

کاربرد شبکه های عصبی مصنوعی در سنجش از دور

الهام بخشی^۱، رضا خالو کاکایی^۲

۱. کارشناسی ارشد مهندسی اکتشاف معدن دانشگاه صنعتی شاهرود،

پست الکترونیک: a_bakhshi2000@yahoo.com.hk

۲. دکتری مهندسی استخراج معدن، ریاست دانشکده مهندسی معدن و ژئوفیزیک دانشگاه صنعتی شاهرود

چکیده

یکی از هیجان انگیزترین پیشرفت‌های زمان معاصر، ظهور ماهواره است. ماهواره‌ها برای اهداف متفاوتی مانند پیش‌بینی وضع هوا، مخابرات، مطالعه زمین، بررسی فضا و سیاره‌های دیگر و... استفاده می‌شوند. ولی یکی از جنبه‌های مهم کاربرد آن‌ها مطالعه زمین و محیط زیست است که توسط ماهواره تکنولوژی منابع زمین انجام شده است. ثروت حاصل از اطلاعاتی که به کمک روش‌های «سنجش از دور»^۱ درباره منابع و محیط اطراف خود به دست می‌آوریم برای کشورهای در حال توسعه ارزش بسیار زیادی دارد و جنبه غالب تکنولوژی سنجش از دور برای کسانی که به طور تمام وقت به آن اشتغال دارند، سرعت تغییر و تحول آن است، به طوری که حتی برای فراگیری و کاربرد کامل وسایل و روش‌های جدید سنجش از دور، به سرعتی که خلق می‌شوند، وقت کافی وجود ندارد و همزمان با پیشرفت تکنولوژی، تکنیک‌های جدید و پر قدرتی در زمینه سنجش از دور ارائه می‌شوند که یکی از این تکنولوژی‌ها، شبکه‌های عصبی مصنوعی^۲ هستند که در زمینه‌های مختلف از جمله سنجش از دور کاربرد وسیعی دارند. اندازه‌گیری خصوصیات فیزیکی و هیدرولیکی خاک، یک کار وقت‌گیر و بسیار پرهزینه است و همچنین به علت وجود ناهمگنی فضایی بسیار زیاد و وجود یک رابطه غیرخطی بین خصوصیات خاک، این اندازه‌گیری‌ها خیلی دقیق نمی‌باشند؛ بنابراین لازم است که روش‌های ساده‌تری برای اندازه‌گیری خصوصیات خاک، در مقیاس وسیع ابداع شوند. پس برای تعیین خصوصیات فیزیکی خاک، در نواحی بسیار دوری که استفاده از روش‌های اندازه‌گیری معمول در آن‌ها غیرممکن و یا بسیار پرهزینه و زمان‌بر است؛ از تکنیک تلفیقی شبکه‌های عصبی مصنوعی و سنجش از دور استفاده شده است.

واژه‌های کلیدی: سنجش از دور، شبکه‌های عصبی مصنوعی، خصوصیات فیزیکی و هیدرولیکی خاک، ماهواره.

۱- مقدمه

فن استفاده از هوا و فضا برای جمع‌آوری اطلاعات زمینی و مطالعه و شناسایی این منابع، بدون تماس فیزیکی با آن‌ها، امروزه به عنوان تکنولوژی سنجش از دور به طور گسترده‌ای مورد استفاده کشورهای مختلف قرار می‌گیرد و در زمان‌های کوتاه‌هجم قابل ملاحظه‌ای از اطلاعات زمینی جمع‌آوری می‌شود که این اطلاعات اساس برنامه‌ریزی‌های مختلف را تشکیل می‌دهند [۱]. واژه سنجش از دور به فنون دریافت اطلاعات از راه دور اطلاق می‌گردد و بسیاری از روش‌های مورد استفاده در سنجش از دور بر محور بینایی استوارند. به علت اهمیت موضوع و نقش سنجش از دور و تصاویر ماهواره‌ای در شناخت بهتر و بیش‌تر محیط پیرامون ما و همچنین پیدایش روش نوین شبکه‌های عصبی مصنوعی، تصمیم گرفته شد که در این مطالعه به بررسی دورسنجی، شبکه‌های عصبی مصنوعی و کاربرد شبکه‌های عصبی مصنوعی در دورسنجی پرداخته شود. از کاربرد شبکه‌های عصبی در سنجش از دور می‌توان به دسته بندی تصاویر سنجش از دور، استخراج اطلاعات از داده‌های سنجش از دور و... اشاره نمود. داده‌های سنجش از دور می‌توانند به صورت عکس، اندازه‌گیری‌های نقطه‌ای و خطی در طول خط پرواز و یا تصاویری با ساختار برداری با تصویری باشند. سیستم‌های سنجش از دور به ویژه آن‌هایی که بر روی ماهواره‌ها قرار دارند کره زمین را به صورت دائم و دوره‌ای مورد نگرش و تصویربرداری قرار می‌دهند. بعضی از کاربردهای فن‌آوری سنجش از دور عبارتند از: نظارت و تعیین تغییرات جهانی، کشاورزی، کشف منابع غیر قابل تجدید، نظارت بر منابع طبیعی تجدید شونده، هواشناسی، تهیه نقشه و مراقبت‌های نظامی. به منظور پاسخ‌گویی به نیازهای متفاوت کاربران، سیستم‌های سنجش از دور زیادی به وجود آمده‌اند که داده‌هایی با ویژگی‌های مختلف مکانی، طیفی و زمینی تولید می‌کنند [۲].

۲- مبانی رادیومتری سنجش از دور

پایه و اساس سنجش از دور بر اندازه‌گیری انرژی بازتابشی پدیده‌ها از راه دور می‌باشد از این رو اشعه الکترومغناطیس مبانی فیزیکی آن را تشکیل می‌دهد، هر چند که اشعه الکترومغناطیس دارای طیف وسیع و گسترده‌ای می‌باشد ولی تنها بخش مرئی تا میکروویو آن در سنجش از دور مورد توجه و استفاده قرار می‌گیرد. برای سیستم‌های سنجش غیر فعال، خورشید به عنوان مهم‌ترین منبع انرژی مطرح است، ضمن آن که کره زمین نیز به دلیل تشعشعات خود-به‌ویژه در محدوده مادون قرمز حرارتی- خود یک منبع انرژی می‌باشد. آن دسته از باندهای سنجنده‌های چند طیفی که در محدوده مادون قرمز حرارتی، فعال می‌باشند؛ نظیر باند ۶ سنجنده Landsat TM، در واقع تشعشعات کره زمین را مورد سنجش قرار می‌دهند. خورشید با درجه حرارتی حدود ۶۰۰۰ درجه کلوین دارای تشعشعاتی نظیر تشعشعات یک جسم سیاه با همان درجه حرارت و حداکثر تشعشعات در محدوده سبز می‌باشد. اشعه خورشید به هنگام عبور از اتمسفر شدیداً تحت تأثیر قرار گرفته و ضعیف می‌شود، به طوری که تنها بخش‌هایی از آن به سطح زمین می‌رسد [۲].

۳- مبانی شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی دستگاه‌ها یا نرم‌افزارهایی هستند که بر اساس ساختمان عصبی مغز انسان سازمان یافته‌اند و رفتارهایی را از خود نشان می‌دهند که مشابه آن در کارکرد مغز انسان وجود دارد و یا آن که قابل تفسیر به یکی از رفتارهای آدمی است. بررسی‌ها نشان می‌دهد که این شبکه‌ها قابلیت یادگیری، یادآوری، فراموش کردن، استنتاج، شناخت الگو، طبقه‌بندی اطلاعات و بسیاری دیگر از مهارت‌های مغز انسان را دارند [۳].

۱-۳) اجزای تشکیل دهنده شبکه عصبی مصنوعی

نرون‌ها (عناصر محاسباتی)

نرون عنصر اصلی شبکه عصبی مصنوعی می‌باشد و کوچک‌ترین واحد پردازش‌گر اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. نرون یک تابع محرک (تبدیل) ریاضی را برای پردازش اطلاعات بردار ورودی به کار می‌برد و یک بردار خروجی به عنوان نتیجه تولید می‌کند. مانند سیستم عصبی بیولوژیکی، نرون‌ها به وسیله رشته‌هایی به هم مرتبط هستند که سیگنال‌ها را در سرتاسر آن‌ها انتقال می‌دهند. هر رشته ارتباطی یک بردار وزن همراه دارد که سیگنال انتقالی را تنظیم می‌کند [۴].

لایه‌ها

یک شبکه عصبی مصنوعی در حالت کلی سه لایه دارد. لایه ورودی، میانی (پنهان) ، خروجی. لایه ورودی، اطلاعات (مجموعه‌ای از ترکیب‌های معرف الگو) را از محیط دریافت کرده و آن را به لایه میانی انتقال می‌دهد. هر نرون واقع شده در لایه ورودی با تمام نرون‌ها در لایه میانی مرتبط است، به طوری که عملکرد پردازش اطلاعات به صورت موازی و همزمان انجام می‌گیرد. به طور مشابه، لایه میانی با لایه خروجی ارتباط دارد. لایه میانی، لایه‌ای است که تحلیل‌های واقعی اطلاعات را از محیط به شبکه عرضه می‌کند. لایه خروجی این تحلیل را دریافت می‌کند و آن را به یک تفسیر معنی‌دار تبدیل کرده و پس از محاسبه به محیط برمی‌گرداند [۴].

۲-۳) مفاهیم شبکه‌های عصبی مصنوعی

مشخصات اساسی یک شبکه عصبی مصنوعی به چهار بخش تقسیم می‌گردد:

الف) ساختار شبکه: معین می‌کند که شبکه از چند نرون تشکیل شده و چگونه این نرون‌ها در شبکه آرایش یافته و به چه شکل به همدیگر اتصال یافته‌اند. هر نرون یا عنصر پردازش‌گر مشابه با نرون طبیعی دارای تعدادی ورودی، قدرت سیناپس، تابع محرک، تعدادی خروجی و بایاس می‌باشد.

ب) توابع محرک: خروجی یک نرون را به ازای یک ورودی معین مشخص می‌کند.

ج) الگوریتم آموزش شبکه: نحوه آموزش شبکه را برای یک سری الگوهای آموزشی معین نشان می‌دهد.

د) شیوه به کارگیری شبکه‌های عصبی مصنوعی: نشان می‌دهد که چگونه می‌توان پاسخ شبکه یا خروجی آن را به ازای یک الگوی ورودی مشخص کرد [۵].

۳-۳) ساختار شبکه‌های عصبی مصنوعی

ساختار شبکه‌های عصبی مصنوعی به صورت لایه‌ای است و از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه میانی تشکیل شده‌اند. هر لایه شامل تعدادی گره یا نرون می‌باشد که گره‌ها به وسیله شبکه و با وزن‌های متفاوت به هم مربوط شده‌اند. بر اساس نحوه اتصال گره‌ها به یکدیگر شبکه‌های عصبی به دو گروه تقسیم می‌شوند:

شبکه‌های عصبی مصنوعی پیشخور^۳ و شبکه‌های عصبی مصنوعی پسخور^۴

شبکه‌های عصبی مصنوعی پیشخور

در این نوع شبکه‌ها، چون ورودی(ها) برای تولید خروجی(ها) از میان نرون عبور می‌کنند؛ به شبکه‌های پیشخور معروفند. در این‌جا نوعی از شبکه‌های عصبی مصنوعی پیشخور، که به شبکه عصبی چند لایه پیشخور موسوم است؛ معرفی می‌شود. فرق این شبکه با شبکه تک لایه در این است که بین لایه ورودی و لایه خروجی، یک یا چند لایه به

نام لایه(های) پنهان وجود دارد. وظیفه این لایه‌ها ارتباط دادن لایه ورودی به لایه خروجی می‌باشد. شبکه با داشتن این لایه پنهان قادر می‌گردد روابط غیر خطی را از داده‌های ارائه شده استخراج نماید. از قانون یادگیری پس انتشار خطا^۵ برای آموزش شبکه‌های عصبی چند لایه پیشخور که عموماً شبکه‌های چند لایه پرسپترون^۶ هم نامیده می‌شوند، استفاده می‌کنند. قانون پس انتشار خطا از دو مسیر اصلی تشکیل می‌شود: مسیر اول به مسیر رفت موسوم می‌باشد که در این مسیر، بردار ورودی به شبکه MLP اعمال می‌شود و تأثیراتش از طریق لایه‌های میانی به لایه‌های خروجی انتشار می‌یابد. بردار خروجی تشکیل یافته در لایه خروجی، پاسخ واقعی شبکه MLP را تشکیل می‌دهد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می‌شوند. مسیر دوم به مسیر برگشت موسوم می‌باشد. در این مسیر بر عکس مسیر رفت، پارامترهای شبکه MLP تغییر و تنظیم می‌گردند. این تنظیم مطابق با قانون اصلاح خطا انجام می‌گیرد. سیگنال خطا در لایه خروجی شبکه تشکیل می‌گردد. بردار خطا برابر با اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه می‌باشد. مقدار خطا پس از محاسبه، در مسیر برگشت از لایه خروجی و از طریق لایه‌های شبکه در کل شبکه توزیع می‌گردد. چون توزیع اخیر در خلاف مسیر ارتباطات وزنی سیناپس‌ها صورت می‌پذیرد، کلمه پس انتشار خطا جهت توضیح اصلاح رفتاری شبکه انتخاب شده است [۵].

شبکه‌های عصبی مصنوعی پسخور

تفاوت شبکه‌های پسخور با شبکه‌های پیشخور این است که در شبکه‌های پسخور، حداقل یک سیگنال برگشتی از نرون به همان نرون(ها) یا نرون‌های لایه قبل وجود دارد.

۳-۴) گونه‌های مختلف آموزش در شبکه‌های عصبی مصنوعی

آموزش شبکه عصبی عبارت است از فرآیندی که به وسیله آن شبکه عصبی خود را برای یک محرک سازگار می‌کند، به نحوی که پس از تعدیل مناسب پارامترهای شبکه، پاسخ مطلوب را ارائه دهد. در خلال آموزش، شبکه پارامترهای خود یعنی وزن‌های سیناپس را در پاسخ به ورودی محرک تعدیل می‌کند به نحوی که خروجی واقعی شبکه به خروجی مطلوب همگرا شود. همان طوری که برای هر فرد یک شیوه آموزشی خاص مناسب است، برای هر شبکه عصبی مصنوعی نیز روش‌های خاصی متناسب است. در ادامه به برخی از روش‌های معمول آموزش اشاره شده است [۵].

آموزش با ناظر^۷

در این شیوه آموزش، ورودی‌های شبکه و خروجی‌های متناظر با آن‌ها از قبل مشخص می‌باشند. در زمان آموزش شبکه، یک ورودی به شبکه اعمال می‌شود. شبکه در پاسخ به آن ورودی محرک، پاسخ خروجی را نتیجه می‌دهد. این خروجی با خروجی مطلوب متناظر با همین ورودی مقایسه می‌شود. حال اگر خروجی واقعی با خروجی مطلوب مغایرت داشته باشد، شبکه یک سیگنال خطا تولید می‌کند که از این سیگنال فقط برای محاسبه میزان تغییری که باید بر وزن‌های سیناپس اعمال شود، استفاده می‌گردد. این روند آن قدر تکرار می‌شود تا خروجی واقعی، همان خروجی مطلوب یا نزدیک به آن شود. روند حداقل نمودن خطا به یک مقدار ویژه به نام معلم یا ناظر نیازمند است که عمل مقایسه بین خروجی واقعی و خروجی مطلوب را انجام دهد و شبکه را با توجه به این میزان سیگنال خطا تعدیل نماید تا این که آموزش لازم را ببیند. به همین دلیل به این شیوه آموزشی، آموزش با ناظر گفته می‌شود. توجه به این نکته مهم است که در خلال آموزش، وزن‌ها به نحوی تعدیل یابند که خطا به حداقل برسد. در زمان آموزش ممکن است به مقادیری برای وزن‌ها برسیم که ظاهراً حداقل خطا در خروجی ایجاد می‌نمایند، اما اگر روند

آموزش ادامه داده شود ابتدا خطا افزایش یافته و به یک حداقل دیگر می‌رسد که از حداقل اولی کم‌تر است. به آن حداقل اول، حداقل محلی گفته می‌شود. حال اگر روند آموزش را ادامه داده ولی میزان خطا هرگز از میزان خطای دوم کم‌تر نشود به این حداقل خطا، حداقل مطلق گویند [۶].

آموزش بدون ناظر^۸

شبکه کوهن با عملکرد خود سازمانده^۹، یک نوع شبکه بدون ناظر است و ساختار آن تنها با دو لایه، ساده ترین نوع نسبت به سایر ساختارها می‌باشد: لایه ورودی و لایه خروجی. شبکه کوهن قادر به یادگیری بدون حضور خروجی های مطلوب در الگوهای نمونه است. این شبکه‌ها می‌توانند الگوهای داده ها را به تعداد مشخصی از مجموعه ها تفکیک کنند. در این روش بر خلاف شیوه آموزش با ناظر نیازی به معلم نیست، یعنی خروجی هدف وجود ندارد. در خلال آموزش، شبکه الگوهای آموزشی خود را از طریق ورودی‌هایش دریافت می‌کند و به شکل دلخواه، آن‌ها را در طبقه‌های مختلفی، دسته‌بندی می‌کند. هنگامی که یک شبکه ورودی را دریافت می‌کند، پاسخی در خروجی ظاهر می‌شود که نشان‌دهنده طبقه‌ای است که ورودی بدان تعلق دارد. اگر طبقه‌ای برای این ورودی یافت نشد، آن‌گاه یک طبقه جدید تشکیل می‌شود [۷].

پرسپترون

طبق تحقیقات به عمل آمده و مرور مقالات مختلف موجود در این زمینه، مشخص شد که شبکه پرسپترون با الگوریتم پس انتشار خطا کارایی زیادی در حل مسائل مربوط به سنجش از دور دارد. پرسپترون اولین شبکه عصبی مصنوعی بود که در سال ۱۹۵۸ توسط فرانک روزنبلات ارائه گردید. در حال حاضر از پرسپترون در کاربردهایی نظیر طبقه‌بندی اشکال، شناسایی نمادها و سیستم بینایی روبات استفاده می‌شود. پرسپترون تک لایه قادر است الگوهای به طور خطی تفکیک‌پذیر را طبقه‌بندی کند، در حالی که پرسپترون چند لایه می‌تواند الگوهای به طور غیرخطی تفکیک‌پذیر را نیز طبقه‌بندی نماید؛ به همین دلیل امروزه در اکثر موارد، به منظور شناسایی الگو و طبقه‌بندی آن‌ها از پرسپترون چند لایه به خاطر قدرت آن در تفکیک‌پذیری استفاده می‌شود. برای آموزش پرسپترون چند لایه از الگوریتم آموزشی «پس انتشار خطا» استفاده می‌گردد [۶].

قانون پس انتشار خطا

از قانون یادگیری پس انتشار خطا برای آموزش شبکه‌های عصبی چند لایه پیشخور که عموماً شبکه‌های چند لایه پرسپترون هم نامیده می‌شوند، استفاده می‌کنند، به عبارتی توپولوژی شبکه‌های MLP با قانون یادگیری پس انتشار خطا تکمیل می‌شود [۴].

۴- کاربرد شبکه های عصبی مصنوعی در سنجش از دور

اندازه گیری خصوصیات فیزیکی و هیدرولیکی خاک، یک کار وقت گیر و بسیار پرهزینه می باشد. به همین دلیل در بسیاری از اندازه گیری ها لازم است که متغیرهای زمانی- مکانی را محدود نمود، همچنین به علت وجود ناهمگنی فضایی بسیار زیاد و وجود یک رابطه غیرخطی بین خصوصیات خاک، این اندازه گیری ها خیلی دقیق نمی باشند؛ بنابراین لازم است که روش های ساده تری برای اندازه گیری خصوصیات خاک، در مقیاس وسیع ابداع شوند. تعیین خصوصیات فیزیکی خاک، در نواحی بسیار دوری که استفاده از روش های اندازه گیری معمول در آن ها غیرممکن و یا بسیار پرهزینه و زمان بر است؛ از تکنیک تلفیقی شبکه های عصبی مصنوعی و سنجش از دور استفاده شده است. برای بررسی امکان پذیر بودن تخمین خصوصیات فیزیکی و هیدرولیکی خاک، فقط به کمک داده های سنجش از

دور، بدون داشتن هیچ گونه اطلاعی از بافت خاک، مطالعاتی انجام گرفته است. بدین منظور از شبکه های مصنوعی خود سازمان ده و ارتباط فیزیکی بین خصوصیات هیدرولیکی و رطوبت خاک در یک فاز خشکی استفاده شده است. مدل های پیشنهادی برای تشخیص خصوصیات خاک به کمک داده های دورسنجی، باید این شرایط را داشته باشند: (۱) توانایی استخراج اطلاعات از ورودی های متعدد و گوناگون مربوط به خصوصیات فیزیکی خاک، (۲) قابلیت انجام عمل طبقه بندی (کلاسه بندی) و نقشه برداری از فضاها و ورودی - خروجی چند بعدی. برای دستیابی به این هدف از شبکه های عصبی مصنوعی و وجود ارتباط فیزیکی بین الگوهای زمانی - مکانی $T_B(x, t)$ (دمای درجه روشنایی)، کاهش رطوبت خاک و ویژگی های خاک استفاده گردید. در این طرح پیشنهادی عملکرد دو نوع از شبکه های عصبی مصنوعی با استفاده از داده های سنسور از دور مورد بررسی قرار گرفته است. چارچوب کلی یادگیری در شبکه های عصبی مصنوعی بر اساس مدل هایی است که استفاده از آن ها را در مواقعی که رابطه علت و معلولی دقیقی بین داده ها وجود ندارد، امکان پذیر می سازد. شبکه های عصبی مصنوعی جز آن دسته از سیستم های دینامیکی هستند که با پردازش بر روی داده های تجربی، دانش یا قانون نهفته در ورای داده ها را به ساختار شبکه منتقل می کنند. برای انجام این کار از شبکه خود سازمانده و شبکه پیش خور با الگوریتم آموزشی پس انتشار خطا استفاده شده است.

۵- تشخیص خصوصیات خاک با استفاده از داده های تصویری سنسور از دور مربوط به درجه روشنایی و شبکه SOM

تغییرپذیری زمانی - مکانی درجه روشنایی خاک، نتیجه فعل و انفعالات پیچیده بین ورودی (به طور مثال بارندگی، تشعشعات و ...) خروجی (به طور مثال ریزش های سطحی، نفوذ، زهکشی) و خصوصیات فیزیکی (به طور مثال ویژگی های هیدرولیکی خاک، توپوگرافی) سطح خاک می باشد. در طول یک دوره خشکی، تغییرپذیری فضایی و گرادیان زمانی $T_B(x, t)$ ، در ابتدا توسط خصوصیات فیزیکی و هیدرولیکی خاک کنترل می شود. در طول این توالی انتظار می رود یک رابطه یکنواخت اولیه بین نموداری و خشکی سطح خاک مشاهده شود. اطلاعات مربوط به تغییرپذیری فضایی مقدار اولیه $T_B(x, t)$ و گرادیان زمانی $T_B(x, t)$ در مقیاس یک پیکسل را می توان برای پیش بینی خواص فیزیکی و هیدرولیکی خاک استفاده نمود. به طور مثال پس از یک دوره بارندگی، در طول زمان خشکی، خاکی با نرمی متوسط (شن) در مقابل خاکی با زبری بیش تر (ماسه) رطوبت اولیه خاک را بالاتر می برد (در مقابل درجه روشنایی را پایین می آورد). فرض می کنیم که یک سری از داده های $T_B(x, t)$ با $M \times N$ پیکسل داریم. قدرت تفکیک پذیری و سائز هر کدام از پیکسل ها ($M \times N$) به خصوصیات سنجنده و ارتفاع پرواز بستگی دارد و تعداد روزهای برداشت (P) نیز به اندازه و فراوانی مجموعه داده ها وابسته است. الگوی ورودی برای شبکه SOM، می تواند یک سری متوالی از داده های دمای درجه روشنایی ($T_B(x, t)$) مربوط به یک پیکسل معلوم باشد. از این شبکه برای تشخیص و طبقه بندی داده های ورودی (بدون در اختیار داشتن خروجی ها) استفاده می شود. عدم وجود هیچ منبعی راجع به خروجی ها در شبکه SOM جالب است، زیرا به ما این اجازه را می دهد که فقط با داشتن $T_B(x, t)$ به عنوان ورودی، خاک را به دسته های مختلفی تقسیم کنیم. تعداد نرون های لایه میانی (که در شبکه SOM به لایه رقابتی معروف است)، Q ، با تعداد کلاس های مورد انتظار (که توسط داده های ورودی مشخص می شوند) برابر است. بردارهای وزن اولیه مربوط به لایه ورودی و لایه رقابتی، به طور تصادفی مقداردهی می شوند. هنگامی که یک بردار (مثلاً یک سری زمانی از دمای درجه روشنایی در یک منطقه) به عنوان ورودی در نظر گرفته می شود، اولین گام در شبکه SOM محاسبه یک مقدار نظیر برای هر واحد در لایه رقابتی است. این

مقدار حدی را که در آن وزن های مربوط به نرون نظیر با مقادیر الگوهای ورودی برابر می شوند را اندازه گیری می کند و نرونی که بیش ترین شباهت به الگوهای ورودی دارد، به عنوان نرون برنده انتخاب می شود. وزن های ارتباطی مربوط به نرون برنده و نزدیک ترین همسایه های آن دوباره مقداردهی می شوند تا به الگوهای ورودی نزدیک تر شوند. سپس دیگر الگوهای ورودی از مجموعه داده ها انتخاب می شوند و این فرآیند تا زمانی که تغییرات بین وزن های ارتباطی الگوهای ورودی و نرون ها متوقف نشود، ادامه می یابد. و بدین ترتیب می توان از شبکه SOM برای دسته بندی یک سری از داده های $T_B(x,t)$ مربوط به لایه ورودی، به Q گروه استفاده نمود که هر گروه (کلاس) بیان گر نوعی از بافت خاک می باشد. مرحله یادگیری تا زمانی ادامه می یابد که هر کدام از کلاس ها به یک حالت پایداری برسند. پس از آن تعداد محدودی از نرون ها در لایه رقابتی باقی می ماند که لایه رقابتی به عنوان فیلتر عمل می کند و هر بردار ورودی را به یکی از کلاس های Q (مربوط به بافت خاک) اختصاص می دهد. برای بررسی تجربی عملکرد شبکه فوق، درصدی از پیکسل های چند زمانه $T_B(x,t)$ به عنوان لایه ورودی در نظر گرفته می شوند. این داده های ورودی به Q نرون در لایه رقابتی متصل می گردند، در نتیجه وزن های مربوط به Q نرون، Q منحنی شاخص از Q بافت متفاوت خاک را تشخیص می دهند [۸].

۵-۱) استفاده از دمای درجه روشنایی ($T_B(x,t)$) برای تشخیص نوع خاک

در ابتدا به طور تصادفی درصدی (۵٪ و ۱۰٪) از داده های مربوط به $T_B(x,t)$ چند زمانه، برای مرحله یادگیری انتخاب شدند و خاک به سه کلاس متفاوت ($Q=3$)، که برابر است با خاک زبر، متوسط و نرم) بافتی بر اساس نسبت ماسه به درصد رس، تقسیم گردید. مقایسه بین نقشه بافت های تخمین زده شده توسط شبکه و نقشه بافت های مشاهده ای تأیید می کنند که این ارزیابی به خوبی انجام شده است. در جدول (۱) برخی از پارامترهای استاتیکی برای اعتبارسنجی مدل SOM نشان داده شده اند که برای مقایسه و تعیین اعتبار شبکه عصبی پیشنهاد شده، از دو معیار ضریب همبستگی (CC) و شاخص اختلاف (DI) استفاده شده است.

$$CC = \frac{1}{N} \sum_{j=1}^n \frac{(x_j - \bar{x})(y_j - \bar{y})}{\sigma_x \sigma_y} \quad DI = \frac{1}{N} \sum_{j=1}^n |B(x_j - y_j)| \quad B(\bullet) = \begin{cases} 1 \rightarrow \bullet > 0 \\ 0 \rightarrow \bullet = 0 \\ -1 \rightarrow \bullet < 0 \end{cases}$$

x_j : شاخص بافت خاک مشاهده ای (خاک زبر = ۱، خاک متوسط = ۲، خاک نرم = ۳).

y_j : شاخص بافت خاک به دست آمده توسط شبکه.

\bar{x}, \bar{y} : مقادیر میانگین x_j و y_j .

σ_x, σ_y : انحراف استاندارد x_j و y_j .

همان طور که در جدول (۱) ملاحظه می شود، فقط انتخاب ۵٪ از داده های دمای درجه روشنایی ($T_B(x,t)$) به عنوان الگوهای یادگیری برای طبقه بندی خاک به سه کلاس متفاوت، کافی می باشد [۸].

جدول (۱): اعتبارسنجی مدل SOM برای پیش بینی سه کلاس مختلف بافتی با استفاده از $T_B(x,t)$ [۸].

داده های یادگیری	دمای درجه روشنایی ($T_B(x,t)$)	رطوبت خاک ($\theta(x,t)$)
۵٪	۰/۵۸	۰/۷۵
	۰/۲۸	۰/۱۶
۱۰٪	۰/۵۸	۰/۶۹
	۰/۲۹	۰/۲

۵-۲) استفاده از رطوبت خاک ($\theta(x,t)$) برای تشخیص انواع خاک

با تکرار آزمایشات ذکر شده در مرحله قبل و استفاده از داده های رطوبت خاک ($\theta(x,t)$)، به جای $T_B(x,t)$ و شبکه SOM نیز می توان خاک را به کلاس های متفاوتی تقسیم نمود. مطابق نتایج جدول (۱) با استفاده از درصد کم تری از داده ها (۵٪) می توان به نتایج بهتری رسید. علاوه بر این جدول (۱) مشخص می کند که با استفاده از داده های رطوبت خاک به عنوان الگوی ورودی، به جای دمای درجه روشنایی، نتایج بهتری حاصل می گردد. این مسئله تا حدی قابل انتظار است زیرا رابطه فیزیکی بین رطوبت خاک و بافت آن، از رابطه بین درجه روشنایی و بافت آن قوی تر می باشد [۸].

۶- استفاده از یک شبکه پیش خور چند لایه برای بالا بردن دقت شبکه طبقه بندی کننده خاک

با استفاده از شبکه های عصبی بدون ناظر و مدل SOM، می توان خاک را به گروه های بافتی مختلفی تقسیم نمود. این روش در مناطقی که هیچ دانش اولیه ای از بافت خاک وجود ندارد بسیار مفید می باشد. اما باید توجه نمود که طبقه بندی بافت خاک، با شبکه های عصبی بدون ناظر و با استفاده از تغییرات $T_B(x,t)$ حاصل می شود. اگر تغییرات مربوط به $T_B(x,t)$ تحت تأثیر فاکتورهای محیطی دیگر (مانند تغییر در شرایط جوی، توپوگرافی و ...) قرار گیرد، آن گاه طبقه بندی بر پایه شبکه های بدون ناظر در شرایط عدم اطمینان انجام می گیرد. برای رفع این مشکل، تصمیم گرفته شد که از یک شبکه پیش خور سه لایه^۱ برای تعیین دقت شبکه طبقه بندی کننده استفاده شود. یک شبکه پیش خور معمولاً از سه لایه تشکیل می شود: لایه ورودی، لایه میانی و لایه خروجی. نرون های مربوط به لایه ورودی، سیگنال هایی را دریافت و ارسال می کنند، بدون این که هیچ گونه تغییری در آن ها پدید آورند. وزن های نرون های خروجی، مجموع سیگنال ها و سپس نتایج شبکه از یک تابع محرک خطی عبور می کنند. رفتار نرون های لایه میانی مشابه نرون های خروجی می باشد با این تفاوت که به جای تابع محرک خطی از یک تابع محرک غیرخطی سیگموئیدی استفاده می کند. به عنوان مثال برای پیکسل مشخص K، هر نرون در لایه میانی، ورودی مربوط به خود ($\xi^k = [T_B(k,1), T_B(k,2), \dots, T_B(k,p)]^T$) را دریافت می کند. اگر تعداد نرون های لایه ورودی و لایه میانی را به ترتیب با P و I نشان دهیم، ξ_m^k برای نمایش mامین جز از ξ^k به کار می رود و خروجی mامین نرون در لایه میانی، مطابق رابطه محاسبه می شود.

$$\varphi_j(k) = f_1 \left[\sum_{m=1}^I (\omega_m^j \times \xi_m^k) \right]$$

که در آن، $f_1(\text{net}_j) = 1 / (1 + e^{-\text{net}_j})$

و نتایج لایه های خروجی مطابق رابطه مقابل محاسبه می گردد. $y(k) = f_2 \left(\sum_{j=1}^I (W_j \times \varphi_j(k)) \right)$

که در آن، $f_2(\text{net}_j) = \text{round}(\text{net}_j)$

$\omega =$ یک ماتریس $I \times P$ برای نمایش بردارهای وزن در لایه میانی.

$W =$ یک ماتریس $1 \times I$ برای نمایش بردارهای وزن در لایه خروجی.

در نتیجه عدد صحیح به دست آمده از خروجی $y(k)$ مربوط به پیکسل k ، برای نمایش بافت خاک به کار می رود. برای به دست آوردن وزن های ارتباطی، می توان به طور تصادفی درصدی (۵٪) از پیکسل های چند زمانه $T_B(x,t)$ را برای مرحله یادگیری شبکه پیش خور سه لایه استفاده نمود (فرض می شود که اطلاعات مربوط به بافت خاک برای پیکسل های فوق موجود باشند). مقدار خروجی به دست آمده توسط شبکه با مقدار واقعی مقایسه شده و مقدار

خطا محاسبه می گردد و این کار تا زمانی ادامه می یابد که کلیه الگوریتم های یادگیری به شبکه نشان داده شوند و وزن های ارتباطی بهینه گردند [۸].

۶-۱) استفاده از دمای درجه روشنایی ($T_B(x,t)$) برای تشخیص انواع خاک

در ابتدا خاک به سه کلاس متفاوت ($Q=3$)، که برابر است با خاک زبر، متوسط و نرم) بافتی بر اساس نسبت ماسه به درصد رس و استفاده از ساختار TFNN تقسیم گردید. پس از مشاهده نتایج حاصل از این آزمایش، کلاس های بافت خاک به شش کلاس افزایش یافتند ($Q=6$). نتایج به دست آمده از محاسبه پارامترهای استاتیکی مربوط به شبکه TFNN در جدول (۲) نشان داده شده اند. با مقایسه نتایج جداول (۱) و (۲) در می یابیم که ضریب شاخص اختلاف (ID) برای TFNN برابر با ۱۹٪ و برای SOM برابر ۲۸٪ است، یعنی این ضریب برای شبکه TFNN کم تر است.

جدول (۲): اعتبارسنجی مدل TFNN برای پیش بینی سه کلاس مختلف بافتی با استفاده از $T_B(x,t)$ [۸]

داده های یادگیری	دمای درجه روشنایی ($T_B(x,t)$)	رطوبت خاک ($\theta(x,t)$)
۵٪	۰/۷۰	۰/۷۲
	۰/۱۹	۰/۱۷
۱۰٪	۰/۷۱	۰/۷۵
	۰/۱۹	۰/۱۵

برای این که بتوان علت برتری (اعتبار پاسخ ها) مدل TFNN را نسبت به مدل SOM (زمانی که از داده های دمای درجه روشنایی به عنوان ورودی استفاده می شود) مشخص نمود؛ در ابتدا باید ساختار مدل SOM را بررسی کرد. مدل SOM بر اساس صفات برجسته مربوط به داده های آموزشی، خود را سازماندهی می کند و داده های آموزشی را بر اساس این صفات برجسته، طبقه بندی می کند. در مثال استفاده از دمای درجه روشنایی به عنوان داده های ورودی، این صفت برجسته، رابطه فیزیکی بین منحنی نزولی درجه روشنایی و بافت خاک می باشد که در نتیجه مدل SOM استنتاج می کند که بافت های مختلف خاک منحنی های نزولی متفاوتی دارند ولی هنگامی که فاکتورهای دیگری (مانند انواع گیاهان، آب موجود در گیاهان، زبری خاک سطحی و ...) بررسی می شوند ملاحظه می گردد که بافت های مختلف خاک، احتمالاً دارای منحنی نزولی درجه روشنایی به همراه خصوصیات فیزیکی خاک (۵٪ تا ۱۰٪ پیکسل های مدل TFNN از تحولات زمانی- مکانی درجه روشنایی به همراه خصوصیات فیزیکی خاک) است. به عبارت دیگر حاوی اطلاعات مربوط به خاک)، به عنوان داده های آموزشی استفاده می کند و وزن های ارتباطی شبکه TFNN با استفاده از مثال های معلوم راجع به خصوصیات بافت خاک، تعدیل می شوند. در نتیجه این تعدیل، کمبود اطلاعات در زمانی که فقط از داده های درجه روشنایی به عنوان داده های آموزشی استفاده شود؛ جبران می گردد [۸].

۶-۲) استفاده از رطوبت خاک ($\theta(x,t)$) برای تشخیص انواع خاک

اکنون با استفاده از داده های دورسنجی مربوط به رطوبت خاک و مدل TFNN، به طبقه بندی خاک در کلاس های مختلف بافتی پرداخته می شود. بررسی نتایج حاصل از این آزمایش مشخص می کند که استفاده از رطوبت خاک به جای درجه روشنایی به عنوان داده های ورودی، بهبود چندانی در پاسخ شبکه حاصل نمی گردد؛ زیرا همان طور که قبلاً نیز گفته شد، رطوبت خاک یک کمیت مشاهده ای مستقل نیست، بلکه کمیتی است که با استفاده از دمای درجه روشنایی و دیگر اطلاعات مربوط به بافت خاک، به دست می آید [۸].

۷- نتیجه گیری

به طور خلاصه می‌توان گفت که سنجش از دور علاوه بر آن که به دانشمندان در جهت شناسایی بهتر محیط زیست کمک می‌کند به علت انعطاف‌پذیری، ارزانی نسبی و پوشش وسیع آن از کره زمین، نقش مهمی را در حل بعضی مشکلات اجتماعی، اقتصادی و محیط زیستی که کره زمین با آن مواجه است ایفا می‌کند. همچنین با توجه به کاربرد گسترده آن در علوم مختلف از جمله علوم زمین، در مواردی که جمع‌آوری و اندازه‌گیری پارامترهای مورد نیاز با امکانات موجود، غیر ممکن و یا بسیار پرهزینه است، می‌توان از تکنیک شبکه‌های عصبی مصنوعی استفاده نمود. در این مقاله سعی شده است با بیان کاربرد شبکه‌های عصبی مصنوعی در تعیین خصوصیات فیزیکی خاک با استفاده از داده‌های جمع‌آوری شده توسط ماهواره‌های سنجش از دور، به گوشه‌ای از کاربردهای این روش نوین اشاره شود. البته علاوه بر شبکه‌های عصبی مصنوعی، می‌توان از سیستم‌های منطق فازی و یا ترکیبی از هر دو روش نیز در حل مسایل اینچنینی بهره جست.

۸- پانویس

1. Remote Sensing
2. Artificial Neural Networks:ANN
3. Feed Forward Neural Networks:FFNN
4. Recurrent or Feedback
5. Error Back-Propagation:BP
6. Multi-layer Perceptron: MLP
7. Supervised Learning
8. Unsupervised Learning
9. Self Organized Method:SOM
10. Three-Layered Feed-Forward Neural Network:TFNN

مراجع

۱. زبیری، م.، مجد، ع.ر.، ۱۳۷۵، *آشنایی با فن سنجش از دور و کاربرد در منابع طبیعی*، دانشگاه تهران، چاپ اول.
۲. درویش صفت، ع.ا.، ۱۳۷۷، *جزوه درس سنجش از دور برای دانشجویان کارشناسی ارشد*، دانشگاه تهران، دانشکده منابع طبیعی، ۱۶۴.
3. Hertz, J., Krogh, A., Palmer, R.G., 1991. *Introduction to the Theory of Neural Computation*. Addison-Wesley Publishing Company, Redwood City, CA.
۴. منہاج، م.ب.، ۱۳۷۹. *مبانی شبکه‌های عصبی مصنوعی*. دانشگاه صنعتی امیرکبیر، ۷۱۵.
5. Wiszniewski, A., 1983. *Accurate Fault Impedance Locating Algorithm*. IEEE Proceedings-C, Generation, Transmission, Distribution, 6, 311-314.
6. Takagi, T., Yamakoshi, Y., Yamaura, M., Kondow, and R. Matsushima, 1982. *A New Algorithm of an Accurate Fault Location for EHV/UHV Transmission Lines: Part II-Laplace Transform Method*, IEEE Transactions on Power Systems: PAS-101, 564-573.
7. Poulton, M., 2002. *Neural networks as an intelligence amplification tool: A review of applications*. *Geophysics*, 67, 979-993.
8. Dyi-Huey, C., and Islam, Sh., 2000. *Estimation of soil physical properties using remote sensing and artificial neural network*: REMOTE SENS, ENVIRON., v. 74, p. 534-544.