



تشکر و قدردانی:

تقدیم به :

سپاس یزدان پاک را که قلم را آفرید و به آن سوگند یاد فرمود. حق تعالی را بسی شکر گذاریم که توفیقمان داد تا در وادی بزرگترین معرفت بشری- علم - گامی هر چند ناچیز برداریم و در این مسیر از محضر انسانهایی عارف و عاشق پیشه فیض بریم که تمام زندگی خویش را عاشقانه صرف علم نموده‌اند.

برخود لازم می‌دانم از زحمات اساتید بزرگوarm جناب آقای دکتر علی مرادزاده و جناب آقای دکتر فرامرز دولتی که مسئولیت راهنمایی پایان نامه را به عهده داشتند و در طول اجرای این پژوهش با دانش و بینش عمیق خویش، بنده را یاری نمودند، قدردانی کنم.

همچنین از جناب آقای دکتر کاکائی ریاست محترم دانشکده معدن، نفت و ژئوفیزیک دانشگاه صنعتی شاهرود تشکر می‌کنم که با حمایت‌های همه جانبه خویش موجبات دلگرمی بیشتر اینجانب را برای ادامه کار فراهم نمودند.

از آقای مهندس سرخیل و نیز آقای مهندس کبیریان، مسئول آزمایشگاه ژئوفیزیک دانشکده معدن، نفت و ژئوفیزیک دانشگاه صنعتی شاهرود بخاطر زحماتشان متشکرم.

و در پایان لازم می‌دانم از همه دوستان و عزیزانی که در به اتمام رساندن این تحقیق یاری‌ام نموده‌اند مراتب سپاسگذاری خود را ابراز نمایم.

چکیده

روش مقاومت ویژه الکتریکی، یکی از پرکاربردترین روشهای الکتریکی است که از آن برای مطالعه آبهای زیرزمینی، اکتشافات معدنی و نیز مطالعات عمقی ساختارهای زیر زمین استفاده می‌کنند. با توجه به کاربردهای مهم روشهای الکتریکی، مدل‌سازی معکوس داده‌های حاصل از این برداشتها نیز حائز اهمیت است؛ ولی از آنجا که داده‌های ژئوالکتریک، طبیعت غیر خطی دارند و نیز با توجه به اینکه مدل‌های بدست آمده از مدل‌سازی، یکتا نیستند؛ مجموعه این عوامل این فرآیند را با مشکلات عدیده‌ای مواجه کرده است. به همین منظور

در این تحقیق، این عوامل و مشکلات مورد بررسی قرار گرفته و سعی در ارائه راه حلی برای رفع آنها شده است. لذا با توجه به تواناییها و قابلیت‌های شبکه‌های عصبی مصنوعی (ANNs) در زمینه‌های مختلف علمی از جمله مسأله وارونه‌سازی، به معکوس‌سازی یک بعدی داده‌های سونداژ مقاومت ویژه الکتریکی با استفاده از این شبکه‌ها پرداخته شده است. شبکه مورد استفاده در این تحقیق، یک شبکه عصبی پیشخور (FNN) بوده که از آن برای تخمین پارامترهای لایه‌های تشکیل دهنده زمین استفاده می‌شود. این شبکه‌ها با استفاده از داده‌های مصنوعی که از طریق مدل‌سازی مستقیم و توسط نرم افزار Resix-IP بدست آمده‌اند، آموزش می‌بینند. الگوریتم آموزشی که در اینجا مورد استفاده واقع شده است، الگوریتم پس انتشار خطا (Backpropagation Error) می‌باشد. در این تحقیق، از هشت شبکه عصبی مختلف برای تخمین پارامترهای مربوط به حالات مختلف یک زمین چهار لایه‌ای که شامل منحنی‌های نوع AA، AK، HA، HK، KH، KQ، QH و QQ است، استفاده و از یک شبکه مجزای دیگر هم برای دسته‌بندی مدل‌های مختلف چهار لایه‌ای بهره گرفته شد. از طرف دیگر برای اینکه داده‌های مصنوعی تولید شده به داده‌های واقعی شبیه‌تر شوند، به این داده‌ها به صورت تصادفی مقداری نویز اضافه کرده و عملکرد شبکه‌ها در برابر آنها نیز مورد بررسی قرار گرفت. در نهایت برای اطمینان از میزان درستی نتایج و آگاهی از قدرت تعمیم شبکه‌ها، به ازای یکسری از داده‌های واقعی، خروجی حاصل از شبکه، با نتایج مربوط به نرم افزار Resix-IP نیز مورد مقایسه قرار گرفت و مشخص شد که پاسخ شبکه‌های تخمینگر و نیز شبکه دسته‌بندی کننده تا حدود زیادی مشابه نتایج نرم افزار فوق هستند. نتایج حاصل از این تحقیق حاکی از آن است که چنانچه داده‌های مصنوعی تولید شده نزدیک به واقعیت باشند و ساختار شبکه‌های مورد استفاده نیز به صورت بهینه انتخاب گردند و از طرف دیگر فرآیند آموزش شبکه‌ها نیز به درستی انجام پذیرد، شبکه‌های مورد نظر ضمن داشتن پاسخی سریع از دقت کافی نیز برخوردار خواهند بود.

عنوان یک

تقدیم دو

تشکر و قدردانی سه

چکیده چهار

فصل اول - کلیات

۱-۱- مقدمه	۲
۲-۱- مروری بر کارهای انجام شده	۷
۳-۱- اهداف پایان نامه و ضرورت انجام آن	۹
۴-۱- روش انجام تحقیق	۱۰
۵-۱- سازماندهی پایان نامه	۱۱

فصل دوم - روش مقاومت ویژه الکتریکی

۱-۲- مقدمه	۱۳
۲-۲- روش مقاومت ویژه الکتریکی	۱۴
۱-۲-۲- اصول روش مقاومت ویژه الکتریکی	۱۵
۲-۲-۲- محاسبه مقاومت ویژه الکتریکی با چهار قطبی غیر مشخص	۱۶
۳-۲-۲- انواع آرایش الکترودی	۱۸
۱-۳-۲-۲- آرایش شلومبرژه	۱۸
۲-۳-۲-۲- مزایا و معایب آرایش شلومبرژه	۱۹
۳-۲- هموارسازی منحنیهای مقاومت ویژه	۲۰
۴-۲- عمق تجسس یا عمق نفوذ خطوط جریان	۲۲
۵-۲- سونداژ الکتریکی قائم	۲۲
۱-۵-۲- قابلیت ثبت یک لایه در سونداژ زنی	۲۳

۲۳	۲-۵-۲- ضرایب آنیزوتروپی
۲۴	۲-۵-۳- اصل هم ارزی
۲۵	۲-۵-۴- اصل اختفاء
۲۵	۲-۶- انواع حالات موجود در یک زمین هموار با چهار لایه افقی
۲۶	۲-۶-۱- منحنی نوع AA
۲۷	۲-۶-۲- منحنی نوع AK
۲۷	۲-۶-۳- منحنی نوع KH
۲۸	۲-۶-۴- منحنی نوع KQ
۲۸	۲-۶-۵- منحنی نوع QQ
۲۹	۲-۶-۶- منحنی نوع QH
۲۹	۲-۶-۷- منحنی نوع HK
۳۰	۲-۶-۸- منحنی نوع HA

فصل سوم - مقدمه ای بر شبکه‌های عصبی مصنوعی

۳۲	۳-۱- مقدمه
۳۳	۳-۲- شبیه سازی عملکرد سیستم عصبی
۳۵	۳-۳- تاریخچه کاربرد شبکه های عصبی مصنوعی
۳۵	۳-۴- مبانی شبکه های عصبی مصنوعی
۳۷	۳-۵- ساختار شبکه های عصبی مصنوعی
۳۸	۳-۶- توابع انتقال

۳۸	۷-۳- معماری شبکه های عصبی مصنوعی
۴۰	۸-۳- آموزش شبکه های عصبی مصنوعی
۴۱	۱-۸-۳- انواع شبکه های عصبی براساس روش یادگیری
۴۱	شبکه های دارای یادگیری با ناظر
۴۱	شبکه های دارای یادگیری بدون ناظر
۴۲	۲-۸-۳- توقف آموزش
۴۳	۳-۸-۳- قابلیت تعمیم شبکه های عصبی مصنوعی
۴۳	۹-۳- تعداد الگوهای یادگیری
۴۴	۱۰-۳- توزیع مقادیر الگوها
۴۵	۱۱-۳- تعیین ساختار بهینه یک مدل شبکه عصبی مصنوعی
۴۶	۱-۱۱-۳- تعداد لایه های شبکه
۴۷	۲-۱۱-۳- اثر تعداد نرون ها در لایه های میانی
۴۸	۳-۱۱-۳- انتخاب نوع تابع محرک
۴۸	۴-۱۱-۳- مقدار دهی اولیه وزنها
۴۹	۵-۱۱-۳- نرخ یادگیری و گشتاور

فصل چهارم - مدل سازی داده های سونداژ مقاومت ویژه با استفاده از

شبکه عصبی مصنوعی

۵۲	۱-۴- مقدمه
۵۳	۲-۴- مراحل انجام کار

۵۳	۴-۲-۱- تهیه، تولید و آماده سازی داده های مصنوعی
۵۵	۴-۲-۲- تعیین ساختار بهینه شبکه عصبی مصنوعی
۵۶	۴-۲-۲-۱- مراحل کلی طراحی شبکه عصبی پیشخور و با ناظر
۵۷	۴-۳-۱- مدل سازی معکوس داده های ژئوالکتریکی چهار لایه با استفاده از شبکه عصبی
۵۷	۴-۳-۱- شبکه طبقه بندی
۶۲	۴-۳-۲- شبکه های تخمینگر
۶۳	۴-۳-۲-۱- شبکه AA
۶۹	۴-۳-۲-۲- شبکه AK
۷۳	۴-۳-۲-۳- شبکه KH
۷۶	۴-۳-۲-۴- شبکه KQ
۷۹	۴-۳-۲-۵- شبکه QQ
۸۲	۴-۳-۲-۶- شبکه QH
۸۵	۴-۳-۲-۷- شبکه HK
۸۸	۴-۳-۲-۸- شبکه HA
۹۱	۴-۳-۳- مقایسه نتایج شبکه های تخمینگر
۹۳	۴-۴- بررسی قدرت تعمیم شبکه عصبی طراحی شده با استفاده از داده های واقعی
۹۳	۴-۴-۱- مطالعه موردی ۱
۱۰۶	۴-۴-۲- مطالعه موردی ۲
۱۱۳	۴-۵- جمع بندی

فصل پنجم - نتیجه گیری و پیشنهادات

- ۱-۵- جمع‌بندی ۱۱۵
- ۲-۵- نتیجه‌گیری ۱۱۶
- ۳-۵- پیشنهادات ۱۱۸

منابع و مراجع

- ۱۲۱ فهرست منابع و مراجع فارسی
- ۱۲۲ فهرست منابع و مراجع انگلیسی

پیوست‌ها

- پیوست الف - نحوه تولید داده‌های مصنوعی ۱۲۵
- پیوست ب - نحوه اضافه نمودن نویز به داده‌های مصنوعی ۱۲۶
- پیوست ج - الگوریتم یادگیری پس انتشار خطا ۱۲۷
- پیوست د - نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه‌های عصبی با داده‌های هدف (به ازای داده‌های فاقد نویز) ۱۳۰
- پیوست ه - برخی از نتایج مربوط به مدل‌سازی معکوس داده‌ها با استفاده از شبکه عصبی ۱۶۳
- شکل ۱-۲- مدل فرضی زمین به همراه الکترودهای جریان A و B ۱۷
- شکل ۲-۲- یک مدل زمین همگن با الکترودهای جریان A و B و الکترودهای پتانسیل M و N ۱۹
- شکل ۳-۲- مثالی از وجود گسستگی روی منحنی سونداژ ۲۱
- شکل ۴-۲- نمایی شماتیک از یک زمین هموار با چهار لایه افقی ۲۶
- شکل ۵-۲- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع AA ۲۶

- شکل ۲-۶- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع AK..... ۲۷
- شکل ۲-۷- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع KH..... ۲۷
- شکل ۲-۸- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع KQ..... ۲۸
- شکل ۲-۹- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع QQ..... ۲۸
- شکل ۲-۱۰- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع QH..... ۲۹
- شکل ۲-۱۱- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع HK..... ۲۹
- شکل ۲-۱۲- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع HA..... ۳۰
- شکل ۳-۱- ساختار یک سلول عصبی..... ۳۳
- شکل ۳-۲- روند شبیه سازی کارکرد یک سلول عصبی..... ۳۴
- شکل ۳-۳- مدل رگرسیون خطی با پارامترهای مربوطه..... ۳۶
- شکل ۳-۴- ساختار یک نرون شبکه عصبی و پارامترهای مربوط به آن..... ۳۷
- شکل ۳-۵- ساختار یک شبکه پیشخور..... ۳۹
- شکل ۳-۶- ساختار یک شبکه پسخور یا برگشتی..... ۳۹
- شکل ۳-۷- فرآیند آموزش شبکه عصبی مصنوعی..... ۴۰
- شکل ۳-۸- تأثیر ممنتم بر یادگیری شبکه عصبی..... ۵۰
- شکل ۴-۱- نمایی کلی از ساختار مورد استفاده برای انجام مدلسازی معکوس داده های ژئوالکتریک..... ۵۳
- شکل ۴-۲- رفتار شبکه طبقه بندی در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است..... ۵۹
- شکل ۴-۳- رفتار شبکه طبقه بندی در هنگام آموزش (وجود ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است..... ۶۰
- شکل ۴-۴- رفتار شبکه طبقه بندی در هنگام آموزش (وجود ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است..... ۶۰
- شکل ۴-۵- نمونه‌ای از نحوه تعیین نوع منحنی سونداز برای یک داده آزمایشی توسط شبکه طبقه‌بندی..... ۶۱
- شکل ۴-۶- رفتار شبکه AA در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است..... ۶۴
- شکل ۴-۷- رفتار شبکه AA در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است..... ۶۵
- شکل ۴-۸- رفتار شبکه AA در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است..... ۶۶
- شکل ۴-۹- خروجی شبکه AA به ازای یکی از داده های آزمایشی..... ۶۸
- شکل ۴-۱۰- خروجی شبکه AA و مقایسه آن با مدل حاصل از نرم افزار Resix-IP..... ۶۹
- شکل ۴-۱۱- خروجی شبکه AK به ازای یکی از داده های آزمایشی..... ۷۲
- شکل ۴-۱۲- خروجی شبکه AK و مقایسه آن با مدل حاصل از نرم افزار Resix-IP..... ۷۳

- شکل ۴-۱۳- خروجی شبکه KH به ازای یکی از داده های آزمایشی..... ۷۵
- شکل ۴-۱۴- خروجی شبکه KH و مقایسه آن با مدل حاصل از نرم افزار Resix-IP..... ۷۶
- شکل ۴-۱۵- خروجی شبکه KQ به ازای یکی از داده های آزمایشی..... ۷۸
- شکل ۴-۱۶- خروجی شبکه KQ و مقایسه آن با مدل حاصل از نرم افزار Resix-IP..... ۷۹
- شکل ۴-۱۷- خروجی شبکه QQ به ازای یکی از داده های آزمایشی..... ۸۱
- شکل ۴-۱۸- خروجی شبکه QQ و مقایسه آن با مدل حاصل از نرم افزار Resix-IP..... ۸۲
- شکل ۴-۱۹- خروجی شبکه QH به ازای یکی از داده های آزمایشی..... ۸۴
- شکل ۴-۲۰- خروجی شبکه QH و مقایسه آن با مدل حاصل از نرم افزار Resix-IP..... ۸۵
- شکل ۴-۲۱- خروجی شبکه HK به ازای یکی از داده های آزمایشی..... ۸۷
- شکل ۴-۲۲- خروجی شبکه HK و مقایسه آن با مدل حاصل از نرم افزار Resix-IP..... ۸۸
- شکل ۴-۲۳- خروجی شبکه HA به ازای یکی از داده های آزمایشی..... ۹۰
- شکل ۴-۲۴- خروجی شبکه HA و مقایسه آن با مدل حاصل از نرم افزار Resix-IP..... ۹۱
- شکل ۴-۲۵- مقایسه نتایج مربوط به خطاهای حاصل از آموزش شبکه های عصبی تخمینگر..... ۹۲
- شکل ۴-۲۶- نقشه توپوگرافی تهیه شده که محل سونداژها (دایره های آبی)، چاه های آب موجود (دایره های قرمز)، مسیر تونل قنات و جهت جریان آب در آن (خط چین قرمز) و پروفیل های مورد برداشت روی آن آمده است..... ۹۴
- شکل ۴-۲۷- ستون چینه شناسی حاصل از حفاری برای چاه های شماره ۳ و ۴..... ۹۵
- شکل ۴-۲۸- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۴۰۱..... ۹۶
- شکل ۴-۲۹- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۴۰۲..... ۹۷
- شکل ۴-۳۰- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۰۵..... ۹۸
- شکل ۴-۳۱- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۰۸..... ۱۰۰
- شکل ۴-۳۲- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۰۹..... ۱۰۱
- شکل ۴-۳۳- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۱۱..... ۱۰۳
- شکل ۴-۳۴- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۲۱۱..... ۱۰۴
- شکل ۴-۳۵- نقشه توپوگرافی تهیه شده که محل سونداژها و پروفیل های مورد برداشت روی آن آمده است..... ۱۰۶
- شکل ۴-۳۶- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۰۲..... ۱۰۷
- شکل ۴-۳۷- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۳۰۳..... ۱۰۸
- شکل ۴-۳۸- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۳۰۵..... ۱۰۹

شکل ۳۹-۴- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۳۰۶	۱۱۰
شکل ۴۰-۴- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۴۰۳	۱۱۱
شکل ۴۱-۴- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۶۰۴	۱۱۲
جدول ۱-۲- مقاومت ویژه برخی سنگها و مواد معدنی و شیمیایی	۱۴
جدول ۱-۴- مقدار خطای (MSE) شبکه AA به ازای هر یک از پارامترهای خروجی (عدم حضور نویز)	۶۴
جدول ۲-۴- ضریب همبستگی بین خروجی شبکه AA با داده های هدف (عدم حضور نویز)	۶۵
جدول ۳-۴- مقدار خطای (MSE) شبکه AA به ازای هر یک از پارامترهای خروجی (در حضور ۵٪ نویز)	۶۶
جدول ۴-۴- ضریب همبستگی بین خروجی شبکه AA با داده های هدف (در حضور ۵٪ نویز)	۶۶
جدول ۵-۴- مقدار خطای (MSE) شبکه AA به ازای هر یک از پارامترهای خروجی (در حضور ۱۰٪ نویز)	۶۷
جدول ۶-۴- ضریب همبستگی بین خروجی شبکه AA با داده های هدف (در حضور ۱۰٪ نویز)	۶۷
جدول ۷-۴- مقایسه بین پاسخ شبکه AA با مدل واقعی به ازای یکی از داده های آزمایشی	۶۸
جدول ۸-۴- مقدار خطای (MSE) شبکه AK به ازای هر یک از پارامترهای خروجی (عدم حضور نویز)	۷۰
جدول ۹-۴- ضریب همبستگی بین خروجی شبکه AK با داده های هدف (عدم حضور نویز)	۷۰
جدول ۱۰-۴- مقدار خطای (MSE) شبکه AK به ازای هر یک از پارامترهای خروجی (در حضور ۵٪ نویز)	۷۰
جدول ۱۱-۴- ضریب همبستگی بین خروجی شبکه AK با داده های هدف (در حضور ۵٪ نویز)	۷۱
جدول ۱۲-۴- مقدار خطای (MSE) شبکه AK به ازای هر یک از پارامترهای خروجی (در حضور ۱۰٪ نویز)	۷۱
جدول ۱۳-۴- ضریب همبستگی بین خروجی شبکه AK با داده های هدف (در حضور ۱۰٪ نویز)	۷۱
جدول ۱۴-۴- مقایسه بین پاسخ شبکه AK با مدل واقعی به ازای یکی از داده های آزمایشی	۷۲
جدول ۱۵-۴- مقدار خطای (MSE) شبکه KH به ازای هر یک از پارامترهای خروجی (عدم حضور نویز)	۷۴
جدول ۱۶-۴- ضریب همبستگی بین خروجی شبکه KH با داده های هدف (عدم حضور نویز)	۷۴
جدول ۱۷-۴- مقایسه بین پاسخ شبکه KH با مدل واقعی به ازای یکی از داده های آزمایشی	۷۵
جدول ۱۸-۴- مقدار خطای (MSE) شبکه KQ به ازای هر یک از پارامترهای خروجی (عدم حضور نویز)	۷۷
جدول ۱۹-۴- ضریب همبستگی بین خروجی شبکه KQ با داده های هدف (عدم حضور نویز)	۷۷
جدول ۲۰-۴- مقایسه بین پاسخ شبکه KQ با مدل واقعی به ازای یکی از داده های آزمایشی	۷۸
جدول ۲۱-۴- مقدار خطای (MSE) شبکه QQ به ازای هر یک از پارامترهای خروجی (عدم حضور نویز)	۸۰
جدول ۲۲-۴- ضریب همبستگی بین خروجی شبکه QQ با داده های هدف (عدم حضور نویز)	۸۰
جدول ۲۳-۴- مقایسه بین پاسخ شبکه QQ با مدل واقعی به ازای یکی از داده های آزمایشی	۸۱

جدول ۴-۲۴	مقدار خطای (MSE) شبکه QH به ازای هر یک از پارامترهای خروجی (عدم حضور نویز).....	۸۳
جدول ۴-۲۵	ضریب همبستگی بین خروجی شبکه QH با داده های هدف (عدم حضور نویز).....	۸۳
جدول ۴-۲۶	مقایسه بین پاسخ شبکه QH با مدل واقعی به ازای یکی از داده های آزمایشی.....	۸۴
جدول ۴-۲۷	مقدار خطای (MSE) شبکه HK به ازای هر یک از پارامترهای خروجی (عدم حضور نویز).....	۸۶
جدول ۴-۲۸	ضریب همبستگی بین خروجی شبکه HK با داده های هدف (عدم حضور نویز).....	۸۶
جدول ۴-۲۹	مقایسه بین پاسخ شبکه HK با مدل واقعی به ازای یکی از داده های آزمایشی.....	۸۷
جدول ۴-۳۰	مقدار خطای (MSE) شبکه HA به ازای هر یک از پارامترهای خروجی (عدم حضور نویز).....	۸۹
جدول ۴-۳۱	ضریب همبستگی بین خروجی شبکه HA با داده های هدف (عدم حضور نویز).....	۸۹
جدول ۴-۳۲	مقایسه بین پاسخ شبکه HA با مدل واقعی به ازای یکی از داده های آزمایشی.....	۹۰
جدول ۴-۳۳	مشخصات چاه های آب موجود در منطقه.....	۹۴
جدول ۴-۳۴	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۴۰۱.....	۹۶
جدول ۴-۳۵	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۴۰۲.....	۹۷
جدول ۴-۳۶	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۱۰۵.....	۹۸
جدول ۴-۳۷	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۱۰۸.....	۱۰۰
جدول ۴-۳۸	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۱۰۹.....	۱۰۱
جدول ۴-۳۹	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ 111	۱۰۳
جدول ۴-۴۰	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۲۱۱.....	۱۰۴
جدول ۴-۴۱	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۱۰۲.....	۱۰۷
جدول ۴-۴۲	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۳۰۳.....	۱۰۸
جدول ۴-۴۳	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۳۰۵.....	۱۰۹
جدول ۴-۴۴	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۳۰۶.....	۱۱۰
جدول ۴-۴۵	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۴۰۳.....	۱۱۱
جدول ۴-۴۶	مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP به ازای داده های واقعی سونداژ ۶۰۴.....	۱۱۲

فصل اول

کلیات

۱-۱- مقدمه

ژئوفیزیک، علم مطالعه زمین توسط اندازه‌گیری خصوصیات فیزیکی سنگها با استفاده از وسایل مناسب و بکارگیری تکنیک‌های بخصوص می‌باشد. یکی از شاخه‌های اصلی این علم، ژئوفیزیک اکتشافی است که خود شامل اندازه‌گیری خصوصیات فیزیکی لایه‌های زیرسطحی برای مقاصد مهندسی و نیز به منظور اکتشاف و پی‌جویی ذخایر پنهان شده در دل زمین (اعم از نفت، گاز، آب و کانیه‌های اقتصادی) است؛ که عمده‌تاً شامل روشهای گرانی‌سنجی، مغناطیس‌سنجی، روشهای الکتریکی، لرزه‌ای، رادیواکتیو، حرارت‌سنجی و ... می‌باشد. انتخاب نوع روش، به خواص فیزیکی منطقه مورد نظر و نیز نوع اطلاعات مورد جستجو، بستگی دارد.

یکی از پرکاربردترین روشهای ژئوفیزیک در مطالعات اکتشافی، روشهای الکتریکی است. اساس این روشها عمده‌تاً بر مبنای عدم توزیع یکسان مقاومت ویژه الکتریکی مواد واقع در زیر سطح زمین استوار است. این تغییرات مقاومت ویژه، منجر به بوجود آمدن تغییرات در پدیده‌های الکتریکی می‌گردد که در سطح زمین اندازه‌گیری می‌شوند. برداشت‌های ژئوالکتریکی خود دارای روشهای متعددی هستند که از جمله آنها می‌توان روش پتانسیل خودزا^۱، روش قطبش القایی^۲، روش الکترومغناطیس^۳، روش مقاومت ویژه^۴ و ... را نام برد. بعضی از این روشها از الکتریسیته طبیعی که در زمین جریان دارد، استفاده می‌کنند، مانند روش پتانسیل خودزا؛ در مقابل، روشهای دیگری هم موجود می‌باشد که بکارگیری آنها مستلزم آن است که جریانی به طور مصنوعی به داخل زمین فرستاده شود، مانند روش مقاومت ویژه الکتریکی (تلفورد^۵ و همکاران، ۱۹۹۰).

روش مقاومت ویژه الکتریکی برای مقاصدی چون مسائل هیدروژئولوژیکی، اکتشاف معدن، بررسی‌های ژئوتکنیکی و نیز مسائل محیط زیستی بکار گرفته می‌شود (مونی^۶، ۱۹۸۰). هدف از اندازه‌گیری‌های مقاومت ویژه، تعیین توزیع مقاومت ویژه مواد واقع در زیر سطح زمین است. مقاومت ویژه زمین به پارامترهای مختلفی

¹ Self Potential Method

² Induced Polarization Method

³ Electromagnetic Method

⁴ Resistivity Method

⁵ Telford

⁶ Mooney

از قبیل نوع مواد تشکیل دهنده محیط، میزان فضاهای خالی سنگ، نوع سیال موجود در آن بستگی دارد. عمده‌ترین عیب این روش حساسیت زیاد آن به تغییرات کوچک مقاومت ویژه در مجاورت سطح زمین است. به زبان دیگر، سطح نويز بالاست (تلفورد و همکاران، ۱۹۹۰).

مشخص نمودن چگونگی تغییرات عمقی مقاومت ویژه ظاهری را اصطلاحاً سونداژ الکتریکی مقاومت ویژه و مشخص نمودن چگونگی تغییرات جانبی مقاومت ویژه زمین را پروفیل الکتریکی مقاومت ویژه گویند (تلفورد و همکاران، ۱۹۹۰).

پس از انجام اندازه‌گیری‌ها، با توجه به نوع روش مورد استفاده، یکسری اطلاعات از برخی خواص فیزیکی زمین (از قبیل مقاومت ویژه، سرعت انتشار امواج، مغناطیس پذیری و ...) به صورت عددی در اختیار ما قرار می‌گیرد. این داده‌ها همراه با نويز بوده و با این حال بایستی اطلاعاتی را در مورد اهداف مورد مطالعه از آنها خارج کنیم. برای این منظور روش‌های مدل‌سازی به عنوان ابزاری برای درک روابط بین داده‌های مشاهده‌ای مذکور و تغییرات خواص مواد زیر سطحی بکار برده می‌شوند (مجو^۷، ۱۹۸۶).

تمام روش‌های ژئوفیزیکی که بر اساس تئوری پتانسیل کار می‌کنند (مثل روش‌های ثقل‌سنجی، مغناطیس‌سنجی و ژئوالکتریکی) تعبیر و تفسیر منحصر بفردی نخواهند داشت. در عمل با ایجاد ارتباط بین چندین منحنی سونداژ (بالاخص سونداژ با پروفیل‌های متقاطع و سونداژ با آرایش‌های متفاوت)، تهیه پروفیل‌های افقی مقاومت ویژه، شناخت مسائل کلی زمین‌شناسی از منطقه و داشتن درک درست از خواص الکتریکی سنگها در محیط مورد مطالعه، می‌توان تعبیر و تفسیر صحیح از لایه‌های زیرسطحی به عمل آورد. موقعی که اطلاعات حفاری موجود باشند، مصلحت آنست که سونداژ را در نزدیکی چاهها انجام داد تا بتوان پارامترهای مقاومت ویژه لایه‌ها را با استفاده از ضخامت‌های دقیق حاصله از حفاری تعیین نمود. سپس با استفاده از این پارامترها می‌توان ضخامت لایه‌ها را در مناطق اطراف بدست آورد (کلاگری، ۱۳۷۱).

مدل‌سازی‌های ژئوفیزیکی بطور عمده به دو دسته مدل‌سازی‌های فیزیکی و عددی تقسیم‌بندی می‌شوند. مدل‌سازی فیزیکی، شبیه‌سازی ساختار زمین در مقیاس آزمایشگاهی است (آپارو^۸، ۱۹۹۷). مدل‌سازی عددی به دو شیوه انجام می‌پذیرد: مدل‌سازی مستقیم یا پیشرو^۹ و مدل‌سازی معکوس^{۱۰}. در مدل‌سازی پیشرو از مدل به داده محاسبه‌ای (پاسخ مدل) می‌رسیم. بدین صورت که ابتدا مدلی با توجه به اطلاعات موجود فرض

⁷ Meju

⁸ Apparo

⁹ Forward Modeling

¹⁰ Inverse Modeling

کرده و سپس با انجام عملیات ریاضی پاسخ آن را محاسبه می‌کنیم. حال با مقایسه پاسخ مدل و داده مشاهده‌ای به صورت سعی و خطا نسبت به تغییرات پارامترهای مدل اقدام نموده و به تکرار محاسبه پاسخ مدل جدید اقدام می‌نماییم، تا جایی که بین پاسخ مدل و داده‌های مشاهده‌ای برازش خوبی حاصل گردد. این شیوه چون بر اساس سعی و خطا است، بسیار وقت گیر است. در مقابل در مدل‌سازی معکوس با انجام محاسبات ریاضی مختلف و در نظر گرفتن خطای قابل قبول، از داده‌های مشاهده‌ای به مدل مورد مطالعه دست پیدا می‌کنیم. البته در این حالت، مدل بدست آمده یکتا نبوده و در بسیاری از موارد به علت وجود نویز و نحوه انجام محاسبات، مدل‌سازی از نظر عددی ناپایدار خواهد بود. معکوس سازی داده‌های مقاومت ویژه، شامل تخمین نحوه توزیع مقاومت ویژه واقعی و ضخامت لایه‌ها با توجه به مقادیر مقاومت ویژه ظاهری اندازه‌گیری شده می‌باشد. بطور کلی روند مسائل معکوس سازی را می‌توان به صورت زیر خلاصه نمود (تلفورد و همکاران، ۱۹۹۰):

۱- پارامتری نمودن مدل.

۲- خطی سازی و فرمولاسیون مسأله با استفاده از قضیه بسط تیلور توابع.

۳- فرمول بندی مسأله به شکل ماتریسی.

۴- یافتن پاسخ مدل با مدل‌سازی پیشرو.

۵- کنترل روند معکوس سازی و انتخاب مدل نهایی.

فرآیند معکوس سازی یکتا نمی‌باشد (تلفورد و همکاران، ۱۹۹۰). یعنی مدل‌های زیادی وجود دارند که منحنی حاصل از پاسخ آنها، با منحنی حاصل از داده‌های مشاهده‌ای یکسان می‌باشد. مفسر از میان این مدل‌ها باید مدل واقعی و منطبق با زمین را انتخاب کند. لذا برای انجام مدل‌سازی نیاز به اطلاعات زمین شناسی و گمانه‌های اکتشافی است تا از میان مدل‌های بدست آمده، مدلی انتخاب گردد که بیشترین همخوانی را با اطلاعات زمین شناسی و چاه‌های اکتشافی داشته باشد.

محققان بسیاری روش هوش مصنوعی و زیر شاخه‌های آن را در مسائل ژئوفیزیکی بکار برده‌اند. در این تحقیق از بین شاخه‌های اصلی هوش مصنوعی به بررسی شبکه‌های عصبی مصنوعی^{۱۱}، به عنوان یک ابزار

¹¹ Artificial Neural Networks (ANNs)

توانمند در مدل سازی داده های سونداز ژئوالکتریک که از شاخه های ژئوفیزیک است، پرداخته شده است. در طول چند سال گذشته، استفاده از شبکه های عصبی مصنوعی برای مدل سازی پارامترهای لایه های زیرین زمین در بسیاری از زمینه های ژئوفیزیکی توسعه یافته است؛ چرا که مدل کردن پارامترهای زمین نقش مهمی در مسائل مهندسی ایفاء می کند.

از آنجا که در روش های معمول محاسباتی، به علت استفاده از فرضیات ساده شده، در نتایج حاصل و تفسیرهای انجام شده، خطاهایی ایجاد می شود؛ نیاز به یک روش دیگر که قادر به در نظر گرفتن تمام پارامترهای مؤثر به طور همزمان، قدرت تعمیم و یادگیری مستقیم از داده های تجربی، با در نظر گرفتن خطاها و عدم قطعیت موجود باشد، به طور فزاینده ای حس می شود. به عنوان یک راه حل جایگزین، در سال های اخیر، شبکه های عصبی مصنوعی با موفقیت در حل بسیاری از مسائل مهندسی استفاده شده است. شبکه های عصبی مصنوعی بواسطه اینکه بر اساس واقعیت عمل می کنند، با مشکلات معمول در مدل سازی روبرو نیستند و می توانند مستقیماً با داده های تجربی آموزش دیده و در انتهای مرحله آموزش با دقت مناسبی رابطه بین ورودی ها و خروجی ها را مدل سازی و پیش بینی نمایند. علاوه بر قدرت یادگیری، مقاوم بودن شبکه در برابر داده های همراه با خطا و نیز امکان آموزش دوباره شبکه با داده های جدید، بدون تغییر ساختار کلی، انعطاف پذیری، سرعت بالا بعد از آموزش، استفاده از این روش را در حل مسائل ژئوفیزیکی روز به روز گسترده تر کرده است و بایستی اذعان داشت که در واقع، شبکه های عصبی مصنوعی در حل بسیاری از مسائل بطور نسبی موفق بوده اند.

یکی از خصوصیات بارز مسائل ژئوفیزیکی غیر خطی بودن آنها است. شبکه های عصبی مصنوعی در مسائل غیر خطی به ویژه آنهایی که بایستی با روش های آزمون و خطا حل شوند، دارای پاسخ های بسیار خوبی می باشند. این روش به ویژه پس از سال ۱۹۸۰ در دنیا مورد استفاده هر چه بیشتر در تفسیر داده های ژئوفیزیکی و مسائل آن قرار گرفته است (بان^{۱۲} و جاتن^{۱۳}، ۲۰۰۰).

خصوصیت حل مسائل غیر خطی شبکه های عصبی را می توان مدیون آموزش و یادگیری شبکه های

عصبی دانست، به این معنا که شبکه قبل از گرفتن وزن، آنچنان که در ادامه بحث خواهد آمد، توسط داده های مصنوعی آموزش دیده و وزن شبکه با توجه به داده های ورودی شبکه و پاسخ های بدست آمده از آنها تعیین

¹² Baan

¹³ Jutten

می‌گردد. اما در یادگیری، هنگامی که داده‌های تصادفی با درصدی از خطا به ورودی شبکه اعمال می‌شود، می‌توان درصدهای وزنی را به گونه‌ای تغییر داد تا پاسخ مطلوب ایجاد شود و این مجموعه از داده‌ها که در حقیقت داده‌های مورد آزمایش بوده‌اند، خود به آموزش وزنی شبکه و بهینه شده آن کمک می‌کنند و در حقیقت در حین عملیات، شبکه بازآموزی می‌شود. این خاصیت بازآموزی شبکه را می‌توان برای پیچیده‌تر کردن مسائل ژئوفیزیکی استفاده کرد. به این منظور بایستی یک شبکه را طراحی نمود و خروجی‌ها و ورودی‌ها را تنظیم کرده، سپس با مدل‌های ساده ژئوفیزیکی شبکه را آموزش داد و در ادامه پیچیدگی‌های ساختاری با پیچیدگی‌های زمین‌شناسی را نیز به مدل‌های ابتدایی افزود و نتیجه‌های دیگری از مدل گرفت (گرامی‌زادگان، ۱۳۸۲). شبکه‌ها می‌توانند رابطه بین پارامترهای خروجی و ورودی شبکه را شبیه سازی کنند. این رابطه ممکن است توابع ریاضی از داده‌های مصنوعی تولید شده یا داده‌های اندازه‌گیری باشد. در زمینه معکوس سازی داده‌های ژئوفیزیکی، شبکه‌های عصبی می‌توانند بعد از آموزش تخمینی از پارامترهای مدل زمینی، مانند ضخامت و مقاومت ویژه لایه‌ها را در یک مدل یک بعدی ارائه دهند. تولید سری‌های آموزشی می‌تواند زمان‌بر بوده و تعداد مدل‌های آموزشی نیز ممکن است زیاد باشد. لازم به ذکر است معکوس سازی توسط شبکه‌های عصبی می‌تواند به دقت معکوس سازی حداقل مربعات و از همه مهمتر، سریعتر از آن باشد. از طرفی شبکه‌های عصبی می‌توانند جهت یادگیری مدل‌سازی پیشرو آموزش داده شده و وقتی که این شبکه‌ها با روش معکوس سازی حداقل مربعات جفت شوند، می‌توانند منجر به تسریع در معکوس سازی داده‌ها گردند (کریمی، ۱۳۸۳).

۱-۲- مروری بر کارهای انجام شده

کاربرد مسأله معکوس سازی در تفسیر داده‌های مقاومت ویژه به قبل از ۱۹۳۰ بر می‌گردد. در آن زمان معکوس سازی به معنی تفسیر مستقیم بود. اسلیشر^{۱۴} (۱۹۳۳) حلی را که لانگر^{۱۵} (۱۹۳۳) بدست آورده بود، برای تفسیر داده‌های مقاومت ویژه حاصل از یک زمین با لایه‌های افقی بکار برد. راه حلی را که لانگر ارائه کرد یک مسأله مقدار مرزی بود. در این روش توابع فوریه - بسط هنکل، در شرایطی که مقاومت ویژه تابع پیوسته‌ای از عمق است، بکار برده می‌شوند. استیونسون^{۱۶} (۱۹۵۴) یک حل تخمینی را، در شرایطی که مقاومت ویژه تابع

¹⁴ Slichter

¹⁵ Langer

¹⁶ Stevenson

پله‌ای از عمق بود، ارائه کرد. وزوف^{۱۷} (۱۹۵۸) روش اسلیشتر را همراه با داده‌های حاصل از عملیات صحرایی و داده‌های حاصل از تئوری برای یک نمونه سه و چهار لایه بکار برد. اگر داده‌ها همراه با نویز باشد، محاسبات ناپایدار می‌شوند. بنابراین زهدی (۱۹۷۲) روشی را ارائه نمود که برای ۵۰ نمونه صحرایی جواب خوبی را بدست آورد. روش‌های دیگری توسط افرادی چون اوجین^{۱۸} (۱۹۳۸)، پکرز^{۱۹} (۱۹۴۰)، کچ^{۲۰} و گلبای^{۲۱} (۱۹۴۲)، ون نسترن^{۲۲} و کوک^{۲۳} (۱۹۶۶) مورد بررسی قرار گرفتند (اینمن^{۲۴} و همکاران، ۱۹۷۵). هیچ یک از تحقیقات بالا در ارتباط با معکوس سازی، به دقت کاری نبود که بکاس^{۲۵} و گیلبرت^{۲۶} (۱۹۶۷ تا ۱۹۶۹) توضیح دادند. آنها نشان دادند که این روش در مسائل ژئوفیزیکی بسیار کاربرد دارد (اینمن ۱۹۷۳). مارکوارد^{۲۷} در سال ۱۹۷۰ تکنیک رگرسیون ريج را طرح کرد و نشان داد چطور اطلاعات نزدیک به هم می‌توانند بوسیله استفاده از تخمینگرها مطلوب‌تر شوند. اینمن و همکارانش در سال ۱۹۷۳ اولین کسانی بودند که روش معکوس سازی را روی مسائل مقاومت ویژه بکار گرفتند (پاترا و نات، ۱۹۹۹). شبکه‌های عصبی مصنوعی دارای پتانسیل خوبی در حل مسائل ژئوفیزیکی برای تشخیص الگو، مانند تفسیر داده‌های چاه پیمایی، دکانولوشن لرزه، دسته‌بندی حادثه‌ها، الکترومغناطیس، مگنتوتلوریک، وارونه‌سازی داده‌های لرزه، داده‌های رادار نفوذکننده در زمین و ... می‌باشند. همچنین در صنعت نفت نیز برای پردازش داده‌های لرزه‌ای در سال‌های اخیر استفاده شده است (مورات و رودمن، ۱۹۹۲) و کاربردهایی نیز در تفسیر اطلاعات ثقل سنجی و مغناطیس سنجی داشته است (پیرسون و همکاران، ۱۹۹۰).

برای حل معکوس سازی یک بعدی داده‌های سونداژ مقاومت ویژه توسط شبکه‌های عصبی، کالدرون ماسیس^{۲۸}، سن^{۲۹} و استوفا^{۳۰} تحقیقاتی انجام دادند (کالدرون-ماسیس و همکاران، ۲۰۰۰)؛ که مطالعات آنها مربوط به زمین‌های سه و چهار لایه بود. آنها برای آموزش شبکه از یکسری داده‌های مصنوعی استفاده می‌کردند که در آنها مقاومت ویژه لایه اول برای سادگی کار برابر واحد فرض شده بود. این در حالی بود که

¹⁷ Vezoff

¹⁸ Evjen

¹⁹ Pekeris

²⁰ Keck

²¹ Colby

²² Van Nostrand

²³ Cook

²⁴ Inman

²⁵ Backus

²⁶ Gilbert

²⁷ Marquardt

²⁸ Calderon-Macias

²⁹ Sen

³⁰ Stoffa

برای مدل‌سازی مدل‌های واقعی و پیچیده‌تر روش آنها کارساز نبود؛ از طرف دیگر آنها فقط از یک شبکه برای تخمین پارامترهای مورد نظر استفاده نمودند که تمامی حالات مورد نظر را پوشش نمی‌داد.

مدل‌سازی معکوس یک بعدی داده‌های سونداژ ژئوالکتریک برای حالت سه لایه (کریمی، ۱۳۸۳) نیز توسط شبکه‌های عصبی صورت گرفته است. در مدل ارائه شده توسط کریمی (۱۳۸۳) از چهار شبکه مجزا برای تخمین استفاده شده است و عیب اصلی آن این بود که بایستی از ابتدا نوع منحنی مربوط به داده‌های صحرائی مشخص می‌شد تا می‌توانستیم با توجه به آن، از یکی از چهار شبکه مورد نظر استفاده کنیم.

از دیگر تحقیقات انجام شده در این زمینه، مقاله ارائه شده توسط مشین‌چی و مرادی است (مشین‌چی و مرادی، ۱۳۸۴) که از شبکه عصبی برای معکوس‌سازی دو بعدی داده‌های مقاومت ویژه استفاده نمودند. البته کار آنها مربوط به لایه‌بندی خاصی از زمین نبوده و در واقع یک مطالعه موردی برای یک منطقه مشخص انجام دادند. مزیت کار آنها استفاده از داده‌های عملی برای آموزش شبکه مورد نظر و نیز حالت دو بعدی معکوس‌سازی بود.

در تحقیقی که در این پایان‌نامه صورت گرفته است، سعی بر آن شد تا در ادامه کار انجام گرفته شده توسط کالدرون - ماسیس، سن و استوفا (کالدرون و همکاران ۲۰۰۰) و نیز در ادامه کار پایان‌نامه کریمی (۱۳۸۳) که به نتایج مطلوبی نیز رسیده بودند، کلیه حالات موجود برای یک زمین چهار لایه که در واقع شامل ۸ حالت مختلف بود، با استفاده از شبکه‌های عصبی مصنوعی مورد مطالعه قرار گیرند. نکته مهم دیگری که در این تحقیق مورد استفاده واقع شد، قرار گرفتن یک شبکه دسته‌بندی در هنگام ورود داده‌های صحرائی به شبکه‌های تخمینگر است که با توجه به نوع مدل ورودی، داده‌ها را به شبکه مورد نظر هدایت می‌کند. لازم به ذکر است که این کار برای اولین بار صورت گرفته است.

۱-۳- اهداف پایان‌نامه و ضرورت انجام آن

در این تحقیق سعی بر آن شد تا عملکرد شبکه‌های عصبی مصنوعی در پیش‌بینی و تخمین پارامترهای مدل زمین چهار لایه‌ای که شامل ضخامت و مقاومت ویژه لایه‌ها است، مورد بررسی قرار گیرد؛ به عبارت دیگر با استفاده از شبکه‌های عصبی مصنوعی به مدل‌سازی معکوس یک بعدی داده‌های سونداژ مقاومت ویژه

پرداخته می‌شود. از دیگر اهداف مهم این تحقیق، دسته‌بندی مدل‌های ورودی و تفکیک آنها به ۸ حالت مختلف و در نهایت هدایت این مدل‌ها به شبکه مورد نظر است.

از آنجا که روش‌های معمول در تفسیر داده‌های سونداژ ژئوالکتریک و نرم افزارهای موجود ژئوفیزیکی از قبیل نرم افزار Resix-IP (راهنمای نرم افزار Resix-IP، ۱۹۹۳)، هیچیک دارای تفسیر یکتایی از داده‌های مقاومت ویژه نبوده و چندین مدل مختلف از لایه‌های زمین ارائه می‌دهند که انتخاب مدل صحیح از بین این مدل‌ها یکی از مسائل پیچیده در اینگونه موارد است؛ و نیز از آنجا که برای تفسیر به شیوه‌های سنتی و معمول نیاز به زمان زیادی است، لذا در این تحقیق با استفاده از شبکه‌های عصبی مصنوعی سعی می‌شود تا پاره‌ای از این مشکلات بر طرف شده و علاوه بر آن نوع منحنی سونداژ مربوط به داده‌های ورودی نیز تعیین شود.

۱-۴- روش انجام تحقیق

برای انجام تحقیق ابتدا مدل‌های مختلفی از یک زمین چهار لایه در نظر گرفته می‌شود. این مدل‌ها طوری انتخاب می‌شوند که اولاً تمام حالات ممکن را پوشش دهند، ثانیاً بیشترین شباهت را با مدل‌های طبیعی داشته باشند. در ادامه کار، با استفاده از نرم افزار Resix-IP و انجام مدل‌سازی مستقیم، پاسخ این مدل‌ها را بدست آورده و آنها را به عنوان ورودی به شبکه عصبی مورد نظر می‌دهیم. پس از این مرحله نوبت به آموزش شبکه می‌رسد. بعد از اینکه مرحله آموزش به پایان رسید، با استفاده از داده‌های آزمایشی، خروجی شبکه را با مقدار واقعی و مدل اولیه مقایسه کرده تا میزان دقت و صحت شبکه و نیز قدرت تعمیم آن سنجیده شود. از طرفی از آنجا که داده‌های موجود در طبیعت حاوی نویز هستند، کارایی شبکه‌ها را به ازای داده‌های حاوی نویز نیز که به صورت مصنوعی به مدل‌ها اضافه شده است، سنجیده و نتایج حاصل از آن را با نتایج نرم افزار Resix-IP مورد مقایسه قرار دادیم. در انتها نیز به منظور ارزیابی توانمندی‌های شبکه‌های طراحی شده، از آنها برای مدل‌سازی و تفسیر داده‌های سونداژ واقعی استفاده نموده و تجزیه و تحلیل‌های لازم صورت گرفت.

۱-۵- سازماندهی پایان نامه

با توجه به مطالب ارائه شده، ساختار اصلی مطالب مورد استفاده در این پایان نامه به این قرار است. در فصل اول ابتدا مقدمه و کلیاتی در مورد این تحقیق و هدف آن آورده شده است. پس از آن در فصل دوم

به بررسی روش مقاومت ویژه الکتریکی پرداخته شده و معادلات حاکم بر آن مورد بررسی قرار می‌گیرد. در فصل سوم شبکه های عصبی مصنوعی معرفی شده و به اصول و مبانی آن پرداخته می‌شود. در ادامه و در فصل چهارم نیز به تفصیل، مدل سازی داده های مصنوعی و واقعی سونداژ ژئوالکتریک با استفاده از شبکه های عصبی مصنوعی و نتایج حاصل مورد بحث قرار می‌گیرد. در نهایت در فصل پنجم به جمع بندی مطالب، نتیجه گیری و ارائه پیشنهادات پرداخته می‌شود.

فصل دوم

روش مقاومت ویژه الکتریکی

۲-۱- مقدمه

علم ژئوفیزیک از قوانین فیزیک، کاربرد ریاضیات و کامپیوتر برای شناسایی و کشف پدیده‌های زمین و فضا استفاده می‌کند. ژئوفیزیک به طور کلی شامل مطالعه زمین توسط اندازه‌گیری خصوصیات فیزیکی سنگ‌ها با استفاده از وسایل مناسب و به کارگیری تکنیک‌های بخصوص در سطح زمین می‌باشد. تجزیه و تحلیل نتایج این اندازه‌گیری‌ها می‌تواند نشانگر آن باشد که چگونه خواص فیزیکی و شیمیایی پوسته زمین به طور قائم یا جانبی تغییر می‌کند (قاسم العسگری، ۱۳۸۴).

هدف از اکتشافات ژئوفیزیکی، مشخص کردن ساختار زمینی است که روی آن اندازه‌گیری‌ها انجام گرفته است. پس از انجام اندازه‌گیری‌های مورد نظر، بسته به نوع روش ژئوفیزیکی، یک سری اطلاعات از برخی خواص فیزیکی زمین از قبیل مقاومت ویژه، سرعت انتشار امواج، مغناطیس‌پذیری و ... به صورت عددی در اختیار ما قرار می‌گیرد. این داده‌ها ممکن است همراه با نویز باشد. با این حال بایستی اطلاعاتی را از این داده‌ها خارج کنیم. برای این منظور تکنیک‌های مدل‌سازی به عنوان ابزاری برای درک روابط بین داده‌های مشاهده‌ای مذکور و تغییرات خواص زیر زمین به کار برده می‌شوند (مجو، ۱۹۸۶).

در ادامه از بین روش‌های مختلف ژئوفیزیکی، با توجه به این تحقیق به بررسی روش مقاومت ویژه الکتریکی و روابط موجود در آن می‌پردازیم.

۲-۲- روش مقاومت ویژه الکتریکی

یکی از روش‌های ژئوالکتریکی که برای اندازه‌گیری و تعیین نحوه توزیع مقاومت ویژه ساختارهای زیرسطحی به کار می‌رود، روش مقاومت ویژه الکتریکی است. در ابتدای امر، برای آشنایی با این روش مقاومت ویژه برخی سنگ‌ها، مواد معدنی و شیمیایی در جدول (۱-۲) نشان داده شده است. با تعیین مقاومت ویژه واقعی لایه‌های مختلف زمین، به کمک این جدول تا حدودی می‌توان جنس لایه‌ها و نیز جنس سنگ کف را مشخص کرد.

جدول ۱-۲ مقاومت ویژه برخی سنگ‌ها و مواد معدنی و شیمیایی (مونی، ۱۹۸۰).

مقاومت ویژه بر حسب اهم متر	برخی سنگ‌ها، رسوبات و آب
۱ - ۱۰۰	آب سفره‌های آب‌رفتی
۳۰ - ۱۰۰۰	آب باران
$۲۰ - ۲ \times ۱۰^۳$	شیل
$۲ \times ۱۰^۳ - ۱۰^۴$	کنگلو مرا
$۵۰ - ۱۰^۷$	آهک
$۳/۵ \times ۱۰^۲ - ۵ \times ۱۰^۳$	دلومیت
۱ - ۱۰۰	رس
۳ - ۷۰	مارن
$۳ \times ۱۰ - ۱۰^۴$	گرانیت
۱۰۴ - ۱۰۵	دیوریت
$۱/۹ \times ۱۰^۳ - ۲/۳ \times ۱۰^۴$	دیوریت پورفیری
$۳ \times ۱۰^۲ - ۹ \times ۱۰^۳$	کوارتز پورفیری
$۲ \times ۱۰^۴ - ۱/۸ \times ۱۰^۵$	کوارتز دیوریت
$۲۰ - ۱۰^۴$	شیست
$۱۰ - ۱۰^۲$	گرانیت شیست
۱۰۰ - ۳۰۰	شیست آرژیلی
$۶ \times ۱۰^۲ - ۴ \times ۱۰^۷$	سیلت
۱۰۰ - ۱۰۰۰۰	سنگ‌های آذرین و دگرگونی
۱۰ - ۱۰۰۰	رسوبات یکپارچه
۱ - ۱۰۰	رسوبات غیر یکپارچه

۲-۱-۲- اصول روش مقاومت ویژه الکتریکی

برای انجام این روش معمولاً جریان مستقیم DC (که متناوباً جهتش عکس می‌شود) و یا جریان متناوب AC با فرکانس خیلی کم (معمولاً کمتر از یک هرتز) را توسط الکترودهای جریان وارد زمین می‌کنند و اختلاف پتانسیل را توسط یک جفت الکترودهای پتانسیل اندازه‌گیری می‌نمایند.

اگر ρ در یک محیط همگن و ایزوتروپ اندازه‌گیری شود، آن را ρ_t یا مقاومت ویژه واقعی^{۳۱} می‌نامند. اما اگر اندازه‌گیری در یک محیط ناهمگن و غیر ایزوتروپ صورت گیرد، آن را ρ_a یا مقاومت ویژه ظاهری^{۳۲} می‌گویند. مقدار ρ_a تابعی از چند متغیر زیر می‌باشد:

- فواصل بین الکترودها
 - وضعیت هندسی آرایش الکترودها
 - مقاومت ویژه واقعی و خواص دیگری از قبیل ضخامت، شیب و خواص آنیزوتروپی^{۳۳} لایه‌ها.
- مقاومت ویژه یک هادی استوانه‌ای شکل از رابطه $\rho = \frac{R.s}{l}$ حاصل می‌شود که در آن R بر حسب اهم، s (سطح مقطع) بر حسب مترمربع، l (طول) بر حسب متر و ρ بر حسب اهم - متر بیان می‌شود. بنا به تعریف اهم - متر عبارتست از مقاومت ویژه یک هادی به سطح مقطع یک متر مربع و طول یک متر و مقاومت الکتریکی یک اهم. عکس مقاومت ویژه را هدایت ویژه الکتریکی می‌نامند و با σ نشان می‌دهند.
- اساس روش مقاومت ویژه، قانون اهم، که قانون حاکم بر جریان الکتریکی در زمین است، می‌باشد. این قانون در محیط همسانگرد و پیوسته، بصورت رابطه (۱-۲) بیان می‌گردد (کلر^{۳۴} و فرشنخت^{۳۵}، ۱۹۷۰):

$$\vec{j} = \sigma \vec{E} \quad (1-2)$$

در این رابطه، σ هدایت ویژه الکتریکی محیط (عکس مقاومت ویژه)، $\vec{j}$ چگالی جریان و $\vec{E}$ شدت میدان الکتریکی است. در عمل ما اختلاف پتانسیل الکتریکی را اندازه‌گیری می‌کنیم. رابطه بین شدت میدان الکتریکی و پتانسیل الکتریکی (φ) به صورت رابطه (۲-۲) بیان می‌شود:

$$E = -\nabla \varphi \quad (2-2)$$

از ترکیب روابط (۱-۲) و (۲-۲) داریم:

³¹ True Resistivity

³² Apparent Resistivity

³³ Anisotropy

³⁴ Keller

³⁵ Frischknecht

$$\vec{J} = -\sigma \nabla \varphi \quad (3-2)$$

رابطه چگالی جریان و جریان برای چشمه نقطه‌ای جریان عبارت است از:

$$\nabla \cdot \vec{J} = I \delta(x - x_s) \delta(y - y_s) \delta(z - z_s) \quad (4-2)$$

(x_s, y_s, z_s) محل چشمه نقطه‌ای است. از قرار دادن رابطه ۳-۲ در رابطه (۴-۲) خواهیم داشت:

$$-\nabla \cdot [\sigma \nabla \varphi] = I \delta(x - x_s) \delta(y - y_s) \delta(z - z_s) \quad (5-2)$$

رابطه (۵-۲)، معادله اساسی است که روش‌های زیادی برای حل آن وجود دارد. از حل این معادله، پتانسیل (φ) برای یک چشمه نقطه‌ای به دست می‌آید (رابطه ۶-۲) که در آن، r فاصله چشمه از نقطه اندازه‌گیری است (کلر و فرشخت، ۱۹۷۰):

$$\varphi = \frac{\rho I}{2\pi r} \quad (6-2)$$

۲-۲-۲- محاسبه مقاومت ویژه الکتریکی با چهار قطبی غیر مشخص

در شکل (۱-۲)، A و B دو الکتروستات فرستنده جریان، I، به زمین بوده و M و N دو الکتروستات مربوط به اندازه‌گیری اختلاف پتانسیل می‌باشند. نقاط M و N را می‌توان در سطح زمین به طور دلخواه روی خط AB و یا در خارج آن انتخاب نمود. به طور کلی اختلاف پتانسیل بین M و N از رابطه (۷-۲) حاصل می‌شود (کلاگری، ۱۳۷۱):

$$V_M - V_N = \Delta V = \frac{\rho I}{2\pi} \left(\frac{1}{r} - \frac{1}{r'} - \frac{1}{R} + \frac{1}{R'} \right) \quad (7-2)$$

با استفاده از رابطه (۷-۲) می‌توان با اندازه‌گیری I ، ΔV ، r ، r' و R و مقدار ρ را محاسبه نمود:

$$\rho = \frac{\Delta V}{I} \cdot \frac{2\pi}{\left(\frac{1}{r} - \frac{1}{r'} - \frac{1}{R} + \frac{1}{R'} \right)} \quad \text{یا} \quad \rho = \frac{\Delta V}{I} \cdot k \quad (8-2)$$

که در آن:


$$k = \frac{2\pi}{\frac{1}{r} - \frac{1}{r'} - \frac{1}{R} + \frac{1}{R'}} \quad (9-2)$$

در رابطه (۹-۲)، پارامتر k فقط تابعی از وضع قرارگیری چهار الکتروستات A، B، M و N نسبت به یکدیگر می‌باشد؛ به همین جهت آن را فاکتور هندسی سیستم اندازه‌گیری می‌نامند.

مقاومت ویژه‌ای که از رابطه (۹-۲) بدست می‌آید، متعلق به زمین همگن و ایزوتروپ است. حال اگر زمین غیر همگن و غیر ایزوتروپ باشد، از رابطه مذکور مقاومت ویژه ظاهری (ρ_a) بدست می‌آید و می‌توان نوشت:

$$\rho_a = \frac{\Delta V}{I} \cdot k \quad (۱۰-۲)$$

در صورت غیر همگن بودن زمین برای آرایش‌های مختلف چهارقطبی‌ها، مقدارهای مختلفی برای ρ_a بدست می‌آید. آرایش چهارقطبی‌ها و نحوه تغییر فواصل بین آنها، در اندازه‌گیری‌های مقاومت ویژه ظاهری دارای اهمیت اساسی می‌باشد و بسته به اینکه هدف از بکارگیری روش مقاومت ویژه، مشخص نمودن چگونگی تغییرات عمقی مقاومت ویژه ظاهری زمین و یا چگونگی تغییرات جانبی آن باشد، نحوه آرایش چهارقطبی‌ها متفاوت خواهد بود.



شکل ۲-۱- مدل فرضی زمین به همراه الکترودهای جریان A و B

۲-۲-۳- انواع آرایش الکترودی^{۳۶}

در این قسمت برخی از انواع مهم و پرکاربرد آرایش‌های الکترودی آورده شده است که با توجه به موضوع این تحقیق، به مطالعه و بررسی تفصیلی آرایش شلومبرژه و سونداژ الکتریکی قائم می‌پردازیم.

³⁶ Electrode Configuration

۱- آرایش و نر

۲- آرایش لی پارتیشنینگ

۳- آرایش شلومبرژه

۴- آرایش دایپل - دایپل (دو قطبی-دوقطبی)


۲-۳-۱- آرایش شلومبرژه

این آرایش از نوع آرایش‌های چهار الکترودی متقارن محسوب می‌شود. جریان از طریق دو الکتروده جریان A و B به درون زمین تزریق می‌شود و اختلاف پتانسیل ناشی از آن توسط دو الکتروده M و N اندازه‌گیری می‌گردد. الکترودهای جریان و پتانسیل به صورت متقارن نسبت به مرکز بین الکترودها، قرار می‌گیرند و داده اندازه‌گیری شده به زیر این نقطه مرکزی نسبت داده می‌شود.

در این آرایش، مطابق شکل (۲-۲)، هر چهار الکتروده در طول یک خط قرار می‌گیرند و طول AB نسبت به طول MN خیلی بزرگ‌تر انتخاب می‌شود؛ ولی باید توجه داشت که در عمل فاصله MN را نمی‌توان بیش از حد کوچک اختیار نمود، زیرا در این صورت اختلاف پتانسیل دو سر آن بسیار کوچک و اندازه‌گیری آن خیلی مشکل می‌شود؛ و بایستی طول آن را متناسب با طول AB اختیار نمود. در عمل معمولاً از نسبتی به شکل $5 \leq \frac{AB}{MN} \leq 10$ استفاده می‌کنند. در این روش فاصله MN ثابت نگه داشته می‌شود و بعد از هر بار اندازه‌گیری اختلاف پتانسیل، دوباره فاصله الکترودهای جریان یعنی طول AB را افزایش می‌دهند. در ازاء هر چند بار افزایش طول AB یک بار هم طول MN را افزایش می‌دهند. با توجه به شکل ذیل، می‌توان رابطه (۲-۱۱) را نوشت (تلفورد و همکاران، ۱۹۹۰):

$$r' = a + b \quad \text{و} \quad r = a - b \quad \text{و} \quad b = \frac{MN}{2} \quad \text{و} \quad a = \frac{AB}{2}$$

$$\Delta V = \frac{2\rho_a \cdot I}{\pi} \cdot \frac{b}{a^2 - b^2} \quad , \quad \rho_a = \frac{\Delta V}{I} \cdot \frac{a^2 - b^2}{2b} \cdot \pi \quad (۲-۱۱)$$



شکل ۲-۲- یک مدل زمین همگن با الکترودهای جریان A و B و الکترودهای پتانسیل M و N.

از آنجا که نحوه توزیع جریان تزریقی به زمین تحت تأثیر لایه‌های مختلف می‌باشد، مقاومت ویژه اندازه‌گیری شده را مقاومت ویژه ظاهری می‌نامیم. ارتباط بین مقاومت ویژه ظاهری و مقاومت واقعی بسیار پیچیده است. حال اگر این رابطه را با فرمول کلی محاسبه مقاومت ویژه ظاهری چهارقطبی‌ها یعنی $\rho_a = \frac{\Delta V}{I} \cdot k$ مقایسه نماییم، خواهیم دید که در آرایش شلومبرژه، طبق رابطه (۲-۱۲)، مقدار k برابر است با (تلفورد و همکاران، ۱۹۹۰):

$$k = \pi \frac{a^2 - b^2}{2b} \quad (۲-۱۲)$$

۲-۳-۲-۲- مزایا و معایب آرایش شلومبرژه

با توجه به اهمیت آرایش شلومبرژه، در زیر به برخی از مزایا و معایب این آرایش اشاره می‌کنیم:

- چون فاصله MN در آرایش شلومبرژه کمتر از آرایش‌های دیگر می‌باشد، اثر جریانهای تلوریک روی مقادیر اندازه‌گیری شده کمتر است.
- چون الکترودهای اندازه‌گیری اختلاف پتانسیل کمتر جابجا می‌شوند، تنها لازم است که الکترودهای جریان را جابجا کرد؛ این موضوع باعث صرفه جویی هزینه و وقت می‌شود.
- در این روش تأثیر تغییرات جانبی مقاومت ویژه را بطور قابل ملاحظه‌ای می‌توان حذف یا تا حدودی اندازه‌گیری کرده و اثر تغییرات سطحی و جانبی مقاومت ویژه را از تغییرات عمقی آن تفکیک نمود (تلفورد و همکاران، ۱۹۹۰).


- از معایب این آرایش مقادیر کوچک ΔV است که برای مقادیر کوچک MN حاصل می‌شود و برای اندازه-گیری احتیاج به دستگاه‌های با حساسیت بالا داریم؛ علاوه بر آن امکان افزایش خطا (نسبت به آرایش ونر) بیشتر است.
- در آرایش شلومبرژه می‌توان با یک طول ثابت AB مقادیر مقاومت ویژه ظاهری را برای دو طول MN اندازه‌گیری کرد. این اندازه‌گیری با دو مقدار کوچک و بزرگ MN در مطالعات سونداژ الکتریکی حائز اهمیت زیادی می‌باشد، زیرا از این طریق می‌توان به اثر تغییرات سطحی و جانبی روی الکترودهای MN پی‌برد و آن‌ها را از تغییرات عمقی مقاومت ویژه تفکیک کرد. این موضوع یکی از مزایای عمده روش شلومبرژه بر روش ونر است.
- عمق بررسی یا عمق مؤثر با آرایش شلومبرژه اندکی بیشتر از عمق بررسی با آرایه ونر و کمتر از آرایش دو قطبی - دو قطبی است (مونی، ۱۹۸۰).

۲-۳- هموارسازی^{۳۷} منحنی‌های مقاومت ویژه

با توجه به اینکه در آرایش شلومبرژه، در جاهایی که برای یک فاصله الکترودی جریان، دو قرائت برای اختلاف پتانسیل با فواصل مختلف الکترودهای پتانسیل داریم، منحنی دچار گسستگی‌هایی می‌شود شکل (۲-۳). چون در اینجا نقاط مربوط به هر MN را بهم وصل می‌کنیم، منحنی از چند قطعه^{۳۸} تشکیل می‌شود که هر کدام می‌تواند تفسیرهای متفاوتی در پی داشته باشند. بنابراین قبل از هر گونه تعبیر و تفسیر منحنی‌های مشاهده‌ای، این هموارسازی باید صورت گیرد تا به یک قطعه منحنی دست یابیم. اساس کار وصل کردن قطعات مختلف منحنی بوده که این منحنی نباید حالت شکستگی داشته باشد. معمولاً آخرین نقطه قطعات سمت چپ (MN کوچک‌تر) در نظر گرفته می‌شود؛ و اولین نقطه قطعات سمت راست (MN بزرگ‌تر) را در نظر نمی‌گیریم. همان‌طور که می‌دانیم برای تفسیر لازم است یک منحنی هموار داشته باشیم، لذا از آخرین نقطه قطعات سمت چپ طوری منحنی را به هم وصل می‌کنیم که شکل همواری حاصل شود (میلسون، ۲۰۰۲).

³⁷ Smoothing

³⁸ Segment



شکل ۲-۳- مثالی از وجود گسستگی روی منحنی سونداژ (راهنمای نرم افزار Resix-IP).

هنگام انطباق منحنی‌های سونداژ شلومبرژه با منحنی‌های تئوریک، این عدم پیوستگی در منحنی شلومبرژه یک مزیت نسبت به منحنی‌های پیوسته و نر محسوب می‌شود. چرا که اثر ناهماهنگی‌های جانبی در روی منحنی شلومبرژه را می‌توان با تغییر جزئی در بخش‌های مقطع از بین برد، در صورتی که چنین کاری را نمی‌توان با منحنی‌های سونداژ و نر انجام داد.

۲-۴- عمق تجسس^{۳۹} یا عمق نفوذ خطوط جریان

این عمق عمدتاً وابسته به قابلیت هدایت ویژه (σ) مربوط به زمین‌های سطحی است. اگر σ بزرگ باشد، خطوط جریان با کشش به طرف این تشکیلات در آن متمرکز شده و در نتیجه عمق تجسس ضعیف خواهد بود. بر عکس اگر زمین مقاومی یک لایه هادی را بپوشاند، خطوط جریان به طرف لایه هادی‌تر کشیده شده و سعی می‌کنند وارد آن شوند؛ در این حال عمق نفوذ از حالت قبل زیادتر است. در آرایش شلومبرژه

³⁹ Investigation Depth

برای شرایط متوسط اگر L طول خط فرستنده AB باشد، عمق تجسس تقریبی می‌تواند برابر $h = \frac{L}{4}$ در نظر گرفته شود. هر چقدر فاصله الکترودی AB بیشتر شود، مقدار بیشتری از جریان می‌تواند تا یک عمق معین نفوذ کند. رابطه زیر در این مورد صدق می‌کند که در آن z ، جریان موجود بین عمق صفر تا z بوده و It ، کل جریانی نفوذی به داخل زمین است (تلفورد و همکاران، ۱۹۹۰):

$$Iz / It = \frac{2}{\pi} \tan^{-1}(2z / AB) \quad (۲-۱۳)$$

۲-۵- سونداژ الکتریکی قائم^{۴۰}

همان‌گونه که قبلاً گفته شد، سونداژ الکتریکی قائم، روشی است که توسط آن تغییرات عمقی مقاومت ویژه لایه‌های زیرسطحی مورد مطالعه قرار می‌گیرد. از آرایش‌های الکترودی که در سونداژ الکتریکی به کار می‌روند می‌توان به آرایش شلومبرژه^{۴۱}، آرایش ونر^{۴۲} و آرایش دوقطبی - دوقطبی^{۴۳} اشاره کرد، که معمولاً دو نوع آرایش اول بیشتر از همه کاربرد دارند (تلفورد و همکاران، ۱۹۹۰).

اگر زمینی دارای یک سری لایه‌های افقی هموزن و ایزوتروپ باشد، یافته‌های VES فقط مبین تغییرات مقاومت ویژه نسبت به عمق می‌باشد. ولی در عمل یافته‌های VES تحت تأثیر ناهمگنی‌های عمودی و افقی مقاومت ویژه قرار می‌گیرند. از این رو اجرا، تعبیر و تفسیر و ارائه یافته‌های سونداژ باید طوری باشند که تغییرات افقی مقاومت ویژه به آسانی از تغییرات قائم قابل تشخیص باشند.

اساس این روش، صرف نظر از نوع آرایش به کار رفته، بدین ترتیب است که هرچقدر فاصله الکترودهای جریان از الکترودهای پتانسیل بیشتر شود، عمق تجسس افزایش خواهد یافت. در روش VES، فواصل الکترودها با توالی لگاریتمی، مرتباً افزایش یافته و مقادیر ρ_a به عنوان تابعی از فواصل الکترودها در روی کاغذهای لگاریتمی ترسیم می‌گردند و منحنی ρ_a حاصل را منحنی VES می‌نامند (تلفورد و همکاران، ۱۹۹۰).

⁴⁰ Vertical Electric Sounding

⁴¹ Schlumberger

⁴² Wenner

⁴³ Dipole-Dipole

۲-۵-۱- قابلیت ثبت یک لایه در سونداژ زنی

قابلیت ثبت یک لایه با مقاومت ویژه معین، به ضخامت نسبی آن بستگی دارد که بصورت نسبت ضخامت به عمق آن (h/z) تعریف می‌گردد. هر چقدر ضخامت نسبی یک لایه معین کمتر باشد، شانس ثبت شدن آن در روی منحنی سونداژ ژئوالکتریکی کمتر خواهد بود. در مدل‌های چهار لایه‌ای یا بیشتر باید ضخامت نسبی مؤثر یک لایه مورد بررسی قرار گیرد. ضخامت نسبی مؤثر، از رابطه زیر بدست می‌آید:

$$h_r = \frac{h_i}{\lambda \sum h_i} \quad (2-14)$$

یعنی، عبارتست از نسبت ضخامت لایه مورد نظر به حاصل ضرب آنیزوتروپ دروغین (آنیزوتروپی حاصله از جمع چند لایه مختلف) در ضخامت کل لایه‌های بالای آن لایه مورد نظر (تلفورد و همکاران، ۱۹۹۰).

۲-۵-۲- ضرایب آنیزوتروپی^{۴۴}

آنیزوتروپی مقاومت بدین معنی است که مقاومت ویژه در نقاط مختلف یک لایه متفاوت است، به عبارت دیگر مقاومت ویژه (f_t) در امتدادهای مختلف یک لایه، یعنی در جهت عرضی و در جهت عمقی (ρ_t) متغیر است. قابلیت هدایت متوسط عبارتست از متوسط هندسی σ_t و σ_l یعنی:

$$\sigma = \sqrt{\sigma_t \cdot \sigma_l} \quad (2-15)$$

و ضریب آنیزوتروپی λ بصورت زیر تعریف می‌شود:

$$\lambda = \sqrt{\frac{\sigma_l}{\sigma_t}} = \sqrt{\frac{\rho_t}{\rho_l}} \quad (2-16)$$

معمولاً در سنگ‌ها $\rho_t > \rho_l$ است. اگر $\rho_t = \rho_l$ باشد آنگاه لایه ایزوتروپ (همسانگرد) است و در آن $\lambda = 1$ خواهد بود (تلفورد و همکاران، ۱۹۹۰).

۲-۵-۳- اصل هم‌ارزی^{۴۵}

^{۴۴} Anisotropy

^{۴۵} Principal of Equivalence

اصل هم ارزی یا برابری مربوط به طبقات لایه‌ای است که بین لایه‌های مقاوم‌تر و یا هادی‌تر از خود قرار گرفته باشند. اگر یک لایه به ضخامت h و مقاومت ویژه ρ داشته باشیم که این لایه مقاوم‌تر از طبقات زیرین و رویی خود باشد، خطوط جریان تمایل دارند که کوتاه‌ترین فاصله را در داخل این لایه مقاوم طی کنند و بنابراین، این لایه خود را توسط مقاومت عرضی‌اش که عبارتست از حاصل ضرب مقاومت ویژه آن در ضخامت لایه، نشان می‌دهد:

$$R = \rho \cdot h \quad (2-17)$$

در عمل برای لایه‌ای که بین لایه‌های هادی‌تر از خود واقع شده است، منحنی‌های سونداژ الکتریکی در صورتیکه مقادیر R برای این لایه‌ها یکسان باشد، مشابه و یا بسیار نزدیک به هم هستند.

به همین ترتیب در صورتی که یک لایه هادی داشته باشیم که مقاومت ویژه آن از لایه‌های زیرین و رویی خود کمتر باشد، خطوط جریان تمایل دارند که بیشترین فاصله را در این لایه هادی طی کنند و بنابراین این لایه خود را توسط هدایت طولی (افقی) که عبارتست از حاصل ضرب قابلیت هدایت لایه در ضخامتش و یا نسبت ضخامت لایه به مقاومت ویژه لایه نشان می‌دهد. در اینجا نیز لایه‌های هادی مختلف (از نظر مقاومت و مقاومت ویژه) در صورتی که هدایت افقی‌شان یکسان باشند، روی منحنی‌های سونداژ الکتریکی تغییرات یکسانی را ارائه می‌دهند.

با توجه به مطالبی که ذکر گردید، تشخیص دو لایه مقاوم که دارای ضخامت‌ها و مقاومت ویژه‌های متفاوت ولی مقاومت‌های عرضی یکسانی هستند و نیز دو لایه هادی که دارای مقاومت ویژه‌ها و ضخامت‌های متفاوتی هستند ولی قابلیت هدایت افقی شان یکسان است، مشکل خواهد بود. این موضوع همانطور که ذکر شد بنام اصل برابری یا اصل هم ارزی طبقات خوانده می‌شود.

۲-۵-۴- اصل اختفاء


هرگاه مقاومت ویژه یک لایه بین مقادیر مقاومت ویژه لایه‌های مجاورش باشد تا زمانی که ضخامت این لایه مقدار کمی است، روی منحنی سونداژ الکتریکی اثر آن را نمی‌توان رویت کرد. در واقع مانند این است که لایه اثر خود را مخفی کرده باشد. به همین دلیل به آن اصل اختفاء می‌گویند. حال در صورتی که ضخامت لایه

رو به افزایش گذارد، در صورتی که مشخصات سایر لایه‌ها ثابت باقی بماند، اثر حقیقی این لایه روی منحنی سونداژ الکتریکی بیشتر و بارزتر می‌گردد.

در مطالعه منابع آب‌های زیرزمینی از طریق ژئوالکتریک، اغلب با این مسأله برخورد می‌شود، زیرا معمولاً مقاومت ویژه لایه بالای سطح آب زیرزمینی که از آبرفت‌های خشک تشکیل شده است، زیاد بوده و لایه زیر سطح آب زیرزمینی که از آبرفت‌های آبدار تشکیل شده، مقاومتش از لایه رویی کمتر بوده و دارای مقاومت ویژه متوسطی است. بالاخره سنگ کف که غالباً رسی و با مقاومت کم است باعث می‌شود که لایه وسطی در صورتی که ضخامتش کم باشد، اثری روی منحنی سونداژ الکتریکی منعکس نکند که این خود مطالعه و تشخیص عمق سنگ کف را مشکل می‌سازد.

۲-۶- انواع حالات موجود در یک زمین هموار با چهار لایه افقی


شکل منحنی‌های سونداژ حاصله در محیط افقی، تابعی از مقاومت ویژه و ضخامت لایه‌های مختلف زیرسطحی و همین‌طور آرایش الکترودها می‌باشد. فرض کنیم یک زمین هموار با چهار لایه افقی مطابق شکل (۲-۴) داریم؛ با توجه به اینکه مقاومت ویژه این لایه‌ها (ρ_i) از نظر اندازه نسبت به هم چگونه باشند، ۴! یا ۲۴ حالت مختلف خواهیم داشت که این حالات در مجموع به ۸ نوع منحنی مختلف تقسیم‌بندی می‌شوند که عبارتند از HA، HK، QH، QQ، KQ، KH، AK، AA.



شکل ۲-۴- نمایی شماتیک از یک زمین هموار با چهار لایه افقی.

۲-۶-۱- منحنی نوع AA


در این حالت بین مقاومت ویژه لایه‌ها رابطه $\rho_1 \langle \rho_2 \langle \rho_3 \langle \rho_4$ برقرار است که فقط شامل ۱ حالت بوده و لایه‌بندی حاصل از آن مطابق شکل (۵-۲) خواهد بود.



شکل ۵-۲- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع AA.

۲-۶-۲- منحنی نوع AK


در این حالت بین مقاومت ویژه لایه‌ها رابطه $\rho_1 \langle \rho_2 \langle \rho_3 \rangle \rho_4$ برقرار است که خود شامل ۳ حالت بوده و لایه‌بندی حاصل از آنها مطابق شکل (۶-۲) خواهد بود.



شکل ۶-۲- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع AK.


۲-۶-۳- منحنی نوع KH

در این حالت بین مقاومت ویژه لایه‌ها رابطه $\rho_1 \langle \rho_2 \rangle \rho_3 \langle \rho_4$ برقرار است که خود شامل ۵ حالت بوده و لایه‌بندی حاصل از آنها مطابق شکل (۷-۲) خواهد بود.




۲-۶-۴- منحنی نوع KQ

در این حالت بین مقاومت ویژه لایه‌ها رابطه $\rho_1 \langle \rho_2 \rangle \rho_3 \langle \rho_4$ برقرار است که خود شامل ۳ حالت بوده و لایه‌بندی حاصل از آنها مطابق شکل (۸-۲) خواهد بود.



۲-۶-۵- منحنی نوع QQ


در این حالت بین مقاومت ویژه لایه‌ها رابطه $\rho_1 \rangle \rho_2 \rangle \rho_3 \rangle \rho_4$ برقرار است که فقط شامل ۱ حالت بوده و لایه‌بندی حاصل از آن مطابق شکل (۹-۲) خواهد بود.



شکل ۲-۹- نمایش شماتیک لایه‌بندی مربوط به منحنی

۲-۶-۶- منحنی نوع QH


در این حالت بین مقاومت ویژه لایه‌ها رابطه $\rho_1 \rangle \rho_2 \rangle \rho_3 \rangle \rho_4$ برقرار است که خود شامل ۳ حالت بوده و لایه‌بندی حاصل از آنها مطابق شکل (۲-۱۰) خواهد بود.



شکل ۲-۱۰- نمایش شماتیک لایه‌بندی مربوط به منحنی نوع QH.

۲-۶-۷- منحنی نوع HK

در این حالت بین مقاومت ویژه لایه‌ها رابطه $\rho_1 \rangle \rho_2 \rangle \rho_3 \rangle \rho_4$ برقرار است که خود شامل ۵ حالت بوده و لایه‌بندی حاصل از آنها مطابق شکل (۲-۱۱) خواهد بود.




$$\rho_4 \langle \rho_2 \langle \rho_3 \langle \rho_1 - 3$$

$$\rho_2 \langle \rho_4 \langle \rho_3 \langle \rho_1 - 4$$

$$\rho_2 \langle \rho_1 \langle \rho_4 \langle \rho_3 - 5$$

۲-۶-۸- منحنی نوع HA

در این حالت بین مقاومت ویژه لایه‌ها رابطه $\rho_1 \langle \rho_2 \langle \rho_3 \langle \rho_4$ برقرار است که خود شامل ۳ حالت بوده و لایه‌بندی حاصل از آنها مطابق شکل (۲-۱۲) خواهد بود.



شکل ۲-۱۲- نمایش شماتیک لایه‌بندی مربوط به منحنی HA

پس از آشنایی کلی با روش مقاومت ویژه و انواع حالات موجود در یک زمین چهار لایه، در فصل بعدی به قابلیت‌های شبکه‌های عصبی مصنوعی پرداخته شده و عوامل موثر در طراحی آنها آورده می‌شود.

فصل سوم

مقدمه ای بر شبکه های عصبی مصنوعی

۳-۱- مقدمه

در طبیعت رابطه بین اطلاعات و پردازشگرها بر خلاف روش های کلاسیک یک ارتباط مستقل و مجزا نیست، بلکه عموماً ارتباط هایی تنگاتنگ و وابسته است. بین یک پردازشگر، مثل انسان، و اطلاعات، همواره

می‌توان نوعی از ارتباط و وابستگی را مشاهده کرد. مغز انسان علاوه بر پردازش اطلاعات، روابط بین آن‌ها را ذخیره‌سازی کرده و فرآیند یادگیری را صورت می‌دهد. تحقیقات زیادی بر روی نحوه یادگیری مغز انسان، همانند یادگیری زبان و درک احساسات، انجام شده است. هدف نهایی این تحقیقات، ساخت ماشین هوشمندی بوده است که رفتار مغز انسان را که از بیلیون‌ها نرون تشکیل شده است، تقلید کند؛ اطلاعات را پردازش کرده، دانش موجود در آن‌ها را استخراج کند و به اصطلاح یاد بگیرد (فهیمی، ۱۳۷۹).

در تلاش برای خلق چنین ماشین هوشمندی، دانش هوش مصنوعی^{۴۶} بر اساس تئوری‌های مربوطه شکل گرفته است. هوش مصنوعی علم شبیه‌سازی هوش انسان، با بهره‌گیری از رایانه است؛ هوش مصنوعی به معنای استخراج هوش، دانش، الگوریتم یا نگاشت از دل محاسبات عددی بر اساس آرایه به روز داده‌های عددی است. این علم به شاخه‌های مختلفی تقسیم شده است. شاخه‌های مهم و اساسی هوش مصنوعی، شبکه‌های عصبی مصنوعی (محاسبات نرونی)، منطق فازی (محاسبات تقریبی) و الگوریتم ژنتیک (محاسبات ژنتیکی) است که هر یک به نوعی مغز را الگو قرار داده‌اند. سیستم‌های خبره^{۴۷}، سیستم‌های مبتنی بر دانش^{۴۸} و یادگیری قیاسی نیز شاخه‌های فرعی‌تر هوش محاسباتی هستند (منهاج، ۱۳۷۴).

در این پژوهش از شبکه‌های عصبی مصنوعی، به عنوان یک ابزار توانمند در مدل‌سازی و تفسیر داده‌های سونداژ ژئوالکتریک استفاده شده است. از این رو در این فصل به شرح مختصر این شبکه‌ها و چگونگی عملکرد آن در پردازش داده‌ها برای استفاده در فصل‌های بعدی پرداخته می‌شود.

۳-۲- شبیه سازی عملکرد سیستم عصبی

مغز انسان یک سیستم پردازش اطلاعات با ساختار موازی و کاملاً پیچیده است که دو درصد وزن بدن را تشکیل می‌دهد و بیش از بیست درصد اکسیژن بدن را به مصرف می‌رساند؛ این مغز شامل بیلیون‌ها سلول عصبی است که نرون نامیده می‌شود. شکل (۳-۱) ساختار یکی از این سلول‌های عصبی را نشان می‌دهد. عامل هوشمندی انسان در واقع شبکه پیچیده همین نرون‌ها است. هر نرون به تنهایی هوشمند نیست، اما وقتی گروهی از آن‌ها در کنار هم قرار می‌گیرند، توانایی‌های شگفت انگیز مغز مانند خواندن، تفکر، سخن


⁴⁶ Artificial Intelligence

⁴⁷ Expert Systems

⁴⁸ Knowledge-based Systems

گفتن؛ دیدن و کلیه اعمال آگاهانه و بسیاری از رفتارهای ناخودآگاه را موجب می‌شوند. دانشمندان علم بیولوژی دریافته‌اند که عملکرد نرون‌های بیولوژیک از قبیل ذخیره سازی و حفظ اطلاعات، در خود نرون‌ها و ارتباطات بین آنها نهفته است. به بیان دیگر، آنچه یادگیری نامیده می‌شود، ایجاد ارتباطات جدید بین نرون‌ها و تنظیم مجدد ارتباطات آنها است.

در سیستم عصبی ارتباط نرون‌ها با یکدیگر زیاد است. نرون‌ها با هزاران نرون دیگر مرتبط هستند. ارتباط بین نرون‌ها، سیناپس نامیده می‌شود. هر نرون از طریق سیناپس‌ها، پالس‌های الکتروشیمیایی به سایر نرون‌ها می‌فرستد. شواهد نشان می‌دهد که تغییرات در غلظت سیناپتیکی اساس حافظه یادگیری است (Lee and Sterling, 1992).




شکل ۳-۱- ساختار یک سلول عصبی (منهاج، ۱۳۷۴).

همان‌طور که گفته شد، شبکه عصبی مصنوعی (ANNs) یکی از شاخه‌های هوش مصنوعی است که تلاش می‌کند رفتار سیستم عصبی در مغز انسان را شبیه‌سازی کند. یک ساختار ایده‌آل ANNs شامل یک تعداد المان پردازش^{۴۹} به نام نرون^{۵۰} است که معمولاً در یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان قرار می‌گیرند. نرون‌های مورد استفاده در ANNs، شکل بسیار ساده‌ای از نرون‌های بیولوژیکی هستند؛ شکل (۲-۳) چگونگی شبیه‌سازی کارکرد یک سلول عصبی در یک واحد پردازش ANNs را نشان می‌دهد. مشابه با نرون‌های سیستم عصبی، بعضی از این نرون‌ها اطلاعات را از محیط خارج دریافت می‌کنند (نرون‌های لایه ورودی)، تعدادی دیگر اطلاعات را منتشر می‌کنند (نرون‌های لایه میانی) و تعدادی دیگر نتایج را تولید می‌کنند. این نرون‌ها یا عناصر پردازش از طریق وزن‌های ارتباطی خود، که در مرحله یادگیری اصلاح و تنظیم می‌شوند، تغییر هدایت سیناپتیکی عصبی را شبیه‌سازی می‌کنند.

⁴⁹ Processing element

⁵⁰ Node



شکل ۳-۲- روند شبیه سازی کارکرد یک سلول عصبی.

۳-۳- تاریخچه کاربرد شبکه های عصبی مصنوعی

پیش زمینه شبکه های عصبی به اواخر قرن نوزدهم و اوایل قرن بیستم بر می گردد. نخستین کاربرد عملی ANNs توسط فرانک روزنبلات^{۵۱} در سال ۱۹۵۸ انجام شد. روزنبلات و همکارانش شبکه ای ساختند که قادر بود الگوها را از هم تشخیص دهد. فعالیت در زمینه شبکه های عصبی در دهه ششم قرن بیستم در مقیاس با دهه هشتم به علت عدم بروز ایده های جدید و نبود کامپیوترهای سریع جهت پیاده سازی آنها، کمرنگ شد؛ اما در خلال دهه هشتم و رشد تکنولوژی میکروپروسسورها روند صعودی داشت و ایده های جدیدی مطرح شدند. این زایش دوباره شبکه های عصبی به دو نگرش جدید در این زمینه بر می گردد؛ یکی استفاده از مکانیسم تصادفی جهت توضیح عملکرد یک طبقه وسیع از شبکه های برگشتی^{۵۲} که در آنها جهت ذخیره سازی اطلاعات استفاده می شد، بود. این ایده توسط جان هاپفیلد^{۵۳} فیزیکدان مشهور آمریکایی در سال ۱۹۸۲ مطرح شد. وی با انتشار مقالات خود دانشمندان زیادی را به تحقیق پیرامون ANNs تشویق کرد. نگرش دیگر

⁵¹ Frank Rosenblatt


⁵² Feed back Recurrent

⁵³ John Hopfield

که کلید توسعه شبکه‌های عصبی شد، الگوریتم پس انتشار خطا^{۵۴} بود. رامل هارت و مک‌لند در سال ۱۹۸۵ با انتشار کتاب توزیع پردازش موازی^{۵۵} و ارائه این الگوریتم یادگیری و تربیت شبکه‌های عصبی چند لایه، تحولی در تحقیقات ANNs پدید آوردند که همچنان ادامه دارد (منهاج، ۱۳۷۴).

۳-۴- مبانی شبکه‌های عصبی مصنوعی

همان طور که گفته شد، شبکه‌های عصبی مصنوعی با استفاده از یک پایگاه داده آموزش می‌بینند و به شیوه‌ای بردار وزن خود را تغییر می‌دهند تا بتوانند ارتباط بین متغیرهای ورودی مدل با خروجی‌های متناظر آن را تشخیص دهند. فلسفه مدل‌سازی شبکه عصبی از این جهت که بر اساس یک دسته ورودی و خروجی سعی در تشخیص رابطه بین آن‌ها دارد، شبیه برخی از روش‌های مرسوم آماری است؛ در مدل ANNs بردار وزن w را می‌توان معادل شیب خط، $\tan \phi$ ، و مقدار آستانه‌ای θ را برابر با عرض از مبدأ β در مدل رگرسیون خطی در نظر گرفت (شکل ۳-۳). شبکه‌های عصبی مصنوعی مقادیر وزن خود را با تکرار و ارائه مثال‌های آموزشی شامل ورودی‌های مدل و خروجی‌های آن، طوری تنظیم می‌کند که تابع خطای بین خروجی‌های واقعی و خروجی‌های پیش‌بینی شده توسط مدل ANNs، کمینه شود.



شکل ۳-۳- مدل رگرسیون خطی با پارامترهای مربوطه (Hubick, 1992).

⁵⁴ Error Back-Propagation

⁵⁵ Parallel Distributed Processing

در دنیای واقعی، رابطه بین x و y ها همیشه خطی نیست؛ بلکه امکان مواجهه با مسائل پیچیده و غیر خطی، زیاد است. در چنین مواردی تحلیل‌های رگرسیونی، در صورتی امکان موفقیت دارند که دانش اولیه‌ای درباره طبیعت غیر خطی مسأله موجود باشد. در مقابل چون یک مدل شبکه عصبی دانش موجود در الگوهای یادگیری را استخراج می‌کند، برای ساخت یک مدل ANNs، نیازی به هیچ دانش اولیه‌ای در مورد مسأله نداریم؛ همچنین در مدل‌های شبکه عصبی درجه غیرخطی بودن رابطه را می‌توان با تغییر تابع انتقال و تعداد نرون‌های لایه میانی تغییر داد؛ به علاوه، مدل‌های ANNs قابلیت ارتقاء از حالت یک متغیره به چند متغیره را دارند. تمامی این موارد قدرت انعطاف‌پذیری مدل‌های ANNs را در مواجهه با این گونه مسائل نشان می‌دهند (Hubick, 1992).

۳-۵- ساختار شبکه‌های عصبی مصنوعی

تمام شبکه‌های عصبی حداقل در سه مولفه اصلی زیر مشترک بوده و می‌توان گفت که در واقع این موارد، جزء سازنده‌های اصلی شبکه‌های عصبی مصنوعی هستند (منهاج، ۱۳۷۴).

۱- نرون

۲- وزن‌های ارتباطی (w_{ij})

۳- لایه‌های مجزایی که شامل نرون‌ها بوده و توسط وزن‌ها به هم مرتبط می‌شوند.


نرون‌ها به عنوان واحدهای محاسباتی پایه، اساس عملکرد شبکه‌ها را تشکیل می‌دهند. همان طور که گفته شد، یک مدل ANNs مجموعه‌ای از عناصر پردازش است که در قالب چند لایه با اتصالاتی با یکدیگر در ارتباط هستند. شکل (۳-۴) ساختار یک عنصر پردازش مدل ANNs، نرون، را نشان می‌دهد؛ خروجی هر نرون از لایه قبلی، x_i ، در مقادیر وزن هر اتصال، w_{ij} ، ضرب می‌شود؛ در هر نرون، مولفه‌های وزن‌یافته با یکدیگر جمع می‌شوند و حد آستانه‌ای^{۵۶}، θ_j ، به آن‌ها اضافه می‌شود. این مقدار ترکیبی، I_j ، با عبور از نرون تحت یک تابع

⁵⁶ Threshold value

انتقال (تابع محرک^{۵۷})، خروجی نرون، y_i ، را تولید می‌کند. خروجی این نرون، ورودی نرون‌های لایه بعدی محسوب می‌شود. این فرآیند در معادلات (۱-۳) و (۲-۳) نشان داده شده است.

$$(۱-۳) \quad I_j = \sum w_{ij} x_i + \theta_j \quad \text{summation}$$

$$(۲-۳) \quad y_j = f(I_j) \quad \text{transfer}$$



شکل ۳-۴- ساختار یک نرون شبکه عصبی و پارامترهای مربوط به آن (راهنمای نرم افزار MATLAB، ۲۰۰۷).
در مورد عملکرد شبکه، جمع وزنی ورودی‌ها به هنگام عبور از تابع محرک با آستانه تابع مقایسه می‌شود، چنانچه این جمع وزنی از مقدار آستانه فراتر رود، نرون فعال می‌شود و چنانچه این مقدار کمتر از آستانه باشد، نرون غیر فعال باقی می‌ماند.

۳-۶- توابع انتقال

وظیفه تابع انتقال، انتقال مقادیر ورودی یک نرون به نرون دیگر است. این تابع می‌تواند خطی یا غیرخطی باشد. یک تابع انتقال بر اساس نیاز مسأله انتخاب می‌شود. از انواع مختلف این توابع می‌توان به موارد ذیل اشاره کرد:

- تابع آستانه‌ای دو مقداره حدی: این تابع دارای دو خروجی حدی ۰ یا ۱ است.
- تابع آستانه‌ای دو مقداره متقارن: این تابع دارای دو خروجی حدی ۱ و -۱ است.
- تابع خطی: خروجی این تابع برابر ورودی آن است.

⁵⁷ Transfer function


- تابع سیگموئیدی^{۵۸}: این تابع S شکل و مشتق پذیر بوده و نقش مهمی در شبکه های عصبی دارد.
- تابع تانژانت هیپربولیک: این تابع نیز دارای کاربرد زیادی در شبکه های عصبی است.

۳-۷- معماری شبکه های عصبی مصنوعی

نوع معماری شبکه در آموزش و عملکرد آن نقش بسزایی دارد. در یک نگاه کلی، دو نوع معماری متفاوت در شبکه ها وجود دارد؛ که بر مبنای جهت جریان اطلاعات در آنها می باشد.

▪ شبکه های پیش خور^{۵۹}

در این شبکه ها، نرون ها، ورودی خود را تنها از لایه قبلی دریافت می کنند و خروجی خود را تنها به لایه بعدی منتقل می کنند. نرون های لایه ورودی، هیچ محاسبه ای بر روی بردار ورودی ها انجام نمی دهند و خروجی این لایه به عنوان ورودی به اولین لایه میانی منتقل می شود و به همین ترتیب اطلاعات در لایه های بعدی منتشر می شوند تا به گره خروجی برسد. اگر هر نرون در هر لایه کاملاً به تمام نرون های لایه بعدی متصل باشد، شبکه دارای اتصال کامل است؛ و در صورت حذف بعضی از اتصالات، شبکه دارای اتصال نسبی است. شکل (۳-۵) یک شبکه پیش خور را نشان می دهد (منهاج، ۱۳۷۴).



شکل ۳-۵- ساختار یک شبکه پیش خور (راهنمای نرم افزار MATLAB، ۲۰۰۷).

▪ شبکه های پس خور یا بازگشتی^{۶۰}

در شبکه های پس خور، حداقل یک سیگنال برگشتی از یک نرون به همان نرون یا نرون های همان لایه و یا لایه قبل استفاده می شود (منهاج، ۱۳۷۴). برای نمونه، یک شبکه بازگشتی هاپفیلد^{۶۱}، ممکن است در یک


⁵⁸ Sigmoidal function

⁵⁹ Feed forward

⁶⁰ Feed back or Recurrent

⁶¹ Hopfield

لایه از نرون‌ها، خروجی خود را به عنوان ورودی به تمامی نرون‌های دیگر بازگرداند. نوع دیگری از شبکه بازگشتی، شبکه‌المان^{۶۲} است که در آن خروجی نرون‌های لایه میانی با یک تأخیر زمانی به نرون‌های لایه ورودی بازگردانده می‌شود (شکل ۳-۶).



شکل ۳-۶- ساختار یک شبکه پس‌خور یا برگشتی (راهنمای نرم افزار MATLAB، ۲۰۰۷).

۳-۸- آموزش شبکه‌های عصبی مصنوعی

از آن‌جا که ارتباط بین ورودی‌ها و خروجی‌ها کاملاً مشخص نیست، به پروسه یادگیری نیاز است. فرآیند انتقال اطلاعات در ANNs از لایه اول که ورودی آن داده‌های اصلی هستند، آغاز می‌شود. شبکه، مقادیر بردارهای وزن خود را در حین ارائه دسته داده‌های آموزشی^{۶۳} و با استفاده از یک قانون یادگیری، طوری تنظیم می‌کند که با کمترین خطای ممکن، رابطه بین خروجی‌ها و ورودی‌های الگوهای آموزشی را تشخیص دهد. این فرآیند را مرحله یادگیری^{۶۴} یا آموزش^{۶۵} شبکه می‌نامند.


برای آموزش شبکه عصبی ترتیبی وجود دارد که در شکل (۳-۷) مشاهده می‌شود. ابتدا داده‌ها به شبکه داده می‌شوند و خروجی با توجه به داده‌ها محاسبه می‌گردد. از مقایسه خروجی شبکه و مقدار واقعی خطایی به دست می‌آید که از آن برای تنظیم وزن‌ها استفاده می‌شود. این پروسه با استفاده از همه داده‌های آموزش تکرار می‌شود تا اینکه شبکه به مقدار همگرایی لازم برسد. در شبکه‌های عصبی، طراح شبکه نمی‌تواند خیلی از پارامترهای سیستم را تعیین کند. بلکه این پارامترها به طور اتوماتیک از داده‌های ورودی و جواب‌های مطلوب به وسیله الگوریتم آموزشی به دست می‌آیند (Principe et al, 1999).

⁶² Elman

⁶³ Training data set

⁶⁴ Learning

⁶⁵ Training



شکل ۳-۷- فرآیند آموزش شبکه عصبی مصنوعی (Principe et al, 1999).

۳-۸-۱- انواع شبکه های عصبی براساس روش یادگیری

به طور کلی شبکه های عصبی بسته به چگونگی آموزش و بر مبنای نحوه یادگیری به چند دسته تقسیم می شوند.

▪ شبکه های دارای یادگیری با ناظر^{۶۶}

در یادگیری با ناظر فرض بر این است که در هر مرحله از تکرار الگوریتم یادگیری، جواب مطلوب سیستم یادگیرنده از قبل آماده است؛ به عبارتی الگوریتم یادگیری به جواب واقعی و مطلوب دسترسی دارد. در این روش یادگیری، الگوهای خروجی مطلوب با خروجی محاسبه شده توسط شبکه با عنوان خروجی واقعی^{۶۷}، مقایسه می شود و اختلاف بین آن ها می بایست با تغییر پارامترهای شبکه (وزن و بایاس) جبران شود. نحوه تغییر پارامترهای شبکه، توسط نوع الگوریتم آموزشی^{۶۸}، تعیین می گردد. در این حالت خطای کلی شبکه از رابطه (۳-۸) به دست می آید (منهاج، ۱۳۷۴).

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{N=1}^N (y_i - t_i)^2 \quad (3-3)$$

که در آن E خطای کلی شبکه، P تعداد الگوهای آموزشی، t_i خروجی واقعی، y_i خروجی شبکه در نرون i و N تعداد نرون های خروجی است. بر اساس خطای محاسبه شده، وزن های شبکه آنقدر تغییر داده می شوند تا اختلاف خروجی شبکه و خروجی مطلوب به حداقل مورد نظر برسد.

⁶⁶ Supervised Learning

⁶⁷ Actual Output

⁶⁸ Learning Algorithm

▪ شبکه های دارای یادگیری بدون ناظر^{۶۹}

در یادگیری بدون ناظر، بردار آموزش دهنده وجود ندارد و وزن ها فقط بر اساس ورودی ها اصلاح می شوند. به عبارت دیگر جواب مطلوب برای سیستم یادگیرنده موجود نیست و دسترسی به خطای یادگیری جهت بهبود رفتار سیستم یادگیرنده وجود ندارد. در این جا چگونگی ارتباط بین نرون ها اعم از ارتباط داخلی بین نرون های یک لایه با نرون های لایه های مختلف و نحوه یادگیری، نوع شبکه را مشخص می کند. به یادگیری بدون ناظر، خود یادگیری^{۷۰} هم می گویند.

قوانینی که در این دسته قرار می گیرند، در پاسخ به ورودی شبکه و با کشف همبستگی و خواص آماری بین ورودی های مختلف، وزن های شبکه را اصلاح می کنند و باعث تفکیک دسته ها و یا کلاس های مختلف از یکدیگر می شوند. در بکارگیری این نوع قوانین یادگیری، دو فرض باید در نظر گرفته شود: یکی اینکه تمام الگوهای ورودی که دارای ویژگی مشترکی هستند، در یک کلاس قرار می گیرند و دیگر اینکه شبکه باید قادر باشد ویژگی های مشترک را تنها با استفاده از ورودی ها کشف کند.

۳-۸-۲- توقف آموزش

همان طور که قبلاً گفته شد، هدف فاز آموزش، کاستن مقدار خطا از طریق تعدیل اوزان می باشد. لذا در خلال آموزش خطا باید کاهش یابد و آموزش زمانی متوقف خواهد شد که خطا به مقدار معینی که از قبل مشخص شده است، برسد. مطلوب آن است که خطا حتی الامکان کاهش یابد، اما به هر حال تجربه نشان می دهد که یک شبکه نمی تواند به همان خوبی که بر روی مجموعه آموزش عمل می کند، بر روی مجموعه آزمایش^{۷۱} کار کند. این پدیده را آموزش مبالغه ای^{۷۲} گویند و گفته می شود که شبکه بر روی داده های آموزش، فوق العاده منطبق شده است. حال این سوال پیش می آید که چگونه با اجتناب از آموزش مبالغه ای زمان توقف آموزش را تشخیص دهیم؟ راهکار پاسخ به این سوال این است که مجموعه داده ها را به جای دو مجموعه به

⁶⁹ Unsupervised Learning

⁷⁰ Self-Learning

⁷¹ Test

⁷² Over Learning

سه مجموعه تقسیم نماییم. به این مجموعه‌ها، مجموعه آموزش^{۷۳}، مجموعه آزمون^{۷۴} و مجموعه اعتبارسنجی^{۷۵} گفته می‌شود. آموزش شبکه با به کارگیری مجموعه آموزش آغاز می‌شود. در خلال آموزش شبکه، داده‌های مجموعه آزمون نیز به شبکه نشان داده می‌شوند و مقدار خطا ثبت می‌شود. وقتی که مجموعه آزمون به شبکه نشان داده می‌شود، اوزان تعدیل نمی‌شوند و تعدیل اوزان تنها پس از ارائه مجموعه آموزش و به وسیله پس انتشار صورت می‌گیرد.

در طول فرآیند آموزش، میزان خطای بین خروجی نرم‌افزار و خروجی واقعی باید کاهش یابد. خطای ناشی از نشان دادن داده‌های آزمون نیز باید پایین بیاید؛ از طرفی مقدار خطای ناشی از ارائه مجموعه آزمون، بزرگ‌تر از میزان خطایی است که از نشان دادن مجموعه آموزش به وجود می‌آید. در نقطه‌ای از آموزش، مقدار خطای مجموعه آزمون از کاهش یافتن باز می‌ماند و حتی ممکن است شروع به بالا رفتن کند. این همان نقطه‌ای است که از آن به بعد آموزش مبالغه‌ای آغاز شده و شبکه شروع به انطباق بیش از حد با مجموعه آموزش می‌نماید. بنابراین در نقطه‌ای که از آنجا خطای مجموعه آزمون شروع به بالارفتن می‌کند، آموزش متوقف شود، و از آموزش مبالغه‌ای اجتناب می‌گردد. پس از آنکه آموزش شبکه متوقف شد، مجموعه تعیین اعتبار به شبکه نشان داده می‌شود که شامل داده‌هایی است که تا به حال به شبکه ارائه نشده‌اند (غضنفری و ارکات، ۱۳۸۳).

۳-۸-۳- قابلیت تعمیم شبکه های عصبی مصنوعی

یک شبکه توانایی تعمیم خوبی دارد، اگر برای الگوهای ارزیابی (بخشی از داده‌های الگوی یادگیری که در تغییر وزن‌های شبکه دخالت داده نمی‌شوند) نیز مقدار خروجی صحیحی به دست آورد. پروسه یادگیری یا به عبارتی تعمیم یک شبکه عصبی را می‌توان به عنوان یک سیستم که عمل درون‌یابی غیرخطی را به خوبی انجام می‌دهد، نگریست. به زبان ریاضی اگر زوج (x, y) متعلق به داده‌های یادگیری باشند و شبکه بر اساس این داده‌ها یاد گرفت که به ازای هر ورودی x ، خروجی y را تولید کند، آنگاه برای حالتی که به شبکه ورودی $x + \Delta x \rightarrow \Delta x \ll 1$ اعمال شود، خروجی حاصله حول و حوش y قرار گیرد (منهاج، ۱۳۷۴).

⁷³ Train Set

⁷⁴ Test Set

⁷⁵ Validation Set

۳-۹- تعداد الگوهای یادگیری

یکی از مواردی که در هنگام ساخت شبکه عصبی بایستی مشخص شود، مجموعه آموزشی آن است (مجموعه آموزشی شامل تعدادی از موارد تحقق یافته است که مقادیر جواب هر یک از آن‌ها معلوم است) که باید مبنای الگوی یادگیری شبکه قرار گیرد. به طور کلی هر چه تعداد متغیرهای ورودی بیشتر شود، الگوی یادگیری پیچیده‌تر شده و نیاز به داده‌های آموزشی بیشتر است تا دقت شبکه برای یافتن الگوی مناسب داده‌ها در حد مطلوب باقی بماند. به طور سرانگشتی حداقل ده تا بیست مثال آموزشی با پوشش کافی دامنه تغییرات بالا، برای هر سری از داده‌های ورودی لازم است. از آنجایی که شبکه عصبی به صورت درونی عمل می‌کند، نه برون‌یابی، لازم است الگوهای یادگیری طوری ارائه شوند که مرزهای محدوده مسأله را در تمام ابعاد شامل شوند، به عبارت دیگر شکل محدوده مسأله باید با محدوده یادگیری هماهنگ باشد. به علاوه، خروجی‌های مجموعه آموزشی نیز باید تمام مقادیر ممکن را پوشش داده و حتی‌الامکان به صورت نرمال توزیع شده باشند. از سوی دیگر تعداد نمونه آموزشی رابطه مستقیمی با پارامترهای قابل تنظیم شبکه (وزن و مقدار آستانه‌ای) دارد؛ مثلاً یک شبکه سه لایه با ساختار ۱-۲-۱ هفت پارامتر و یک شبکه ۱-۷-۱ دارای ۲۲ پارامتر قابل تنظیم است؛ با این حساب یک مجموعه شامل ۸ مثال آموزشی، خروجی شبکه اول را با خطای کمتری به دست خواهد آورد، چرا که یک شبکه در صورتی قابلیت تعمیم خواهد داشت که تعداد پارامترهای قابل تنظیم شبکه حتماً کمتر از تعداد مثال‌های مجموعه باشد. به عنوان یک قاعده کلی اگر L تعداد پارامترهای قابل تنظیم شبکه و e خطای قابل قبول شبکه در تخمین مقدار خروجی باشد، تعداد نمونه آموزشی برابر است با

$$N \geq \frac{L}{e} \quad (\text{منهاج، ۱۳۷۴}).$$

۳-۱۰- توزیع مقادیر الگوها

علاوه بر اهمیت تعداد الگوهای یادگیری، توزیع مقادیر این داده‌ها نیز بسیار مهم است؛ از آنجایی که غالباً شبکه‌های عصبی نمی‌توانند با برون‌یابی به جواب مسأله برسند؛ لازم است که الگوهای یادگیری طوری ارائه شوند که مرزهای محدوده مسأله را در تمام ابعاد شامل شوند. به بیان دیگر، شکل محدوده مسأله با محدوده یادگیری هماهنگ باشد؛ همچنین تمرکز دادن به یادگیری‌ها در محل‌هایی که شکل راه‌حل مسأله

پیچیدگی بیشتری دارد، بسیار سودمند خواهد بود؛ همچنین، با توجه به محدوده عمل فعالیت، انتقال متغیرهای خروجی و ورودی به بازه مناسب با یک توزیع مناسب لازم به نظر می‌رسد. مهم‌ترین هدف از این انتقال، تصحیح پخش متغیرهای ورودی و خروجی به نحوی است که خطای مدل‌سازی شبکه کاهش یابد. انتقال خطی (رابطه ۳-۴) بیشترین کاربرد را برای توزیع الگوهای یک مدل ANNs دارد (منهاج، ۱۳۷۴).

$$NP = \frac{UB - LB}{MaxP - MinP} \times (SP - MinP) + LB \quad (4-3)$$

که در آن UB و LB، حد بالایی و پایینی بازه مورد نظر، MinP و MaxP مقدار حداقل و حداکثر داده در بانک اطلاعات مدل و SP و NP، مقدار داده خام و نرمالیزه شده است.

رابطه انتقال دیگری که برای توزیع الگوهای ANNs استفاده می‌شود، یک روش آماری است که داده‌های خام را با توجه به خصوصیات آماری آن‌ها مطابق رابطه زیر طوری نرمالیزه می‌کند که میانگین داده‌ها (Mean P) صفر و انحراف معیار (Std P) آن‌ها یک شود (Demuth, 1996).

$$NP = \frac{SP - MeanP}{StdP} \quad (5-3)$$

لازم به ذکر است در این تحقیق، برای نرمالایزسازی داده‌ها از رابطه ۳-۴ استفاده شده است.

۳-۱۱- تعیین ساختار بهینه یک مدل شبکه عصبی مصنوعی

هر شبکه عصبی ساختاری چند لایه دارد که تعداد این لایه‌ها و همچنین تعداد نرون‌های موجود در آن باید به نحو بهینه‌ای انتخاب شود. از آنجایی که معمولاً تعداد نرون‌های لایه‌های ورودی و خروجی توسط مسأله دیکته می‌شود، بهینه‌سازی ساختار شبکه به تعیین تعداد نرون‌های لایه میانی (لایه پنهان) محدود می‌شود. ممکن است این طور استنباط شود که با کاهش تعداد نرون‌های لایه میانی و بالطبع کاهش تعداد پارامترهای شبکه، می‌توان با تعداد نمونه آموزشی اندک نیز به دقت قابل قبول دست یافت؛ اما بایستی در نظر داشت که لایه‌های میانی، عنصری کلیدی در ساختار یک شبکه عصبی هستند و نقش مهمی را در قابلیت تخمین نگاشت و تشخیص الگوی داده‌های ورودی بازی می‌کنند؛ این ویژگی هنگامی که متغیرهای ورودی زیاد هستند، بارزتر می‌شود. بطورکلی هر چه تعداد نرون‌های لایه میانی بیشتر شود، قابلیت شبکه برای تشخیص الگو و کاهش خطای تخمین، بیشتر خواهد شد. به نظر می‌رسد مهم‌ترین قسمت در طراحی ساختار

شبکه عصبی، تعیین تعداد نرون‌های لایه میانی است که باید به طور بهینه انجام شود. اگر تعداد واحدها را کم بگیریم، قدرت یادگیری شبکه کاهش می‌یابد. از طرفی در صورت استفاده از تعداد زیادی واحد علاوه بر نیاز به داده‌های آموزشی بیشتر، شبکه با تولید یک نگاشت غیرخطی پیچیده، داده‌های آموزشی را به اصطلاح حفظ می‌کند و در مقابل داده‌های آزمایشی عملکرد مناسبی نخواهد داشت و در واقع قدرت تعمیم خود را از دست خواهد داد. تعیین تعداد نرون‌های لایه میانی عموماً تجربی است؛ بطوریکه از تعداد واحدهای کم شروع کرده، شبکه را آموزش می‌دهیم و به همین ترتیب هر بار تعداد واحدها را افزایش داده و شبکه را باز آموزش می‌دهیم؛ تا زمانی که شبکه در عین حفظ قدرت تعمیم، همگرا شود. اگر شبکه همگرا نشود، به منزله عدم تشخیص الگوی داده‌های ورودی است (منهاج، ۱۳۷۴).

در این قسمت پارامترهایی را که اثر مستقیم در نحوه عملکرد شبکه داشته و کاربر می‌تواند آنها را کنترل کند، شرح می‌دهیم. این پارامترها عبارتند از :

- ۱- تعداد لایه‌های شبکه
- ۲- تعداد نرون‌ها در لایه پنهان
- ۳- تابع محرک (تابع انتقال)
- ۴- مقدار دهی اولیه وزنها^{۷۶}
- ۵- نرخ یادگیری^{۷۷} و گشتاور^{۷۸}

۳-۱۱-۱- تعداد لایه‌های شبکه

یک راهنمای مناسب برای تعیین تعداد حداکثر لایه‌ها در سال ۱۹۵۷ توسط یک ریاضیدان روسی به نام کولموگوروف^{۷۹} مطرح شده است. قضیه بقای کولموگوروف به صورت زیر خلاصه می‌شود:

⁷⁶ Weight initialization

⁷⁷ Learning Rate

⁷⁸ Momentum

⁷⁹ Kolomogorov Existence Theorem

" هر تابع پیوسته n متغیره را می توان تنها توسط حاصل جمع های خطی و توابع غیرخطی پیوسته اکیداً صعودی، از یک متغیر محاسبه کرد."

براساس این قضیه، یک شبکه سه لایه با $n(2n+1)$ نرون با استفاده از توابع غیرخطی پیوسته اکیداً صعودی، می تواند هر تابع پیوسته ای از n متغیر را محاسبه نماید. بنابراین از یک شبکه سه لایه می توان برای ایجاد هر تابع پیوسته مورد نیاز یک طبقه بندی استفاده کرد.

به هر حال آنچه محققان می گویند این است که به کارگیری دو لایه پنهان، الزاماً بهترین گزینه نمی باشد و بکارگیری تعداد لایه های بیشتر می تواند منجر به استفاده از تعداد کمتری نرون در کل شبکه گردد. از لحاظ تئوری، ثابت شده است که شبکه های سه لایه با تابع محرک سیگموئیدی تقریب زنده های جامعی هستند، بدین معنی که این شبکه ها را می توان برای تقریب زدن هر تابعی آموزش داد. میزان دقت تقریب به کار رفته به تعداد نرون های موجود در لایه پنهان بستگی دارد (غضنفری و ارکات، ۱۳۸۳).

۳-۱۱-۲- اثر تعداد نرون ها در لایه های میانی

محققین تلاش های بسیاری را برای یافتن روشی برای انتخاب بهینه تعداد نرون های لایه میانی انجام دادند و روش هایی مانند روش واسطه هندسی را در شبکه هایی که تعداد نرون های خروجی در آنها کمتر از ورودی می باشد، پیشنهاد کردند و یا پیشنهاد دادند که برای شبکه ای با یک لایه پنهان، تعداد $(n+1)$ نرون در این لایه نیاز است، که (n) تعداد نرون های ورودی می باشد.

با بررسی همه روش های پیشنهادی این نتیجه حاصل می شود که هیچ یک از این روش ها در همه موارد عمومیت ندارد و بهترین روش برای تعیین تعداد بهینه المان های پردازش در لایه پنهان روش آزمون و خطا می باشد (Principe et al, 1999).

۳-۱۱-۳- انتخاب نوع تابع محرک

در شبکه پس انتشار خطا، هر تابع مشتق‌پذیر و پیوسته‌ای که به طور یکنواخت افزایش یابد، می‌تواند به عنوان تابع محرک استفاده شود. معمول‌ترین این توابع، توابع سیگموئیدی، تانژانت هیپربولیک و خطی می‌باشند. انتخاب نوع تابع محرک به هدف مسأله بستگی دارد. چنانچه شبکه یک مسأله دسته‌بندی^{۸۰} را حل می‌کند، بهتر است از تابع سیگموئیدی یا تانژانت هیپربولیک در لایه خروجی استفاده شود. اگر هدف از حل مسأله، تخمین تابع^{۸۱} باشد، بهتر است از تابع محرک غیرخطی مانند سیگموئیدی برای نرون‌های لایه میانی و از تابع خطی برای لایه خروجی استفاده شود. خطی بودن تابع لایه خروجی اجازه می‌دهد تا شبکه مقادیر خارج از یک گستره محدود را هم تولید کند (طهماسبی، ۱۳۸۳).

لازم به ذکر است که در این تحقیق، از تابع محرک سیگموئیدی برای نرون‌های لایه میانی و از تابع محرک خطی برای نرون‌های لایه خروجی استفاده شده است.

۳-۱۱-۴- مقدار دهی اولیه وزنها

کاهش خطای شبکه چندین قید (قانون) را وارد پروسه یادگیری می‌کند، که چگونگی انتخاب وزن‌های اولیه و انتخاب تعداد لایه‌های میانی از جمله این قوانین می‌باشند. چگونگی انتخاب تعداد لایه‌های میانی قبلاً توضیح داده شد و در اینجا چگونگی انتخاب وزن‌های اولیه شبکه مورد بررسی قرار می‌گیرد.

اندازه وزن‌های اولیه بر راندمان شبکه اثر گذاشته و وزن‌های دور از وزن‌های نهایی، زمان آموزش را افزایش می‌دهند و باعث می‌شوند که سرعت یادگیری نرون‌های مختلف که ما تمایل به یکسان بودن آنها داریم، تغییر یابد. وقتی که وزن‌های اولیه، دور از مقدار بهینه انتخاب شوند، پیدا کردن مقدار کمینه سخت‌تر و غیر واقعی‌تر است. همچنین، مشخص نیست که وزن‌های بهینه در کجای الگو قرار می‌گیرند. بسیاری از افراد پیشنهاد کردند که راه حل خطی برای وزن‌های اولیه به کار رود، اما این قضیه همیشه درست عمل نمی‌کند. در بسیاری از حالت‌ها، راه حل خطی برای وزن‌های اولیه، باعث می‌شود که دقیقاً به نقاطی برسیم که نقاط کمینه محلی^{۸۲}

⁸⁰ Classification Problem

⁸¹ Function Approximation

⁸² Local minimum

می‌باشند. همچنین اگر وزن‌های اولیه خیلی بزرگ انتخاب شوند، توابع محرک سیگموئیدی سریعاً اشباع^{۸۳} خواهند شد و احتمال گرفتار شدن شبکه در کمینه محلی افزایش می‌یابد. برای از بین بردن مسائلی که از یادگیری درست جلوگیری می‌کنند، راه معمول، مقدار دهی اولیه تصادفی به وزن‌های شبکه است. یک نرون در حالت خطی سریعتر از نرون در حالت اشباع آموزش می‌بیند و برای آموزش بهتر، لازم است که یادگیری نرون‌ها در نرخ‌های برابر صورت‌گیرد (Principe et al, 1999).

۳-۱۱-۵- نرخ یادگیری و گشتاور


این دو کمیت میزان تغییر وزن‌ها را کنترل می‌کند. انتخاب نرخ یادگیری بسیار مهم است و اندازه گام‌ها را در راستای حصول به حداقل خطا تنظیم می‌کند. زمانی که تابع خطا نسبتاً تخت باشد، استفاده از نرخ آموزشی بزرگتر سودمند است. استفاده از نرخ آموزشی کوچک باعث طولانی‌تر شدن زمان همگرایی می‌شود. در روش‌های آموزشی سریعتر که با اعمال تغییراتی در الگوریتم پس انتشار خطا^{۸۴} حاصل شده است، نرخ یادگیری ثابت نیست و در خلال آموزش تغییر می‌کند.

گشتاور (مومنتم) برای بهتر کردن اجرای الگوریتم استفاده شده و همگرایی را سریعتر و پایدار می‌کند و به طور نرمال عددی بین ۰/۵ و ۰/۹ می‌باشد. در جایی که شبکه در یک گودی (کمینه محلی) گیر می‌افتد، گشتاور به رهایی از کمینه محلی کمک می‌کند و آن را از گودی به سمت ملایم‌تر می‌برد. شکل (۳-۸) یادگیری گشتاور را به صورت خلاصه نشان می‌دهد. در این شکل یک توپ دیده می‌شود (موقعیت بردار وزن)، که به سمت پایین تپه حرکت می‌کند. اگر توپ به قسمت صاف کوچکی برسد، به حرکت خود از این قسمت کمینه محلی ادامه می‌دهد، که دلیل این امر وجود گشتاور است. یک توپ بدون نیروی گشتاور، در این گودال می‌ماند و نمی‌تواند از آن خارج شود.

گشتاور روشی برای سریع‌تر کردن آموزش شبکه بوده و پیشنهاد می‌شود که به عنوان پیش فرض شبکه‌های غیرخطی قرار گیرد (Principe et al, 1999).

⁸³ Saturate

⁸⁴ Backpropagation Error



شکل ۳-۸- تأثیر گشتاور بر یادگیری شبکه عصبی (Principe et al, 1999).

یک نرخ یادگیری کوچک می‌تواند با یک گشتاور بزرگتر جهت تسریع همگرایی استفاده شود و یک نرخ یادگیری بزرگتر معمولاً با یک گشتاور کوچکتر جهت اطمینان از پایداری شبکه می‌تواند همراه شود. مقادیر گشتاور و نرخ یادگیری اغلب توسط آزمون و خطا، انتخاب می‌شوند (طهماسبی ۱۳۸۳).

در ادامه کار، در فصل بعدی نحوه طراحی شبکه‌های عصبی مورد استفاده در معکوس سازی داده‌های سونداژ ژئوالکتریک برای حالت چهار لایه پرداخته شده و عملکرد آنها به ازاء داده‌های مصنوعی و واقعی مورد ارزیابی قرار می‌گیرد.


فصل چهارم

مدل سازی داده های سونداژ مقاومت ویژه

مدل سازی داده های سونداژ مقاومت ویژه
با استفاده از شبکه عصبی مصنوعی

در این فصل با استفاده از شبکه‌های عصبی مصنوعی به تفسیر داده‌های مقاومت ویژه الکتریکی در زمین‌های چهار لایه پرداخته می‌شود. برای انجام این تحقیق، ابتدا با استفاده از نرم‌افزار Resix-IP یک سری داده مصنوعی تولید می‌گردد و با استفاده از آنها دو نوع شبکه عصبی مختلف آموزش داده می‌شود؛ به طوریکه شبکه اول برای طبقه‌بندی و انتخاب نوع داده‌های ورودی و شبکه دوم برای تخمین پارامترهای هر لایه به کار خواهد رفت. از طرفی برای بررسی دقیقتر، به داده‌های مصنوعی تولید شده در دو مرحله مجزا به میزان 5 و 10 درصد نویز اضافه نموده و شبکه‌های مورد نظر در این حالات نیز برای آنها طراحی گشته و عملکرد آنها مورد بررسی قرار می‌گیرد. در پایان نیز برای ارزیابی قدرت تعمیم شبکه‌های طراحی شده، از آنها برای مدل‌سازی داده‌های واقعی چندین سونداژ استفاده نموده و نتایج مربوط به هر یک را با نتایج حاصل از نرم‌افزار Resix-IP مورد مقایسه قرار می‌دهیم. در شکل (1-4) نمایی کلی از نحوه عملکرد این شبکه‌ها و کاربرد آنها آورده شده است.

شبکه‌های مدل‌سازی کننده یا تخمین‌زن پارامترها (شبکه‌های تخمین‌گر)



شکل ۴-۱- نمایی کلی از ساختار مورد استفاده برای انجام مدل‌سازی معکوس داده‌های ژئوالکتریک.

۴-۲- مراحل انجام کار

با توجه به انواع حالات موجود در زمین‌های چهار لایه، در ادامه به طور اجمال در مورد مراحل انجام تحقیق و شیوه انجام کار توضیحاتی ارائه می‌گردد و در انتها به تفصیل در مورد هر یک از شبکه‌ها توضیحات تکمیلی آورده می‌شود.

۴-۲-۱- تهیه، تولید و آماده‌سازی داده‌های مصنوعی

اولین و اساسی‌ترین قدم در راستای انجام این تحقیق، تولید داده‌های مصنوعی به منظور آموزش و آزمایش شبکه عصبی مورد نظر است؛ که در اینجا برای این منظور از نرم‌افزار ژئوفیزیکی Resix-IP استفاده گردید. از آنجا که این تحقیق مربوط به مدل‌سازی یک زمین چهار لایه با استفاده از داده‌های سونداژ مقاومت ویژه الکتریکی است، لذا با توجه به نکات ذکر شده در بخش‌های قبلی، اقدام به تولید ۸ گروه مختلف از داده‌های مصنوعی شامل انواع AA, AK, KH, KQ, QQ, QH, HK و HA گردید.

پس از تولید داده‌های مصنوعی، از آنجا که فرمت این داده‌ها و نحوه ارتباط آنها برای استفاده در نرم‌افزار MATLAB و آموزش شبکه مناسب نبود، لذا با استفاده از نرم‌افزار Excel یک عملیات آماده‌سازی نیز روی داده‌های تولیدی صورت گرفت و داده‌های مذکور به فرمت مورد نظر تبدیل شدند. لازم به ذکر است که برای هر یک از حالات هشتگانه مذکور، تعداد ۲۵۰ جفت داده مصنوعی تولید گردید که هر یک از این جفت نمونه‌ها شامل موارد ذیل است:

۱- مقادیر مقاومت ویژه صحرایی که به عنوان ورودی^{۸۵} شبکه مورد استفاده قرار می‌گیرند و شامل ۲۲ مقدار مقاومت ویژه به ازاء ۲۲ فاصله الکترودی ($AB/2$) مختلف است.

۲- پارامترهای مربوط به هر مدل که به عنوان مقادیر هدف^{۸۶} شبکه مورد استفاده قرار می‌گیرند. این پارامترها شامل هفت پارامتر $\rho_1, \rho_2, \rho_3, \rho_4, h_1, h_2, h_3$ می‌باشد که در آن ρ_i مقاومت ویژه لایه i ام و h_i ضخامت لایه i ام است.

لازم به ذکر است که هر چه تعداد داده‌های ورودی و نیز تنوع مدل‌های ساخته شده بیشتر باشد، قدرت تخمین و تعمیم شبکه بیشتر بوده و نتایج حاصل از آن از دقت و صحت بالاتری برخوردارند.

از جمله موارد مهمی که بایستی در اینجا به آن اشاره نمود این است که در مرحله تولید داده‌های مصنوعی، پارامترهای مربوط به هر لایه به صورت تصادفی و در یک بازه معین انتخاب می‌گردند. این کار سبب می‌شود که در مرحله آموزش شبکه، اولاً کلیه حالات ممکن و موجود را در نظر بگیریم؛ ثانیاً از یک روند مشخص و یا از یک حالت خاص برای آموزش استفاده نکنیم (نحوه تولید داده‌های مصنوعی در پیوست الف آمده است).

^{۸۵} Input Data

^{۸۶} Target Data

در این تحقیق، برای آموزش هشت شبکه عصبی تخمینگر⁸⁷ که پارامترهای مدل‌ها را تخمین می‌زنند و مربوط به هر یک از حالات هشتگانه منحنی‌های سونداژ چهار لایه هستند، از داده‌های مصنوعی تولید شده مربوط به هر حالت استفاده گردید. از طرفی برای آموزش شبکه عصبی طبقه‌بندی‌کننده⁸⁸ که نوع داده ورودی را تعیین می‌کرد، ترکیبی از داده‌های مربوط به ۸ حالت فوق در نظر گرفته شد که در بخش‌های آتی روش کار به تفصیل شرح داده خواهد شد. نکته مهم قابل ذکر آن که در اینجا برای آموزش شبکه عصبی تنها از مقادیر مقاومت ویژه ظاهری استفاده کرده و چون فواصل الکترونی مربوط به برداشتها در همه داده‌ها یکسان بود، استفاده از این پارامتر به عنوان ورودی شبکه لازم نبوده و در روند آموزش تأثیری نداشت. مورد دیگر اینکه در این تحقیق شبکه‌های تخمینگر با توجه به نحوه تولید داده‌های مصنوعی و فواصل الکترونی مورد نظر، طوری آموزش یافتند که برای مدل‌سازی داده‌ها نیازی به عملیات هموارسازی داده‌ها نداشته باشند.

۴-۲-۲- تعیین ساختار بهینه شبکه عصبی مصنوعی

همانطور که قبلاً نیز به آن اشاره گردید، در این تحقیق از دو نوع شبکه عصبی مختلف برای انجام مدل‌سازی استفاده گردید. بدین ترتیب که داده‌های ورودی ابتدا وارد یک شبکه طبقه‌بندی شده و در آنجا پس از تعیین نوع مدل، وارد شبکه دوم که یک شبکه تخمینگر می‌باشد، می‌شوند و پارامترهای ژئوالکتریکی مدل یعنی ضخامت و مقاومت ویژه مربوط به هر لایه تعیین می‌گردند. در نهایت نیز نتایج حاصل از آن هم به صورت جدول و هم به صورت نمودار نمایش داده می‌شود.

با توجه به سهولت اجرا و توانایی خوب شبکه‌های عصبی پرسپترون چند لایه با الگوریتم پس انتشار خطا در مسائل تشخیص الگو و مسأله تخمین که دارای نتایج بسیار خوبی در اینگونه موارد است، در این تحقیق تمامی شبکه‌های طبقه‌بندی و تخمینگر از نوع شبکه پرسپترون چند لایه پیشخور و باناظر انتخاب گردیدند. در ادامه، قبل از وارد شدن به مبحث اصلی، اقدامات مورد نیاز در زمینه تعیین ساختار بهینه این شبکه‌ها آورده شده است.

۴-۲-۱- مراحل کلی طراحی شبکه عصبی پیشخور و باناظر

⁸⁷ Estimator

⁸⁸ Classifier

در راستای انجام این تحقیق و به منظور ایجاد یک شبکه عصبی صحیح و مناسب، لازم بود اصول کلی و اقدامات اساسی که در ذیل به آنها اشاره شده است، رعایت و اجرا گردند:

- تهیه، تعیین و فراخوانی داده‌های ورودی و هدف.
- پیش پردازش^{۸۹} داده‌ها از طریق انتخاب نوع روش مناسب برای انجام این امر که خود شامل نحوه نرمال کردن^{۹۰} داده‌های ورودی و نیز چگونگی تقسیم این داده‌ها به سه مجموعه آموزش، ارزیابی و آزمایش و نیز بررسی لزوم اجرای این اقدامات.
- تعیین نوع شبکه مورد نظر (شبکه پرسپترون، شبکه هاپفیلد، شبکه آدالین و ...).
- تعیین نوع تابع آموزش شبکه (trainlm, trainscg, trainbr و ...).
- تعیین سایر پارامترهای مورد نیاز برای آموزش شبکه؛ از قبیل تعداد تکرارها، مقدار هدف، نرخ یادگیری، ممنتم و
- تعیین تعداد لایه‌های شبکه.
- تعیین تعداد نرونهای مربوط به هر لایه.
- تعیین توابع محرک مورد استفاده برای هر نرون (Tansig, Purlin و ...).

با توجه به موارد فوق الذکر و نیز مطالب بیان شده در فصل قبل، بایستی یادآور شد که بررسی و تعیین نوع تابع آموزش، تعداد لایه‌های شبکه، تعداد نرونهای لایه میانی، نوع توابع محرک و ... از طریق قرار دادن شبکه در حلقه تکرار صورت گرفته است. به عبارت دیگر با انجام سعی و خطا و مقایسه نتایج مربوط به هر مورد، گزینه مناسب و بهینه تعیین شده و در شبکه نهایی اعمال گشته است. لازم به ذکر است کلیه مراحل بالا برای هر یک از شبکه‌های هشتگانه تخمینگر و نیز شبکه طبقه‌بندی کننده به صورت مجزا صورت گرفته است؛ چرا که ممکن است در یک شبکه یک عامل، مفید بوده و باعث کاهش خطای شبکه گردد، ولی همین عامل در شبکه دیگر باعث افزایش خطای شبکه و یا عدم همگرایی شبکه گردد.

۴-۳- مدل سازی معکوس داده‌های ژئوالکتریکی چهار لایه با استفاده از شبکه عصبی

پس از آشنایی با انواع حالات زمین‌های چهار لایه، نحوه تولید داده‌های مصنوعی و آگاهی از دستورالعمل طراحی شبکه‌های عصبی مصنوعی که در این تحقیق مورد استفاده قرار گرفته‌اند؛ در ادامه، پارامترهای انتخابی مورد نظر در طراحی شبکه و آموزش آن و نیز نتایج حاصل از آزمایش شبکه به همراه

⁸⁹ Preprocessor

⁹⁰ Normalizing

مقایسه این نتایج با نرم افزار Resix-IP برای هر یک از شبکه‌ها به صورت مجزا آورده شده است. از طرفی نمودارهای مربوط به هر قسمت نیز تهیه گشته و به موارد فوق افزوده گردیده است.

از آنجا که داده‌های صحرایی همواره به دلیل وجود عوامل مختلف با نویز همراه هستند؛ لذا در اینجا نیز به منظور مدل‌سازی این حالات به داده‌های مورد نظر، ۵ و ۱۰ درصد نویز اضافه کرده تا رفتار شبکه‌ها در این حالات نیز مورد ارزیابی قرار گیرند. نتایج مربوط به این قسمت در بخش‌های مربوطه آورده شده است.

۴-۳-۱- شبکه طبقه بندی

موارد کلیدی و نیز نتایج حاصل از طراحی، آموزش و آزمایش شبکه طبقه‌بندی، به همراه پارامترهای مفید و موثر در این زمینه به شرح ذیل می‌باشند:

- تعداد لایه‌های شبکه: دو لایه (که شامل یک لایه میانی و یک لایه خروجی است)

- تعداد نرون‌های لایه ورودی: ۲۲ نرون (که برابر تعداد داده‌های صحرایی هر سونداژ است)

- تعداد نرون‌های لایه میانی: ۳۳ نرون (که از طریق سعی و خطا حاصل شده است)

- تعداد نرون‌های لایه خروجی: ۸ نرون (که به دلیل وجود ۸ تیپ مدل چهار لایه است)

- درصد داده‌های آموزش، ارزیابی و آزمایش: ۷۰٪، ۲۰٪ و ۱۰٪

- تابع اندازه‌گیری خطا: MSE^{۹۱} یا میانگین مربعات خطا

- تابع محرک لایه میانی: tansig (که یک تابع غیر خطی سیگموئیدی است)

- تابع محرک لایه خروجی: logsig (که یک تابع غیر خطی سیگموئیدی است)

- تابع آموزش: trainlm یا الگوریتم آموزش لوببرگ - مارکوآرت

- تابع نرمالایزکننده: mapminmax (که داده‌ها را به بازه [-1,1] نگاشت می‌کند)

- نوع شبکه: شبکه از نوع پیشخور^{۹۲} بوده و از الگوریتم پس‌انتشار خطا استفاده می‌کند.

- ماتریس داده‌های ورودی (۲۲×۲۰۰۰):

^{۹۱} Mean squared error

^{۹۲} FeedForward

$$Input\ Data = \begin{pmatrix} \rho_{a_{1,1}} & \rho_{a_{1,2}} & \dots & \rho_{a_{1,2000}} \\ \rho_{a_{2,1}} & \rho_{a_{2,2}} & \dots & \rho_{a_{2,2000}} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \rho_{a_{22,1}} & \rho_{a_{22,2}} & \dots & \rho_{a_{22,2000}} \end{pmatrix}$$

$\underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250}$

لازم به ذکر است که ماتریس فوق شامل ۸ گروه ۲۵۰ ستونی از داده‌ها (جمعاً ۲۰۰۰ ستون) است، به طوریکه هر یک از این گروه‌ها، مربوط به داده‌های یکی از ۸ حالت موجود در مدل‌های چهار لایه است. الگوریتم مورد استفاده در آموزش این شبکه و نیز فرآیند طبقه‌بندی به گونه‌ای است که مقادیر موجود در این ماتریس، قبل از ورود به شبکه ابتدا نرمال می‌شدند و سپس مورد تجزیه و تحلیل قرار می‌گرفتند.

$$Target\ Data = \begin{bmatrix} 1 \dots 0 \dots 0 \dots 0 \dots 0 \dots 0 \dots 0 \\ 0 \dots 1 \dots 0 \dots 0 \dots 0 \dots 0 \dots 0 \\ 0 \dots 0 \dots 1 \dots 0 \dots 0 \dots 0 \dots 0 \\ 0 \dots 0 \dots 0 \dots 1 \dots 0 \dots 0 \dots 0 \\ 0 \dots 0 \dots 0 \dots 0 \dots 1 \dots 0 \dots 0 \\ 0 \dots 0 \dots 0 \dots 0 \dots 0 \dots 1 \dots 0 \\ 0 \dots 0 \dots 0 \dots 0 \dots 0 \dots 0 \dots 1 \\ 0 \dots 0 \dots 0 \dots 0 \dots 0 \dots 0 \dots 1 \end{bmatrix}$$

$\underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250} \quad \underbrace{\hspace{1.5cm}}_{250}$
 2000 Column


- ماتریس داده‌های هدف (۸×۲۰۰۰):

ماتریس فوق شامل ۸ گروه ۲۵۰ ستونی از اعداد ۰ و ۱ می‌باشد. به طوریکه برای شبکه AA یک ستون ۲۵۰ تایی از اعداد ۰ و ۱ را در نظر گرفتیم که سطر اول همه آنها ۱ و بقیه سطرها برابر ۰ در نظر گرفته شد. به همین ترتیب برای شبکه دوم سطر دوم برابر ۱ و بقیه سطرها مساوی ۰ قرار داده شد و همین روند برای ۶ شبکه باقیمانده دیگر تکرار گردید.

پس از تشکیل ساختار مورد نظر با ویژگی‌های فوق، با قرار دادن این شبکه در یک حلقه با ۵۰ تکرار و مقایسه نتایج حاصل از هر اجرا، تعداد نرون‌های لایه میانی شبکه نیز برابر ۳۳ نرون انتخاب گردید. بدین ترتیب شبکه مورد نظر طراحی شد و پارامترهای مناسب و بهینه آن انتخاب گردیدند. بعد از این مرحله، شبکه مذکور با استفاده از داده‌های موجود (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش یافت که نتایج حاصل از آن به صورت میانگین مربعات خطا (MSE) در اشکال (۴-۲)، (۴-۳) و (۴-۴) آمده است. از آنجا که در فرآیند آموزش، انتخاب وزنها و بایاسهای مربوط به هر نرون کاملاً تصادفی است، لذا برای اینکه مقادیر

مربوط به وزن‌ها و بایاس‌های بدست آمده، بهینه‌ترین مقدار باشند، بنابراین خود فرآیند آموزش نیز در یک حلقه با ۵۰ تکرار قرار داده شد و در نهایت با مقایسه نتایج مربوط به هر مرحله، بهترین مقادیر ذخیره شدند. در پیوست ب، نحوه اضافه نمودن نویز به داده‌ها شرح داده شده است.


الف- استفاده از داده‌های بدون نویز



شکل ۴-۲- رفتار شبکه طبقه بندی در زمان آموزش (بدون حضور نویز)،

مقدار خطای آموزش در بالای نمودار آمده است.


ب- استفاده از داده‌های حاوی ۵٪ نویز



شکل ۴-۳- رفتار شبکه طبقه بندی در زمان آموزش (وجود ۵٪ نویز)،

مقدار خطای آموزش در بالای نمودار آمده است.

ج- استفاده از داده‌های حاوی ۱۰٪ نویز



شکل ۴-۴- رفتار شبکه طبقه بندی در هنگام آموزش (وجود ۱۰٪ نویز)، مقدار خطای آموزش در بالای نمودار آمده است.

همانطور که در اشکال (۲-۴)، (۳-۴) و (۴-۴) مشاهده می‌شود، وجود نویز باعث افزایش خطای آموزش گردیده است و مقدار میانگین مربعات خطا در زمان توقف آموزش در هر حالت برابر است با:


آموزش با داده‌های بدون نویز : $MSE = 0.0145$

آموزش با داده‌های حاوی ۵٪ نویز: $MSE = 0.0338$

آموزش با داده‌های حاوی ۱۰٪ نویز: $MSE = 0.0359$

در شکل (۵-۴) مثالی از نحوه تعیین نوع منحنی سونداز توسط شبکه عصبی طبقه‌بندی کننده آمده است. در اینجا با ورود داده‌های مقاومت ویژه صحرایی به شبکه طبقه بندی، این شبکه با توجه به روند آموزش خود، به خوبی نوع منحنی سونداز را تعیین می‌کند. لازم به ذکر است که این عملیات برای نمونه‌های دیگر و با مدل‌های چهار لایه مختلف نیز صورت گرفت که نتایج مربوطه حاکی از صحت نتایج حاصل بود.

>> Curve Type = QH



شکل ۴-۵- نمونه‌ای از نحوه تعیین نوع منحنی سونداژ برای یک داده آزمایشی توسط شبکه طبقه‌بندی که در آن نوع مدل چهار لایه را تیپ QH معرفی نموده است.

۴-۳-۲- شبکه‌های تخمینگر

- به طور کلی در مورد هر یک از شبکه‌های تخمینگر که مربوط به هشت حالت مختلف هستند، موارد زیر به طور عمومی در ساختار شبکه‌ها مورد استفاده قرار گرفت:
- تعداد لایه‌های شبکه: دو لایه (که شامل یک لایه میانی و یک لایه خروجی است)
 - تعداد نرون‌های لایه ورودی: ۲۲ نرون (که برابر تعداد داده‌های صحرایی هر سونداژ است)
 - تعداد نرون‌های لایه خروجی: ۷ نرون (به دلیل وجود ۷ پارامتر در هر مدل چهار لایه‌ای)
 - درصد داده‌های آموزش، ارزیابی و آزمایش: ۷۰٪، ۲۰٪ و ۱۰٪
 - تابع اندازه‌گیری خطا: MSE یا میانگین مربعات خطا
 - تابع محرک لایه میانی: tansig (که یک تابع غیر خطی سیگموئیدی است)
 - تابع محرک لایه خروجی: purlin (که یک تابع خطی است)
 - تابع آموزش: trainlm یا الگوریتم آموزش لونبرگ - مارکوآرت
 - تعداد نرون‌های لایه میانی: که برای هر حالت، متفاوت بوده و در ادامه آورده شده است.
 - تابع نرمالایزکننده: mapminmax (که داده‌ها را به بازه [-1,1] نگاشت می‌کند)
 - نوع شبکه: شبکه از نوع پیشخور بوده و از الگوریتم پس‌انتشار خطا استفاده می‌کند.
 - ماتریس داده‌های ورودی (۲۵۰×۲۲):

$$Input\ Data = \begin{pmatrix} \rho_{a_{1,1}} & \rho_{a_{1,2}} & & \rho_{a_{1,250}} \\ \rho_{a_{2,1}} & \rho_{a_{2,2}} & & \rho_{a_{2,250}} \\ . & . & & . \\ . & . & & . \\ . & . & & . \\ \rho_{a_{22,1}} & \rho_{a_{22,2}} & & \rho_{a_{22,250}} \end{pmatrix}$$

$$T \text{ arg et } Data = \underbrace{\begin{bmatrix} \rho_{1,1} & \dots & \rho_{1,250} \\ \rho_{2,1} & \dots & \rho_{2,250} \\ \rho_{3,1} & \dots & \rho_{3,250} \\ \rho_{4,1} & \dots & \rho_{4,250} \\ h_{1,1} & \dots & h_{1,250} \\ h_{2,1} & \dots & h_{2,250} \\ h_{3,1} & \dots & h_{3,250} \end{bmatrix}}_{250 \text{ Column}}$$

- ماتریس داده‌های هدف (۷×۲۵۰):

لازم به ذکر است که در ماتریس‌های فوق، داده‌های مصنوعی تولید شده و پارامترهای مربوط به مدل‌های چها لایه، به کار رفته است. الگوریتم مورد استفاده در این تحقیق به گونه‌ای است که داده‌های موجود در این ماتریس‌ها، قبل از ورود به شبکه‌های عصبی مورد نظر، ابتدا نرمال شده و سپس مورد استفاده قرار می‌گیرند و در پایان عملیات مربوطه بر روی این داده‌ها، خروجی حاصل از شبکه دوباره به بازه اولیه خود نگاشت داده می‌شوند.

در ادامه این فصل، نحوه تعیین تعداد نرون‌های لایه میانی مربوط به شبکه‌های تخمینگر و نیز خطای حاصل از آموزش هر شبکه، به همراه ضرایب همبستگی موجود بین خروجی این شبکه‌ها با داده‌های هدف به ازاء هر پارامتر آورده شده است.


۴-۳-۱- شبکه AA

نکات اساسی و نیز نتایج حاصل از آموزش و آزمایش شبکه AA، به همراه پارامترهای مفید و موثر در این زمینه به شرح ذیل می‌باشند.

در این قسمت پس از تشکیل ساختار شبکه AA با توجه به مطالب بیان شده در مورد شبکه‌های تخمینگر، با قرار دادن این شبکه در یک حلقه با ۵۰ تکرار و مقایسه نتایج حاصل از هر اجرا، تعداد نرون‌های لایه میانی شبکه برابر ۳۲ نرون انتخاب گردید. با توجه به این مطلب و نیز مطالب بیان شده در بخش‌های قبلی، شبکه مورد نظر طراحی شده و پارامترهای مناسب و بهینه آن انتخاب گردید. بعد از این مرحله، شبکه مذکور با داده‌های مورد نظر (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش داده شد که مقدار خطای حاصل از آن در هر مرحله در اشکال (۴-۶) تا (۴-۸) و مقدار خطای شبکه در تخمین هر پارامتر و نیز مقادیر ضرایب همبستگی بین خروجی شبکه با داده‌های هدف در جداول (۴-۱) تا (۴-۶) آمده است. از آنجا که در فرآیند آموزش، انتخاب وزن‌ها و بایاس‌های مربوط به هر نرون کاملاً تصادفی است، لذا برای اینکه مقادیر مربوط به آنها، بهینه‌ترین مقدار باشند، خود فرآیند آموزش نیز در یک حلقه با ۵۰ تکرار

قرار داده شد و در نهایت با مقایسه نتایج مربوط به هر مرحله، بهترین مقادیر ذخیره شدند. لازم به ذکر است که برای کلیه شبکه‌های تخمینگر و نیز برای هر یک از پارامترهای خروجی شبکه، نمودارهای مربوط به ضرایب همبستگی به ازاء داده‌های فاقد نویز، در پیوست د آمده است.

الف- استفاده از داده‌های بدون نویز



شکل ۴-۶- رفتار شبکه AA در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ۴-۱- مقدار خطای (MSE) شبکه AA به ازای هر یک از پارامترهای مدل خروجی (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0347	0.0111	0.0163	0.0001	0.0001	0.0057	0.0009	مقدار خطا به ازای داده‌های آموزشی
0.1465	0.0164	0.0054	0.0009	0.0455	0.0084	0.0032	مقدار خطا به ازای داده‌های اعتبارسنجی
0.2467	0.0291	0.0168	0.0044	0.0569	0.0105	0.0097	مقدار خطا به ازای داده‌های آزمایشی


جدول ۴-۲- ضریب همبستگی بین خروجی شبکه AA با داده‌های هدف (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9094	0.9458	0.9792	0.9943	0.9394	0.9478	0.9978	ضریب همبستگی به ازای داده‌های آموزشی
0.4306	0.8682	0.8454	0.9888	0.8442	0.8866	0.9980	ضریب همبستگی به ازای داده‌های اعتبارسنجی

0.5265	0.8102	0.8505	0.9635	0.7994	0.8120	0.9980	ضریب همبستگی به ازای داده‌های آزمایشی
--------	--------	--------	--------	--------	--------	--------	--

همانطور که ملاحظه می‌شود در این شبکه مقدار خطا و نیز ضریب همبستگی به ازاء داده‌های آزمایشی در مورد پارامتر آخر یعنی h_3 نسبت به سایر پارامترها عملکرد ضعیف‌تری از خود نشان داده است. که این امر تخمین این پارامتر را با خطای بالاتری همراه خواهد ساخت. ولی سایر پارامترها دارای مقادیر خطا و ضریب همبستگی قابل قبولی بوده و نشان دهنده آموزش مناسب شبکه به ازاء این پارامترها است.

ب- استفاده از داده‌های حاوی ۵٪ نویز



شکل ۴-۷- رفتار شبکه AA در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ۴-۳- مقدار خطای (MSE) شبکه AA به ازای هر یک از پارامترهای مدل خروجی (در حضور ۵٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0087	0	0.0016	0.0356	0	0.0001	0	مقدار خطا به ازای داده‌های آموزشی
1.4291	0.0007	0.0014	0.0294	0.0324	0.1262	0.0011	مقدار خطا به ازای داده‌های اعتبارسنجی
0.325	0.5494	0.0176	0.0268	0.1902	0.0767	0.0124	مقدار خطا به ازای داده‌های آزمایشی

جدول ۴-۴- ضریب همبستگی بین خروجی شبکه AA با داده‌های هدف (در حضور ۵٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9911	0.9886	0.9752	0.9796	0.9945	0.9943	0.9962	ضریب همبستگی به ازای داده‌های آموزشی
0.3132	0.546	0.5368	0.7350	0.4082	0.5883	0.9914	ضریب همبستگی به ازای داده‌های اعتبارسنجی
-0.194	0.3195	0.4930	0.6873	0.3321	0.0680	0.9848	ضریب همبستگی به ازای داده‌های آزمایشی

همانطور که ملاحظه می‌شود افزودن ۵٪ نویز به داده‌های ورودی باعث افزایش خطای داده‌های آزمایشی گردیده و ضرایب همبستگی مربوط به پارامترها کاهش یافته و در برخی پارامترها نیز منفی شده است که نشان‌دهنده تأثیر نامطلوب نویز بر روی داده‌های ورودی است.

ج- استفاده از داده‌های حاوی ۱۰٪ نویز



شکل ۴-۸- رفتار شبکه AA در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ۴-۵- مقدار خطای (MSE) شبکه AA به ازای هر یک از پارامترهای مدل خروجی (در حضور ۱۰٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.004	0.0105	0.0039	0.0099	0.0666	0.019	0.0002	مقدار خطا به ازای داده‌های آموزشی
0.2849	0.3653	0.1821	0.5543	0.0458	0.0205	0.0057	مقدار خطا به ازای داده‌های اعتبارسنجی

0.8167	0.0435	0.0122	0.0131	0.0112	0.1725	0.0023	مقدار خطا به ازای داده‌های آزمایشی
--------	--------	--------	--------	--------	--------	--------	------------------------------------

جدول ۴-۶- ضریب همبستگی بین خروجی شبکه AA با داده‌های هدف (در حضور ۱۰٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9869	0.9207	0.9544	0.9484	0.9685	0.9678	0.9925	ضریب همبستگی به ازای داده‌های آموزشی
0.5206	0.0612	0.4350	0.5561	0.5394	0.6202	0.9688	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.2648	0.0873	0.5226	0.5606	0.5356	0.4813	0.9587	ضریب همبستگی به ازای داده‌های آزمایشی

با بررسی جداول فوق باز هم ملاحظه می‌گردد که با افزودن نویز به داده‌های ورودی مقدار خطای شبکه به ازاء هر یک از پارامترهای مدل خروجی نسبت به حالت بدون نویز افزایش چشمگیری یافته و ضرایب همبستگی مربوطه نیز با کاهش شدیدی مواجه گردیده است. لذا با توجه به مطالب مذکور در مجموع بایستی اظهار داشت که شبکه‌هایی که با داده‌های نویز دار آموزش دیده‌اند، برای تفسیر سوندازهای ژئوالکتریک از کارایی مناسبی برخوردار نبوده و نمی‌توان از آنها در تخمین پارامترهای مدل بهره برد؛ ولی از آنجا که در حالت عدم حضور نویز، خطای شبکه به ازاء داده‌های آزمایشی و نیز ضرایب همبستگی مربوط به آنها نسبتاً مناسب است، لذا در این حالت می‌توانند برای تخمین پارامترهای مدل، مورد استفاده قرار گیرند. در انتهای این بخش، برای اینکه میزان کارایی شبکه (در حالت عدم حضور نویز) سنجیده شود و از طرفی قدرت تعمیم آن مورد بررسی قرار گیرد، از یکسری داده آزمایشی برای آزمایش شبکه استفاده شد که نتایج آن در جدول (۷-۴) و شکل (۹-۴) آمده است. در ادامه نیز برای درک بهتر پاسخ شبکه، این نتایج با مدل واقعی مربوطه مورد مقایسه قرار گرفت (شکل ۴-۱۰).



Curve Type = AA


	Layer 1	Layer 2	Layer 3	Layer 4
	=====	=====	=====	=====
Apperant Resistivity (ohm-m) :	24.11	35.62	63.15	93.09
Thickness (m) :	17.54	40.96	41.73	--INF--

شکل ۴-۹- خروجی شبکه AA (بدون حضور نویز) به ازاء یکی از داده‌های آزمایشی که به دو صورت نمایش گرافیکی مدل (بالا) و نمایش عددی پارامترها (پایین) آورده شده است.

لازم به ذکر است در شکل فوق دایره‌ها () نشان‌دهنده داده‌های مقاومت ویژه حاصل از آرایش شلومبرژه، خط ممتد (—) نشان‌دهنده پاسخ مدل حاصل توسط شبکه عصبی و خط چین (---) نشان‌دهنده مدل لایه‌ای حاصل از شبکه است.

جدول ۴-۷- مقایسه مدل حاصل از شبکه AA (در حالت عدم حضور نویز) با مدل واقعی به ازای یکی از داده‌های آزمایشی.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
38	54	10	92	75	35	24	مدل واقعی
41.73	40.96	17.54	93.09	63.15	35.62	24.11	پاسخ شبکه (در حالت عدم حضور نویز)



شکل ۴-۱۰- مقایسه مدل حاصل از شبکه AA (---) با مدل واقعی (—) به ازاء یک داده آزمایشی (عدم حضور نویز).

همانطور که در نمودار (۴-۱۰) و جدول (۴-۷) مشاهده می‌شود، شبکه عصبی به خوبی توانسته است، مقاومت ویژه لایه‌های مدل مورد نظر را تخمین بزند و فقط در مورد ضخامت‌ها دارای اندکی اختلاف است که می‌تواند ناشی از خطای شبکه در هنگام تخمین ضخامت‌ها باشد.

۴-۳-۲- شبکه AK

در این قسمت پس از تشکیل ساختار شبکه AK با توجه به مطالب بیان شده، با قرار دادن شبکه در یک حلقه با ۵۰ تکرار و مقایسه نتایج حاصل از هر اجرا، تعداد نرون‌های لایه میانی شبکه برابر ۳۵ نرون انتخاب گردید. بعد از این مرحله، شبکه مذکور با داده‌های مورد نظر (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش داده شد که نمودارهای مربوط به آن به همراه میزان خطای آموزش در پیوست ه آورده شده است. از طرفی مقدار خطای شبکه در تخمین هر پارامتر و نیز ضرایب همبستگی بین خروجی شبکه با داده‌های هدف در جداول (۴-۸) تا (۴-۱۳) آمده است.

الف- استفاده از داده‌های بدون نویز

جدول ۴-۸- مقدار خطای (MSE) شبکه AK به ازای هر یک از پارامترهای مدل خروجی (عدم حضور نویز).

پارامترهای مربوط به خروجی شبکه	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3
--------------------------------	----------	----------	----------	----------	-------	-------	-------

0.0039	0.0441	0.002	0.0014	0.0009	0.0011	0.0007	مقدار خطا به ازای داده‌های آموزشی
0.038	0.0969	0.0087	0	0.0009	0.0046	0	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0996	0.0219	0.0008	0.0002	0.0129	0.0266	0.0001	مقدار خطا به ازای داده‌های آزمایشی

جدول ۴-۹- ضریب همبستگی بین خروجی شبکه AK با داده‌های هدف (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9361	0.9284	0.9892	0.9983	0.9760	0.9710	0.9992	ضریب همبستگی به ازای داده‌های آموزشی
0.3642	0.4853	0.8905	0.9909	0.8182	0.7110	0.9907	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.0660	0.4225	0.9527	0.9918	0.9192	0.9261	0.9895	ضریب همبستگی به ازای داده‌های آزمایشی

همانطور که از نتایج موجود در جداول فوق بر می‌آید، مقدار خطای شبکه به ازای کلیه پارامترهای مدل به غیر از h_2 و h_3 (ضخامت لایه دوم و سوم) نسبتاً مناسب بوده و ضرایب همبستگی مربوط به این پارامترها به ازاء داده‌های آزمایشی نیز قابل قبول می‌باشد. یکی از دلایل وجود خطای زیاد در تخمین پارامترهای h_2 و h_3 و همبستگی پایین آنها با داده‌های هدف، ممکن است عدم آموزش مناسب شبکه برای این پارامترها به دلیل کثرت پارامترهای مورد تخمین (پارامترهای خروجی) باشد.

ب- استفاده از داده‌های حاوی ۵٪ نویز

جدول ۴-۱۰- مقدار خطای (MSE) شبکه AK به ازای هر یک از پارامترهای مدل خروجی (در حضور ۵٪ نویز)

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0035	0.0028	0.0001	0.0028	0.004	0.0486	0	مقدار خطا به ازای داده‌های آموزشی
0.0301	0.0929	0.0115	0.0055	0.0039	0.1342	0.001	مقدار خطا به ازای داده‌های اعتبارسنجی
7.7467	1.0157	0.975	0.006	0.0351	1.4227	0.0001	مقدار خطا به ازای داده‌های آزمایشی

جدول ۴-۱۱- ضریب همبستگی بین خروجی شبکه AK با داده‌های هدف (در حضور ۵٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9847	0.9942	0.9851	0.9934	0.9810	0.9727	0.9976	ضریب همبستگی به ازای داده‌های آموزشی
0.2715	0.2601	0.3943	0.9456	0.8166	0.5615	0.9867	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.1412	0.0341	0.5387	0.9487	0.7887	0.337	0.9958	ضریب همبستگی به ازای داده‌های آزمایشی

ج- استفاده از داده‌های حاوی ۱۰٪ نویز

جدول ۴-۱۲- مقدار خطای (MSE) شبکه AK به ازای هر یک از پارامترهای مدل خروجی (در حضور ۱۰٪ نویز)

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0178	0.0111	0.0567	0.0082	0.0704	0.0957	0.0004	مقدار خطا به ازای داده‌های آموزشی
0.7053	0.0011	0.7162	0.0277	0.175	0.2325	0.0093	مقدار خطا به ازای داده‌های اعتبارسنجی
0.6571	2.0789	0.4327	0.0379	0.3501	1.0403	0.0002	مقدار خطا به ازای داده‌های آزمایشی


جدول ۴-۱۳- ضریب همبستگی بین خروجی شبکه AK با داده‌های هدف (در حضور ۱۰٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9506	0.9579	0.9229	0.9825	0.9537	0.9237	0.9904	ضریب همبستگی به ازای داده‌های آموزشی
0.1222	0.2793	0.1262	0.9165	0.6855	0.3497	0.9894	ضریب همبستگی به ازای داده‌های اعتبارسنجی
-0.105	0.2755	-0.049	0.8657	0.6658	0.3736	0.9733	ضریب همبستگی به ازای داده‌های آزمایشی

با بررسی جداول فوق می‌توان گفت در حالتی که به داده‌های ورودی شبکه (داده‌های مقاومت ویژه صحرایی) نویز اضافه می‌کنیم، میزان خطای تخمین به طور فزاینده‌ای افزایش یافته و ضرایب همبستگی پارامترها به سمت صفر و در برخی موارد به سوی اعداد منفی تغییر می‌یابد که نشان از عدم توانایی شبکه برای تشخیص الگو و تخمین پارامترهای مدل در این حالات است.

در ادامه برای اینکه میزان کارایی شبکه (در حالت عدم حضور نویز) سنجیده شود و از طرفی قدرت تعمیم آن مورد بررسی قرار گیرد، از یکسری داده آزمایشی برای آزمایش شبکه استفاده شد که نتایج آن در جدول

(۱۴-۴) و شکل (۱۱-۴) آمده است. از طرفی برای شناخت بهتر از پاسخ شبکه، نتایج حاصل از آن با مدل واقعی مربوطه نیز مورد مقایسه قرار گرفت (شکل ۱۲-۴).




Curve Type = AK

	Layer 1	Layer 2	Layer 3	Layer 4
Apperant Resistivity (ohm-m) :	59.28	84.36	139.09	88.39
Thickness (m) :	25.35	14.60	35.12	--INF--

شکل ۱۱-۴ - خروجی شبکه AK (بدون حضور نویز) به ازاء یکی از داده‌های آزمایشی که به دو صورت نمایش گرافیکی مدل (بالا) و نمایش عددی پارامترها (پایین) آورده شده است.

جدول ۱۴-۴ - مقایسه مدل حاصل از شبکه AK (در حالت عدم حضور نویز) با مدل واقعی به ازای یکی از داده‌های آزمایشی.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
35.20	16.80	24.00	86.40	142.50	73.50	58.10	مدل واقعی
35.12	14.60	25.35	88.39	139.09	84.36	59.28	پاسخ شبکه (در حالت عدم حضور نویز)



شکل ۴-۱۲- مقایسه مدل حاصل از شبکه AK (---) با مدل واقعی (—) به ازاء یک داده آزمایشی (عدم حضور نویز).

با توجه به جدول (۴-۱۴) و نیز شکل (۴-۱۲)، ملاحظه می‌گردد که پاسخ شبکه با مدل واقعی دارای برآزش مناسبی بوده و نشان از آموزش مناسب و قدرت تخمین خوب این شبکه است. وجود اختلافات بین این دو مورد می‌تواند ناشی از تعداد اندک داده‌های مصنوعی و یا عدم پوشش کامل تمام حالات مورد نظر در هنگام آموزش و مواردی از این قبیل است.

۴-۳-۲-۳- شبکه KH

در این قسمت نیز با قرار دادن شبکه در یک حلقه با ۵۰ تکرار و مقایسه نتایج حاصل از هر اجرا، تعداد نرون‌های لایه میانی شبکه برابر ۴۰ نرون انتخاب گردید. با توجه به این مطلب و نیز مطالب بیان شده در بخش‌های قبلی، شبکه مورد نظر طراحی شده و پارامترهای مناسب و بهینه آن انتخاب گردید. بعد از این مرحله، شبکه مذکور با داده‌های مورد نظر (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش داده شد که نتایج حاصل از آن در حالت عدم حضور نویز در جداول (۴-۱۵) و (۴-۱۶) آمده و مابقی نتایج در پیوست ه آورده شده است.

- استفاده از داده‌های بدون نویز

جدول ۴-۱۵- مقدار خطای (MSE) شبکه KH به ازای هر یک از پارامترهای مدل خروجی (عدم حضور نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0068	0	0.0041	0	0	0.0043	0.0001	مقدار خطا به ازای داده‌های آموزشی
0.0851	0.0193	0.0003	0.0003	0	0.0012	0	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0447	0.0894	0.0035	0.0001	0.0059	0.0056	0.0003	مقدار خطا به ازای داده‌های آزمایشی

جدول ۴-۱۶- ضریب همبستگی بین خروجی شبکه KH با داده‌های هدف (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9232	0.9079	0.9795	0.9987	0.9848	0.9850	0.9996	ضریب همبستگی به ازای داده‌های آموزشی
0.6303	0.5803	0.9464	0.9971	0.8328	0.8824	0.9997	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.2817	0.6224	0.9352	0.9981	0.8603	0.8672	0.9994	ضریب همبستگی به ازای داده‌های آزمایشی

در این قسمت با بررسی نتایج فوق ملاحظه می‌گردد که به مانند شبکه AK، این شبکه نیز دارای خطای قابل قبولی در تخمین پارامترهای مربوط به داده‌های آموزشی بوده و ضریب همبستگی بین پاسخ شبکه با داده‌های هدف دارای مقدار مناسبی است و فقط در مورد دو پارامتر آخر یعنی h_2 و h_3 ضعیف عمل نموده است. این امر می‌تواند به علت وجود تعداد زیاد پارامترهای مورد تخمین (۷ پارامتر) توسط یک شبکه و یا بهینه نبودن ساختار مورد استفاده در شبکه حادث شود.

در پایان این بخش و در ادامه کار، برای ارزیابی میزان کارایی شبکه (در حالت عدم حضور نویز) و از طرفی بررسی قدرت تعمیم آن، از یکسری داده آزمایشی برای آزمایش شبکه استفاده شد که نتایج آن در جدول (۴-۱۷) و شکل (۴-۱۳) آمده است. همچنین برای درک بهتر از پاسخ شبکه، نتایج حاصل از آن با مدل واقعی مربوطه مورد مقایسه قرار گرفت (شکل ۴-۱۴).



Curve Type = KH


	Layer 1	Layer 2	Layer 3	Layer 4
Apperant Resistivity (ohm-m) :	15.61	77.62	46.39	64.46
Thickness (m) :	19.17	19.21	17.45	--INF--

شکل ۴-۱۳- خروجی شبکه KH (بدون حضور نویز) به ازاء یکی از داده‌های آزمایشی که به دو صورت

نمایش گرافیکی مدل (بالا) و نمایش عددی پارامترها (پایین) آورده شده است.

جدول ۴-۱۷- مقایسه مدل حاصل از شبکه KH (در حالت عدم حضور نویز) با مدل واقعی به ازای یکی از داده‌های آزمایشی.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
19	12	22	64.8	48.2	73.5	16.5	مدل واقعی
17.45	19.21	19.17	64.46	46.39	77.62	15.61	پاسخ شبکه (در حالت عدم حضور نویز)



شکل ۴-۱۴- مقایسه مدل حاصل از شبکه KH (---) با مدل واقعی (—) به ازاء یک داده آزمایشی (عدم حضور نویز).

با بررسی نتایج حاصل شبکه KH، ملاحظه می‌گردد که این شبکه نیز به خوبی توانسته پارامترهای مدل واقعی را تخمین بزند و فقط در مورد ضخامت لایه دوم میزان اختلاف قابل تأمل است که علت آن بالا بودن میزان خطای تخمین شبکه در مورد این پارامتر با توجه به جدول (۴-۱۵) است.

۴-۳-۲- شبکه KQ

پس از تشکیل ساختار شبکه KQ و قرار دادن آن در یک حلقه با ۵۰ تکرار و مقایسه نتایج حاصل از هر اجرا، تعداد نرون‌های لایه میانی شبکه برابر ۳۷ نرون انتخاب گردید و مانند شبکه قبلی پارامترهای مناسب و بهینه آن انتخاب گردید. بعد از این مرحله، شبکه مذکور با داده‌های مورد نظر (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش داده شد که نتایج حاصل از آن در حالت عدم حضور نویز در جداول (۴-۱۸) و (۴-۱۹) آمده است.

- استفاده از داده‌های بدون نویز

جدول ۴-۱۸- مقدار خطای (MSE) شبکه KQ به ازای هر یک از پارامترهای مدل خروجی (عدم حضور نویز).

پارامترهای مربوط به خروجی شبکه	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3
--------------------------------	----------	----------	----------	----------	-------	-------	-------


0.0028	0.0148	0.0033	0.0002	0	0.0164	0.0003	مقدار خطا به ازای داده‌های آموزشی
0.3497	0.5209	0.0257	0.0002	0.0015	0.0007	0	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0862	0.0344	0.0293	0.0007	0.0009	0.0103	0.0004	مقدار خطا به ازای داده‌های آزمایشی

جدول ۴-۱۹- ضریب همبستگی بین خروجی شبکه KQ با داده‌های هدف (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.8080	0.7780	0.9559	0.9870	0.9469	0.9739	0.9962	ضریب همبستگی به ازای داده‌های آموزشی
0.0436	0.1296	0.9439	0.9943	0.9126	0.9438	0.9811	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.2567	0.1002	0.9168	0.9908	0.8668	0.9241	0.9883	ضریب همبستگی به ازای داده‌های آزمایشی

با توجه به مقادیر حاصل از آموزش شبکه KQ که در جداول فوق آورده شده است، به خوبی مشخص می‌گردد که در این حالت نیز مانند شبکه‌های نوع قبلی، خطای تخمین مربوط به هر سه پارامتر ضخامت نسبتاً بالا بوده و تخمین این پارامترها را با خطا مواجه خواهد کرد ولی در عوض پارامترهای مقاومت ویژه هر چهار لایه دارای خطاهای قابل قبول و ضرایب همبستگی مناسبی می‌باشند. علت وجود خطا در تخمین ضخامت لایه‌ها می‌تواند زیاد بودن تعداد پارامترهای مورد تخمین توسط شبکه باشد.

در ادامه مطالعه، برای بررسی کارایی شبکه (در حالت عدم حضور نویز) و نیز قدرت تعمیم آن از یکسری داده‌های آزمایشی برای آزمایش شبکه استفاده شد که نتایج آن در جدول (۴-۲۰) و شکل (۴-۱۵) آمده است. در نهایت نیز برای شناخت دقیقتر شبکه، پاسخ آن با مدل واقعی مربوطه نیز مورد مقایسه قرار گرفت (شکل ۴-۱۶).




Curve Type = KQ

	Layer 1	Layer 2	Layer 3	Layer 4
Apperant Resistivity (ohm-m) :	28.05	170.67	132.73	82.95
Thickness (m) :	17.20	34.85	23.09	--INF--

شکل ۴-۱۵- خروجی شبکه KQ (بدون حضور نویز) به ازاء یکی از داده‌های آزمایشی که به دو صورت نمایش گرافیکی مدل (بالا) و نمایش عددی پارامترها (پایین) آورده شده است.

جدول ۴-۲۰- مقایسه مدل حاصل از شبکه KQ (در حالت عدم حضور نویز) با مدل واقعی به ازای یکی از داده‌های آزمایشی.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
21	35	18	78.2	142	186	26.5	مدل واقعی
23.09	34.85	17.20	82.95	132.73	170.67	28.05	پاسخ شبکه (در حالت عدم حضور نویز)



شکل ۴-۱۶- مقایسه مدل حاصل از شبکه KQ (---) با مدل واقعی (—) به ازاء یک داده آزمایشی (عدم حضور نویز).

همانگونه که از جدول (۴-۲۰) و شکل (۴-۱۶) مشخص است، این شبکه به ازاء داده آزمایشی مورد نظر نسبت به مدل واقعی پاسخ کاملاً قابل قبولی ارائه نموده و از قدرت بالایی در تخمین پارامترهای این مدل برخوردار است.

۴-۳-۵- شبکه QQ

پس از تشکیل ساختار شبکه QQ با توجه به مطالب بیان شده، با قرار دادن شبکه در یک حلقه با ۵۰ تکرار و مقایسه نتایج حاصل از هر اجرا، تعداد نرون‌های لایه میانی شبکه برابر ۳۷ نرون انتخاب گردید. بعد از تشکیل ساختار بهینه برای شبکه مذکور، این شبکه با داده‌های مورد نظر (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش داده شد که نتایج حاصل از آن در حالت عدم حضور نویز در جداول (۴-۲۱) و (۴-۲۲) آمده است.

- استفاده از داده‌های بدون نویز

جدول ۴-۲۱- مقدار خطای (MSE) شبکه QQ به ازای هر یک از پارامترهای مدل خروجی (عدم حضور نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0023	0.0252	0.0027	0.0001	0.0019	0.0004	0.0001	مقدار خطا به ازای داده‌های آموزشی
0.4626	0.0099	0.0015	0	0.0115	0.0003	0.0001	مقدار خطا به ازای داده‌های اعتبارسنجی
0.18	0.292	0.0155	0	0.0056	0.0018	0	مقدار خطا به ازای داده‌های آزمایشی

جدول ۴-۲۲- ضریب همبستگی بین خروجی شبکه QQ با داده‌های هدف (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9545	0.9189	0.9828	0.9995	0.9833	0.9887	0.9991	ضریب همبستگی به ازای داده‌های آموزشی
0.5952	0.5886	0.9427	0.9986	0.8530	0.9684	0.9985	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.4448	0.4248	0.8982	0.9981	0.8503	0.8956	0.9931	ضریب همبستگی به ازای داده‌های آزمایشی

با انجام بررسی بر روی مقادیر موجود در جداول فوق که در واقع پس از توقف فرآیند آموزش حاصل شده‌اند، به خوبی مشخص است که در این شبکه نیز به مانند شبکه‌های تخمینگر قبلی، دارای قدرت مناسب در تخمین پارامترهای مدل QQ بوده و فقط در مورد دو پارامتر آخر مقداری از قدرت شبکه کاسته شده است. این مطلب به خوبی در جدول (۴-۲۲) نمایان است. علت آن نیز می‌تواند ناشی از تعدد پارامترهای مورد تخمین توسط شبکه‌های تخمینگر باشد.

در ادامه مبحث، برای اینکه میزان کارایی شبکه (در حالت عدم حضور نویز) سنجیده شود و از طرفی قدرت تعمیم آن مورد بررسی قرار گیرد، از یکسری داده آزمایشی برای آزمایش شبکه استفاده شد که نتایج آن در جدول (۴-۲۳) و شکل (۴-۱۷) آمده است. در نهایت نیز پاسخ شبکه با مدل واقعی مربوطه مورد مقایسه قرار گرفت (شکل ۴-۱۸).




Curve Type = QQ

	Layer 1	Layer 2	Layer 3	Layer 4
	-----	-----	-----	-----
Apperant Resistivity (ohm-m) :	93.51	83.87	67.10	18.27
Thickness (m) :	11.07	32.97	19.77	--INF--

شکل ۴-۱۷- خروجی شبکه QQ (بدون حضور نویز) به ازاء یکی از داده‌های آزمایشی که به دو صورت نمایش گرافیکی مدل (بالا) و نمایش عددی پارامترها (پایین) آورده شده است.

جدول ۴-۲۳- مقایسه مدل حاصل از شبکه QQ (در حالت عدم حضور نویز) با مدل واقعی به ازای یکی از داده‌های آزمایشی.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
26	30	11	18.40	62.40	84.20	92.60	مدل واقعی
19.77	32.97	11.07	18.27	67.10	83.87	93.51	پاسخ شبکه (در حالت عدم حضور نویز)



شکل ۴-۱۸- مقایسه مدل حاصل از شبکه QQ (---) با مدل واقعی (—) به ازاء یک داده آزمایشی (عدم حضور نویز).

با انجام بررسی بر روی نتایج حاصل در جدول (۴-۲۳) و نمودارهای مربوطه در شکل (۴-۱۸)، مشخص می‌گردد که این شبکه به خوبی توانسته پارامترهای مربوطه را تخمین بزند. وجود اختلاف در تخمین ضخامت لایه دوم با مدل واقعی نیز به علت وجود خطای نسبتاً بالا برای این پارامتر با توجه به جداول (۴-۲۱) و (۴-۲۲) است.

۴-۳-۲-۶- شبکه QH

پس از تشکیل ساختار شبکه QH با توجه به مطالب بیان شده، با قرار دادن این شبکه در یک حلقه با ۵۰ تکرار، تعداد نرون‌های لایه میانی شبکه برابر ۳۱ نرون انتخاب گردید و با لحاظ موارد قبلی، شبکه مورد نظر طراحی شده و پارامترهای مناسب و بهینه آن انتخاب گردید. بعد از این مرحله، شبکه مذکور با داده‌های مورد نظر (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش داده شد که نتایج حاصل از آن در حالت عدم حضور نویز در جداول (۴-۲۵) و (۴-۲۶) آمده است.

- استفاده از داده‌های بدون نویز

جدول ۴-۲۴- مقدار خطای (MSE) شبکه QH به ازای هر یک از پارامترهای مدل خروجی (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.142	0.0021	0.0017	0.0001	0.0076	0	0.0003	مقدار خطا به ازای داده‌های آموزشی
0	0.1135	0.0691	0.0003	0.0052	0.001	0	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0652	0.2053	0.0098	0	0.0034	0	0.0001	مقدار خطا به ازای داده‌های آزمایشی


جدول ۴-۲۵- ضریب همبستگی بین خروجی شبکه QH با داده‌های هدف (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.8050	0.8960	0.9692	0.9924	0.9675	0.9600	0.9983	ضریب همبستگی به ازای داده‌های آموزشی
0.3586	0.3315	0.8226	0.9681	0.9552	0.8389	0.9805	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.1596	0.2524	0.5238	0.9940	0.8489	0.8274	0.9907	ضریب همبستگی به ازای داده‌های آزمایشی

در این حالت نیز با توجه به جداول فوق و مقایسه خطاها و نیز ضرایب همبستگی مربوط به هر پارامتر به راحتی مشخص می‌شود که این شبکه نیز در تخمین مقادیر مقاومت ویژه خیلی خوب عمل نموده و در مورد مقادیر ضخامت لایه‌ها مخصوصاً ضخامت لایه دوم و سوم دارای خطای بالاتر و ضریب همبستگی پایین‌تری است. این امر می‌تواند به علت عدم بهینه بودن ساختار و معماری شبکه باشد و یا از تخمین همزمان ۷ پارامتر ناشی گردد که فرآیند آموزش را با مشکل مواجه ساخته است.

پس از انجام مراحل فوق و آموزش شبکه‌ها در حالات مورد نظر، برای اینکه میزان کارایی شبکه (در حالت عدم حضور نویز) سنجیده شود و از طرفی قدرت تعمیم آن مورد بررسی قرار گیرد، از یکسری داده‌های آزمایشی برای آزمایش شبکه استفاده شد که نتایج آن در جدول (۴-۲۶) و شکل (۴-۱۹) آمده است. در نهایت نیز پاسخ شبکه با مدل واقعی مربوطه مورد مقایسه قرار گرفت (شکل ۴-۲۰).

نکته مهمی که لازم به ذکر است، آنست که در کلیه حالات چهار لایه، شبکه طبقه‌بندی به خوبی توانسته نوع منحنی سونداژ را تعیین کند.




Curve Type = QH

	Layer 1	Layer 2	Layer 3	Layer 4
	=====	=====	=====	=====
Apperant Resistivity (ohm-m) :	82.97	55.78	14.77	102.40
Thickness (m) :	18.89	27.47	42.69	--INF--

شکل ۴-۱۹- خروجی شبکه QH (بدون حضور نویز) به ازاء یکی از داده‌های آزمایشی که به دو صورت نمایش گرافیکی مدل (بالا) و نمایش عددی پارامترها (پایین) آورده شده است.

جدول ۴-۲۶- مقایسه مدل حاصل از شبکه QH (در حالت عدم حضور نویز) با مدل واقعی به ازای یکی از داده‌های آزمایشی.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
33	26	18	99.80	12.50	58.30	86.40	مدل واقعی
42.69	27.47	18.89	102.40	14.77	55.78	82.97	پاسخ شبکه (در حالت عدم حضور نویز)



شکل ۴-۲۰- مقایسه مدل حاصل از شبکه QH (---) با مدل واقعی (—) به ازاء یک داده آزمایشی (عدم حضور نویز).

از بررسی نتایج جدول (۴-۲۶) و مشاهده نمودار فوق، می‌توان اظهار داشت که شبکه QH در تخمین پارامترهای این مدل چهار لایه‌ای به خوبی عمل کرده و به دلیل وجود خطای نسبتاً بیشتر در هنگام آموزش (با توجه به جدول (۴-۲۴))، در تخمین ضخامت لایه دوم دارای مقداری خطا است.

۴-۳-۲-۷- شبکه HK

پس از تشکیل ساختار شبکه HK و با انجام عملیاتی مشابه موارد قبلی، تعداد نرون‌های لایه میانی شبکه برابر ۳۸ نرون انتخاب گردید و سپس شبکه مورد نظر طراحی شده و پارامترهای مناسب و بهینه آن انتخاب گردید. پس از این مرحله، شبکه مذکور با داده‌های مورد نظر (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش یافت. نتایج حاصل از آموزش شبکه در حالت عدم حضور نویز در جداول (۴-۲۷) و (۴-۲۸) آمده است.

- استفاده از داده‌های بدون نویز

جدول ۴-۲۷- مقدار خطای (MSE) شبکه HK به ازای هر یک از پارامترهای مدل خروجی (عدم حضور نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0697	0.0933	0.0139	0.0003	0.0419	0.0296	0.0033	مقدار خطا به ازای داده‌های آموزشی
0.8251	0.7479	0.0118	0.0109	0.0255	0.0403	0.0002	مقدار خطا به ازای داده‌های اعتبارسنجی
0.441	1.293	0.0016	0	0.1086	0.048	0.0079	مقدار خطا به ازای داده‌های آزمایشی

جدول ۴-۲۸- ضریب همبستگی بین خروجی شبکه HK با داده‌های هدف (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.8114	0.7685	0.8909	0.9924	0.9371	0.9149	0.9696	ضریب همبستگی به ازای داده‌های آموزشی
0.4235	0.5424	0.6952	0.9817	0.9102	0.7372	0.9489	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.3958	0.2208	0.8439	0.9874	0.7832	0.8459	0.9490	ضریب همبستگی به ازای داده‌های آزمایشی

با انجام بررسی‌های لازم بر روی مقادیر خطا و ضرایب همبستگی مربوط به هر یک از پارامترهای مدل، به این نتیجه می‌رسیم که این شبکه نسبت به چهار پارامتر مقاومت ویژه و ضخامت لایه اول، دارای آموزش موفق بوده و از قدرت مناسبی در تخمین این پارامترها برخوردار است؛ و در عوض نسبت به دو پارامتر آخر یعنی ضخامت لایه دوم و سوم به دلیل بالا بودن نسبی خطا، از قدرت تخمین کمتری برخوردار بوده و می‌تواند تفسیر نتایج را با مشکل مواجه سازد.

در ادامه برای اینکه میزان کارایی شبکه (در حالت عدم حضور نویز) سنجیده شود و از طرفی قدرت تعمیم آن مورد بررسی قرار گیرد، از یکسری داده آزمایشی برای آزمایش شبکه استفاده شد که نتایج آن در جدول (۴-۲۹) و شکل (۴-۲۱) آمده است. علاوه بر آن نتایج شبکه با مدل واقعی مربوطه نیز مورد مقایسه قرار گرفت که در شکل (۴-۲۲) آورده شده است.



Curve Type = HK


	Layer 1	Layer 2	Layer 3	Layer 4
Apperant Resistivity (ohm-m) :	66.18	54.41	93.41	55.32
Thickness (m) :	23.65	30.87	31.67	--INF--

شکل ۴-۲۱- خروجی شبکه HK (بدون حضور نویز) به ازاء یکی از داده‌های آزمایشی که به دو صورت

نمایش گرافیکی مدل (بالا) و نمایش عددی پارامترها (پایین) آورده شده است.

جدول ۴-۲۹- مقایسه مدل حاصل از شبکه HK (در حالت عدم حضور نویز) با مدل واقعی به ازای یکی از داده‌های آزمایشی.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
31	25	19	61.3	72.3	55.6	69.8	مدل واقعی
31.67	30.87	23.65	55.32	93.41	54.41	66.18	پاسخ شبکه (در حالت عدم حضور نویز)



شکل ۴-۲۲- مقایسه مدل حاصل از شبکه HK (---) با مدل واقعی (—) به ازاء یک داده آزمایشی (عدم حضور نویز).

با مشاهده نتایج موجود در جدول (۴-۲۹) ملاحظه می‌گردد که به دلیل وجود خطای نسبتاً بالا در مورد مقاومت ویژه لایه سوم و نیز ضخامت لایه دوم و سوم و از طرفی پایین بودن ضریب همبستگی پارامترهای مذکور (جدول (۴-۲۸)) که خود می‌تواند ناشی از عدم بهینه بودن ساختار این شبکه و یا وجود کاستی در تعداد داده‌های مصنوعی و ... باشد، تخمین این پارامترها با دقت کمتری صورت گرفته است.

۴-۳-۲-۸- شبکه HA

پس از تشکیل ساختار شبکه HA و با توجه به مطالب قبلی، تعداد نرونهاى لایه میانی این شبکه برابر ۲۹ نرون انتخاب گردید و سپس شبکه مورد نظر طراحی شده و پارامترهای مناسب و بهینه آن انتخاب گردید. بعد از این مرحله، شبکه مذکور با داده‌های مورد نظر (هم با داده‌های حاوی نویز و هم با داده‌های بدون نویز) آموزش داده شد. نتایج حاصل از این فرآیند در حالت عدم حضور نویز در جداول (۴-۳۰) و (۴-۳۱) آمده است.

- استفاده از داده‌های بدون نویز

جدول ۴-۳۰- مقدار خطای (MSE) شبکه HA به ازای هر یک از پارامترهای مدل خروجی (عدم حضور نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0251	0.0034	0.0047	0.0019	0.0086	0.0516	0.0017	مقدار خطا به ازای داده‌های آموزشی
0.0152	0.042	0.0008	0.0072	0.0355	0.0009	0.0116	مقدار خطا به ازای داده‌های اعتبارسنجی
0.5815	0.6784	0.0107	0.003	0.0066	0.0075	0.0033	مقدار خطا به ازای داده‌های آزمایشی

جدول ۴-۳۱- ضریب همبستگی بین خروجی شبکه HA با داده‌های هدف (عدم حضور نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.7476	0.8267	0.9680	0.9844	0.9304	0.9475	0.9951	ضریب همبستگی به ازای داده‌های آموزشی
0.1565	0.4404	0.9593	0.9904	0.8267	0.8987	0.9770	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.1429	0.3200	0.9439	0.9894	0.9064	0.9054	0.9935	ضریب همبستگی به ازای داده‌های آزمایشی

با نگاهی به مقادیر موجود در جداول فوق به راحتی می‌توان فهمید که این شبکه نیز مانند اکثر شبکه‌های قبلی به غیر از دو پارامتر آخر یعنی ضخامت لایه‌های دوم و سوم، در بقیه موارد دارای مقادیر امیدوار کننده‌ای بوده و از قدرت تخمین نسبتاً مناسبی برخوردار خواهد بود که علت آن باز هم به تعدد پارامترهای مورد تخمین (۷ پارامتر) توسط یک شبکه، یا عدم بهینه بودن ساختار شبکه و یا کم بودن تعداد داده‌های آموزشی بر می‌گردد.

در ادامه مطلب برای اینکه میزان کارایی شبکه (در حالت عدم حضور نویز) سنجیده شود و از طرفی قدرت تعمیم آن مورد بررسی قرار گیرد، از یکسری داده‌های آزمایشی برای آزمایش شبکه استفاده شد که نتایج آن در جدول (۴-۳۲) و شکل (۴-۲۳) آمده است. همچنین پاسخ شبکه با مدل واقعی مربوطه نیز مورد مقایسه قرار گرفت (شکل ۴-۲۴).




Curve Type = HA

	Layer 1	Layer 2	Layer 3	Layer 4
Apperant Resistivity (ohm-m) :	53.30	25.49	111.99	144.24
Thickness (m) :	12.37	45.76	18.45	--INF--

شکل ۴-۲۳- خروجی شبکه HA (بدون حضور نویز) به ازاء یکی از داده‌های آزمایشی که به دو صورت نمایش گرافیکی مدل (بالا) و نمایش عددی پارامترها (پایین) آورده شده است.

جدول ۴-۳۲- مقایسه مدل حاصل از شبکه HA (در حالت عدم حضور نویز) با مدل واقعی به ازای یکی از داده‌های آزمایشی.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
24	37	16	157	118	25	48.2	مدل واقعی
18.45	45.76	12.37	144.24	111.99	25.49	53.30	پاسخ شبکه (در حالت عدم حضور نویز)




شکل ۴-۲۴- مقایسه مدل حاصل از شبکه HA (---) با مدل واقعی (—) به ازاء یک داده آزمایشی (عدم حضور نویز).

همانطور که در جدول (۴-۳۲) و نیز شکل (۴-۲۴) مشاهده می‌شود، مقادیر مربوط به ضخامت هر سه لایه به دلیل وجود خطای بالاتر نسبت به سایر پارامترها (با توجه به جدول ۴-۳۰)، دارای اختلاف قابل ملاحظه‌ای نسبت به مدل واقعی بوده و شبکه از قدرت تخمین کمتری در مورد این پارامترها برخوردار است.

۴-۳-۳- مقایسه نتایج شبکه‌های تخمینگر

با توجه به نتایج بدست آمده در بخشهای قبلی، برای اینکه شبکه‌های تخمینگر به صورت یکجا مورد مقایسه قرار گیرند، میانگین مربعات خطای مربوط به آنها با هم در شکل (۴-۲۵) آورده شده است. همانطور که در این شکل مشاهده می‌گردد از بین ۸ نوع شبکه طراحی شده تخمینگر، شبکه KH دارای کمترین خطای آموزش و شبکه KQ دارای بیشترین مقدار خطا می‌باشد و با توجه به این مقدار خطا، قدرت تخمین هر یک با دیگری متفاوت خواهد بود. البته لازم به ذکر است که چنین حالتی در این تحقیق و با توجه به داده‌های مصنوعی و نیز شبکه‌های آموزش دیده مشاهده می‌شود که با تغییر داده‌های مصنوعی و نیز شبکه‌های عصبی می‌تواند تغییر کند.



شکل ۴-۲۵- مقایسه نتایج مربوط به خطاهای حاصل از آموزش شبکه‌های عصبی تخمینگر (عدم حضور نویز).

۴-۴- بررسی قدرت تعمیم شبکه عصبی طراحی شده با استفاده از داده‌های واقعی

در این قسمت از تحقیق و در ادامه بخش قبلی به بررسی قدرت تعمیم شبکه‌های عصبی طراحی شده با استفاده از داده‌های واقعی حاصل از برداشت‌های ژئوفیزیکی مربوط به دو کار تحقیقاتی پرداخته می‌شود و نتایج بدست آمده از نرم افزار Resix-IP و شبکه‌های عصبی طراحی شده مورد مقایسه قرار می‌گیرند. لازم به ذکر است که تمام داده‌های واقعی مورد استفاده در این بخش همگی با استفاده از نرم افزار Resix-IP تفسیر شده و نتایج آنها موجود می‌باشد (مرادزاده، ۱۳۸۳). نکته مهمی که در اینجا بایستی یادآور شد آن است که داده‌های ورودی به شبکه عصبی نیاز به هیچگونه پردازش اولیه نظیر عملیات Shift Segment نداشته و مستقیماً مورد ارزیابی قرار می‌گیرند، در حالی که برای استفاده از آنها در نرم افزار Resix-IP حتماً بایستی عملیات فوق صورت گیرد.

۴-۴-۱- مطالعه موردی

اکتشاف آبهای زیرزمینی در استان سمنان (مطالعه دشتهای اطراف شاهرود) (مرادزاده، ۱۳۸۳)

منطقه مورد مطالعه در این طرح، بخشی از دشت گورخان است که در شمال شرق ایران و در ۴۰ کیلومتری شمال شرقی شاهرود و در مسیر جاده آسفالت شاهرود - آزادشهر نرسیده به پادگان چهل دختر قرار دارد. در این منطقه یک رشته قنات با آبدی نسبتاً خوب وجود دارد که مادر چاه آن در ۶۰۰ متری غرب راه دار خانه گورخان قرار دارد. از طرفی چندین چاه آب نیز در قسمتهای جنوبی دشت حفر گردیده است. هدف اصلی طرح فوق، شناسایی لایه‌های مختلف، تعیین عمق سطح آب زیرزمینی، تعیین ضخامت لایه آبدار و نیز تعیین جنس سنگ کف بود که بدین منظور مطابق شکل (۴-۲۶)، چندین سونداژ الکتریکی مقاومت ویژه در این منطقه انتخاب گردید.

در این تحقیق از بین این سونداژها، سونداژهای شماره ۴۰۱، ۴۰۲ و ۱۰۵ (نزدیک مادر چاه قنات یا Wghanat) و سونداژهای ۱۰۸ و ۱۰۹ (نزدیک چاه W3)، سونداژ شماره ۱۱۱ (نزدیک چاه W1) و سونداژ شماره ۲۱۱ (نزدیک چاه W4) برای استفاده در شبکه عصبی که امکان مقایسه نتایج آن با نتایج نرم افزار Resix-IP و نیز با لاگ‌های مربوط به چاهای W3 و W4 میسر بود، انتخاب گردیدند. در جدول (۴-۳۳) مشخصات مربوط به این چاه‌ها آورده شده است. در شکل (۴-۲۷) نیز ستون چینه شناسی حاصل از حفاری چاه‌های شماره ۳ و ۴ آورده شده است.



ستون چینه شناسی چاه شماره ۳ (W3)




ستون چینه شناسی چاه شماره ۴ (W4)

شکل ۴-۲۷- ستون چینه شناسی حاصل از حفاری برای چاههای شماره ۳ و ۴ (مرادزاده، ۱۳۸۳).

در ادامه، نتایج حاصل از شبکه عصبی برای سونداژهای ۴۰۱، ۴۰۲، ۱۰۵، ۱۰۸، ۱۰۹، ۱۱۱ و ۲۱۱ که شامل پارامترهای تخمین زده شده و گرافهای تولید شده است، آورده شده و با نتایج نرم افزار Resix-IP مقایسه می گردد (اشکال ۴-۲۸ تا ۴-۳۴). همانطور که خواهید دید، مشاهده می گردد که شبکه عصبی توانسته است مقادیر مقاومت ویژه لایه های مختلف و ضخامت آنها را با دقت خوبی تخمین بزند (جدول ۴-۳۴ تا ۴-۴۰).

• سونداژ ۴۰۱




شکل ۴-۲۸- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۴۰۱.

جدول ۴-۳۴- مقایسه بین پاسخ شبکه با خروجی نرم افزار **Resix-IP** برای داده‌های واقعی سونداژ ۴۰۱.

پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	144.97	24.44	207.87	37.17	0.44	10.17	41.85	52.46
مدل حاصل از نرم افزار Resix-IP	140.21	23.98	221.05	45.10	0.98	9.02	38.77	48.75

• سونداژ ۴۰۲





شکل ۴-۲۹- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۴۰۲.

جدول ۴-۳۵- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۴۰۲.

پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	ρ_5	h_1	h_2	h_3	h_4	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	235.45	33.54	304.33	51.8	-	4.25	26.45	26.69	-	53.14
مدل حاصل از نرم افزار Resix-IP	266.2	45.1	384.7	64.5	13.28	2.36	24.52	25.22	351.3	52.10

• سونداژ ۱۰۵



شکل ۴-۳۰- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۰۵.

جدول ۴-۳۶- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۱۰۵.


پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	289.58	38.52	156.11	73.82	0.81	10.15	66.68	77.64
مدل حاصل از نرم افزار Resix-IP	401.8	48.8	226.23	68.17	0.798	8.27	58.17	67.24

با بررسی نتایج بدست آمده برای سه سونداژ ۴۰۱، ۴۰۲ و ۱۰۵ که همگی در نزدیکی مادر چاه قنات هستند، به وضوح مشخص است که شبکه‌های عصبی طراحی شده به خوبی توانسته‌اند مقادیر مقاومت ویژه و ضخامت هر لایه را با دقت مناسبی تخمین بزنند. فقط در مورد سونداژ ۴۰۲ که در واقع یک حالت پنج لایه است، از آنجا که شبکه‌های طراحی شده در این تحقیق فقط مربوط به زمین‌های چهار لایه هستند، لذا در

مورد لایه آخر، شبکه تخمین مناسبی نسبت حالت پنج لایه انجام نداده است. در ادامه عمق تخمینی برخورد به آب در این سه سونداژ و نیز در مادر چاه قنات آورده شده است. لازم به ذکر است علت وجود اختلاف بین عمق سطح آب بدست آمده از سونداژها با چاه موجود، وجود اختلاف فاصله بین محل این سونداژها با چاه مورد نظر، وجود اختلافات توپوگرافی و اندکی نیز به خاطر وجود خطاهای انسانی و دستگاهی در هنگام برداشت و نیز تفسیر داده‌ها است.

عمق سطح آب (متر)	موقعیت
۴۰	مادر چاه قنات
۵۲/۴۶	سونداژ ۴۰۱ (مدل شبکه)
۴۸/۷۵	سونداژ ۴۰۱ (مدل Resix-IP)
۵۳/۱۴	سونداژ ۴۰۲ (مدل شبکه)
۵۲/۱۰	سونداژ ۴۰۲ (مدل Resix-IP)
۷۷/۶۴	سونداژ ۱۰۵ (مدل شبکه)
۶۷/۲۴	سونداژ ۱۰۵ (مدل Resix-IP)

• سونداژ ۱۰۸




شکل ۴-۳۱- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۰۸.

جدول ۴-۳۷- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۱۰۸.

امترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	ρ_5	h_1	h_2	h_3	h_4	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	97.80	28.42	111.1	68.91	-	3.86	16.34	68.25	-	88.45
مدل حاصل از نرم افزار Resix-IP	120.85	36.1	123.1	75.2	16.9	0.88	21.49	51.47	516.08	73.84

• سونداژ ۱۰۹



شکل ۴-۳۲- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۰۹.


جدول ۴-۳۸- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۱۰۹.

مترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	ρ_5	h_1	h_2	h_3	h_4	عمق سطح آب
ل حاصل از شبکه عصبی مصنوعی	172.04	40.74	129.2	57.32	-	2.17	26.6	52.41	-	81.18
ل حاصل از نرم افزار Resix-IP	146.2	40.6	118.8	69.79	31.67	1.71	19.36	52.6	263.6	73.66

همانطور که از نتایج نرم افزار Resix-IP برای دو سونداژ ۱۰۸ و ۱۰۹ مشخص است، مشاهده می‌شود که با وجود اینکه مدل‌های مربوطه ۵ لایه هستند ولی با این حال شبکه‌های عصبی طراحی شده توانسته‌اند مقادیر مقاومت ویژه و ضخامت هر لایه به غیر از لایه آخر را با اختلاف نه چندان زیادی تخمین بزنند که علت به ماهیت شبکه‌های طراحی شده که مخصوص زمین‌های چهار لایه هستند، بر می‌گردد.

از آنجا که سونداژهای فوق در نزدیکی چاه W3 واقع شده‌اند، در ادامه عمق تخمینی برخورد به آب در آنها آورده شده است. لازم به ذکر است علت وجود اختلاف بین عمق سطح آب بدست آمده از سونداژها با چاه موجود، وجود اختلاف فاصله بین محل این سونداژها با چاه مورد نظر، وجود اختلافات توپوگرافی و اندکی نیز به خاطر وجود خطاهای انسانی و دستگاهی در هنگام برداشت و نیز تفسیر داده‌ها است.


موقعیت	عمق سطح آب (متر)
چاه W3	۷۹
سونداژ ۱۰۸ (مدل شبکه)	۸۸/۴۵
سونداژ ۱۰۸ (مدل Resix-IP)	۷۳/۸۴
سونداژ ۱۰۹ (مدل شبکه)	۸۱/۱۸
سونداژ ۱۰۹ (مدل Resix-IP)	۷۳/۶۶



شکل ۴-۳۳- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۱۱.

جدول ۴-۳۹- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۱۱۱.

پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	ρ_5	h_1	h_2	h_3	h_4	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	73.99	41.66	133.23	63.74	-	4.82	27.99	49.48	-	82.29
مدل حاصل از نرم افزار Resix-IP	81.7	51.1	104.9	76.03	32.6	1.17	21.12	50.5	246.04	72.80



شکل ۴-۳۴- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۲۱۱.

جدول ۴-۴۰- مقایسه بین پاسخ شبکه با خروجی نرم افزار **Resix-IP** برای داده‌های واقعی سونداژ ۲۱۱.

پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	22.69	75.71	130.68	48.66	5.58	16.04	49.79	71.64
مدل حاصل از نرم افزار Resix-IP	23.54	76.72	133.7	48.12	3.74	13.47	43.56	60.77

در مورد سونداژ ۱۱۱ که در نزدیکی چاه W1 واقع شده و عمق سطح آب در آن ۶۸ متر است، بایستی اظهار داشت این سونداژ که مربوط به یک مدل ۵ لایه است، به کمک شبکه‌های عصبی طراحی شده مربوط به مدل‌های چهار لایه‌ای مورد تحلیل قرار گرفته است و به همین دلیل به غیر از تخمین پارامترهای لایه آخر،


در تخمین سایر پارامتر نسبتاً خوب عمل نموده است. عمق تخمینی سطح آب توسط شبکه و نرم افزار Resix-IP برای این سونداژ به ترتیب برابر با ۸۲/۲۹ و ۷۲/۸۰ متر است. وجود اختلاف چند متری بین این مقادیر می تواند به خاطر وجود خطای آموزش در شبکه مورد نظر است.

در مورد سونداژ ۲۱۱ نیز که در نزدیکی چاه W4 قرار داشته و عمق سطح آب در آن ۵۶ متر است ، با توجه به ستون چینه شناسی مربوط به این چاه در شکل (۴-۲۷) و نتایج حاصل از تخمین پارامترهای مدل توسط نرم افزار Resix-IP و نیز شبکه مشاهده می شود که این موارد تقریباً رفتار مشابهی دارند و فقط شبکه در تخمین دو پارامتر آخر یعنی ضخامت لایه دوم و سوم دارای اندکی خطا است که به دلیل وجود خطای تخمین نسبتاً بالاتری در مورد این پارامترها است که در بخشهای قبلی به آن اشاره شد. از طرفی لازم به ذکر است شبکه عصبی عمق سطح آب را در محل این سونداژ ۷۱/۶۴ متر تخمین زده که با نتیجه حاصل از نرم افزار Resix-IP که این عمق را ۶۶/۷۷ متر برآورد نموده است، دارای اختلاف اندکی است و دلیل آن می تواند وجود خطا در آموزش شبکه مورد نظر باشد.

۲-۴-۴- مطالعه موردی ۲

مطالعات هیدروژئولوژیکی آب مورد نیاز کارخانه سیمان رویال سمنان (دولتی و مرادزاده، ۱۳۸۴)



منطقه مورد مطالعه در این تحقیق، در ۱۴ کیلومتری شمال سمنان و ۶ کیلومتری شرق مهدی شهر واقع شده است. دسترسی به این محل از جاده آسفalte سمنان - مهدی شهر امکان پذیر می باشد. هدف اصلی این طرح، بررسی وضعیت سفره آب زیرزمینی منطقه سیمان رویال با استفاده از روش ژئوفیزیکی مقاومت ویژه است که بدین منظور مطابق شکل ۴-۳۵، چندین پروفیل سونداژزنی مقاومت ویژه در این منطقه انتخاب گردید.



شکل ۴-۳۵- نقشه توپوگرافی تهیه شده که محل سونداژها (دایره های آبی) و پروفیل های مورد برداشت روی آن آمده است (دولتی و مرادزاده، ۱۳۸۴).

در این تحقیق از بین این سونداژها، سونداژهای شماره ۱۰۲، ۳۰۳، ۳۰۵، ۳۰۶، ۴۰۳ و ۶۰۴ که همگی مربوط به حالت چهار لایه بوده و امکان مقایسه نتایج آن با نتایج نرم افزار Resix-IP میسر بود، انتخاب گردیدند (اشکال ۴-۳۶ تا ۴-۴۲ و جداول ۴-۴۱ تا ۴-۴۷). تحلیل نتایج مربوط به این سونداژها در پایان این بخش و پس از ارائه نتایج آورده شده است.

• سونداژ ۱۰۲




شکل ۴-۳۶- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۱۰۲.

جدول ۴-۴۱- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۱۰۲.

پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	210.26	23.85	37.71	734.89	10.11	24.10	93.29	34.21
مدل حاصل از نرم افزار Resix-IP	293.67	14.42	34.46	1916.4	1.32	34.36	108.77	35.68

سونداژ ۳۰۳




شکل ۴-۳۷- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۳۰۳.

جدول ۴-۴۲- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۳۰۳.

پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	41.98	12.87	29.67	6.73	10.69	24.65	140.80	35.34
مدل حاصل از نرم افزار Resix-IP	35.55	10.87	31	1.37	2.61	35.67	119.65	38.28

• سونداژ ۳۰۵




شکل ۴-۳۸- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۳۰۵.

جدول ۴-۴۳- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۳۰۵.

پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	5.04	10.03	4.70	55.59	2.91	10.73	80.57	94.21
مدل حاصل از نرم افزار Resix-IP	4.7	9.45	5.47	56.28	2.39	11.42	82.68	96.49

• سونداژ ۳۰۶




شکل ۴-۳۹- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۳۰۶.

جدول ۴-۴۴- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۳۰۶.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
26.94	12.51	5.35	12.40	863.84	3.84	96.06	مدل حاصل از شبکه عصبی مصنوعی
23.49	12.55	1.298	6.94	2219.4	5.52	88.95	مدل حاصل از نرم افزار Resix-IP

• سونداژ ۴۰۳




شکل ۴-۴۰- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۴۰۳.

جدول ۴-۴۵- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۴۰۳.

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مدل مورد نظر جهت تخمین
41.26	46.80	5.36	9.92	154.35	12.95	9.21	مدل حاصل از شبکه عصبی مصنوعی
41.47	42.42	2.22	2.106	201.05	11.51	7.198	مدل حاصل از نرم افزار Resix-IP

• سونداژ ۶۰۴



شکل ۴-۴۱- خروجی حاصل از شبکه عصبی (بالا) و خروجی حاصل از نرم افزار Resix-IP (پایین) از سونداژ ۶۰۴.

جدول ۴-۴۶- مقایسه بین پاسخ شبکه با خروجی نرم افزار Resix-IP برای داده‌های واقعی سونداژ ۶۰۴.

پارامترهای مدل مورد نظر جهت تخمین	ρ_1	ρ_2	ρ_3	ρ_4	h_1	h_2	h_3	عمق سطح آب
مدل حاصل از شبکه عصبی مصنوعی	187.29	58.45	28.53	53.52	2.25	3.03	82.71	87.99
مدل حاصل از نرم افزار Resix-IP	182.51	54.89	26.98	56.99	2.617	7.253	81.99	91.86

همانطور که از جداول و نمودارهای آورده شده در مورد سونداژهای فوق برآورد می‌شود، نتایج بدست آمده از شبکه‌های عصبی با نتایج نرم افزار Resix-IP هم از نظر نوع مدل چهار لایه‌ای و هم از نظر مقادیر پارامترهای مورد تخمین بسیار خوب عمل نموده و فقط در تخمین برخی پارامترها مثل ضخامت لایه دوم و سوم که شبکه نسبت به آنها آموزش کاملاً مناسبی ندیده است، دارای مقداری خطا است که میزان این خطا نیز با توجه به نوع شبکه متفاوت است. البته ذکر این نکته ضروری است که عدم انطباق کامل نمودارهای حاصل از پاسخ شبکه و نرم افزار Resix-IP در اشکال ارائه شده که در برخی موارد مثل سونداژ 303 که از

نظر ظاهری و با یک نگاه سطحی اختلاف بالایی را نشان می‌دهد، به دلیل خاصیت لگاریتمی محورهای مختصات بوده که با بررسی دقیقتر آن و مشاهده مقادیر مربوطه در جداول ارائه شده متوجه خواهیم شد که اختلافات موجود بین نتایج، چندان زیاد نبوده و تقریباً در یک محدوده نزدیک به هم قرار دارند و به عبارت دیگر ماهیت اصلی مدل تغییری نمی‌یابد.

۴-۵- جمع‌بندی

در پایان این فصل با نگاهی کلی به مطالب می‌توان گفت شبکه طبقه‌بندی کننده چه در مورد داده‌های مصنوعی و چه در مورد داده‌های واقعی، توانسته با دقت بسیار بالایی نوع منحنی مربوط به هر سونداژ را تعیین کند. در حالت عدم حضور نویز، شبکه‌های تخمینگر نیز به غیر از تخمین دو پارامتر آخر مدل چهار لایه‌ای یعنی تعیین ضخامت لایه دوم و سوم، در بقیه موارد پارامترهای مدل را با دقت قابل قبولی تخمین می‌زنند که علت وجود خطا در این نوع شبکه‌ها می‌تواند تعدد پارامترهای خروجی شبکه در هنگام آموزش، کم بودن تعداد داده‌های آموزشی و یا عدم بهینه بودن کامل ساختارهای اصلی شبکه باشد. در حالتی هم که به داده‌های ورودی شبکه در هنگام آموزش ۵ و ۱۰ درصد نویز اضافه می‌کنیم، از آنجا که داده‌های هدف نسبت به حالت بدون نویز ثابت مانده و فقط داده‌های مقاومت ویژه صحرایی نویز دار می‌شوند و از آنجا که ساختار شبکه‌های طراحی شده، برای این حالات تغییری نمی‌کند، لذا شبکه در هنگام آموزش قادر به تشخیص الگو نبوده و افزایش خطای آموزش و در نهایت عدم کارایی شبکه‌های تخمینگر در حالت وجود نویز را به همراه خواهد داشت.

فصل پنجم

نتیجه گیری و پیشنهادات

یکی از معایب عمده روش‌های معکوس سازی عددی خصوصاً در ژئوالکتریک، عدم یکتایی مدل بدست آمده می‌باشد؛ از طرف دیگر با توجه به وجود اصل هم ارزی و اصل اختفاء در مورد داده‌های مقاومت ویژه، تفسیر نتایج خالی از اشتباه نخواهد بود. مجموعه این عوامل سبب شده تا از شبکه عصبی مصنوعی که از سرعت بالاتری نیز برخوردار است، برای مدل سازی معکوس داده‌های ژئوالکتریکی استفاده گردد. همانطور که قبلاً نیز به آن اشاره شد، هدف از انجام این تحقیق، مدل سازی معکوس و تفسیر داده‌های مقاومت ویژه الکتریکی با استفاده از شبکه‌های عصبی مصنوعی برای یک زمین چهار لایه است. برای انجام این تحقیق، ابتدا با استفاده از نرم افزار Resix-IP یکسری داده مصنوعی تولید گردید؛ سپس با استفاده از آنها دو نوع شبکه عصبی مختلف بدست آمد؛ شبکه اول برای طبقه بندی و انتخاب نوع داده‌های ورودی و شبکه دوم برای تخمین پارامترهای مربوط به لایه‌ها به کار گرفته شد.

از جمله اشکالات موجود در مورد شبکه‌های عصبی که بایستی در کنار ویژگی‌های مثبت آن در نظر گرفت، موارد ذیل را می‌توان برشمرد:

- ۱- افزایش زمان آموزش شبکه با افزایش تعداد داده‌های آموزشی.
- ۲- عدم وجود روشی برای تعیین ساختار بهینه شبکه‌های عصبی مصنوعی؛ که این امر باعث شده که تنها از طریق روش‌های سعی و خطا به این مهم بپردازیم.
- ۳- عدم عملکرد مناسب در هنگام برون یابی؛ شبکه‌های عصبی در هنگام درون یابی عملکرد بسیار خوبی دارند ولی در مقابل، قادر به تشخیص الگوهایی که خارج از گستره الگوهای آموزش داده شده اولیه باشند، نخواهند بود.

۵-۲- نتیجه گیری

با توجه به مجموعه مطالب بیان شده در فصول قبلی و نتایج حاصل از شبکه‌های عصبی طراحی شده، در مجموع می‌توان موارد زیر را عنوان کرد:

- ۱- هر چقدر تعداد الگوهای ورودی بیشتر باشد و از طرفی تعداد نرون‌های لایه میانی کمتر باشد، این امر سبب می‌شود تا شبکه دچار از برکردن یا آموزش مبالغه‌ای گردد. یکی از روش‌های جلوگیری از آموزش مبالغه‌ای و تشخیص زمان توقف آموزش، تقسیم داده‌های ورودی به سه مجموعه آموزش، ارزیابی و آزمایش است.

۲- نرمالایز سازی داده‌ها یا نگاشت داده‌های ورودی به بازه $[-1, 1]$ ، سبب می‌شود تا شبکه در هنگام آموزش، بهتر بتواند بین داده‌های ورودی تفاوت قائل شود و در نتیجه یادگیری بهتر و سریعتر انجام پذیرد. از آنجایی که غالباً شبکه‌های عصبی نمی‌توانند با برون‌یابی به جواب مسأله برسند؛ لازم است که الگوهای یادگیری طوری ارائه شوند که مرزهای محدوده مسأله را در تمام ابعاد شامل شوند. مهمترین هدف از این انتقال، تصحیح پخش متغیرهای ورودی و خروجی به نحوی است که خطای مدل‌سازی شبکه کاهش یابد.

۳- یک شبکه در صورتی قابلیت تعمیم خواهد داشت که تعداد پارامترهای قابل تنظیم شبکه حتماً کمتر از تعداد مثالهای مجموعه باشد. به عنوان یک قاعده کلی اگر L تعداد پارامترهای قابل تنظیم شبکه و e خطای قابل قبول شبکه در تخمین مقدار خروجی باشد، تعداد نمونه آموزشی (N) برابر است با $N \geq \frac{L}{e}$.

۴- داده‌های مصنوعی تولید شده که برای آموزش شبکه بکار می‌روند، بایستی در نهایت دقت و صحت و نزدیک به واقعیت تولید شوند، چرا که به عنوان رکن اساسی در شبکه‌های عصبی مصنوعی به شمار می‌روند و از اهمیت بالایی برخوردارند.

۵- برای تعیین ساختار بهینه شبکه‌های عصبی قانون خاصی وجود ندارد و معمولاً این کار از طریق سعی و خطا صورت می‌گیرد که همین امر بهینه کردن ساختار شبکه را با مشکل مواجه خواهد ساخت.

۶- استفاده از چندین شبکه مختلف برای تخمین هر یک از پارامترهای مدل به طور جداگانه، به جای تخمین همه پارامترها توسط یک شبکه (که در حالت چهار لایه نیاز به تخمین ۷ پارامتر مختلف شامل ضخامت‌ها و مقاومت ویژه مربوط به هر لایه است)، ممکن است نتایج بهتری را به همراه داشته باشد.

۷- شبکه پرسپترون چند لایه بکار برده شده در این تحقیق، از توانایی بالایی در دسته‌بندی مدل‌های ورودی برخوردار است.

۹- شبکه‌های تخمینگر طراحی شده برای هر یک از هشت حالت مختلف از مدل‌های چهار لایه‌ای که در اینجا مورد استفاده قرار گرفتند، توانستند با دقت بالایی پارامترهای مربوطه را تخمین بزنند و فقط در مورد دو پارامتر آخر مدل یعنی ضخامت لایه دوم و سوم به دلیل وجود خطای نسبتاً بالاتر در هنگام آموزش، عملکرد ضعیفی از خود نشان دادند. این مطلب با مقایسه خروجی شبکه‌های عصبی مصنوعی و نتایج حاصل از نرافزار Resix-IP و نیز نمودارهای ترسیم شده هم برای داده‌های مصنوعی آزمایشی و هم برای داده‌های واقعی به خوبی مشخص است. علت این امر می‌تواند وجود ۷ پارامتر خروجی از یک شبکه، کم بودن تعداد الگوهای آموزشی، عدم بهینه بودن ساختار شبکه و عدم پوشش مناسب تمامی حالات ممکن از طریق تولید داده‌های

مصنوعی باشد.

۱۰- از بین شبکه‌های مورد تخمین در این تحقیق، شبکه KH دارای کمترین خطای آموزش و شبکه KQ دارای بیشترین مقدار خطای آموزش است.

۱۱- مدل‌سازی معکوس داده‌های سونداژ مقاومت ویژه با استفاده از شبکه‌های عصبی مصنوعی علاوه بر اینکه از سرعت بالاتری بر خوردار است، نتایج حاصل از آن دارای دقت کافی در مقایسه با دیگر روش‌ها است.

۱۲- نتایج حاصل از تفسیر داده‌های واقعی مربوط به سونداژهای الکتریکی دو مطالعه موردی که در اینجا مورد استفاده قرار گرفت با نتایج حاصل از نرم افزار Resix-IP برازش مناسبی داشته و از دقت مناسبی برخوردار است و در بسیاری از موارد تخمین عمق لایه آبدار با توجه به چاههای موجود در منطقه به درستی و با اختلاف ناچیزی همراه بود.

۱۳- شبکه‌هایی که با استفاده از داده‌های نويز دار آموزش دیدند، به دلیل دارا بودن خطای بالا در هنگام آموزش و کم بودن مقادیر ضرایب همبستگی، نمی‌توانند برای مدل‌سازی مورد استفاده قرار گیرند. یکی از دلایل اصلی وجود چنین خطای بالایی می‌تواند استفاده از همان ساختار قبلی شبکه در حالت بدون نويز، برای آموزش داده‌های نويز دار باشد که باعث عدم تشخیص الگو توسط شبکه مورد نظر شده است. مطلب دیگر اینکه اضافه نمودن نويز فقط به داده‌های مقاومت ویژه (داده‌های ورودی) صورت گرفته و داده‌های هدف در این حالت بدون تغییر مورد استفاده قرار گرفته‌اند.

۵-۳- پیشنهادات

با در نظر گرفتن مطالب قبلی و نیز با توجه به وجود نقصان‌هایی که در این تحقیق دیده می‌شود، موارد تکمیلی زیر پیشنهاد می‌گردد:

۱- استفاده از داده‌های واقعی برداشت شده برای آموزش شبکه، تخمین‌های حاصل از آنها را به واقعیت نزدیک‌تر خواهد کرد.

۲- در صورت عدم دسترسی به داده‌های آموزشی واقعی، از داده‌های مصنوعی که معرف شرایط واقعی زمین باشند و کلیه حالات ممکن را پوشش دهند، استفاده شود.

۳- کارایی روش مورد نظر برای آرایه‌های دیگر ژئوفیزیکی مثل آرایه وئر برای سونداژنی نیز مورد ارزیابی قرار گیرد.

- ۴- با افزایش تعداد داده‌های آموزشی که حالات بیشتری از شرایط زمین را نشان دهند و معرف تعداد بیشتری از الگوهای یادگیری باشند، می‌توان قدرت تخمین و تعمیم شبکه‌ها را افزایش داد.
- ۵- برای تعیین ساختار بهینه شبکه‌های عصبی بهتر است از روش‌های دیگری مثل الگوریتم ژنتیک، پارامترهای ساختاری بهینه را بدست آوریم تا هم دقت کار افزایش پیدا کند و هم سرعت کار به طور قابل ملاحظه‌ای بهبود یابد.
- ۶- استفاده از انواع دیگر شبکه‌های عصبی مصنوعی مثل شبکه‌های عصبی شعاعی، ممکن است که نتایج بهتری به همراه داشته باشد.
- ۷- برای تکمیل شدن این تحقیق، لازم است شبکه‌هایی تهیه شوند که قادر باشند کلیه حالات دو لایه، سه لایه، چهار لایه و ... را از هم تمیز داده و با توجه به حالت مورد نظر، پارامترهای مربوط به هر لایه را تخمین بزنند. البته این امر نیازمند تولید داده‌های مصنوعی برای سایر حالات و آموزش شبکه در هر مورد است.

پیوست ها

پیوست الف:

نحوه تولید داده‌های مصنوعی

برای تولید داده‌های مصنوعی، در اینجا از نرم افزار **Resix-IP** استفاده شده است. روش کار به این صورت است که در ابتدا بعد از انتخاب نوع آرایه الکترونی، به منوی **Edit** رفته و **Edit model** را انتخاب می‌کنیم. حال با توجه به تعداد لایه‌های مدل و با توجه به اینکه این مدل مربوط به کدام یک از حالات مورد نظر باشد، مقادیر مقاومت ویژه و ضخامت هر یک از لایه‌ها را با توجه به ترتیب و قاعده مشخصی که خودمان در نظر گرفته‌ایم، وارد می‌کنیم و فایل مربوط به آن را برای استفاده‌های بعدی ذخیره می‌نماییم. در مرحله بعد، با انجام مدل‌سازی مستقیم (**Forward model**) و با توجه به پارامترهای وارد شده در مرحله قبل، یکسری داده مصنوعی تولید می‌گردد. حال با انتقال این داده‌های تولید شده به یک فایل مجزا و ذخیره کردن آن می‌توان از آن استفاده نمود؛ و به همین روش برای تمام حالات مورد نظر داده مصنوعی تولید نمود.

پیوست ب:

نحوه اضافه نمودن نویز به داده‌های مصنوعی

برای این کار، ابتدا توسط تابع **Rands** در نرم افزار **MATLAB** به تعداد سطر بردار داده‌های ورودی که در اینجا برابر با ۲۲ بود، یک بردار داده‌های تصادفی ایجاد کرده و سپس توسط تابع **Sign** علامت آن را استخراج می‌کنیم. این تابع اعداد تولید شده توسط تابع **Rands** را به ۱ و -۱ تبدیل می‌کند. در مرحله بعد مقدار درصد نویزی که می‌خواهیم به داده‌های ورودی اضافه کنیم (در اینجا ۵٪ و ۱۰٪) را در بردار علامتی که بدست آمده ضرب می‌کنیم و سپس این بردار را با بردار ورودی جمع می‌کنیم؛ و بدین ترتیب به بردار داده‌های ورودی نویز اضافه می‌کنیم.

پیوست ج:

الگوریتم یادگیری پس انتشار خطا (BP)

از آنجا که در این تحقیق از الگوریتم یادگیری پس انتشار خطا برای آموزش شبکه عصبی استفاده شده است، لذا در اینجا به بررسی این الگوریتم می‌پردازیم.

هر مدل ANNs با سه ویژگی ساختار شبکه (شامل تعداد لایه‌ها و گره‌ها و نحوه اتصالات گره‌ها)، خصوصیات واحدهای پردازش آن (شامل نوع توابع انتقال و قوانین فعال سازی گره) و نوع قانون یادگیری آن مشخص می‌شود. قوانین یادگیری یک مجموعه اولیه از وزن‌ها را تعیین می‌کنند و نحوه تصحیح وزن‌ها را متناسب با الگوهای ارائه شده، کنترل می‌نمایند. از بین قوانین یادگیری موجود، الگوریتم یادگیری پس انتشار خطا یکی از پرطرفدارترین الگوریتم‌های یادگیری جهت آموزش مدل‌های ANNs با ساختار چند لایه می‌باشد (Haug and Wanstedt 1998).

همان طور که گفته شد، شبکه عصبی پس انتشار خطا، از تعداد زیادی گره قرار گرفته در لایه‌های مختلف تشکیل شده است. سیگنال‌های خروجی هر لایه به لایه بعدی انتقال داده می‌شود که بسته به وزن آن می‌تواند اثر تقویت‌کننده یا تضعیف‌کننده داشته باشد. به جز گره‌های لایه ورودی، هر گره، جمع وزن‌دار

خروجی‌های گره‌های لایه قبلی است. برای محاسبه خروجی‌های گره‌های میانی و خروجی، از توابع انتقال استفاده می‌شود.

این شبکه، یک شبکه قدرتمند تعیین نگاشت است که می‌تواند برای یادگیری رابطه بین پارامترهای ورودی و خروجی، مورد استفاده قرار گیرد. زمانی که ورودی جدیدی به شبکه اعمال می‌شود، شبکه متناسب با روابطی که یاد گرفته است، خروجی تولید می‌کند. ویژگی مهم روش پس انتشار خطا، دقت و راندمان بالا و همچنین انعطاف‌پذیری آن در مواجهه با خطاهای موجود در داده‌های الگوی یادگیری است. این شبکه‌ها دارای دو فاز مختلف است: فاز اول، یادگیری و فاز دوم، تولید است. فاز یادگیری خود شامل انتشار پیشرو و انتشار پسرو است. در انتشار پیشرو، مجموعه‌ای از الگوهای یادگیری به سیستم ارائه می‌شوند و سیستم، خروجی را محاسبه می‌کند. در انتشار پسرو، سیستم مجموع مربع خطای هر الگوی یادگیری را محاسبه کرده و با خروجی هدف (خروجی مطلوب) مقایسه می‌کند.

اگر مجموع خطاهای کلیه الگوهای یادگیری به یک مقدار کوچک از پیش تعیین شده همگرا شود، فاز یادگیری خاتمه می‌یابد. در غیر این صورت، انتشار پسرو انجام شده و در آن خطای محاسبه شده به صورت پسرو در شبکه منتشر شده و وزن‌های ارتباطی را تصحیح می‌کند. این وزن‌های ارتباطی برای فاز تولید بعدی، در شبکه ذخیره می‌گردند. در فاز تولید، شبکه با ارائه ورودی‌های جدید، خروجی مناسب را تولید می‌نماید. در زیر روابط مهم الگوریتم یادگیری پس انتشار خطا آورده شده است.

▪ انتشار پیشرو

در این حالت، ورودی گره هر لایه و خروجی آن به صورت زیر محاسبه می‌شود.

$$\begin{aligned} net_{pj} &= \sum w_{ij} o_{pi} \\ o_{pj} &= f_j(net_{pj}) = 1 / (1 + e^{-(net_{pj} + \theta_k)}) \end{aligned} \quad (ج-۱)$$

که در آن net_{pj} ، ورودی گره لایه زام شبکه، o_{pj} ، خروجی گره لایه زام، w_{ij} ، وزن بین لایه مخفی ز و لایه ورودی ا، o_{pi} ، خروجی گره لایه ورودی ا، f_j ، تابع سیگموئیدی و θ_j جمله بایاس یا آستانه است. به طریق مشابه، ورودی net_{pk} و خروجی o_{pk} لایه kام شبکه محاسبه می‌شود.

(ج-۲)

$$net_{pk} = \sum w_{jk} o_{pj}$$

$$o_{pk} = f_k(net_{pk}) = 1 / (1 + e^{-(net_{pk} + \theta_k)})$$

▪ انتشار پسرو

معمولاً الگوی خروجی o_{pk} با الگوی خروجی هدف t_{pk} مساوی نیست. بنابراین خطای الگو E_p و خطای کلی سیستم E_t به صورت زیر محاسبه می‌شوند.

(ج-۳)

$$E_p = (1/2) \sum_{p=1}^p (t_{pk} - o_{pk})^2$$

$$E_t = (1/2) \sum_1^N \sum_{p=1}^p (t_{pk} - o_{pk})^2$$

جهت کاهش خطای کلی سیستم، وزن‌های ارتباطی با افزایش Δw_{kj} ، تغییر می‌یابند. برای هر الگوی ورودی، خروجی P به صورت زیر محاسبه می‌شود.

(ج-۴)

$$\Delta_p w_{kj} = -\eta (\partial E / \partial w_{kj}) = \eta (\delta_{pk} o_{pj})$$

در معادله (۳-۱۲)، η مقدار ثابت نرخ یادگیری و δ_{pk} سیگنال خطا است و داریم :

$$(ج-۵) \quad \delta_{pk} = (t_{pk} - o_{pk}) f'_k(net_{pk}) = (t_{pk} - o_{pk}) o_{pk} (1 - o_{pk})$$

در نهایت، تغییرات افزایشی Δw_{ji} با جمع کردن $\Delta_p w_{kj}$ در کل الگوهای یادگیری بدست می‌آید.




(ج-۶)

$$\Delta w_{ji} = \Delta_p w_{kj}$$

پیوست د:


در این پیوست نمودارهای مربوط به ضرایب همبستگی بین خروجی شبکه‌های عصبی تخمینگر با داده‌های هدف و به ازاء داده‌های فاقد نویز آورده شده است. این نمودارها برای ۷ پارامتر خروجی شبکه و برای ۳ دسته داده آموزش، ارزیابی و آزمایش و برای ۸ نوع شبکه تخمینگر ترسیم شده است.

شبکه مربوط به منحنی نوع AA




شکل د-۱- نمودارهای مربوط به ضرایب همبستگی بین خروجی شبکه AA با داده‌های هدف به ازای پارامتر ρ_1 .


Training Outputs vs. Targets, $R=0.94784$




Validation Outputs vs. Targets, $R=0.68662$



Test Outputs vs. Targets, $R=0.54198$




Test Output




شکل د-۲- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AA با داده های هدف به ازای پارامتر ρ_2 .


Training Outputs vs. Targets, $R=0.93939$




Validation Outputs vs. Targets, $R=0.47421$



Test Outputs vs. Targets, $R=0.59935$




Test Ou




شکل د-۳- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AA با داده های هدف به ازای پارامتر ρ_3 .


Training Outputs vs. Targets, $R=0.99428$



Validation Outputs vs. Targets, $R=0.98882$




Test Outputs vs. Targets, $R=0.96348$




شکل د-۴- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AA با داده های هدف به ازای پارامتر ρ_4 .


Training Outputs vs. Targets, $R=0.97918$



Validation Outputs vs. Targets, $R=0.84535$




Test Outputs vs. Targets, $R=0.85053$




شکل د-۵- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AA با داده های هدف به ازای پارامتر h_1 .


Training Outputs vs. Targets, $R=0.9458$



Validation Outputs vs. Targets, $R=0.7482$




Test Outputs vs. Targets, $R=0.62019$




شکل د-۶- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AA با داده های هدف به ازای پارامتر h_2 .


Training Outputs vs. Targets, $R=0.90935$



Validation Outputs vs. Targets, $R=0.43061$




Test Outputs vs. Targets, $R=0.52651$




شکل د-۷- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AA با داده های هدف به ازای پارامتر h_3 .




شبکه مربوط به منحنی نوع AK






شکل د-۸- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AK با داده های هدف به ازای پارامتر ρ_1 .






شکل د-۹- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AK با داده های هدف به ازای پارامتر ρ_2 .




شکل د-۱۰- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AK با داده های هدف به ازای پارامتر ρ_3 .




شکل د-۱۱- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AK با داده های هدف به ازای پارامتر ρ_4 .



شکل د-۱۲- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AK با داده های هدف به ازای پارامتر h_1 .




شکل د-۱۳- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AK با داده های هدف به ازای پارامتر h_2 .




شکل د-۱۴- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه AK با داده های هدف به ازای پارامتر h_3 .


شبکه مربوط به منحنی نوع KH




شکل د-۱۵- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KH با داده های هدف به ازای پارامتر ρ_1 .




شکل د-۱۶- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KH با داده های هدف به ازای پارامتر ρ_2 .




شکل د-۱۷- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KH با داده های هدف به ازای پارامتر ρ_3 .




شکل د-۱۸- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KH با داده های هدف به ازای پارامتر ρ_4 .



شکل د-۱۹- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KH با داده های هدف به ازای پارامتر h_1 .




شکل د-۲۰- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KH با داده های هدف به ازای پارامتر h_2 .




شکل د-۲۱- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KH با داده های هدف به ازای پارامتر h_3 .

شبکه مربوط به منحنی نوع HK




شکل د-۲۲- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HK با داده های هدف به ازای پارامتر ρ_1 .


Training Outputs vs. Targets, $R=0.91488$



Validation Outputs vs. Targets, $R=0.73717$




Test Outputs vs. Targets, $R=0.71588$




شکل د-۲۳- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HK با داده های هدف به ازای پارامتر ρ_2 .


Training Outputs vs. Targets, $R=0.93714$



Validation Outputs vs. Targets, $R=0.91015$




Test Outputs vs. Targets, $R=0.78316$




شکل د-۲۴- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HK با داده های هدف به ازای پارامتر ρ_3 .


Training Outputs vs. Targets, $R=0.99238$



Validation Outputs vs. Targets, $R=0.98174$




Test Outputs vs. Targets, $R=0.98737$




شکل د-۲۵- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HK با داده های هدف به ازای پارامتر ρ_4 .


Training Outputs vs. Targets, $R=0.89085$



Validation Outputs vs. Targets, $R=0.69519$




Test Outputs vs. Targets, $R=0.84392$




شکل د-۲۶- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HK با داده های هدف به ازای پارامتر h_1 .


Training Outputs vs. Targets, $R=0.76854$



Validation Outputs vs. Targets, $R=0.24236$




Test Outputs vs. Targets, $R=0.22084$




شکل د-۲۷- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HK با داده های هدف به ازای پارامتر h_2 .


Training Outputs vs. Targets, $R=0.81137$



Validation Outputs vs. Targets, $R=0.4235$




Test Outputs vs. Targets, $R=0.39579$




شکل د-۲۸- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HK با داده های هدف به ازای پارامتر h_3 .

شبکه مربوط به منحنی نوع HA


Training Outputs vs. Targets, $R=0.99511$



Validation Outputs vs. Targets, $R=0.97701$




Test Outputs vs. Targets, $R=0.99346$




شکل د-۲۹- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HA با داده های هدف به ازای پارامتر ρ_1 .


Training Outputs vs. Targets, $R=0.94746$




Validation Outputs vs. Targets, $R=0.89886$




Test Outputs vs. Targets, $R=0.90535$




شکل د-۳۰- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HA با داده های هدف به ازای پارامتر ρ_2 .



شکل د-۳۱- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HA با داده های هدف به ازای پارامتر ρ_3 .




شکل د-۳۲- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HA با داده های هدف به ازای پارامتر ρ_4 .




شکل د-۳۳- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HA با داده های هدف به ازای پارامتر h_1 .


Training Outputs vs. Targets, $R=0.82673$



Validation Outputs vs. Targets, $R=0.44404$




Test Outputs vs. Targets, $R=0.32004$




شکل د-۳۴- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HA با داده های هدف به ازای پارامتر h_2 .


Training Outputs vs. Targets, $R=0.74757$



Validation Outputs vs. Targets, $R=0.1565$




Test Outputs vs. Targets, $R=0.14288$




شکل د-۳۵- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه HA با داده های هدف به ازای پارامتر h_3 .


شبکه مربوط به منحنی نوع KQ




شکل د-۳۶- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KQ با داده های هدف به ازای پارامتر ρ_1 .




شکل د-۳۷- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KQ با داده های هدف به ازای پارامتر ρ_2 .




شکل د-۳۸- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KQ با داده های هدف به ازای پارامتر ρ_3 .




شکل د-۳۹- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KQ با داده های هدف به ازای پارامتر ρ_4 .



شکل د-۴۰- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KQ با داده های هدف به ازای پارامتر h_1 .




شکل د-۴۱- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KQ با داده های هدف به ازای پارامتر h_2 .






شکل د-۴۲- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه KQ با داده های هدف به ازای پارامتر h_3 .




شبکه مربوط به منحنی نوع QH






شکل د-۴۳- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QH با داده های هدف به ازای پارامتر ρ_1 .




شکل د-۴۴- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QH با داده های هدف به ازای پارامتر ρ_2 .




شکل د-۴۵- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QH با داده های هدف به ازای پارامتر ρ_3 .




شکل د-۴۶- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QH با داده های هدف به ازای پارامتر ρ_4 .



شکل د-۴۷- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QH با داده های هدف به ازای پارامتر h_1 .




شکل د-۴۸- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QH با داده های هدف به ازای پارامتر h_2 .




شکل د-۴۹- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QH با داده های هدف به ازای پارامتر h_3 .


شبکه مربوط به منحنی نوع QQ




شکل د-۵۰- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QQ با داده های هدف به ازای پارامتر ρ_1 .




شکل د-۵۱- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QQ با داده های هدف به ازای پارامتر ρ_2 .



شکل د-۵۲- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QQ با داده های هدف به ازای پارامتر ρ_3 .




شکل د-۵۳- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QQ با داده های هدف به ازای پارامتر ρ_4 .




شکل د-۵۴- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QQ با داده های هدف به ازای پارامتر h_1 .


Training Outputs vs. Targets, $R=0.91887$



Validation Outputs vs. Targets, $R=0.58862$




Test Outputs vs. Targets, $R=0.42592$




شکل د-۵۵- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QQ با داده های هدف به ازای پارامتر h_2 .


Training Outputs vs. Targets, $R=0.95453$



Validation Outputs vs. Targets, $R=0.59523$



Test Outputs vs. Targets, $R=0.44483$



شکل د-۵۶- نمودارهای مربوط به ضریب همبستگی بین خروجی شبکه QQ با داده های هدف به ازای پارامتر h_3 .


پیوست ه:

در این پیوست برخی از جداول و اشکال حاصل از آموزش شبکه های عصبی تخمینگر که در فصل چهارم آورده نشده است، آمده شده است. لازم به ذکر است که نتایج حاصل از آموزش شبکه های تخمینگر در حضور نویز بسیار ناامید کننده بوده و به علت وجود خطای بالا و ضرایب همبستگی پایین که در برخی موارد نیز منفی ظاهر شده است که دال بر عدم کارایی شبکه بوده و نمی توان در این حالات از شبکه های آموزش دیده شده در تخمین پارامترهای مدل های چهار لایه ای بهره برد.


۱- شبکه AA

برای این حالت در اینجا نتیجه ای جهت نمایش آورده نشده است.


۲- شبکه AK



شکل ه-۱- رفتار شبکه AK در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است.




شکل ه-۲- رفتار شبکه AK در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است




شکل ه-۳- رفتار شبکه AK در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

۳- شبکه KH



شکل ه-۴- رفتار شبکه KH در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است.

- استفاده از داده‌های حاوی ۵٪ نویز



شکل ه-۵- رفتار شبکه KH در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۱- مقدار خطای (MSE) شبکه KH به ازای هر یک از پارامترهای خروجی (در حضور ۵٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
-------	-------	-------	----------	----------	----------	----------	--------------------------------

0.0055	0	0.0597	0.0003	0.0103	0.0196	0	مقدار خطا به ازای داده‌های آموزشی
0.0361	0.1322	0.2758	0.0056	0.0496	0.0812	0.0041	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0386	1.2227	0.0005	0.017	0.0101	0.0429	0.0026	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۲- ضریب همبستگی بین خروجی شبکه KH با داده‌های هدف (در حضور ۵٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9059	0.9406	0.8930	0.9808	0.9892	0.9718	0.9965	ضریب همبستگی به ازای داده‌های آموزشی
0.1221	0.0986	0.1748	0.9617	0.4221	0.2634	0.9810	ضریب همبستگی به ازای داده‌های اعتبارسنجی
-0.008	-0.116	0.2963	0.9431	0.5904	0.4291	0.9848	ضریب همبستگی به ازای داده‌های آزمایشی

- استفاده از داده‌های حاوی ۱۰٪ نویز



شکل ه-۶- رفتار شبکه KH در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.


جدول ه-۳- مقدار خطای (MSE) شبکه KH به ازای هر یک از پارامترهای خروجی (در حضور ۱۰٪ نویز)

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0011	0.0057	0.0181	0.0061	0.0003	0.0003	0.0008	مقدار خطا به ازای داده‌های آموزشی
1.9728	0.0021	0.1752	0	0.005	0.0017	0.0015	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0654	0.0398	0.3111	0.0003	0.0806	0.2318	0.0006	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۴- ضریب همبستگی بین خروجی شبکه KH با داده‌های هدف (در حضور ۱۰٪ نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9876	0.9814	0.9914	0.9920	0.9920	0.9902	0.9951	ضریب همبستگی به ازای داده‌های آموزشی
-0.022	0.2616	0.3021	0.8596	0.3206	0.2267	0.9457	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.1596	0.0274	0.0523	0.8506	0.2283	0.4027	0.9739	ضریب همبستگی به ازای داده‌های آزمایشی

۴- شبکه KQ



شکل ه-۷- رفتار شبکه KQ در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است.

- استفاده از داده‌های حاوی ۵٪ نویز



شکل ه-۸- رفتار شبکه KQ در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۵- مقدار خطای (MSE) شبکه KQ به ازای هر یک از پارامترهای خروجی (در حضور ۵٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
-------	-------	-------	----------	----------	----------	----------	--------------------------------

0.0231	0.0006	0.0454	0.0005	0.0043	0.0095	0.0052	مقدار خطا به ازای داده‌های آموزشی
0.346	0.1573	0.0003	0.0028	0.0019	0.0016	0.0021	مقدار خطا به ازای داده‌های اعتبارسنجی
1.2166	0.0288	0.1524	0.0009	0.0169	0.0333	0.0081	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۶- ضریب همبستگی بین خروجی شبکه KQ با داده‌های هدف (در حضور ۵٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9392	0.9280	0.9193	0.9919	0.9542	0.9793	0.9950	ضریب همبستگی به ازای داده‌های آموزشی
-0.052	0.1081	0.4785	0.9823	0.6899	0.8195	0.9907	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.0398	-0.109	0.3895	0.9769	0.5522	0.6825	0.9910	ضریب همبستگی به ازای داده‌های آزمایشی

- استفاده از داده‌های حاوی ۱۰٪ نویز



شکل ه-۹- رفتار شبکه KQ در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.


جدول ه-۷- مقدار خطای (MSE) شبکه KQ به ازای هر یک از پارامترهای خروجی (در حضور ۱۰٪ نویز)

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
1.0702	0.2056	0.2972	0.0222	0.0062	0	0.0091	مقدار خطا به ازای داده‌های آموزشی
0.5773	0.5242	1.8765	0.0078	0.0006	0.0079	0	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0023	0.8069	0.1316	0.043	0.0012	0.0113	0.0225	مقدار خطا به ازای داده‌های آزمایشی

جدول ۵-۸- ضریب همبستگی بین خروجی شبکه **KQ** با داده‌های هدف (در حضور ۱۰٪ نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.8420	0.8302	0.9244	0.9470	0.9484	0.9639	0.9813	ضریب همبستگی به ازای داده‌های آموزشی
0.055	-0.176	0.2963	0.9587	0.7032	0.7604	0.9038	ضریب همبستگی به ازای داده‌های اعتبارسنجی
-0.028	0.3384	0.4443	0.9278	0.7256	0.7073	0.9673	ضریب همبستگی به ازای داده‌های آزمایشی

۵- شبکه QQ



شکل ه-۱۰- رفتار شبکه QQ در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است.

- استفاده از داده‌های حاوی ۵٪ نویز



شکل ه-۱۱- رفتار شبکه QQ در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۹- مقدار خطای (MSE) شبکه QQ به ازای هر یک از پارامترهای خروجی (در حضور ۵٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.16	0.0323	0.0357	0.0002	0.0051	0.0015	0.0006	مقدار خطا به ازای داده‌های آموزشی

0.0815	2.0497	0.0121	0.0059	0.0468	0.0147	0.0003	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0019	0.0411	1.2318	0.0019	0	0.1861	0.0006	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۱۰- ضریب همبستگی بین خروجی شبکه QQ با داده‌های هدف (در حضور ۵٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.8406	0.7544	0.8721	0.9936	0.9340	0.9419	0.9950	ضریب همبستگی به ازای داده‌های آموزشی
0.2010	-0.178	0.3130	0.9801	0.8257	0.6903	0.9882	ضریب همبستگی به ازای داده‌های اعتبارسنجی
-0.177	-0.057	0.3681	0.9864	0.7572	0.8180	0.9861	ضریب همبستگی به ازای داده‌های آزمایشی

- استفاده از داده‌های حاوی ۱۰٪ نویز



شکل ه-۱۲- رفتار شبکه QQ در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۱۱- مقدار خطای (MSE) شبکه QQ به ازای هر یک از پارامترهای خروجی (در حضور ۱۰٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
-------	-------	-------	----------	----------	----------	----------	--------------------------------

0.0012	0.0169	0.0003	0.0013	0.0195	0.0307	0.0002	مقدار خطا به ازای داده‌های آموزشی
0.0058	0.3136	0.4686	0.0017	0.0157	0.0022	0.0015	مقدار خطا به ازای داده‌های اعتبارسنجی
0.2303	0.1528	0.1071	0.0097	0.0353	0.0011	0.0042	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۱۲- ضریب همبستگی بین خروجی شبکه **QQ** با داده‌های هدف (در حضور ۱۰٪ نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9423	0.9535	0.9283	0.9887	0.9652	0.9789	0.9890	ضریب همبستگی به ازای داده‌های آموزشی
0.1302	0.2320	0.0863	0.9623	0.6628	0.9164	0.9662	ضریب همبستگی به ازای داده‌های اعتبارسنجی
-0.186	0.0695	0.4007	0.9522	0.6573	0.8617	0.9731	ضریب همبستگی به ازای داده‌های آزمایشی

۶- شبکه QH



شکل ه-۱۳- رفتار شبکه QH در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است.

- استفاده از داده‌های حاوی ۵٪ نویز



شکل ه-۱۴- رفتار شبکه QH در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۱۳- مقدار خطای (MSE) شبکه QH به ازای هر یک از پارامترهای خروجی (در حضور ۵٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0003	0.0002	0.0048	0.0021	0.0001	0.0022	0.0018	مقدار خطا به ازای داده‌های آموزشی

1.7073	2.2798	0.0155	0.079	0.0027	0.0075	0.0003	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0435	0.9417	0.188	0.0056	0.0003	0	0.0002	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۱۴- ضریب همبستگی بین خروجی شبکه QH با داده‌های هدف (در حضور ۵٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9995	0.9995	0.9977	0.9888	0.9897	0.9847	0.9959	ضریب همبستگی به ازای داده‌های آموزشی
0.2416	0.0116	0.4510	0.9319	0.8805	0.7904	0.9888	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.0378	0.2459	0.3995	0.9399	0.7626	0.6983	0.9767	ضریب همبستگی به ازای داده‌های آزمایشی

- استفاده از داده‌های حاوی ۱۰٪ نویز



شکل ه-۱۵- رفتار شبکه QH در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۱۵- مقدار خطای (MSE) شبکه QH به ازای هر یک از پارامترهای خروجی (در حضور ۱۰٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
-------	-------	-------	----------	----------	----------	----------	--------------------------------

0.119	0.017	0.0363	0.0041	0.0065	0.0102	0.0236	مقدار خطا به ازای داده‌های آموزشی
0.0033	0.3081	0.7522	0.0072	0.1751	0.0072	0.012	مقدار خطا به ازای داده‌های اعتبارسنجی
0.136	1.8159	0.4353	0.0056	0.1274	0.0002	0.0055	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۱۶- ضریب همبستگی بین خروجی شبکه QH با داده‌های هدف (در حضور ۱۰٪ نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9206	0.7565	0.8911	0.9549	0.9526	0.9344	0.9778	ضریب همبستگی به ازای داده‌های آموزشی
0.1151	-0.255	-0.112	0.8784	0.6706	0.8158	0.9744	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.2836	-0.044	0.3379	0.7725	0.7067	0.7911	0.9313	ضریب همبستگی به ازای داده‌های آزمایشی

۷- شبکه HK



شکل ه-۱۶- رفتار شبکه HK در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است.

- استفاده از داده‌های حاوی ۵٪ نویز



شکل ه-۱۷- رفتار شبکه HK در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۱۷- مقدار خطای (MSE) شبکه HK به ازای هر یک از پارامترهای خروجی (در حضور ۵٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.1701	0.0013	0.0122	0.0002	0.0309	0.0006	0.0044	مقدار خطا به ازای داده‌های آموزشی

0.0511	0.0625	0.0122	0.0007	0.0255	0.0184	0.0016	مقدار خطا به ازای داده‌های اعتبارسنجی
0.8957	0.023	1.0335	0.0054	0.2002	0	0.0038	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۱۸- ضریب همبستگی بین خروجی شبکه HK با داده‌های هدف (در حضور ۵٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9169	0.9164	0.8800	0.986	0.9465	0.9565	0.9917	ضریب همبستگی به ازای داده‌های آموزشی
-0.075	0.3010	0.3486	0.9863	0.9287	0.2103	0.9605	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.1153	0.064	-0.098	0.9701	0.805	0.6886	0.9759	ضریب همبستگی به ازای داده‌های آزمایشی

- استفاده از داده‌های حاوی ۱۰٪ نویز



شکل ه-۱۸- رفتار شبکه HK در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۱۹- مقدار خطای (MSE) شبکه HK به ازای هر یک از پارامترهای خروجی (در حضور ۱۰٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
-------	-------	-------	----------	----------	----------	----------	--------------------------------

0.0539	0.0026	0.0007	0.0005	0.0027	0.0142	0.0034	مقدار خطا به ازای داده‌های آموزشی
0.121	0.4904	0.4954	0.0045	0	0.0241	0.0006	مقدار خطا به ازای داده‌های اعتبارسنجی
0.2222	0.2952	1.7886	0.0018	0.0016	0.0379	0.0031	مقدار خطا به ازای داده‌های آزمایشی

جدول ۵-۲۰- ضریب همبستگی بین خروجی شبکه HK با داده‌های هدف (در حضور ۱۰٪ نویز).


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.9302	0.9595	0.9608	0.9827	0.9782	0.9840	0.9915	ضریب همبستگی به ازای داده‌های آموزشی
-0.066	0.2815	-0.312	0.9034	0.5436	0.5882	0.9464	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.1950	-0.055	0.2570	0.9437	0.7610	0.5106	0.9663	ضریب همبستگی به ازای داده‌های آزمایشی

۸- شبکه HA



شکل ه-۱۹- رفتار شبکه HA در هنگام آموزش (عدم حضور نویز)، مقدار کلی خطا در بالای نمودار آمده است.

- استفاده از داده‌های حاوی ۵٪ نویز



شکل ه-۲۰- رفتار شبکه HA در هنگام آموزش (حضور ۵٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۲۱- مقدار خطای (MSE) شبکه HA به ازای هر یک از پارامترهای خروجی (در حضور ۵٪ نویز)


h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.0246	0.1157	0.0327	0.0552	0.1044	0.021	0.0127	مقدار خطا به ازای داده‌های آموزشی

0.0623	1.3616	0.0004	0.1182	0.1775	0.2026	0.0149	مقدار خطا به ازای داده‌های اعتبارسنجی
0.3703	1.4887	0.0378	0.0118	0.0305	0.0532	0.0032	مقدار خطا به ازای داده‌های آزمایشی

جدول ه-۲۲- ضریب همبستگی بین خروجی شبکه HA با داده‌های هدف (در حضور ۵٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.8314	0.6422	0.9021	0.9509	0.8885	0.9103	0.9816	ضریب همبستگی به ازای داده‌های آموزشی
-0.06	-0.087	0.3720	0.7859	0.6429	0.6988	0.9689	ضریب همبستگی به ازای داده‌های اعتبارسنجی
-0.045	-0.299	0.4551	0.9100	0.7509	0.5684	0.9867	ضریب همبستگی به ازای داده‌های آزمایشی

- استفاده از داده‌های حاوی ۱۰٪ نویز



شکل ه-۲۱- رفتار شبکه HA در هنگام آموزش (حضور ۱۰٪ نویز)، مقدار کلی خطا در بالای نمودار آمده است.

جدول ه-۲۳- مقدار خطای (MSE) شبکه HA به ازای هر یک از پارامترهای خروجی (در حضور ۱۰٪ نویز)

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
-------	-------	-------	----------	----------	----------	----------	--------------------------------

0.1566	0.0988	0.0972	0.0471	0.1409	0.0106	0.0042	مقدار خطا به ازای داده‌های آموزشی
1.657	0.6607	0.0023	0.0723	0.0168	0.0097	0.0121	مقدار خطا به ازای داده‌های اعتبارسنجی
0.0125	0.1224	0.0335	0.0431	0.0138	0.0314	0.0182	مقدار خطا به ازای داده‌های آزمایشی

جدول ۵-۲۴- ضریب همبستگی بین خروجی شبکه HA با داده‌های هدف (در حضور ۱۰٪ نویز).

h_3	h_2	h_1	ρ_4	ρ_3	ρ_2	ρ_1	پارامترهای مربوط به خروجی شبکه
0.7595	0.7314	0.7998	0.8485	0.7998	0.8856	0.9718	ضریب همبستگی به ازای داده‌های آموزشی
0.2945	-0.022	0.7170	0.8178	0.4998	0.8039	0.9499	ضریب همبستگی به ازای داده‌های اعتبارسنجی
0.0691	0.1824	0.4654	0.7397	0.6874	0.3032	0.9327	ضریب همبستگی به ازای داده‌های آزمایشی

منابع و مراجع

فهرست منابع و مراجع فارسی

- طهماسبی، ش. ۱۳۸۳، مدلسازی معکوس دو بعدی داده‌های مگنتوتلوریک با استفاده از شبکه‌های عصبی مصنوعی، پایان نامه کارشناسی ارشد، دانشکده معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود.

- غضنفری، م. و ارکات، ج. ۱۳۸۳، شبکه‌های عصبی مصنوعی (اصول و کارکردها)، مرکز انتشارات دانشگاه علم و صنعت.

- فهیمی، مهرداد، ۱۳۷۹، هوش مصنوعی، مجموعه دانش و فن و کامپیوتر.

- قاسم العسگری، محمد کمال، ۱۳۸۴، اصول ژئوفیزیک اکتشافی، انتشارات دانشگاه مهندسی نفت اهواز.

- کریمی، آرش، ۱۳۸۳، مدلسازی داده‌های سونداژ ژئوالکتریک با استفاده از شبکه‌های عصبی مصنوعی، پایان نامه کارشناسی ارشد، دانشکده معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود.

- کلاگری، ع.ا، ۱۳۷۱، اصول اکتشافات ژئوفیزیکی، انتشارات تابش، ۱۹-۲۱۸ص.

- گرامی زادگان، ا. ۱۳۸۲، معکوس‌سازی دو بعدی داده‌های ژئوالکتریک با استفاده از شبکه‌های عصبی مصنوعی، پایان‌نامه کارشناسی ارشد، دانشکده معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود.

- دولتی، ف. و مرادزاده، ع. ۱۳۸۴، مطالعات هیدروژئولوژیکی آب مورد نیاز کارخانه سیمان رویال سمنان، طرح پژوهشی، دانشکده معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود.

- مرادزاده، ع. ۱۳۸۳، اکتشاف آبهای زیرزمینی در استان سمنان (مطالعه دشتهای اطراف شاهرود)، طرح پژوهشی، دانشکده معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود.
- مشین‌چی، م. و مرادی، م. ۱۳۸۴، اینورژن دو بعدی داده‌های مقاومت ویژه با استفاده از شبکه‌های عصبی مصنوعی، دوازدهمین کنفرانس ژئوفیزیک ایران.
- منہاج، محمد باقر، ۱۳۷۴، مبانی شبکه‌های عصبی مصنوعی، مرکز نشر دانشگاه صنعتی امیرکبیر.

فهرست منابع و مراجع انگلیسی

- Apparao, A., 1997, **Developments in geoelectrical methods**, first edition, A.A.Balkema/Rotterdam/Brookfield, 156-182.
- Baan, M. and Jutten, C., 2000, **Neural networks in geophysics applications**, *Geophysics*, **65**, 1032-1047.
- Calderon-Macias, C., Sen, M.K. and Stoffa, P.L., 2000, **Artificial neural networks for parameter estimation in geophysics**, *Geophysical Prospecting*, **48**, 21-47.
- Huang, Y. and Wanstedt, S., 1998, **The introduction of Neural Network system and its applications in rock engineering**, *Engineering Geology*, **49**, 253-260.
- &.- Hubick, K. T., 1992, **Artificial neural networks in Australia**, Department of Industry, Tech Commonwealth of Australia, Canberra. Commerce,
- Inman, J.R. and Ryu, J., Ward, S. H., 1973, **Resistivity Inversion:** *Geophysics*, **38**, 1088-1108.

- Inman, J. R., 1975, **Resistivity Inversion with ridge regression:**
Geophysics, **40**, 798-817.

- Interpex Limited Golden Co., 1993, **Resix-IP, User Manual - Resistivity data interpretation software.**

- Keller, G.V and Frischknecht, F.C., 1970, **Electrical methods in geophysical prospecting**, second edition, Pergamon press, oxford, New York, Toronto, Sidney. Braunschweig.

- Lee, C. & Sterling, R., 1992, **Identifying probable failure modes for underground openings using a neural network**, Int. J. Rock Mechanics & Mining Science & Geomechanics Abstracts, **29**, 49-67.

- Meju, M.A., 1986, **Geophysical data analysis: Understanding inverse problem theory and practice**, SEG.

- Milson, J., 2002, **Field geophysics**, 3 Edition, Cambridge university press.

- Mooney, H.M., 1980, **Handbook of engineering geophysics**, Volume 2, First edition, Bison instruments, inc. and Minneapolis, Minnesota, 1-31.

- Murat, M.E. and Rudman, A.J., 1992, **Automated first arrival picking: A neural network approach:**
Geophysics Prospecting, **40**, 587-604.

- Patra, H.P. and Nath, S.K., 1999, **Schulomburger geoelectric sounding in ground water (principle, interpretation, application)**, Reserved, 35-65.

- Pearson, W., Wiener, J. and Moll, R., 1990, **Aeromagnetic structural interpretation using neural network: a case study from the northern Denver-Julesburg Basin.**

- Poulton, M. and El-fouly, A., 1991, **Preprocessing GPR signatures for cascading neural network classification**, SEG meeting.

- Principe, J.C., Euliano, N.R. and Lefebvre, W.C., 1999, **Neural and Adaptive systems: Fundamentals through Simulation**, Willy, New York.

- Telford W.M., Geldart L.P. and Sheriff R.E., 1990, **Applied geophysics**, second edition, Cambridge university press.
- The Mathworks Inc., 2007. **User Manual for the Language of technical computing**, The Mathworks Inc.