا می‌رود، ممکن است مساله‌ی کمبود حافظه و کاهش سرعت آموزش به وجود آید. الگوریتم گوسی - نیوتون معمولاً دارای همگرایی بهتر و سریع‌تری نسبت به الگوریتم‌های گرادیان توام می‌باشند اما بسیار پیچیده بوده و برای شبکه‌های عصبی مناسب نمی‌باشند [Haykin, 1994].

در ساده‌ترین پیاده‌سازی الگوریتم یادگیری پس انتشار خطا وزن‌ها و بایاس‌ها در جهتی که تابع کارایی کاهش می‌یابد، به روز می‌شوند. یک تکرار از این الگوریتم به صورت معادله‌ی (۲-۲) نوشته می‌شود [Rumelhart et al, 1986].

$$X_{k+1} = X_k - \alpha_k g_k \quad (۲-۲)$$

که در آن: X_k بردار فعلی وزن‌ها و بایاس‌ها، g_k شیب فعلی و α_k نرخ یا سرعت یادگیری^۱ می‌باشند. g_k نیز تابع انحراف معیار مدل می‌باشد (معادله‌ی ۲-۳)، که می‌بایست بهینه شود. الگوریتم پس انتشار خطا در واقع حل این مساله است که چه کسری از خطای کل مدل به هر نرون باید نسبت داده شود تا وزن مربوط به آن نرون بهینه شود و برای این کار از گرادیان استفاده می‌شود.

$$g_k = \frac{\partial P_k}{\partial X_{k-1}} \quad (۳-۲)$$

که در آن تابع کارایی در الگوریتم پس انتشار خطا (P) با مجذور خطای شبکه طبق معادله‌ی (۲-۴) تعریف می‌شود:

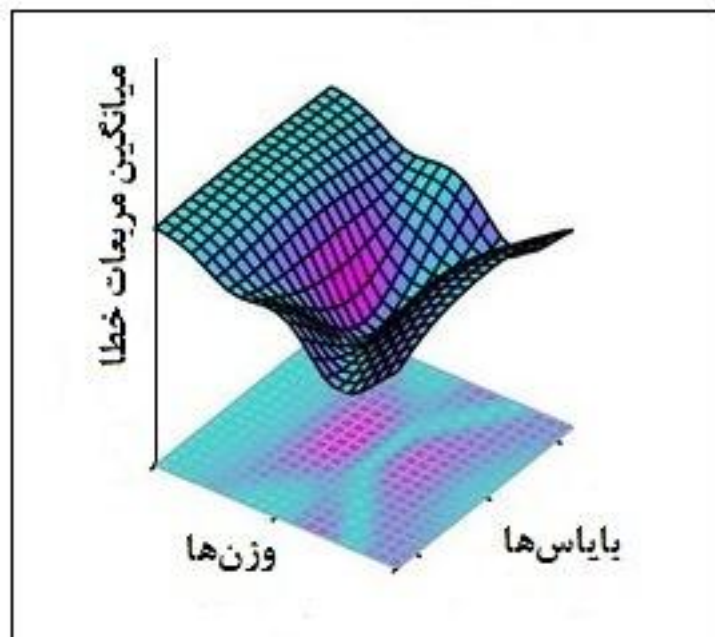
$$(۴-۲)$$

$$P = mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2$$

که در آن t بردار هدف مورد انتظار از شبکه، a بردار خروجی شبکه و در نتیجه e بردار خطای شبکه برای i نرون در لایه‌ی خروجی می‌باشد. شکل (۲-۴) طرح شماتیکی از سطح خطا را به ازای

^۱ Learning rate

اوزان سیناپسی و بایاس‌ها نشان می‌دهد. طبق تعریف P تابعی از خروجی شبکه است، بنابراین گرادینان خروجی شبکه نسبت به وزن‌ها و بایاس‌ها محاسبه می‌گردد.



شکل ۲-۴: میانگین مربعات خطا به ازای وزن‌ها و بایاس‌ها

الگوریتم لونبرگ مارکوارت:

الگوریتم لونبرگ - مارکوارت روند آموزش را با بردارهای ارزیابی و اعتبارسنجی حمایت می‌کند. بردارهای اعتبارسنجی برای توقف آموزش به کار برده می‌شوند. زمانی که کارایی شبکه پیرامون داده‌های فضای اعتبارسنجی شروع به افزایش پایداری بکند و یا برای ماکزیمم تکرارهای در نظر گرفته شده ثابت باقی بماند، الگوریتم متوقف خواهد شد. این الگوریتم قادر به آموزش هر شبکه‌ای با وزن‌ها، ورودی‌ها، و توابع انتقالی که مشتق‌پذیرند، می‌باشد [Hagan et al, 1994]. همانند روش‌های گوسی - نیوتون، الگوریتم لونبرگ - مارکوارت برای دستیابی به سرعت آموزشی بهتر بدون نیاز به محاسبه‌ی ماتریس هسین^۱، طراحی شده است. زمانی که تابع کارایی شکلی از مجموع مربعات را دارد (همانند معمول آموزش شبکه‌های پیش‌خور)، ماتریس هسین می‌تواند به صورت معادله‌ی (۲-۵) تخمین زده شود [Hagan et al, 1994].

^۱ Hessian

$$H = J^T J \quad (۵-۲)$$

و گرادین می‌تواند با معادله‌ی (۶-۲) محاسبه شود.

$$g = J^T e \quad (۶-۲)$$

که در آن J ماتریس ژاکوبین^۱ است که شامل مشتقات اول خطاهای شبکه نسبت به وزن‌ها و بایاس‌هاست، و e بردار خطاهای شبکه است. ماتریس ژاکوبین می‌تواند از طریق یک روش پس‌انتشار استاندارد که ساده‌تر از محاسبه‌ی ماتریس هسین است، محاسبه شود.

الگوریتم لونیبرگ - مارکوارت برای به‌روز رسانی وزن‌ها و بایاس‌ها معادله‌ی (۷-۲) را به کار می‌برد.

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e \quad (۷-۲)$$

زمانی که اسکالر μ صفر است، این معادله همان روش نیوتون است که با تخمین ماتریس هسین محاسبه می‌شود. زمانی که μ مقدار بزرگی دارد، این معادله همان کاهش شیب با اندازه گام کوچک است. روش نیوتون سریعتر است و مجاور یک کمینه‌ی خطا دقیق‌تر است، بنابراین هدف نزدیک شدن به سمت روش نیوتون است. بنابراین μ بعد از هر گام موفق کاهش می‌یابد (کاهش در تابع کارایی) و تنها زمانی که یک گام آزمایشی تابع کارایی را افزایش دهد، افزایش می‌یابد. به‌این روش تابع کارایی معمولاً در هر تکرار الگوریتم کاهش می‌یابد.

این الگوریتم سریعترین روش برای آموزش شبکه‌های عصبی پیش‌خور با اندازه‌ی متوسط (به اندازه‌ی چند صد وزن) می‌باشد. [Hagan et al, 1996].

۲-۷-۲ یادگیری حافظه انجمنی^۲

عملکرد این نوع از یادگیری به این صورت است که اگر یک قسمت کافی از اطلاعات به عنوان ورودی به شبکه داده شود، شبکه قادر به بازیابی کامل اطلاعات حافظه می‌باشد. این شبکه یک الگو از فعالیت‌های عصبی ایجاد شده در سطوح خروجی از نرون‌ها را به یک الگو از فعالیت‌های عصبی (الگوی ورودی) نگاشت می‌دهد. حافظه به خاطر خصلت انجمنی یا ارتباطدهی خود، دارای توانایی بازیابی صحیح الگوهای ذخیره شده است.

الگوریتم یادگیری هب^۳، الگوریتم یادگیری اینستار^۴ و الگوریتم یادگیری کوهنن^۱ نمونه‌هایی از

^۱ Jacobian

^۲ Associative memory learning

^۳ Hebbian learning rule

^۴ In-star rule

الگوریتم‌هایی هستند که در این دسته قرار می‌گیرند.

۲-۷-۳ یادگیری رقابتی^۲

در این نوع از یادگیری خروجی نرون‌ها در شبکه با یکدیگر به رقابت می‌پردازند تا یکی از آن‌ها که دارای امتیاز بیشتری است، در رقابت برنده و از بین سایر نرون‌ها متمایز شود.

۲-۸ انواع شبکه عصبی مصنوعی

شبکه‌ی عصبی انواع مختلفی دارد اما در این تحقیق یکی از پرکاربردترین شبکه‌های عصبی یعنی شبکه‌های MLP معرفی و به کار برده شده‌اند.

۲-۸-۱ شبکه MLP

شبکه‌ی پرسپترون چند لایه شناخته‌ترین و پرکاربردترین شبکه‌ی عصبی است. این شبکه با غلبه بر محدودیت‌های پرسپترون سهم زیادی در توسعه‌ی شبکه‌های عصبی داشته است [Minsky et al, 1969]. شبکه‌ی پرسپترون یک تقریب‌گر عمومی است [Nelles, 2001]. این به این معنی است که پرسپترون می‌تواند به یک تابع نرم با هر دقت دلخواهی با افزایش نرون‌های لایه‌ی میانی، نزدیک شود. قابلیت تقریب عمومی، ویژگی مهمی است و باعث می‌شود پرسپترون برای مساله‌ی تقریب تابع مناسب باشد. در واقع بسیاری از تخمین‌گرهای عمومی مانند چندجمله‌ای‌ها، مدل‌های فازی و اکثر شبکه‌های عصبی نیز تخمین‌گر عمومی هستند. دلیلی که باعث شده است قابلیت تقریب‌زنی عمومی پرسپترون توجه زیادی را به خود جلب کند این است که برخلاف بسیاری از تقریب‌گرهای عمومی، خروجی پرسپترون با ترکیب توابع خطی محاسبه می‌شود. در واقع این موضوع به راحتی قابل درک نیست که یک تابع عمومی و با چند متغیر ورودی، با دقت دلخواه قابل تقریب با مجموعه‌ای از توابع یک بعدی باشد.

معادل ریاضی نرون بیولوژیکی اولین بار توسط روزنبلات^۳ در سال ۱۹۶۲ ارائه گردید. این معادل ریاضی یک تابع فعال‌سازی^۴ است که بر مجموع ورودی‌های وزن داده شده اعمال می‌گردد. معادله‌ی (۲-۸) تابع فعال‌سازی کلاسیک را نشان می‌دهد [Bishop, 1997].

¹ Kohonen learning rule

² Competitive learning

³ Rosenblatt

⁴ Activation function


$$f(n) = \begin{cases} 1 & n > 0 \\ 0 & n \leq 0 \end{cases} \quad (8-2)$$

که در آن n به صورت نشان داده شده در معادله‌ی (۹-۲) تعریف می‌شود:

$$n = \sum_{j=0}^R w_j u_j \quad (9-2)$$

که در آن u ها ورودی‌های نرون‌ها در یک لایه و w ها اوزان نرون‌ها در لایه‌ی مذکور می‌باشند. اما در شبکه‌های MLP، اغلب این تابع فعال‌سازی، با توابع پیوسته جایگزین می‌گردد. این به این دلیل است که در الگوریتم یادگیری پس‌انتشار خطا که در شبکه‌های پرسپترون چندلایه استفاده می‌شود، توابع پیوسته‌ی غیرخطی مشتق پذیر نیاز هست. که پراستفاده‌ترین تابع فعال‌سازی، تابع سیگموئید^۱ است (شکل ۲-۴)، که با رابطه‌ی (۲-۱۰) بیان می‌گردد [Hangman et al, 1996].

$$f(n) = \frac{1}{1 + \exp(-n)} \quad (10-2)$$



شکل ۲-۵: تابع فعال‌سازی سیگموئید [After Samarasinghe, 2007]

تابع سیگموئید دارای ویژگی‌های خوبی به منظور استفاده در نرون‌های غیرخطی می‌باشد. از مهمترین این ویژگی‌ها، سادگی و مشتق پذیر بودن آن و نرمال‌سازی داده‌ها بین ۰ و ۱ است. توابع فعال‌سازی مختلف دیگری وجود دارند که از مهمترین آن‌ها می‌توان به توابع فعال‌سازی تانژانت هیپربولیک^۲ و خطی^۳ اشاره کرد. معادلات (۲-۱۱) و (۲-۱۲) و نیز اشکال (۲-۵) و (۲-۶)

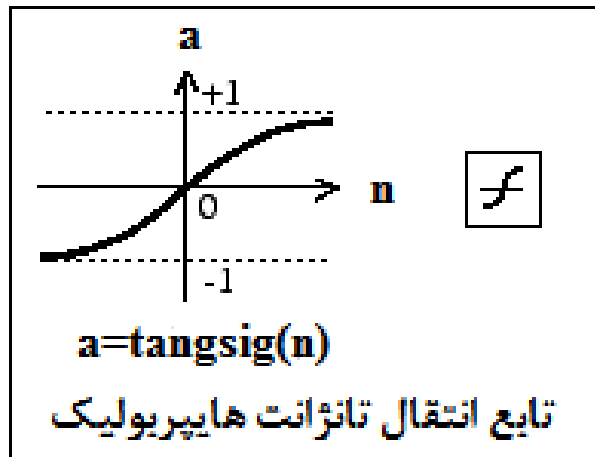
¹ Sigmoid

² Hyperbolic tangent sigmoid transfer function

³ Linear Transfer Function

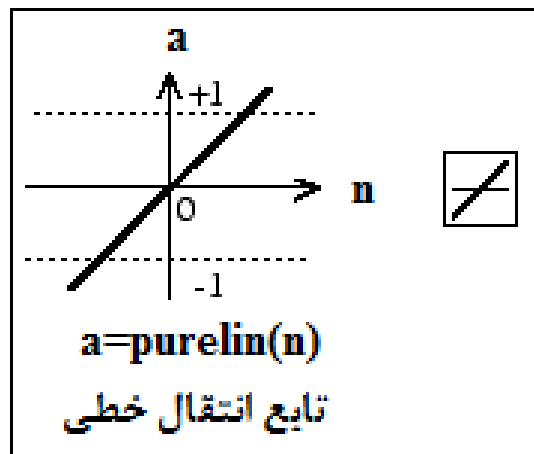
به ترتیب بیانگر این توابع هستند [Samarasinghe, 2007].

$$f(n) = \text{tansig}(n) = \frac{2}{(1 + \exp((-2)^n)) - 1} \quad (11-2)$$



شکل ۶-۲ تابع فعال سازی تانژانت هایپربولیک [After Samarasinghe, 2007].

$$f(n) = \text{purelin}(n) = n \quad (12-2)$$



شکل ۷-۲: تابع فعال سازی خطی [After Samarasinghe, 2007].

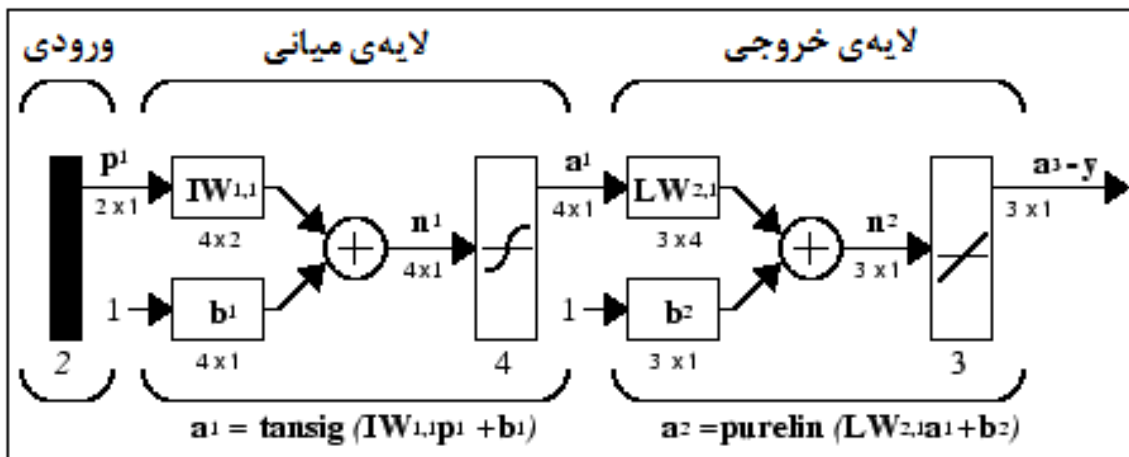
بر اساس نوع مسأله‌ای که قرار است با شبکه‌ی عصبی حل شود، نوع تابع انتقال تعیین می‌شود. برای حل مسائل دسته‌بندی، در لایه‌ی خروجی ترجیحاً از تابع انتقال سیگموئیدی یا تانژانت هایپربولیک استفاده می‌شود. برای حل مسائل تخمین توسط شبکه‌ی عصبی، از توابع فعال سازی

غیرخطی در لایه‌های میانی و از تابع فعال‌سازی خطی در لایه‌ی خروجی استفاده می‌شود. استفاده از یک تابع انتقال غیرخطی در لایه‌ی خروجی منجر به محدود شدن خروجی‌ها در یک بازه‌ی مشخص می‌باشد که این مدنظر مساله‌ی تخمین نمی‌باشد و برای مسائل دسته‌بندی مناسب است [Hangman et al, 1996].

در ساختار شبکه‌ی عصبی پرسپترون چندلایه، نرون‌ها در چند لایه‌ی مختلف قرار می‌گیرند. در این نوع شبکه هیچ اتصالی بین نرون‌های متعلق به یک لایه وجود ندارد. ساده‌ترین شکل شبکه‌ی پرسپترون به صورت سه لایه است که شامل یک لایه‌ی ورودی، یک لایه پنهان^۱ یا میانی و یک لایه‌ی خروجی می‌باشد و در حالت‌های پیچیده‌تر تعداد لایه‌های میانی افزایش می‌یابد. یک شبکه پرسپترون سه لایه قادر است هر نوع فضایی را تفکیک کند و یا به عبارت دیگر اگر بر روی تعداد نرون‌های لایه پنهان محدودیتی وجود نداشته باشد، خواهد توانست که هر تابع غیر خطی را تخمین بزند [Nelles, 2001].

لایه‌ی ورودی اطلاعات یا الگوها را دریافت و به لایه‌ی میانی انتقال می‌دهد. تعداد ورودی‌ها، تعداد نرون‌های لایه‌ی ورودی را تعیین می‌کند. معمولاً لایه‌ی ورودی را به عنوان یک لایه‌ی مستقل در نظر نمی‌گیرند بلکه فقط به نام ورودی عنوان می‌شوند. لایه‌ی میانی تحلیل و پردازش اطلاعات را به عهده دارد و در نهایت لایه‌ی خروجی تحلیل حاصل از آخرین لایه‌ی میانی را دریافت کرده و به یک تفسیر معنادار تبدیل می‌کند. تعداد نرون‌های لایه‌ی خروجی با توجه به تعداد خروجی‌های مورد انتظار از شبکه تعیین می‌شود. شکل (۲-۷) ساختار یک شبکه عصبی سه لایه را نشان می‌دهد، که در آن تابع تانژانت هایپربولیک به عنوان تابع فعال‌سازی لایه‌ی میانی و تابع خطی به عنوان تابع فعال‌سازی لایه‌ی خروجی به کار برده شده‌اند.

^۱ Hidden layer



شکل ۲-۸: ساختار یک شبکه‌ی عصبی سه لایه (Matlab, manual help)

۹-۲ مراحل یادگیری شبکه‌های عصبی

برای حل هر مسئله به کمک شبکه‌ی عصبی، شبکه‌ی عصبی باید سه مرحله‌ی آموزش^۱، تعمیم^۲ و اجرا^۳ را طی کند. در طول فرآیند آموزش، شبکه باید به گونه‌ای آموزش داده شود که بتواند الگوی موجود در داده‌های آموزشی را بشناسد. در این مرحله داده‌های آموزشی به شبکه وارد میشوند و وزن‌های بهینه برای ورودی‌ها به دست می‌آیند. در حقیقت آموزش شبکه به معنای تعدیل کردن اوزان است به طوری که برای مجموعه‌ای از داده‌های آموزشی، مجموعه‌ای از خروجی‌های مطلوب را به دست دهد. در فرآیند آموزش فرض بر این است که هر بردار ورودی با یک بردار هدف که خروجی‌های مطلوب است مرتبط است. پس باید هر بار خطای شبکه محاسبه شود و اوزان تعدیل شود تا زمانی که خطا برای کل مجموعه آموزشی به میزان قابل پذیرشی کاهش یابد. این روش آموزش شبکه، که متداولترین روش آموزش است، همان الگوریتم پس‌انتشار است که قبلاً به آن اشاره شد.

الگوریتم پس‌انتشار شامل سه مرحله می‌باشد:

۱- انتشار داده‌ها رو به جلو و محاسبه کردن خطای شبکه (اختلاف پاسخ شبکه و پاسخ مورد

انتظار از شبکه)

۲- انتشار خطا به عقب در طول شبکه

¹ Training

² Generalization

³ Operation

۳- تعدیل اوزان سیناسی و حداقل نمودن تابع خطا

به این ترتیب بعد از وارد شدن تعداد نمونه‌ی کافی به شبکه، شبکه همگرا^۱ شده، میزان خطا به حداقل مقدار خود رسیده است و شبکه برای مرحله‌ی پیش‌گویی آماده است. لازم به ذکر است که داده‌های آموزشی را از فضای مشاهده شده اختیار می‌کنیم. همیشه در مرحله‌ی پردازش، داده‌ها باید به دو زیر فضا تقسیم شوند:

الف- فضای مشاهده شده: این فضا شامل ۷۰ درصد از داده‌ها می‌باشد که در فرآیند آموزش شبکه به کار می‌روند.

ب- فضای مشاهده نشده: ۳۰ درصد از داده‌های باقیمانده مربوط به فضای مشاهده نشده است که مربوط به ارزیابی و اعتبارسنجی شبکه‌ی عصبی می‌باشد، داده‌های ارزیابی و اعتبارسنجی شبکه هیچگاه در فرآیند آموزش و نیز در بهینه‌سازی شبکه دخالت داده نمی‌شوند.

۲-۱۰ مقادیر اولیه برای وزن‌ها و بایاس‌ها

قبل از آغاز فرآیند آموزش، مقادیر اولیه‌ای برای همه‌ی اوزان و بایاس‌ها در شبکه در نظر گرفته می‌شوند. اگرچه این مقادیر آغازین می‌توانند هر مقداری را داشته باشند اما اینکه کاملاً تصادفی در نظر گرفته شوند صحیح نیست، این به این دلیل است که زمان آموزش که موضوع بسیار مهمی در شبکه‌های عصبی است، ممکن است بسیار بالا رود. بنابراین اوزان سیناپسی و بایاس‌ها باید با کمترین و بزرگترین مقادیر ورودی محدود شوند و سپس از این بین به صورت تصادفی اختیار شوند. بزرگ بودن زمان آموزش و نیز خروجی مینیمم محلی دو مشکلی هستند که بسیار حساس به مقادیر آغازین اوزان و بایاس‌ها هستند.

۲-۱۱ نرمالایز^۲ کردن داده‌های ورودی

وقتی با متغیرهای زیادی کار می‌کنیم باید اول متغیرها را هم‌شکل کنیم، به این معنی که آنها را نرمالایز کنیم. از معادله‌ی (۲-۱۳) برای این کار استفاده می‌کنیم [McCulloch et al, 1943].

$$\bar{X} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2-13)$$

^۱ Convergence

^۲ Normalize

که در آن x_{\min} و x_{\max} به ترتیب کمترین مقدار و بیشترین مقدار داده‌های فضای مشاهده‌ای است.

معادله‌ی (۳-۵) داده‌های ورودی را به فضای $\{0, 1\}$ می‌برد. البته در برخی موارد داده‌ها به فضای $\{1, -1\}$ برده می‌شوند، بنابراین از معادله‌ی (۲-۱۴) برای نرمالایز کردن استفاده می‌شود [Haykin, 1994].

$$\bar{X} = 2\bar{X} - 1 \quad (۲-۱۴)$$

۱۲-۲ معیارهای پایان آموزش

همان‌طور که گفته شد در فرآیند آموزش شبکه‌ی عصبی الگوریتم بهینه‌سازی وزن‌ها و بایاس‌ها باید به دفعات تکرار شود تا به خروجی مطلوب دست پیدا کرد. حال سوالی که مطرح می‌شود این است که زمان متوقف کردن بهینه‌سازی چه وقت می‌باشد؟

برای پاسخ دادن به این سوال ابتدا منحنی یادگیری باید ترسیم شود. این منحنی نمودار خطای شبکه بر اساس تعداد دفعات بهینه‌سازی یا به عبارتی تعداد تکرارهای فرآیند آموزش شبکه است. ابتدا می‌بایست مجموع مربعات خطا به طور جداگانه برای داده‌های مجموعه‌ی آموزشی و همین‌طور برای داده‌های مجموعه‌ی اعتبارسنجی محاسبه گردد. هر چقدر تعداد دفعات بهینه‌سازی افزایش یابد نمودار خطای مربوط به داده‌های مشاهده‌ای کاهش می‌یابد. اما در فضای داده‌های اعتبارسنجی از یک تکرار به بعد خطا شروع به افزایش پایداری خواهد کرد. اوزان سیناپسی و بایاس‌ها در این تکرار بهینه مقادیر خود را شامل می‌شوند. این همان روش اعتبارسنجی است که در آن اعتبار شبکه در هر تکرار هم‌زمان با آموزش سنجیده می‌شود. شروط توقف دیگری نیز در الگوریتم‌ها وجود دارند اما این معمول‌ترین شرط توقف در الگوریتم‌ها می‌باشد.

در این‌جا توجه به این نکته حائز اهمیت است که تعداد نرون‌های لایه‌ی میانی یا به عبارتی اندازه‌ی شبکه بسیار مهم است. در حالت کلی هرچه تعداد نرون‌ها در لایه‌ی میانی افزایش یابد بهتر است اما اگر تعداد نرون‌ها در لایه‌ی میانی خیلی زیاد شود، مساله‌ی بیش‌برازش^۱ در شبکه رخ داده و اصطلاحاً شبکه دچار حالت ازبرکردن می‌شود. تعداد زیاد وزن‌های یک شبکه‌ی عصبی باعث می‌شود

^۱ Overfitting

شبکه درجات آزادی زیادی برای انطباق داشته باشد، نمودار در این حالت گول‌زننده است و این‌طور به نظر می‌آید که تخمین خیلی خوبی صورت می‌گیرد، درحالی‌که اگر از داده‌هایی که در مجموعه‌ی آموزشی نبوده‌اند استفاده شود، شبکه عملکرد بسیار بدی خواهد داشت. بنابراین استفاده از روش اعتبارسنجی از بروز این پدیده جلوگیری می‌کند. همچنین اگر تعداد نرون‌ها در لایه‌ی میانی کمتر از حد مناسبی باشد، شبکه به‌درستی آموزش نخواهد دید و پدیده‌ی کم‌ترین برازش (یا برازش ضعیف)^۱ رخ خواهد داد. [gret et al, 1998].

^۱ Underfitting

فصل سوم:

تهیه داده‌های مصنوعی و ایجاد شبکه عصبی

به منظور بررسی توانمندی روش شبکه‌ی عصبی در کاربردهای عملی ابتدا باید یک مجموعه‌ی آموزشی تهیه شود که توسط آن شبکه‌ی عصبی مورد نظر، آموزش داده شود. این مجموعه‌ی آموزشی یک سری داده‌ی مصنوعی می‌باشد که پاسخ گرانی مدل‌های دو بعدی، با هندسه و خواص فیزیکی متفاوت می‌باشد. در این جا مدل‌های مصنوعی تهیه شده، مدل‌هایی با هندسه‌ی منظم مانند کره، استوانه‌ی افقی، استوانه‌ی قائم و مدلی ترکیبی از این دو به عنوان مدل گنبدی شکل می‌باشند. پارامترهای هندسی و فیزیکی این مدل‌ها تا حد امکان باید دربرگیرنده‌ی پارامترهای مدل‌های واقعی مورد بررسی باشند، به عبارت دیگر مجموعه‌ی آموزشی شبکه باید کامل باشد تا در نهایت شبکه‌ی ایجاد شده، کمترین خطا را در تشخیص داشته باشد. در این بخش اثر گرانی ناشی از چند شکل هندسی ذکر شده با تهیه‌ی الگوریتم‌ها و نیز کدهای مربوطه در محیط نرم‌افزار متلب محاسبه شده است.

۱-۳ مدل‌سازی گرانی سنجی

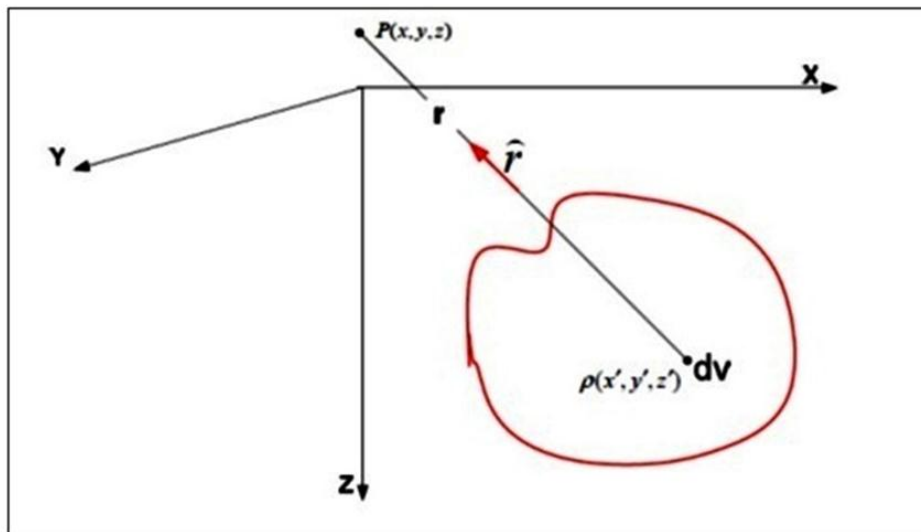
اثر گرانی توده‌های بی‌هنجاری توسط افراد زیادی محاسبه شده است [Talwani et al, 1959; Talwani and Ewing, 1960; Talwani, 1965; Bott, 1963; Plouff, 1976; Okabe, 1979; Cady, 1980; Won and Bevis, 1987; Dobrin and Savit, 1988; cooper, 1993-2003; Chakravathi land sundarajan, 2008]. اصولاً برای بررسی و تحلیل بی‌هنجاری‌های ناشی از ساختارهای زیرسطحی، می‌توان از مدل‌های ساده به عنوان توده‌های مدفون مولد بی‌هنجاری استفاده نمود. برای مثال در بررسی گنبدهای نمکی مدل‌های هندسی ساده مانند کره و یا استوانه توسط پژوهشگران به وفور استفاده شده است. در این فصل برخی از مدل‌های با هندسه منظم که در این تحقیق به کار برده شده‌اند، به اختصار شرح داده می‌شوند. پتانسیل گرانی ناشی از یک توده‌ی جرمی، در یک نقطه‌ی مشخص p به کمک رابطه‌ی (۱-۳) محاسبه می‌گردد [Blakely, 1995; Telford et al, 1991]:

$$U(p) = G \int_R \frac{\rho}{r} dv \quad (1-3)$$

و بنابراین شتاب گرانی ناشی از این توده‌ی جرمی در نقطه‌ی مشخص P به کمک رابطه‌ی (۲-۳) مشخص می‌شود:

$$g(p) = \nabla U(p) = -G \int_R \frac{\rho \cdot \hat{r}}{r^2} dv \quad (2-3)$$

که در آن چگالی جامد، G مقدار ثابت جهانی شتاب جاذبه می‌باشد $G = 6.672 \times 10^{-11} \text{ m}^3/\text{KgS}^2$ ، r فاصله از نقطه‌ی P تا المان کوچکی از توده‌ی جرمی به حجم dv بردار واحد از یک المان کوچک جسم تا نقطه‌ی P می‌باشد که فاصله‌ی آن با رابطه‌ی $r = \sqrt{(x-x')^2 + (y-y')^2 + (z-z')^2}$ محاسبه می‌شود.



شکل ۳-۱: یک جسم سه بعدی با شکل دلخواه و یک نقطه‌ی مشاهده‌ای p به فاصله‌ی r از آن

همانطور که در شکل (۳-۱) نشان داده شده است جهت مثبت محور z به سمت پایین در نظر گرفته می‌شود. گرانی‌سنج‌ها مقدار شتاب گرانشی را در جهت افزایش محور z اندازه‌گیری می‌کنند بنابراین در مختصات کارتزین خواهیم داشت [Blakley, 1995]:

$$g(x, y, z) = \frac{\partial U}{\partial z} = -G \iiint_{z'y'x'} \rho(x', y', z') \frac{(z-z')}{r^3} dx' dy' dz' \quad (3-3)$$

و نیز می‌توان نوشت:

$$g(x, y, z) = \iiint_{z'y'x'} \rho(x', y', z') \psi(x-x', y-y', z-z') dx' dy' dz' \quad (4-3)$$

که در آن تابع گرین به صورت زیر تعریف می‌شود:

$$\psi(x, y, z) = -G \frac{z}{(\sqrt{x^2 + y^2 + z^2})^3} \quad (5-3)$$

روش مستقیم محاسبه‌ی $g(x,y,z)$ بر اساس معادله‌ی (۴-۳) در عمل کار ساده‌ای نیست. انتگرال

حجمی موجود در این معادله برای اشکال هندسی ساده به آسانی قابل محاسبه است اما مشکل از آنجایی شروع می‌شود که تصمیم به حل این انتگرال برای ساختارهای پیچیده‌ی زمین‌شناسی شود. برای حل این مشکل باید از الگوریتم‌های کامپیوتری بهره برد. ابتدا باید توده‌ی بی‌هنجاری به N بخش ساده تقسیم گردد، در نتیجه می‌توان به جای رابطه‌ی (۳-۴) از رابطه‌ی (۳-۶) بهره برد:

$$g_m = \sum_{n=1}^N \rho_n \psi_{mn} \quad (۳-۶)$$

که در آن g_m شتاب گرانشی قائم در نقطه‌ی مشاهده‌ی m ، ρ_n چگالی قسمت n ام و ψ_{mn} شتاب گرانشی در نقطه‌ی m ناشی از n با چگالی واحد و یکسان می‌باشد.


۲-۳ پاسخ گرانی بی‌هنجاری‌های با شکل منظم هندسی

۱-۲-۳ اثر گرانی ناشی از یک کره‌ی مدفون

اثر گرانی ناشی از یک کره در نقطه‌ی مفروض P طبق رابطه‌ی زیر به دست می‌آید [Telford et al, 1991]:

$$\Delta g_z = \frac{4\pi G \Delta \rho z R^3}{3R^3} \quad (۳-۷)$$


که در آن Δg_z : اثر گرانشی قائم کره، G : ثابت جهانی جاذبه‌ی زمین، R : شعاع کره، z : عمق مرکز کره و $\Delta \rho$ تباین چگالی بین کره و ساختار زیرسطحی در برگیرنده‌ی آن است (شکل ۳-۲).



شکل ۳-۲: یک مدل کره‌ی به همراه پارامترهای ساختاری و نقطه‌ی مشاهده‌ی p از آن

برای محاسبه‌ی بی‌هنجاری گرانی ناشی از این کره بر روی یک پروفیل که از مرکز کره می‌گذرد:

$$r = \sqrt{x^2 + z^2} \text{ و } x: \text{فاصله‌ی افقی نقطه‌ی اندازه‌گیری از مرکز کره می‌باشد.}$$



شکل ۳-۳: اثر گرانی ناشی از یک کره‌ی مدفون به عمق ۳ کیلومتر، شعاع ۵۰۰ متر و تباین چگالی منفی ۰.۲ گرم بر سانتی‌متر مکعب

شکل (۳-۳) اثر گرانی ناشی از یک کره‌ی مدفون را بر روی یک شبکه‌ی منظم 10×10 کیلومتری نشان می‌دهد که در آن عمق مرکزی کره ۳ کیلومتر، شعاع آن ۵۰۰ متر و تباین چگالی آن با محیط در برگیرنده‌ی آن منفی ۰.۲ گرم بر سانتیمتر مکعب در نظر گرفته شده است.

این مدل ساده می‌تواند نمایانگر یک گنبد نمکی باشد. در واقع بسیاری از پژوهشگران [Nettelton, 1976; Mohan et al, 1986; Shaw and Agarwal, 1990; Salem et al, 2003] از یک مدل کروی برای بررسی گنبدهای نمکی استفاده کرده‌اند. در این جا نیز یک سری از داده‌های مصنوعی که برای آموزش شبکه به کار برده می‌شود، بی‌هنجاری‌های گرانی مربوط به مدل سه‌بعدی کره می‌باشند.

۲-۲-۳ مدل استوانه‌ی قائم

مدل پرکاربرد دیگر برای بررسی گنبدهای نمکی به ویژه گنبدهای نمکی نوع نفوذی [Jenkins et al, 1983]، و گنبدهای آتشفشانی، مدل استوانه‌ی قائم است.

در نهایت با بسط $\Delta g_z(r, \theta)$ برای یک نقطه در خارج از محور استوانه، مقدار اثر گرانشی قائم برای این استوانه به صورت زیر قابل محاسبه خواهد بود:

$$\Delta g_z(r, \theta) = \pi G \Delta \rho R^2 \left[\frac{1}{\sqrt{x^2 + z^2}} - \frac{1}{4} \frac{R^2}{(\sqrt{x^2 + z^2})^3} P_2(\cos \theta) \right. \quad (10-3)$$


$$+ \frac{1}{8} \frac{R^4}{(\sqrt{x^2 + z^2})^5} P_4(\cos \theta) - \frac{5}{64} \frac{R^6}{(\sqrt{x^2 + z^2})^7} P_6(\cos \theta)$$

$$\left. + \frac{7}{128} \frac{R^8}{(\sqrt{x^2 + z^2})^9} P_8(\cos \theta) - \dots \right]$$


شکل (۳-۶) مقدار Δg_z یک استوانه‌ی عمودی با شعاع ۰.۵ کیلومتر، عمق ۳ کیلومتر و تباین چگالی منفی ۰.۲ گرم بر سانتی‌مترمکعب را از یک نقطه‌ی دلخواه در سطح نشان می‌دهد.

۳-۳ مدل گنبد نمکی


ساختارهای نمکی به خاطر چگالی کمتر نسبت به سایر رسوبات در حوضه‌های رسوبی با بی‌هنجاری گرانی کمتری نسبت به محیط اطراف مشخص می‌شوند. گنبدهای نمکی در واقع توده‌های بزرگی از نمک هستند که به دلیل چگالی کمتر به سمت بالا حرکت کرده و به صورت یک ساختار قارچی شکل در می‌آیند. بی‌هنجاری‌های ناشی از گنبدهای نمکی معمولاً شکلی نزدیک به دایره دارند، بنابراین این بی‌هنجاری‌ها را می‌توان به شکل یک کره، استوانه و یا ترکیبی از این دو در نظر گرفت. بنابراین تشخیص شکل یک توده‌ی نمک به وسیله‌ی گنبدهای نمکی، که به کدام یک از سه مدل ساده مورد بحث شباهت دارد، بسیار کارآمد به نظر می‌رسد. مجموعه‌ی آموزشی ما به شبکه‌ی عصبی، ترکیبی از مشخصه‌های استخراج شده از این سه نوع بی‌هنجاری می‌باشد. در اینجا مدل ترکیبی از یک استوانه‌ی عمودی که تا سنگ بستر کشیدگی دارد و یک نیم کره در بالای آن، تشکیل شده است. اثر گرانی حاصل از این شکل ترکیبی مطابق با معادله‌ی (۳-۶) از حاصل جمع مقدار گرانی دو جسم نیم کره و استوانه‌ی طویل به دست می‌آید. شکل (۳-۵) پارامترهای ساختاری این مدل را نشان می‌دهد. الگوریتم مورد نظر در نرم‌افزار متلب تهیه شده و نتیجه در شکل (۳-۷) برای حالتی که شعاع نیم کره ۵۰۰ متر و عمق آن ۱ کیلومتر، شعاع استوانه ۵۰۰ متر و عمق آن ۱.۵ کیلومتر است،



شکل ۳-۵: پارامترهای ساختاری مدل گنبد نمکی (که در آن $Z1$ عمق نیم کره‌ی بالای آن، $Z2$ عمق استوانه‌ی طولی، R شعاع مربوط به هر دو قسمت نیم کره و استوانه و L طول استوانه)




شکل ۳-۶: اثر گرانی ناشی از یک استوانه‌ی عمودی طولی با شعاع ۰.۵ کیلومتر، عمق ۳ کیلومتر و تباین چگالی منفی ۰.۲ گرم بر سانتی متر مکعب



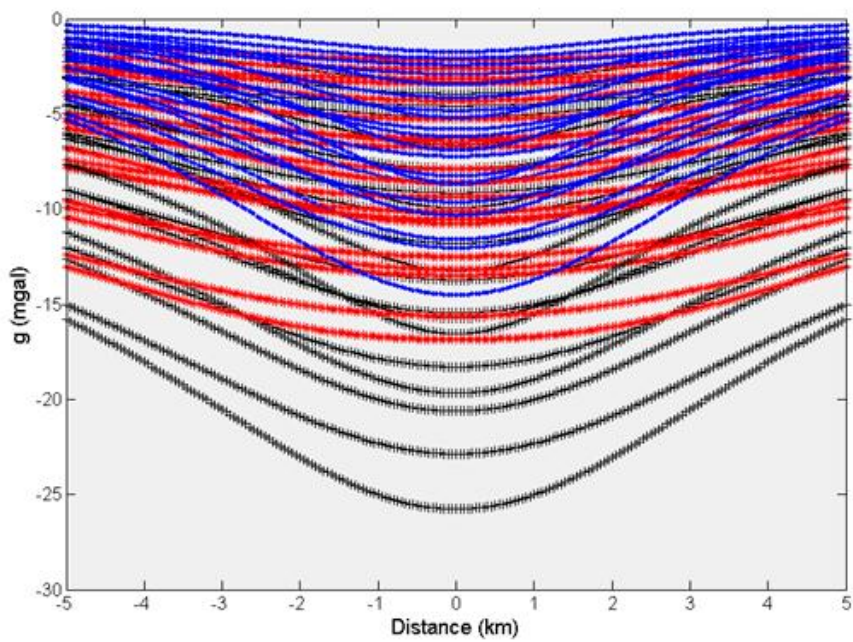
شکل ۳-۷: اثر گرانی ناشی از مدل گنبد نمکی با شعاع نیم کره ۵۰۰ متر و عمق آن ۱ کیلومتر، شعاع استوانه ۵۰۰ متر و عمق آن ۱.۵ کیلومتر.

ترسیم شده است.

در راستای پروفیلی گذرنده از مرکز هر یک از این سه مدل مصنوعی، مقدار بی‌هنجاری‌ها محاسبه و ترسیم و در نهایت مشخصه‌های مورد نیاز از آنها استخراج شده است. شکل (۳-۸) نگاهی مقایسه‌ای بین اثر گرانی این سه مدل بر روی پروفیل مذکور دارد. هر سه مدل با شعاع ۵۰۰ متر و تباین چگالی منفی ۰.۲ گرم بر سانتی‌متر مکعب در عمق ۱.۵ کیلومتری قرار دارند. تفاوت سه اثر گرانی به نمایش درآمده در این شکل به خوبی بیانگر تفاوت در شکل منبع مولد آن‌ها می‌باشد. در این جا باید به این نکته توجه شود که ممکن است اثر گرانی ناشی از این سه مدل با هم در چگالی و شعاع و عمق‌های دیگر، هم‌پوشانی داشته باشند و در نتیجه شبکه عصبی در تشخیص خود گمراه شود. برای بررسی این موضوع اثر گرانی ناشی از این سه مدل با هم‌ی پارامترهایی که در حوزه‌ی آموزشی قرار دارند با هم ترسیم و خروجی در شکل (۳-۹) به نمایش درآمده است و به وضوح تفاوت در بی‌هنجاری‌های حاصل قابل مشاهده است. این تفاوت‌ها که در ویژگی‌هایی همچون شیب، مقدار انتگرال زیر سطح منحنی و میزان کشیدگی می‌تواند خلاصه شود مبنای تشخیص شکل و عمق توده‌های بی‌هنجار توسط شبکه‌های عصبی در این تحقیق می‌باشد.



شکل ۳-۸: اثر گرانی ناشی از پروفیل گذرنده از مرکز سه جسم بی‌هنگار کره، استوانه‌ای قائم و مدل گنبدی شکل



شکل ۳-۹: اثر گرانی ناشی از پروفیل گذرنده از مرکز مدل‌های مختلف آموزشی کره، استوانه قائم و گنبدی شکل

۴-۳ به کار بردن داده‌های مصنوعی برای آموزش شبکه‌های عصبی مصنوعی

به منظور شناسایی اجسام زیرسطحی

به منظور شناسایی توده‌های زیر سطحی باید ابتدا یک تفسیر کیفی به منظور تشخیص شکل و سپس یک تفسیر کمی برای ارائه‌ی پارامترهای توده‌ی موردنظر ارائه کرد. در ابتدا به مشخصه‌هایی نیاز هست که معرف توده‌های بی‌هنجاری بوده تا به عنوان ورودی به شبکه و به منظور آموزش آن مورد استفاده قرار گیرند. هر مجموعه‌ی آموزشی شامل بردارهای ورودی و بردارهای هدف می‌باشد. در این جا بردارهای ورودی همان مشخصه‌های گرفته شده از یک بی‌هنجاری گرانی می‌باشند. این مشخصه‌ها که مقادیری همچون موقعیت نقطه‌ی عطف، بیشینه مقدار گرانی و شیب بی‌هنجاری‌ها می‌باشند، می‌توانند از بی‌هنجاری در طول هر پروفیلی برداشت شوند. مجموعه‌ی آموزشی ایجاد شده در هر حالت، برای شبکه‌ی عصبی پرسپترون چند لایه به کار برده شد.

در این جا ذکر دو نکته حائز اهمیت است. اول این که در شبکه عصبی مصنوعی با افزایش این مشخصه‌ها به عنوان ورودی، تعداد نرون‌ها و بنابراین زمان آموزش شبکه افزایش می‌یابد، بنابراین تعداد مشخصه‌ها تا حد ممکن باید کم باشد. قانونی کلی برای دانستن تعداد مشخصه‌ها برای ورود به شبکه وجود ندارد، مثلاً برای تشخیص یک کره یا یک استوانه‌ی قائم دو مشخصه کافی است [Gret et al, 1998] دوم این که اگر یک شبکه با کمترین تعداد ممکن مشخصه‌ها آموزش ببیند، باید این مشخصه‌ها به طور خطی غیروابسته باشند، در غیر این صورت فقدان اطلاعات وجود دارد و شبکه به شکل صحیحی آموزش نمی‌بیند. درنهایت اگر خروجی‌های شبکه عصبی به مقادیر هدف نزدیک باشند و خطا به طور قابل قبولی کم باشد، شبکه آموزش دیده است.

۳-۴-۱ تشخیص شکل توده‌های زیرسطحی (تفسیر کیفی)

در نقشه‌ی گرانی تمایز قائل شدن بین آنومالی‌های متقارن مرکزی با آنومالی‌های متقارن محوری بسیار آسان است. اما تشخیص شکل توده‌ی جرمی که هر کدام از این بی‌هنجاری‌ها را ایجاد کرده‌اند کار ساده‌ای نیست. بی‌هنجاری دو بعدی دایره‌ای شکل می‌تواند توسط کره یا استوانه‌ی قائم ایجاد گردد، بی‌هنجاری دوبعدی بیضوی شکل نیز می‌تواند توسط یک استوانه‌ی افقی و یا توسط یک دایک قائم ایجاد شود [Gret & Klingele, 1998].

به دلیل این که شکل بی‌هنجاری تنها وابسته به شکل توده‌ی بی‌هنجاری می‌باشد، برای بررسی

تعیین شکل اجسام زیرسطحی مورد نظر می‌بایست بر روی مشخصه‌هایی تمرکز کرد که میزان گسترش آنومالی‌ها در آن‌ها نمود بهتری دارد. در تفسیر ساختارهای نمک بررسی این موضوع که گنبد نمکی ریشه‌ای عمیق دارد و یا اینکه توسط ساختارهای دیگر از ریشه جدا شده باشد مفید بوده و از آنجا که شبکه‌عصبی روش سریعی در تشخیص است، بررسی این موضوع به کمک روش مذکور انجام می‌شود. دو مدل مصنوعی در نظر گرفته شده برای این بررسی مدل کروی و مدل گنبدی شکلی که تا سنگ بستر کشیدگی دارد، می‌باشد.

پس از تعیین ورودی‌ها چون الگوریتم یادگیری به کار رفته در این خصوص یک الگوریتم تحت

نظارت است، به یک سری بردار هدف نیاز هست. بردار هدف در این جا $\begin{pmatrix} a_1 \\ a_2 \end{pmatrix}$ می‌باشد که $\begin{pmatrix} 0 \\ 1 \end{pmatrix}$ برای

مدل کروی و $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$ برای مدل گنبد نمکی ریشه دار در نظر گرفته شده‌اند. بنابراین از شبکه انتظار

می‌رود که داده‌ها را به دو دسته تفکیک کند، به طوری که مجموع دو عدد واقع شده در هر بردار خروجی تقریباً معادل عدد ۱ باشد.

معادلات (۱۱-۳) و (۱۲-۳) مشخصه‌های به کار رفته در تشخیص شکل توده‌ی بی‌هنجاری نمک می‌باشد.

$$F_1 = \frac{xg_{50}}{xg_{75}} \quad (11-3)$$

$$F_2 = \frac{(xg_{25} - xg_{66})}{(xg_{66} - xg_{75})} \quad (12-3)$$

که در آن: مقادیر F_1 و F_2 مشخصه‌های معرف بی‌هنجاری در توصیف شکل ساختار می‌باشند.

g_y مقدار g در $y\%$ ماکزیمم مقدار g و xg_y مقدار x در g_y .

در این معادلات، xg_y به صورت زیر تعیین می‌شوند:

$$xg_y = g_{\max} - 0.1 * y * (g_{\max} - g_{\min}) \quad (13-3)$$

که در آن g_{\max} بیشترین مقدار گرانی اندازه‌گیری شده و g_{\min} کمترین مقدار گرانی اندازه‌گیری

شده بر روی پروفیل موردنظر است.

۳-۴-۲ تشخیص پارامترهای توده‌های زیرسطحی (تفسیر کمی)

علاوه بر شکل از شبکه‌ی عصبی مصنوعی می‌توان برای تخمین پارامترهای اجسام زیرسطحی استفاده کرد، بنابراین در این حالت بردار هدف، بردار پارامتر مورد انتظار برای داده‌های مصنوعی در مجموعه‌ی آموزشی می‌باشد. برخی از مشخصه‌های توصیف کننده‌ی یک بی‌هنجاری قبلاً شرح داده شدند. وارون‌سازی مساله‌ی پیچیده‌تری از تشخیص شکل یک جسم بی‌هنجار است، بنابراین به توصیف دقیق‌تری از بی‌هنجاری‌ها نیاز است. به منظور تخمین پارامترهای جسم مورد بررسی، مجموعه مشخصه‌های استخراج شده از این مدل‌ها، باید شامل مشخصه‌هایی باشند که در آنها مقدار مطلق گرانی نقاط وجود داشته باشد.

در این‌جا ابتدا این موضوع بررسی شد که آیا می‌توان فقط با یک شبکه، مساله‌ی تخمین پارامترهای جسم مولد بی‌هنجاری مورد نظر حل شود. پس از این مطالعه مشخص شد که به دست آوردن عمق، شعاع و چگالی جسم بی‌هنجار گرانی با تنها یک شبکه‌ی عصبی، با خطای زیادی برای شعاع و مخصوصاً چگالی همراه است. این به این دلیل است که وقتی که پارامترها عوض می‌شوند، پاسخ مدل‌های گرانی با پارامترهای متفاوت، ممکن است بسیار شبیه به هم بوده و همپوشانی داشته باشند، در نتیجه شبکه در تشخیص خود دچار اشتباه شود. در واقع یک مجموعه مشخصه‌ی انتخابی ممکن است به دو یا تعداد بیشتری مدل مربوط شود.

برای حل این مشکل منحنی‌های بی‌هنجاری به دقت مطالعه شدند. ابتدا پاسخ بی‌هنجاری گرانی برای مدل‌های مختلف با گستره‌ی پارامترهای در نظر گرفته شده برای مدل‌ها ترسیم شده و بهترین مشخصه‌هایی که توانایی تفکیک بهتر آنومالی‌ها را داشتند انتخاب شدند. اما با وجود اضافه کردن مشخصه‌های دقیقتر که در ادامه در مورد آن‌ها بحث خواهد شد، باز هم خطا به مقدار رضایت بخشی نرسید.

پیشتر ذکر شد که ابتدا فقط یک شبکه برای تخمین هر سه پارامتر به کار برده شد. با وجود اینکه شعاع و مخصوصاً چگالی به دست آمده از این شبکه تفاوت زیادی با مقدارهای مورد انتظار از شبکه داشتند، اما تخمین پارامتر عمق بسیار رضایت بخش بود. این نکته می‌توانست در دستیابی به مقدارهای مناسب‌تری برای چگالی و شعاع راه‌گشا باشد. در واقع می‌توان از سه شبکه‌ی مجزا برای

تخمین پارامترها استفاده کرد و از آن جا که تخمین عمق با این روش با دقت بسیار خوبی تعیین می‌گردد می‌توان ابتدا با یک شبکه پارامتر عمق را تخمین زده، سپس مقدار تخمینی را در مرحله‌ی بعد یعنی تخمین پارامتر شعاع استفاده کرد.

در واقع در مرحله‌ی تخمین شعاع، ابتدا شبکه با مشخصه‌هایی مانند آنچه که در تخمین عمق به کار برده شد آموزش می‌بیند، با این تفاوت که مشخصه‌ی دیگری که همان عمق مدل هست نیز به این مجموعه اضافه می‌گردد. در واقع وقتی شبکه به این روش آموزش می‌بیند، زمانی که مشخصه‌های بی‌هنجاری گرانی واقعی که عمق تخمین زده شده در مرحله‌ی اول نیز یکی از این مشخصه‌هاست، به شبکه ارائه شود، شبکه به سراغ مدل‌هایی در حدود همان عمق رفته و در همان حدود اقدام به تشخیص پارامتر شعاع می‌کند. با این کار دقت شبکه بالا می‌رود. شعاع و عمق تخمینی در مرحله‌ی بعد برای به دست آوردن چگالی با شبکه‌ی دیگری، به کار برده می‌شوند.

۳-۴-۲-۱ تخمین عمق توده‌های نمک

معادلات (۳-۱۳) تا (۳-۱۶) مشخصه‌هایی اضافه بر آنچه که قبلاً شرح داده شد، می‌باشند (گرت و کلینگله). مشخصه‌ی پنجم و ششم که در این جا معرفی شده است، با مطالعه و دقت در بی‌هنجاری‌های گرانی به دست آمده است. این دو مشخصه که مقادیری مربوط به شیب منحنی‌ها هستند، برای هر مدل خاص، مقداری ثابت داشته و در مقدار این مشخصه‌ها برای بی‌هنجاری‌های کروی شکل در پارامترهای مختلف، تفاوت محسوسی وجود دارد. بنابراین به کمک مشخصه‌های قبلی در تخمین عمق توده‌های عمیق بسیار خوب عمل می‌کنند. هر توده‌ی بی‌هنجار به مشخصه‌های متفاوتی حساس بوده و برخی از اجسام بی‌هنجار برای توصیف خود نسبت به سایر اجسام، به مشخصه‌های بیشتری نیاز دارند. جدول (۳-۱) فهرستی از مشخصه‌های منطبق با دو مدل کره و گنبد نمکی ریشه‌دار را برای تخمین عمق نشان می‌دهد.

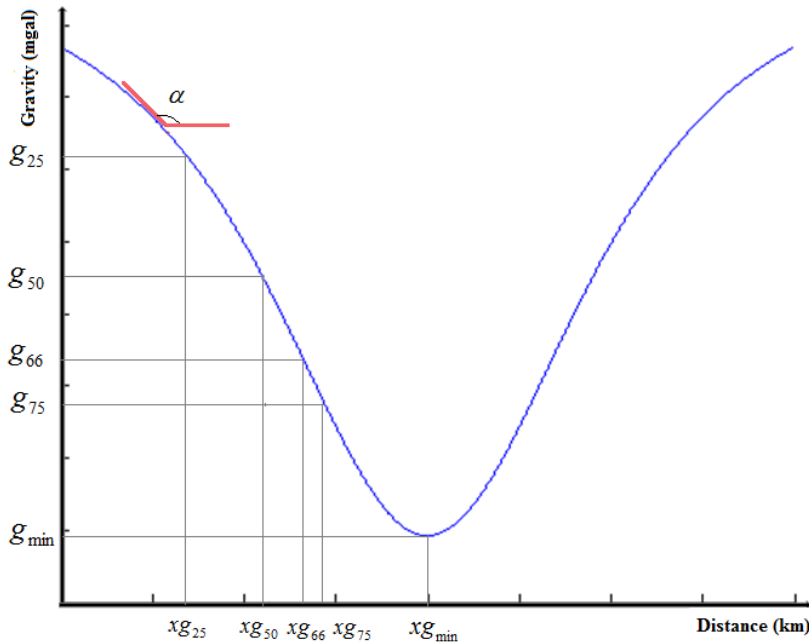
$$F_3 = \int_{-}^{+} g(x) dx \quad (۳-۱۳)$$

$$F_4 = |g_{\max}| - |g_{\min}| \quad (۳-۱۴)$$

$$F_5 = \frac{|g_{75}| - |g_{50}|}{|xg_{75}| - |xg_{50}|} \quad (۳-۱۵)$$

$$F_6 = \max(\tan(\alpha)) \quad (16-3)$$

که در آن: مقادیر F_3 تا F_7 مشخصه‌های معرف آنومالی‌ها می‌باشند. g_y مقدار g در $y\%$ ماکزیمم مقدار g و xg_y مقدار x در g_y ، $\tan(\alpha)$ شیب منحنی بین هر دو نقطه‌ی متوالی به فاصله‌ی ۱۰۰ یکسان متر می‌باشد. این پارامترها در شکل (۱۰-۳) نشان داده شده‌اند.



شکل ۱۰-۳: پارامترهای تعریف شده در معادلات مربوط به مشخصه‌ها

آنچنان که در شکل (۱۱-۳) نمایان است، برای به دست آوردن مشخصه‌ی سوم که انتگرال زیر سطح منحنی می‌باشد، در حدود بالا و پایین این انتگرال مقدار $g(x)$ مساوی g_c می‌باشد، که g_c به کمک معادله‌ی (۱۷-۳) مشخص می‌شود (حاجیان، ۲۰۰۹).

$$g_c = g_{\min} + 0.2 * (g_{\max} - g_{\min}) \quad (17-3)$$

که در آن g_{\max} بیشترین مقدار گرانی اندازه‌گیری شده و g_{\min} کمترین مقدار گرانی اندازه‌گیری شده بر روی پروفیل موردنظر است.

۲-۲-۴-۳ تخمین شعاع

مشخصه‌های مورد نیاز برای ایجاد شبکه همان مشخصه‌های تعریف شده در حالت تخمین عمق


به‌اضافه‌ی مشخصه‌ی مربوط به عمق (معادله‌ی (۱۸-۳)) می‌باشند.

$$F_7 = Z \quad (18-3)$$

بردار هدف در این حالت، بردار شعاع‌های مورد انتظار از شبکه برای مدل‌های مصنوعی در نظر گرفته شده است.

جدول ۱-۳: مشخصه‌های معرف دو مدل کروی و گنبدی شکل برای مساله‌ی تخمین عمق

	F1	F2	F3	F4	F5	F6
مدل کروی			*	*	*	*
مدل گنبدی	*	*	*			*



شکل ۱۱-۳: حدود انتگرال برای محاسبه‌ی مشخصه‌ی سوم

جدول ۳-۲: مشخصه‌های به کار رفته در تخمین شعاع برای مدل‌های مصنوعی مرحله‌ی ارزیابی شبکه عصبی

	F1	F2	F3	F4	F5	F6	F7
مدل کروی			*	*	*	*	*
مدل گنبدی	*	*	*			*	*

۳-۲-۴-۳ تخمین چگالی

مشخصه‌های مورد نیاز برای ایجاد شبکه در این مرحله نیز همان مشخصه‌های تعریف شده در حالت تخمین شعاع به اضافه‌ی مشخصه‌ی مربوط به شعاع (معادله‌ی (۳-۱۹)) می‌باشند.

$$F_8 = R \quad (۳-۱۹)$$

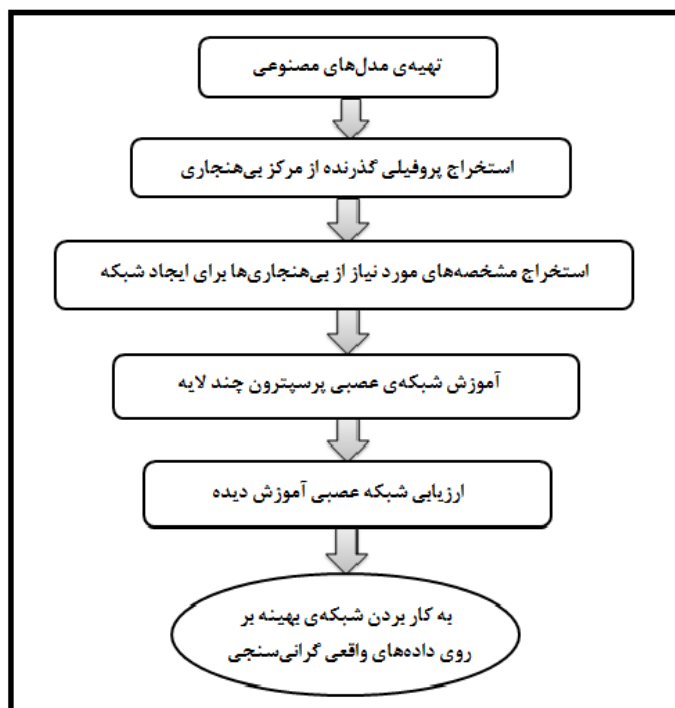
جدول ۳-۳: مشخصه‌های به کار رفته در تخمین چگالی برای مدل‌های مصنوعی مرحله‌ی ارزیابی شبکه عصبی

	F1	F2	F3	F4	F5	F6	F7	F8
مدل کروی			*	*	*	*	*	*
مدل گنبدی	*	*	*			*	*	*

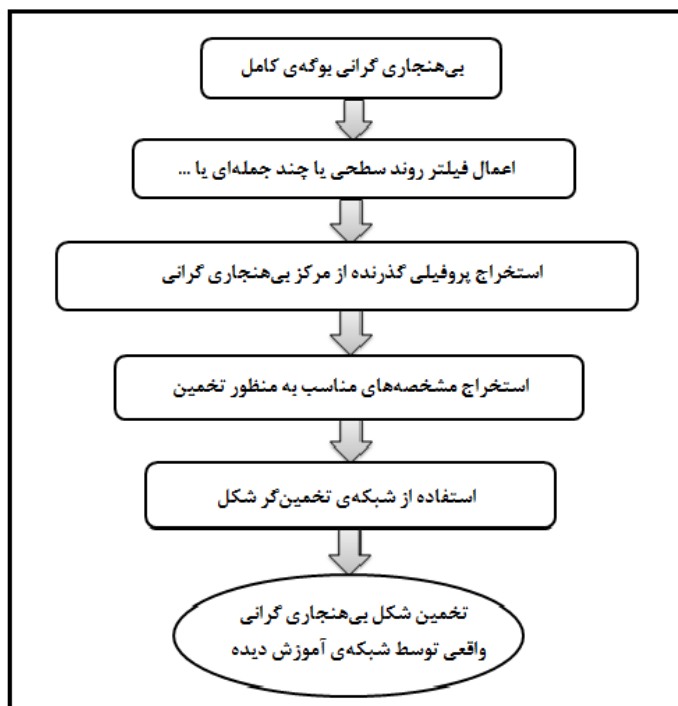
۳-۴-۳ نمایش کلی مراحل کار و روند مدل‌سازی معکوس به روش شبکه‌های عصبی:

پیشتر روند انجام این تحقیق با ذکر جزئیات بیان گردید. ارائه‌ی روش تفسیر یک بی‌هنجاری به روش شبکه‌های عصبی مصنوعی در یک روندنما^۱ مفید به نظر می‌رسد. اشکال (۳-۱۲) و (۳-۱۳) و (۳-۱۴) نگاهی گذرا به روال تفسیر یک بی‌هنجاری گرانی‌سنجی را به کمک شبکه‌های عصبی تولید شده در این تحقیق نشان می‌دهد. شکل (۳-۱۵) نیز شمایی از ماتریس‌های ورودی و خروجی به شبکه را نشان می‌دهد.

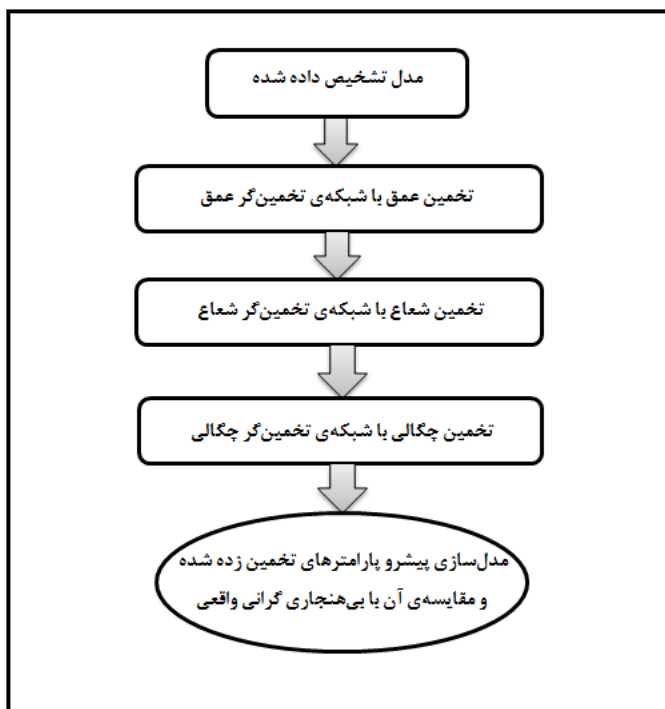
^۱Flowchart




شکل ۳-۱۲: ترسیم روند کلی کار برای ایجاد یک شبکه ی عصبی تخمین گر



شکل ۳-۱۳: ترسیم روند کلی کار برای مرحله ی تشخیص شکل جسم بی هنجاری مورد نظر



شکل ۳-۱۴: مراحل کلی کار در مدل‌سازی معکوس داده‌های گرانی‌سنجی به روش شبکه عصبی



شکل ۳-۱۵: طرح شماتیک ماتریس ورودی و خروجی شبکه عصبی. F ها مشخصه‌های به کار برده شده، i تعداد مشخصه‌ها، Q تعداد نمونه‌ها و p پارامتری است که شبکه قصد تخمین آن را دارد.

۳-۴-۴ آموزش شبکه‌ی عصبی

برای حل مسأله‌ی وارون‌سازی از همان نوع شبکه‌ی عصبی به کار رفته برای تشخیص مدل یعنی پرسپترون چند لایه استفاده می‌شود. به دلیل این که مسأله پیچیده‌تر است، شبکه به مینیمم محلی، بیش‌برازش و کم‌ترین‌برازش، حساس‌تر می‌باشد. تغییرات روی سطح خطای چند بعدی در این مسأله بیشتر است، بنابراین تنها یک شبکه‌ی قوی قادر به یافتن بردارهای هدف در مجموعه‌ی

آموزشی خواهد بود. شبکه‌ای مطلوب است که یک مجموعه‌ی آموزشی و یک مجموعه‌ی کاربردی را با یک مرتبه بزرگی از خطا تنظیم کند. این نشان می‌دهد تعداد نرون‌ها در لایه‌ی میانی برای مساله قطعی است.

به دلیل تغییرات سطح خطا، فرآیند آموزش اغلب در مینیمم محلی اتفاق می‌افتد. به این دلیل یک الگوریتم پس انتشار به کار برده می‌شود که قدرت بیشتری در یافتن روش فرار از یک مینیمم محلی را دارا است [Levenberg-Marquardt back-propagation approximation; Hagan et al., 1994]. اما حتی با یک الگوریتم آموزشی بهبودیافته، یافتن راهی برای خروج از همه‌ی مینیمم محلی‌ها دشوار است.

زمان آموزش: برخلاف مساله‌ی تشخیص شکل، در وارون‌سازی زمان آموزش می‌تواند یک مساله باشد.

آموزش ANN نیاز به تجربه‌ی فراوان دارد و این تجربه، اگر زمان آموزش خیلی بزرگ باشد نمی‌تواند اندوخته شود. بنابراین بسیار مهم است که مجموعه‌ی آموزشی تا حد ممکن کوچک در نظر گرفته شود.

مسائل پیش‌روی آموزش:

- **طول پروفیل بی‌هنجاری:** هنگامی که با مجموعه‌ای از بی‌هنجاری‌ها با یک طول پروفیل مشخص شبکه‌ای آموزش داده شود، شبکه قادر به تخمین پارامتر بی‌هنجاری‌هایی خواهد بود که طول پروفیلی تقریباً هم‌اندازه با طول پروفیل داده‌های مجموعه‌ی آموزشی داشته باشند. در واقع در این‌جا چون مشخصه‌ها تابع گسترش افقی آنومالی‌ها می‌باشند، بنابراین هرچند روند آموزش صحیح بوده است، ولی شبکه در تشخیص خود گمراه خواهد شد. به این منظور در الگوریتم تهیه شده این مساله در نظر گرفته شده و امکان آموزش شبکه با طول پروفیل مدنظر کاربر وجود دارد.
- **ابعاد اجسام بی‌هنجار در عمق زیاد:** در این تحقیق مشخص شد که اگر مدل‌های در نظر گرفته شده در اعماق زیاد که برای آموزش شبکه به کار برده می‌شوند، دارای ابعاد کوچکی باشند به این دلیل مهم که تغییرات بی‌هنجاری‌ها در سطح عملاً مقدار کوچکی خواهد بود و تفاوت قائل شدن بین این بی‌هنجاری‌ها برای شبکه دشوار خواهد بود، شبکه

به درستی آموزش نخواهد دید. برای حل این مشکل در الگوریتم مورد استفاده این شرط قرار داده شد که با زیاد شدن عمق، کمترین مقدار در نظر گرفته شده برای شعاع نیز بیشتر شود. در واقع مقدار آغازین بازه شعاع در نظر گرفته شده برای مدل‌های آموزشی با افزایش عمق زیاد می‌شود تا توان شبکه در آموزش و تشخیص بالا رود.

- **بازه‌ی تغییرات پارامترهای مدل‌های آموزشی:** مدل‌های در نظر گرفته شده برای آموزش شبکه باید تا حدودی بیان‌گر ساختارهای واقعی زمین‌شناسی باشند. اگر تفاوت مقدار یک پارامتر برای مدل‌های متفاوت کوچک در نظر گرفته شود، آنگاه این احتمال وجود دارد که بی‌هنجاری گرانی حاصل از دو جسم متفاوت، بسیار به هم شبیه باشند. بنابراین تشخیص شبکه در هر بار آموزش با دفعه‌ی قبل متفاوت خواهد بود. برای جلوگیری از این مساله تفاوت‌ها به صورتی انتخاب شده‌اند که ابهامات موجود در آموزش و نتیجتاً تشخیص، برطرف شود.

- **تعیین هر سه پارامتر عمق، شعاع و چگالی توسط یک شبکه:** برای بررسی این موضوع که آیا شبکه قادر به تخمین سه پارامتر همزمان با هم می‌باشد، ماتریس هدف شامل هر سه پارامتر شعاع، عمق و چگالی در نظر گرفته شد. برآورد شبکه برای تخمین پارامتر عمق خوب بوده ولی نتیجه‌ی مطلوبی برای دو پارامتر دیگر و مخصوصاً پارامتر چگالی نداشته است. در واقع مشخص شد که شبکه با مجموعه‌ی مشخصی از اطلاعات نمی‌تواند همزمان راجع به سه مساله اظهار نظر کند. بنابراین برای تخمین هر پارامتر یک شبکه‌ی مجزا در نظر گرفته شد.

- **مساله‌ی تعیین چگالی و شعاع:** پیشتر اشاره شد که مساله‌ی تعیین چگالی دشوارترین مساله‌ی تشخیص پارامتر توسط شبکه می‌باشد. در روش ارائه شده توسط گرت و کلینگله (۱۹۹۸) تباین چگالی ثابت فرض شده است و تخمین عمق با یک چگالی ثابت برای همه‌ی مدل‌های آموزشی انجام شده است. این روش بر روی مدل‌های مصنوعی با همان چگالی که شبکه با آن آموزش دیده است، به کار برده شده است. این روش به دلیل داشتن یک فرض اولیه راجع به چگالی، بر روی داده‌های واقعی جواب درستی نخواهد داد. با این دیدگاه، حل مساله‌ی تشخیص تباین چگالی ضروری به نظر می‌آید. اگر قیدی بر

شبکه اعمال نشود، آموزش شبکه با خطای بسیار زیادی همراه خواهد بود و بنابراین شبکه تخمین درستی نخواهد داشت. وارد کردن قیدها در آموزش به روند آموزش بهتر شبکه کمک خواهند کرد. مشکل از آن جا ناشی می‌شود که ممکن است در یک عمق خاص، دو یا چند جسم با شعاع و چگالی متفاوت بی‌هنجاری‌هایی هم‌شکل ایجاد کرده و بنابراین مشخصه‌ها مقادیری نزدیک به هم داشته و تشخیص شبکه گمراه‌کننده خواهد بود. برای حل مساله ایده‌ای که به کار برده شد، کاربرد عمق و شعاع به دست آمده در مراحل قبل در فرآیند آموزش شبکه بود که کمک بسیار خوبی در روند یک آموزش صحیح بوده است.


فصل چهارم:

به کاربردن روش شبکه‌ی عصبی مصنوعی بر روی داده‌ی واقعی

۱-۴ گنبد نمکی هامبل^۱

میدان نفتی هامبل یک میدان تولید نفت در آمریکا می‌باشد که در دو کیلومتری شهر هامبل در ساحل شمالی خلیج تگزاس در منطقه‌ی کانزاس آمریکا قرار دارد. سنگ مخزن این میدان نفتی که مقدار ناچیزی گاز دارد، سنگ‌های انیدرتی و آهکی سازندهای مربوط به دوره‌های ائوسن، میوسن، الیگوسن و پلیوسن می‌باشد. هامبل دارای ذخیره‌ی قابل ملاحظه‌ای بوده که نزدیک به یک قرن از مخازن آن نفت استخراج می‌شود [USGS, 2009].

به منظور تفسیر آنومالی گرانی ناشی از این گنبدنمکی پس از رقومی کردن نقشه (شکل ۱-۴) آنومالی گرانی بوگه [Nettleton, 1976]، پروفیلی در راستای شمالی-جنوبی به فاصله‌ی نقاط ۰/۵ کیلومتر تهیه و مقادیر عددی آن به عنوان فایل ورودی در محیط نرم‌افزار متلب مورد استفاده قرار گرفت.

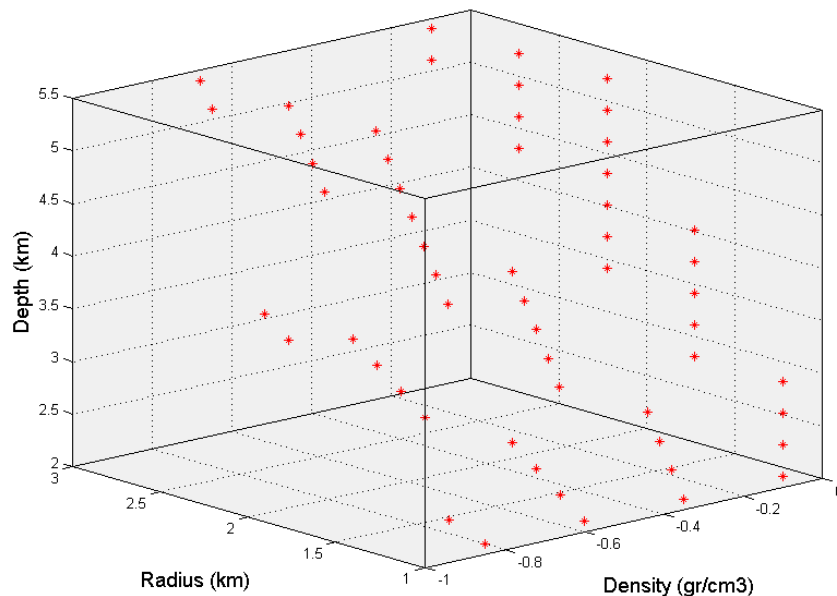


شکل ۱-۴: آنومالی گرانی بوگه ناشی از گنبد نمکی هامبل با مقیاس ۱:۲۵۰۰۰۰، هریس تگزاس.

^۱ Humble

۴-۱-۱ تعیین شکل گنبد نمکی هامبیل

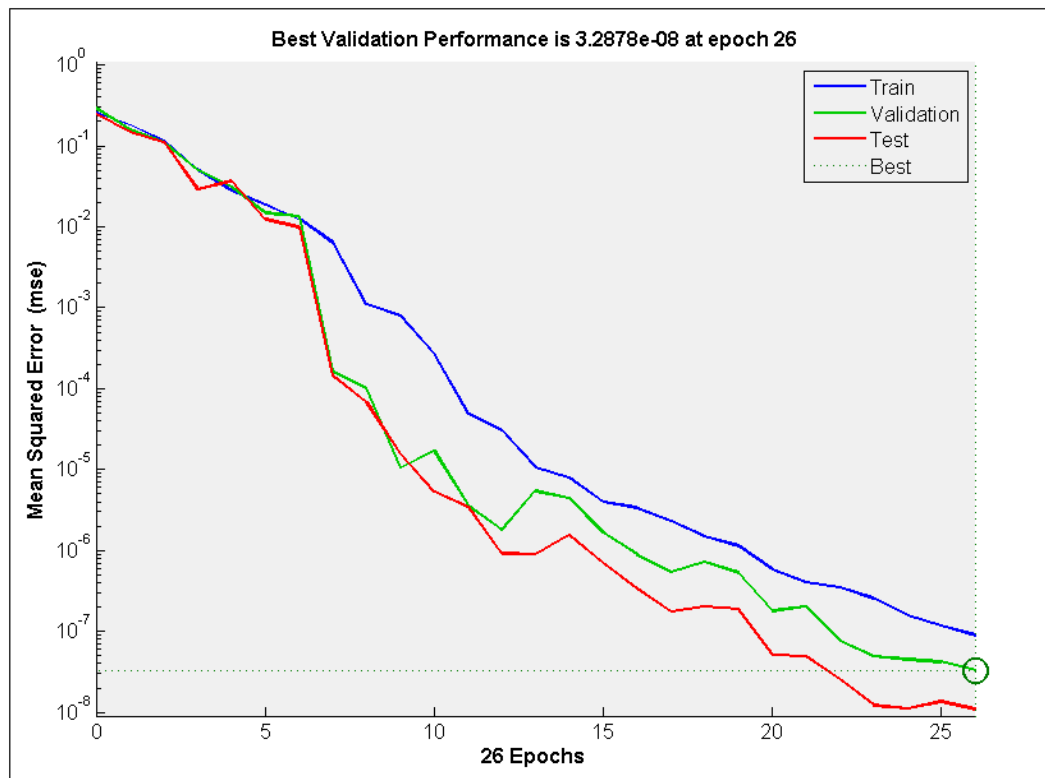
همانطور که پیشتر اشاره شده است، در این جا به کمک دو مدل کروی و مدل گنبدی شکل (استوانه‌ای قائم و عرفچین کروی) به بررسی شکل نمک هامبیل پرداخته شده است. برای این منظور در مرحله‌ی اول تعدادی مدل کروی و گنبدی شکل برای مرحله‌ی آموزش شبکه ساخته شد. به منظور دریافت خروجی‌های صحیح از شبکه، پارامترهای این مدل‌ها باید به پارامترهای واقعی ساختارهای نمک نزدیک باشند. فضای آموزشی سه بعدی ۱۱۲ مدل مصنوعی در نظر گرفته شده در شکل (۴-۲) و مقادیر کمینه و بیشینه‌ی مربوط به هر یک از این پارامترها در جدول (۴-۱) آورده شده است. از این ۱۱۲ مدل، ۵۶ مدل کروی و ۵۶ مدل گنبدی شکل می‌باشند. برای مرحله‌ی آموزش شبکه ۷۸ مدل از مجموعه‌ی کلی به صورت تصادفی انتخاب و مشخصه‌های لازم برای ورود به شبکه از این مدل‌ها استخراج شدند. ۳۴ مدل باقی‌مانده برای ارزیابی و اعتبارسنجی شبکه مورد استفاده قرار گرفت. همان‌طور که پیشتر ذکر شد، به جای استفاده از تمام داده‌های گرانی در مدل‌سازی، از یک مجموعه مشخصه‌ی مناسب که بیانگر بی‌هنجاری مدنظر باشد، استفاده شده است. به این منظور یک پروفیل گذرنده از مرکز هر مدل انتخاب و مشخصه‌های مورد نیاز از آن استخراج شدند.



شکل ۴-۲: نمایش حدود پارامترهای داده‌های مصنوعی تولید شده برای تشخیص شکل بی‌هنجاری (هر کدام از *ها یک مدل مصنوعی کروی یا گنبدی شکل می‌باشند).

جدول ۴-۱: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تشخیص شکل

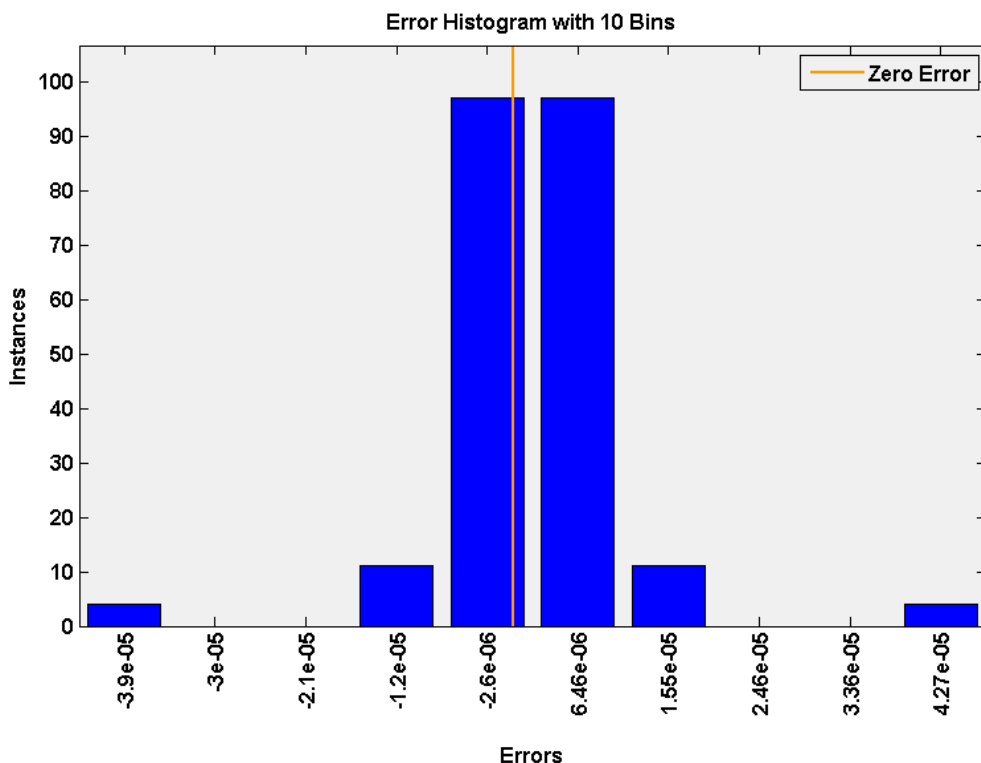
مدل‌های کروی شکل و گنبدی شکل	کمترین مقدار	بیشترین مقدار	مقدار تغییرات بین هر دو مدل متوالی
عمق (کیلومتر)	۱/۶	۵/۴	۰/۳
شعاع (کیلومتر)	۱	۳	۰/۵
چگالی (گرم بر سانتی‌متر مکعب)	-۰/۱	-۱	-۰/۱



شکل ۴-۳: نمودار تابع کارایی (متوسط مربعات خطا) شبکه‌ی تخمین‌گر شکل برای هر سه مرحله‌ی آموزش، اعتبارسنجی و ارزیابی

در آموزش شبکه‌ی عصبی پرسپترون به منظور تخمین شکل، پارامترها پس از چندین مرحله تنظیم در نهایت به گونه‌ای انتخاب شدند که شبکه بهترین کارایی را داشته باشد. شبکه‌ی ایجاد شده

یک شبکه‌ی پرسپترون سه لایه (۲ ۲ ۲) با نرخ آموزشی ۰.۱ می‌باشد که پس از ۲۶ تکرار آموزش دید. نمودار خطا در تکرارهای انجام شده در مرحله‌ی آموزش در شکل (۳-۴) نشان داده شده است. شکل (۴-۴) هیستوگرام خطا در مرحله‌ی آموزش را برای نمونه‌های آموزشی نشان می‌دهد. رگرسیون خطی بین بردار خروجی و بردار هدف برای مرحله‌ی آموزش (۰.۹۹۹۹)، برای مرحله‌ی ارزیابی (۰.۹۳۸۷) و برای مرحله‌ی اعتبارسنجی (۰.۹۹۹۹۸) می‌باشد که نتایج بسیار خوبی هستند و در مجموع این نتایج شبکه را بسیار خوب ارزیابی می‌کنند و می‌توان گفت قابلیت اطمینان بالایی دارد. نتیجه‌ی تشخیص شبکه برای ۱۰ مدل از مدل‌های ارزیابی شبکه در جدول (۲-۴) آورده شده است. همانطور که قابل ملاحظه است شبکه در تعیین شکل برای هر ۱۰ مدل بسیار خوب عمل کرده است. نتیجه این شبکه برای داده‌های گرانی‌سنجی نمک هامبل به صورت $\begin{pmatrix} -0.0023 \\ 1.0023 \end{pmatrix}$ است که نشان از کروی بودن این نمک است و به عبارتی نمک مذکور ریشه‌ای عمیق ندارد.



شکل ۴-۴: نمودار هیستوگرام خطا برای داده‌های فضای آموزشی شبکه‌ی تخمین‌گر شکل

جدول ۴-۲: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تعیین شکل در مرحله‌ی ارزیابی

پارامترهای مربوط به ۱۰ مدل مصنوعی در مرحله‌ی ارزیابی شبکه			خروجی شبکه			
نوع مدل	عمق (کیلومتر)	شعاع (کیلومتر)	چگالی (گرم بر سانتی‌متر مکعب)	(a1)	(a2)	شکل تشخیص داده شده
گنبد	۲/۲	۱	-۰/۵۹	۰/۹۹۹	۰/۰۰۰۱۳	گنبد
کره	۳/۲	۱/۵	-۰/۶۵	۰/۰۰۰۰۰۳	۰/۹۹۹	کره
کره	۳/۷	۲	-۰/۶۸	۰/۰۰۰۰۰۴	۰/۹۹۹	کره
گنبد	۳/۱	۱/۵	-۰/۹	۰/۹۹۹	۰/۰۰۰۰۰۲	گنبد
کره	۳/۷	۲	-۰/۵۶	۰/۰۰۰۰۰۴	۰/۹۹۹	کره
گنبد	۴/۰	۱/۵	-۰/۵۹	۰/۹۹۹	۰/۰۰۰۰۰۲	گنبد
گنبد	۴/۳	۲/۵	-۰/۱	۰/۹۹۹	۰/۰۰۰۰۰۲	گنبد
گنبد	۴/۶	۲/۵	-۰/۷	۰/۹۹۹	۰/۰۰۰۰۰۲	گنبد
کره	۴/۶	۳	-۰/۶	۰/۰۰۰۰۰۳	۰/۹۹۹	کره
گنبد	۵/۲	۳	-۰/۷۵	۰/۹۹۹	۰/۰۰۰۰۰۲۴	گنبد

۴-۱-۲ تخمین عمق گنبد نمکی هامبل

پس از تعیین شکل با شبکه‌ی عصبی می‌توان برای تخمین پارامترهای جسم زیرسطحی موردنظر از شبکه‌های مجزایی به کار برد.

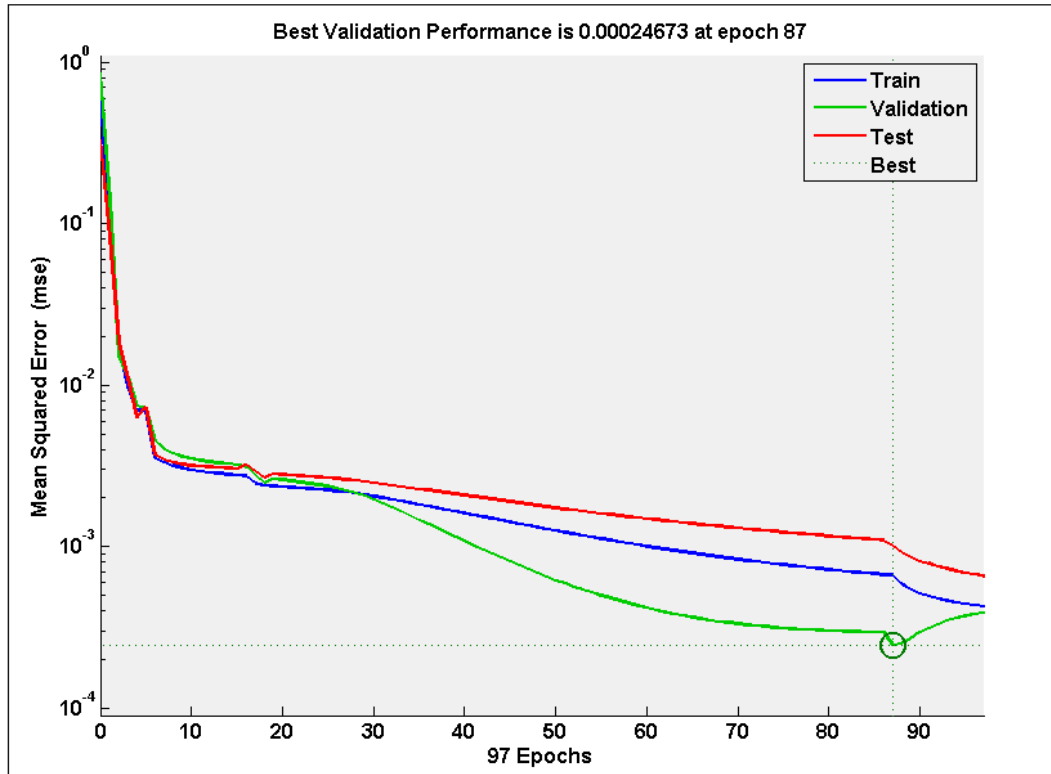
حدود و میزان اختلاف پارامترهای مدل‌های مصنوعی در مجموعه‌ی آموزشی به کار برده شده در تخمین عمق در جدول (۴-۳) آورده شده‌اند. در مرحله‌ی آموزش شبکه‌ی عصبی پرسپترون، پارامترهای شبکه پس از چندین مرحله تنظیم در نهایت به گونه‌ای انتخاب شدند که شبکه بهترین کارایی را داشته باشد. این پارامترها، شامل تعداد لایه‌های میانی، تعداد نرون‌ها در لایه‌های مذکور، توابع انتقال مورد استفاده برای لایه‌های میانی و خروجی و نیز نرخ آموزش شبکه در هر بار آموزش می‌باشد. اگر هر کدام از این پارامترها به درستی انتخاب نگردد احتمال همگرا شدن مدل به یک

کمینه‌ی محلی و در نتیجه دست‌یابی به یک پاسخ گول‌زننده بسیار بالاست. این به این دلیل است که در مساله‌ی مدل‌سازی معکوس به روش شبکه عصبی، سطح خطا اوجاجات بسیار داشته و کمینه محلی‌های فراوانی در آن وجود دارد. این مساله اهمیت دقت در مرحله‌ی آموزش شبکه را به خوبی نشان می‌دهد. در هر بار تلاش به منظور آموزش شبکه، نمودار تابع کارایی ترسیم و در نهایت بهترین حالت آنچنان‌که در شکل (۴-۵) نمایش داده شده است، به دست آمد.

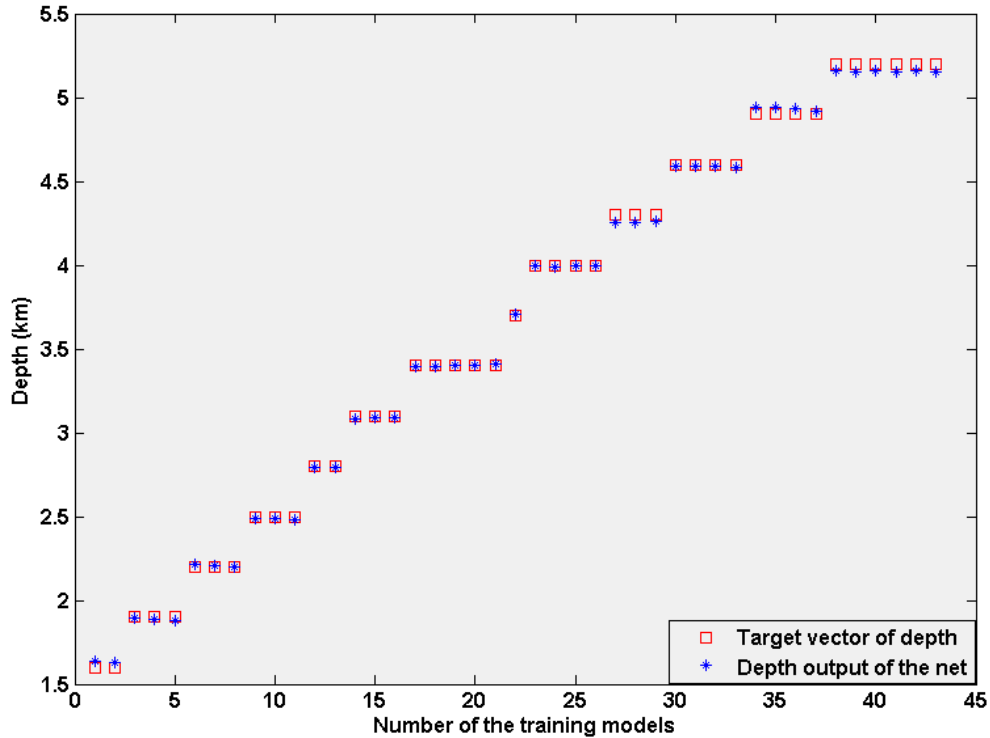
همان‌طور که قبلاً ذکر شده است، هنگامی که خطای ارزیابی و نیز اعتبارسنجی شبکه شروع به افزایش پایداری کند، بهینه‌ترین حالت را برای شبکه خواهیم داشت. ملاحظه می‌شود در این نقطه خطای اعتبارسنجی در حدود $0/0002$ می‌باشد. شبکه‌ی نهایی یک شبکه‌ی پرسپترون سه لایه (۱ ۳ ۴) با نرخ آموزشی (۰.۱) می‌باشد که پس از ۸۷ تکرار آموزش دید. نتایج تخمین شبکه در مرحله‌ی آموزش در برابر مقادیر مورد انتظار از شبکه در شکل (۴-۶) به نمایش درآمده است. همان‌گونه که ملاحظه می‌شود شبکه روند تغییرات مورد انتظار در مرحله‌ی آموزش را به خوبی تشخیص داده است.

جدول ۴-۳: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تخمین‌گر عمق

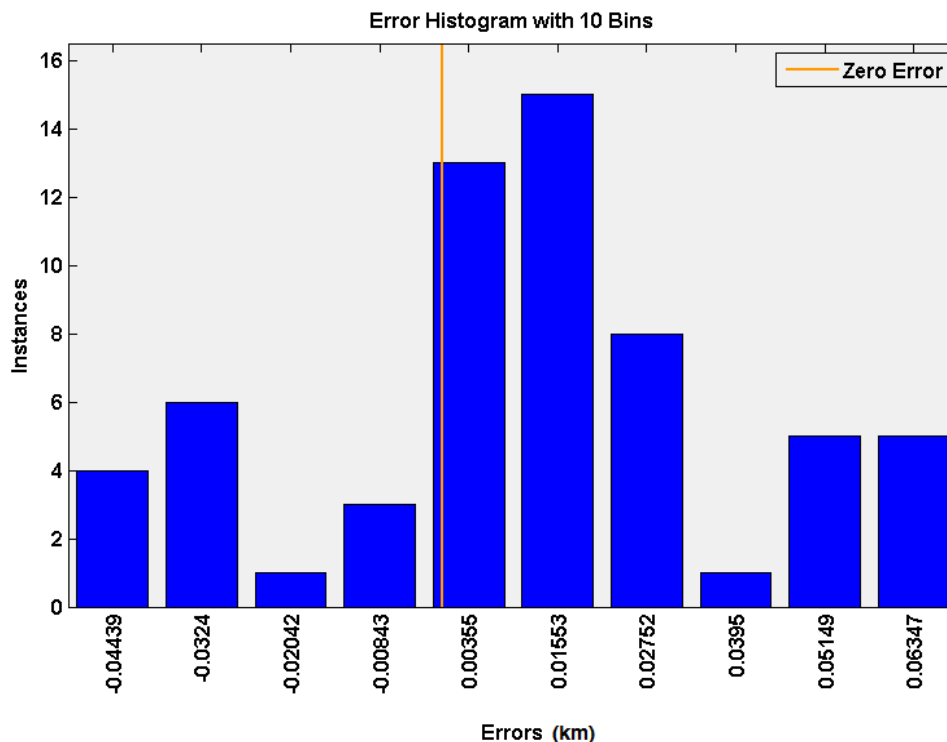
مدل کروی شکل	کمترین مقدار	بیشترین مقدار	مقدار تغییرات بین هر دو مدل متوالی
عمق (کیلومتر)	۱/۶	۵/۴	۰/۵
شعاع (کیلومتر)	۱	۳	۰/۳
چگالی (گرم بر سانتی‌متر مکعب)	-۰/۱	-۱	-۰/۱



شکل ۴-۵: نمودار تابع کارایی شبکه‌ی تخمین‌گر عمق برای هر سه مرحله‌ی آموزش، اعتبارسنجی و ارزیابی



شکل ۴-۶: خروجی‌های شبکه‌ی تخمین‌گر عمق در مقابل مقادیر مورد انتظار از آن در مرحله‌ی آموزش

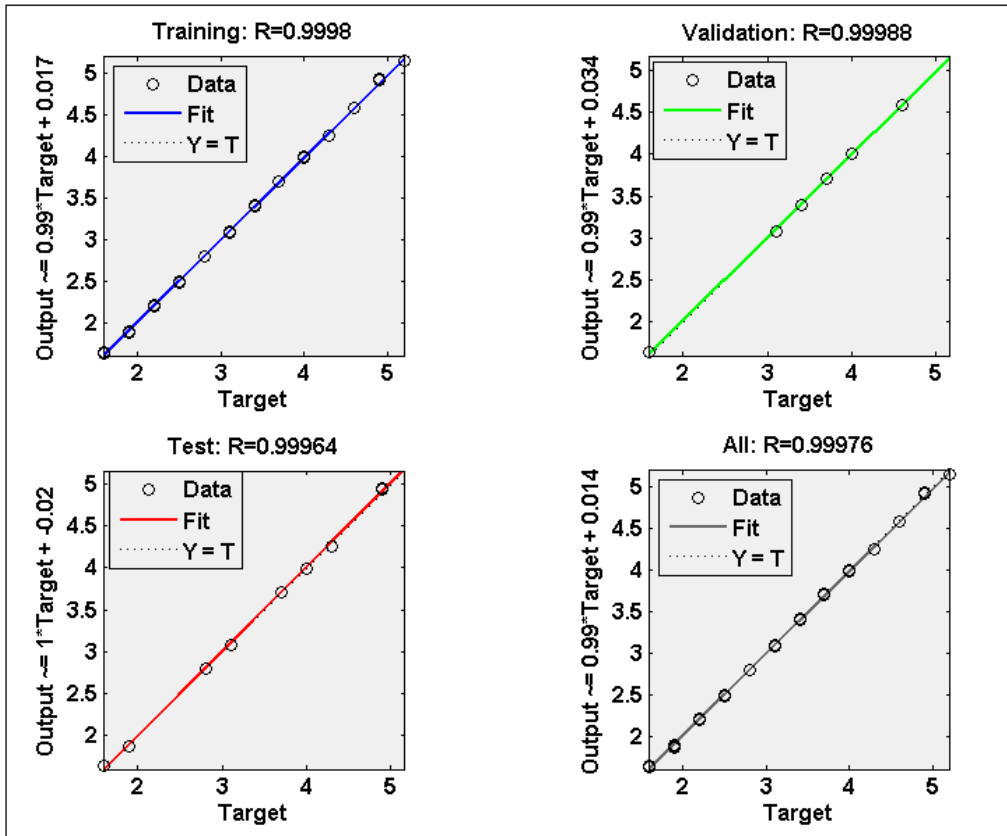


شکل ۴-۷: نمودار هیستوگرام خطا برای داده‌های فضای آموزشی شبکه‌ی تخمین‌گر عمق

شکل (۴-۷) هیستوگرام خطا در مرحله‌ی آموزش را برای نمونه‌های آموزشی نشان می‌دهد. پس از مرحله‌ی آموزش شبکه با مدل‌هایی که قبلاً ندیده است و به عبارتی در آموزش شبکه دخالت نداشته‌اند، ارزیابی می‌شود. نتایج تخمین شبکه در مرحله‌ی ارزیابی در جدول (۴-۴) آورده شده است و به وضوح دیده می‌شود که شبکه عملکرد خوبی را در این مرحله نیز داشته است.

نمودار رگرسیون بین مقادیر خروجی و مقادیر انتظاری از شبکه در هر سه مرحله در شکل (۴-۸) آورده شده است. پس از انجام مراحل ذکر شده از مدل تهیه شده در تخمین عمق داده‌های هامبل استفاده شد. نتیجه‌ی حاصل برای عمق نمک هامبل $5/2$ کیلومتر می‌باشد. باید یادآور شد که دقت^۱ آموزش شبکه با مدل‌های مصنوعی برای پارامتر عمق $0/5$ کیلومتر بوده است، بنابراین شبکه در تخمین عمق عملکرد بسیار خوبی داشته است. همان‌طور که در جدول (۴-۵) آورده شده است، عمق به دست آمده با این روش توافق خوبی با عمق به دست آمده توسط مطالعات پیشین دارد.

^۱. Resolution



شکل ۴-۸: رگرسیون خطی بین خروجی‌های شبکه و مقادیر مورد انتظار از آن در هر سه مرحله‌ی آموزش، ارزیابی و اعتبارسنجی برای تخمین عمق (عمق بر حسب کیلومتر می‌باشد).

جدول ۴-۴: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تخمین عمق در مرحله‌ی ارزیابی

شماره مدل (مدل کره)	پارامترهای مدل‌های مصنوعی در مرحله‌ی ارزیابی شبکه			خروجی شبکه (پارامتر مورد بررسی: عمق)
	عمق (کیلومتر)	شعاع (کیلومتر)	چگالی (گرم بر سانتی‌متر مکعب)	عمق تخمین‌زده شده (کیلومتر)
۱	۱/۶	۱	-۰/۳۵	۱/۶۳۶۱
۲	۱/۹	۱	-۰/۹۴	۱/۸۶۶۱
۳	۲/۸	۱/۵	-۰/۸۴	۲/۷۹۲۲
۴	۳/۱	۱/۵	-۰/۹	۳/۰۸۷۳
۵	۳/۷	۲	-۰/۵۶	۳/۷۱۸۳
۶	۴/۰	۱/۵	-۰/۵۹	۳/۹۹۰۵
۷	۴/۳	۲/۵	-۰/۱	۴/۲۵۲۹
۸	۴/۹	۲	-۰/۱	۴/۹۴۴۴
۹	۴/۹	۳	-۰/۱	۴/۹۴۱۸

جدول ۴-۵: نتایج عمق برای داده‌های گرانی نمک هامبل با روش‌های مختلف

عمق مرکز کره (کیلومتر)	مدل	نویسنده مقاله	روش
۴/۹۷	کره	نتلتون (۱۹۷۶)	منحنی‌های شاخص
۴/۹۶	کره	موهان و همکاران (۱۹۸۶)	تبدیل ملین
۴/۹۸	کره	شاو و اگراوا (۱۹۹۷)	تبدیل والش
۴/۹۲	کره	عبدالرحمان و ت.م. العربی (۱۹۹۳)	کمترین مربعات
۴/۶۰	کره	عبدالرحمان و ت.م. العربی (۱۹۹۶)	میانگین متحرک
۴/۹۶	کره	عبدالرحمان و همکاران (a-۲۰۰۱)	کمینه‌سازی کمترین مربعات سوم
۴/۸۰	کره	آفاجانی و همکاران (۲۰۰۹d)	روش گرادیان نرمال

۴-۱-۳ تخمین شعاع گنبد نمکی هامبل

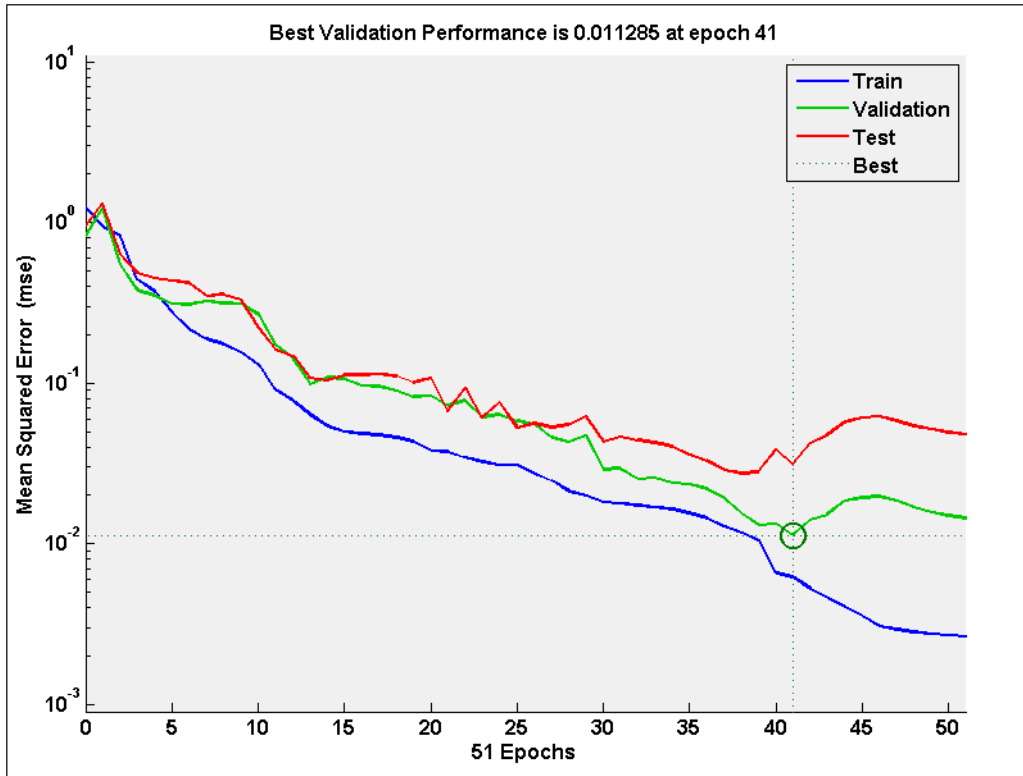
برای تخمین شعاع از ۳۳ مدل مصنوعی کروی شکل استفاده شد که از این تعداد ۲۳ مدل برای آموزش، ۵ مدل برای ارزیابی و ۵ مدل برای اعتبار سنجی شبکه استفاده شده است. حدود پارامترها مانند آنچه که در جدول (۴-۶) به نمایش در آمده است می‌باشد. در این مرحله ۲ پارامتر هنوز مشخص نیستند و اگر مدل‌های بیشتری یا تغییرات کوچک در مقدار پارامترهایشان در نظر گرفته

شوند، پاسخ بی‌هنجاری آن‌ها هم‌پوشانی^۱ خواهد داشت و تشخیص شبکه با خطای زیادی همراه خواهد بود. بنابراین ترجیح داده شد که میزان تغییر شعاع از یک مدل به مدل دیگر ۰/۵ کیلومتر در نظر گرفته شود تا تغییرات واضحتری روی منحنی بی‌هنجاری ناشی از این مدل‌ها دیده شود. با در نظر گرفتن این مدل‌ها بهترین نمودار تابع کارایی برای یک شبکه‌ی (۱ ۵ ۵) به دست آمد (شکل ۴-۹). ملاحظه می‌شود هنگامی که میانگین مربعات خطا به مقدار ۰/۰۱۱ رسیده است، مقدار این تابع برای داده‌های اعتبار سنجی شروع به افزایشی پایدار کرده است و بنابراین در این تکرار بهترین مقدار وزن‌ها و بایاس‌ها و در نتیجه بهترین مدل ممکن برای شبکه در نظر گرفته شده به دست آمد. نتایج مورد انتظار برای شعاع مدل‌های مصنوعی در دو مرحله‌ی آموزش و ارزیابی به ترتیب در شکل (۴-۱۰) و جدول (۴-۷) به نمایش در آمده‌اند. شکل (۴-۱۱) هیستوگرام خطا در مرحله‌ی آموزش را برای نمونه‌های آموزشی نشان می‌دهد.


جدول ۴-۶: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تخمین گر شعاع

مدل کروی شکل	کمترین مقدار	بیشترین مقدار	مقدار تغییرات بین هر دو مدل متوالی
عمق (کیلومتر)	۲/۲	۵/۷	۰/۵
شعاع (کیلومتر)	۱	۳	۰/۵
چگالی (گرم بر سانتی متر مکعب)	-۰/۲	-۰/۸	-۰/۳


^۱. overlap



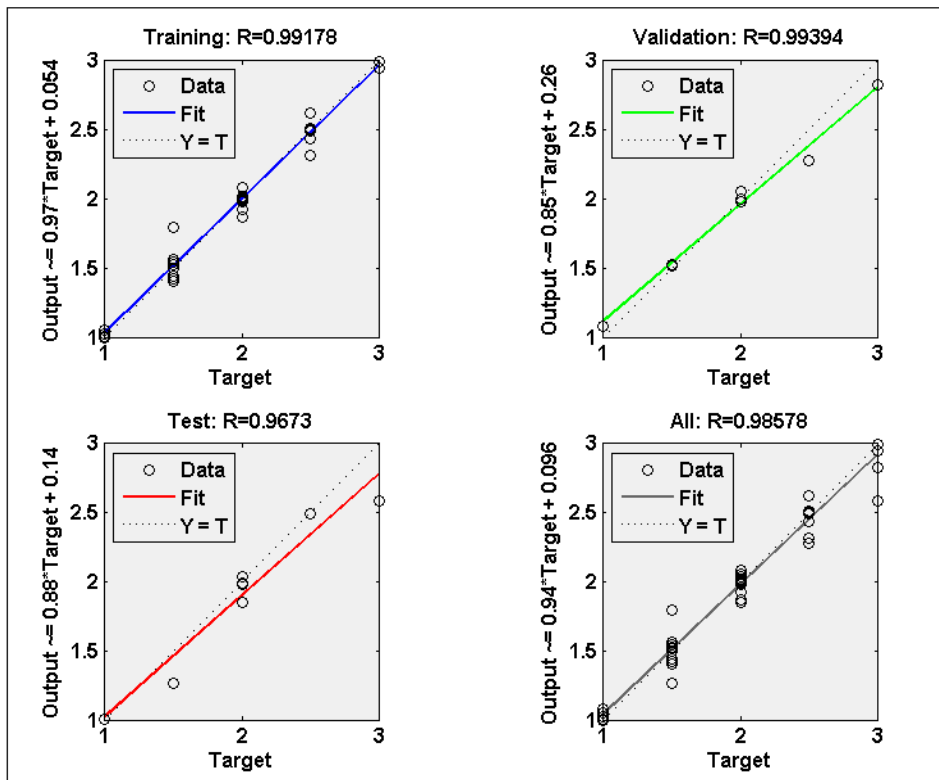
شکل ۴-۹: نمودار تابع کارایی (میانگین مربعات خطا) برای تخمین شعاع در هر سه مرحله‌ی آموزش، ارزیابی و اعتبارسنجی



شکل ۴-۱۰: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تخمین شعاع در مرحله‌ی آموزش



شکل ۴-۱: نمودار هیستوگرام خطا برای داده‌های فضای آموزشی شبکه‌ی تخمین‌گر شعاع



شکل ۴-۱۲: رگرسیون خطی بین خروجی‌های شبکه و مقادیر مورد انتظار از آن در هر سه مرحله‌ی آموزش،

ارزیابی و اعتبارسنجی برای تخمین شعاع (شعاع بر حسب کیلومتر می‌باشد).

به وضوح قابل ملاحظه است که هرچند که دقت تخمین شعاع مانند تخمین عمق نمی‌باشد ولی شبکه توانسته است روند تغییرات را با دقتی در حدود دقت مورد انتظار از آن پیش‌بینی کند. شکل (۱۲-۴) نمودار رگرسیون بین مقادیر انتظاری و مقادیر به دست آمده از شبکه برای شعاع نشان می‌دهد. مقدار رگرسیون برای کل داده‌ها در هر سه مرحله (۰/۹۸) به دست آمد که مقدار قابل قبولی می‌باشد. عدد تخمین زده شده توسط این شبکه برای شعاع نمک هامبل ۲.۵ کیلومتر می‌باشد.

جدول ۴-۷: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تخمین شعاع در مرحله‌ی ارزیابی

پارامترهای مدل‌های مصنوعی در مرحله‌ی ارزیابی شبکه				خروجی شبکه (پارامتر مورد بررسی: شعاع)
شماره مدل (مدل کره)	عمق (کیلومتر)	شعاع (کیلومتر)	چگالی (گرم بر سانتی‌متر مکعب)	شعاع تخمین زده شده (کیلومتر)
۱	۲/۲	۱	-۰/۵۹	۱/۰۸۱۹
۲	۳/۲	۱/۵	-۰/۶۵	۱/۵۳
۳	۳/۷	۲	-۰/۶۸	۱/۵۲۰۲
۴	۴/۲	۲	-۰/۲	۱/۹۸۰۴
۵	۴/۷	۲	-۰/۷۴	۲/۰۵۴۴
۶	۵/۲	۳	-۰/۲	۲/۷۷۷۴
۷	۵/۷	۲/۵	-۰/۸	۲/۰۰۳۸
۸	۵/۷	۲	-۰/۲	۱/۸۲۸۶

۴-۱-۴ تخمین چگالی گنبدنمکی هامبل


در این مرحله برای تخمین شعاع از ۵۲۵ مدل مصنوعی کروی شکل که ۳۶۷ مدل برای آموزش شبکه و ۷۹ مدل برای ارزیابی و ۷۹ مدل برای اعتبار سنجی شبکه به کار برده شده است. مقدار تغییر

چگالی از یک مدل به مدل دیگر ۰.۰۵ گرم بر سانتی متر مکعب می‌باشد. حدود و تغییرات پارامترهای مربوط به مدل‌های مجموعه‌ی آموزشی در جدول (۴-۸) آورده شده است.


شبکه‌ی (۱ ۴ ۶) با نرخ آموزشی (۰/۱) پس از چندین بار تغییر در پارامترهای آن، بهترین شبکه‌ی ممکن برای تشخیص چگالی تشخیص داده شد. نمودار تابع کارایی این شبکه در شکل (۴-۱۳) نشان داده شده است. الگوریتم در پنجاه و سومین تکرار در مقدار خطای ۰/۰۰۰۵ برای داده‌های اعتبارسنجی متوقف شده است. در واقع محتمل‌ترین حالت برای مینیمم مربعات خطا در این تکرار است و مقادیر وزن‌ها و بایاس‌های به دست آمده در این تکرار به عنوان مقادیر نهایی مجهولات شبکه برای حل مساله‌ی تخمین چگالی در نظر گرفته می‌شوند. مقادیر خروجی شبکه در برابر خروجی‌های مورد انتظار از آن در مرحله‌ی آموزش و ارزیابی به ترتیب در شکل‌های (۴-۱۴) و (۴-۱۵) ترسیم شده است. به وضوح توانایی تشخیص شبکه در تعیین چگالی در هر دو مرحله قابل مشاهده است. برای بررسی کمی این تشخیص خروجی‌های به دست آمده از شبکه در مقابل خروجی‌های مورد انتظار از آن برای ۱۰ مدل از کل ۷۹ مدل مجموعه‌ی ارزیابی در جدول (۴-۹) نشان داده شده است. شکل (۴-۱۶) هیستوگرام خطا در مرحله‌ی آموزش را برای نمونه‌های آموزشی نشان می‌دهد. شکل (۴-۱۷) رگرسیون بین مقادیر انتظاری و مقادیر خروجی از شبکه برای چگالی را نشان در هر سه مرحله‌ی آموزش، اعتبارسنجی و ارزیابی نشان می‌دهد. رگرسیون کل (۰/۹۹۶) برای تخمین چگالی نتیجه‌ی بسیار رضایت‌بخشی می‌باشد.

جدول ۴-۸: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تخمین گر چگالی


مدل کروی شکل	کمترین مقدار	بیشترین مقدار	مقدار تغییرات بین هر دو مدل متوالی
عمق (کیلومتر)	۱/۶	۵/۲	۰/۳
شعاع (کیلومتر)	۱	۳	۰/۵
چگالی (گرم بر سانتی متر مکعب)	-۰/۱	-۱	-۰/۰۵




شکل ۴-۱۳: نمودار تابع کارایی شبکه در هر سه مرحله‌ی آموزش، اعتبارسنجی و ارزیابی برای تخمین چگالی



شکل ۴-۱۴: نتایج تخمین زده شده توسط شبکه در مقابل خروجی‌های مورد انتظار از آن در مرحله‌ی آموزش



شکل ۴-۱۵: نتایج تخمین زده شده توسط شبکه در مقابل خروجی‌های مورد انتظار از آن در مرحله‌ی ارزیابی



شکل ۴-۱۶: نمودار هیستوگرام خطا برای داده‌های فضای آموزشی شبکه‌ی تخمین‌گر چگالی

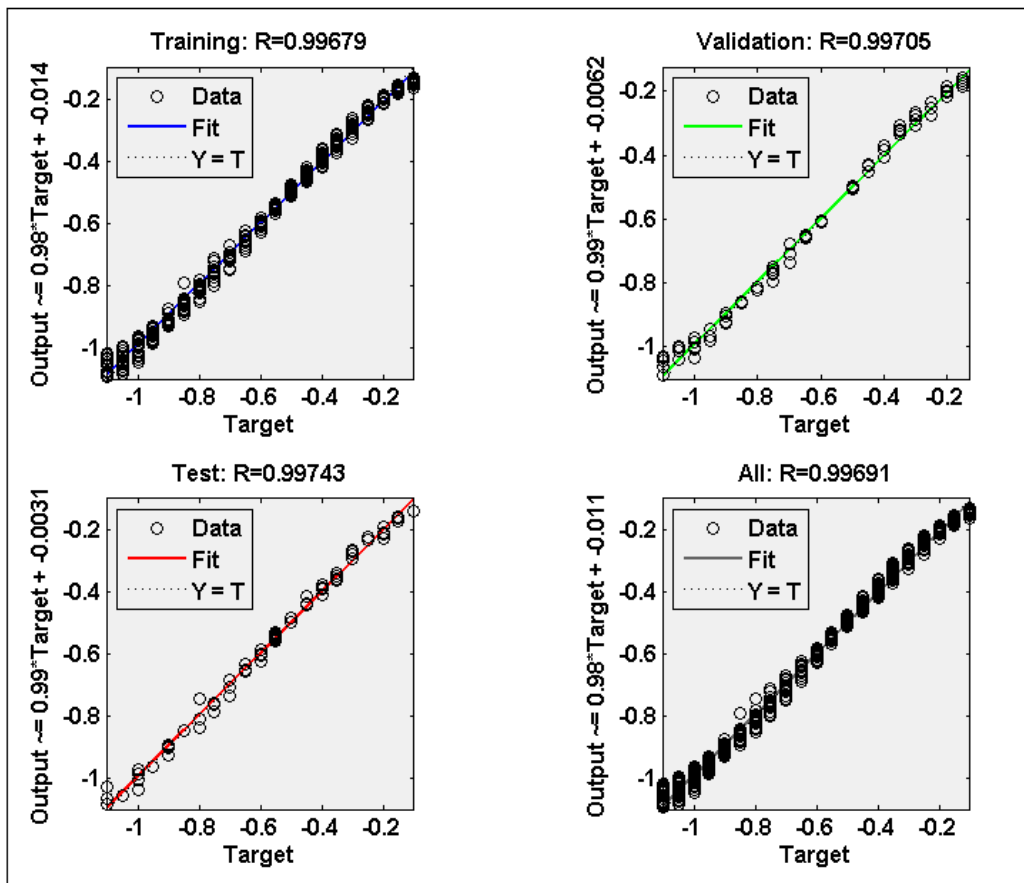
جدول ۴-۹: خروجی‌های به دست آمده از شبکه در مقابل خروجی‌های مورد انتظار از آن برای تخمین چگالی

شماره مدل (مدل کره)	پارامترهای مربوط به ۱۰ مدل مصنوعی در مرحله‌ی ارزیابی شبکه			خروجی شبکه (پارامتر مورد بررسی: چگالی)
	عمق (کیلومتر)	شعاع (کیلومتر)	چگالی (گرم بر سانتی‌متر مکعب)	چگالی تخمین زده شده (گرم بر سانتی‌متر مکعب)
۱	۱/۶	۱	-۰/۳۵	-۰/۳۴۹۹
۲	۱/۹	۱	-۰/۷	-۰/۷۳۵۱
۳	۲/۵	۱/۵	-۰/۶	-۰/۵۸۵۵
۴	۳/۱	۲	-۱	-۱/۰۳۷۹
۵	۳/۴	۲	-۰/۳۵	-۰/۳۶۳۲
۶	۴	۲	-۰/۲	-۰/۱۸۹۹
۷	۴/۳	۲	-۰/۳	-۰/۲۶۹۵
۸	۴/۶	۲/۵	-۰/۷	-۰/۷۰۷۸
۹	۴/۶	۳	-۰/۶	-۰/۶۰۰۱
۱۰	۵/۲	۳	-۰/۷۵	-۰/۷۶۲۵


این با تکیه بر این نتایج برای مدل‌های مصنوعی، شبکه‌ی عصبی مورد نظر برای تخمین چگالی داده‌های واقعی به کار برده شد و در نتیجه‌ی آن، عدد تخمین زده شده توسط این شبکه برای چگالی نمک هامبل (۰/۵-) گرم بر سانتی‌متر مکعب می‌باشد.

برای تحقیق درستی نتایج به روش شبکه‌های عصبی مصنوعی، ابتدا مدل‌سازی مستقیم این پارامترها در محیط نرم‌افزار مدل‌ویژن انجام شد و پس از آن بی‌هنجاری گرانی به دست آمده از این مدل مصنوعی با بی‌هنجاری گرانی داده‌های هامبل مقایسه شد. همان‌گونه که در شکل (۴-۱۸) نشان

داده شده است، توافق نسبتاً خوبی بین این دو بی‌هنجاری به دست آمد. این نتیجه دلیل روشنی بر کارآمد بودن روش شبکه‌های عصبی مصنوعی در مدل‌سازی معکوس داده‌های گرانی‌سنجی می‌باشد.



شکل ۴-۱۷: رگرسیون خطی بین خروجی‌های مورد انتظار از شبکه و خروجی‌های شبکه برای تخمین چگالی برای هر سه مرحله آموزش، ارزیابی و اعتبارسنجی

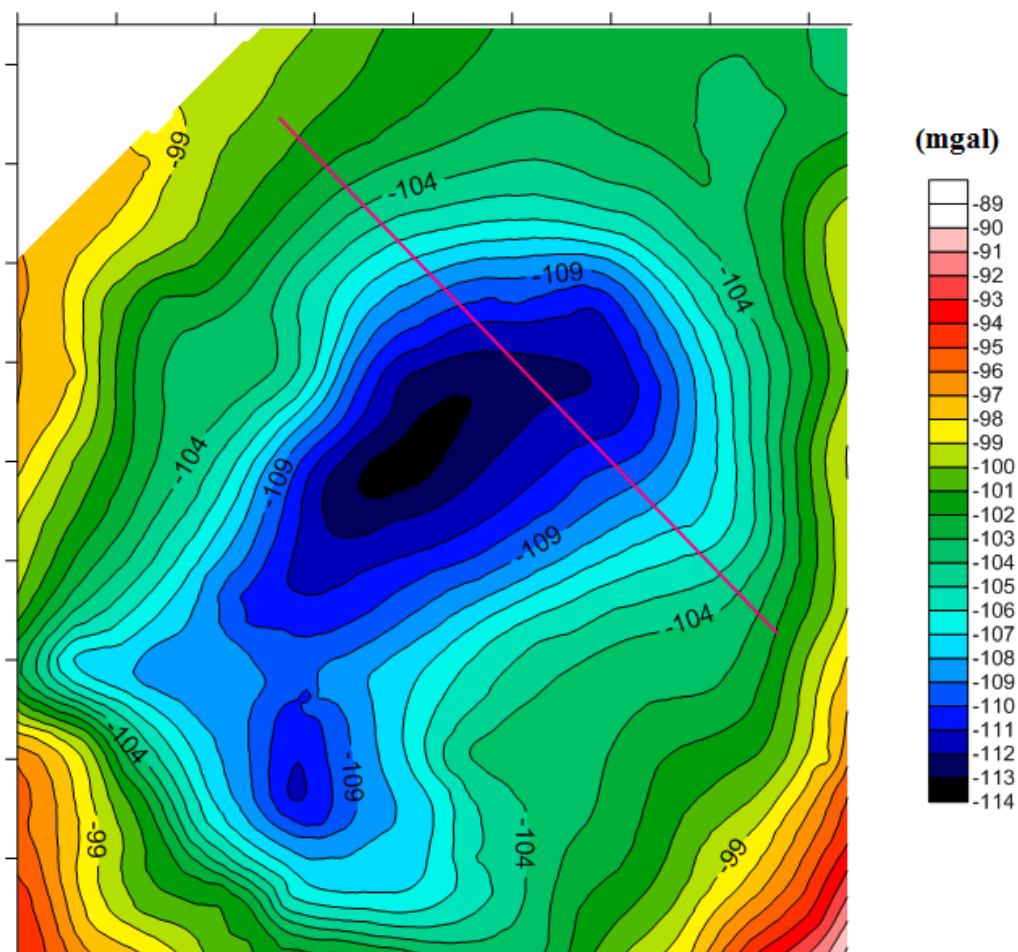


شکل ۴-۱۸: بی‌هنجاری گرانی هامبل در برابر بی‌هنجاری به دست آمده از مدل‌سازی معکوس توسط شبکه عصبی

۲-۴ نمک هرمز

تشکیلات تبخیری هرمز در جنوب ایران یکی از قدیمی‌ترین تشکیلات ایران محسوب می‌شود که در پهنه‌ی زمین‌شناسی ساختاری زاگرس به شکل گنبد‌های نمکی نمود پیدا کرده است. سری هرمز در زیر سطح زمین و همچنین رخنمون آن در چین‌خوردگیها و نیز در راستای برخی شکستگی‌های

پهنه زمین‌شناسی ساختاری زاگرس و پلاتفرم^۱ عربی همواره مورد توجه و تحقیق بوده است. سری هرمز با ضخامت حدود هزار متر [Kent, 1970] برگرفته از نام جزیره‌ی هرمز که خود یک نمونه از گنبد‌های نمکی رخنمون یافته از این سری تبخیری در خلیج فارس است [Pilgrim 1908; Blanford 1972] بوده و عمدتاً از نهشته‌های تبخیری تشکیل یافته است. داده‌های گرانی‌سنجی یکی از گنبد‌های نمکی هرمز که توسط مدیریت اکتشاف شرکت ملی نفت ایران برداشت شد و بی‌هنجاری بوگه‌ی کامل آن برای تفسیر در اختیار قرار گرفت. همانطور که در شکل (۴-۱۹) نمایش داده شده است، پروفیلی گذرنده از مرکز این بی‌هنجاری ترسیم شده و پس از حذف بی‌هنجاری ناحیه‌ای، بی‌هنجاری باقی‌مانده برای تفسیر مورد استفاده قرار گرفت.




شکل ۴-۱۹: بی‌هنجاری گرانی بوگه‌ی کامل مربوط به سازند نمک هرمز با مقیاس ۱:۱۰۰۰۰۰ (طول پروفیل ۱۶ کیلومتر)

^۱ Platform

۴-۲-۱ تعیین شکل نمک هرمز

طبق روال تعریف شده در این پایان‌نامه، در مرحله‌ی اول شکل نمک بررسی شده است. مجموعه‌ی آموزشی در نظر گرفته شده برای این کار شامل ۱۲۲ مدل که از این تعداد ۶۱ مدل کروی و ۶۱ مدل دیگر گنبدی شکل می‌باشند. ۸۶ مدل از این مجموعه به صورت تصادفی انتخاب و در اختیار مرحله‌ی آموزش شبکه قرار گرفت. ۱۸ مدل برای اعتبارسنجی و ۱۸ مدل نیز برای ارزیابی شبکه به کار برده شدند. حدود پارامترهای این مدل‌های مصنوعی در جدول (۴-۱۰) و (۴-۱۱) آمده است. پس از انتخاب یک پروفیل گذرنده از مرکز هر مدل و استخراج مشخصه‌های مورد نیاز از آن برای آموزش شبکه‌ی تخمین‌گر شکل به کار برده شد. پس از بررسی حالات مختلف برای تعداد لایه‌ها و نرون‌ها و به دست آوردن خطای شبکه در هر حالت به ازای نرخ آموزشی متفاوت در هر حالت، بهترین نمودار کارایی شبکه‌ی سه لایه‌ی (۲ ۲ ۲) با نرخ آموزشی (۰/۱) به دست آمد.



شکل ۴-۲۰: نمودار تابع کارایی شبکه‌ی تخمین‌گر شکل

جدول ۴-۱۰: حدود پارامترهای مدل‌های مصنوعی گنبدی شکل برای آموزش شبکه‌ی تخمین‌گر شکل


مدل گنبدی شکل	کمترین مقدار	بیشترین مقدار	مقدار تغییرات بین هر دو مدل متوالی
عمق نیم‌کره‌ی بالای آن (کیلومتر)	۱/۷	۳/۷	۰/۳
عمق استوانه‌ی طویل (کیلومتر)	۲/۷	۵/۷	۰/۳
شعاع (کیلومتر)	۱	۲.۵	۰/۵
چگالی (گرم بر سانتی‌متر مکعب)	-۰/۱	-۱	-۰/۱

جدول ۴-۱۱: حدود پارامترهای مدل‌های مصنوعی کروی شکل برای آموزش شبکه‌ی تخمین‌گر شکل

مدل کروی شکل	کمترین مقدار	بیشترین مقدار	مقدار تغییرات بین هر دو مدل متوالی
عمق (کیلومتر)	۱/۷	۵	۰/۳
شعاع (کیلومتر)	۱	۲	۰/۵
چگالی (گرم بر سانتی‌متر مکعب)	-۰/۱	-۱	-۰/۱

چنانچه در شکل (۴-۲۰) مشاهده می‌شود، این الگوریتم در تکرار هفتم متوقف شده است. مقدار خطا در این تکرار به مقدار 0.0081683 رسیده است که مقدار بسیار رضایت‌بخشی است. نمودار هیستوگرام خطا برای داده‌های آموزشی در شکل (۴-۲۱) نمایش داده شده است. در جدول (۴-۱۲) تعداد ۹ مدل از کل مدهای مصنوعی مرحله‌ی ارزیابی انتخاب و نتایج حاصل از ارزیابی شبکه‌ی تخمین‌گر شکل برای این ۹ مدل به نمایش درآمده است. همانطور که قابل ملاحظه است شبکه قدرت تخمین بسیار خوبی در تشخیص شکل داشته است. پس از حصول این نتایج و اطمینان از کارایی بالای شبکه، از آن در تشخیص شکل گنبد نمکی هرگز استفاده شده است. نتیجه برای این

نمک $\begin{pmatrix} 0.999 \\ 0.9762 \end{pmatrix}$ می باشد که نماد مدل گنبدی شکل طویل است و دلالت بر ریشه دار بودن این گنبد نمکی می باشد.



شکل ۴-۲۱: نمودار هیستوگرام خطا برای داده های فضای آموزشی شبکه ی تخمین گر شکل

جدول ۴-۱۲: خروجی‌های شبکه در مقابل مقادیر مورد انتظار از آن برای تعیین شکل در مرحله‌ی ارزیابی


پارامترهای مربوط به ۱۰ مدل مصنوعی در مرحله‌ی ارزیابی شبکه					خروجی شبکه		
نوع مدل	عمق نیم‌کره (کیلومتر)	عمق استوانه (کیلومتر)	شعاع (کیلومتر)	چگالی (گرم بر سانتی‌متر مکعب)	(a1)	(a2)	شکل تشخیص داده شده
گنبد	۲/۴	۳/۹	۱/۵	-۰/۱۳	۰/۹۹۹۱	۰/۲۵۸	گنبد
کره	۲/۴	۳/۹	۱/۵	-۰/۶	۰/۰۰۱۲	۰/۹۹۹	کره
گنبد	۲/۷	۴/۲	۱/۵	-۰/۱۴	۰/۹۹۷۶	۰/۰۰۱۷	گنبد
گنبد	۲/۷	۴/۲	۱/۵	-۰/۳۲	۰/۹۹۹	۰/۰۰۱۰	گنبد
کره	۳/۱	۵/۱	۲	-۰/۱۵	۰/۰۰۲۴	۰/۹۹۹	کره
گنبد	۳/۱	۵/۱	۲	-۰/۳۵	۰/۹۹۹	۰/۳۳۴	گنبد
کره	۳/۴	۵/۴	۲	-۰/۶۵	۰/۰۰۱۴	۰/۹۹۹	کره
گنبد	۳/۷	۵/۷	۲	-۰/۳۵	۰/۹۹۹	-۰/۲۹	گنبد
کره	۳/۷	۵/۷	۲	-۰/۷	۰/۰۰۲۲	۰/۹۹۹	کره

۴-۲-۲ تخمین عمق نمک هرمز


برای این مرحله از ۹۹ مدل مصنوعی گنبدی شکل استفاده شد که از این مجموعه، ۶۹ مدل برای آموزش، ۱۵ مدل برای اعتبارسنجی و ۱۵ مدل باقی‌مانده برای ارزیابی شبکه عصبی تخمین‌گر عمق استفاده شده است. حدود پارامترهای این مجموعه در جدول (۴-۱۳) آورده شده است. پس از چندین تلاش برای به دست آوردن یک شبکه‌ی مناسب برای تخمین عمق، در نهایت شبکه‌ی سه لایه‌ی (۲ ۳ ۴) با تابع کارایی نشان داده شده در شکل (۴-۲۲) انتخاب شد. همان‌طور که قابل ملاحظه است در چهل و هفتمین تکرار و خطای 0.0108 بهترین حالت برای اوزان و بایاس شبکه تشخیص داده شده و الگوریتم متوقف شده است.

جدول ۴-۱۳: حدود پارامترهای مدل‌های مصنوعی برای آموزش شبکه‌ی تخمین‌گر عمق

مدل گنبدی شکل	کمترین مقدار	بیشترین مقدار	مقدار تغییرات بین هر دو مدل متوالی
عمق نیم‌کره (کیلومتر)	۰/۹	۳/۸	۰/۲
عمق استوانه (کیلومتر)	۱/۴	۵/۸	۰/۲
شعاع (کیلومتر)	۰/۵	۲.۵	۰/۵
چگالی (گرم بر سانتی‌متر مکعب)	-۰/۱	-۱	-۰/۱




شکل ۴-۲۲: نمودار تابع کارایی شبکه‌ی تخمین‌گر عمق



شکل ۴-۲۳: خروجی‌های شبکه در مقابل خروجی‌های مورد انتظار از شبکه‌ی تخمین‌گر عمق در مرحله‌ی آموزش

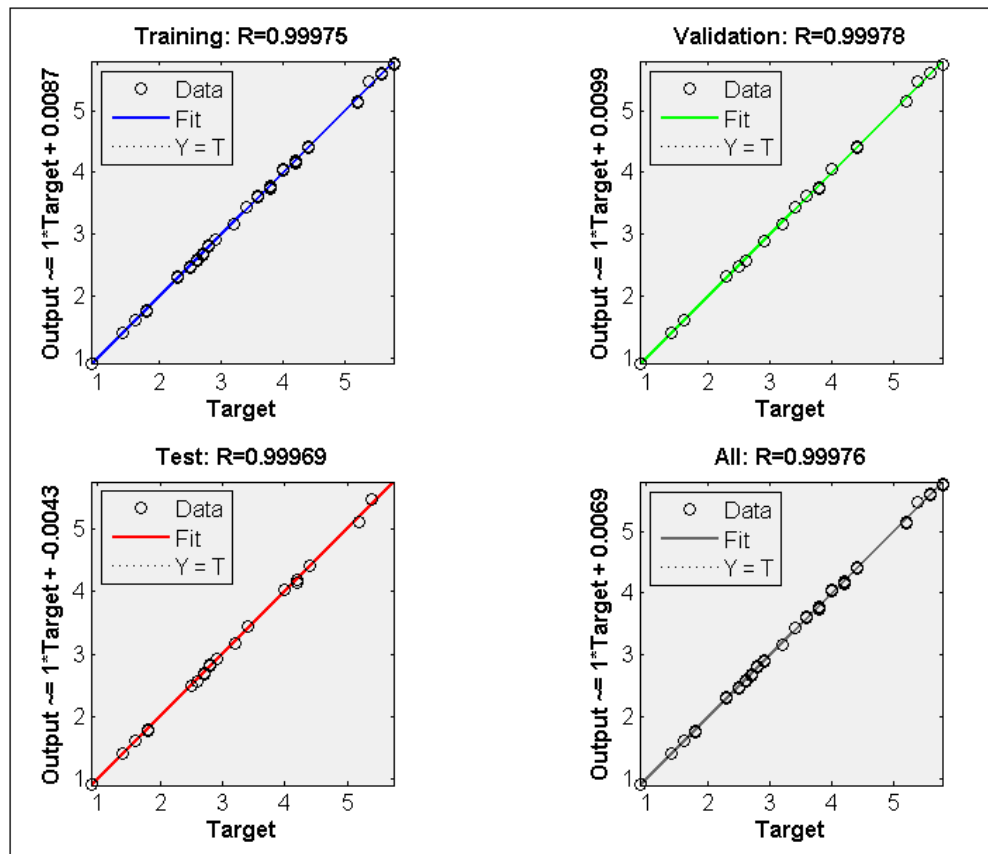
شکل (۴-۲۳) تشخیص شبکه‌ی تخمین‌گر عمق را در مرحله‌ی آموزش نشان می‌دهد. همانطور که قابل ملاحظه است شبکه به خوبی قادر به تخمین عمق مدل‌های آموزشی بوده است. نمودار هیستوگرام خطا برای این شبکه در مرحله‌ی آموزش در شکل (۴-۲۴) نمایش داده شده است. با تکیه بر نتایج بسیار خوبی که از مرحله‌ی آموزش شبکه به دست آمد، از این شبکه برای تخمین عمق ۱۵ مدل مصنوعی استفاده شد. نتایج حاصل از این ارزیابی برای نه مدل از این مجموعه در جدول (۴-۱۴) و رگرسیون خطا برای هر سه مرحله‌ی آموزش، اعتبارسنجی و ارزیابی در شکل (۴-۲۵) آورده شده است. همان‌طور که ملاحظه می‌شود نتایج بسیار رضایت بخش می‌باشند. در نهایت این شبکه برای داده‌های واقعی نمک هرگز مقدار $3/8$ و $5/8$ کیلومتر را به ترتیب برای عمق نیم‌کره و عمق استوانه‌ی تشکیل دهنده‌ی مدل گنبدی شکل، تخمین زد.



شکل ۴-۲۴: نمودار هیستوگرام خطا در مرحله‌ی آموزش شبکه‌ی تخمین‌گر عمق

جدول ۴-۱۴: خروجی‌های شبکه‌ی تخمین‌گر عمق در مقابل خروجی‌های موردانتظار از آن

شماره مدل (گنبدی شکل)	پارامترهای ۹ مدل مصنوعی در مرحله‌ی ارزیابی شبکه				خروجی شبکه (پارامتر مورد بررسی: عمق)	
	عمق نیم‌کره (کیلومتر)	عمق استوانه (کیلومتر)	شعاع (کیلومتر)	چگالی (گرم بر سانتی‌متر مکعب)	عمق تخمین‌زده شده برای نیم‌کره (کیلومتر)	عمق تخمین‌زده شده برای استوانه (کیلومتر)
۱	۰/۹	۱/۴	۰/۵	-۰/۱۱	۰/۹۰۹۲	۱/۴۰۳
۲	۱/۶	۲/۶	۱	-۰/۱۳	۱/۵۸۱۹	۲/۶۱۶۲
۳	۱/۸	۲/۸	۱	-۰/۴۵	۱/۸۱۰۳	۲/۷۹۲۰
۴	۱/۸	۲/۸	۱	-۰/۶۹	۱/۸۰۹۰	۲/۷۸۹
۵	۲/۳	۳/۸	۱/۵	-۰/۱۵	۲/۳۰۴۰	۳/۷۷۴
۶	۲/۵	۴	۱/۵	-۰/۶۵	۲/۴۹۸۲	۴/۰۴۰۱
۷	۲/۹	۴/۴	۱/۵	-۰/۱۶	۲/۸۸۷۴	۴/۴۰۴۳
۸	۲/۹	۴/۴	۱/۵	-۰/۷۱	۲/۹۰۶۲	۴/۴۷۹
۹	۳/۸	۵/۸	۲	-۰/۷	۳/۷۳۰۸	۵/۷۴۹




شکل ۴-۲۵: نمودار رگرسیون خطی بین خروجی‌های شبکه‌ی تخمین‌گر عمق و خروجی‌های مورد انتظار از آن


۴-۲-۳ تخمین شعاع نمک هرمز

همانند مرحله‌ی تخمین عمق، برای این مرحله نیز از ۹۹ مدل مصنوعی گنبدی شکل استفاده شد که از این مجموعه، ۶۹ مدل برای آموزش، ۱۵ مدل برای اعتبارسنجی و ۱۵ مدل باقی‌مانده برای ارزیابی شبکه عصبی تخمین‌گر شعاع استفاده شده است. حدود پارامترهای این مجموعه نیز همانند آنچه که در جدول (۴-۱۳) آورده شده است، می‌باشد.


شبکه‌ی سه لایه‌ی (۱ ۲ ۵) بهترین شبکه‌ی تخمین‌گر در این حالت تشخیص داده شد. نمودار تابع کارایی این شبکه در شکل (۴-۲۶) به نمایش درآمده است. در تکرار سی و ششم و در خطای



شکل ۴-۲۶: نمودار تابع کارایی شبکه‌ی تخمین‌گر شعاع



شکل ۴-۲۷: خروجی‌های شبکه در مقابل خروجی‌های مورد انتظار از شبکه‌ی تخمین‌گر شعاع در مرحله‌ی آموزش

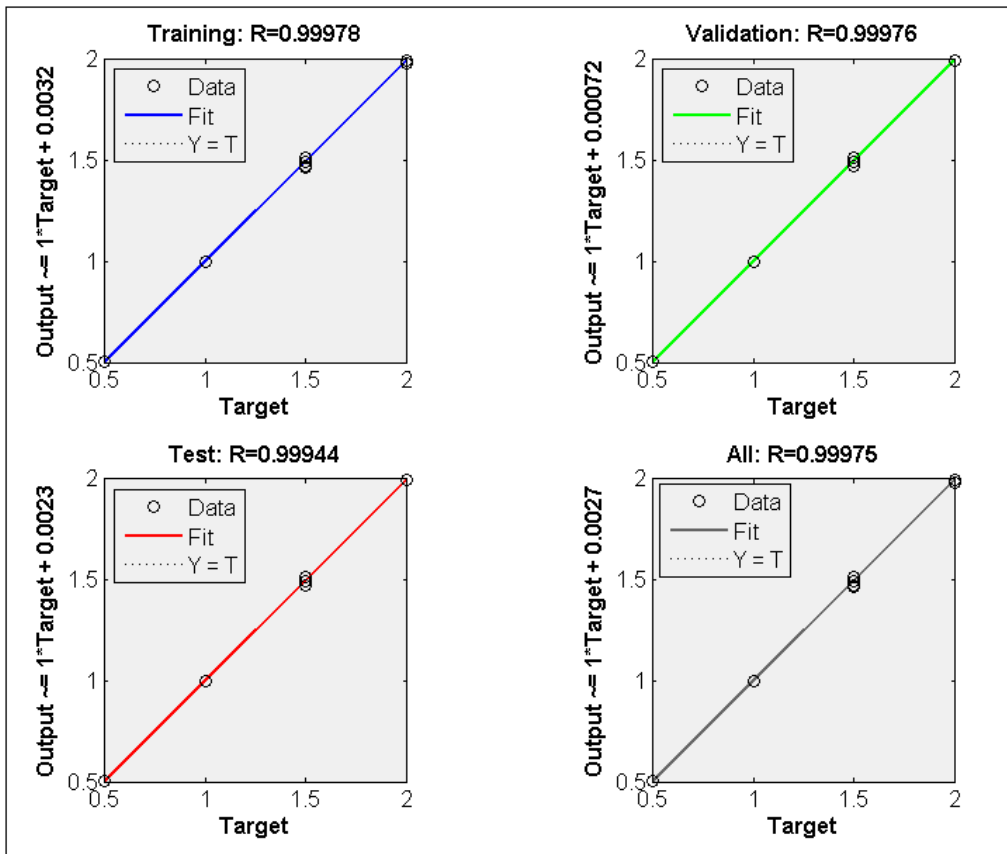


شکل ۴-۲۸: نمودار هیستوگرام خطا در مرحله‌ی آموزش شبکه‌ی تخمین‌گر شعاع

۰/۰۰۰۱ بهترین شبکه برای تخمین شعاع به دست آمده است. خروجی‌های تخمین زده شده در مرحله‌ی آموزش در مقابل خروجی‌های مورد انتظار از آن در شکل (۴-۲۷) و نمودار هیستوگرام خطا در این مرحله در شکل (۴-۲۸) نشان داده شده‌اند. این نتایج نشان‌دهنده‌ی تشخیص خوب شبکه در این مساله می‌باشد. شکل (۴-۲۹) نمودار رگرسیون بین خروجی‌های شبکه و خروجی‌های مورد انتظار از آن در مساله‌ی تخمین عمق را نشان می‌دهد. رگرسیون کل (۰/۹۹۹) مقدار رضایت بخشی است. خروجی‌های این شبکه برای این نه مدل از کل پانزده مدل مصنوعی در جدول (۴-۱۵) آورده شده است. واضح است که تخمین شعاع در عمق‌های کم بهتر از تخمین شعاع در عمق‌های زیاد است و در مجموع نتایج بسیار خوبی هستند. تخمین این شبکه برای شعاع داده‌های گرانی‌سنجی نمک هرمز ۲ کیلومتر می‌باشد.

جدول ۴-۱۵: خروجی‌های شبکه‌ی تخمین‌گر عمق در مقابل خروجی‌های موردانتظار از آن


پارامترهای ۹ مدل مصنوعی در مرحله‌ی ارزیابی شبکه					خروجی شبکه (پارامتر مورد بررسی: شعاع)
شماره مدل (گنبد)	عمق نیم‌کره (کیلومتر)	عمق استوانه (کیلومتر)	شعاع (کیلومتر)	چگالی (گرم بر سانتی‌متر مکعب)	شعاع تخمین زده شده برای نیم‌کره (کیلومتر)
۱	۰/۹	۱/۴	۰/۵	-۰/۱۱	۰/۵۰۰۵
۲	۱/۶	۲/۶	۱	-۰/۱۳	۱/۰۰۰۳
۳	۱/۸	۲/۸	۱	-۰/۲۱	۱/۰۰۰۶
۴	۱/۸	۲/۸	۱	-۰/۷۷	۱/۰۰۰۶
۵	۲/۳	۳/۸	۱/۵	-۰/۱۵	۱/۴۹۱۸
۶	۲/۵	۴	۱/۵	-۰/۴۵	۱/۵۱۴۸
۷	۲/۷	۴/۲	۱/۵	-۰/۶	۱/۴۷۰۵
۸	۲/۹	۴/۴	۱/۵	-۰/۴۹	۱/۵۱۸۰
۹	۳/۲	۵/۲	۲	-۰/۴۱	۱/۹۹۸۹



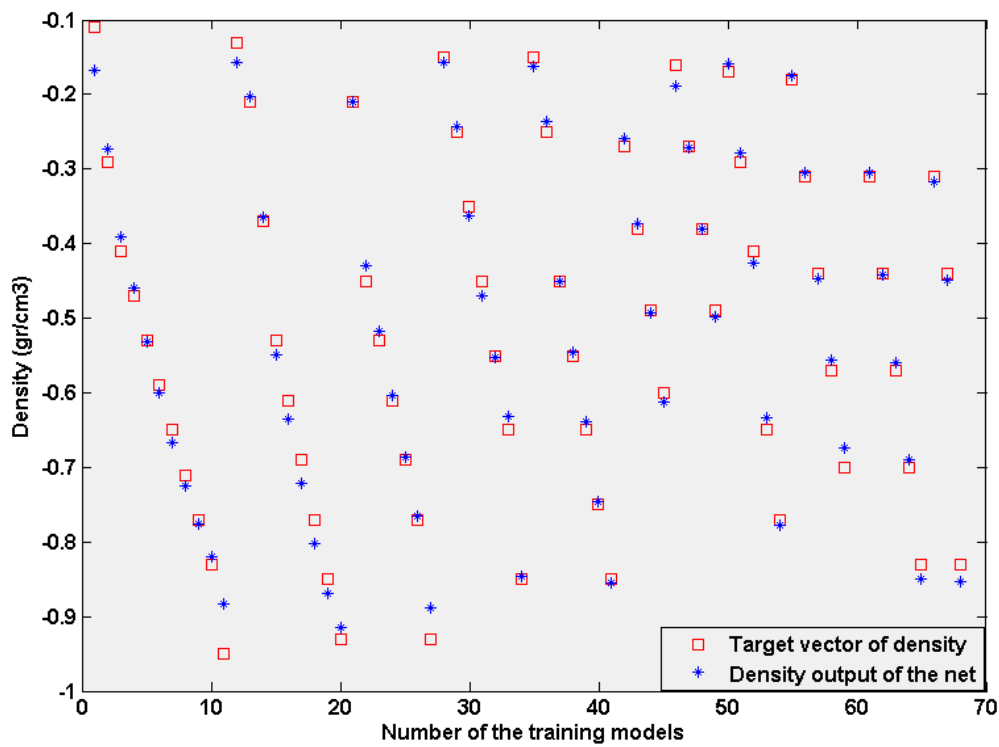
شکل ۴-۲۹: نمودار رگرسیون خطی بین خروجی‌های شبکه‌ی تخمین‌گر عمق و خروجی‌های مورد انتظار از آن

۴-۲-۴ تخمین چگالی نمک هرمز

مجموعه‌ی آموزشی این مرحله نیز مانند دو مرحله‌ی قبل می‌باشد. به کمک ۹۹ مدل مصنوعی در فضای داده‌های مشاهده‌ای شبکه‌ی سه لایه‌ی (۶ ۲ ۱) با نرخ آموزشی ۰.۱ بهترین مدل شناخته شد. نمودار تابع کارایی این شبکه در شکل (۴-۳۰) نشان داده شده است. از تکرار دوازدهم به بعد منحنی خطای داده‌های اعتبارسنجی افزایش یا کاهشی نداشته و در این نقطه بهترین پارامترهای شبکه که شامل وزن‌ها و بایاس‌ها می‌باشد به دست آمده است. شکل (۴-۳۱) خروجی‌های شبکه در مقابل خروجی‌های مورد انتظار از آن را در مرحله‌ی آموزش و شکل (۴-۳۲) نمودار هیستوگرام خطا در آن را در این مرحله نشان می‌دهد.




شکل ۴-۳۰: نمودار تابع کارایی شبکه‌ی تخمین‌گر چگالی



شکل ۴-۳۱: خروجی‌های شبکه در مقابل خروجی‌های مورد انتظار از شبکه‌ی تخمین‌گر چگالی در مرحله‌ی

آموزش

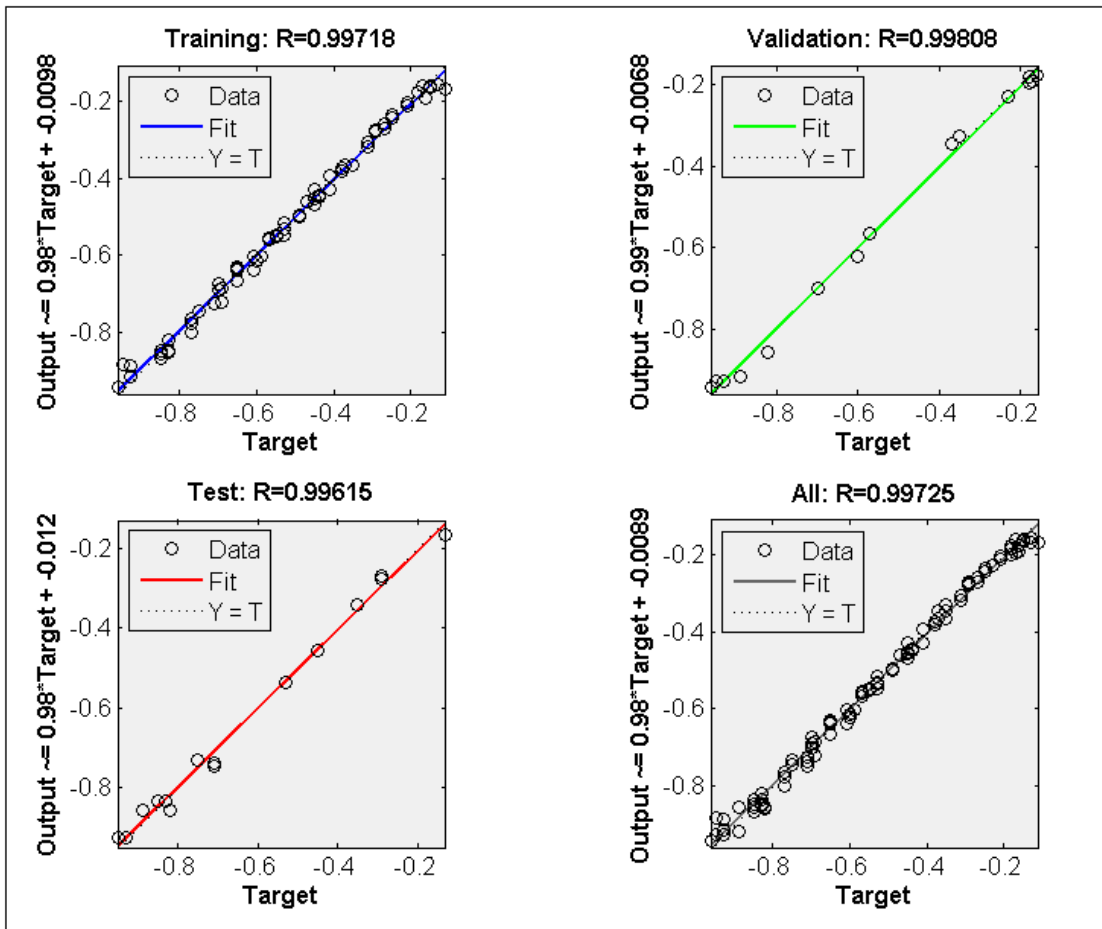


شکل ۴-۳۲: نمودار هیستوگرام خطا در مرحله‌ی آموزش شبکه‌ی تخمین‌گر چگالی


جدول (۴-۱۶) خروجی‌های حاصل از شبکه برای نه مدل از کل ۱۵ مدل مصنوعی را در مقابل خروجی‌های مورد انتظار برای پارامتر چگالی نشان می‌دهد. شکل (۴-۳۳) رگرسیون بین مقادیر مورد انتظار برای چگالی را در مقابل مقادیر به دست آمده از شبکه برای این پارامتر، در هر سه مرحله‌ی آموزش، اعتبارسنجی و خطا نشان می‌دهد. رگرسیون کل داده‌ها (۰/۹۹۷) می‌باشد که مقدار بسیار مناسبی می‌باشد. بنابراین شبکه در تخمین چگالی داده‌های واقعی به کار برده شده است. این شبکه چگالی را برای نمک هرمز (۰/۵۸-) تخمین زده است. در شکل (۴-۳۴) نیز مدل‌سازی پیشرو پارامترهای به دست آمده از روش شبکه عصبی را در مقایسه با بی‌هنجاری گرانی نمک هرمز نشان می‌دهد.

جدول ۴-۱۶: خروجی‌های شبکه‌ی تخمین‌گر عمق در مقابل خروجی‌های مورد انتظار از آن

پارامترهای ۹ مدل مصنوعی در مرحله‌ی ارزیابی شبکه					خروجی شبکه (پارامتر مورد بررسی: چگالی)
شماره مدل (گنبد)	عمق نیم‌کره (کیلومتر)	عمق استوانه (کیلومتر)	شعاع (کیلومتر)	چگالی (گرم بر سانتی‌متر مکعب)	چگالی تخمین زده شده برای نیم‌کره (کیلومتر)
۱	۰/۹	۱/۴	۰/۵	۰/۸۹	-۰/۸۵۵۴
۲	۱/۶	۲/۶	۱	-۰/۲۹	-۰/۲۷۵۴
۳	۱/۸	۲/۸	۱	-۰/۱۳	-۰/۱۶۶۶
۴	۱/۸	۲/۸	۱	-۰/۸۵	-۰/۸۳۴۷
۵	۲/۳	۳/۸	۱/۵	-۰/۷۵	-۰/۷۳۱۳
۶	۲/۵	۴	۱/۵	-۰/۹۵	-۰/۹۲۵۹
۷	۲/۷	۴/۲	۱/۵	-۰/۷۱	-۰/۸۵۵۳
۸	۳/۲	۵/۲	۲	-۰/۵۳	-۰/۵۳۴۳
۹	۳/۴	۵/۴	۲	-۰/۸۳	-۰/۸۳۵۵



شکل ۴-۳: نمودار رگرسیون خطی بین خروجی‌های شبکه‌ی تخمین‌گر چگالی و خروجی‌های مورد انتظار از آن



شکل ۴-۳۴: بی‌هنجاری گرانی نمک هرمز در برابر بی‌هنجاری به دست آمده از مدل‌سازی معکوس توسط شبکه

عصبی

فصل پنجم:

نتیجہ گیری و پیشہادات

تخمین عمق و شکل ساختارهای زیرسطحی مهم‌ترین بخش تفسیر کمی بی‌هنجاری‌های گرانی است که بر اساس روش‌های مختلفی انجام‌پذیر است. در این تحقیق از شبکه‌ی عصبی مصنوعی پرسپترون چند لایه جهت تخمین شکل، عمق، شعاع و چگالی استفاده شد.

- بررسی‌های انجام شده روی شکل نمودارهای اثر گرانی آنومالی‌های اجسام ساده مانند کره، استوانه‌ی قائم و اجسام پیچیده‌تر مانند استوانه‌ی قائم به همراه یک عرقچین کروی نشان می‌دهد که تفاوت‌هایی قابل ملاحظه روی منحنی‌ها وجود دارد. با استفاده از شکل این نمودارها می‌توان اشکال اجسام آنومال را از هم تفکیک کرد.
- بر مبنای ویژگی‌های نمودارهای اثر گرانی دو بعدی حاصل از اجسام آنومال، شبکه عصبی مصنوعی طراحی و آزمایش شد. نتایج این بررسی نشان می‌دهد که شبکه عصبی توانمندی شناسایی شکل اجسام را تا حد بالایی دارد.
- همچنین بر اساس شکل مورد نظر تخمین زده شده، عمق، شعاع و چگالی اجسام آنومال با دقت بالایی تخمین زده شد. البته تخمین مقدار شعاع به میزان دقت تخمین شکل و عمق بستگی دارد. همچنین به روش انجام شده در این تحقیق دقت تخمین پارامتر چگالی به دقت تخمین شکل، عمق و شعاع بستگی دارد.
- بررسی‌های انجام شده روی مدل‌های مختلف نشان می‌دهد که بازه‌ی تغییرات پارامترهای مدل‌های ارائه شده به شبکه نباید خیلی کوچک باشند، زیرا در این حالت بی‌هنجاری‌ها و در نتیجه مشخصه‌های مربوط به آن‌ها شباهت زیادی با هم پیدا خواهند کرد و در نتیجه جواب مناسب ارائه نمی‌دهد.

پیشنهادات:

- بر اساس روش‌های انجام شده در این کار به نظر می‌رسد طراحی شبکه اساسی‌ترین مرحله کار به این روش باشد، بنابراین پیشنهاد می‌شود که با تهیه و ساخت مدل‌های بیشتر و متنوع‌تر این موضوع بررسی شود.
- با توجه به گسترش افقی آنومالی‌ها و تغییر شکل اثر آنومالی گرانی با تغییر ساختارهای سه بعدی، این روش به صورت سه بعدی مورد بررسی قرار گیرد.
- طراحی شبکه عصبی که بتواند همزمان پارامترهای سه‌گانه‌ی عمق، شعاع و چگالی را

تخمین بزند.

- با توجه به این که تخمین عمق و تفکیک ساختارهایی که روی هم قرار گرفته باشند، به روش گرانی مشکل یا تقریبا غیر ممکن است، پیشنهاد می شود روی ویژگی های نمودارهای حاصل از این ساختارها بررسی صورت گیرد تا بدین روش بتوان تخمین مناسبی داشت.

مراج

منه‌اج، محمد باقر، ۱۳۸۹. مبانی شبکه‌های عصبی، انتشارات دانشگاه صنعتی امیرکبیر، چاپ هفتم، تهران.

References

- Abdelrahman, E.M. El-Araby, T.M. 1993. A least-square minimization approach to depth determination from moving average residual gravity anomalies. *Geophysics*, v. 59, p. 1779-1784.
- Abdelrahman, E.M., El-Araby, T.M. 1996. Shape and depth solutions from moving average residual gravity anomalies. *Journal of Applied Geophysics*, v. 36, p. 89-95.
- Abdelrahman, E.M., El-Araby, H.M., El-Araby, T.M., Abo-Ezz, E.R., 2001a. Three least-squares minimization approaches to depth, shape and amplitude coefficient determination from gravity data. *Geophysics*, v. 66, p. 1105-1109.
- Aghajani, H., Moradzadeh, A., Zeng, H., 2009. Estimation of Depth to Anomalous body from Normalized Full Gradient of Gravity Anomaly. *Journal of Earth Science*, v. 10, p. 21-24.
- Albora, A.M., Ucan, O. N., Ozmen, A., Ozkan, T. 2001. Separation of Bouguer anomaly map using cellular neural network. *Journal of Applied Geophysics*, v. 46, p. 129-142.
- Al-Garni, M.A., 2013. Inversion of residual gravity anomalies using neural network. *Arabian Journal of Geosciences*, p. 1-8.
- Aydogan, D., 2007. Processing the Bouguer anomaly map of Biga and the surrounding area by the cellular neural network. application to the southwestern Marmara region: *Earth, Planets, and Space*, v. 59, p. 201-208.
- Bishop, M.CH., 1997. *Neural networks for pattern recognition*. Oxford Clarendon press, 2nd edition, P. 482.
- Blakely R. J., 1996. Potential theory in gravity and magnetic application. Cambridge University Press, 2nd edition, p. 464.
- Blandford W.T., 1972. Notes on the geological formations seen along the coast of Balochistan and Persia from Karachi to the head of the Persian Gulf and some of the gulf islands.
- Elawadi, E. and Salem, A. and Ushijima, K., 2001. Detection of cavities and tunnels from gravity data using a neural network. *Exploration Geophysics*, v. 32, p. 204-208.
- Gret, A.A. and Klingele, E.E., 1998. Application of Artificial neural networks for Gravity Interpretation in Two Dimension. *Institute of Geodesy and photogrammetry Swiss Federal Institute*. P. 87.
- Hagan, M.T., Menhaj. M., 1994. Training feed-forward networks with the Marquardt

algorithm. *IEEE Transactions on Neural Networks*, v. 5, No. 6, p. 989–993.

Hagan, M.T., Demuth H.B., M.H. Beale, 1996. *Neural Network Design*, Boston, MA: PWS Publishing.

Hajian, A.R., Ardestani, E.V., Lucas, C., Saghaiannejad, S.M., 2009 .Detection of subsurface Qanats by Artificial Neural Network via microgravity data. *Journal of the Earth & Space Physics*. v. 35, p. 9-15.

Hangman, M.T., Demuth, H.B., and Beale, M.H., 1996. *Neural Network Design*, PWS Publishing, Boston, MA.

Haykin, S., 1994. *Neural Networks a Comprehensive Foundation*, McMaster University, Canada.

Hopfield, J., 1984. Neurons with graded response have collective computational properties, *Proceeding of the national academy of science*, vol. 81.

Kearey P., Brooks M. and Hill I., 2003. *An introduction to geophysical exploration*, Blackwell, 3rd Edition, 272.

Kent, P.E., 1970. The salt plugs of the Persian Gulf region. *Transactions of the Leicester Literary and Philosophical Society*. v. 64, p. 56-88.

Kohonen, T., 1972. Correlation matrix memories. *IEEE Transactions on Computers*. v. 21, p. 353-359.

Matlab Software, 2011. manual help.

McCulloch, W.S., Pitts, W., 1943. A logical calculus of idea's immanent in nervous activity. *Bulletin of Mathematical Biophysics* 5, p. 115-133. Reprinted in Anderson, J.A. and Rosenfield, E., 1988. *Neurocomputing: Foundations of Research*, Cambridge MIT press.

Minsky, M., Papert, S., 1969. *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Cambridg, MA.

Mohan, N.L., Anandababu, L., Seshagiri, R., 1986. Gravity interpretation using the Melin transform. *Geophysics*, v. 51, P. 114-122.

Nelles, O., 2001. *Nonlinear system identification: from classical approaches to neural networks and fuzzy models*. Springer Press.

Nettelton, L.L., 1976. *Gravity and Magnetic in Oil Prospecting*. New York: McGraw-Hill. P. 462.

Osman, O., Muhittin, A.A., Ucan, O.N., 2006. A new approach for residual gravity anomaly profile interpretations: Forced Neural Network (FNN). *Annals of geophysics*, v. 49, n. 6.

Osman, O., Muhittin, A.A., Ucan, O.N., 2007. Forward Modeling with Forced Neural Networks for Gravity Anomaly Profile. *Mathematical Geology*, v. 39, p. 593-605.

Rumelhart, D.E., McClelland, J.L., and the PDP Research group. *Cambridge, MA*,

MIT Press, p. 318-362.

Samarasinghe, S., 2007. *Neural Networks for Applied Science and Engineering*. Auerbach Publications. P. 570.

Shaw, R.K., Agarwal, B.N.P. 1997. A generalized concept of resultant gradient to interpret potential field maps. *Geophysical Prospecting*, v. 45, p. 1003-1011.

Telford, W.M., Geldart, L.P., and Sheriff, R.C., 1991. *Applied geophysics*, 2nd edition, Cambridge University Press, 770 p.

USGS, 2009. Humble oilfield U.S. Geological Survey, www.usgs.gov.

Widrow. B., and Hoff. E., 1960. Adaptive Switching circuits. *IRE part 4 WESCON report*, N. Y.

Abstract:

Different ways are used in geophysics to detect underground structures and quantitative and qualitative interpretation of anomalies in consequence of such structures. Detection of surface, depth expansion and the depth of embedment of bodies, masses and geophysics phenomena are of geophysics aims. Among geophysics methods, the gravity one is applied to detect geology anomalies in varied scales. To interpret the qualitative and quantitative anomalies, identification of their depth and shape with modeling is used in different ways. To do this, simple models are used such as sphere and cylinder and compound model. One of the used ways about qualitative and quantitative interpretation is artificial neural network. In this study the aim of using of artificial neural network is the estimation of underground structure shape, the estimation of depth, radius and the density of anomalies made by them. So by providing artificial models and accounting their gravity effect, the artificial networks have been designed. The MLP has been the used as a neural network in this study that has been trained by some artificial models, a part for training and some for validating and assessing. In order to estimate the shape, depth and the density of anomalies, four distinct neural networks have been provided and made. At first anomalies shape has been identified and based on that the estimation of depth and density has been gotten possible. To do this to coordinate the modeling results along with earth fact, sphere simple models and cylinder model and vertical cylinder-sphere compound artificial model (salt dome) with different dimensions and parameters have been used. Considering the anomaly shape of gravity is dependent on dimensions and depth and shape of underground structures, so these dependent features of the diagram of the gravity effect of these phenomena has been used as artificial network input. To train the network, firstly some of results of different models were used to train the network and the other models for evaluating and validating of the network. A network with different layers and neuron numbers has been considered to produce an optimum neural network and the performance diagram of every network in different states has been provided and calculated to gain the optimum model. Thus by making some networks, the estimation of shape, depth and radius and density of underground anomalies have been dealt with. Finally the optimized network has been used to interpret the real gravity data, of salt dome of Hormoz and the salt dome of Humble. The study results showed that the shape of Humble salt dome up to higher extent is sphere and its depth is 2.5. This method also was used to estimate the shape and the depth of anomaly of Hormoz salt in Hormozgan province and the result of this study shows that the shape of this salt structure is compound meaning the chimney state along with spheroid skullcap.

Key words: gravity anomaly, Multi Layers Perceptron, the estimation of shape and

depth, artificial neural network, gravity, salt dome.



Shahrood University of Technology
Faculty of Mining, Petroleum and Geophysics Engineering

M.Sc. Thesis in Gravimetry

Determination of shape of anomalous bodies using
gravity anomalies by means of neural network method and
estimation of their depths

By: Mahin Mohammadzadeh

Supervisors:

Dr. Hamid Aghajani

Dr. Amin Roshandel Kahoo

Advisor:

Dr. Tokhmchi

September 2015