






دانشکده مهندسی معدن، نفت و ژئوفیزیک

رشته مهندسی معدن، گرایش اکتشاف

پایان نامه مقطع کارشناسی ارشد

کاربرد روش یادگیری عمیق در ژئوشیمی معادن برای نواحی سونگون و آستمال

نگارنده:

محمدرضا قاسمی ساسان سرا

استاد راهنما:

دکتر منصور ضیائی

تیر ۱۴۰۰

تقدیم بہ

خدای را بسی شاکرم کہ از روی کرم، پدر و مادری فداکار نصیم ساخته تا در سایہ درخت پر بار وجودشان بیایم و از

ریشہ آن ہا شاخ و برگ گیرم و زیر سایہ وجودشان در راہ کسب علم و دانش تلاش نمایم.

والدینی کہ بودنشان تاج افتخاری است بر سرم و نامشان دلیلی است بر بودنم چرا کہ این دو وجود پس از پروردگار

مایہ ہستی من بودہ اند؛ دستم را گرفتند و راہ رفتن را در این وادی زندگی پر از فراز و نشیب بہ من آموختند.

با تمام عشق این پژوهش را بہ پدر و ماد عزیزم تقدیم می کنم.

سپاسگزاری

بر خود واجب می‌دانم از استاد فرهیخته و فرزانه جناب آقای دکتر منصور ضیائی که به عنوان استاد راهنما و پدری مهربان در مراحل مختلف این پایان نامه، همواره با سه صدر و گشاده رویی بنده را راهنمایی و بار نمودن ایشان مرا تا پایان مسیر همراهی کردند تشکر و قدردانی نمایم.

همچنین از آقای دکتر رضا کاکائی و آقای دکتر احمد واعظیان که زحمات داوران را در این پایان نامه اینجانب را قبول فرمودند، قدردانی می‌نمایم.

تعهد نامه

اینجانب **محمدرضا قاسمی ساسانرا** دانشجوی دوره کارشناسی ارشد رشته مهندسی معدن-گرایش اکتشاف دانشکده مهندسی معدن، نفت و ژئوفیزیک دانشگاه صنعتی شاهرود نویسنده پایان نامه کاربرد روش یادگیری عمیق در ژئوشیمی معادن برای نواحی سونگون و آستمال تحت راهنمایی دکتر منصور ضیائی متعهد می‌شوم:

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

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده

با توجه به کاهش منابع سطحی، نیاز روز افزون به اکتشاف کانسارهای عمیق بیش از پیش احساس شده است. در کشور ایران با وجود کمربندهای کانی‌سازی فلزی به خصوص کمربند ارومیه-دختر، بسیاری از اکتشافات صورت گرفته به دلیل مشکلات تشخیص و اکتشاف کانی‌سازی پنهان اقتصادی، کم‌عمق هستند. زونالیت‌ه ژئوشیمیایی به عنوان رویکردی از ژئوشیمی معادن، از روش‌های قابل اطمینان در اکتشاف ذخایر پنهان اقتصادی است ولی کاستی‌های این روش از یک سو و رشد شاخه علم داده‌های زمین از سوی دیگر، محققین را به استفاده و بررسی کاربرد روش‌های نوین در روش‌های سنتی، به منظور بهبود عملکرد و کاهش کاستی‌های روش‌های سنتی سوق داده است. در این پژوهش الگویی برای ترکیب و ایجاد ارتباط بین یادگیری عمیق به عنوان یکی از موضوعات جذاب در علم داده‌های زمین با روش سنتی زونالیت‌ه ژئوشیمیایی به منظور رفع کاستی‌ها و توسعه زونالیت‌ه ژئوشیمیایی برای تشخیص بهتر مناطق کانی‌سازی پنهان اقتصادی ارائه شده است. الگوی ارائه شده شامل ۷ مرحله تمام متصل است. هر کدام از مراحل نقش اساسی در استخراج ویژگی‌های غیرخطی و پیچیده ژئوشیمیایی و روابط پنهان بین داده‌های ژئوشیمیایی دارد که به وسیله الگوریتم‌های یادگیری عمیق تحت یادگیری نظارت نشده و نظارت شده، انجام شده است. به منظور بررسی عملکرد الگوی ارائه شده، دو منطقه چالش برانگیز سونگون و آستامال واقع در کمربند اهر-ارسباران انتخاب شده است. سونگون به عنوان یک کانسار مس-مولیبدن در کلاس جهانی شناخته شده است ولی آستامال بر خلاف وجود دگرسانی‌های قوی و اندیس‌های معدنی مس، یک منطقه فقیر از کانی‌سازی پنهان اقتصادی است. با توجه به نتایج بدست آمده از الگوی ارائه شده، منطقه سونگون شامل دو زون کانی‌سازی پنهان اقتصادی در قسمت جنوب شرقی و شمال غربی است. همچنین کانی‌سازی پنهان در منطقه آستامال در دو زون در غرب و جنوب شرقی معرفی شد ولی کانی‌سازی پراکنده و غیراقتصادی بوده‌اند. در مجموع الگوی ارائه شده برای تفکیک داده‌های ژئوشیمیایی در سطوح مختلف آنومالی بدون نیاز به محاسبه زمینه و حدآستانه آنومالی، تشخیص مناطق کانی‌سازی پنهان، تعیین نوع کانی‌سازی اقتصادی یا غیراقتصادی و تعیین محل حفاری کارآمد است.

کلمات کلیدی: یادگیری عمیق، ژئوشیمی معادن، زونالیت‌ه ژئوشیمیایی، کانی‌سازی پنهان اقتصادی.

فهرست مطالب

فصل اول: کلیات	۱
۱-۱- مقدمه	۲
۲-۱- بیان مسئله و ضرورت انجام پژوهش	۳
۳-۱- اهداف پژوهش	۴
۴-۱- نوآوری پژوهش	۵
۵-۱- ساختار پژوهش	۵
فصل دوم: روش‌شناسی و پیشینه مطالعات	۷
۱-۲- مقدمه	۸
۲-۲- کانسارهای مس پورفیری	۸
۱-۲-۲- زون‌های دگرسانی مس پورفیری	۹
۳-۲- مطالعات دورسنجی	۱۰
۱-۳-۲- معرفی سنجنده استر	۱۰
۲-۳-۲- پیش‌پردازش تصاویر استر	۱۰
۳-۳-۲- استخراج خطواره	۱۱
۴-۳-۲- بارزسازی دگرسانی‌ها به وسیله الگوریتم عملگرهای منطقی	۱۲
۴-۲- ژئوشیمی معادن	۱۳
۱-۴-۲- اکتشاف ذخایر پنهان	۱۳
۲-۴-۲- هاله‌های ژئوشیمیایی	۱۴
۳-۴-۲- تئوری زونالیته ژئوشیمیایی	۱۵
۱-۳-۴-۲- روش زونالیته ژئوشیمیایی	۱۶
۲-۳-۴-۲- پیش‌پردازش داده‌های ژئوشیمیایی	۱۷
۳-۳-۴-۲- محاسبه زمینه و آنومالی	۱۸
۴-۳-۴-۲- محاسبه سطح از فرسایش	۱۸

۲۱	۵-۲- علم داده و علوم زمین
۲۲	۲-۵-۱- خوشه‌بندی
۲۲	۲-۵-۲- مبانی شبکه عصبی مصنوعی
۲۳	۲-۵-۱- الگوریتم پسانتشار خطا
۲۳	۲-۵-۲- شبکه‌های پیشخور
۲۴	۲-۵-۳- کم‌برازش و بیش‌برازش
۲۵	۲-۵-۴- تابع فعال‌ساز
۲۷	۲-۵-۵- تابع هزینه
۲۸	۲-۵-۶- الگوریتم بهینه‌ساز
۳۰	۲-۵-۷- ارزیابی صحت
۳۰	۲-۵-۸- آماده‌سازی داده‌ها
۳۱	۲-۵-۳- یادگیری ماشین
۳۲	۲-۵-۴- یادگیری عمیق
۳۳	۲-۵-۱- الگوریتم خودرمنگار
۳۷	۲-۵-۲- الگوریتم شبکه عصبی همگشتی
۴۱	۲-۶- مروری بر مطالعات پیشین
۴۱	۲-۶-۱- مطالعات انجام شده در استخراج خودکار خطواره‌ها
۴۳	۲-۶-۲- مطالعات انجام شده در بارزسازی دگرسانی‌ها با الگوریتم عملگرهای منطقی
۴۴	۲-۶-۳- مطالعات انجام شده در تشخیص آنومالی ژئوشیمیایی با روش زونالیته
۴۷	۲-۶-۴- مطالعات انجام شده در کاربرد یادگیری عمیق در اکتشاف ژئوشیمیایی
۵۱	فصل سوم: بررسی زمین‌شناسی و دورسنجی مناطق مورد مطالعه
۵۲	۳-۱- مقدمه
۵۲	۳-۲- زمین‌شناسی و دورسنجی در مناطق مورد مطالعه
۵۲	۳-۲-۱- منطقه آستامال
۵۴	۳-۲-۱-۱- استخراج خطواره‌ها در منطقه آستامال

۵۶	۳-۲-۱-۲- بارزسازی کانی سازی آهن و دگرسانی ها در منطقه آستمال
۵۹	۳-۲-۲- منطقه سونگون
۶۱	۳-۲-۲-۱- استخراج خطواره ها در منطقه سونگون
۶۳	۳-۲-۲-۲- بارزسازی کانی سازی آهن و دگرسانی ها در منطقه سونگون
۶۵	۳-۳- نمونه برداری در مناطق مورد مطالعه
۶۵	۳-۳-۱- نمونه برداری در منطقه آستمال
۶۶	۳-۳-۲- نمونه برداری در منطقه سونگون
۶۶	۳-۴- مطالعات انجام شده در تشخیص کانی سازی پنهان در مناطق سونگون و آستمال
۶۹	۳-۵- جمع بندی
۷۱	فصل چهارم: کاربرد یادگیری عمیق در ژئوشیمی معادن
۷۲	۴-۱- مقدمه
۷۵	۴-۲- فرآیند اجرای الگوی ترکیب یادگیری عمیق با زونالیت ژئوشیمیایی
۷۵	۴-۲-۱- اعمال روش کا- میانگین بر روی شاخص زونالیت
۷۶	۴-۲-۲- جداسازی زمینه و آنومالی در کلاس های مختلف به وسیله خودرمنگار پشته ای
۷۷	۴-۲-۳- تشخیص نقاط کانی سازی پنهان به وسیله خودرمنگار پشته ای و تنظیم دقیق
۷۸	۴-۲-۴- تشخیص مناطق کانی سازی پنهان به وسیله خودرمنگار پشته ای و تنظیم دقیق
۷۹	۴-۲-۵- تشخیص مناطق کانی سازی پنهان به وسیله شبکه عصبی همگشتی
۸۰	۴-۲-۶- محاسبه زمینه، سطح از فرسایش و تعیین نوع کانی سازی
۸۱	۴-۲-۷- اعتبارسنجی نتایج
۸۲	۴-۳- تشخیص کانی سازی پنهان اقتصادی در منطقه آستمال
۸۲	۴-۳-۱- اعمال روش کا- میانگین بر روی شاخص زونالیت
۸۲	۴-۳-۲- جداسازی زمینه و آنومالی در کلاس های مختلف به وسیله خودرمنگار پشته ای
۸۵	۴-۳-۳- تشخیص نقاط کانی سازی پنهان به وسیله خودرمنگار پشته ای و تنظیم دقیق
۸۷	۴-۳-۴- تشخیص مناطق کانی سازی پنهان به وسیله خودرمنگار پشته ای و تنظیم دقیق
۹۰	۴-۳-۵- تشخیص مناطق کانی سازی پنهان به وسیله شبکه عصبی همگشتی

۹۱	۴-۳-۶- محاسبه زمینه، سطح از فرسایش و تعیین نوع کانی‌سازی
۹۲	۴-۴- تشخیص کانی‌سازی پنهان اقتصادی در منطقه سونگون
۹۲	۴-۴-۱- اعمال روش کا-میانگین بر روی شاخص زونالیت
۹۳	۴-۴-۲- جداسازی زمینه و آنومالی در کلاس‌های مختلف به وسیله خودرمنگار پشته‌ای
۹۶	۴-۴-۳- تشخیص نقاط کانی‌سازی پنهان به وسیله خودرمنگار پشته‌ای و تنظیم دقیق
۹۸	۴-۴-۴- تشخیص مناطق کانی‌سازی پنهان به وسیله خودرمنگار پشته‌ای و تنظیم دقیق
۱۰۰	۴-۴-۵- تشخیص مناطق کانی‌سازی پنهان به وسیله شبکه عصبی همگشتی
۱۰۱	۴-۴-۶- محاسبه زمینه، سطح از فرسایش و تعیین نوع کانی‌سازی
۱۰۲	۴-۵- اعتبارسنجی نتایج
۱۰۲	۴-۵-۱- منطقه آستامال
۱۰۴	۴-۵-۲- منطقه سونگون
۱۰۷	۴-۶- جمع‌بندی و نتیجه‌گیری
۱۱۱	فصل پنجم: نتیجه‌گیری و پیشنهادات
۱۱۲	۵-۱- نتیجه‌گیری
۱۱۴	۵-۲- پیشنهادات
۱۱۵	واژه‌نامه
۱۲۰	منابع

فهرست اشکال

- شکل ۱-۲: مدل مصور کانسار مس پورفیری ۹
- شکل ۲-۲: موقعیت‌های کانسارهای پنهان ۱۴
- شکل ۳-۲: حد آستانه مقادیر خارج از ردیف (g) به عنوان تابعی از تعداد نمونه (n) و میزان دقت ۱۷
- شکل ۴-۲: مدل شاخص زونالیتة قائم معرفی شده توسط ضیائی (۱۹۹۶) ۲۰
- شکل ۵-۲: مدل شاخص زونالیتة قائم معرفی شده توسط ضیائی و همکاران (۲۰۰۹) ۲۱
- شکل ۶-۲: شمایی از مشکل کم‌برازش و بیش‌برازش در شبکه عصبی مصنوعی ۲۴
- شکل ۷-۲: شمایی از حذف تصادفی ۲۵
- شکل ۸-۲: شمایی از تابع یکسوساز خطی ۲۶
- شکل ۹-۲: شمایی از معماری خودرمنگار ۳۴
- شکل ۱۰-۲: شمایی از معماری خودرمنگار پشته‌ای ۳۵
- شکل ۱۱-۲: شمایی از معماری خودرمنگار پشته‌ای بعد از تنظیم دقیق ۳۷
- شکل ۱۲-۲: مثالی از شبکه عصبی همگشتی در کلاس‌بندی تصویر ۳۸
- شکل ۱۳-۲: شبکه عصبی همگشتی بر مبنای معماری LeNet ۴۰
- شکل ۱۴-۲: شبکه عصبی همگشتی بر مبنای معماری AlexNet ۴۱
- شکل ۱-۳: موقعیت جغرافیایی و راه‌های دسترسی به مناطق آستامال و سونگون ۵۳
- شکل ۲-۳: نقشه زمین شناسی منطقه آستامال ۵۴
- شکل ۳-۳: (الف) بردار ویژه روش تحلیل مولفه‌های اصلی بر روی باندهای محدوده مرئی-مادون قرمز نزدیک تصاویر استر؛ (ب) تصویر PC1 در منطقه آستامال ۵۵
- شکل ۴-۳: فیلتر جهت‌دار در ۴ جهت N-S (الف)، NE-SW (ب)، E-W (ج) و NW-SE (د) بر روی تصویر PC1 در منطقه آستامال ۵۵
- شکل ۵-۳: (الف) جهت خطواره‌ها؛ (ب) نقشه پراکندگی خطواره‌ها بر روی تصویر ترکیب رنگی استر در منطقه آستامال ۵۶
- شکل ۶-۳: (الف) آهن فریک؛ (ب) آهن فروس؛ (ج) اکسید آهن فریک در منطقه آستامال ۵۷
- شکل ۷-۳: دگرسانی‌های بارزسازی شده به وسیله الگوریتم عملگرهای منطقی بر روی تصاویر استر در منطقه آستامال ۵۹
- شکل ۸-۳: نقشه زمین‌شناسی منطقه سونگون ۶۱
- شکل ۹-۳: (الف) بردار ویژه روش تحلیل مولفه‌های اصلی بر روی باندهای محدوده مرئی-مادون قرمز نزدیک تصاویر استر؛ (ب) تصویر PC1 در منطقه سونگون ۶۲

شکل ۳-۱۰: فیلتر جهت‌دار در ۴ جهت N-S (الف)، NE-SW (ب)، E-W (ج) و NW-SE (د) بر روی تصویر PC1 در منطقه سونگون ۶۲

شکل ۳-۱۱: (الف) جهت خطواره‌ها؛ (ب) نقشه پراکندگی خطواره‌ها بر روی تصویر ترکیب رنگی استر در منطقه سونگون ۶۳

شکل ۳-۱۲: (الف) آهن فریک؛ (ب) آهن فروس؛ (ج) اکسید آهن فریک در منطقه سونگون ۶۳

شکل ۳-۱۳: دگرسانی‌های بارزسازی شده به وسیله الگوریتم عملگرهای منطقی بر روی تصاویر استر در منطقه سونگون ۶۴

شکل ۴-۱: نمودار توزیع فراوانی عناصر Cu, Mo, Pb و Zn در منطقه آستامال ۷۳

شکل ۴-۲: نمودار توزیع فراوانی عناصر Cu, Mo, Pb و Zn در منطقه سونگون ۷۴

شکل ۴-۳: نمودار ضریب شیب در منطقه آستامال ۸۲

شکل ۴-۴: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه آستامال ۸۳

شکل ۴-۵: نقشه آنومالی عناصر Cu (الف)؛ Mo (ب)؛ Pb (ج)؛ Zn (د)؛ عناصر ضربی فوق کانسار (ز)؛ عناصر ضربی تحت کانسار (ی)؛ بدست آمده از خودرمنگار پشته‌ای در منطقه آستامال ۸۴

شکل ۴-۶: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه آستامال ۸۵

شکل ۴-۷: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۲۰۰ تکرار آموزش در منطقه آستامال ۸۶

شکل ۴-۸: نقشه نقاط کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و تنظیم دقیق در منطقه آستامال ۸۷

شکل ۴-۹: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۱۰۰ تکرار آموزش در منطقه آستامال ۸۸

شکل ۴-۱۰: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۲۵ تکرار آموزش در منطقه آستامال ۸۹

شکل ۴-۱۱: نقشه مناطق کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و تنظیم دقیق در منطقه آستامال ۸۹

شکل ۴-۱۲: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه آستامال ۹۰

شکل ۴-۱۳: نقشه مناطق کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی در منطقه آستامال ۹۱

شکل ۴-۱۴: نمودار ضریب شیب در منطقه سونگون ۹۳

شکل ۴-۱۵: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه سونگون ۹۴

شکل ۴-۱۶: نقشه آنومالی عناصر Cu (الف)؛ Mo (ب)؛ Pb (ج)؛ Zn (د)؛ عناصر ضربی فوق کانسار (ز)؛ عناصر ضربی تحت کانسار (ی)؛ بدست آمده از خودرمنگار پشته‌ای در منطقه سونگون ۹۵

شکل ۴-۱۷: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه سونگون ۹۶

شکل ۴-۱۸: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۸۵ تکرار آموزش در منطقه سونگون ۹۷

شکل ۴-۱۹: نقشه نقاط کانی سازی پنهان بدست آمده از خودرمزنگار پشته‌ای و تنظیم دقیق در منطقه سونگون
 ۹۷.....

شکل ۴-۲۰: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۱۰۰ تکرار آموزش در منطقه سونگون ۹۸

شکل ۴-۲۱: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۳۰ تکرار آموزش در منطقه سونگون ۹۹

شکل ۴-۲۲: نقشه مناطق کانی سازی پنهان بدست آمده از خودرمزنگار پشته‌ای و تنظیم دقیق در منطقه
 سونگون ۹۹

شکل ۴-۲۳: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه سونگون ۱۰۰

شکل ۴-۲۴: نقشه مناطق کانی سازی پنهان بدست آمده از شبکه عصبی همگشتی در منطقه سونگون .. ۱۰۱

شکل ۴-۲۵: تغییرات غلظت مس و شاخص زونالیت در گمانه ۱ (الف) و گمانه ۲ (ب) در منطقه آستمال
 ۱۰۳.....

شکل ۴-۲۶: محل گمانه‌ها و زون‌های I و II در منطقه آستمال؛ (الف) نقشه کانی سازی پنهان بدست آمده از
 خودرمزنگار پشته‌ای؛ (ب) نقشه کانی سازی پنهان بدست آمده از شبکه عصبی همگشتی ۱۰۴

شکل ۴-۲۷: تغییرات غلظت مس و شاخص زونالیت در گمانه ۶۶ در منطقه سونگون ۱۰۵

شکل ۴-۲۸: تغییرات غلظت مس و شاخص زونالیت در گمانه ۶۹ در منطقه سونگون ۱۰۵

شکل ۴-۲۹: تغییرات غلظت مس و شاخص زونالیت در گمانه ۷۸ در منطقه سونگون ۱۰۶

شکل ۴-۳۰: محل گمانه‌ها و زون‌های I و II در منطقه سونگون؛ (الف) نقشه کانی سازی پنهان بدست آمده از
 خودرمزنگار پشته‌ای؛ (ب) نقشه کانی سازی پنهان بدست آمده از شبکه عصبی همگشتی ۱۰۷

فهرست جداول

جدول ۱-۳: الگوریتم عملگرهای منطقی استفاده شده بر روی تصاویر استر برای بارزسازی دگرسانی‌ها در مناطق آستامال و سونگون.....	۵۸
جدول ۱-۴: تصحیح داده‌های ژئوشیمیایی خارج از ردیف در مناطق مورد مطالعه.....	۷۲
جدول ۲-۴: اطلاعات آماری داده‌های ژئوشیمیایی در مناطق مورد مطالعه.....	۷۳
جدول ۳-۴: مقادیر زمینه، مقادیر بدست آمده از روش سالاووف (K_S) و گریگوریان (K_G)، نوع کانی‌سازی و دگرسانی‌ها در زون‌های I و II آستامال.....	۹۲
جدول ۴-۴: مقادیر زمینه، مقادیر بدست آمده از روش سالاووف (K_S) و گریگوریان (K_G)، نوع کانی‌سازی و دگرسانی در زون‌های I و II سونگون.....	۱۰۲

فصل اول

کلیات

۱-۱- مقدمه

نیاز روز افزون به فلزات از یک طرف و کاهش منابع سطحی و سهل الوصول از طرف دیگر موجب شده است تا ذخایر با عیارهای پایین تر مورد توجه قرار گیرند. شناسایی آنومالی‌های عمیق ارزشمند است ولی باید توجه شود که هر آنومالی بدست آمده از عمق، مرتبط با کانی‌سازی اقتصادی نیست. بدین منظور از روش‌های اکتشافی استفاده می‌شود که قادر هستند با اندازه‌گیری‌های مستقیم یا غیرمستقیم اطلاعات مفیدی را از منطقه مورد مطالعه ارائه نمایند (Zuo et al., 2012, 2019). بدون شک در راستای تحقق این هدف، مطالعات ژئوشیمیایی به خصوص ژئوشیمی معادن توصیه می‌شود. گریگوریان و سالووف بر اساس ژئوشیمی معادن، روش زونالیت‌ ژئوشیمیایی و بالتبع آن شاخص زونالیت‌ را برای شناسایی کانی‌سازی پنهان^۱ اقتصادی مطرح کردند (Solovov, 1990; Garigorian, 1992). این روش در کشورهای بلوک شرق توسعه یافت و در بررسی چندین منطقه به منظور تشخیص کانی‌سازی پنهان اقتصادی موفق بوده است اما در مقایسه با بلوک شرق، زونالیت‌ ژئوشیمیایی در بلوک غرب کم‌تر شناخته شده است (Ziaii et al., 2011).

علاوه بر پیچیدگی در تفسیر نتایج زونالیت‌ ژئوشیمیایی، این روش مبتنی بر بانک اطلاعات است. بدین ترتیب در استفاده از این روش چالش‌هایی در انتخاب بخش غیرآنومال برای محاسبه زمینه، حد آستانه آنومالی و تفکیک مناطق آنومالی وجود دارد. همچنین فرآیندهای پیچیده زمین‌شناسی، فرآیندهای پیچیده فرسایش، تاثیر ساختار و توزیع سنگ بستر و لایه‌های پوششی سنگ باعث شده است داده‌های ژئوشیمیایی مورد استفاده در روش زونالیت‌ ژئوشیمیایی به صورت غیرطبیعی یا غیرنرمال، دارای چولگی قوی و توزیعی چند متغیره باشند.

علم داده‌های زمین به عنوان رویکردی جدید برای استخراج اطلاعات و دانش مرتبط با داده‌های زمین‌شناسی توسعه یافته است (Zuo and Xiang, 2020). در این راستا امروزه یادگیری عمیق^۲ به عنوان موضوعی جذاب و رویکردی نوین از یادگیری ماشین در زمینه شناسایی آنومالی ژئوشیمیایی کاربرد وسیعی نشان داده است. توانایی یادگیری عمیق در استخراج ویژگی، کلاس‌بندی^۳، کاهش بعد داده‌ها، کشف ارتباط

¹ Blind Mineralization (BM)

² Deep learning

³ Classification

ساختاری بین داده‌ها و بدست آوردن روابط پیچیده در بررسی‌های ژئوشیمیایی به اثبات رسیده است (Xiong and Zuo, 2016; Li et al., 2020; Chen et., 2019a).

در این پژوهش الگویی برای ترکیب و ایجاد ارتباط بین یادگیری عمیق و روش زونالیته ژئوشیمیایی به منظور رفع مشکلات و توسعه روش زونالیته ژئوشیمیایی ارائه و عملکرد آن در مناطق سونگون و آستامال بررسی شده است.

۱-۲- بیان مسئله و ضرورت انجام پژوهش

کشور ایران به واسطه وجود کمربندهای بزرگ ذخایر مختلف فلزی مانند مس از اهمیت بالایی برخوردار است (Safonov, 1997)، ولی بسیاری از اکتشافات مرتبط با ذخایر سطحی رخنمون دار است که عمق آن‌ها از صد متر تجاوز نمی‌کند. در طی چندین سال ژئوشیمی معادن در تشخیص کانی‌سازی پنهان اقتصادی موفق بوده است اما این روش با محدودیت‌هایی رو به رو است که مهم‌ترین آن‌ها، نیاز به بانک اطلاعات قوی و پیچیده‌ای شامل منظرهای ژئوشیمیایی، زونالیته ژئوشیمیایی، تیپ کانی‌سازی و ژئوشیمی عناصر مرتبط با کانی‌سازی است (Ziaii et al., 2012). همچنین بسیاری از مسائل در بررسی ژئوشیمی معادن با عدم قطعیت بالا همراه هستند و روابط بین داده‌ها چند متغیره و پیچیده است که باعث شده است بسیاری از اطلاعات ناشناخته و مبهم باقی بماند. لازم به ذکر است مطالعات انجام شده برای ترکیب زونالیته ژئوشیمیایی با دیگر روش‌ها معمولاً به صورت خطی و پارامتری است و در جهت شناسایی آنومالی‌های ژئوشیمیایی مثبت مربوط به کانی‌سازی انجام شده است. این فرآیند منجر به عدم شناسایی اطلاعات پیچیده و پنهان بین داده‌ها خواهد شد.

با توجه به این محدودیت‌ها توسعه زونالیته ژئوشیمیایی با روش‌های بین رشته‌ای نوین مانند یادگیری عمیق، برای تشخیص کانی‌سازی پنهان اقتصادی به عنوان یکی از اهداف اصلی اکتشاف، ضرورت اصلی این پژوهش است. یادگیری عمیق ابزاری قدرتمند برای استخراج ویژگی‌های داده‌های ژئوشیمیایی است که با کشف الگوهای ژئوشیمیایی، آنومالی‌های ژئوشیمیایی را مشخص می‌کند. ترکیب این روش با زونالیته ژئوشیمیایی منجر به مرتفع نمودن مشکلات روش زونالیته ژئوشیمیایی، کاهش زمان، کاهش هزینه‌های اکتشافی، کاهش عدم قطعیت و تشخیص بهتر کانی‌سازی پنهان اقتصادی خواهد شد.

لازم به ذکر است به منظور بررسی کاربرد و ترکیب یادگیری عمیق با زونالیتة ژئوشیمیایی، منطقه سونگون و آستامال که از فرآیند زمین‌شناسی یکسان برخوردار هستند و با توجه به مطالعات پیشین به عنوان مناطقی چالش برانگیز در تشخیص کانی‌سازی پنهان معرفی شده‌اند، به عنوان مناطق مورد مطالعه انتخاب شده است. با توجه به مطالعات پیشین، به منظور تشخیص کانی‌سازی پنهان در این مناطق از روش‌های سنتی زونالیتة ژئوشیمیایی و ترکیب زونالیتة ژئوشیمیایی با دیگر روش‌ها استفاده شده است (Ziaii et al., 2009; Safari et al., 2018; Grigorian, 1994). دگرسانی‌های معرف کانسار مس پورفیری در منطقه آستامال وسعت و شدت بیشتری نسبت به منطقه سونگون داشته ولی این منطقه به عنوان کانی‌سازی پراکنده^۱ غیراقتصادی معرفی شده است. همچنین دگرسانی‌های معرف کانسار مس پورفیری در منطقه سونگون از وسعت و شدت کمتری برخوردار بوده ولی دو زون در این منطقه به عنوان کانی‌سازی پنهان اقتصادی معرفی شده است. همچنین وجود آنومالی کاذب و تداخل هاله‌های^۲ فوق کانسار^۳ و تحت کانسار^۴ در مناطق مورد مطالعه و به خصوص در منطقه آستامال، از چالش‌های مهم در تشخیص مناطق کانی‌سازی پنهان در مناطق مورد مطالعه است (Ziaii et al., 2009). مطالعات پیشین در مناطق مورد مطالعه عملکرد مناسبی در تشخیص زون‌های کانی‌سازی پنهان و تفکیک آن از کانی‌سازی پراکنده داشته و منجر به توسعه روش سنتی زونالیتة ژئوشیمیایی شده، ولی در تعیین زمینه، تفکیک آنومالی از زمینه و به خصوص تفکیک سطوح مختلف آنومالی محدودیت‌هایی داشته است. بدین ترتیب در این پژوهش به منظور تشخیص کانی‌سازی پنهان اقتصادی و تفکیک آن از کانی‌سازی پراکنده غیراقتصادی در مناطق سونگون و آستامال، از ترکیب یادگیری عمیق با زونالیتة ژئوشیمیایی استفاده شده است.

۱-۳- اهداف پژوهش

با توجه به عملکرد چندین ساله روش‌های سنتی و مدرن برای اکتشاف ذخایر پنهان اقتصادی (Beus and Garigorian, 1977; Ziaii et al., 2012, 2019)، در این پژوهش به بررسی روشی نوین در جهت توسعه

^۱ Zone Dispersed Mineralization (ZDM)

^۲ Halos

^۳ Supra-ore

^۴ Sub-ore

زونالیتة ژئوشیمیایی پرداخته شده است. هدف این پژوهش ارائه یک الگو برای ایجاد ارتباط و ترکیب روش نوین یادگیری عمیق با روش سنتی زونالیتة ژئوشیمیایی به منظور تشخیص مناطق کانی‌سازی پنهان اقتصادی است. لازم به ذکر است در این پژوهش، الگو معرفی شده برای تشخیص کانی‌سازی پنهان در مناطق سونگون و آستامال بررسی شده است.

۱-۴- نوآوری پژوهش

نوآوری‌های این پژوهش به سه دسته کلی تقسیم شده است. دسته اول در ارتباط با ترکیب یادگیری عمیق با زونالیتة ژئوشیمیایی به منظور ارائه یک الگو و توسعه زونالیتة ژئوشیمیایی است. دسته دوم در ارتباط با انتخاب الگوریتم‌های یادگیری عمیق به منظور انجام دسته اول است. در این راستا از الگوریتم‌های متفاوتی نسبت به مطالعات گذشته در بررسی داده‌های ژئوشیمیایی استفاده شده است و همچنین الگویی برای ترکیب و ایجاد ارتباط بین یادگیری عمیق با روش زونالیتة ژئوشیمیایی، ارائه و بررسی شده است. دسته سوم در ارتباط با بهبود نتایج بدست آمده در مناطق سونگون و آستامال به منظور تشخیص کانی‌سازی پنهان اقتصادی نسبت به مطالعات پیشین در این مناطق است.

۱-۵- ساختار پژوهش

این پژوهش از ۵ فصل تشکیل شده است. در فصل بعدی، ضمن معرفی ذخایر مس پورفیری، کلیاتی درباره روش‌های استفاده شده و پیشنهادی از مطالعات مرتبط با روش‌های استفاده شده، ارائه خواهد شد. در فصل سوم، مباحث زمین‌شناسی و دورسنجی در مناطق مورد مطالعه و همچنین مطالعات پیشین در مناطق مورد مطالعه به منظور تشخیص کانی‌سازی پنهان بررسی خواهد شد. در فصل چهارم به وسیله ارائه یک الگو، فرآیند ترکیب یادگیری عمیق با روش زونالیتة ژئوشیمیایی بررسی و سپس الگوی ارائه شده بر روی مناطق مورد مطالعه اعمال خواهد شد. در فصل پنجم نتایج کلی بدست آمده از این پژوهش و پیشنهاداتی برای بهبود آن ارائه خواهد شد.

فصل دوم

روش‌شناسی و پیشینه مطالعات

۲-۱- مقدمه

ارزش بالقوه ژئوشیمی معادن در اکتشاف منابع معدنی به خصوص در تعیین سطح از فرسایش^۱ و شناسایی و تفکیک کانی‌سازی پنهان اقتصادی از غیراقتصادی در طی چند سال گذشته اثبات شده است. گریگوریان و سالووف بر اساس ژئوشیمی معادن که شامل داده‌های زمین‌شناسی، ژئوشیمیایی، کانی‌شناسی، ترمودینامیکی و ریاضی است، شاخه‌ای به نام زونالیت‌ ژئوشیمیایی را ایجاد کردند (Solovov, 1990; Garigorian, 1992). مطالعات فنی و اقتصادی روش زونالیت‌ ژئوشیمیایی نشان می‌دهد که این روش نقش مهمی در اکتشاف ذخایر معدنی اتحاد جماهیر شوروی سابق و بلوک شرق داشته است (Ziaii et al., 2012). عملکرد مناسب روش‌های یادگیری ماشین برای تجزیه و تحلیل داده‌ها، کشف ارتباط ساختاری بین داده‌ها، بدست آوردن روابط پیچیده و جزئی بین الگوهای ژئوشیمیایی و کانی‌سازی به اثبات رسیده است (Zuo, 2017). یادگیری عمیق به عنوان شاخه‌ای از یادگیری ماشین، این امکان را فراهم می‌کند تا سهم بزرگی در داده‌های مرتبط با علوم زمین، به خصوص داده‌های ژئوشیمیایی داشته باشد (Zuo et al., 2019). در این فصل ابتدا به ارائه کلیاتی درباره کانسارهای مس پورفیری و مبانی روش‌های استفاده شده در این پژوهش پرداخته شده و در انتهای فصل نیز مروری بر مطالعات پیشین در ارتباط با روش‌های استفاده شده در این پژوهش، انجام شده است.

۲-۲- کانسارهای مس پورفیری

کانسارهای پورفیری از مهم‌ترین کانسارهای معدنی برای عناصر مس، مولیبدن، طلا، نقره و دیگر فلزات است. کانی‌سازی سیستم پورفیری در عمق ۱ تا ۶ کیلومتری از سطح زمین و به صورت رگه و رگچه‌های استوک‌ورک، برش‌های هیدروترمال و جایگزینی در سنگ دیواره تشکیل می‌شود. سنگ‌های مونزونیتی، دیوریتی و گرانودیوریتی کالک آلکان بستری مناسب برای اکتشاف کانسارهای مس پورفیری است (Carranza and Hale, 2002). این کانسارها در کمربند تکتونیکی زون فرورانش حاشیه قاره‌ها^۲ و جزایر قوسی^۳ کشف

¹ Level of erosion


² Continental Margin Seduction Zones

³ Island Arcs

شده‌اند. طبقه‌بندی کانسارهای پورفیری اغلب بر اساس اقتصادی بودن عناصر است و شامل دو مجموعه اصلی مس-مولیبدن و مس-طلا پورفیری هستند (Sillitoe, 2010).

۲-۱-۲- زون‌های دگرسانی مس پورفیری

لاول و گیلبرت (۱۹۷۰)، کانسار سان مانوئل-کلامازو را توصیف و نتایج بدست آمده را با ۲۷ کانسار مس پورفیری دیگر مقایسه کردند. در نتیجه این بررسی، مدل لاول-گیلبرت برای کانسارهای مس پورفیری ارائه شد که بر اساس این مدل، چهار زون دگرسانی^۱ برای کانسار مس پورفیری معرفی شده است. در شکل ۱-۲ زون‌های دگرسانی و کانی‌های تشکیل دهنده هر زون را در مدل لاول-گیلبرت نشان داده شده است. در یک کانسار مس پورفیری زون‌های دگرسانی از داخل به خارج عبارتند از: پتاسیک، فلیک، آرژلیک و پروپلیتیک (Lowell and Guilbert, 1970).



شکل ۱-۲: مدل مصور کانسار مس پورفیری (Mars, 2014)

¹ Alteration

۲-۳- مطالعات دورسنجی

مطالعات دورسنجی به دلیل داشتن داده‌هایی با وسعت دید مناسب و محدوده‌های مختلف طول موج الکترومغناطیس، یکی از بهترین روش‌ها برای تهیه نقشه‌های زمین‌شناسی، ساختاری، سنگ‌شناسی و دگرسانی در مراحل اولیه اکتشاف به ویژه در مرحله پی‌جویی و پتانسیل‌یابی ماده معدنی است. لازم به ذکر است وجود دگرسانی‌ها رابطه مستقیم با کانی‌سازی ندارد (Sabins, 1999).

۲-۳-۱- معرفی سنجنده استر

سنجنده استر^۱ یکی از پنج سنجنده‌ای است که توسط ماهواره ترا^۲ در دسامبر ۱۹۹۹ به فضا پرتاب شد. سنجنده استر بر اساس نیازهای زمین‌شناسی طراحی شده است و در این زمینه کارایی بسیار بالایی دارد. این سنجنده شامل سه باند در محدوده مرئی-مادون قرمز نزدیک^۳ با طول موج ۰/۵۲ تا ۰/۸۶ میکرومتر، شش باند در مادون قرمز کوتاه^۴ با طول موج ۱/۶ تا ۲/۴۳ میکرومتر و پنج باند در محدوده حرارتی^۵ با طول موج ۸/۱۲۵ تا ۱۱/۶۵ میکرومتر با قدرت تفکیک مکانی به ترتیب ۱۵ متر، ۳۰ متر و ۹۰ متر است (معصومی و رنجبر، ۱۳۹۰).

۲-۳-۲- پیش‌پردازش تصاویر استر

در این پژوهش از تصاویر استر دارای سطح تصحیح 1T استفاده شده است. داده‌های این سطح تصحیح، شامل کالیبراسیون تابشی سنجنده^۶ است و با سطح تصحیح 1B مطابقت دارد. تصحیح هندسی تصاویر و بازگردان به سمت شمال سیستم مختصات UTM^۷ در سطح تصحیح 1T انجام شده است. با توجه به ویژگی جغرافیایی ایران، بهترین و کارآمدترین روش برای حذف اثرات جوی و تصحیحات اتمسفری تصاویر استر، روش کالیبراسیون بازتاب نسبی متوسط داخلی^۸ است (خجسته‌فر و رنجبر، ۱۳۹۵).

¹ Advanced Spaceborne Thermal Emission Reflection Radiometer (ASTER)

² TERRA satellite

³ Visible-Near Infrared (VNIR)

⁴ Shortwave Infrared (SWIR)

⁵ Thermal Infrared (TIR)

⁶ Sensor Radiance

⁷ Universal Transverse Mercator coordinate system (UTM)

⁸ Internal Average Relative Reflectance

رابطه ۱-۲ چگونگی اعمال این تصحیح بر روی تصاویر سنجده استر را نشان می‌دهد که در این رابطه X_{ic} مقدار تصحیح شده در هر باند طیفی i ، D_i مقدار تابشی در هر باند طیفی i و D_m مقدار میانگین پیکسل‌ها در باند i است (Ayoobi and Tangestani, 2017).

$$X_{ic} = D_i / D_m \quad (1-2)$$

۲-۳-۳- استخراج خطواره

اولری و همکاران (۱۹۷۶)، اصطلاح خطواره^۱ را به عنوان یک ویژگی خطی ساده یا ترکیبی از سطح تعریف کردند که می‌تواند برخی از پدیده‌های زیر سطح را منعکس کند (O'Leary et al, 1976). خطواره‌ها معمولاً مناطقی که دارای ارتباط با کانسارهای معدنی هستند را بارز می‌کنند. همچنین ممکن است خطواره‌ها نشان دهنده مرز بین واحدهای سنگ‌شناسی، گسل‌ها، پوشش گیاهی و عارضه‌های خطی مانند جاده‌ها، پل‌ها و دره‌ها باشد (Adiri et al., 2017).

خطواره‌ها به وسیله روش‌های مختلف از تصاویر ماهواره‌ای استخراج می‌شوند. استخراج خودکار خطواره‌ها به وسیله نرم‌افزار PCI Geomatica به دلیل یکسان بودن عملیات برای کلیه تصاویر و سرعت و دقت بالای آن در مناطقی که چشم انسان قادر به تشخیص نیست، روشی کارآمد است. مراحل استخراج خودکار خطواره‌ها عبارت است از (Adiri et al., 2017):

(۱) اعمال روش تحلیل مولفه‌های اصلی^۲ بر روی باندهای محدوده مرئی-مادون قرمز نزدیک تصویر استر و انتخاب تصویر PC1 (تصویر PC1 بیشترین مقدار بردار ویژه، بیشترین روشنایی در بین باندها و اثر آلبدو که تا حد زیادی به ویژگی‌های توپوگرافی مربوط است را شامل می‌شود).

(۲) اعمال فیلترهای جهت‌دار^۳ با کرنل 3×3 در ۴ جهت با آزمون‌های ۰، ۴۵، ۹۰ و ۱۳۵ درجه به ترتیب برای بارزسازی عوارض در ۴ جهت اصلی N-S، NE-SW، E-W و NW-SE بر روی تصویر

PC1

¹ Lineament

² Principal Component Analysis (PCA)

³ Directional filters

۳) استخراج خودکار خطوطاره‌ها به وسیله مدل LINE در نرم افزار PCI Geomatica از تصاویر مرحله

قبل

۴) ایجاد نقشه خطوطاره‌ها

۲-۳-۴- بارزسازی دگرسانی‌ها به وسیله الگوریتم عملگرهای منطقی

مارس و روان (۲۰۰۶) با استفاده از خصوصیت طیفی کانی‌ها در محدوده‌های محدوده مرئی-مادون قرمز نزدیک و محدوده مادون قرمز کوتاه به وسیله نسبت‌های باندی^۱ بر روی تصاویر استر الگوریتم عملگرهای منطقی^۲ را در کمر بند آتشفشانی-رسوبی ایران برای بارزسازی زون‌های دگرسانی آرژیلیک و فیلیک بکار بردند (Mars and Rowan, 2006). مارس (۲۰۱۳) الگوریتم‌های دیگری را پیشنهاد نمود که از محدوده طیفی حرارتی نیز برای تفکیک بهتر دگرسانی‌ها استفاده می‌کند. بر این اساس انواع مختلف دگرسانی آرژیلیک، فیلیک، پروپیلیتیک (کربنات، کلریت-اپیدوت) و همچنین مناطق دگرسانی مرتبط با سنگ‌های غنی از کانی-های سیلیسی با ارائه یک الگوریتم عملگر منطقی مخصوص به خود به صورت یک مقدار مشخص درست (ارزش یک برای پیکسل مورد نظر) یا نادرست (ارزش صفر برای پیکسل مورد نظر) برای هر پیکسل از تصویر مشخص می‌شود (Mars, 2013).

این الگوریتم‌ها مبتنی بر حد آستانه برای بارزسازی دگرسانی‌ها است. برای انتخاب حد آستانه، معصومی و رنجبر (۱۳۹۶)، استفاده از رابطه ۲-۲ را پیشنهاد دادند. لازم به ذکر است در مواردی خاص با توجه به تجربه و شناخت از منطقه مورد مطالعه، این مقدار تغییر داده می‌شود. در این رابطه μ میانگین، σ انحراف معیار و t حد آستانه است (معصومی و رنجبر، ۱۳۹۶).

$$t = \mu \pm \sigma \quad (2-2)$$

¹ Band Ratios


² Logical operator algorithm

۲-۴- ژئوشیمی معادن

هدف از اکتشاف ژئوشیمیایی، توسعه یک برنامه کلی جهت تشخیص کانی‌سازی پنهان است که به لحاظ اقتصادی ارزش بالایی دارند. استفاده از روش‌های ژئوشیمیایی برای اکتشاف کانسارهای معدنی به سال ۱۹۳۰ برمی‌گردد که اولین بررسی آن توسط فرسمن انجام شد (Fersman, 1939). از آن زمان مطالعات بیشتری در مورد نظریه و کاربرد روش‌های اکتشاف ژئوشیمیایی انجام شده است و این روش تا حد زیادی اصلاح و بهبود یافته است. ژئوشیمی معادن شاخه‌ای از ژئوشیمی کاربردی است که به وسیله روش‌های ژئوشیمیایی به ارزیابی پتانسیل کانی‌سازی در افق‌های سطحی تا عمیق می‌پردازد که به افزایش شناخت از کانسارهای عمیق در معادن شناخته شده کمک می‌کند. به عبارت دیگر مدل‌های اکتشاف در مقیاس محلی و معدنی برای تشخیص آنومالی توسط ژئوشیمی معادن ایجاد و توسعه می‌یابند (Ziaii et al., 2009, 2012).

۲-۴-۱- اکتشاف ذخایر پنهان

ذخایر پنهان در موقعیت‌های مختلفی از سطح زمین قرار دارند و لازم است برای هر کدام از این موقعیت‌ها، از روش اکتشافی مناسب استفاده نمود. در شکل ۲-۲ در حالت A، کانسار در سطح رخنمون دارد که به وسیله روش‌های سنتی اکتشاف، قابل تشخیص است. در حالت B، دگرسانی‌ها عملکرد مناسبی دارند زیرا کانسار در عمق کمی از سطح زمین قرار دارد. همچنین ممکن است کانسار در عمقی از سطح زمین و به وسیله سنگ بستر، رسوبات آبراهه‌ای، پوشش گیاهی و رسوبات آبرفتی پوشیده شده باشد که به ترتیب بیانگر حالات C, D, E و F در شکل ۲-۲ است. در این حالت‌ها روش‌های ژئوشیمیایی عملکرد مناسبی برای شناسایی کانسار دارند، ولی در بعضی از مواقع ممکن است در سطح زمین هاله‌های ژئوشیمیایی مشاهده شوند ولی در عمق کانی‌سازی وجود نداشته باشد. در این حالت که در شکل G نام دارد، کانی‌سازی از نوع پراکنده است. به طور کلی کانی‌سازی پراکنده به دلیل تاثیر سیالات بر سنگ‌های درونگیر تشکیل می‌شوند که باعث بالا رفتن تمرکز عناصر نسبت به زمینه می‌گردد و ارزش اقتصادی بالایی ندارد (Grigorian, 1992).



شکل ۲-۲: موقعیت‌های کانسارهای پنهان (صفری، ۱۳۹۶)

کانی‌سازی پنهان و کانی‌سازی پراکنده بر اساس ساختار و ماهیت هاله‌های ژئوشیمیایی در بالای کانسار قابل شناسایی هستند. ولی ممکن است هاله‌های ژئوشیمیایی کانی‌سازی پراکنده به عنوان قسمت فوقانی کانی‌سازی پنهان تشخیص داده شود که منجر به اشتباه در شناسایی کانی‌سازی پنهان می‌شود (Beus and Grigorian, 1977). بنابراین از وظایف مهم یک ژئوشیمیست تشخیص و تفکیک این دو نوع کانی‌سازی از یکدیگر است (Ziaii et al., 2019).

۲-۴-۲- هاله‌های ژئوشیمیایی

نخستین بار سافرونوف، مفهوم هاله اولیه را به صورت منطقه‌ای سنگی در اطراف کانسار و غنی‌شدگی عناصر مرتبط با کانسار، معرفی کرد (Safronov, 1936). زون‌های هاله‌های ژئوشیمیایی اولیه دربرگیرنده کانسار هستند که در نتیجه تأثیر اثر متقابل بین سنگ بستر و سیالات معدنی، از چند عنصر شیمیایی تهی یا غنی شده‌اند. ابعاد هاله‌های ژئوشیمیایی اولیه وسیع‌تر از ابعاد کانسار است و گاهی وسعت آن‌ها نسبت به ماده معدنی به صد برابر می‌رسد. اهمیت کاربردی هاله‌های ژئوشیمیایی در این است که عناصر یا فلزات تشکیل دهنده هاله‌های اولیه در اطراف ذخایر معدنی نقش مسیریاب را برای منطقه معدنی بازی می‌کنند. در واقع این نوع هاله‌ها دارای عناصری هستند که برای توده‌های کانساری نقش عناصر شاخص را دارند و بدین جهت به عنوان راهنمای اکتشافی توده‌های کانساری به کار می‌روند (Beus and Grigorian, 1977).

یکی از جنبه‌های مهم هاله‌های ژئوشیمیایی تشخیص حد آستانه عناصر ردیاب است. عنصر ردیاب به عنصر نسبتاً متحرکی گفته می‌شود که ارتباط ژنتیکی نزدیکی با عنصر یا عناصر مورد اکتشاف داشته و به آسانی قابل تشخیص باشد. عناصر ردیاب دارای ویژگی‌های زیر می‌باشند (Peters, 1987):

۱) تحرک پذیری بالایی داشته و به آسانی در اطراف ماده معدنی توزیع می‌شوند. همچنین نسبت به سایر عناصر، هاله‌های وسیع و گسترده‌تری دارند. عناصر ردیاب باید در مقاطع عمقی مختلف بررسی شوند زیرا گسترش این عناصر در مکان‌ها و جهت‌های مختلف کانسار ممکن است به مقدار قابل توجهی متفاوت باشد.

۲) تمرکز عناصر ردیاب با توجه به آنومالی، حد آستانه و زمینه مشخص می‌شود. این عناصر باید به اندازه کافی فراوان باشند به طوریکه بتوان هاله را از مقدار زمینه تفکیک کرد.

۳) عناصر ردیاب باید به گونه‌ای انتخاب شوند که آنالیز آن‌ها نیازمند به تکنیک‌های خاص و پرهزینه نباشد و با روش‌های آسان، ارزان و حساس قابل اندازه‌گیری باشد.

۴) توزیع ساختمانی عناصر ردیاب باید مشابه با شکل توزیع هاله‌های ماده معدنی باشد.

۲-۴-۳- تئوری زونالیته ژئوشیمیایی

پیدایش زون‌بندی اولین بار توسط تئوری امونز مطرح شد. دما و فشار با دور شدن از توده نفوذی به تدریج کاهش می‌یابد که منجر به تشکیل کانی‌های مختلفی می‌شود. تئوری امونز پاراژنز این کانی‌ها را عامل ایجاد زون‌بندی معرفی کرده است (Emmons, 1933). زون‌بندی هاله‌های ژئوشیمیایی یک طبیعت فضایی و مفهوم جهتی است که می‌تواند با سه پارامتر بعد، جهت و غلظت عناصر تعریف شود (Hamedani et al., 2012). در اطراف یک کانسار، زون‌بندی هاله اولیه در ۳ جهت طولی، عرضی و محوری (قائم) وجود دارد. زون‌بندی قائم هاله‌های اولیه مرتبط با راستای جریان سیالات معدنی است و نسبت به دو زون دیگر از اهمیت بالاتری برخوردار است (Yongqing and Pengda., 1998; Li et al., 2006). این زون شاخصی برای تعیین موقعیت سطح از فرسایش آنومالی‌های ژئوشیمیایی نسبت به کانسار است. در ژئوشیمی معادن زون‌بندی قائم ابزاری مناسب برای شناسایی مناطق هدف است و شاخص زونالیته قائم نام دارد (Beus and Grigorian, 1977).

بئوس و گریگوریان (۱۹۷۷)، مدلی را برای پیش‌بینی کانی‌سازی پنهان ارائه کردند که فقط از شاخص زونالیته قائم به عنوان یک شاخص پیش‌بینی کننده برای شناسایی انواع مختلف کانی‌سازی تحت وضعیت زمین شناسی، در مقیاس معدنی و اکتشافات در مقیاس بزرگ استفاده می‌کند (Beus and Grigorian, 1977).

روش زونالیت‌ها در ابتدا برای آنالیز داده‌های لیتوژئوشیمیایی توسعه یافته بود (Kitaev, 1991). سپس گریگوریان (۱۹۹۲) ثابت کرد از این روش برای داده‌های ژئوشیمیایی رسوبات آبراهه‌ای نیز می‌توان استفاده نمود تا به وسیله حاصل ضرب عناصر مختلف، سطح از فرسایش بدست آید. شناخت موفقیت آمیز سطح از فرسایش آنومالی‌ها مرتبط با دورنمای کانی‌سازی در مقیاس ناحیه‌ای است (Ziaii et al., 2009; Grigorian, 1992). در روش زونالیت‌ها قابل اطمینان‌ترین ملاک برای تشخیص هاله‌های اولیه فوق کانسار، سطح از فرسایش کانسار و عمق احتمالی آن از طریق زون‌بندی عناصر مرتبط با کانسار است. زون‌بندی عنصری برای محاسبه شاخص زونالیت‌ها به کار می‌رود. شاخص زونالیت‌ها از نسبت غلظت عناصر قسمت‌های بالایی کانسار به غلظت عناصر در قسمت‌های پایینی کانسار به دست می‌آید. مقادیر بالای شاخص زونالیت‌ها، وجود کانی‌سازی در عمق را نشان می‌دهد و مقدار پایین آن نشان دهنده این است که کانسار فرسایش یافته است (Ziaii et al., 2009, 2011).


۲-۴-۳-۱- روش زونالیت‌ها ژئوشیمیایی

بررسی شاخص زونالیت‌ها بدست آمده از هاله‌های ژئوشیمیایی مرتبط با کانی‌سازی پنهان از تجزیه و تحلیل چهار مورد حاصل می‌شود (Ziaii et al., 2009):

- ۱) بررسی پیوستگی هاله‌های عناصر فوق کانسار و تحت کانسار و ارتباط آن با کانسار معدنی
 - ۲) بررسی مولفه واحد ناشی از آنومالی کاذب
 - ۳) تجزیه و تحلیل مقادیر میانگین عناصر شاخص خارج از آنومالی‌های ژئوشیمیایی برای حذف کردن نویز زمینه در تجزیه و تحلیل داده‌ها
 - ۴) ترسیم نقشه بدست آمده از آنومالی‌های ژئوشیمیایی ضربی (مانند شاخص‌های زونالیت‌ها)
- در کانسار مس پورفیری، نسبت عناصر Pb و Zn به Cu و Mo که غالباً به عنوان $(Pb \times Zn)/(Cu \times Mo)$ تعریف می‌شود، از اهمیت بالایی برخوردار است (Ziaii et al., 2009). متغیرهای ورودی در این شاخص به دو گروه تقسیم می‌شوند: بخش فوق کانسار (Pb و Zn) و تحت کانسار (Cu و Mo) (Solovov, 1990).

۲-۳-۴-۲- پیش پردازش داده‌های ژئوشیمیایی

داده‌های خارج از ردیف^۱ باعث به وجود آمدن مشکلاتی در بررسی روش‌های آماری داده‌های ژئوشیمیایی می‌شود. خطای نمونه‌برداری و خطای آزمایشگاهی عامل ایجاد این داده‌ها است که باید به وسیله مقادیر مناسب جایگزین شوند. روش دورفل برای شناسایی و جایگزینی این داده‌ها مناسب است. شکل ۳-۲ نمودار دورفل را برای تعیین حد آستانه مقادیر خارج از ردیف برای سطح معنی‌دار پنج درصد و یک درصد نشان می‌دهد (Shirazi et al., 2020).



شکل ۳-۲: حد آستانه مقادیر خارج از ردیف (g) به عنوان تابعی از تعداد نمونه (n) و میزان دقت (Shirazi et al., 2020)

روش دورفل به وسیله رابطه ۳-۲ محاسبه می‌شود که در این رابطه $\bar{x}$ میانگین، s انحراف معیار، g حد آستانه مقادیر خارج از ردیف و x_A بزرگ‌ترین مقدار داده‌ها است (Shirazi et al., 2020). به منظور انجام روش دورفل، ابتدا با توجه به تعداد داده‌های ژئوشیمیایی، به وسیله شکل ۳-۲ در سطح معنی‌دار مورد نظر مقدار حد آستانه مقادیر خارج از ردیف (g) تعیین می‌شود. سپس داده‌های ژئوشیمیایی از مقدار حداکثر به حداقل مرتب می‌شوند و میانگین ($\bar{x}$) و انحراف معیار (s) داده‌ها بدون در نظر گرفتن بزرگ‌ترین مقدار داده‌ها (x_A) محاسبه می‌شود. اگر بزرگ‌ترین مقدار داده‌ها (x_A) در رابطه ۳-۲ صدق کند، یک مقدار خارج از ردیف در

¹ Outlier

نظر گرفته می‌شود. این کار تا زمانی که رابطه ۳-۲ صادق نباشد انجام شده و آخرین مقدار محاسبه شده جایگزین تمام مقادیر خارج از ردیف می‌شود.

$$x_A \geq x + s.g \quad (3-2)$$

۲-۴-۳-۳- محاسبه زمینه و آنومالی

برای محاسبه شاخص زونالیت به محاسبه مقادیر زمینه، حد آستانه آنومالی و انحراف از معیار است. مقدار زمینه برابر میانگین هندسی مقادیر غلظت در منطقه خارج از آنومالی است. روابط ۴-۲ و ۵-۲ برای محاسبه حد آستانه آنومالی استفاده می‌شود که در آن C_A غلظت آنومال، C_x مقدار زمینه، s_{log} لگاریتم خطا (ε) است. مقدار ε از رابطه ۶-۲ به دست می‌آید (Solovov, 1987).

$$\log C_A = \log C_x + t s_{log} \quad (4-2)$$

$$C_A = C_x \varepsilon^t \quad (5-2)$$

$$\varepsilon = \text{anti log} \left(\sqrt{\frac{\sum_{i=1}^N (\log C_i - \log C_x)}{N - 1}} \right) \quad (6-2)$$

برای آشکارسازی آنومالی‌های قوی، t برابر ۳ در نظر گرفته می‌شود ولی برای آشکارسازی آنومالی‌های ضعیف‌تر از رابطه ۷-۲ استفاده می‌شود (Solovov, 1987). این محاسبات سنتی باعث از دست دادن بسیاری از آنومالی‌های ضعیف خواهد شد و به گونه‌ای منتهی به حذف آنومالی‌های مهم در کانسارهای کم فرسایش یافته و یا پنهان می‌شود.

$$C_A = C_x \varepsilon^{\frac{3}{\sqrt{m}}} \quad (7-2)$$

در این رابطه m مقداری بین ۱ تا ۹ و برابر تعداد نقاطی است که غلظت بیشتر از $C_x \varepsilon$ دارند. در صورتی که این تعداد بیشتر از ۹ باشد مقدار m برابر ۹ در نظر گرفته می‌شود.

۲-۴-۳-۴- محاسبه سطح از فرسایش

برای محاسبه شاخص زونالیت، سالووف (۱۹۸۷) و بئوس و گریگوریان (۱۹۷۷) به ترتیب استفاده از تولید سطحی و شاخص کانی‌سازی را برای حذف پارامترهای سین‌ژنتیک هاله‌ها پیشنهاد کردند. تا با حذف

بخش نامطلوب، قدرت آشکارسازی آنومالی‌ها افزایش یابد. لازم به ذکر است هر دو روش تولید سطحی و شاخص کانی‌سازی برای محاسبه شاخص زونالیت‌ه قائم استفاده می‌شود. مقادیر تولید خطی و تولید سطحی در یک شبکه نمونه‌برداری سیستماتیک از روابط ۸-۲ و ۹-۲ محاسبه می‌شود (Solovov, 1987).

$$M = \Delta X \left(\sum_{x=1}^n C_x - nC_0 \right) \quad (8-2)$$

$$P = 2l \left(\sum_{i=1}^m M_i \right) \quad (9-2)$$

در این روابط، M تولید خطی، P تولید سطحی و ΔX فاصله بین نمونه‌ها در طول پروفیل، C_x غلظت هر نمونه آنومال، n تعداد نمونه‌های آنومال و C_0 غلظت زمینه، $2l$ فاصله بین دو پروفیل و m تعداد پروفیل‌ها است.

شاخص زونالیت‌ه معرفی شده توسط سالووف از نسبت تولید سطحی عناصر فوق کانساری به تولید سطحی عناصر تحت کانساری برای هر آنومالی به وسیله رابطه ۱۰-۲ به دست می‌آید (Solovov, 1987). لازم به ذکر است با توجه به مناطق مورد مطالعه در این پژوهش، عناصر سرب و روی به عنوان فوق کانسار و عناصر مس و مولیبدن به عنوان تحت کانساری در نظر گرفته شده است.

$$K_S = \frac{P(Pb) \times P(Zn)}{P(Cu) \times P(Mo)} \quad (10-2)$$

برای محاسبه شاخص زونالیت‌ه معرفی شده توسط روش بئوس و گریگوریان نیاز به ارائه یک ضریب برای هر عنصر است که به عنوان ضریب کانی‌سازی شناخته می‌شود. رابطه ۱۱-۲ محاسبه ضریب کانی‌سازی را نشان می‌دهد که در آن $\eta_a(\alpha)$ برابر کل نمونه‌های یک زون و $\eta(\alpha)_{ore}$ برابر تعداد نمونه‌های آنومال است.

$$\eta(\alpha) = \frac{\eta_a(\alpha)_{ore}}{\eta_a(\alpha)} \quad (11-2)$$

سپس مقدار ضریب کانی‌سازی بدست آمده برای هر عنصر در زون مورد نظر، باید در میانگین غلظت آن عنصر (C_A) ضرب شود تا به وسیله رابطه ۱۲-۲ شاخص زونالیت‌ه محاسبه شود.

$$K_G = \frac{\eta(\alpha)_{Pb} \times CA_{Pb} \times \eta(\alpha)_{Zn} \times CA_{Zn}}{\eta(\alpha)_{Cu} \times CA_{Cu} \times \eta(\alpha)_{Mo} \times CA_{Mo}} \quad (12-2)$$


ضیائی (۱۹۹۶) به وسیله محاسبه مقادیر تولید سطحی، مدل شاخص زونالیته قائم را برای ذخایر مس پورفیری بر پایه ذخایر مس پورفیری قزاقستان، بلغارستان، ارمنستان و ایران معرفی کرد (Ziaii, 1996). در شکل ۴-۲ تغییرات عمودی در سه شاخص زونالیته نشان داده شده است که مرتبط با کنسارهای مس پورفیری در مناطقی با شرایط مشابه منظرهای-حالات ژئوشیمیایی در کشورهای متفاوت است. با وجود تفاوت‌های قابل توجه در موقعیت زمین‌شناسی کنسارهای مس پورفیری، مقادیر شاخص‌های زونالیته رو به پایین به صورت یکنواخت کاهش پیدا می‌کنند که نشان دهنده وجود شاخص زونالیته عمودی یکسان در هاله‌های اولیه کنسارهای مس پورفیری است. مقادیر مشابه شاخص زونالیته حاکی از عمق مشابه کانی‌سازی و هاله‌های اولیه در محدوده سنگ معدن است. بنابراین هاله‌های اولیه کنسارهای معدنی در اعماق مختلف با شاخص زونالیته مشخص، توصیف می‌شود (Ziaii et al., 2011). با توجه به شکل ۴-۲، مقادیر سطح از فرسایش بیشتر از یک، معرف کانی‌سازی پنهان اقتصادی و مقادیر سطح از فرسایش کمتر از یک، معرف کانی‌سازی پراکنده غیر اقتصادی است.

Erosional surface		Vertical section	$K = \frac{Zn.Pb}{Cu.Ag}$	$K = \frac{Zn.Pb}{Cu.Mo}$	$K = \frac{Zn.Pb.Bi}{Cu.Mo.Ag}$
					
Supra-ore	I		>100	>5	>1
Uppre-ore	II		100 – 10	5 – 0.5	1 – 0.1
Ore	III		10 – 1	0.5 – 0.05	0.1 – 0.01
Ore	IV		1 – 0.1	0.05 – 0.005	0.01 – 0.001
Lower-ore	V		0.1 – 0.01	0.005 – 0.0005	0.001 – 0.0001
Sub-ore	VI		<0.01	<0.0005	<0.0001
		Contrast K(I)/K(VI)	10,000	10,000	10,000

 orebody
  enclosing rocks
  primary halo
  ground surface

شکل ۴-۲: مدل شاخص زونالیته قائم معرفی شده توسط ضیائی (۱۹۹۶) (با تغییرات از Ziaii, 1996)

ضیائی و همکاران (۲۰۰۹) به وسیله محاسبه شاخص کانی‌سازی، مدلی برای ذخایر مس پورفیری آکتوگی (قزاقستان)، آسارل (بلغارستان)، تخوت (ارمنستان) و سونگون و آستامال (ایران) ارائه کردند (شکل ۵-۲). در این شکل با وجود تفاوت‌های قابل توجه در موقعیت زمین‌شناسی این مناطق، نقاط بر روی یک خط مستقیم قرار دارند که حاکی از وجود شاخص زونالیته عمودی یکسان در ساختار هاله‌های اولیه کنسار است (Ziaii et al., 2009). با توجه به شکل ۵-۲، مقادیر سطح از فرسایش بیشتر از یک، معرف کانی‌سازی پنهان اقتصادی و مقادیر سطح از فرسایش کمتر از یک، معرف کانی‌سازی پراکنده غیر اقتصادی است (شکل ۵-۲).



شکل ۲-۵: مدل شاخص زونالیتة قائم معرفی شده توسط ضیائی و همکاران (۲۰۰۹) (Ziaii et al., 2009)

۲-۵- علم داده و علوم زمین

علم داده‌های زمین یک زمینه نوین میان رشته‌ای برای استخراج اطلاعات علوم زمین است تا با ارزیابی و پیش‌بینی منابع و محیط زیست، منشا و آینده زمین بهتر درک شود. روش‌های مختلفی برای تجزیه و تحلیل داده‌های علوم زمین وجود دارد که می‌توان به طور کلی آن‌ها را به آمار داده، داده‌کاوی، بینش و یا بینایی و پیش‌بینی داده‌ها تقسیم نمود. آمار داده‌ها عمدتاً به روش‌های آماری سنتی با هدف مرتب‌سازی، فیلتر کردن، محاسبه و شمارش داده‌ها برای استخراج اطلاعات معنی‌دار اشاره دارد. داده‌کاوی به کشف قوانین ناشناخته، اطلاعات مفید و پنهان از داده‌های علوم زمین مانند روش‌های خوشه‌بندی^۱، آنالیز فاکتوری و الگوریتم‌های هوش مصنوعی اشاره دارد. همچنین هدف بینش و یا بینایی و پیش‌بینی داده‌ها مهیا نمودن بازنمایی رخدادهای زمین‌شناسی و یکپارچه‌سازی متغیرهای علوم زمین برای قطعیت در تصمیم‌گیری‌ها است (Zuo and Xiang, 2020).

¹ Clustering

۲-۵-۱- خوشه‌بندی

با توجه به عدم وجود برچسب^۱ در داده‌های بدون برچسب، نحوه یافتن الگوها در این داده‌ها مد نظر است. این روش خوشه‌بندی نام دارد که به معنای نسبت دادن اشیا به گروه‌هایی است که خوشه نامیده می‌شوند (لی، ۱۳۹۹). هدف از خوشه‌بندی، تقسیم داده‌ها به خوشه‌هایی است که شباهت بین داده‌های درون هر خوشه حداکثر و شباهت بین داده‌های درون خوشه‌های متفاوت، حداقل شود. روش خوشه‌بندی یک روش غیرمستقیم است، یعنی می‌توان از این روش حتی زمانی که هیچ گونه اطلاعاتی از ساختار داده‌ها وجود ندارد، استفاده کرد (شیرازی و همکاران، ۱۳۹۸).

کا-میانگین^۲ یکی از ساده‌ترین و مشهورترین روش‌های خوشه‌بندی است. این روش با اینکه از شبکه عصبی مصنوعی^۳ استفاده نمی‌کند ولی ایده بسیاری از روش‌های خوشه‌بندی است (هزارخانی و شکوه سلجوقی، ۱۳۹۷). هدف این خوشه‌بندی بدست آوردن K مرکز ثقل خوشه‌ها و برچسب برای داده‌های ورودی است. در این روش اغلب جهت تعیین فاصله از فاصله اقلیدسی استفاده می‌شود. از مسائل مهم در خوشه بندی کا- میانگین بدست آوردن K بهینه است که برای انجام این کار از ضریب شبح^۴ استفاده می‌شود. ضریب شبح از رابطه ۲-۱۳ بدست می‌آید (لی، ۱۳۹۹).

$$SC = 1 - (a/b) \quad (2-13)$$

در این رابطه، a فاصله میانگین یک نقطه به دیگر نقاط در خوشه مشابه و b کم‌ترین فاصله میانگین یک نقطه به همه دیگر نقاط در نزدیک‌ترین خوشه است. بالاترین مقدار SC معرف تعداد K بهینه است (لی، ۱۳۹۹).

۲-۵-۲- مبانی شبکه عصبی مصنوعی

شبکه عصبی مصنوعی از مطالعات مربوط به مدل‌سازی مغز انسان، الهام گرفته و مجموعه‌ای از عناصر پردازنده متصل غیر خطی‌اند. این شبکه از عناصر ساده‌ای تشکیل شده است که به طور موازی عمل می‌کنند

¹ Label

² K-means

³ Artificial Neural Network (ANN)

⁴ Silhouette

و با الهام از شبکه‌های بیولوژیک، هر یک از این عناصر نورون^۱ نامیده می‌شود. از شبکه عصبی مصنوعی در شناسایی و تشخیص الگوها استفاده می‌شود که شامل سه لایه ورودی، پنهان و خروجی است. آموزش شبکه‌های عصبی مصنوعی شامل تنظیم وزن‌های ارتباطی نورون‌ها به ازای ورودی‌های شبکه است تا خروجی شبکه به سمت خروجی مطلوب همگرا شود (هزارخانی و شکوه سلجوقی، ۱۳۹۷).

در شبکه‌های عصبی مصنوعی، اگر تعداد لایه‌های پنهان و نورون‌ها بیشتر باشد به آن شبکه عصبی عمیق گفته و به فرآیند آموزش این شبکه، یادگیری عمیق گفته می‌شود. بدین ترتیب اساس کار یادگیری عمیق بر مبانی شبکه عصبی مصنوعی استوار است (آگاروال، ۱۳۹۸). در این بخش به بررسی و معرفی پارامترهای شبکه عصبی مصنوعی و شبکه عصبی عمیق که در فرآیند یادگیری عمیق موثر هستند، پرداخته می‌شود.

۲-۵-۱-۲- الگوریتم پس‌انتشار خطا

الگوریتم پس‌انتشار^۲ بر قانون یادگیری اصلاح خطا مبتنی است. بدین ترتیب ساختار شبکه‌های پیش‌خور^۳ با این الگوریتم تکمیل می‌شود. فرآیند این الگوریتم به صورت رفت و برگشت است. در مسیر رفت، ورودی به شبکه اعمال شده و خروجی ایجاد می‌شود و در مسیر برگشت پارامترهای شبکه تغییر کرده و اصلاح می‌شوند (هزارخانی و شکوه سلجوقی، ۱۳۹۷).

۲-۵-۲-۲- شبکه‌های پیش‌خور

زمانی که در یک شبکه عصبی مصنوعی خروجی هر نورون تنها به نورون‌های لایه بعد وصل شود به آن پیش‌خور گفته می‌شود. در این شبکه اگر هر نورون در هر لایه از همه نورون‌های لایه قبل ورودی گرفته باشد به آن شبکه تمام متصل گفته می‌شود که این شبکه می‌تواند تک لایه یا عمیق و چند لایه باشد (هزارخانی و شکوه سلجوقی، ۱۳۹۷).


¹ Neuron

² Backpropagation

³ Feed Forward Neural Networks

۲-۵-۳- کم‌برازش و بیش‌برازش

قابلیت تعمیم^۱ یکی از مهم‌ترین مواردی است که باید در شبکه عصبی به آن توجه شود. مفهوم کم‌برازش^۲ و بیش‌برازش^۳ بر مبنای یادگیری و قابلیت تعمیم ایجاد شده و به عنوان دو مسئله مهم در آموزش شبکه عصبی مصنوعی شناخته می‌شود (شکل ۲-۶). با توجه به شکل ۲-۶ کم‌برازش زمانی رخ می‌دهد که نمودار خطای مجموعه آموزش^۴ (نمودار آبی) پایین‌تر از نمودار خطای مجموعه آزمایش^۵ (نمودار نارنجی) بوده و هر دو نمودار در جهت کاهش خطا است. همچنین بیش‌برازش زمانی رخ می‌دهد که نمودار خطای داده‌های آزمایش شروع به افزایش کرده ولی نمودار خطای داده‌های آموزش کاهش یابد. به طور کلی کم‌برازش بیانگر عملکرد ضعیف شبکه در یادگیری و تعمیم نتایج بر روی دیگر داده‌ها است. همچنین بیش‌برازش نشان‌دهنده یادگیری خوب در شبکه ولی قابلیت تعمیم ضعیف است (Smith, 2018).



شکل ۲-۶: شمایی از مشکل کم‌برازش و بیش‌برازش در شبکه عصبی مصنوعی (Zhang et al., 2019)

برای رفع مشکل کم‌برازش راهکارهای متعددی وجود دارد که می‌توان به انتخاب معماری بهتر برای شبکه، اضافه کردن ویژگی‌های بهتر برای آموزش شبکه و افزایش و رفع محدودیت داده‌ها اشاره کرد. همچنین برای رفع مشکل بیش‌برازش نیز می‌توان داده‌ها را افزایش داد ولی در بیشتر مواقع این روش امکان‌پذیر نیست

¹ Generalization

² Underfitting


³ Overfitting

⁴ Training data

⁵ Test data

و از روش دیگری به نام منظم‌سازی^۱ استفاده می‌شود. منظم‌سازی باعث تغییر جزئی در الگوریتم یادگیری و ایجاد قابلیت تعمیم در مدل می‌شود. حذف تصادفی^۲ یکی از روش‌های کاربردی در منظم‌سازی است (Zhang et al., 2019).

روش حذف تصادفی به منظور جلوگیری از بیش‌برازش ارائه شده است. در این روش شبکه مجبور به یادگیری ویژگی‌های مفید بیشتری می‌شود. بدین ترتیب در طول فرآیند آموزش در هر تکرار، هر نورون با احتمال p در شبکه حفظ و با احتمال $1 - p$ از شبکه حذف (غیرفعال) می‌شود. در شکل ۷-۲ شمایی از یک شبکه قبل و بعد از حذف تصادفی نشان داده شده است (Baldi and Sadowski, 2013).



شکل ۷-۲: شمایی از یک شبکه قبل از حذف تصادفی (الف) و بعد از حذف تصادفی (ب) (Liu et al., 2018)

۲-۵-۴- تابع فعال‌ساز

تابع فعال‌ساز^۳ آستانه‌ای برای مقادیر خروجی هر نورون تعیین می‌کند (هزارخانه‌ی و شکوه سلجوقی، ۱۳۹۷). توابع فعال‌ساز مورد استفاده در شبکه‌های پیش‌خور، باید ویژگی‌های خاصی داشته باشد. این تابع باید پیوسته، مشتق‌پذیر و یکنوا نزولی باشد. همچنین مشتق اول این تابع باید به راحتی محاسبه شود. برخی از توابع فعال‌ساز پرکاربرد در شبکه‌های عمیق عبارتند از: تابع سیگموئید^۴، تانژانت هذلولی^۵، تابع یکسوساز خطی^۶

¹ Regularization

² Dropout

³ Activation Function

⁴ Sigmoid

⁵ Hyperbolic Tangent


⁶ Rectified Linear Unit (ReLU)

و تابع بیشینه هموار^۱ (آگاروال، ۱۳۹۸). استفاده از توابع یکسوساز خطی و بیشینه هموار در یادگیری عمیق مرسوم بوده و منجر به ارائه نتایج بهتر نسبت به دیگر توابع فعال ساز می شود (شوله، ۱۳۹۹). بدین منظور در این پژوهش از توابع یکسوساز خطی و بیشینه هموار استفاده شده است.

الف) تابع یکسوساز خطی

تابع تابع یکسوساز خطی در طی سال های اخیر به عنوان محبوب ترین تابع فعال ساز در شبکه های عمیق شناخته شده است (شکل ۸-۲) و به وسیله رابطه ۱۴-۲ محاسبه می شود. در صورتی که ورودی مقدار منفی باشد این تابع مقدار صفر و برای ورودی های مثبت این تابع حد نداشته و ورودی را بازمی گرداند. این تابع از نظر محاسباتی نسبت به دیگر توابع بسیار کارآمد است و به شبکه اجازه می دهد خیلی سریع همگرا شود. همچنین این تابع با خطاهای موجود در پس انتشار مواجهه نمی شود (آگاروال، ۱۳۹۸).

$$RELU = \max(0, x) \quad (۱۴-۲)$$



شکل ۸-۲: شمایی از تابع یکسوساز خطی

ب) تابع بیشینه هموار

از تابع تابع بیشینه هموار در لایه خروجی استفاده می شود. این تابع تعمیم یافته تابع سیگموئید بوده و برای مشکلات مربوط به کلاس بندی استفاده می شود. خروجی تابع تابع بیشینه هموار یک توزیع احتمال است. این تابع خروجی را به بازه صفر تا یک منتقل کرده و هر خروجی را به نحوی نگاشت می کند که مجموع

¹ Softmax

آن برابر با یک باشد. تابع تابع بیشینه هموار به وسیله رابطه ۲-۱۵ محاسبه می‌شود. در این رابطه y بردار داده ورودی، k تعداد طبقه‌های خروجی، e^{y_i} و e^{y_j} به ترتیب تابع نمایی استاندارد برای بردار ورودی و خروجی است (Goodfellow et al., 2016).

$$S(y_i) = \frac{e^{y_i}}{\sum_{j=1}^k e^{y_j}} \quad (2-15)$$

۲-۵-۲-۵- تابع هزینه

تابع هزینه^۱ معیاری مهم در آموزش است که نشان می‌دهد شبکه عصبی مصنوعی آموزش داده شده تا چه اندازه نزدیک به معیار ایده‌آل مورد نظر بوده است. انتخاب تابع هزینه مناسب یکی از جنبه‌های مهم آموزش است. این تابع نقش مهمی در سرعت همگرایی شبکه دارد و معیاری برای بررسی عملکرد و تنظیم پارامترهای شبکه است. تابع هزینه برای مقاصد کلاس‌بندی و رگرسیون استفاده می‌شود. توابع هزینه‌ای که بیشترین استفاده را در شبکه‌های عمیق دارند عبارتند از: آنتروپی متقاطع^۲، کولبک-لیبر^۳، هینج^۴، میانگین خطای مربعات^۵ و میانگین خطای قدر مطلق^۶ (Goodfellow et al., 2016). توابع هزینه آنتروپی متقاطع و میانگین خطای مربعات به ترتیب کاربرد وسیعی در مباحث کلاس‌بندی و رگرسیون در یادگیری عمیق دارند (شوله، ۱۳۹۹). بدین ترتیب در این پژوهش از توابع هزینه آنتروپی متقاطع و میانگین خطای مربعات استفاده شده است.

الف) تابع آنتروپی متقاطع

تابع هزینه آنتروپی متقاطع یک روش ریاضی است که در مسائل گسسته مانند کلاس‌بندی استفاده می‌شود. این تابع کاربرد وسیعی در شبکه‌های عمیق به منظور طبقه‌بندی دودویی و چندتایی دارد که به ترتیب عبارتند از آنتروپی متقاطع باینری^۷ و آنتروپی متقاطع دسته‌ای^۸. رابطه ۲-۱۶ نشان دهنده تابع هزینه آنتروپی

¹ Loss Function

² Cross Entropy

³ Kullback-Leibler

⁴ Hinge

⁵ Mean Squared Error (MSE)

⁶ Mean Absolute Error

⁷ Binary Cross Entropy

⁸ Categorical Cross Entropy

مقاطع است که در آن y مقدار واقعی، y' خروجی شبکه و n تعداد نمونه‌های شبکه داده‌ها است (Goodfellow et al., 2016).

$$CE(y, y') = \frac{\sum_{i=1}^n y_i \log y'_i}{n} \quad (۱۶-۲)$$

ب) تابع میانگین خطای مربعات

میانگین خطای مربعات از معروف‌ترین توابع هزینه در رگرسیون است که میانگین اختلاف مربعات بین مقادیر واقعی و خروجی شبکه را به وسیله رابطه ۱۷-۲ محاسبه می‌نماید (Goodfellow et al., 2016).

$$MSE(y, y') = \frac{\sum_{i=1}^n (y_i - y'_i)^2}{n} \quad (۱۷-۲)$$

۲-۵-۶- الگوریتم بهینه‌ساز

بهینه‌سازها الگوریتم‌هایی هستند که با تعیین نرخ یادگیری و از طریق به‌هنگام‌سازی وزن‌ها در شبکه سعی در به حداقل رساندن تابع هزینه دارند. این فرآیند هدف اصلی شبکه است یعنی وزن‌ها به گونه‌ای تنظیم شوند تا شبکه توانایی یادگیری را بدست آورد. روش‌های مختلفی برای بهینه‌سازی وجود دارد که گرادیان کاهشی^۱ یکی از محبوب‌ترین و متداول‌ترین این الگوریتم‌ها در شبکه عصبی مصنوعی است. الگوریتم گرادیان کاهشی یک روش بهینه‌سازی مبتنی بر تکرار است و با تغییر در وزن‌های داخلی شبکه و بروزرسانی تدریجی آن‌ها در جهت حداقل رساندن تابع هزینه انجام می‌شود. فرآیند تکرار تا زمانی که در تابع هزینه تغییری مشاهده نشود ادامه دارد که به آن همگرایی گفته می‌شود. انواع مختلفی از الگوریتم‌های بهینه‌سازی گرادیان کاهشی در شبکه‌های عمیق وجود دارد؛ این الگوریتم‌ها عبارتند از: گرادیان کاهشی تصادفی^۲، آداگراد^۳، آدالتا^۴، آرام‌اس پراب^۵ و برآورد تکانه تطبیقی^۶ (Ruder, 2016). در این پژوهش به واسطه عملکرد مناسب الگوریتم برآورد تکانه تطبیقی در شبکه‌های مختلف یادگیری عمیق، از این الگوریتم در بهینه‌سازی استفاده شده است.

¹ Gradient descent

² Stochastic gradient descent

³ Adagrad

⁴ Adadelta

⁵ RMSprop

⁶ Adaptive Moment Estimation (ADAM)

الگوریتم برآورد تکانه تطبیقی روشی جهت محاسبه نرخ یادگیری تطبیقی برای هر پارامتر است. این الگوریتم از مزایای الگوریتم‌های آداگرا و آرام‌اس پراب استفاده می‌کند و در جهت توسعه آن‌ها معرفی شده است. از مزایای این دو الگوریتم می‌توان به تنظیم خودکار نرخ یادگیری بدون تنظیم دستی و برطرف کردن مشکل کاهش نرخ یادگیری اشاره کرد. برآورد تکانه تطبیقی عملکرد بهتری نسبت به دیگر روش‌ها دارد و در کم‌ترین زمان همگرا می‌شود. همچنین بر مشکلاتی مانند فروپاشی نرخ یادگیری، واریانس بالا در بروزرسانی و همگرایی آهسته غلبه می‌کند (Kingma and Ba, 2015; Ruder, 2016).

الگوریتم برآورد تکانه تطبیقی میانگین فروپاشی نمایی از گرادیان‌های گذشته را در v_t و میانگین تکانه‌ای دوم گرادیان را در m_t ذخیره می‌کند. بر این اساس m_t و v_t به ترتیب بیانگر مقادیر میانگین (رابطه ۱۸-۲) و واریانس غیرمتمرکز (رابطه ۱۹-۲) هستند (Kingma and Ba, 2015).

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (18-2)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (19-2)$$

همچنین این الگوریتم میانگین‌های متحرک نمایی گرادیان و گرادیان مربع را به ترتیب توسط معادلات ۲۰-۲ و ۲۱-۲ کنترل می‌کند (Ruder, 2016).

$$m'_t = \frac{m_t}{1 - \beta_1^t} \quad (20-2)$$

$$v'_t = \frac{v_t}{1 - \beta_2^t} \quad (21-2)$$

بنابراین بروزرسانی وزن‌ها طبق الگوریتم برآورد تکانه تطبیقی به وسیله رابطه ۲۲-۲ محاسبه می‌شود. در تمامی روابط، مقادیر β_1 و β_2 عضو بازه صفر تا یک و ε مقداری برای جلوگیری از صفر شدن مخرج است که به‌طور معمول برابر 10^{-8} در نظر گرفته می‌شود (Ruder, 2016).

$$w_{t+1} = w_t - \frac{\eta}{\sqrt{v'_t} + \varepsilon} m'_t \quad (22-2)$$

۲-۵-۲-۷- ارزیابی صحت

دقت^۱ و صحت^۲ دو روش برای ارزیابی مدل است که در زمینه روش عملی در تقابل با یکدیگر هستند. صحت یک سیستم اندازه‌گیری برای بررسی فاصله نتایج با مقادیر واقعی است در حالی که دقت مربوط به تکرارپذیری است. صحت بیان‌کننده تعداد پیش‌بینی‌های درست انجام شده توسط شبکه بر تعداد کل پیش‌بینی‌های انجام شده توسط همان شبکه است که اشاره به قدرت شبکه در تشخیص درست دارد (Fawcett, 2006). معیار صحت به وسیله رابطه ۲-۲۳ محاسبه می‌شود. برای معرفی پارامترهای این معیار، به طور مثال شبکه‌ای را در نظر بگیرید که برای تشخیص بیماران از افراد سالم در نظر گرفته شده است. پارامترهای تشکیل ماتریس درهم‌ریختگی^۳ این شبکه عبارتند از: تعداد افراد سالمی که توسط شبکه به درستی سالم معرفی شده‌اند (TN)، تعداد افراد بیمار که توسط شبکه به اشتباه سالم معرفی شده‌اند (FN)، تعداد افراد بیماری که توسط شبکه به درستی بیمار تشخیص داده شده‌اند (TP)، تعداد افراد سالم که توسط شبکه به اشتباه بیمار تشخیص داده شده‌اند (FP) (هزارخانی و شکوه سلجوقی، ۱۳۹۷).

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} \quad (2-23)$$

۲-۵-۲-۸- آماده‌سازی داده‌ها

در شبکه‌های عمیق داده‌ها به صورت تنسور^۴ است و به سه دسته مجموعه آموزش^۵، مجموعه آزمایش^۶ و مجموعه اعتبارسنجی^۷ تقسیم می‌شوند. همچنین برای آموزش صحیح شبکه و اجرای صحیح پارامترهای مورد استفاده در شبکه، داده‌ها با تقسیم‌بندی خاصی وارد شبکه می‌شوند. یک تقسیم‌بندی معمول عبارت است از: اختصاص ۱۵ درصد داده‌ها برای مجموعه آزمایش، ۱۵ درصد داده‌ها برای مجموعه اعتبارسنجی و ۷۰ درصد داده‌ها برای مجموعه آموزش (شوله، ۱۳۹۹؛ هزارخانی و شکوه سلجوقی، ۱۳۹۷).

¹ Precision

² Accuracy

³ Confusion matrix

⁴ Tensor

⁵ Training data

⁶ Test data

⁷ Validation data

مقادیر ورودی تنسورها در شبکه باید به مقادیر کوچک‌تر مقیاس شوند که تبدیل داده‌ها به دامنه $[-1,1]$ و $[0,1]$ مرسوم است. در این پژوهش داده‌ها به دامنه $[0,1]$ منتقل شدند که به نرمال‌سازی ویژگی معروف است. نرمال‌سازی ویژگی عملکرد بهتری دارد زیرا برای مقادیر نسبی ویژگی رایج است که بیش از ده برابر تغییرپذیری داشته باشد. در رابطه ۲-۲۴ نحوه تبدیل داده‌ها به وسیله نرمال‌سازی ویژگی نشان داده شده است (شوله، ۱۳۹۹، آگاروال، ۱۳۹۸).

$$x'_{ij} = \frac{x_{ij} - \min_j}{\max_j - \min_j} \quad (2-24)$$

۲-۵-۳- یادگیری ماشین

یادگیری ماشین یک روش تجزیه و تحلیل داده است. این روش اطلاعات را بدون اینکه صریحا برنامه‌نویسی شود از داده‌ها می‌آموزد (Bishop, 2007). با توجه به ماهیت یادگیری، الگوریتم‌های یادگیری ماشین به طور گسترده در یادگیری نظارت شده^۱ و یادگیری نظارت نشده^۲ تقسیم‌بندی می‌شوند (Mohri et al., 2018). در یادگیری نظارت شده، مجموعه ورودی پاسخ‌های برچسب‌دار را ایجاد می‌کند که هدف آن ایجاد یک تابع غیرخطی برای تبدیل ورودی‌های جدید به خروجی‌ها است. در زمانی که پاسخ‌های خروجی مورد انتظار مقادیر گسسته هستند یا مشکلات رگرسیون وجود دارد که در آن خروجی مقادیر پیوسته را نشان می‌دهد، این نوع یادگیری ماشین می‌تواند مشکلات کلاس‌بندی را مرتفع کند. برخلاف یادگیری نظارت شده، یادگیری بدون نظارت به وسیله مجموعه‌های ورودی بدون برچسب آموزش داده می‌شود. در این نوع یادگیری، هدف آشکارسازی الگوهای پنهان و بالقوه در داده‌ها است و غالبا شامل خوشه‌بندی، کاهش ابعاد و استخراج ویژگی است (Zuo et al., 2019).

ویژگی مشترک این الگوریتم‌های یادگیری، معماری ساده‌ای است که تنها یک لایه پنهان را شامل می‌شود و بر اساس برچسب‌هایی که به صورت دستی ایجاد شده است، برای شناسایی ویژگی‌های کم عمق

¹ Supervised learning

² Unsupervised learning

مناسب است. این معماری کم عمق ابزاری قدرتمند برای مدل سازی بسیاری از موضوعات ساده یا به خوبی محدود شده است، اما در یادگیری سطوح بالاتر محدودیت هایی را نشان می دهد (LeCun et al., 2015).

۲-۵-۴- یادگیری عمیق

در سال های اخیر یادگیری عمیق به عنوان زیر مجموعه ای از یادگیری ماشین، به موضوعی جذاب در رشته های مختلف تبدیل شده است. الگوریتم های یادگیری عمیق نوعی از روش های یادگیری بازنمایی^۱ هستند که به عنوان یک ماشین می توانند به طور خودکار الگوهای خوب و مفید را از داده ها استخراج کرده و برای کلاس بندی یا تشخیص استفاده نمایند. این روش در استخراج و بازنمایی خودکار ویژگی ها در سطوح بالا از داده های پیچیده، بسیار توانمند است (LeCun et al., 2015; Zuo et al., 2019). به عنوان مثال در زمینه شناسایی و کلاس بندی تصاویر در یک شبکه عمیق شامل ۴ لایه برای مجموعه ورودی تصاویر، لایه اول شبکه لایه ها را در جهت های خاص استخراج می کند؛ لایه دوم با بررسی نحوه قرارگیری و ترکیب لایه ها، خطوط را استخراج می کند؛ لایه سوم خطوط را در مجموعه ای بزرگ تر در کنار هم قرار می دهد که می تواند با بخشی از اهداف مطابقت داشته باشد و لایه چهارم با ترکیب لایه های قبل اهداف را تشخیص می دهد (Zeiler and Fergus, 2014; LeCun et al., 2015).

روش های یادگیری عمیق به وسیله شبکه عصبی مصنوعی چند لایه بر مبنای تفکیک ویژگی ها به صورت سلسله مراتبی به کشف ساختار پنهان بین داده ها می پردازند. عبارت عمیق نیز برگرفته از همین خاصیت است، به گونه ای که شبکه آموزشی در هر مرحله با در نظر گرفتن یکسری ویژگی های شاخص اقدام به کشف رابطه و ویژگی های غیرخطی بین داده ها می نماید. افزایش عمق شبکه باعث می شود تا ویژگی های ساده تر با ویژگی های پیچیده ترکیب شوند و مناسب ترین بازنمایی سلسله مراتبی از داده ها بدست آید (LeCun et al., 2015; Schmidhuber, 2015).

¹ Representation learning

برخی از الگوریتم‌های معروف یادگیری عمیق عبارتند از: خودرمزنگار^۱، باور عمیق^۲، شبکه عصبی همگشتی^۳، شبکه مولد تخصصی^۴ و شبکه عصبی بازگشتی^۵ (Goodfellow et al., 2016). با توجه به داده‌ها و روش ژئوشیمیایی مورد استفاده در این پژوهش، به منظور ترکیب و ایجاد ارتباط بین یادگیری عمیق با زونالیت‌ه ژئوشیمیایی از الگوریتم‌های خودرمزنگار و شبکه عصبی همگشتی استفاده شده است. در ادامه این دو الگوریتم و پارامترهای مرتبط با آن‌ها بررسی شده است.

۲-۵-۴-۱- الگوریتم خودرمزنگار

خودرمزنگار به عنوان نوع خاصی از شبکه عصبی مصنوعی برای بازنمایی، فشرده‌سازی، کاهش بعد و رمزگذاری بر روی داده‌ها به وسیله به حداقل رساندن خطای بازنمایی بین مقادیر ورودی و خروجی شبکه، به روش نظارت نشده طراحی شده است (Bengio et al., 2007; Vincent et al., 2010). در این شبکه خروجی همان ورودی است. بنابراین تعداد واحدهای ورودی با خروجی برابر است، ولی معمولاً تعداد واحدهای خروجی بیشتر از تعداد واحدهای لایه‌های پنهان است. در شکل ۲-۹ معماری یک خودرمزنگار نشان داده شده است که شامل سه مولفه رمزگذار^۶، رمز^۷ و رمزگشا^۸ است. رمزگذار ورودی را فشرده می‌کند و بر اساس ویژگی‌های بدست آمده رمز را تولید می‌کند و رمزگشا ورودی را بر اساس رمز بازسازی می‌کند (Hinton and Salakhutdinov, 2006).

¹ Autoencoder (AE)

² Deep Belief Network (DBN)

³ Convolutional Neural Network (CNN)


⁴ Generative Adversarial Networks (GAN)

⁵ Recurrent Neural Networks (RNN)

⁶ Encoder

⁷ Code

⁸ Decoder



شکل ۲-۹: شمایی از معماری خودرمزنگار (Aouedi et al., 2020)

رابطه ۲-۲۵ و ۲-۲۶ به ترتیب فرآیند تبدیل ورودی به لایه رمز و بازنمایی ورودی را برای خودرمزنگار با یک لایه میانی نشان می‌دهد. در این روابط، x بردار ورودی با شرایط $x \in \mathbb{R}^n$ ، $\theta = \{W, b\}$ که در آن W ماتریس وزن با شرایط $W \in \mathbb{R}^{n \times m}$ و b بردار بایاس با شرایط $b \in \mathbb{R}^m$ است. همچنین $f_\theta(x)$ رمزگذار و σ تابع فعال‌ساز است. مشابه پارامترهای معرفی شده، x' بردار خروجی با همان ابعاد بردار ورودی، $\theta' = \{W', b'\}$ و $g_{\theta'}(h)$ رمزگشا است (Liu et al., 2018).

$$h = f_\theta(x) = \sigma(Wx + b) \quad (2-25)$$

$$x' = g_{\theta'}(h) = \sigma(hW' + b') \quad (2-26)$$

خودرمزنگار به انواع متعددی تقسیم می‌شود که عبارتند از: خودرمزنگار متغیر^۱، خودرمزنگار عمیق^۲، خودرمزنگار پشته‌ای^۳ و خودرمزنگار همگشتی^۴. لازم به ذکر است با توجه به داده‌ها و روش ژئوشیمیایی مورد استفاده در این پژوهش، از الگوریتم خودرمزنگار پشته‌ای استفاده شده است.

الف) الگوریتم خودرمزنگار پشته‌ای

خودرمزنگار در ساده‌ترین حالت از یک لایه میانی تشکیل شده است اما شبکه‌های عمیق‌تر در مقایسه با انواع کم عمق خود قادر به بازنمایی بهتری هستند که منجر به طراحی خودرمزنگار پشته‌ای شده است. در


¹ Variational Autoencoder (VAE)

² Deep Autoencoder (DAE)

³ Stacked Autoencoder (SAE)

⁴ Convolutional Autoencoder (CAE)

خودرمزنگار پشته‌ای همه نورون‌ها به هم متصل بوده و آموزش از لایه ورودی به خروجی، بدون داشتن حلقه رو به عقب جریان پیدا می‌کند که معرف شبکه‌های پیش‌خور است. خودرمزنگار پشته‌ای مانند شبکه عصبی مصنوعی به وسیله روش پس‌انتشار آموزش داده می‌شود (شکل ۲-۱۰). از ویژگی‌های این الگوریتم آموزش حریصانه است که شبکه به صورت چند لایه‌ای و لایه به لایه آموزش داده می‌شود تا بتوان اطلاعات مورد نیاز در جهت استخراج ویژگی، خوشه‌بندی، کاهش بعد و فشرده سازی را در لایه رمز بدست آورد. بدین ترتیب می‌توان شبکه‌ای متفاوت با شبکه ابتدایی طراحی نمود و با داده‌های برچسب‌دار مجدد شبکه را آموزش داد. لازم به ذکر است اطلاعات بدست آمده از شبکه اول به شبکه جدید منتقل می‌شود که به یادگیری انتقالی^۱ معروف است. همچنین فرآیند آموزش مجدد شبکه به وسیله داده‌های برچسب‌دار با عنوان تنظیم دقیق^۲ شناخته شده است که آموزشی نظارت شده است (Hinton and Salakhutdinov, 2006; Bengio et al., 2007).



شکل ۲-۱۰: شمایی از معماری خودرمزنگار پشته‌ای (با تغییرات از Luo et al., 2020)


^۱ Transfer Learning

^۲ Fine Tuning

ب) تنظیم دقیق و الگوریتم خودرمنگار پشته‌ای

یادگیری انتقالی به ویژه در مدل‌هایی که به تدریج آموزش داده می‌شوند بسیار مفید است و می‌تواند از یک مدل به عنوان نقطه شروع برای ادامه آموزش استفاده کند. هدف از تنظیم دقیق بهبود فرآیند یادگیری با استفاده از تجربه بدست آمده از حل مسائل قبلی است که تا حدودی شباهت دارند. بررسی‌های قبلی نشان داده‌اند که آموزش شبکه به صورت نظارت نشده ویژگی‌ها و اطلاعات بسیار مناسبی را از داده‌ها استخراج می‌کند و با انتقال کل یا جزئی از وزن‌ها و اطلاعات شبکه می‌توان شبکه را با یادگیری نظارت شده آموزش داده تا علاوه بر نتایج بدست آمده، توانایی یادگیری افزایش و از شبکه برای کلاس‌بندی نیز استفاده کرد. به طور کلی در این نوع آموزش، در ابتدا به صورت نظارت نشده ویژگی‌ها استخراج شده و سپس با داده‌های برچسب‌دار و به صورت نظارت شده شبکه مجدد آموزش داده می‌شود که دقت، عملکرد و کارایی بهتری نسبت به شبکه قبل دارد (Hinton and Salakhutdinov, 2006).

در شکل ۱-۲، الگوریتم خودرمنگار پشته‌ای با سه لایه بر مبنای تنظیم دقیق نشان داده شده است. در ابتدا قبل از تنظیم دقیق، هر لایه ورودی به صورت یک خودرمنگار مجزا به وسیله آموزش نظارت نشده، آموزش داده می‌شود. سپس واحد رمزگشا حذف و واحد رمز به عنوان ورودی جدید عمل می‌کند. این الگوریتم تا زمانی که آموزش شبکه مورد نظر تکمیل شود، تکرار می‌شود. سپس بعد از اتمام آموزش شبکه، اطلاعات و پارامترها ذخیره شده و شبکه با داده‌های برچسب‌دار به منظور حداقل رساندن تابع هزینه و به روزرسانی وزن‌ها آموزش داده می‌شود که بیانگر تنظیم دقیق است (Liu et al., 2018).



شکل ۲-۱۱: شمایی از معماری خودرمنگار پشته‌ای بعد از تنظیم دقیق (با تغییرات از Liu et al., 2018)


۲-۵-۴-۲- الگوریتم شبکه عصبی همگشتی

شبکه عصبی همگشتی از مهم‌ترین الگوریتم‌های یادگیری عمیق و یکی از رایج‌ترین روش‌های بینایی ماشین است. برخلاف معماری خودرمنگار که لایه‌های آن با یکدیگر تمام متصل هستند، مجموعه ورودی در شبکه عصبی همگشتی به وسیله فیلترها به زیرناحیه‌هایی تقسیم می‌شود و با اعمال فیلترهای مورد نظر، نورون‌ها لایه‌های بعدی را تشکیل می‌دهند (LeCun et al., 1998). برای برخی از انواع داده‌ها به ویژه تصاویر، شبکه‌های پیش‌خور کارکرد مناسبی ندارند. در شبکه‌های پیش‌خور هر نورون به طور کامل به هریک از نورون‌های موجود در لایه بعدی متصل است اما در بازنمایی تصاویر اغلب استفاده از زیرساخت محلی در تصویر سودمند است. ویژگی دیگری که شبکه عصبی همگشتی را از دیگر شبکه‌ها متمایز می‌کند، مشترک بودن وزن‌های شبکه در نورون‌های مختلف لایه‌های پنهان است. شبکه عصبی همگشتی به عنوان یادگیری موثر مجموعه فیلترها شناخته شده است که هر کدام از آن‌ها برای همه زیر پنجره‌های تصویر ورودی اعمال می‌شود. استفاده از فیلترها در کل تصویر، شبکه را مجبور به یادگیری یک بازنمایی کلی از داده‌ها می‌کند و از دیگر

مزایای آن کاهش تعداد پارامترها، آسان‌تر شدن آموزش شبکه و کارآمدی شبکه است (آگاروال، ۱۳۹۸؛ شوله، ۱۳۹۹).

فرآیند آموزش شبکه عصبی همگشتی در مقایسه با آموزش شبکه پیش‌خور وضعیت پیچیده‌تری دارد. دلیل آن وجود لایه‌های مختلف در شبکه است که بنابر ویژگی‌ها از قوانین ویژه برای انتشار به جلو و پس‌انتشار استفاده می‌کنند. همچنین برخلاف شبکه پیش‌خور که هر نورون دارای یک بردار وزن جداگانه است، نورون‌ها در شبکه عصبی همگشتی وزن مشترک دارند. این اشتراک وزن‌ها منجر به کاهش تعداد کلی وزن‌های قابل آموزش می‌شود (آگاروال، ۱۳۹۸؛ شوله، ۱۳۹۹).

شبکه عصبی همگشتی شامل انواع مختلفی از لایه‌های پنهان است که عبارتند از: لایه همگشت^۱، لایه ادغام^۲ و لایه تمام متصل^۳ (Krizhevsky et al., 2012). در شکل ۲-۱۲ لایه‌های مختلف یک شبکه عصبی همگشتی را برای کلاس‌بندی یک تصویر نشان داده شده است. در ادامه این لایه‌ها و چند معماری از شبکه عصبی همگشتی بررسی شده است.



شکل ۲-۱۲: مثالی از شبکه عصبی همگشتی در کلاس‌بندی تصویر

^۱ Convolutional Layer

^۲ Pooling Layer

^۳ Fully Connected Layer

الف) لایه همگشت در شبکه عصبی همگشتی

لایه همگشت مهم‌ترین قسمت شبکه عصبی همگشتی است و به عنوان اولین لایه استفاده می‌شود. این لایه بیشترین بار محاسباتی را بر عهده دارد و بسته به ساختار شبکه ممکن است بیش از یک لایه همگشت در شبکه وجود داشته باشد. نقش اصلی این لایه در شناسایی ویژگی‌های محلی در بخش‌های مختلف مجموعه ورودی است. مزیت این بخش شامل تقسیم وزن‌ها و ایجاد همبستگی مکانی است که باعث یادگیری ارتباط بین پیکسل‌های همسایه می‌شود (Guo et al., 2016). دو مفهوم اساسی در لایه همگشت عبارتند از: پرش‌ها^۱ و لایه‌گذاری^۲. پرش‌ها بیانگر تعداد پیکسل‌های فیلتر در راستای عمودی و افقی است و لایه‌گذاری زمانی استفاده می‌شود که فیلتر با ماتریس ورودی تناسب ندارد. همچنین اندازه خروجی شبکه عصبی همگشتی مقداری کوچک‌تر از اندازه مجموعه ورودی است که با اعمال لایه گذاری یکسان^۳، حاشیه‌ها تغییری نکرده و فیلتر متناسب با مجموعه ورودی می‌شود. به طور کلی لایه همگشت شامل ۳ مولفه تصویر ورودی، استخراج ویژگی و نقشه ویژگی^۴ است (آگاروال، ۱۳۹۸؛ شوله، ۱۳۹۹).

ب) لایه ادغام در شبکه عصبی همگشتی

معمولاً بعد از هر لایه همگشت یک لایه ادغام قرار می‌گیرد و از آن برای کاهش اندازه نقشه ویژگی و پارامترهای شبکه استفاده می‌شود. اجرای این لایه به وسیله دو تابع معروف ادغام حداکثری^۵ و ادغام میانگین^۶ انجام می‌شود (Scherer et al., 2010). لازم به ذکر است این فرآیند منجر به کاهش قدرت محاسباتی مورد نیاز برای پردازش داده‌ها می‌شود. بدین ترتیب به جای استفاده از این لایه، در لایه همگشت یک پرش تعریف می‌شود. از لحاظ تعداد پارامترهای آموزش، این روش با لایه ادغام برابر است ولی مشکلات لایه ادغام را برطرف می‌کند.

¹ Strides

² Padding

³ Same padding

⁴ Feature map

⁵ Max Pooling


⁶ Average Pooling

ج) لایه تمام متصل در شبکه عصبی همگشتی

در شبکه عصبی همگشتی لایه‌های همگشت و ادغام وظیفه استخراج ویژگی‌ها را بر عهده دارند. لایه تمام متصل در شبکه عصبی همگشتی مانند لایه‌های پنهان در شبکه عصبی مصنوعی است و در انتهای شبکه عصبی همگشتی قرار دارند. به وسیله این لایه می‌توان از شبکه عصبی همگشتی در جهت کلاس‌بندی، بازنمایی ویژگی‌ها و پردازش‌های دیگر استفاده کرد (Krizhevsky et al., 2012; Girshick et al., 2014).


د) معماری شبکه عصبی همگشتی

تعیین معماری شبکه عصبی همگشتی از اهمیت بالایی برخوردار است. معماری‌های LeNet, AlexNet, ZFNet, VGGNet, GoogLeNet و ResNet از جمله معماری‌های مهم و تاثیرگذار در شبکه عصبی همگشتی هستند. در این بخش معماری‌های LeNet و AlexNet که جزو معماری‌های معروف شبکه عصبی همگشتی و مبنای ایجاد معماری شبکه عصبی همگشتی در این پژوهش است، بررسی شده است. معماری LeNet در سال ۱۹۹۸ طراحی شد. LeNet اولین معماری مبتنی بر همگشت بود که از الگوریتم پس‌انتشار برای آموزش شبکه استفاده نمود و برای دسته‌بندی اسناد دست نویس طراحی شده است. با وجود اینکه این معماری دقت خوبی داشت اما موفقیت چندانی کسب نکرد و تا چندین سال بعد از ارائه نیز ناشناخته بود (شکل ۲-۱۳). از مشکلات این معماری می‌توان به کمبود داده‌های برچسب‌دار، تکنولوژی ضعیف آن زمان و استفاده از تابع فعال‌ساز غیرخطی اشتباه اشاره نمود (LeCun et al., 1998).



شکل ۲-۱۳: شبکه عصبی همگشتی بر مبنای معماری LeNet (LeCun et al., 1998)

معماری AlexNet شبیه به LeNet است، با این تفاوت که شبکه عمیق تر و بزرگ تر شده و همچنین از ترکیب چندین لایه همگشت استفاده کرده است (شکل ۲-۱۴). در این معماری تابع فعال ساز برآورد تکانه تطبیقی و روش حذف تصادفی برای اولین بار استفاده شد (Krizhevsky et al., 2012).



شکل ۲-۱۴: شبکه عصبی همگشتی بر مبنای معماری AlexNet (Krizhevsky et al., 2012)

۲-۶- مروری بر مطالعات پیشین

در این بخش به منظور درک بهتر و ارائه کاربرد روش‌های ارائه شده در بخش‌های قبل، مطالعات پیشین در ارتباط با استخراج خودکار خطواره‌ها، بارزسازی دگرسانی‌ها با الگوریتم عملگرهای منطقی، تشخیص آنومالی ژئوشیمیایی با روش زونالیت و کاربرد یادگیری عمیق در اکتشافات ژئوشیمیایی، بررسی شده است.

۲-۶-۱- مطالعات انجام شده در استخراج خودکار خطواره‌ها

چراغی و همکاران (۱۳۹۴)، خطواره‌های مرتبط با حوضه آبریز منطقه خرم‌آباد را به دو صورت دستی و خودکار استخراج کردند. در ابتدا روش تحلیل مولفه‌های اصلی را بر روی تصاویر استر اعمال کردند و PC1 که شامل بیشترین اطلاعات بود را برای فیلترگذاری جهت‌دار انتخاب کردند. خطواره‌ها به صورت خودکار به وسیله نرم‌افزار PCI Geomatica استخراج شده است و تطابق نقشه تراکم خطواره‌ها با نقشه ریخت‌شناسی منطقه مورد مطالعه نشان می‌دهد که علاوه بر رخنمون سازندها، تمامی عوارض سطحی مانند خطواره‌ها جهت یافتگی داشته و متاثر از ساختارهای زمین‌شناسی هستند. براساس نتایج این پژوهش خطواره‌ها از مورفولوژی منطقه که متاثر از ساختارهای زمین‌شناسی است تبعیت می‌نمایند (چراغی و همکاران، ۱۳۹۴).

ادیری و همکاران (۲۰۱۷)، با استفاده از تصاویر ماهواره‌های سنتینل ۱^۱ و لندست ۸^۲ و سنجنده استر و اعمال روش تحلیل مولفه‌های اصلی، خطواره‌های منطقه سی‌دی فلاح-بوشکور اینلیر در مراکش را به صورت خودکار استخراج کردند. خطواره‌های بدست آمده از هر تصویر با نقشه زمین‌شناسی، واحدهای سنگی، داده‌های ارتفاعی، تراکم و جهت گسل‌های بدست آمده از بررسی میدانی مقایسه گردید و نتایج نشان‌دهنده این است که خطواره‌های بدست آمده از تصاویر استر عمدتاً مرزهای بین واحدهای سنگی را بارزسازی کرده و ماهواره Sentinel 1 به واسطه سنجنده راداری در استخراج خطواره‌ها عملکرد بهتری داشته است. همچنین خطواره‌های بدست آمده از سنجنده استر ساختار محلی منطقه مورد مطالعه را به خوبی بارزسازی کرده است. لازم به ذکر است در این پژوهش مقادیر بهینه‌ای برای پارامترهای نرم‌افزار PCI Geomatica در منطقه مورد مطالعه معرفی گردید ولی این مقادیر قابل تعمیم به دیگر مناطق نیز می‌باشد (Adiri et al., 2017).

محمدپور و همکاران (۱۳۹۸)، با استفاده از تصاویر استر و اعمال روش تحلیل مولفه‌های اصلی، PC1 را جهت استخراج خطواره‌های برگه ۱:۱۰۰۰۰۰ جبال بارز انتخاب کرده‌اند. در این پژوهش برای بهبود تشخیص لبه الگوریتم Canny و برای آشکارسازی خطواره‌ها تبدیل هاف انجام شده است. پس از بارزسازی خطواره‌ها، گسل‌های نهایی مرتبط با کانی‌زایی شناسایی شدند. با توجه به نتایج بدست آمده، ۷۷ درصد از اندیس‌های معدنی در نواحی با چگالی بالای گسل‌های بدست آمده قرار گرفته و این گسل‌ها ۶۳ درصد همپوشانی با گسل‌های نقشه زمین‌شناسی محدوده داشتند (محمدپور و همکاران، ۱۳۹۸).

همیمی و همکاران (۲۰۲۰)، از تصاویر ماهواره لندست ۸ و سنجنده استر برای بررسی ساختارهای زمین‌شناسی و سنگ‌شناسی زون برشی آتالا در مراکش استفاده کردند. در این پژوهش مدل ارتفاعی بدست آمده از مکان‌نگاری شاتل‌دار^۳ جهت اعمال فیلتر جهت‌دار و استخراج خودکار خطواره‌ها در نرم‌افزار PCI Geomatica استفاده شده است. استخراج خطواره‌ها یک برآورد کلی از توزیع و تراکم روند ساختاری زمین‌شناسی را در منطقه مورد مطالعه ارائه و منطقه از نظر ساختاری به چهار بخش تقسیم می‌کند. همچنین نتایج بدست آمده به وسیله بررسی میدانی و کانی‌شناسی تایید شدند (Hamimi et al., 2020).

¹ Sentinel 1 satellite

² Landsat 8 satellite

³ Shuttle Radar Topography Mission

۲-۶-۲- مطالعات انجام شده در بارزسازی دگرسانی‌ها با الگوریتم عملگرهای منطقی

محبی و همکاران (۱۳۹۲)، عوامل کنترل‌کننده کانی‌زایی مس پورفیری را در محدوده کوه هنزا بررسی کردند. در این پژوهش الگوریتم عملگرهای منطقی برای بارزسازی مناطق دگرسانی آرژیلیک و فیلیک و ماسک کردن مناطق پوشش گیاهی استفاده شد. همچنین مناطق دگرسانی آرژیلیک و فیلیک به وسیله روش نقشه‌بردار زاویه طیفی بارزسازی شدند. با توجه به نتایج بدست آمده، مناطق دگرسانی از دو روش به وسیله نقاط معدنی تایید شدند و مناطقی که در آن هر دو روش الگوریتم عملگرهای منطقی و نقشه‌بردار زاویه طیفی یکدیگر را تایید کنند، بیشترین احتمال کانی‌زایی مس پورفیری را دارند (محبی و همکاران، ۱۳۹۲).

اخیانی و همکاران (۱۳۹۳)، به وسیله روش‌های مختلف مانند ترکیب رنگی کاذب، عملگرهای منطقی و روش نقشه‌بردار زاویه طیفی بر روی داده‌های استر مناطق دگرسانی آرژیلیک پیشرفته، آرژلیک متوسط، فیلیک و پروپیلیتیک در منطقه آتشفشانی نفوذی ترو-چاه شیرین پرداختند. سپس نتایج بدست آمده را با نقشه زمین‌شناسی، مشاهدات میدانی و آنالیز کانی‌شناسی مقایسه کرده و برای ارزیابی صحت روش‌های یادشده از ماتریس خطا و ضریب کاپا استفاده کردند. با توجه به نتایج این پژوهش، روش‌های الگوریتم عملگرهای منطقی و نقشه‌بردار زاویه طیفی دقت بالایی برای بارزسازی مناطق دگرسانی دارند (اخیانی و همکاران، ۱۳۹۳).

معصومی و رنجبر (۱۳۹۶)، به وسیله تصاویر استر و الگوریتم عملگرهای منطقی مناطق دگرسانی غنی از سیلیس، پروپیلیتیک، آرژیلیک و فیلیک را در منطقه‌ای از برگه زمین‌شناسی پاریز بارزسازی کردند. این منطقه حاوی کانسارهای مس متعددی است. در این پژوهش مقادیر حدآستانه مورد استفاده در عملگرها بر اساس مطالعات زمین‌شناسی، آزمایشگاهی و بررسی آماری تعیین گردید. همچنین نتایج بدست آمده به وسیله بررسی نقشه زمین‌شناسی، نمونه‌برداری و مشاهدات صحرایی تایید شدند (معصومی و رنجبر، ۱۳۹۶).

ژنگ و ژو (۲۰۱۷)، به منظور شناسایی مناطق کانی‌سازی مس پورفیری از روش‌های الگوریتم عملگرهای منطقی و تحلیل مولفه‌های اصلی برای بارزسازی مناطق دگرسانی‌های آرژیلیک، فیلیک و پروپیلیتیک در منطقه بائوگوتو در چین که شامل کانسارهای معدنی است، استفاده کردند. همچنین برای مقایسه، کانی‌های مرتبط با دگرسانی‌ها به وسیله روش‌های فیلترگذاری انطباقی^۱ و کمینه‌ساز انرژی مقید^۲

^۱ Mixture-Tuned Matched-Filtering

^۲ Constrained Energy Minimization

بارزسازی شده است. مناطق بارزسازی شده از طریق مشاهده میدانی، طیف سنجی و مطالعات سنگ‌شناسی تایید شد. با توجه به نتایج بدست آمده، مناطق معرفی شده برای ادامه عملیات اکتشافی ارزشمند هستند (Zhang and Zhou, 2017).

۲-۶-۳- مطالعات انجام شده در تشخیص آنومالی ژئوشیمیایی با روش زونالیت

ضیائی و همکاران (۲۰۱۱)، بر روی بخشی از نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ منطقه جبال بارز که شامل ذخایر معدنی شهر بابک، کانسارهای مس پورفیری میدوک و سرچشمه است، بررسی ژئوشیمی معادن را انجام دادند. در این پژوهش ۳۰۰ نمونه رسوبات آبراهه‌ای برای بررسی عناصر Cu, Zn, Ag, Pb, Au, W, As, Hg, Ba, Bi و Mo مورد بررسی قرار گرفت. عناصر سرب و روی به عنوان فوق کانسار و عناصر مس و نقره به عنوان تحت کانسار معرفی شدند و از شاخص زونالیت $Pb \times Zn / Cu \times Ag$ برای شناسایی کانی‌سازی پنهان استفاده شد. به وسیله روش وزن‌های نشانگر لایه‌های ژئوشیمی بدست آمده از روش زونالیت، گسل‌ها و خطواره‌ها، واحدهای سنگی، دگرسانی، ساختار زمین‌شناسی و ۱۵ منطقه اندیس و کانسار مس پورفیری تلفیق شده و نقشه پتانسیل مطلوب کانی‌زایی بدست آمده است. برای مقایسه، این روش با لایه ژئوشیمی عنصر مس نیز تکرار شد. بر اساس نتایج این پژوهش، مدل بدست آمده مبتنی بر روش زونالیت عملکرد بهتری در تهیه نقشه پتانسیل و شناسایی کانی‌سازی پنهان نسبت به مدل مبتنی بر عنصر مس دارد (Ziaii et al., 2011).

همدانی و همکاران (۲۰۱۲)، به بررسی ذخیره سرب، روی و نقره بروکن‌هیل در استرالیا پرداخت. مطالعات ژئوشیمیایی را بر روی ۴ مقطع عرضی، ۲ مقطع محوری و ۲ مقطع طولی از کانسار انجام داد و تغییرات غلظت عناصر، کانی‌شناسی، بافت و سنگ‌شناسی را در این مقاطع بررسی کرد. در این پژوهش ۷۷ حفاری با فواصل یک متر برداشت شد و عناصر Sb, Pb, Zn, As, Ag, Cu, Fe, Cd, S, Bi بررسی شدند. سپس با بررسی تغییرات عمقی، ده عنصر را به عنوان عناصر معرف انتخاب کرد که عناصر Pb, Zn, Cd و S را به عنوان عناصر فوق کانسار و Ar, Bi, Cu و Ag را به عنوان عناصر تحت کانسار معرفی کرد. با توجه به نتایج بدست آمده، نسبت ضربی عناصر تحت کانسار به فوق کانسار $(Ag \times Cu \times Bi / S \times Pb \times Zn)$ شاخص مناسبی برای شناسایی ذخیره در عمق و بررسی موقعیت سطح از فرسایش است (Hamedani et al., 2012).

لیو و همکاران (۲۰۱۴)، کانسار مس اسکارن آنهوی در چین را با عمق ۸۰۰ متر از سطح زمین، بررسی ژئوشیمیایی کردند. به منظور بررسی تغییرات غلظت عناصر، نمونه‌برداری در عمق‌های مختلف در مقطع‌های عرضی و قائم مورد بررسی قرار گرفتند. علاوه بر نمونه‌برداری سطحی به صورت شبکه‌بندی منظم ۲۰۰ در ۵۰ متر، تعداد ۳۰۸ مغزه از ۵ گمانه برداشت کردند. با توجه به نتایج بدست آمده، غلظت مس و نقره از عمق ۲۰۰ متر از سطح زمین، به سمت ماده‌معدنی افزایش و غلظت سرب و آرسنیک نسبت به عمق، کاهش یافته است. دو شاخص برای شناسایی ذخیره در عمق معرفی شد که با نزدیک شدن به ماده معدنی شاخص As/Te کاهش و شاخص Cu/As افزایش می‌یابد (Liu et al., 2014).

هراز و همدی (۲۰۱۵)، به منظور ارائه یک مدل ژئوشیمیایی برای کانسار طلای آتود در مصر، به بررسی هاله‌های اولیه پرداختند. تعداد ۲۸۰ نمونه از سطح و سه افق مختلف برداشت شد و غلظت ۱۱ عنصر $Au, U, Ag, Cu, S, Pb, As, Ba, Zn, Ba$ و Co بررسی شد. در این پژوهش به وسیله روش زونالیت زون‌بندی محوری و عرضی، عناصر در هاله‌ها مشخص شد. عناصر سرب و مس به عنوان عناصر فوق کانسار و اورانیوم و روی به عنوان عناصر تحت کانسار معرفی شدند. همچنین آنالیز فاکتوری را در منطقه بررسی کردند که ۷ فاکتور شناسایی شد. فاکتور اول و دوم به ترتیب با عناصر (U, S, Zn, Co) و $(Ag, Zn, Co, Au, U, As, S)$ در ارتباط با کانی‌سازی و کنترل کننده ماده‌معدنی است. با توجه به نتایج بدست آمده از این پژوهش، شاخص $Pb \times Cu / U \times Zn$ بیشترین تغییرات را از سطح به عمق نشان داد و به عنوان بهترین شاخص برای تشخیص ذخایر پنهان مشابه با این نوع کانی‌سازی معرفی شد (Harraz and Hamdy, 2015).

امامعلی‌پور و همکاران (۲۰۱۹)، به بررسی هاله‌های ژئوشیمیایی برای تخمین سطح از فرسایش در چشم‌انداز معدنی جیوه طوره در ایران پرداختند. از ویژگی‌های مهم منطقه مورد مطالعه، وجود یک سیستم دگرسانی و کانی‌زایی است که به وسیله ساختارهای زمین‌شناسی و زون‌های برشی کنترل می‌شود. در این پژوهش تعداد ۶۴ نمونه سنگی از ۱۳ پروفیل در یک شبکه نمونه‌برداری منظم به فواصل ۳۰ در ۵۰ متر برداشت شد و غلظت عناصر $Hg, As, Sb, Ag, Cu, Co, Ni, Pb, Zn, Ba, Mo, Bi$ و Au را اندازه‌گیری کردند. با بررسی تغییرات عمقی، عناصر آرسنیک، آنتیموان و نقره به عنوان فوق کانسار و عناصر کبالت، مس، نیکل، سرب و روی به عنوان تحت کانسار معرفی شده است. دو شاخص زونالیت $As \times Sb \times Ag / Cu \times Co \times Ni$

و $Sb \times As/Pb \times Zn$ برای تعیین سطح از فرسایش استفاده شد. برای تعیین سطح از فرسایش، شاخص زونالیتة منطقه مورد مطالعه با یک ذخیره استاندارد که از لحاظ کانی‌سازی شباهت دارد، مقایسه شد. این شاخص‌ها در کانسار اولگائوک بررسی شد که برای شاخص اول مقادیر بیشتر از ۰/۰۰۱ و برای شاخص دوم مقادیر بیشتر از یک، معرف کانی‌سازی پنهان است. میانگین مقدار شاخص زونالیتة اول و دوم در منطقه مورد مطالعه به ترتیب برابر ۰/۰۰۰۱۹۸ و ۳/۷۶ است که مقدار شاخص زونالیتة اول در مقایسه با کانسار اولگائوک، کم‌تر از سطح فوقانی کانسار و بیشتر از سطح تحتانی کانسار است و برای شاخص زونالیتة دوم نشان‌دهنده سطحی بالاتر از فوق کانسار در مقایسه با کانسار اولگائوک است. همچنین انتظار می‌رود با افزایش عمق، مقادیر این شاخص‌ها کاهش یابد (Imamalipour et al., 2019).

ضیائی و همکاران (۲۰۱۹)، با ترکیب روش زونالیتة و گرادیان غلظت^۱، روشی جدید برای شناسایی کانی‌سازی پنهان در منطقه کرور در بخشی از جبال بارز ارائه دادند. منطقه مورد مطالعه به ۴ زون تقسیم شد در این مناطق ۹۳۲ نمونه در شبکه سطحی برای اندازه‌گیری غلظت عناصر $Cu, Zn, Ag, Pb, Au, W, As$ و Hg, Ba برداشت شد. علاوه بر نمونه‌برداری سطحی در زون ۲ محدوده مورد مطالعه، ۱۲۵۳ نمونه از ۶ گمانه اکتشافی برداشت شد. برای بررسی روش گرادیان غلظت شاخص ضربی عناصر فوق کانسار و عناصر تحت کانسار انتخاب شد که در آن عناصر سرب و روی معرف فوق کانسار و عناصر مس و نقره معرف تحت کانسار است. با توجه به نتایج بدست آمده، مقدار شاخص زونالیتة بزرگ‌تر از یک معرف کانی‌سازی پنهان و مقادیر کوچک‌تر از یک بیانگر کانی‌سازی پراکنده است (Ziaii et al., 2019).

علی‌یاری و همکاران (۲۰۲۰)، با استفاده از شاخص زونالیتة و مدل فرکتال، شاخص جدیدی برای کانسارهای مس پورفیری-مولیبدن در کمربند ماگمایی کرمان ارائه کردند. تعداد ۵۲۲ نمونه خاک درجا و ۹۱ نمونه سنگ برداشت شده در شبکه‌بندی منظم ۱۰۰ در ۱۰۰ متر برای ۴۴ عنصر مرتبط با مس پورفیری مورد بررسی قرار گرفت. در این پژوهش پس از ۳ مرحله آنالیز فاکتوری، فاکتورهای $F1-3$ و $F2-3$ استخراج شد که فاکتور اول شامل Pb, Zn, Au, Ag, Mn, Cd و As و فاکتور دوم شامل $Cu-Mo$ است. بر اساس فاکتورها، نسبت $F1 - 3/F2 - 3$ به عنوان یک شاخص زونالیتة توسعه یافته معرفی شد. همچنین شاخص زونالیتة

¹ Concentration gradient

متداول نیز به وسیله $Pb \times Zn/Cu \times Mo$ محاسبه شد. در انتها شاخص‌های زونالیت به وسیله مدل فرکتال تعداد-اندازه طبقه‌بندی شدند. مناطق اصلی آنومالی بدست آمده تطابق خوبی با واحدهای آتشفشانی، نمونه‌های کانسنگ معدنی و گمانه‌های اکتشافی دارد (Aliyari et al., 2020).

۲-۶-۴- مطالعات انجام شده در کاربرد یادگیری عمیق در اکتشاف ژئوشیمیایی

ژیانگ و زو (۲۰۱۶)، برای شناسایی ذخایر پلی‌متال آهن از خودرمزنگار عمیق جهت بارزسازی آنومالی ژئوشیمیایی فوجیان در چین که زمین‌شناسی پیچیده‌ای دارد، استفاده کردند. در این پژوهش خودرمزنگار عمیق برای رمزنگاری و بازنمایی داده‌های ژئوشیمیایی با توزیع احتمال چند متغیره پیچیده ناشناخته، آموزش داده شده است. معماری خودرمزنگار عمیق از سه بخش تشکیل شده است. ابتدا ماشین‌های بولتزمن محدود پیوسته^۱، به ترتیب برای وزن‌های اولیه شبکه آموزش داده می‌شود و سپس برای ایجاد خودرمزنگار عمیق تفکیک می‌شود. در انتها کل شبکه عمیق از طریق تنظیم دقیق آموزش داده شده است. پارامترهای شبکه بر اساس کاهش خطا تنظیم شده است و خطای بازنمایی یا امتیاز آنومالی، شاخص مفیدی برای شناسایی آنومالی‌های ژئوشیمیایی چند متغیره در ارتباط با کانی‌سازی پلی‌متال آهن است. همچنین نتایج بدست آمده از خودرمزنگار عمیق با ماشین‌های بولتزمن محدود پیوسته مقایسه شد و هر دو نتایج مشابه داشتند. مناطق کانسار آهن نوع اسکارن تطابق خوبی با نقشه آنومالی بدست آمده دارد که نشان از ارتباط بین مناطق آنومالی با کانی‌سازی آهن است (Xiong and Zuo, 2016).

چن و همکاران (۲۰۱۹)، به منظور شناسایی آنومالی‌های ژئوشیمیایی مرتبط با ذخایر آهن منطقه فوجیان در چین از یک رویکرد جدید در خودرمزنگار مبتنی بر ناهمگنی فضایی زمینه به نام رویکرد چندگانه خودرمزنگار فضایی محدود کننده^۲ استفاده کرد. در شناسایی آنومالی ژئوشیمیایی چند متغیره، مقدار زمینه باعث کاهش قابلیت مدل در شناسایی الگوهای ژئوشیمیایی چند متغیره غیرخطی و جداسازی آنومالی از زمینه می‌شود. همچنین برای بررسی ناهمگنی فضایی زمینه ژئوشیمیایی، منطقه مورد مطالعه به وسیله روش کا- میانگین، فیلتر فضایی و ادغام فضایی به چند قسمت تقسیم شد که از لحاظ الگوی زمینه با هم تطابق دارند.

¹ Restricted Boltzmann Machines (RBM)

² Spatially Constrained Multi-Autoencoder (SCMA)

سپس خودرمنگار در هر کدام از این بخش‌ها اجرا شده تا اثر زمینه حذف و اثرات وزن‌های ابتدایی شروع شبکه کاهش یابد. امتیاز آنومالی به عنوان معیاری برای شناسایی مناطق آنومال، از فاصله اقلیدسی بین ویژگی‌های ژئوشیمیایی اصلی و بارزسازی شده محاسبه شده است. با توجه به نتایج بدست آمده، روش معرفی شده عملکرد و دقت بهتری در تشخیص مناطق کانی‌سازی آهن در مقایسه با روش‌های دیگر در منطقه مورد مطالعه داشته است (Chen et al., 2019a).

چن و همکاران (۲۰۱۹)، به منظور شناسایی مناطق با اهمیت کانی‌سازی آهن منطقه فوجیان در چین از شبکه خودرمنگار چندگانه پیچشی^۱ استفاده کردند. بدین منظور از ویژگی‌های ساختاری و فضایی به عنوان یک مولفه اصلی برای تشخیص زمینه در منطقه مورد مطالعه استفاده کردند که منجر به ارائه یک مفهوم و روش جدید در شناسایی آنومالی ژئوشیمیایی شد. این شبکه ترکیبی از خودرمنگار چندگانه^۲ و شبکه عصبی همگشتی است که آموزش آن در سه مرحله انجام می‌شود. در ابتدا فرآیند موسوم به سفیدکاری که در آن همبستگی بین عناصر ژئوشیمیایی به حداقل رسیده و تاثیر زمینه حداقل می‌شود. به دلیل اینکه انتخاب اندازه پنجره در شبکه همگشتی یکی از مسائل دشوار این شبکه است، برای رفع آن از شاخص Moran's I برای تشخیص ساختار فضایی در شبکه استفاده شد. در انتها یک خودرمنگار چندگانه پیچشی برای یادگیری الگوهای ساختاری و فضایی و همچنین تشخیص زمینه برای هر عنصر ایجاد شد. در این پژوهش این روش به وسیله بررسی نمونه‌های ژئوشیمیایی آبراهه‌ای برای عناصر Cu, Mg, Pb, Zn و Fe₂O₃ استفاده شده است و به وسیله امتیاز آنومالی، ویژگی‌های مفید بارزسازی شده است. با توجه به نتایج بدست آمده، شبکه خودرمنگار با دقت ۰/۸۹ و منطقه پیش‌بینی ۱۷ درصد بیشترین تطابق مکانی را با کانسارهای آهن شناخته شده در منطقه مورد مطالعه دارد (Chen et al., 2019b).

لوو و همکاران (۲۰۲۰)، برای استخراج ویژگی‌های مربوط به کانی‌سازی منطقه فوجیان در چین از خودرمنگار متغیر در توزیع عناصر ژئوشیمیایی استفاده کردند. ویژگی‌ها از عناصر Fe₂O₃ و Zn, Mn, Pb, Cu که مرتبط با کانی‌سازی است استخراج شدند. سپس این ویژگی‌ها با یکدیگر ادغام و نقشه آنومالی منطقه بر اساس داده‌های ژئوشیمیایی حاصل شد. مناطق آنومال بدست آمده همبستگی خوبی با کانسارهای پلی‌متال

¹ Multi-Convolutional Autoencoder (MCA)

² Multi-Autoencoder (MAE)

آهن دارد. بر اساس نتایج بدست آمده، روش خودرمننگار متغیر در شناسایی آنومالی‌ها در مقایسه با خودرمننگار عمیق که در مطالعات گذشته در منطقه استفاده شده است، عملکرد بهتری دارد و مناطقی که خودرمننگار عمیق در شناسایی آن‌ها ناتوان است را به خوبی شناسایی کرده است (Luo et al., 2020).

لی و همکاران (۲۰۲۰)، روشی مبتنی بر شبکه عصبی همگشتی و یادگیری انتقالی را بر اساس نقشه-های ژئوشیمیایی به منظور ارائه یک مدل برای شناسایی دقیق کانسارهای شناخته شده و پتانسیل‌یابی طلا در منطقه ژانگ بالینگ-گواندیان در چین که شامل چندین کانسار و اندیس طلا-مس است، ارائه کردند. در این روش با ترکیب ویژگی‌های فضایی و ساختاری، زون‌بندی آنومالی‌های ژئوشیمیایی چند متغیره و هاله‌ها، تاثیر مناطق کانسارها، اندیس‌ها و معادن در شبکه کاهش می‌یابد که باعث همگرایی و بهبود مدل و دقت بالاتر در نقشه پتانسیل می‌شود. افزودن عناصر بیشتر به مجموعه آموزش، اثر بخشی شناسایی آنومالی ژئوشیمیایی را بهبود می‌بخشد. بر اساس نتایج ارائه شده، دقت شبکه بیش از ۹۹ درصد و مقدار خطا کمتر از ۰/۱ است و ۸۸ درصد از کانسارها و اندیس‌ها در نقشه بدست آمده جزو مناطق با آنومالی بالا شناسایی شده است. همچنین چندین بخش از منطقه مورد مطالعه برای بررسی اکتشافی بیشتر برای عناصر مس و طلا معرفی شده است (Li et al., 2020).

ژنگ و همکاران (۲۰۲۱)، به بررسی علم داده، شبکه‌های خودرمننگار همگشتی و شبکه عصبی همگشتی برای چندین اطلاعات زمین‌شناسی با ویژگی‌های یکسان در منطقه هزو-میوو در چین پرداختند. بدین منظور ۹۰۴۱ نمونه رسوبات آبراهه‌ای برای عناصر W, Au, As, Sb, Hg, Ba, Co, Pb, Mo, Zn, Ag و تحت بررسی تکنیکی و تحلیل مولفه‌های اصلی قرار گرفتند که عناصر Sb, Cu, Au, As و Ag ارتباط خوبی با کانی‌سازی در منطقه مورد مطالعه داشتند. در ابتدا دو شبکه خودرمننگار همگشتی برای تشخیص تکه‌های تصاویر زمین مرجع شده (فاصله تا گسل و سنگ‌های نفوذی، شاخص تکنیکی Sb, Cu, Au, As و Ag، مولفه‌های اول و دوم بدست آمده از روش تحلیل مولفه‌های اصلی) به وسیله ۹ لایه ساخته شد که دارای خطای بازنمایی بالایی بودند که مرتبط با کانی‌سازی هستند. برای بهینه بودن پارامترهای شبکه، خودرمننگار همگشتی با معماری و تعداد دوره‌های آموزش متفاوت بررسی شد. همچنین برای قابل اطمینان بودن نتایج، ترکیبی از نقشه‌های شاهد کانی‌سازی استفاده شد. با توجه به نتایج بدست آمده از خودرمننگار همگشتی،

مناطق با خطای بارزسازی بالا و کم به ترتیب معرف آنومالی و زمینه است. نتایج بدست آمده از خودرمنزگار همگشتی در شبکه عصبی همگشتی نیز استفاده شد و نتایج بدست آمده از شبکه عصبی همگشتی همبستگی مکانی قوی با ذخایر شناخته شده طلا در منطقه مورد مطالعه نشان داده است. با توجه به عملکرد روش استفاده شده در این پژوهش، نویسندگان این روش را یک رویکرد بالقوه برای نقشه‌برداری از مناطق با پتانسیل معدنی معرفی کردند (Zhang et al., 2021a).

ژنگ و همکاران (۲۰۲۱)، تعداد زیادی نمونه آموزشی برای استفاده در الگوریتم‌های یادگیری ماشین به خصوص یادگیری عمیق برای داده‌های ژئوشیمیایی منطقه فوجیان در چین ایجاد کردند. کانی‌سازی یک رویداد زمین‌شناسی نادر است که منجر به کمبود نمونه‌های آموزش می‌شود. به همین دلیل تعداد کمی الگوریتم‌های نظارت شده یادگیری ماشین در پتانسیل‌یابی و بررسی ژئوشیمیایی استفاده شده است. در این پژوهش برای تشخیص آنومالی‌های ژئوشیمیایی چند متغیره در ارتباط با کانی‌سازی از یک روش جدید حاصل از ترکیب شبکه عصبی پیچشی عمیق^۱ با ویژگی پیکسل‌ها استفاده شد. در ابتدا به وسیله ویژگی پیکسل‌ها، داده‌های برچسب‌دار کافی برای آموزش شبکه ایجاد شد. سپس شبکه عصبی همگشتی را با ۱۵ لایه ایجاد و با داده‌های بدست آمده از مرحله قبل برای تشخیص آنومالی‌های ژئوشیمیایی آموزش دادند. با توجه به نتایج بدست آمده، نقشه آنومالی‌های ژئوشیمیایی، ارتباط مکانی نزدیکی با ذخایر معدنی شناخته شده دارد که نشان دهنده کاربرد الگوریتم‌های نظارت شده در تشخیص آنومالی‌های ژئوشیمیایی و پتانسیل‌یابی مواد معدنی است (Zhang et al., 2021b).

¹ Deep Convolutional Neural Network

فصل سوم

بررسی زمین‌شناسی و دورسنجی مناطق مورد مطالعه

۳-۱- مقدمه

در این پژوهش الگوی مورد نظر با بررسی مناطق سونگون و آستامال ارائه شده است. کمر بند ارومیه- دختر مهم‌ترین کمر بند فلزای ایران است و تعداد زیادی کانسار مس پورفیری در آن وجود دارد. زون ماگمایی ارومیه دختر از لحاظ کانی‌سازی مس پورفیری به سه بخش کمر بند مس پورفیری اهر-ارسباران، کمر بند مس پورفیری ساوه-یزد و کمر بند مس پورفیری کرمان تقسیم می‌شود. مناطق سونگون و آستامال در کمر بند مس پورفیری اهر-ارسباران قرار دارند. این کمر بند یکی از پرمپتانسیل‌ترین مناطق ایران برای اکتشاف کانسارهای مس-مولیبدن و مس-طلا پورفیری است (Zürcher et al., 2019).


در این فصل ابتدا زمین‌شناسی و دورسنجی شامل استخراج خطواره‌ها و بازسازی کانی‌سازی آهن و دگرسانی‌ها و سپس نمونه‌برداری در شبکه سطحی و عمقی در مناطق سونگون و آستامال بررسی شده است. در انتها پیشینه‌ای از مطالعات انجام شده در مناطق سونگون و آستامال که در تشخیص کانی‌سازی پنهان بوده، بررسی شده است.

۳-۲- زمین‌شناسی و دورسنجی در مناطق مورد مطالعه

مناطق سونگون و آستامال به عنوان دو منطقه چالش بر انگیز برای بررسی موضوع پژوهش انتخاب شده است. در این بخش ابتدا ویژگی‌های عمومی زمین‌شناسی این دو منطقه معرفی شده و سپس به منظور بررسی مطالعات زمین‌شناسی و دگرسانی در مناطق مورد مطالعه، خطواره‌ها و دگرسانی‌ها به وسیله دورسنجی در هر کدام از این مناطق بارزسازی شده است.

۳-۲-۱- منطقه آستامال


منطقه روستایی آستامال در ۷۰ کیلومتری شمال تبریز و ۲۵ کیلومتری شمال شرقی خاروانا قرار دارد. در شکل ۳-۱ موقعیت جغرافیایی و راه‌های دسترسی به منطقه آستامال نشان داده شده است. آستامال منطقه‌ای با توپوگرافی کوهستانی، دامنه‌های پرشیب و دره‌های عمیق است که قره‌گوزای بلندترین قله آن با ارتفاع ۲۶۰۰ متر است.



شکل ۳-۱: موقعیت جغرافیایی و راه‌های دسترسی به مناطق آستمال و سونگون

استخراج مس در این منطقه ریشه تاریخی دارد. در قسمت شمال غربی روستای آستمال، دو کنده‌کاری قدیمی در فاصله یک کیلومتر از یکدیگر و معدن گویران در ۳ کیلومتری از شمال روستا، گواهی بر کانی‌سازی مس در این منطقه است. در بخش‌های استخراج شده قدیمی، کربنات‌های مس با مقادیر اندکی از کانی‌سازی کالکوپیریت دیده می‌شود که درون آهک تکتونیزه رخ داده است. بررسی زمین‌شناسی، اکتشاف چکشی و ژئوشیمیایی در آستمال توسط مهندسين مشاور کانساران انجام و پیشنهادهایی برای کارهای آینده ارائه شد، ولی در تشخیص نقاط امیدبخش، نتایج خوبی نداشته است. سپس گریگوریان به همراه چند ژئوشیمیست به منظور شناسایی کانی‌سازی در آستمال، پژوهش‌های زونالیت‌ ژئوشیمیایی را انجام دادند و در انتها، این منطقه را عقیم از کانی‌سازی اعلام کردند (خوئی و همکاران، ۱۳۷۸).


شکل ۳-۲ نقشه زمین‌شناسی منطقه آستمال را نشان می‌دهد که قدیمی‌ترین رخنمون سنگ‌ها در این منطقه، واحدهای رسوبی-آتشفشانی کرتاسه است. به طور کلی این بخش به دو واحد تقسیم شده است. یک لایه تناوبی از مارن و ماسه‌سنگ به رنگ سبز زیتونی و گاه خاکستری با میان‌لایه‌های آهک مارنی که دایک‌هایی، آن‌ها را قطع می‌کنند. واحدهای دیگر شامل لایه‌های نازک و متوسط آهک است. بخش پایانی کرتاسه از نهشته‌های ولکانوسدیمتری به وجود آمده است که وابستگی آن‌ها به کرتاسه پیشین، با استناد به فسیل‌های یافت شده در آن انجام شده است.




شکل ۳-۲: نقشه زمین شناسی منطقه آستمال (Mehrpour et al, 1992)

۳-۲-۱-۱- استخراج خطواره‌ها در منطقه آستمال


به وسیله نرم‌افزار ENVI روش تحلیل مولفه‌های اصلی بر روی باندهای محدوده مرئی-مادون قرمز نزدیک تصویر استر اعمال شده است. در شکل ۳-۳ تصویر PC1 و نمودار بردار ویژه را در منطقه آستمال نشان داده شده است. فیلتر جهت‌دار در ۴ جهت با آزمون‌های ۰ (N-S)، ۴۵ (NE-SW)، ۹۰ (E-W) و ۱۳۵ (NW-SE) برای بارسازی عوارض بر روی تصویر PC1 اعمال شده (شکل ۳-۴) و سپس به وسیله نرم‌افزار PCI Geomatica و مقادیر پیشنهادی ادیری و همکاران (۲۰۱۷) برای پارامترهای مدل LINE، خطواره‌ها در هر کدام از جهات استخراج شده است. در انتها خطواره‌های بدست آمده در نرم‌افزار GIS ادغام شدند و بخش‌های تکراری و خطوط غیر زمین‌شناسی مانند رودخانه و جاده، حذف شده است. در شکل ۳-۵ پراکندگی خطواره‌ها بر روی تصویر ترکیب رنگی استر و جهت خطواره‌ها در منطقه آستمال نشان داده شده است. با توجه به تراکم و تقاطع خطواره‌ها در این منطقه، پتانسیل ساختاری برای کانی‌سازی در منطقه آستمال وجود دارد. همچنین جهت خطواره‌ها عموماً شمال شرقی-جنوب غربی است.



شکل ۳-۳: (الف) بردار ویژه روش تحلیل مولفه‌های اصلی بر روی باندهای محدوده مرئی-مادون قرمز نزدیک تصاویر استر؛ (ب) تصویر PC1 در منطقه آستمال




شکل ۳-۴: فیلتر جهت‌دار در ۴ جهت (الف) N-S، (ب) NE-SW، (ج) E-W و (د) NW-SE بر روی تصویر PC1 در منطقه آستمال



شکل ۳-۵: (الف) جهت خطواره‌ها؛ (ب) نقشه پراکندگی خطواره‌ها بر روی تصویر ترکیب رنگی استر در منطقه آستامال

۳-۲-۱-۲-۳- بارزسازی کانی‌سازی آهن و دگرسانی‌ها در منطقه آستامال

با توجه به زون‌های دگرسانی مس پورفیری وجود کانی‌سازی آهن در منطقه برای تشکیل مس پورفیری اهمیت بالایی دارد. به وسیله روش نسبت باندی بر روی باندهای محدوده مرئی-مادون قرمز نزدیک و محدوده مادون قرمز کوتاه تصویر استر و ماسک کردن مناطق پوشش گیاهی، مناطق حاوی آهن فریک ($B1/B2$)، آهن فروس ($B5/B3$) و اکسید آهن فریک ($B4/B3$) در منطقه آستامال بارزسازی شده است (شکل ۳-۶).




شکل ۳-۶: (الف) آهن فریک؛ (ب) آهن فروس؛ (ج) اکسید آهن فریک در منطقه آستامال

در شکل ۳-۷ مناطق دگرسانی غنی از سیلیس (هیدروسیلیکا، کلسدونی و اپال)، دگرسانی پروپیلیتیک در ارتباط با کانی‌های کربنات و کلریت-اپیدوت به صورت مجزا، دگرسانی آرژیلیک با حضور کانی‌های آلونیت-کائولینیت و دگرسانی فلیک با کانی‌های شاخص سرسیت-مسکویت را که به وسیله الگوریتم عملگرهای منطقی و باندهای محدوده مرئی-مادون قرمز نزدیک، محدوده مادون قرمز کوتاه و حرارتی بر روی تصویر استر بارزسازی شده است را در منطقه آستامال نشان داده شده است. لازم به ذکر است مارس (۲۰۱۳)، از تصاویر با سطح تصحیح متفاوت نسبت به تصاویر این پژوهش استفاده کرده و به منظور حذف پیکسل‌های سیاه از

عبارت $(b4 \text{ gt } 260)$ and در الگوریتم استفاده نموده است. در تصاویر مورد استفاده در این پژوهش، پیکسلی ارزش بالاتر از ۲۶۰ ندارد و وجود and در این الگوریتم باعث صفر شدن کل نتیجه می‌شود. بدین ترتیب عبارت $(b4 \text{ gt } 260)$ and از الگوریتم‌ها حذف شده است (جدول ۳-۱).

جدول ۳-۱: الگوریتم عملگرهای منطقی استفاده شده بر روی تصاویر استر برای بارزسازی دگرسانی‌ها در مناطق آستامال و سونگون

منطقه	دگرسانی هیدروترمال	الگوریتم
آستامال	مناطق گرمابی غنی از سیلیس (هیدروسیلیکا، کلسدونی و اپال)	$((\text{float}(b3)/b2) \text{ le } 4.52) \text{ and } ((\text{float}(b4)/b7) \text{ ge } 1.16) \text{ and } ((\text{float}(b13)/b12) \text{ ge } 1.08) \text{ and } ((\text{float}(b12)/b11) \text{ lt } 1.13)$
	پروپیلیتیک (کربنات)	$((\text{float}(b3)/b2) \text{ le } 4.52) \text{ and } ((\text{float}(b6)/b8) \text{ gt } 1.11) \text{ and } (b5 \text{ gt } b6) \text{ and } (b7 \text{ gt } b8) \text{ and } (b9 \text{ gt } b8) \text{ and } ((\text{float}(b13)/b14) \text{ gt } 1.13)$
	دگرسانی پروپیلیتیک (کلریت-اپیدوت)	$((\text{float}(b3)/b2) \text{ le } 4.52) \text{ and } ((\text{float}(b6)/b8) \text{ gt } 1.11) \text{ and } ((\text{float}(b5)/(\text{float}(b4)+b6)) \text{ gt } 0.57) \text{ and } (b5 \text{ gt } b6) \text{ and } (b6 \text{ gt } b7) \text{ and } (b7 \text{ gt } b8) \text{ and } (b9 \text{ gt } b8) \text{ and } ((\text{float}(b13)/b14) \text{ le } 1.13)$
	آرژلیک (آلونیت-کائولینیت)	$((\text{float}(b3)/b2) \text{ le } 3.19) \text{ and } ((\text{float}(b4)/b6) \text{ gt } 1.17) \text{ and } ((\text{float}(b5)/b6) \text{ le } 1.12) \text{ and } ((\text{float}(b7)/b6) \text{ ge } 1.1)$
	فیلیک (سرسیت-مسکویت)	$((\text{float}(b3)/b2) \text{ le } 3.19) \text{ and } ((\text{float}(b4)/b6) \text{ gt } 1.17) \text{ and } ((\text{float}(b5)/b6) \text{ gt } 1.12) \text{ and } ((\text{float}(b7)/b6) \text{ ge } 1.1)$
سونگون	مناطق گرمابی غنی از سیلیس (هیدروسیلیکا، کلسدونی و اپال)	$((\text{float}(b3)/b2) \text{ le } 6.34) \text{ and } ((\text{float}(b4)/b7) \text{ ge } 1.18) \text{ and } ((\text{float}(b13)/b12) \text{ ge } 1.1) \text{ and } ((\text{float}(b12)/b11) \text{ lt } 1.14)$
	پروپیلیتیک (کربنات)	$((\text{float}(b3)/b2) \text{ le } 6.34) \text{ and } ((\text{float}(b6)/b8) \text{ gt } 1.18) \text{ and } (b5 \text{ gt } b6) \text{ and } (b7 \text{ gt } b8) \text{ and } (b9 \text{ gt } b8) \text{ and } ((\text{float}(b13)/b14) \text{ gt } 1.06)$
	دگرسانی پروپیلیتیک (کلریت-اپیدوت)	$((\text{float}(b3)/b2) \text{ le } 6.34) \text{ and } ((\text{float}(b6)/b8) \text{ gt } 1.18) \text{ and } ((\text{float}(b5)/(\text{float}(b4)+b6)) \text{ gt } 0.55) \text{ and } (b5 \text{ gt } b6) \text{ and } (b6 \text{ gt } b7) \text{ and } (b7 \text{ gt } b8) \text{ and } (b9 \text{ gt } b8) \text{ and } ((\text{float}(b13)/b14) \text{ le } 1.06)$
	آرژلیک (آلونیت-کائولینیت)	$((\text{float}(b3)/b2) \text{ le } 2.91) \text{ and } ((\text{float}(b4)/b6) \text{ gt } 1.21) \text{ and } ((\text{float}(b5)/b6) \text{ le } 1.09) \text{ and } ((\text{float}(b7)/b6) \text{ ge } 1.09)$
	فیلیک (سرسیت-مسکویت)	$((\text{float}(b3)/b2) \text{ le } 2.91) \text{ and } ((\text{float}(b4)/b6) \text{ gt } 1.21) \text{ and } ((\text{float}(b5)/b6) \text{ gt } 1.09) \text{ and } ((\text{float}(b7)/b6) \text{ ge } 1.09)$
b: باند، float: اعداد اعشاری، le: کوچک‌تر یا مساوی، lt: کوچک‌تر، ge: بزرگ‌تر یا مساوی، gt: بزرگ‌تر		



شکل ۳-۷: دگرسانی‌های بارزسازی شده به وسیله الگوریتم عملگرهای منطقی بر روی تصاویر استر در منطقه آستمال

با توجه به مطالعات گذشته، دگرسانی‌های شناسایی شده در منطقه آستمال شامل دو نوع دگرسانی ناحیه‌ای و دگرسانی در محدوده کانسار است. دگرسانی در مقیاس ناحیه‌ای به صورت آلونیتی شدن است که از شمال غرب تا زنجان ادامه یافته است. در محدوده کانی‌سازی دگرسانی‌ها شامل پتاسیک، سریسیتی شدن، سریسیتی-کائولینیتی، آرژیلیک-کربناتی، آلونیتی شدن و پروپیلیتیک است. کانی‌سازی اولیه به صورت افشان شامل پیریت با تراکم بسیار متغیر و دانه‌های کالکوپیریت و پیروتیت است و کانی‌های ثانویه مس به ندرت دیده می‌شود (خوئی و همکاران، ۱۳۷۸).


۳-۲-۲- منطقه سونگون

منطقه روستایی و معدنی سونگون در استان آذربایجان شرقی، ۱۳۰ کیلومتری شمال تبریز، ۷۵ کیلومتری شمال غرب اهر و ۳۰ کیلومتری شمال ورزقان قرار دارد. این ناحیه معدنی در گستره‌ای به مختصات جغرافیایی $38^{\circ} 41' 43''$ تا $38^{\circ} 42' 45''$ شمالی و $46^{\circ} 41'$ تا $46^{\circ} 43'$ شرقی واقع شده است. با توجه به

شکل ۳-۱، مسیرهای دسترسی اصلی به معدن سونگون از طریق جاده آسفالت تبریز-ورزقان-سونگون و همچنین جاده تبریز-اهر-ورزقان-سونگون میسر است.

کانسار مس سونگون یک کانسار مس پورفیری مونزونیتی است و در کمربند تکتونیکی زون فرورانش حاشیه قاره‌ای با سن ترشیاری تشکیل شده است. در این منطقه در سه نوع کانی‌سازی اسکارن، کانی‌سازی در توده پورفیری و زون دگرسان سوپرژن قابل تفکیک است (خوئی و همکاران، ۱۳۷۸). سنگ‌های آتشفشانی منطقه سونگون از توف آندزیتی تا تراکیتی و آگلومرا تشکیل شده است و اثرات متاسوماتیسمی در سنگ درون‌گیر وجود دارد (Ziaii et al., 2009). منطقه سونگون شامل یک استوک دیوریت-گرانودیوریت تا کوارتز مونزونیت با سن میوسن است. توده‌های نفوذی این استوک شامل مونزونیت-کوارتز مونزونیت (قدیمی) در بخش غربی و دیوریت-گرانودیوریت (جدید) در بخش شرق است (شکل ۳-۸). همچنین ماگماتیسم در این منطقه منجر به جایگزینی دایک‌های آندزیتی حجیمی در بخش شرقی شده است (هزارخانی و همکاران، ۱۳۸۹). این عامل باعث شده است تا کانسار سونگون به عنوان یک کانسار مس-مولیبدن پورفیری-اسکارن در سطح جهانی شناخته شده باشد (Zürcher et al., 2019). دایک‌های تاخیری و توده‌های نفوذی سونگون شامل چهار دسته است که سرشت کالک آلکالن با پتاسیم بالا و شوشونیتی دارند (علوی و همکاران، ۱۳۹۳):


- ۱) دایک‌های نسل اول، ترکیبی در حد مونزونیت تا دیوریت پورفیری دارند.
- ۲) دایک‌های نسل دوم، ترکیبی گابرویدیوریتی و بافتی گرانولار دارد.
- ۳) دایک‌های نسل سوم، ترکیب دیوریتی با بافت میکرولیتی تا پورفیری دارد.
- ۴) دایک‌های نسل چهارم، از آپوفیزهای توده داسیتی حاشیه سونگون با بافت آفانتیک است.




شکل ۳-۸: نقشه زمین‌شناسی منطقه سونگون (Ziaii et al., 2009)

۳-۲-۱- استخراج خطواره‌ها در منطقه سونگون

در شکل ۳-۹ تصویر PC1 و نمودار بردار ویژه را در منطقه سونگون نشان داده شده است. تصویر PC1 برای اعمال فیلتر جهت‌دار در ۴ جهت با آزمون‌های ۰ (N-S)، ۴۵ (NE-SW)، ۹۰ (E-W) و ۱۳۵ (NW-SE) انتخاب شده (شکل ۳-۱۰) و به وسیله مدل LINE در PCI Geomatica و مقادیر پیشنهادی ادیری و همکاران (۲۰۱۷) برای پارامترهای این مدل، خطواره‌ها در هر کدام از جهات در منطقه سونگون استخراج شده است. سپس خطواره‌های بدست آمده در جهات مختلف، در نرم‌افزار GIS ادغام و بخش‌های اضافه حذف شده است. شکل ۳-۱۱ نقشه پراکندگی خطواره‌ها را بر روی تصویر ترکیب رنگی استر و جهت خطواره‌ها را در منطقه سونگون نشان می‌دهد. مشابه منطقه آستمال، در منطقه سونگون نیز جهت خطواره‌ها عموماً شمال شرقی-جنوب غربی است. تراکم و تقاطع خطواره‌ها در این منطقه نشان از پتانسیل ساختاری برای کانی‌سازی است.




شکل ۳-۹: (الف) بردار ویژه روش تحلیل مولفه‌های اصلی بر روی باندهای محدوده مرئی-مادون قرمز نزدیک تصاویر استر؛ (ب) تصویر PC1 در منطقه سونگون



شکل ۳-۱۰: فیلتر جهت‌دار در ۴ جهت (الف) N-S، (ب) NE-SW، (ج) E-W و (د) NW-SE بر روی تصویر PC1 در منطقه سونگون

سپس الگوریتم عملگرهای منطقی در جدول ۳-۱ بر روی باندهای محدوده مرئی-مادون قرمز نزدیک، محدوده مادون قرمز کوتاه و حرارتی تصویر استر اعمال و مناطق دگرسانی مرتبط با کانی‌سازی مس پورفیری بارزسازی شده است (شکل ۳-۱۳).



شکل ۳-۱۳: دگرسانی‌های بارزسازی شده به وسیله الگوریتم عملگرهای منطقی بر روی تصاویر استر در منطقه سونگون

با توجه به مطالعات گذشته، کانسار سونگون شامل دگرسانی‌های پتاسیک، پتاسیک-فیلیک، فیلیک، آرژیلیک و پروپیلیتیک است. کانی‌های موجود در این منطقه شامل سولفیدها (پیریت، کالکوپریت و مولیبدینیت)، کوارتز، کلسیت و انیدریت (به صورت ژپس) است. در سونگون کانه شاخص مس، کالکوپریت است و مولیبدینیت، بورنیت، کالکوسیت و تتراهدریت در مقادیر خیلی کم وجود دارند. کانی‌سازی هیپوژن مس نیز به طور عمده در طول دگرسانی پتاسیک و به میزان کم‌تر در طول دگرسانی فیلیک انجام شده است.

مولیبدنیت به طور عمده در بخش‌های ژرف استوک تشکیل شده و بیشتر در ارتباط با دگرسانی پتاسیک است (هزارخانی و همکاران، ۱۳۸۹).

در زون پتاسیک، تهی شدگی عناصر سدیم، کلسیم، منیزیم و آهن ولی غنی شدگی پتاسیم موجود دارد. این تغییرات مرتبط با جایگزینی پلاژیوکلاز و آمفیبول با بیوتیت و فلدسپات پتاسیم است. همچنین در کانسار سونگون، دگرسانی پتاسیک در مرکز سیستم پورفیری منطقه و زیر بخش فیلک قرار گرفته است. لازم به ذکر است وسعت مکانی زون فیلک بسیار گسترده است و دگرسانی هیپوژن غالب در منطقه است. زون فیلک در سونگون با حضور کانی‌های کوارتز ثانویه، سرسیت و پیریت و پتاسیم فلدسپار و آلبیت ثانویه شناخته می‌شود. در زون فیلک، کلسیت به مقدار فراوان و کلریت به مقدار کم یافت می‌شود. در طی دگرسانی فیلک، فلدسپارها به سرسیت و مقدار کمی رس دگرسان می‌شوند. به طور کلی دگرسانی فیلک تمام بخش‌های فوقانی و خارجی استوک پورفیری را پوشش داده و زون پروپیلیتیک را از زون پتاسیک جدا می‌کند (هزارخانی و همکاران، ۱۳۸۹؛ عباس‌زاده و همکاران، ۱۳۹۸).

۳-۳- نمونه‌برداری در مناطق مورد مطالعه

در این پژوهش از داده‌های ژئوشیمیایی عناصر Cu, Mo, Pb و Zn در بررسی کاربرد یادگیری عمیق در ژئوشیمی معادن استفاده شد. سپس نتایج بدست آمده به وسیله گمانه‌های حفاری شده در مناطق مورد مطالعه، اعتبارسنجی شدند. در ادامه نمونه‌برداری در شبکه سطحی و عمقی در مناطق مورد مطالعه بررسی شده است.

۳-۳-۱- نمونه‌برداری در منطقه آستامال

تعداد ۹۱۶ نمونه سنگی در یک شبکه نمونه‌برداری منظم در راستای شمال-جنوب، متشکل از ۱۹ پروفیل با فواصل ۱۰۰ متر و فاصله نمونه‌برداری ۴۰ متر در هر پروفیل برداشت شده است. این نمونه‌ها برای ۴ عنصر Cu, Mo, Pb و Zn به وسیله روش جذب اتمی در سازمان صنایع مس ایران آنالیز شده است. همچنین ۲ گمانه در منطقه آستامال تا عمق ۱۰۰ متر از سطح زمین حفر شده و از هر کدام ۱۰ نمونه با فواصل ۱۰

متری برداشت شده است. نمونه‌های گمانه‌ها توسط موسسه کانی‌شناسی، ژئوشیمی کریستالوگرافی عناصر کمیاب در روسیه، آنالیز ۳۶ عنصری با روش اسپکترومتری نشری انجام شده است (صفری، ۱۳۹۶).

۳-۳-۲- نمونه‌برداری در منطقه سونگون

تعداد ۸۴۲ نمونه سنگی به صورت شبکه منظم نمونه‌برداری در راستای شمال-جنوب به وسیله ۱۹ پروفیل با فواصل ۱۰۰ متر و فاصله نمونه‌برداری ۲۰ متر در هر پروفیل برداشت شده است. نمونه‌های برداشت شده برای عناصر مس، نقره، سرب، روی، مولیبدن، آنتیموان، آرسنیک و طلا توسط سازمان صنایع مس ایران و به وسیله روش جذب اتمی آنالیز شده است. سه گمانه به نام‌های ۶۶، ۶۹ و ۷۸ در منطقه سونگون به ترتیب تا عمق ۶۰۰ متر، ۵۰۰ متر و ۵۵۰ متر حفاری شده است که از هرکدام از گمانه‌ها به ترتیب تعداد ۶۰، ۴۴ و ۶۴ نمونه با فواصل ۱۰ متری برداشت شده است. آنالیز ۳۶ عنصری نمونه‌های برداشت شده از گمانه‌های در موسسه کانی‌شناسی، ژئوشیمی کریستالوگرافی عناصر کمیاب روسیه انجام شده است (صفری، ۱۳۹۶).

۳-۴- مطالعات انجام شده در تشخیص کانی‌سازی پنهان در مناطق سونگون

و آستامال

مطالعات انجام شده به منظور تشخیص کانی‌سازی پنهان در منطقه سونگون و آستامال به وسیله روش زونالیت‌شیمیایی انجام شده و به سال ۱۹۷۹ برمی‌گردد. گریگوریان در طی سال‌های ۱۹۷۹ تا ۱۹۹۳ به وسیله روش سنتی زونالیت‌ژئوشیمیایی به تشخیص کانی‌سازی پنهان در منطقه سونگون پرداخت. در طی این بررسی محدوده‌ای در جنوب شرقی این منطقه به عنوان کانی‌سازی پنهان اقتصادی معرفی شد که به نام سونگون ۱ شناخته می‌شود. همچنین گریگوریان (۱۹۹۴) به وسیله روش سنتی زونالیت‌ژئوشیمیایی به تشخیص کانی‌سازی پنهان در منطقه سونگون و آستامال پرداخت. لازم به ذکر است در سال ۱۹۹۲ منطقه غربی سونگون که به نام سونگون ۲ شناخته شده، به عنوان محل باطله انتخاب شده بود. مطالعات گریگوریان (۱۹۹۴) نشان داد که سونگون ۲ یک کانی‌سازی پنهان اقتصادی است که با توجه به کانی‌سازی پنهان در سونگون ۱، کل منطقه سونگون به عنوان کانسار بزرگ شامل کانی‌سازی پنهان اقتصادی معرفی شد. همچنین گریگوریان منطقه آستامال را که از لحاظ زمین‌شناسی مشابه منطقه سونگون بوده ولی دگرسانی‌ها در آن از وسعت و

شدت بیشتری برخوردار است، به وسیله روش سنتی زونالیتة ژئوشیمیایی به عنوان کانی‌سازی پراکنده غیراقتصادی معرفی کرد (Ziaii, 1996; Garigorian, 1994).

روش سنتی زونالیتة ژئوشیمیایی نقش مهمی در تشخیص کانی‌سازی پنهان در منطقه سونگون و آستامال داشته است اما این روش در تفکیک زمینه از آنومالی و تعیین سطوح مختلف آنومالی محدودیت‌هایی داشته است. به منظور مرتفع نمودن این مشکلات، ضیائی و همکاران (۲۰۰۹) به بررسی کانی‌سازی پنهان در منطقه سونگون و آستامال پرداختند. بدین ترتیب به منظور تشخیص کانی‌سازی پنهان، منطقه سونگون که شامل سونگون ۱ و سونگون ۲ است را به روش سنتی زونالیتة ژئوشیمیایی و سونگون ۳ که در جنوب غربی سونگون ۲ و خارج از محدوده مورد مطالعه این پژوهش قرار دارد را به وسیله ترکیب شبکه عصبی مصنوعی و میانگین-فازی^۱ با روش زونالیتة ژئوشیمیایی بررسی کردند. همچنین تشخیص کانی‌سازی پراکنده در منطقه آستامال از هر دو روش سنتی زونالیتة ژئوشیمیایی و ترکیب شبکه عصبی مصنوعی و میانگین-فازی با روش زونالیتة ژئوشیمیایی بررسی شده است. بدین منظور به ترتیب ۲۹۰۰ و ۹۲۰ نمونه از سنگ در منطقه سونگون و آستامال برای بررسی عناصر Cu, Mo, Pb و Zn آنالیز کردند. لازم به ذکر است عناصر سرب و روی به عنوان فوق کانسار، عناصر مس و مولیبدن به عنوان تحت کانسار و نسبت ضریبی $Pb \times Zn / Cu \times Mo$ به عنوان شاخص زونالیتة انتخاب شده است. با توجه به نتایج بدست آمده منطقه سونگون ۳ به عنوان کانی‌سازی پنهان اقتصادی و منطقه آستامال به عنوان کانی‌سازی پراکنده غیراقتصادی معرفی شده است (Ziaii et al., 2009).

صفری و همکاران (۲۰۱۸)، به منظور تشخیص مناطق کانی‌سازی پنهان و پراکنده در منطقه سونگون و آستامال در ایران و اینزا در کانادا از ترکیب روش گرادیان غلظت با زونالیتة ژئوشیمیایی استفاده کردند. در این پژوهش ۴۳۶ نمونه از خاک برای آنالیز عناصر Cu, Mo, Pb و Zn در منطقه اینزا به صورت شبکه‌بندی منظم ۲۰۰ در ۵۰ متر و به ترتیب ۸۴۰ و ۸۸۰ نمونه از سنگ برای آنالیز عناصر Cu, Mo, Pb, Zn, Ag, As و Sb در منطقه سونگون در شبکه‌بندی منظم ۱۰۰ در ۲۰ متر و آستامال در شبکه‌بندی منظم ۱۰۰ در ۴۰ متر مورد بررسی شده است. همچنین به منظور بررسی تغییرات عمقی عناصر، ۲ گمانه در منطقه اینزا و ۳ گمانه در منطقه سونگون و آستامال بررسی شده است. لازم به ذکر است عناصر سرب و روی به عنوان فوق

¹ Fuzzy C-Means

کانسار، عناصر مس و مولیبدن به عنوان تحت کانسار و نسبت ضربی $Pb \times Zn/Cu \times Mo$ به عنوان شاخص زونالیتة انتخاب شده است. با توجه به نتایج بدست آمده از نسبت روش گرادیان غلظت برای عناصر فوق کانسار و تحت کانسار، مقادیر بیشتر از یک معرف کانی سازی پنهان و مقادیر کمتر از یک معرف کانی سازی پراکنده است. همچنین اگر میانگین گرادیان غلظت برای عناصر فوق کانسار و تحت کانسار بیشتر از مقدار عناصر فوق کانسار باشد، معرف کانی سازی پراکنده غیر اقتصادی است. با توجه به نتایج بدست آمده منطقه سونگون و اینزا به عنوان کانی سازی پنهان اقتصادی و منطقه آستمال به عنوان کانی سازی پراکنده غیر اقتصادی معرفی شد. لازم به ذکر است نتایج بدست آمده در مناطق مورد مطالعه، تطابق مکانی خوبی با گمانه ها دارد (Safari et al., 2018).

صفری (۱۳۹۶)، به منظور تشخیص مناطق کانی سازی پنهان در مناطق سونگون و آستمال از روش سنتی زونالیتة ژئوشیمیایی، ترکیب روش گرادیان غلظت با زونالیتة ژئوشیمیایی و ترکیب روش سینگولاریتی^۱ با زونالیتة ژئوشیمیایی استفاده کرده است. داده های ژئوشیمیایی و نتایج بدست آمده از روش ترکیب گرادیان غلظت با زونالیتة ژئوشیمیایی در منطقه سونگون و آستمال مشابه صفری و همکاران (۲۰۱۸) است. با توجه به نتایج بدست آمده از روش سنتی زونالیتة ژئوشیمیایی، آستمال به عنوان کانی سازی پراکنده غیر اقتصادی و دو زون در جنوب شرقی و غرب منطقه سونگون به عنوان کانی سازی پنهان اقتصادی معرفی شده است. همچنین به منظور تشخیص مناطق کانی سازی پنهان از ترکیب روش سینگولاریتی با زونالیتة ژئوشیمیایی در منطقه سونگون استفاده کرده است که در نتیجه قسمت جنوب شرقی و غرب منطقه سونگون به عنوان کانی سازی پنهان اقتصادی معرفی شده است. لازم به ذکر است نتایج بدست آمده از این سه روش در تشخیص کانی سازی پنهان در مناطق مورد مطالعه، تطابق خوبی با گمانه ها داشته است. به طور کلی با توجه به نتایج بدست آمده منطقه سونگون به عنوان کانی سازی پنهان اقتصادی و منطقه آستمال به عنوان کانی سازی پراکنده غیر اقتصادی تشخیص داده شد. همچنین روش گرادیان غلظت و سینگولاریتی نسبت به روش سنتی زونالیتة ژئوشیمیایی عملکرد بهتری در تشخیص مناطق کانی سازی پنهان و پراکنده داشته است (صفری، ۱۳۹۶).

¹ Singularity

۳-۵- جمع‌بندی

منطقه سونگون و آستامال در شمال غربی ایران بر روی کمر بند مس پورفیری اهر-ارسباران واقع شده است. این دو منطقه از گذشته به عنوان مناطقی چالشی برای کانسار مس پورفیری شناخته شده است. در این فصل ابتدا زمین‌شناسی و دورسنجی منطقه سونگون و آستامال مورد بررسی قرار گرفت. به منظور بررسی دورسنجی در مناطق مورد مطالعه، خطواره‌ها به روش خودکار، کانی‌سازی آهن به روش نسبت‌های باندی و دگرسانی‌ها به روش الگوریتم عملگرهای منطقی بارزسازی شدند. خطواره‌های استخراج شده در مناطق مورد مطالعه به صورت متراکم و متقاطع هستند و همچنین جهت خطواره‌ها شمال شرقی-جنوب غربی است. کانی‌سازی آهن و دگرسانی‌ها که اهمیت بالایی در شناسایی کانسار مس پورفیری دارند، در هر دو منطقه سونگون و آستامال نمایان شده، اما با توجه به مطالعات پیشین، دگرسانی‌ها در منطقه آستامال شدت و وسعت بیشتری نسبت به منطقه سونگون دارد. لازم به ذکر است از نظر زمین‌شناسی و ساختاری، مناطق مورد مطالعه پتانسیل مناسبی برای تشکیل مس پورفیری دارند، اما باید توجه شود وجود دگرسانی‌ها با وسعت و شدت بالا در منطقه آستامال و عدم کانی‌سازی اقتصادی در این منطقه، منجر به ایجاد چالش اکتشافی شده است.

نمونه‌برداری در مناطق مورد مطالعه به دو صورت سطحی و عمقی انجام شده است. تعداد ۹۱۶ و ۸۴۲ نمونه سطحی از سنگ در شبکه‌بندی منظم به ترتیب در منطقه آستامال و سونگون برداشت شده است. همچنین تعداد ۲ گمانه در منطقه آستامال تا عمق ۱۰۰ متر از سطح زمین و ۳ گمانه در منطقه سونگون با عمق‌های ۵۰۰، ۵۵۰ و ۶۰۰ متر از سطح زمین حفاری شده است که از هر کدام از گمانه‌ها با فواصل ۱۰ متر نمونه‌برداری شده است.

با توجه به مطالعات پیشین، منطقه آستامال به عنوان کانی‌سازی پراکنده غیر اقتصادی و منطقه سونگون در دو زون جنوب شرقی و غرب منطقه، به عنوان کانی‌سازی پنهان اقتصادی معرفی شده است. لازم به ذکر است نتایج بدست آمده از مطالعات پیشین در مناطق مورد مطالعه منجر به توسعه روش سنتی زونالیت به ژئوشیمیایی بوده ولی در تعیین زمینه، تفکیک آنومالی از زمینه و به خصوص تفکیک سطوح مختلف آنومالی محدودیت‌هایی داشته است. بدین ترتیب در فصل بعد کاربرد یادگیری عمیق در ژئوشیمی معادن و بالتبع آن زونالیت ژئوشیمیایی در مناطق سونگون و آستامال بررسی شده است.

فصل چهارم

کاربرد یادگیری عمیق در ژئوشیمی معادن

۴-۱- مقدمه

شاخص زونالیت (قائم) به عنوان یکی از بخش‌های مهم زونالیت ژئوشیمیایی، به وسیله بررسی عناصر فوق کانسار و تحت کانسار در تشخیص مناطق کانی‌سازی پنهان کاربرد وسیعی داشته است. بر اساس مطالعات پیشین در مناطق مورد مطالعه، عناصر سرب و روی به عنوان فوق کانسار، عناصر مس و مولیبدن به عنوان تحت کانسار و نسبت ضریبی $Pb \times Zn / Cu \times Mo$ به عنوان شاخص زونالیت انتخاب شده است (Ziaii et al., 2009). در این فصل ابتدا داده‌های ژئوشیمیایی خارج از ردیف مناطق سونگون و آستامال به وسیله روش دورفل برای عناصر Cu, Mo, Pb و Zn تصحیح شده است (جدول ۴-۱). اطلاعات آماری داده‌های ژئوشیمیایی عناصر Cu, Mo, Pb و Zn مناطق سونگون و آستامال پس از اعمال روش دورفل در جدول ۴-۲ آورده شده است. همچنین به منظور بررسی بهتر داده‌ها، نمودار توزیع فراوانی^۱ عناصر Cu, Mo, Pb و Zn به صورت جداگانه برای مناطق آستامال و سونگون به ترتیب در شکل ۴-۱ و ۴-۲ نشان داده شده است. با توجه به این دو شکل، داده‌های ژئوشیمیایی در مناطق مورد مطالعه دارای توزیع غیرنرمال و چولگی مثبت هستند که بیانگر تعداد بالایی از مقادیر غلظت کم عناصر Cu, Mo, Pb و Zn در منطقه سونگون و آستامال است.


جدول ۴-۱: تصحیح داده‌های ژئوشیمیایی خارج از ردیف در مناطق مورد مطالعه

منطقه	عنصر	تعداد داده خارج از ردیف	مقدار جایگزین شده (ppm)
آستامال	Cu	۲۰	۲۸۱
	Mo	۲۲	۱۵
	Pb	۴۱	۴۰
	Zn	۳۰	۲۶۶
سونگون	Cu	۶۳	۴۶۰
	Mo	۸۲	۴۵
	Pb	۲۶	۴۸۹
	Zn	۲۲	۲۶۶


^۱ Frequency

جدول ۴-۲: اطلاعات آماری داده‌های ژئوشیمیایی پس از اعمال روش دورفل در مناطق مورد مطالعه

منطقه	عنصر	حداقل غلظت (ppm)	حداکثر غلظت (ppm)	میانگین غلظت (ppm)	انحراف معیار	چولگی	کشیدگی
آستمال	Cu	۵	۲۸۱	۷۲/۳۸	۵۷/۶	۱/۸	۳/۳
	Mo	۰/۵	۱۵	۴/۱	۳/۱	۱/۷	۲/۹
	Pb	۱۲	۴۰	۱۹/۷۲	۶/۷	۱/۸	۲/۶
	Zn	۱۵	۲۶۶	۸۸/۶	۵۳/۲	۱/۷	۲/۹
سونگون	Cu	۱/۴	۴۶۰	۱۲۷/۴	۱۲۵/۳	۱/۶	۱/۵
	Mo	۰/۱	۴۵	۱۱/۲	۱۳/۹	۱/۶	۱
	Pb	۲	۴۸۹	۱۱۱/۶	۱۱۳/۵	۱/۸	۲/۸
	Zn	۳	۲۶۶	۸۰/۵	۵۴	۱/۷	۲/۸



شکل ۴-۱: نمودار توزیع فراوانی عناصر Cu, Mo, Pb و Zn در منطقه آستمال



شکل ۴-۲: نمودار توزیع فراوانی عناصر Cu, Mo, Pb و Zn در منطقه سونگون

به منظور ارائه الگویی برای ترکیب یادگیری عمیق با زونالیت‌ه ژئوشیمیایی، مراحل زیر به صورت جداگانه در مناطق سونگون و آستامال بررسی شده است:

- (۱) اعمال روش کا-میانگین بر روی شاخص زونالیت‌ه
- (۲) جداسازی زمینه و آنومالی در کلاس‌های مختلف به وسیله خودرمنزنگار پشته‌ای
- (۳) تشخیص نقاط کانی‌سازی پنهان به وسیله خودرمنزنگار پشته‌ای و تنظیم دقیق
- (۴) تشخیص مناطق کانی‌سازی پنهان به وسیله خودرمنزنگار پشته‌ای و تنظیم دقیق
- (۵) تشخیص مناطق کانی‌سازی پنهان به وسیله شبکه عصبی همگشتی
- (۶) زون‌بندی مناطق مورد مطالعه به منظور محاسبه زمینه، سطح از فرسایش و تعیین نوع کانی‌سازی در مناطق کانی‌سازی پنهان
- (۷) اعتبارسنجی نتایج

در این پژوهش الگوریتم‌های مورد استفاده در محیط برنامه‌نویسی VS Code، به زبان پایتون^۱ و تحت کراس^۲ کدنویسی و اجرا شده است. لازم به ذکر است کراس یک کتابخانه قدرتمند برای کدنویسی شبکه عصبی مصنوعی و یادگیری عمیق است. این کتابخانه با رابط کاربری مناسب، بر بستر تنسورفلو^۳ که از کتابخانه‌های اصلی ایجاد کدهای یادگیری عمیق است، اجرا می‌شود. مراحل کدنویسی در کراس عموماً شامل ۴ مرحله اصلی (۱) آماده‌سازی داده‌ها^۴ شامل تقسیم‌بندی و نرمال‌سازی داده‌ها، (۲) ایجاد لایه‌ها و ساخت مدل یادگیری عمیق، (۳) تعیین پارامترهای آموزش مدل شامل تابع هزینه، الگوریتم بهینه‌ساز، تابع فعال‌ساز و تابع ارزیابی و (۴) آموزش مدل ایجاد شده است (شوله، ۱۳۹۹). در این پژوهش از پارامترهای تابع فعال‌ساز یکسوساز خطی و بیشینه هموار، تابع هزینه آنتروپی متقاطع دسته‌ای و میانگین خطای مربعات، الگوریتم بهینه‌ساز برآورد تکانه تطبیقی و تابع ارزیابی صحت با توجه به نوع عملکرد الگوریتم‌ها در مراحل مختلف معماری شبکه‌ها استفاده شده است. در این فصل ابتدا فرآیند الگوی ارائه شده بررسی و سپس به منظور تشخیص مناطق کانی‌سازی پنهان اقتصادی به صورت جداگانه در مناطق سونگون و آستمال اجرا شده است.

۴-۲- فرآیند اجرای الگوی ترکیب یادگیری عمیق با زونالیته ژئوشیمیایی

در این بخش فرآیند ۷ مرحله‌ای الگوی ارائه شده برای تشخیص مناطق کانی‌سازی پنهان اقتصادی بررسی شده است. لازم به ذکر است معماری‌های معرفی شده متناسب با داده‌های ژئوشیمیایی در مناطق سونگون و آستمال است.

۴-۲-۱- اعمال روش کا-میانگین بر روی شاخص زونالیته

برای شناسایی روند و خوشه‌بندی داده‌های ژئوشیمیایی، روش کا-میانگین بر روی نتایج شاخص زونالیته که شامل تاثیر عناصر Cu, Mo, Pb, Zn و عناصر فوق کانسار و تحت کانسار است، اعمال شده است. خوشه‌بندی در تعیین تعداد نوروں لایه رمز خودرمنزگار پشته‌ای و تعداد نوروں لایه خروجی شبکه عصبی همگشتی اهمیت بالایی داشته است. این لایه‌ها مرتبط با ویژگی‌ها بوده و در کلاس‌بندی توزیع آنومالی تاثیر

^۱ Python

^۲ Keras

^۳ TensorFlow

^۴ Data preparation

مستقیمی داشته است. بدین ترتیب برای تعیین تعداد خوشه، علاوه بر معیار ضریب شبیح باید تعداد خوشه‌های انتخاب شده با روند ساختار زمین‌شناسی و مناطق محتمل آنومالی تطابق مناسبی داشته باشد.

۴-۲-۲- جداسازی زمینه و آنومالی در کلاس‌های مختلف به وسیله خودرمنگار

پشته‌ای

تفکیک آنومالی از زمینه اهمیت بالایی در بررسی‌های ژئوشیمیایی دارد. فرآیند آموزش خودرمنگار پشته‌ای برای جداسازی زمینه از آنومالی در کلاس‌های مختلف شامل ۳ مرحله است.

اولین مرحله تعیین معماری خودرمنگار پشته‌ای است؛ خودرمنگار پشته‌ای یک الگوریتم با معماری قرینه است که معمولاً معماری این شبکه با لایه رمز متناسب است. در این پژوهش بعد از بررسی چندین معماری با پارامترهای مختلف، معماری $x - 48 - d - 24 - d - 12 - d - \blacksquare - d - 12 - d - 24 - d - 48 - x'$ بیشترین تناسب را با داده‌های ژئوشیمیایی عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار در مناطق مورد مطالعه نشان داده است که در آن x لایه ورودی و x' لایه خروجی شبکه برای بازنمایی x است. همچنین در این معماری جهت جلوگیری از مشکل بیش‌برازش، از لایه حذف تصادفی (d) استفاده شده است که در هر مرحله تکرار^۱ فرآیند آموزش خودرمنگار پشته‌ای، ۲۰ درصد از نورون‌ها از فرآیند آموزش شبکه خارج شده است. همچنین بخش خالی ($\blacksquare$) در معماری خودرمنگار پشته‌ای اشاره به تعداد نورون لایه رمز دارد که در هر کدام از مناطق مورد مطالعه متفاوت است.

در مرحله دوم به منظور بررسی عملکرد و تعیین تعداد بهینه تکرار، خودرمنگار پشته‌ای با ۵۰۰ تکرار برای مجموعه ورودی شامل داده‌های ژئوشیمیایی عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار آموزش داده شده است که ۷۰، ۱۵ و ۱۵ درصد داده‌ها به ترتیب به عنوان مجموعه آموزش، آزمایش و اعتبارسنجی اختصاص داده شده است. سپس با انتخاب بهینه تکرار، خودرمنگار پشته‌ای به صورت جداگانه برای داده‌های معرفی شده اجرا شده و پارامترها و وزن‌ها ذخیره شده است. لازم به ذکر است مجموعه ورودی به وسیله رابطه ۲-۲۴ نرمال‌سازی شده است.

^۱ Epoch

در مرحله سوم با حفظ پارامترها و وزن‌های بدست آمده از مرحله قبل، بخش رمزگشا از خودرمزنگار پشته‌ای حذف و معماری شبکه به $\blacksquare - d - 12 - d - 24 - d - 48 - x$ تبدیل شده است. به وسیله این شبکه با داشتن اطلاعات بدست آمده از شبکه قبل، داده‌های ژئوشیمیایی هر عنصر به صورت جداگانه به تعداد کلاس‌های مورد نظر (تعداد نوروں‌های لایه رمز) تقسیم شده است. برای ایجاد نقشه آنومالی، نتایج بدست آمده برای عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار به صورت جداگانه به نرم‌افزار GIS منتقل شده و به روش وزن‌دهی بر مبنای عکس فاصله^۱ از درجه ۲، درون‌یابی شده است. لازم به ذکر است ابعاد تصاویر در منطقه آستامال و سونگون به ترتیب ۲۵۱×۲۷۶ (سطر×ستون) پیکسل و ۳۹۱×۲۵۱ (سطر×ستون) پیکسل است که مساحت هر پیکسل در منطقه آستامال برابر ۵۱/۸۴ متر مربع و در منطقه سونگون برابر ۲۳/۳۳ متر مربع است.

۴-۲-۳- تشخیص نقاط کانی‌سازی پنهان به وسیله خودرمزنگار پشته‌ای و تنظیم

دقیق

برای تشخیص نقاط کانی‌سازی پنهان از معماری معرفی شده در بخش قبل استفاده شده با این تفاوت که داده‌های ژئوشیمیایی عناصر ضربی فوق کانسار و تحت کانسار به عنوان مجموعه آزمایش و اعتبارسنجی انتخاب شده است. همچنین در این بخش بعد از حذف بخش رمزگشا، شبکه مجدد به وسیله روش تنظیم دقیق با ورودی‌های برچسب‌دار آموزش داده شده است. برای برچسب‌دار شدن مجموعه ورودی، شاخص زونالیت به برای مجموعه آموزش اعمال شد و سپس به وسیله روش کا-میانگین، داده‌ها به تعداد خوشه‌های مورد نظر تقسیم شده است. این فرآیند برای مجموعه‌های آزمون و اعتبارسنجی نیز انجام شده و بدین ترتیب هر کدام از ورودی‌های شبکه برچسب‌دار شده است. مراحل آموزش خودرمزنگار پشته‌ای برای تشخیص نقاط کانی‌سازی پنهان عبارت است از:

¹ Inverse Distance Weighting (IDW)

مرحله اول، ابتدا ورودی‌ها که به صورت بردار است به وسیله رابطه ۲-۲۴ نرمال‌سازی شده است. خودرمنگار پشته‌ای با ۵۰۰ تکرار، آموزش داده شده و با انتخاب تعداد بهینه تکرار، شبکه بار دیگر با این تعداد تکرار آموزش داده شده و پارامترها و وزن‌های شبکه برای اعمال تنظیم دقیق ذخیره شده است.

در مرحله دوم برای اعمال تنظیم دقیق، بخش رمزگشا از خودرمنگار پشته‌ای حذف شده و معماری شبکه به $\blacksquare - d - 12 - d - 24 - d - 48 - x$ تغییر کرده است. سپس شبکه جدید مجدد به وسیله داده‌های برچسب‌دار در تعداد بهینه تکرار، آموزش داده شده است. بعد از اتمام آموزش، داده‌های ژئوشیمیایی Cu, Mo, Pb و Zn به عنوان ورودی به شبکه داده شده و نقاط مرتبط با کانی‌سازی پنهان در کلاس‌های مختلف تشخیص داده شده است.

۴-۲-۴- تشخیص مناطق کانی‌سازی پنهان به وسیله خودرمنگار پشته‌ای و تنظیم

دقیق

فرآیند آموزش این بخش مشابه با بخش قبل است ولی معماری و مجموعه ورودی خودرمنگار پشته‌ای متفاوت است. خودرمنگار پشته‌ای ورودی‌ها را از نوع مختلف داده یا تصویر به بردار تبدیل می‌کند. در ابتدا نقشه‌های آنومالی عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار، به بردار تبدیل شده که مقادیر هر عضو این بردار، بیانگر میزان روشنایی پیکسل مربوطه است. بدین ترتیب بخشی از پیکسل‌های نقشه‌های آنومالی عناصر Cu, Mo, Pb و Zn به عنوان مجموعه آموزش اختصاص یافت که شامل ۷۰ درصد از مجموعه ورودی است. این فرآیند برای مجموعه آزمایش و اعتبارسنجی بر اساس نقشه‌های آنومالی عناصر ضربی فوق کانسار و تحت کانسار انجام شده که ۳۰ درصد باقی‌مانده از مجموعه ورودی را تشکیل داده است. همچنین به منظور تخصیص برچسب به مجموعه ورودی برای تنظیم دقیق، نتایج بدست آمده از بخش قبل به وسیله روش وزن‌دهی بر مبنای عکس فاصله از درجه ۲، درون‌یابی و نقشه آن ایجاد شده و برچسب‌های مجموعه‌های ورودی شبکه مشابه با بخش قبل ولی بر روی پیکسل‌های تصاویر اعمال شده است.

با توجه به بررسی برداری تصاویر، نیاز به معماری ساده‌تری برای خودرمنگار پشته‌ای است زیرا این شبکه در آموزش به وسیله مجموعه تصاویر، عملکرد ضعیف‌تری نسبت به دیگر روش‌ها مانند شبکه عصبی همگشتی دارد. بدین ترتیب با بررسی چندین معماری خودرمنگار پشته‌ای با پارامترهای مختلف، معماری

$x' - d - 24 - d - 12 - \blacksquare - d - 12 - d - 24 - x$ با لایه حذف ۴۰ درصد انتخاب شده است. انتخاب معماری مناسب برای خودرمنگار پشته‌ای دشوار است اما با اعمال تنظیم دقیق نتایج بدست آمده از شبکه اول توسعه داده شده است. فرآیند آموزش شبکه مشابه مراحل یک و دو در بخش قبل است با این تفاوت که خودرمنگار پشته‌ای ابتدا با ۱۰۰ تکرار آموزش و سپس تعداد بهینه تکرار انتخاب شده است. همچنین معماری شبکه برای تنظیم دقیق برابر $x - d - 12 - d - 24 - x$ است. سپس برای تشخیص مناطق مرتبط با کانی‌سازی پنهان، نقشه‌های آنومالی عناصر Cu, Mo, Pb و Zn به صورت برداری به شبکه وارد شده است و مناطق مرتبط با کانی‌سازی پنهان در کلاس‌های مختلف تشخیص داده شده است.

۴-۲-۵- تشخیص مناطق کانی‌سازی پنهان به وسیله شبکه عصبی همگشتی

شبکه عصبی همگشتی یکی از قوی‌ترین الگوریتم‌های یادگیری عمیق است که در بینایی ماشین کاربرد وسیعی دارد. از مشکلات مهم شبکه عصبی همگشتی در بررسی داده‌های ژئوشیمیایی، کمبود داده‌های برچسب‌دار است. فرآیند کانی‌سازی یک فرآیند نادر و مناطق اندیس‌ها و کانسارهای معدنی محدود است که منجر به کمبود داده‌ها برای شبکه عصبی همگشتی شده است. به منظور رفع این مشکل، فرآیند آموزش شبکه عصبی همگشتی در این پژوهش بر مبنای پیکسل است که در طی ۳ مرحله این آموزش انجام شده است.

مرحله اول مهم‌ترین بخش شروع فرآیند آموزش یعنی انتخاب معماری برای شبکه عصبی همگشتی است. ابتدا برای بهینه بودن پارامترهای شبکه، معماری‌های مختلفی بر اساس معماری‌های LeNet و AlexNet بررسی شده است. معماری $x - c(16) - c(32) - c(64) - fl - f(24) - d - f(12) - d - y(\blacksquare)$ مناسب خوبی با داده‌های مورد استفاده داشته و برای آموزش شبکه استفاده شده است. این معماری شامل ۳ لایه همگشت (c)، یک لایه برداری^۱ (fl)، ۳ لایه تمام متصل (f)، ۲ لایه حذف تصادفی (d) و یک لایه خروجی (y) است. لازم به ذکر است به منظور افزایش سرعت و قدرت محاسباتی شبکه عصبی همگشتی به جای لایه ادغام یک پرش در هر لایه همگشت انتخاب شده است. در لایه همگشت پارامترهای فیلتر، پرش و لایه‌گذاری

¹ Flatten

به ترتیب ۵×۵، ۲ و لایه گذاری یکسان انتخاب شده است. به منظور جلوگیری از بیش‌برازش بعد از هر لایه تمام متصل یک لایه حذف تصادفی به اندازه ۲۰ درصد در معماری شبکه استفاده شده است.

در مرحله دوم، مجموعه ورودی و برچسب‌ها برای آموزش شبکه عصبی همگشتی انتخاب شده است. نقشه‌های آنومالی عناصر Cu, Mo, Pb و Zn در سطوح مختلف زمینه و آنومالی به صورت جداگانه به عنوان مجموعه آموزش و نقشه‌های آنومالی عناصر ضربی فوق کانسار و تحت کانسار در سطوح مختلف زمینه و آنومالی به صورت جداگانه به عنوان مجموعه اعتبارسنجی انتخاب شده است. برای مجموعه ورودی ابتدا شاخص زونالیت به روی داده‌های ژئوشیمیایی اعمال و به وسیله روش کا-میانگین به تعداد خوشه‌های مورد نظر تقسیم شده و به وسیله روش وزن‌دهی بر مبنای عکس فاصله از درجه ۲، نقشه زونالیت حاصل شده است. نقشه زونالیت در سطوح مختلف آنومالی برای مجموعه آزمایش استفاده شده است. همچنین برای برچسب‌دار شدن مجموعه ورودی که همان کلاس‌های مورد نظر است، نقشه بدست آمده از قسمت قبل با نقشه زونالیت ایجاد شده، مجدد به وسیله روش کا-میانگین خوشه‌بندی شده است. بدین ترتیب برچسب‌های مجموعه ورودی شامل نتایج بدست آمده از خودرمنگار پشته‌ای و شاخص زونالیت است که معرف مجموعه خروجی است. لازم به ذکر است ورودی شبکه عصبی همگشتی به صورت داده‌های تنسور است و به وسیله رابطه ۲-۲۴ نرمال‌سازی شده است.

در مرحله سوم، شبکه عصبی همگشتی با مجموعه ورودی و برچسب‌های انتخاب شده برای ۵۰۰ تکرار آموزش داده شده است و تعداد بهینه تکرار انتخاب و شبکه مجدد با این تعداد تکرار آموزش داده شده است. در انتها شبکه عصبی همگشتی به عنوان یک شبکه تشخیص و کلاس‌بندی عمل کرده و نقشه آنومالی عناصر Cu, Mo, Pb و Zn برای تشخیص مناطق کانی‌سازی پنهان وارد شبکه شده و مناطق مرتبط با کانی‌سازی پنهان در کلاس‌های مختلف تشخیص داده شده است.

۴-۲-۶- محاسبه زمینه، سطح از فرسایش و تعیین نوع کانی‌سازی

برای تعیین نوع کانی‌سازی در مناطق کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی، منطقه مورد مطالعه به چند زون تقسیم شده است که هر زون شامل مناطق کانی‌سازی پنهان در کلاس‌های مختلف آنومالی است. بدین ترتیب ابتدا مقدار زمینه در مناطق غیر آنومالی نقشه‌های آنومالی بدست آمده از بخش ۴-

۲-۲ برای هر کدام از عناصر Cu, Mo, Pb و Zn با روش زونالیتة ژئوشیمیایی محاسبه و سپس به وسیله روش‌های ارائه شده توسط سالوووف (رابطه ۲-۱۰) و گریگوریان (رابطه ۲-۱۲) سطح از فرسایش در هر زون محاسبه شده است. با محاسبه سطح از فرسایش از روش سالوووف، نوع کانی‌سازی بر اساس شکل ۲-۴ و همچنین با محاسبه سطح از فرسایش به روش گریگوریان، نوع کانی‌سازی بر اساس شکل ۲-۵ برای هر زون تعیین شده است.

لازم به ذکر است با استفاده از الگوی ارائه شده، مناطق کانی‌سازی پنهان برای تعیین نوع کانی‌سازی و اعتبارسنجی از شبکه شبکه عصبی همگشتی حاصل شده است. همچنین علاوه بر شبکه عصبی همگشتی، مناطق کانی‌سازی پنهان به وسیله خودرمنگار پشته‌ای بدست آمده و نتایج آن در شبکه عصبی همگشتی نیز استفاده شده است. بدین منظور علاوه بر بررسی موارد مطرح شده در این بخش برای مناطق کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی، برای بررسی بهتر نتایج بدست آمده از الگوی ارائه شده و مقایسه نتایج بدست آمده از خودرمنگار پشته‌ای با شبکه عصبی همگشتی، مناطق کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای نیز مشابه نتایج بدست آمده از شبکه عصبی همگشتی بررسی شده است.

۴-۲-۷- اعتبارسنجی نتایج


مشابه مرحله قبل در این مرحله نیز علاوه بر بررسی نتایج شبکه عصبی همگشتی که منجر به تشخیص مناطق کانی‌سازی پنهان و تعیین نوع کانی‌سازی شده، نتایج بدست آمده از خودرمنگار پشته‌ای نیز اعتبارسنجی شده است. دلیل این کار بررسی بهتر الگوی ارائه شده و ارائه مزیت‌های چند مرحله‌ای بودن الگو است.

در انتها نتایج بدست آمده از الگوی ارائه شده به وسیله گمانه‌های موجود در مناطق مورد مطالعه بررسی شده است. با توجه به بخش ۳-۳ اطلاعات عمقی ۲ گمانه در منطقه آستامال و ۳ گمانه در منطقه سونگون موجود است. بدین ترتیب با بررسی ارتباط مکانی این گمانه‌ها با نتایج بدست آمده برای هر کدام از مناطق سونگون و آستامال، عملکرد الگوی ارائه شده بررسی شده است. لازم به ذکر است با توجه به مطالعات گذشته، منطقه آستامال و سونگون (سونگون ۱ و ۲) به ترتیب به عنوان کانی‌سازی پراکنده (غیراقتصادی) و کانی‌سازی پنهان اقتصادی معرفی شده است (Ziaii et al., 2009).

۴-۳- تشخیص کانی‌سازی پنهان اقتصادی در منطقه آستمال

۴-۳-۱- اعمال روش کا-میانگین بر روی شاخص زونالیته

با توجه به نتیجه ضریب شبج بر روی شاخص زونالیته، بهترین تعداد خوشه‌ها در منطقه آستمال برابر ۲ است (شکل ۴-۳)، اما تعداد ۳ خوشه بیشترین تطابق را با روند ساختار زمین‌شناسی و مناطق محتمل آنومالی در منطقه آستمال داشته است. همچنین ضریب شبج برای ۳ خوشه نیز مقدار قابل قبولی را نشان داده است.





شکل ۴-۳: نمودار ضریب شبج در منطقه آستمال

۴-۳-۲- جداسازی زمینه و آنومالی در کلاس‌های مختلف به وسیله خودرمنگار


پشته‌ای

با توجه به تعداد خوشه‌های بدست آمده از روش کا-میانگین با بررسی ساختار زمین‌شناسی در منطقه آستمال، تعداد نوروهای لایه رمز برابر ۳ انتخاب و معماری خودرمنگار پشته‌ای برابر $x - 48 - d - 24$ و $x' - 48 - d - 24 - d - 12 - d - 3 - d - 12$ است. برای بررسی عملکرد معماری خودرمنگار پشته‌ای و تعیین تعداد بهینه تکرار، قبل از بررسی جداگانه عناصر، شبکه با مجموعه ورودی عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار و با توجه به بخش ۴-۲-۲ در ۵۰۰ تکرار آموزش داده شده است. با توجه به شکل ۴-۴، از تکرار ۲۵۰ به بعد تغییری در کاهش خطا برای مجموعه آموزش (نمودار آبی)

و اعتبارسنجی (نمودار نارنجی) نمایان نشده است. بدین ترتیب خودرمنزنگار پشته‌ای با تکرار ۲۵۰ برای ادامه کار انتخاب شده است. میزان خطا و صحت شبکه برای مجموعه آزمایش در ۲۵۰ تکرار به ترتیب برابر ۰/۰۲ و ۰/۸۲ است. لازم به ذکر است هرچه میزان خطا به صفر و صحت به یک نزدیک شود عملکرد شبکه مناسب است. سپس این فرآیند به صورت جداگانه با ۲۵۰ تکرار برای عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار انجام شده است. در شکل ۴-۵ نقشه آنومالی بدست آمده از خودرمنزنگار پشته‌ای را برای این عناصر در ۳ کلاس زمینه، آنومالی ضعیف و آنومالی قوی در منطقه آستمال نشان داده شده است.



شکل ۴-۴: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه آستمال




شکل ۴-۵: نقشه آنومالی عناصر Cu (الف)؛ Mo (ب)؛ Pb (ج)؛ Zn (د)؛ عناصر ضربی فوق کانسار (ز)؛ عناصر ضربی تحت کانسار (ی)؛ بدست آمده از خودرمننگار پشته‌ای در منطقه آستامل

۴-۳-۳- تشخیص نقاط کان‌سازی پنهان به وسیله خودرمنگار پشته‌ای و تنظیم


دقیق

با توجه به بخش ۴-۳-۳ با انتخاب ۳ نورون در لایه رمز، خودرمنگار پشته‌ای با معماری $x - 48 - x'$ $d - 48 - d - 24 - d - 12 - d - 3 - d - 12 - d - 24 - d - 48$ برای ۵۰۰ تکرار آموزش داده شده است. در شکل ۴-۶ نمودار خطا و دقت برای ۵۰۰ تکرار نشان داده شده است. با توجه به این شکل بعد از ۲۰۰ تکرار، خطای مجموعه اعتبارسنجی نسبت به خطای مجموعه آموزش بیشتر شده است. بدین ترتیب تعداد ۲۰۰ تکرار برای ادامه آموزش شبکه انتخاب شده که میزان خطا و صحت در آن به ترتیب برابر ۰/۲۶ و ۰/۸۷ است.




شکل ۴-۶: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه آستمال

پس از اعمال تنظیم دقیق با ۲۰۰ تکرار بر روی شبکه $x - 48 - d - 24 - d - 12 - d - 3$ میزان خطا و صحت به ترتیب برابر ۰/۱۸ و ۰/۹۶ است (شکل ۴-۷). بدین ترتیب نقاط کانی‌سازی پنهان اقتصادی در منطقه آستمال به وسیله خودرمنگار پشته‌ای و تنظیم دقیق در ۳ کلاس زمینه، آنومالی ضعیف و آنومالی قوی تقسیم‌بندی شده است (شکل ۴-۸).



شکل ۴-۷: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۲۰۰ تکرار آموزش در منطقه آستمال




شکل ۴-۸: نقشه نقاط کانی‌سازی پنهان بدست آمده از خودرمزنگار پشته‌ای و تنظیم دقیق در منطقه آستمال

۴-۳-۴- تشخیص مناطق کانی‌سازی پنهان به وسیله خودرمزنگار پشته‌ای و تنظیم

دقیق


تعداد نوروں لایه رمز، مشابه بخش قبل، ۳ در نظر گرفته شده است. شبکه خودرمزنگار پشته‌ای با معماری $x' - d - 24 - d - 12 - d - 3 - 12 - d - 24 - d - x$ برای ۱۰۰ تکرار آموزش مشابه بخش ۴-۲ آموزش داده شده است (شکل ۴-۹). با توجه به شکل ۴-۷ مقادیر خطا برای ۱۰۰ تکرار مقدار بالایی را نشان داده است که بیانگر سختی استخراج ویژگی‌ها از ورودی است که با اعمال تنظیم دقیق تا حدودی این مشکل برطرف شده است. همچنین صحت برای ۱۰۰ تکرار نوسانی است که می‌تواند مبتنی به ۳ دلیل باشد. با بالاتر رفتن درصد حذف تصادفی، مقدار خطا کاهش و مقدار صحت نیز کاهش یافته است. همچنین تعداد کم تکرارها باعث بزرگنمایی نمودار و بارزسازی جزئیات بیشتر شده است که با زیاد بودن تعداد تکرارها نمودار روند بهتری را خواهد داشت. این امکان نیز وجود دارد که با توجه به مقادیر خطای بالا، شبکه در استخراج ویژگی‌ها عملکرد مناسبی نداشته باشد که با اعمال تنظیم دقیق بر روی شبکه این مشکلات تا حد قابل قبولی برطرف شده است.




شکل ۴-۹: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۱۰۰ تکرار آموزش در منطقه آستمال

مقدار خطای مجموعه آموزش و اعتبارسنجی بعد از ۲۵ تکرار روند ثابتی داشته و نمودار این دو خطا به یکدیگر نزدیک شده است. بدین ترتیب ۲۵ تکرار برای ادامه آموزش شبکه انتخاب شده که در این تعداد تکرار میزان خطا و صحت به ترتیب برابر $0/4$ و $0/72$ است.

با حذف بخش رمزگشا و اعمال تنظیم دقیق برای ۲۵ تکرار آموزش شبکه با معماری $x - 24 - d$ مقدار خطا و صحت به ترتیب برابر $0/108$ و $0/77$ است (شکل ۴-۱۰). با توجه به این مقادیر، تنظیم دقیق عملکرد شبکه را بهبود بخشیده و شبکه با میزان خطای کمتر ویژگی‌های ورودی‌ها را تشخیص داده است. در مبحث شبکه عصبی مصنوعی خطا بر صحت برتری دارد ولی با این وجود به وسیله تنظیم دقیق میزان صحت شبکه نیز بیشتر شده است. در شکل ۴-۱۱ نقشه مناطق کانی‌سازی پنهان اقتصادی بدست آمده از خودرمنگار پشته‌ای و تنظیم دقیق را در ۳ کلاس زمینه، آنومالی ضعیف و آنومالی قوی برای منطقه آستمال نشان داده شده است.




شکل ۴-۱۰: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۲۵ تکرار آموزش در منطقه آستمال




شکل ۴-۱۱: نقشه مناطق کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و تنظیم دقیق در منطقه آستمال

۴-۳-۵- تشخیص مناطق کانی‌سازی پنهان به وسیله شبکه عصبی همگشتی

با توجه به بخش ۴-۲-۵، شبکه عصبی همگشتی با ۳ نورون در لایه خروجی و ۵۰۰ تکرار برای منطقه آستامال آموزش داده شده است. در شکل ۴-۱۲ نمودار خطا و دقت برای ۵۰۰ تکرار شبکه عصبی همگشتی نشان داده شده که از ۱۰۰ تکرار به بعد، خطای مجموعه آموزش و اعتبارسنجی تغییر خاصی نداشته و برابر است و بعد از ۳۰۰ تکرار، خطای مجموعه اعتبارسنجی بیشتر از خطای مجموعه آموزش شده است. بدین ترتیب ۱۰۰ تکرار برای آموزش مجدد شبکه عصبی همگشتی انتخاب شده که مقدار خطا و صحت در آن به ترتیب ۰/۰۰۲ و ۰/۹۸ است. در شکل ۴-۱۳ نقشه مناطق کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی برای منطقه آستامال در ۳ کلاس زمینه، آنومالی ضعیف و آنومالی قوی نشان داده شده است.



شکل ۴-۱۲: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه آستامال



شکل ۴-۱۳: نقشه مناطق کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی در منطقه آستمال

۴-۳-۶- محاسبه زمینه، سطح از فرسایش و تعیین نوع کانی‌سازی

با توجه به نتایج بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی در تشخیص مناطق کانی‌سازی پنهان، منطقه آستمال به ۲ زون برای بررسی سطح از فرسایش و تعیین نوع کانی‌سازی تقسیم شده است (شکل ۴-۲۶). مقدار زمینه عناصر منطقه آستمال در بخش غیرآنومالی نقشه آنومالی عناصر، برای عناصر Cu, Mo, Pb و Zn به وسیله زونالیت ژئوشیمیایی محاسبه شده است. بر اساس بخش ۴-۲-۶ هر دو زون انتخاب شده معرف کانی‌سازی پراکنده (غیراقتصادی) است و زون II نسبت به زون I بیشتر فرسایش یافته است. در نتیجه زون I نسبت به زون II ارزش بالاتری داشته ولی هر دو زون غیراقتصادی است. جدول ۴-۳ شامل مقادیر زمینه عناصر در منطقه آستمال، مقادیر بدست آمده از روش سالووف و گریگوریان، نوع کانی‌سازی و دگرسانی‌ها در زون‌های I و II منطقه آستمال است. همچنین در این دو زون خطواره‌ها متراکم و به صورت متقاطع است که نشان‌دهنده ساختاری مناسب برای کانی‌سازی است.


جدول ۳-۴: مقادیر زمینه، مقادیر بدست آمده از روش سالاووف (K_S) و گریگوریان (K_G)، نوع کانی‌سازی و دگرسانی‌ها در زون‌های I و II آستامال

منطقه	عنصر	مقدار زمینه (ppm)	زون	K_S	K_G	کانی‌سازی	دگرسانی‌ها
آستامال	Cu	۴۱	زون I	۰/۸۲	۰/۱۳	پراکنده (غیراقتصادی)	به صورت وسیع و متمرکز دگرسانی آرژلیک، فیلک، پروپیلیتیک (کلریت-اپیدوت) و مناطق غنی از سیلیس
	Mo	۲/۳					
	Pb	۱۷	زون II	۰/۲۴	۰/۱	پراکنده (غیراقتصادی)	دگرسانی آرژلیک، فیلک، پروپیلیتیک (کلریت-اپیدوت) و پروپیلیتیک (کربنات) با وسعت کمتر نسبت به زون I
	Zn	۶۱					

۴-۴- تشخیص کانی‌سازی پنهان اقتصادی در منطقه سونگون

۴-۴-۱- اعمال روش کا-میانگین بر روی شاخص زونالیت

با اعمال روش کا-میانگین بر روی شاخص زونالیت، تعداد ۲ خوشه بیشترین مقدار ضریب شبیح را داشته (شکل ۴-۱۴)، اما این تعداد خوشه با روند ساختار زمین‌شناسی و مناطق محتمل آنومالی تطابق خوبی نداشته است. به همین دلیل تعداد خوشه‌های ۳، ۴ و ۵ نیز بررسی شده است. داده‌های ژئوشیمیایی منطقه سونگون در تعداد خوشه‌های ۳ و ۴ شباهت نزدیکی برای کلاس‌بندی داشته و حتی ضریب شبیح در این خوشه‌ها برابر است. مقدار ضریب شبیح در تعداد ۵ خوشه، کم‌تر از دو خوشه قبل است اما با روند ساختار زمین‌شناسی منطقه تطابق خوبی داشته است. بدین ترتیب در معماری شبکه‌های مورد استفاده در منطقه سونگون، هر کدام از این تعداد خوشه‌ها (۳، ۴ و ۵) به صورت جداگانه در معماری شبکه بررسی شده و تعداد خوشه بهینه برای معماری شبکه انتخاب شده است.




شکل ۴-۱۴: نمودار ضریب شبیح در منطقه سونگون


۴-۴-۲- جداسازی زمینه و آنومالی در کلاس‌های مختلف به وسیله خودرمنگار

پشته‌ای

با توجه به بخش ۴-۲-۲، تعداد نورون‌های لایه رمز در خودرمنگار پشته‌ای به وسیله روش کا-میانگین با بررسی ساختار زمین‌شناسی در منطقه سونگون، برابر ۵ انتخاب شده است. در ابتدا قبل از بررسی جداگانه عناصر به وسیله خودرمنگار پشته‌ای با معماری $x - 48 - d - 24 - d - 12 - d - 5 - d - 12 - d$ به منظور بررسی عملکرد شبکه، خودرمنگار پشته‌ای برای مجموعه ورودی عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار برای ۵۰۰ تکرار اجرا شده است. از تکرار ۱۴۰ به بعد نمودار خطای مجموعه آموزش و اعتبارسنجی با یکدیگر یکسان شده است. بدین ترتیب تعداد ۱۴۰ تکرار برای آموزش خودرمنگار پشته‌ای انتخاب شده که مقدار خطا و صحت برای این تعداد تکرار به ترتیب برابر ۰/۰۲۲ و ۰/۸۷ است (شکل ۴-۱۵). سپس این فرآیند به صورت جداگانه با ۱۴۰ تکرار برای عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار انجام شده که در نتیجه نقشه آنومالی این عناصر به وسیله خودرمنگار پشته‌ای در ۵ کلاس زمینه سطح ۱، زمینه سطح ۲، آنومالی ضعیف، آنومالی متوسط و آنومالی قوی برای منطقه سونگون ایجاد شده است (شکل ۴-۱۶).



شکل ۴-۱۵: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه سونگون




شکل ۴-۱۶: نقشه آنومالی عناصر Cu (الف)؛ Mo (ب)؛ Pb (ج)؛ Zn (د)؛ عناصر ضربی فوق کانسار (ز)؛ عناصر ضربی تحت کانسار (ی)؛ بدست آمده از خودرمنگار پشته‌ای در منطقه سونگون

۴-۴-۳- تشخیص نقاط کان‌سازی پنهان به وسیله خودرمنگار پشته‌ای و تنظیم

دقیق


در این بخش تعداد ۳ نورون در لایه رمز خودرمنگار پشته‌ای برای منطقه سونگون انتخاب شده است. با توجه به معماری $x' - 48 - d - 24 - d - 12 - d - 3 - d - 12 - d - 24 - d - 48 - x$ مطرح شده در بخش ۴-۲-۳، خودرمنگار پشته‌ای برای ۵۰۰ تکرار آموزش داده شده است. با توجه به نمودار خطا و دقت در شکل ۴-۱۷، تعداد ۸۵ تکرار برای ادامه آموزش خودرمنگار پشته‌ای انتخاب شده است. در این شکل در تعداد تکرار بیشتر از ۸۵، خطای مجموعه آموزش با اعتبارسنجی یکسان شده و تغییر خاصی نشان نداده است. همچنین از ۱۵۰ تکرار به بعد، شبکه دچار بیش‌برازش شده است. مقدار خطا و صحت در ۸۵ تکرار به ترتیب برابر ۰/۰۲۷ و ۰/۷۸ است.




شکل ۴-۱۷: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه سونگون

پس از اعمال تنظیم دقیق بر روی شبکه با معماری $x - 48 - d - 24 - d - 12 - d - 3 - d - 12 - d - 24 - d - 48 - x$ برای ۸۵ تکرار، میزان خطا و صحت نسبت به شبکه قبل بهبود یافته و به ترتیب برابر ۰/۰۲۴ و ۰/۹۵ است (شکل

۱۸-۴). در شکل ۴-۱۹ نقاط کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و تنظیم دقیق را در ۳ کلاس زمینه، آنومالی ضعیف و آنومالی قوی در منطقه سونگون نشان داده شده است.



شکل ۴-۱۸: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۸۵ تکرار آموزش در منطقه سونگون




شکل ۴-۱۹: نقشه نقاط کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و تنظیم دقیق در منطقه سونگون

۴-۴-۴- تشخیص مناطق کانی سازی پنهان به وسیله خودرمنگار پشته‌ای و تنظیم


دقیق

به منظور ایجاد برچسب‌ها، نتایج بدست آمده از بخش قبل به وسیله روش وزن‌دهی بر مبنای عکس فاصله از درجه ۲، درون‌یابی شده ولی در نقشه بدست آمده تفکیک مناطق آنومالی به خوبی انجام نشده است. بدین ترتیب برای تعیین تعداد نورون لایه رمز، نتایج بدست آمده به وسیله روش کا-میانگین با شاخص زونالیتیه تطابق داده شده و نقشه بدست آمده از بخش قبل به ۴ کلاس تقسیم شده است. بدین ترتیب با تعداد ۴ نورون در لایه رمز خودرمنگار پشته‌ای با معماری $x' - d - 24 - d - 12 - d - 4 - 12 - d - 24 - x$ برای ۱۰۰ تکرار، مشابه با بخش ۴-۲-۴ آموزش داده شده است. مقدار خطای مجموعه آموزش بعد از ۳۰ تکرار روند ثابتی داشته و خطای مجموعه اعتبارسنجی شروع بیشتر شده است. بدین ترتیب ۳۰ تکرار برای ادامه آموزش شبکه انتخاب شده که مقدار خطا و صحت در این تعداد تکرار به ترتیب برابر ۰/۳۱۷ و ۰/۶۵ است (شکل ۴-۲۰). مشکلات بخش ۴-۳-۴ نیز در منطقه سونگون مشاهده شده است که با اعمال تنظیم دقیق این مشکلات تا حد قابل قبولی برطرف شده است.




شکل ۴-۲۰: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۱۰۰ تکرار آموزش در منطقه سونگون

با حذف بخش رمزگشا و اعمال تنظیم دقیق در ۳۰ تکرار آموزش شبکه با معماری $x - 24 - d$ مقدار خطا و صحت به ترتیب برابر ۰/۰۰۶۲ و ۰/۷۷ است (شکل ۴-۲۱). در شکل ۴-۲۲ نقشه مناطق کانی‌سازی پنهان اقتصادی بدست آمده از خودرمنگار پشته‌ای و تنظیم دقیق در ۴ کلاس زمینه، آنومالی ضعیف، آنومالی متوسط و آنومالی قوی در منطقه سونگون نشان داده شده است.




شکل ۴-۲۱: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۳۰ تکرار آموزش در منطقه سونگون




شکل ۴-۲۲: نقشه مناطق کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و تنظیم دقیق در منطقه سونگون

۴-۴-۵- تشخیص مناطق کانی‌سازی پنهان به وسیله شبکه عصبی همگشتی

با توجه به اطلاعات بدست آمده از بخش قبل و نقشه آنومالی عناصر، تعداد نورون لایه خروجی مشابه با فرآیند بخش قبل ولی در این بخش برابر ۵ انتخاب شده است. بدین ترتیب شبکه عصبی همگشتی با ۵ نورون در لایه خروجی با توجه به بخش ۴-۲-۵ و با ۵۰۰ تکرار برای منطقه سونگون آموزش داده شده است. با توجه به شکل ۴-۲۳ در نزدیک ۱۰۰ تکرار، خطای مجموعه آموزش و اعتبارسنجی یکسان شده و بعد از آن خطای مجموعه اعتبارسنجی بیشتر از مجموعه آموزش و منجر به بیش‌برازش شده است. بدین ترتیب ۸۵ تکرار برای آموزش شبکه عصبی همگشتی انتخاب شده و شبکه مجدد با این تعداد تکرار آموزش داده شده است. مقدار خطا و صحت در ۸۵ تعداد تکرار به ترتیب برابر ۰/۱۷ و ۰/۹ است. در شکل ۴-۲۴ نقشه مناطق کانی‌سازی پنهان اقتصادی بدست آمده از شبکه عصبی همگشتی برای منطقه سونگون شامل ۵ کلاس زمینه سطح ۱، زمینه سطح ۲، آنومالی ضعیف، آنومالی متوسط و آنومالی قوی نشان داده شده است.



شکل ۴-۲۳: نمودار خطا (الف)؛ صحت (ب)؛ بر حسب ۵۰۰ تکرار آموزش در منطقه سونگون



شکل ۴-۲۴: نقشه مناطق کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی در منطقه سونگون

۴-۴-۶- محاسبه زمینه، سطح از فرسایش و تعیین نوع کانی‌سازی

بر اساس نتایج بدست آمده از شبکه‌های خودرمنگار پشته‌ای و شبکه عصبی همگشتی برای تشخیص مناطق کانی‌سازی پنهان، برای بررسی سطح از فرسایش و تعیین نوع کانی‌سازی منطقه سونگون به ۲ زون تقسیم شده است (شکل ۴-۳۰). در ابتدا مقدار زمینه برای عناصر Cu, Mo, Pb و Zn به وسیله زونالیت‌ه ژئوشیمیایی و در مناطق غیرآنومالی نقشه آنومالی هر عنصر محاسبه شده است. با توجه به بخش ۴-۲-۶ هر دو زون انتخاب شده معرف کانی‌سازی پنهان است ولی زون I نسبت به زون II بیشتر فرسایش یافته است. بدین ترتیب زون I و II اقتصادی است و زون II از اهمیت بیشتری در این زمینه برخوردار است. جدول ۴-۴ شامل مقدار زمینه عناصر در منطقه سونگون، مقادیر بدست آمده از روش سلاووف و گریگوریان، نوع کانی‌سازی و دگرسانی‌ها در زون‌های I و II منطقه سونگون است. همچنین در این دو زون، خطواره‌ها متراکم و به صورت متقاطع هستند که نشان از اهمیت این مناطق برای کانی‌سازی است.

جدول ۴-۴: مقادیر زمینه، مقادیر بدست آمده از روش سالووف (K_S) و گریگوریان (K_G)، نوع کانی سازی و دگرسانی در زون های I و II سونگون

منطقه	عنصر	مقدار زمینه (ppm)	زون	K_S	K_G	کانی سازی	دگرسانی ها
سونگون	Cu	۳۴	زون I	۲/۷	۲/۱	پنهان اقتصادی	به صورت متمرکز دگرسانی آرژلیک؛
	Mo	۱/۳					به صورت جزئی دگرسانی پروپیلیتیک (کلریت-اپیدوت) و پروپیلیتیک (کربنات)
	Pb	۲۴	زون II	۴۶/۴	۴۲/۳	پنهان اقتصادی	به صورت وسیع و متمرکز دگرسانی فیلیک؛
	Zn	۵۹					دگرسانی آرژلیک با وسعت خیلی کمتر، پروپیلیتیک (کلریت-اپیدوت) و پروپیلیتیک (کربنات) با وسعت کمتر نسبت به دگرسانی فیلیک

۴-۵- اعتبارسنجی نتایج


به وسیله گمانه های اکتشافی در دو منطقه سونگون و آستامال، نتایج بدست آمده از الگوی ارائه شده، اعتبارسنجی شده است. با توجه به وجود اطلاعات مکانی و عمقی گمانه ها، علاوه بر بررسی ارتباط مکانی گمانه ها با نقشه های آنومالی مناطق کانی سازی پنهان، تغییرات غلظت مس و شاخص زونالیت در گمانه های مختلف به منظور بررسی نوع کانی سازی ارائه شده، بررسی شده است.

۴-۵-۱- منطقه آستامال

منطقه آستامال از لحاظ دگرسانی ارزش بالایی دارد ولی مناطق دگرسان شده، با کانی سازی همراه نیست. بر این اساس منطقه آستامال فرسایش یافته است و در بررسی منطقه به منظور شناسایی کانی سازی مس پورفیری، غلظت کمی از مس را نشان داده است. همچنین گمانه های اکتشافی حفر شده در منطقه، در بهترین حالت فقط پیریت را نشان داده است. بدین ترتیب منطقه آستامال شامل کانی سازی پورفیری نبوده و صرفاً آنومالی های ایجاد شده در آن اندکی بیشتر از زمینه است. همچنین وجود اندیس های مس در منطقه، به دلیل اسکارن زایی آهک است که منجر به تمرکز مس شده است (Ziaii et al., 2009).


گمانه ۱ و ۲ تغییرات عناصر Cu, Mo, Pb و Zn را از عمق ۱۰ تا ۱۰۰ متر از سطح زمین نشان داده است. در گمانه ۱، شاخص زونالیت تا عمق ۱۰۰ متر تقریباً روند ثابتی را نشان داده است و عیار عنصر مس در

عمق ۶۰ متر افزایش و بیشترین مقدار خود را داشته ولی مقدار آن برای وجود یک کانی‌سازی اقتصادی در عمق، بسیار کم است و در ارتباط با کانی‌سازی پراکنده است. در گمانه ۲، شاخص زونالیته مانند گمانه ۱ روند ثابتی را نشان داده است ولی غلظت عنصر مس به شدت کاهش یافته است. بدین ترتیب این گمانه عقیم بودن از کانی‌سازی را در عمق نشان داده است (شکل ۴-۲۵).



شکل ۴-۲۵: تغییرات غلظت مس و شاخص زونالیته در گمانه ۱ (الف) و گمانه ۲ (ب) در منطقه آستمال (صفری، ۱۳۹۶)

در شکل ۴-۲۶ محل گمانه‌های ۱ و ۲ بر روی نقشه‌های کانی‌سازی پنهان اقتصادی بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی نشان داده شده است. با توجه به این شکل، گمانه ۱ در زون I که به وسیله الگوی ارائه شده کانی‌سازی پراکنده غیراقتصادی معرفی شده و گمانه ۲ در بخش زمینه که ارزش اقتصادی ندارد نمایان شده است. همچنین گمانه ۱ در نقشه بدست آمده از خودرمنگار پشته‌ای برای مناطق کانی‌سازی پنهان، در بخش آنومالی ضعیف و در نقشه بدست آمده از شبکه عصبی همگشتی برای مناطق کانی‌سازی پنهان، در آنومالی قوی نمایان شده است.




شکل ۴-۲۶: محل گمانه‌ها و زون‌های I و II در منطقه آستمال؛ (الف) نقشه کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای؛ (ب) نقشه کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی

۴-۵-۲- منطقه سونگون


مطالعات پیشین ژئوشیمیایی در منطقه سونگون در طی سال‌های ۱۹۷۹ تا ۱۹۹۳، محدوده جنوب شرقی این منطقه را به عنوان کانی‌سازی پنهان معرفی کرده است که بعدها به نام سونگون ۱ شناخته شده است. میزان ذخیره در این محدوده حدود ۳۰۰ میلیون تن همراه با عیار ۰/۶۶ درصد برای مس و ۲۴۰ ppm برای مولیبدن است. از بخش غربی و شمال غربی منطقه سونگون تا مدت‌ها اطلاعاتی موجود نبود و این محدوده در آن زمان به عنوان محل باطله استفاده شده است. در سال ۱۹۹۴ به وسیله شاخص زونالیت‌ها این محدوده به عنوان کانی‌سازی پنهان و به نام سونگون ۲ معرفی شده است. لازم به ذکر است مجموع ذخایر در سونگون ۱ و ۲ حدود یک میلیارد تن برآورد شده است (Ziaii et al., 2009).

در منطقه سونگون گمانه‌های زیادی حفاری شده است. در این پژوهش برخی از گمانه‌های در ارتباط با کانی‌سازی پنهان که اطلاعات عمقی آن‌ها موجود است، بررسی شده است. همچنین اطلاعات عمقی گمانه‌های ۶۶، ۶۹ و ۷۸ برای تغییرات عناصر Cu, Mo, Pb و Zn، وجود کانی‌سازی پنهان اقتصادی را در عمق ۶۰۰ متر تایید کرده است. در شکل ۴-۲۷ تغییرات غلظت مس و شاخص زونالیت‌ها گمانه ۶۶ از سطح زمین تا عمق ۶۰۰ متر را نشان داده شده که شاخص زونالیت‌ها در آن روند کاهشی داشته ولی مقدار غلظت مس افزایش یافته است.


در شکل ۴-۲۹ تغییرات غلظت مس و شاخص زونالیت گمانه ۷۸ از سطح تا عمق ۵۵۰ متر را نشان داده شده که شاخص زونالیت در آن روند کاهشی داشته ولی غلظت مس تا عمق ۵۵۰ متری افزایش یافته است. این دو گمانه رفتار مشابهی دارند ولی در گمانه ۶۹ با عمق ۵۰۰ متر از سطح زمین، شاخص زونالیت تا عمق ۲۰۰ متر روند کاهشی نشان داده است و در عمق ۳۰۰ متر مجدد افزایش و بعد از این عمق کاهش یافته است. این فرآیند بیانگر وجود کانی سازی تا عمق ۲۰۰ متر است که بعد از این عمق کانی سازی محو شده و در عمق ۳۰۰ متری مجدد کانی سازی تکرار شده است (شکل ۴-۲۸).



شکل ۴-۲۷: تغییرات غلظت مس و شاخص زونالیت در گمانه ۶۶ در منطقه سونگون (صفری، ۱۳۹۶)




شکل ۴-۲۸: تغییرات غلظت مس و شاخص زونالیت در گمانه ۶۹ در منطقه سونگون (صفری، ۱۳۹۶)



شکل ۴-۲۹: تغییرات غلظت مس و شاخص زونالیت در گمانه ۷۸ در منطقه سونگون (صفری، ۱۳۹۶)

در شکل ۴-۳۰ محل گمانه‌های ۶۶، ۶۹ و ۷۸ بر روی نقشه‌های کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی نشان داده شده است. گمانه ۶۶ و ۷۸ تطابق مکانی خوبی با نقشه‌های بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی داشته است. این دو گمانه در نقشه بدست آمده از خودرمنگار پشته‌ای در کلاس آنومالی قوی نشان داده شده است ولی مقدار شاخص زونالیت در گمانه ۷۸ کمتر از گمانه ۶۶ است که این تفکیک به خوبی در نقشه بدست آمده از شبکه عصبی همگشتی نمایان شده است. در نقشه مناطق کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی، گمانه ۶۶ در کلاس آنومالی قوی و گمانه ۷۸ در کلاس آنومالی متوسط تشخیص داده شده است. همچنین گمانه ۶۹ که از لحاظ شاخص زونالیت مقدار کمتری نسبت به دو گمانه دیگر داشته، به وسیله خودرمنگار پشته‌ای شناسایی نشده است ولی شبکه عصبی همگشتی به دلیل تقسیم‌بندی منطقه سونگون در ۵ کلاس به خوبی با گمانه ۶۹ تطابق مکانی داشته است. همچنین وجود گمانه‌ها به خوبی نتایج بدست آمده از الگوی ارائه شده را در زون‌های I و II که معرف کانی‌سازی پنهان اقتصادی است را تایید کرده است.



شکل ۴-۳۰: محل گمانه‌ها و زون‌های I و II در منطقه سونگون؛ (الف) نقشه کانی‌سازی پنهان بدست آمده از خودمرزنگار پشته‌ای؛ (ب) نقشه کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی

۴-۶- جمع‌بندی و نتیجه‌گیری

در این فصل الگویی برای ترکیب و ایجاد ارتباط بین یادگیری عمیق و زونالیت‌ه ژئوشیمیایی مطرح شده است. این الگو شامل ۷ مرحله اصلی است که هر مرحله به مرحله قبل وابسته است و نتیجه هر مرحله در پاسخ نهایی الگو تاثیر مستقیم داشته است. این وابستگی از نقاط قوت الگوی ارائه شده است زیرا در طی چند مرحله مختلف به وسیله استفاده‌های متفاوت از الگوریتم‌های یادگیری عمیق تحت آموزش نظارت نشده و نظارت شده، ویژگی‌ها و الگوهای پیچیده و پنهان بین داده‌های ژئوشیمیایی استخراج شده است.

الگوی ارائه شده به منظور تشخیص مناطق کانی‌سازی پنهان اقتصادی در مناطق سونگون و آستامال بررسی شده است. در مرحله اول به منظور خوشه‌بندی و تعیین تعداد نوروں لایه رمز خودرمنگار پشته‌ای و تعداد نوروں خروجی شبکه عصبی همگشتی، روش کا-میانگین بر روی شاخص زونالیتة در مناطق سونگون و آستامال اعمال شده که تعداد خوشه‌ها بر اساس ضریب شبیح و روند ساختار زمین‌شناسی و مناطق محتمل آنومالی در مناطق مورد مطالعه تعیین شده است. بدین ترتیب تعداد ۳ خوشه برای منطقه آستامال و برای منطقه سونگون تعداد خوشه‌های ۳، ۴ و ۵ انتخاب شده است. در مرحله دوم به وسیله خودرمنگار پشته‌ای، نقشه آنومالی عناصر Cu, Mo, Pb, Zn و عناصر ضربی فوق کانسار و تحت کانسار به صورت جداگانه در ۳ کلاس برای منطقه آستامال و ۵ کلاس برای منطقه سونگون حاصل شده است. در مرحله سوم نقاط کانی‌سازی پنهان در مناطق آستامال و سونگون به صورت جداگانه به وسیله خودرمنگار پشته‌ای و تنظیم دقیق در ۳ کلاس تشخیص داده شده که از نتایج بدست آمده از این مرحله در برچسب‌گذاری داده‌های مرحله بعد استفاده شده است. در مرحله چهارم از خودرمنگار پشته‌ای و تنظیم دقیق به منظور تشخیص مناطق کانی‌سازی پنهان استفاده شده است. برای ایجاد داده‌های برچسب‌دار در منطقه آستامال از نتایج مرحله قبل استفاده شده و در منطقه سونگون که چند تعداد خوشه انتخاب شده است، برای تعیین تعداد نوروں لایه رمز از خوشه‌بندی مجدد نتایج بدست آمده از مرحله قبل با شاخص زونالیتة استفاده شده است. در این مرحله مناطق کانی‌سازی پنهان منطقه آستامال در ۳ کلاس و منطقه سونگون در ۴ کلاس تشخیص داده شده‌اند. در مرحله پنجم به وسیله نتایج بدست آمده از مراحل قبل، مناطق کانی‌سازی پنهان به وسیله شبکه عصبی همگشتی تشخیص داده شد. در این مرحله مجموعه ورودی از نقشه آنومالی عناصر در سطوح مختلف آنومالی ایجاد شده و برای ایجاد داده‌های برچسب‌دار، نتایج بدست آمده از مرحله قبل با شاخص زونالیتة به وسیله روش کا-میانگین مجدد خوشه‌بندی شده و تعداد خوشه‌ها در منطقه آستامال و سونگون به ترتیب برابر ۳ و ۵ است. بدین ترتیب مناطق کانی‌سازی پنهان بدست آمده از شبکه عصبی همگشتی در منطقه آستامال و سونگون به ترتیب در ۳ و ۵ کلاس تشخیص داده شد. لازم به ذکر است به دلیل بررسی بهتر عملکرد الگوی ارائه شده در تشخیص مناطق کانی‌سازی پنهان، دو مرحله آخر الگو که شامل تعیین نوع کانی‌سازی و ارزیابی نتایج است بر روی مناطق کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی بررسی شده است. بدین ترتیب

مناطق کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی به زون‌های مختلفی در مناطق مورد مطالعه تقسیم شده که در هر زون کلاس‌های مختلف آنومالی وجود داشته است. پس از محاسبه مقدار زمینه برای عناصر Cu, Mo, Pb و Zn در مناطق غیرآنومالی نقشه آنومالی عناصر مربوطه، سطح از فرسایش و نوع کانی‌سازی در این زون‌ها تعیین شده است. بدین ترتیب زون‌های I و II در منطقه آستمال در ارتباط با کانی‌سازی پراکنده غیراقتصادی و زون‌های I و II در منطقه سونگون در ارتباط با کانی‌سازی پنهان اقتصادی تعیین شده است. همچنین با بررسی و تطابق مکانی گمانه‌ها در مناطق مورد مطالعه با نقشه مناطق کانی‌سازی پنهان بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی و نوع کانی‌سازی تعیین شده در زون‌های مناطق مورد مطالعه، نتایج بدست آمده ارزیابی شده است. در ادامه دلیل بررسی ۲ مرحله پایانی الگوی ارائه شده برای نتایج بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی بررسی شده است.

در الگوی ارائه شده تشخیص مناطق کانی‌سازی پنهان و تعیین نوع کانی‌سازی به منظور تشخیص کانی‌سازی پنهان اقتصادی به وسیله نتایج بدست آمده از شبکه عصبی همگشتی است. البته تشخیص مناطق کانی‌سازی پنهان اقتصادی در این الگو به همه ۷ مرحله به صورت پیوسته و متصل استوار است و از اطلاعات مفیدی که از هر مرحله استخراج شده است در تشخیص مناطق کانی‌سازی پنهان اقتصادی استفاده شده است.

با توجه به این نکته، تفاوت در نتایج بدست آمده در تشخیص توزیع آنومالی مناطق کانی‌سازی پنهان به وسیله خودرمنگار پشته‌ای و شبکه عصبی همگشتی دلیل بر عدم کارآمدی خودرمنگار پشته‌ای نیست. به وسیله خودرمنگار پشته‌ای در مراحل مختلف الگوی ارائه شده با آموزش نظارت نشده و نظارت شده اطلاعات مفید از داده‌های ژئوشیمیایی استخراج شده و دلیل عملکرد مناسب شبکه عصبی همگشتی نیز مبتنی بر اطلاعات بدست آمده از خودرمنگار پشته‌ای است. با بررسی گمانه‌های موجود در مناطق مورد مطالعه، عملکرد خودرمنگار پشته‌ای و شبکه عصبی همگشتی در تشخیص مناطق کانی‌سازی پنهان ارزیابی شده است. وجود گمانه‌ها در زون‌های معرفی شده نشان دهنده عملکرد قابل قبول خودرمنگار پشته‌ای و شبکه عصبی همگشتی در تشخیص زون‌های کانی‌سازی پنهان است ولی به منظور ارتباط مکانی با گمانه‌ها و تعیین محل حفاری برای ادامه عملیات اکتشاف، شبکه عصبی همگشتی عملکرد بهتری در تشخیص مناطق کانی‌سازی پنهان اقتصادی نسبت به خودرمنگار پشته‌ای نشان داده است. دلیل این اتفاق در نوع شبکه خودرمنگار پشته‌ای است که

صرفاً با لایه‌های تمام متصل برای بررسی تصاویر نسبت به شبکه عصبی همگشتی عملکرد ضعیف‌تری داشته است.

در منطقه سونگون، خودرمنگار پشته‌ای در تشخیص گمانه‌ای که شاخص زونالیت‌ها در آن کم است و تفکیک دو گمانه با شاخص زونالیت‌ها متفاوت عملکرد خوبی نداشته ولی شبکه عصبی همگشتی به دلیل خاصیت منحصربه‌فرد خود، منطقه سونگون را به ۵ کلاس تقسیم کرده و در تطابق مکانی با گمانه‌ها عملکرد بسیار خوبی داشته است. لازم به ذکر است در منطقه آستامال نیز مشابه منطقه سونگون فرآیند الگو انجام شده است ولی با توجه به تعداد گمانه‌های در دسترس نمی‌توان منطقه آستامال را مانند منطقه سونگون از لحاظ کارایی شبکه بررسی نمود. با توجه به مقادیر خطا، صحت و نوع ساختار خودرمنگار پشته‌ای در تشخیص مناطق کانی‌سازی پنهان، این احتمال وجود دارد که نتایج بدست آمده از این شبکه در شناسایی ویژگی‌های پیچیده نقشه‌های آنومالی در آموزش نظارت نشده عملکرد محدودی داشته است. البته اعمال تنظیم دقیق این مشکل را تا حد قابل قبولی بهبود بخشیده است. بدین ترتیب با توجه به مراحل ۷ گانه الگوی ارائه شده، شبکه عصبی همگشتی با توجه به ویژگی‌های خاص شبکه‌ای، خطا، صحت و اطلاعات بدست آمده از مراحل قبل الگو، مشابه منطقه سونگون در منطقه آستامال نیز بر خودرمنگار پشته‌ای در تشخیص مناطق کانی‌سازی پنهان اقتصادی ارجحیت داشته است.

به طور کلی استفاده از الگوی ارائه شده در مناطق سونگون و آستامال منجر به تفکیک آنومالی از زمینه در کلاس‌های مختلف بدون محاسبه زمینه و حدآستانه، تشخیص نقاط کانی‌سازی پنهان در کلاس‌های مختلف، تشخیص مناطق کانی‌سازی پنهان در کلاس‌های مختلف و تعیین نوع کانی‌سازی پنهان اقتصادی و پراکنده غیراقتصادی شده است. علاوه بر موارد ذکر شده، الگوی ارائه شده منجر به برطرف شدن بسیاری از مشکلات روش زونالیت‌ها ژئوشیمیایی و توسعه‌ای برای این روش شده است. همچنین نتایج بدست آمده از این الگو بدون نیاز به بانک اطلاعات پیچیده و فقط به وسیله داده‌های ژئوشیمیایی برای تعیین مناطق حفاری و ادامه مراحل اکتشاف کارآمد است.

فصل پنجم

نتیجه‌گیری و پیشنهادات

۵-۱- نتیجه گیری

بر اساس کارهای انجام شده در این پژوهش و با توجه به داده‌های موجود، الگویی برای ترکیب و ایجاد ارتباط بین یادگیری عمیق و زونالیته ژئوشیمیایی ارائه شده و به منظور تشخیص کانی‌سازی پنهان اقتصادی در مناطق سونگون و آستامال بررسی شده است. به طور کلی نتایج نشان داده است که ترکیب یادگیری عمیق با زونالیته ژئوشیمیایی، روشی نوین و کاربردی برای ارزیابی و تفکیک آنومالی‌ها و تشخیص مناطق کانی‌سازی پنهان اقتصادی در کانسارهای مس پورفیری محسوب خواهد شد.

الگوی ۷ مرحله‌ای ارائه شده در این پژوهش نشان دهنده تاثیر مثبت کاربرد یادگیری عمیق در ژئوشیمی معادن و توسعه‌ای برای روش زونالیته ژئوشیمیایی است. این الگو در تفکیک آنومالی از زمینه در کلاس‌های مختلف، تشخیص آنومالی‌های ضعیف تا قوی مناطق کانی‌سازی پنهان و تشخیص نوع کانی‌سازی پنهان اقتصادی و پراکنده غیراقتصادی عملکرد مناسبی داشته است.

چند مرحله‌ای بودن این الگو منجر به استخراج ویژگی‌های مختلف، شناسایی روابط پنهان پیچیده و غیرخطی بین داده‌های ژئوشیمیایی شده است. چرا که این الگو صرفاً به یک الگوریتم متکی نبوده و با استفاده از آموزش نظارت نشده و نظارت شده به وسیله الگوریتم‌های مختلف یادگیری عمیق در ۷ مرحله اطلاعات استخراج شده است. به عنوان مثال به واسطه ارتباط این مراحل با یکدیگر در تشخیص مناطق کانی‌سازی پنهان به وسیله شبکه عصبی همگشتی مجموعه ورودی، برچسب‌ها و حتی تعداد کلاس‌های خروجی شبکه از مراحل مختلف الگوی ارائه شده بدست آمده و این فرآیند تا ارزیابی نتایج نیز برقرار است. بدین ترتیب الگوی ارائه شده منجر به کاهش عدم قطعیت و تشخیص بهتر مناطق کانی‌سازی پنهان اقتصادی خواهد شد.

با توجه به نتایج بدست آمده از این الگو در مناطق سونگون و آستامال، زون‌های I و II در منطقه آستامال و بالتبع آن کل منطقه آستامال به عنوان کانی‌سازی پراکنده غیراقتصادی و زون‌های I و II در منطقه سونگون به عنوان کانی‌سازی پنهان اقتصادی در سطوح مختلف آنومالی تشخیص داده شد. لازم به ذکر است مقادیر خطا و صحت شبکه عصبی همگشتی در تشخیص کانی‌سازی پنهان به ترتیب در منطقه آستامال برابر ۰/۰۰۲ و ۰/۹۸ و در منطقه سونگون برابر ۰/۰۱۷ و ۰/۹۰ است.

لازم به ذکر است نتایج بدست آمده از الگوی ارائه شده بدون استفاده از مناطق گمانه‌ها، اطلاعات زمین‌شناسی و بدون وابستگی به بانک اطلاعات پیچیده و صرفاً بر اساس داده‌های ژئوشیمیایی حاصل شده است. بدین ترتیب با استفاده الگوی ارائه شده بدون انجام حفاری در منطقه مورد مطالعه و تنها بر اساس داده‌های ژئوشیمیایی، کانی‌سازی پنهان اقتصادی تشخیص داده شده و نقشه آنومالی مربوطه در جهت تعیین محل حفاری و برنامه‌ریزی فعالیت‌های اکتشافی کارآمد است.

۵-۲- پیشنهادات

- با توجه به مطالب ارائه شده در این پژوهش، در ادامه پیشنهاداتی برای توسعه الگوی ارائه شده و ادامه فرآیند اکتشاف در مناطق مورد مطالعه برای کمک به محققان بعدی بیان شده است.
- حفر گمانه‌های اکتشافی به منظور تعیین عمق کانی‌سازی و اکتشاف تفضیلی در مناطق با آنومالی قوی بدست آمده از الگوی ارائه شده در زون II و سپس زون I منطقه سونگون.
 - اکتشاف تفضیلی و حفر گمانه‌های اکتشافی به منظور تشخیص ارزش اقتصادی مناطق آنومالی متوسط و ضعیف در زون II و سپس زون I منطقه سونگون.
 - حفر گمانه‌های اکتشافی در مناطق با آنومالی قوی زون‌های I و II منطقه آستامال به منظور بررسی بهتر نتایج بدست آمده از خودرمنگار پشته‌ای و شبکه عصبی همگشتی در تشخیص کانی‌سازی پنهان.
 - مبنای تئوری یادگیری عمیق در ابتدای راه فعالیت خود است. بدین ترتیب نیاز به ارائه تئوری توسعه یافته در راستای بهینه‌سازی پارامترهای الگوریتم‌ها به خصوص در بررسی ژئوشیمیایی ضروری است.
 - بررسی الگوریتم‌های یادگیری عمیق متفاوت با الگوریتم‌های بررسی شده در الگو ارائه شده، به منظور بررسی عملکرد الگوریتم‌های استفاده شده.
 - استفاده از الگوی ارائه شده در مراحل مختلف اکتشاف، در مقیاس معدنی تا ناحیه‌ای برای تشخیص کانی‌سازی پنهان اقتصادی.
 - بررسی الگوی ارائه شده برای تشخیص کانی‌سازی پنهان اقتصادی در دیگر ذخایر معدنی.
 - توسعه الگوی ارائه شده به منظور تشخیص همزمان مناطق کانی‌سازی پنهان اقتصادی و سطح از فرسایش.
 - استفاده از الگوی معرفی شده برای بررسی اطلاعات گمانه‌ها به منظور مدل‌سازی ماده معدنی.

واژه‌نامه

Accuracy	صحت
Activation Function	تابع فعال‌ساز
Adaptive Moment Estimation (ADAM)	برآورد تکانه تطبیقی
Advanced Spaceborne Thermal Emission Reflection Radiometer (ASTER)	سنجنده استر
Alteration	دگرسانی
Artificial Neural Network (ANN)	شبکه عصبی مصنوعی
Autoencoder (AE)	خودرمزنگار
Average Pooling	ادغام میانگین
Backpropagation	پس‌انتشار
Band Ratios	نسبت‌های باندی
Binary Cross Entropy	آنترپی متقاطع باینری
Blind Mineralization (BM)	کانی‌سازی پنهان
Categorical Cross Entropy	آنترپی متقاطع دسته‌ای
Classification	کلاس‌بندی
Clustering	خوشه‌بندی
Code	لایه رمز
Concentration gradient	گرادیان غلظت
Confusion matrix	ماتریس درهم‌ریختگی
Constrained Energy Minimization	کمینه‌ساز انرژی مقید
Continental Margin Seduction Zones	زون فرورانش حاشیه قاره‌ها
Convolutional Autoencoder (CAE)	خودرمزنگار همگشتی

Convolutional Layer	لایه همگشت
Convolutional Neural Network (CNN)	شبکه عصبی همگشتی
Cross Entropy	آنتروپی متقاطع
Data preparation	آماده‌سازی داده‌ها
Decoder	لایه رمزگشا
Deep Autoencoder (DAE)	خودرمزنگار عمیق
Deep Belief Network (DBN)	باور عمیق
Deep Convolutional Neural Network	شبکه عصبی پیچشی عمیق
Deep learning	یادگیری عمیق
Directional filters	فیلترهای جهت‌دار
Dropout	حذف تصادفی
Encoder	لایه رمزگذار
Epoch	مرحله تکرار
Feature map	نقشه ویژگی
Feed Forward Neural Networks	شبکه‌های عصبی پیش‌خور
Fine Tuning	تنظیم دقیق
Flatten	لایه برداری
Frequency	توزیع فراوانی
Fully Connected Layer	لایه تمام متصل
Fuzzy C-Means	میانگین c-فازی
Generalization	قابلیت تعمیم
Generative Adversarial Networks (GAN)	شبکه مولد تخصصی

Gradient descent	گرادیان کاهش
Halo	هاله
Hyperbolic Tangent	تانژانت هذلولی
Internal Average Relative Reflectance	بازتاب نسبی متوسط داخلی
Inverse Distance Weighting (IDW)	وزن دهی بر مبنای عکس فاصله
Island Arcs	جزایر قوسی
K-means	کا-میانگین
Label	برچسب
Level of erosion	سطح از فرسایش
Lineament	خطواره
Logical operator algorithm	الگوریتم عملگرهای منطقی
Loss Function	تابع هزینه
Max Pooling	ادغام حداکثری
Mean Absolute Error	میانگین خطای قدرمطلق
Mean Squared Error (MSE)	میانگین خطای مربعات
Mixture-Tuned Matched-Filtering	فیلترگذاری انطباقی
Multi-Autoencoder (MAE)	خودرمزننگار چندگانه
Multi-Convolutional Autoencoder (MCA)	خودرمزننگار چندگانه پیچشی
Neuron	نورون
Outlier	داده‌های خارج از ردیف
Overfitting	بیش‌برازش
Padding	لایه‌گذاری

Pooling Layer	لایه ادغام
Precision	دقت
Principal Component Analysis (PCA)	تحلیل مولفه‌های اصلی
Rectified Linear Unit (RELU)	یکسوساز خطی
Recurrent Neural Networks (RNN)	شبکه عصبی بازگشتی
Regularization	منظم‌سازی
Representation learning	یادگیری بازنمایی
Restricted Boltzmann Machines (RBM)	ماشین‌های بولتزمن محدود پیوسته
Same padding	لایه‌گذاری یکسان
Sensor Radiance	تابشی سنجنده
Silhouette	ضریب شبج
Softmax	بیشینه هموار
Sortwave Infrared (SWIR)	محدوده مادون قرمز کوتاه
Spatially Constrained Multi-Autoencoder (SCMA)	خودرمزنگار فضایی محدود کننده
Stacked Autoencoder (SAE)	خودرمزنگار پشته‌ای
Stochastic gradient descent	گرادیان کاهش تصادفی
Strides	پرش‌ها
Sub-ore	تحت کانسار
Supervised learning	یادگیری نظارت شده
Supra-ore	فوق کانسار
Test data	مجموعه آزمایش
Thermal Infrared (TIR)	محدوده حرارتی

Training data	مجموعه آموزش
Transfer Learning	یادگیری انتقالی
Underfitting	کم‌پرازش
Unsupervised learning	یادگیری نظارت نشده
Validation data	مجموعه اعتبار سنجی
Variational Autoencoder (VAE)	خودرمزنگار متغییر
Visible-Near Infrared (VNIR)	محدوده مرئی-مادون قرمز نزدیک
Zone Dispersed Mineralization (ZDM)	کانی‌سازی پراکنده

منابع

- آگاروال، چ. س. (۱۳۹۸). شبکه‌های عصبی و یادگیری عمیق. مترجم ایوب ترکیان. انتشارات نیاز دانش، تهران.
- اخیانی، م.، خرقانی، م.، رحیمی، م.، سرشکی، ف. (۱۳۹۳). بارزسازی پهنه‌های دگرسانی کمر بند آتشفشانی نفوذی تروند چاه‌شیرین با استفاده از روش‌های مختلف پردازش تصویر ASTER. فصلنامه علمی-پژوهشی علوم زمین، ۲۴(۹۴)، ۱۱۶-۱۰۷.
- چراغی، ز.، فرهپور. م.، ساریخانی، ر.، قاسمی، آ. (۱۳۹۴). استخراج خطواره‌ها و شکستگی‌های خرم‌آباد از تصاویر سنجنده Landsat8 و ASTER با استفاده از روش بصری و رقومی خودکار. فصلنامه زمین-ساخت، ۱(۴)، ۹۴-۷۷.
- خجسته‌فر، س.، رنجبر، ح. ا. (۱۳۹۵). برای بارزسازی کانی‌های موجود در دگرسانی گرمابی از کدام روش پیش‌پردازش جوی روی داده‌های استر استفاده کنیم؟. مجموعه مقالات سی و پنجمین گردهمایی علوم زمین.
- خوئی، ن.، قربانی، م.، تاجبخش، پ. (۱۳۷۸). کانسارهای مس در ایران. انتشارات سازمان زمین‌شناسی و اکتشافات معدنی.
- شوله، ف. (۱۳۹۸). یادگیری عمیق با پایتون. مترجم ایوب ترکیان. انتشارات نیاز دانش، تهران.
- شیرازی، ع.، ضیائی، م.، هزارخانی، ا. (۱۳۹۸). بررسی رفتار ژئوشیمیایی عنصر مس به روش کا-میانگین و پیش‌بینی آن با شبکه عصبی مصنوعی در منطقه کیوی، استان اردبیل. نشریه علمی پژوهشی مهندسی معدن. ۱۴(۴۵)، ۱۱۲-۹۶.
- صفری، س. (۱۳۹۶). ارائه مدلی جهت تفکیک کانی‌سازی‌های پورفیری پنهان اقتصادی از پراکنده در کمر بند ارومیه-دختر. رساله دکتری، دانشگاه صنعتی شاهرود، سمنان.
- عباس‌زاده، م.، هزارخانی، ا.، سلطانی محمدی، س. (۱۳۹۸). مرزبندی زون‌های دگرسانی پتاسیک و فلیک بر اساس نتایج حاصل از مدل‌سازی سه بعدی داده‌های میانبارهای سیال به روش شبکه‌های عصبی مصنوعی. فصلنامه علمی-پژوهشی علوم زمین، ۲۹(۱۳)، ۱۲۲-۱۱۵.

علوی، غ.، حسین‌زاده، م.، موید، م. (۱۳۹۳). سنگ‌نگاری و سنگ‌شناسی توده پورفیری کانسار مس سونگون و دایک‌های پس از کانی‌سازی با نگرشی بر اسکارن همراه (شمال ورزقان-آذربایجان شرقی). پترولوژی، ۱۷، ۷.

لی، و. م. (۱۳۹۹). پایتون-یادگیری ماشین. مترجم ایوب ترکیان. انتشارات نیاز دانش، تهران.

محبی، آ.، بهزادی، م.، میرنژاد، ح.، تقی‌زاده، ح. (۱۳۹۲). شناسایی هاله‌های دگرسانی همراه با کانه‌زایی مس پورفیری در کوه هنزا با استفاده از تصاویر ASTER. سنجش از دور و GIS ایران، ۵(۲)، ۶۴-۵۳.

محمدپور، م. ا.، ویسی، خ. ا.، بحرودی، ع. (۱۳۹۸). استخراج اتوماتیک خطواره‌های زمین‌شناسی از تصاویر ASTER با استفاده از تبدیل هاف، برگه ۱:۱۰۰۰۰۰ جبال بارز. زمین‌شناسی کاربردی پیشرفته، ۹(۴)، ۳۷۴-۳۹۱.

معصومی، ا.، رنجبر، ح. ا. (۱۳۹۶). بارزسازی دگرسانی‌های گرمابی در تصاویر استر منطقه سرچشمه با استفاده از عملگرهای منطقی. نشریه علمی-پژوهشی روش‌های تحلیلی و عددی در مهندسی معدن، ۱۴، ۷۱-۶۱.

معصومی، ف. ا.، رنجبر، ح. ا. (۱۳۹۰). نقشه‌برداری مناطق دگرسان شده با استفاده از تصاویر سنجنده‌های استر و ETM+ در نیمه شمالی نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ بافت. فصلنامه علمی-پژوهشی علوم زمین، ۷۹، ۱۲۱-۱۲۸.

هزارخانی، ا.، شکوه سلجوقی، ب. (۱۳۹۷). شبکه‌های عصبی مصنوعی و کاربردهای آن در مهندسی اکتشاف معدن. انتشارات دانشگاه صنعتی امیرکبیر، تهران.

هزارخانی، ا.، طهماسبی، پ.، اصغری، ا. (۱۳۸۹). تفکیک دگرسانی‌های کانسار مس سونگون با استفاده از شبکه‌های عصبی مصنوعی. فصلنامه علمی-پژوهشی علوم زمین، ۷۷، ۴۱.

Adiri, Z., El Harti, A., Jellouli, A., Lhissou, R., Maacha, L., Azmi, M., Zouhair, M., Bachaoui, E. M. (2017). Comparison of Landsat-8, ASTER and Sentinel 1 satellite remote sensing data in automatic lineaments extraction: A case study of Sidi Flah-Bouskour inlier, Moroccan Anti Atlas. *Advances in Space Research*, 60(11), 2355-2367.

Aliyari, F., Afzal, P., Lotfi, M., Shokri, S., Feizi, H. (2020). Delineation of geochemical haloes using the developed zonality index model by multivariate and fractal analysis in the Cu-Mo porphyry deposits. *Applied Geochemistry*, 121, 104694.

- Aouedi, O., Piamrat, K., Bagadthey, D. (2020). A semi-supervised stacked autoencoder approach for network traffic classification. 2020 IEEE 28th International Conference on Network Protocols (ICNP), 1-6.
- Ayoobi, I., Tangestani, M. H. (2017). Evaluation of relative atmospheric correction methods on ASTER VNIR–SWIR data in playa environment. *Carbonates and Evaporites*, 32(4), 539-546.
- Baldi, P., Sadowski, P. J. (2013). Understanding dropout. *Advances in neural information processing systems*, 26(1), 2814-2822.
- Bengio, Y., Lamblin, P., Popovici, D., Larochelle, H. (2007). Greedy layer-wise training of deep networks. *Advances in neural information processing systems*, 153-160.
- Beus, A.A., Grigorian, S.V. (1977). *Geochemical Exploration Methods for Mineral Deposits*. Applied Publishing Ltd., Wilmette, Illinois.
- Bishop, C. M. (2007). *Pattern recognition and machine learning*. New York, Springer.
- Carranza, E. J. M., Hale, M. (2002). Where are porphyry copper deposits spatially localized? A case study in Benguet province, Philippines. *Natural Resources Research*, 11(1), 45-59.
- Chen, L., Guan, Q., Feng, B., Yue, H., Wang, J., Zhang, F. (2019b). A multi-convolutional autoencoder approach to multivariate geochemical anomaly recognition. *Minerals*, 9(5), 270.
- Chen, L., Guan, Q., Xiong, Y., Liang, J., Wang, Y., Xu, Y. (2019a). A Spatially Constrained Multi Autoencoder approach for multivariate geochemical anomaly recognition. *Computers & Geosciences*, 125, 43-54.
- Emmons, W. H. (1933). On the mechanism of the deposition of certain metalliferous lode systems associated with granitic batholiths. *Ore deposits of the western States*: New York. American Institute of Mining and Metallurgical Engineers, 327-349.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), 861-874.
- Fersman, A. E. (1939). *Geochemical and Mineralogical Methods of Prospecting for Mineral Deposits*. Publishing Akad.
- Girshick, R., Donahue, J., Darrell, T., Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 580-587.
- Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep learning*. MIT press.
- Grigorian, S.V. (1992). *Mining Geochemistry*. Nedra Publishing House, Moscow.

- Grigorian, S.V. (1994). Geochemical exploration in Sungun area. Report of Ahar Copper Complex Company. NICICO.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27-48.
- Hamedani, M. L., Plimer, I. R., Xu, C. (2012). Orebody modelling for exploration: the Western mineralisation, Broken Hill, NSW. *Natural resources research*, 21(3), 325-345.
- Hamimi, Z., Hagag, W., Kamh, S., El-Araby, A. (2020). Application of remote-sensing techniques in geological and structural mapping of Atalla Shear Zone and Environs, Central Eastern Desert, Egypt. *Arabian Journal of Geosciences*, 13, 414.
- Harraz, H. Z., Hamdy, M. M. (2015). Zonation of primary haloes of Atud auriferous quartz vein deposit, Central Eastern Desert of Egypt: A potential exploration model targeting for hidden mesothermal gold deposits. *Journal of African Earth Sciences*, 101, 1-18.
- Hinton, G. E., Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504-507.
- Imamalipour, A., Karimlou, M., Hajalilo, B. (2019). Geochemical zonality coefficients in the primary halo of Tavreh mercury prospect, northwestern Iran: implications for exploration of listwaenitic type mercury deposits. *Geochemistry: Exploration, Environment, Analysis*, 19(4), 347-357.
- Kingma, D. P., Ba, J. L. (2015). Adam: a Method for Stochastic Optimization. *International Conference on Learning Representations*, 1–13.
- Kitaev, N.A. (1991). Multidimensional analysis of geochemical fields. *Mathematical Geology*, 23, 15–32.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Li, H., Li, X., Yuan, F., Jowitt, S. M., Zhang, M., Zhou, J., Zhou, T., Xiangling, L., Ge, C., Wu, B. (2020). Convolutional neural network and transfer learning based mineral prospectivity modeling for geochemical exploration of Au mineralization within the Guandian–Zhangbaling area, Anhui Province, China. *Applied Geochemistry*, 122, 104747.

- Li, H., Zhang, G. Y., Yu, B. (2006). Tectonic primary halo model and the prospecting effect during deep buried ore prospecting in gold deposits. Geological Publishing House, Beijing.
- Liu, C., Hu, S., Ma, S., Tang, L. (2014). Primary geochemical patterns of Donggua Mountain laminar skarn copper deposit in Anhui, China. *Journal of Geochemical Exploration*, 139, 152-159.
- Liu, G., Bao, H., Han, B. (2018). A stacked autoencoder-based deep neural network for achieving gearbox fault diagnosis. *Mathematical Problems in Engineering*, 2018.
- Lowell, J. D., Guilbert, J. M. (1970). Lateral and vertical alteration-mineralization zoning in porphyry ore deposits. *Economic geology*, 65(4), 373-408.
- Luo, Z., Xiong, Y., Zuo, R. (2020). Recognition of geochemical anomalies using a deep variational autoencoder network. *Applied Geochemistry*, 122, 104710.
- Mars, J. C. (2013). Hydrothermal alteration maps of the central and southern basin and range province of the United States compiled from advanced spaceborne thermal emission and reflection radiometer (ASTER) data. U.S. Geological Survey Open-File Report 2013–1139.
- Mars, J. L. (2014). Regional mapping of hydrothermally altered igneous rocks along the Urumieh Dokhtar, Chagai, and Alborz Belts of western Asia using Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) data and Interactive Data Language (IDL) logical operators: a tool for porphyry copper exploration and assessment. U.S. Geological Survey Scientific Investigations Report 2010– 5090–O.
- Mars, J.C., and Rowan, L.C. (2006). Regional mapping of phyllic- and argillic altered rocks in the Zagros magmatic arc, Iran, using Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) data and logical operator algorithms. *Geosphere*. 2, 161–186.
- Mehrpartou, M., Amini Fazl, A., Radfar J. (1992). Geological survey of Iran. Geology map of Varzaghan. sheet No, 5367, scale 1:100,000.
- Mohri, M., Rostamizadeh, A., Talwalkar, A. (2018). Foundations of machine learning. MIT press.
- O'leary, D. W., Friedman, J. D., Pohn, H. A. (1976). Lineament, linear, lineation: some proposed new standards for old terms. *Geological Society of America Bulletin*. 87(10), 1463 1469.
- Peters, W. C. (1987). Exploration and mining geology. John Wiley and Sons Inc, New York.

- Ruder, S. (2016). An overview of gradient descent optimization algorithms. arXiv preprint arXiv:1609.04747.
- Sabins, F. F. (1999). Remote sensing for mineral exploration. *Ore geology reviews*, 14(3-4), 157-183.
- Safari, S., Ziaii, M., Ghoorchi, M., Sadeghi, M. (2018). Application of concentration gradient coefficients in mining geochemistry: A comparison of copper mineralization in Iran and Canada. *Journal of Mining and Environment*, 9(1), 277-292.
- Safonov, Y. G. (1997). Hydrothermal gold deposits: Distribution, geological-genetic types, and productivity of ore-forming systems. *Geology of ore deposits*, 39(1), 20-32.
- Safronov, N. I. (1936). Dispersion haloes of ore deposits and their use in exploration. *Problemy Sovetskoy Geologii*, 4, 41-53.
- Scherer, D., Müller, A., Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. *International conference on artificial neural networks*, 92-101.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Shirazy, A., Ziaii, M., Hezarkhani, A., Timkin, T. (2020). Geostatistical and remote sensing studies to identify high metallogenic potential regions in the Kivi area of Iran. *Minerals*, 10(10), 869.
- Sillitoe, R. H. (2010). Porphyry copper systems. *Economic Geology*, 105(1), 3-41.
- Smith, L. N. (2018). A disciplined approach to neural network hyper-parameters: Part 1—learning rate, batch size, momentum, and weight decay. *US Naval Research Laboratory Technical Report 5510-026*.
- Solovov, A. P. (1990). *Handbook on Geochemical Prospecting for Useful Minerals*. Nedra Publishing House, Moscow.
- Solovov, A. P. (1987). *Geochemical Prospecting for Mineral Deposits*. Mir, Moscow.
- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., Manzagol, P. A., & Bottou, L. (2010). Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of machine learning research*, 11(12), 3371-3408.
- Xiong, Y., Zuo, R. (2016). Recognition of geochemical anomalies using a deep autoencoder network. *Computers & Geosciences*, 86, 75-82.
- Yongqing, C., Pengda, Z. (1998). Zonation in primary halos and geochemical prospecting pattern for the Guilaizhuang gold deposit, eastern China. *Nonrenewable Resources*, 7(1), 37-44.

- Zeiler, M.D., Fergus, R. (2014). Visualizing and understanding convolutional networks. European Conference on Computer Vision, 818–833.
- Zhang, C., Zuo, R., Xiong, Y. (2021b). Detection of the multivariate geochemical anomalies associated with mineralization using a deep convolutional neural network and a pixel-pair feature method. *Applied Geochemistry*, 130, 104994.
- Zhang, H., Zhang, L., Jiang, Y. (2019). Overfitting and underfitting analysis for deep learning based end-to-end communication systems. 11th International Conference on Wireless Communications and Signal Processing (WCSP), 1-6.
- Zhang, N., Zhou, K. (2017). Identification of hydrothermal alteration zones of the Baogutu porphyry copper deposits in northwest China using ASTER data. *Journal of Applied Remote Sensing*, 11(1), 015016.
- Zhang, S., Carranza, E. J. M., Wei, H., Xiao, K., Yang, F., Xiang, J., Zhang, S., Xu, Y. (2021a). Data-driven mineral prospectivity mapping by joint application of unsupervised convolutional auto-encoder network and supervised convolutional neural network. *Natural Resources Research*, 30(2), 1011-1031.
- Ziaei, M. (1996). Lithogeochemical Exploration Methods for Porphyry Copper Deposit in Sungun, NW Iran. M.Sc. Thesis, Moscow State University, Moscow.
- Ziaei, M., Ardejani, F. D., Ziaei, M., Soleymani, A. A. (2012). Neuro-fuzzy modeling based genetic algorithms for identification of geochemical anomalies in mining geochemistry. *Applied geochemistry*, 27(3), 663-676.
- Ziaei, M., Carranza, E. J. M., Ziaei, M. (2011). Application of geochemical zonality coefficients in mineral prospectivity mapping. *Computers & geosciences*, 37(12), 1935-1945.
- Ziaei, M., Pouyan, A. A., Ziaei, M. (2009). Neuro-fuzzy modelling in mining geochemistry: identification of geochemical anomalies. *Journal of Geochemical Exploration*, 100(1), 25-36.
- Ziaei, M., Safari, S., Timkin, T., Voroshilov, V., Yakich, T. (2019). Identification of geochemical anomalies of the porphyry–Cu deposits using concentration gradient modelling: a case study, Jebel-Barez area, Iran. *Journal of Geochemical Exploration*, 199, 16-30.
- Zuo, R. (2017). Machine learning of mineralization-related geochemical anomalies: A review of potential methods. *Natural Resources Research*, 26(4), 457-464.
- Zuo, R., Carranza, E. J. M., Cheng, Q. (2012). Fractal/multifractal modelling of geochemical exploration data. *Journal of Geochemical Exploration*, 122, 1-3.
- Zuo, R., Xiong, Y. (2018). Big data analytics of identifying geochemical anomalies supported by machine learning methods. *Natural Resources Research*, 27(1), 5-13.

- Zuo, R., Xiong, Y. (2020). Geodata science and geochemical mapping. *Journal of Geochemical Exploration*, 209, 106431.
- Zuo, R., Xiong, Y., Wang, J., Carranza, E. J. M. (2019). Deep learning and its application in geochemical mapping. *Earth-Science Reviews*, 192, 1-14.
- Zürcher, L., Bookstrom, A. A., Hammarstrom, J. M., Mars, J. C., Ludington, S. D., Zientek, M. L., Dunlap, P., Wallis, J. C. (2019). Tectono-magmatic evolution of porphyry belts in the central Tethys region of Turkey, the Caucasus, Iran, western Pakistan, and southern Afghanistan. *Ore Geology Reviews*, 111, 102849.

Abstract

Depleting the surface mineral resources has been led to the rising demand for exploring deep deposits. Although there are various metal mineralization belts in Iran, particularly the Urmia-Dokhtar belt, the explorations have mostly been performed in shallow depths. This issue was due to several reasons, including the detection problems and the exploration of blind economic mineralization. The geochemical zonality method is known as one of the substantial approaches in mining geochemistry. This technique is characterized as one of the most reliable methods in exploring blind economic reserves. However, the shortcoming of this method and the advances in earth data science have forced the researchers to develop integrated approaches by combining novel and traditional techniques to improve the performance and cover the obstacles of the traditional methods. This study proposes a comprehensive methodology to integrate the deep learning technique as an interesting topic in earth data science and the traditional geochemical zonality method. Thus, the shortcomings of the geochemical zonality method are eliminated, and the blind economic mineralization areas are detected more efficiently. The suggested comprehensive methodology deals with seven continuous stages. Every stage plays a significant role in extracting the non-linear and complex geochemical features and the latent relationship among geochemical data. This procedure is conducted by the supervised and unsupervised deep learning algorithms. The performance of the proposed comprehensive methodology has been examined using two challenging areas (i.e., Sungun and Astamal areas) situated in the Ahar-Arasbaran belt. Sungun area is known as a world-class Cu-Mo deposit. Astamal area is a weak area of blind economic mineralization, while it contains strong alterations and Copper mineral indices. The findings demonstrated that the Sungun area had two blind economic mineralization zones in the southeast and northwest. Also, blind mineralization in the Astamal area was recognized in the west and southeast zones. However, these were zone dispersed mineralization and non-economic. This study proved that the proposed comprehensive methodology was an efficient approach to split the geochemical data at different levels of anomalies without computing anomaly matrix and threshold, detecting the blind mineralization areas, determining the type of mineralization (i.e., economic and non-economic), and specifying the drilling location.

Keywords: Deep Learning, Mining Geochemistry, Geochemical Zonality, Blind Economic Mineralization.



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

Application of Deep Learning Method in Mining Geochemistry for
Sungun and Astamal Areas

By: Mohammad Reza Ghasemi Sasansara

Supervisor:
Dr. Mansour Ziaii

July 2021