

# طبقه بندی و شناسایی رخصاره‌های زمین‌شناسی با استفاده از داده‌های لرزه نگاری و شبکه‌های عصبی رقابتی

شبنم شهبازی<sup>۱</sup>، عبدالرحیم جواهریان<sup>۲\*</sup> و مجتبی محمدو خراسانی<sup>۳</sup>

<sup>۱</sup>دانش آموخته کارشناسی ارشد مهندسی اکتشاف نفت - دانشگاه صنعتی امیرکبیر

<sup>۲</sup>استاد مؤسسه ژئوفیزیک دانشگاه تهران

<sup>۳</sup>اداره کل ژئوفیزیک، مدیریت اکتشاف - شرکت ملی نفت ایران

(تاریخ دریافت ۸۴/۹/۱۹، تاریخ دریافت روایت اصلاح شده ۸۷/۸/۱۱، تاریخ تصویب ۸۸/۲/۲۹)

## چکیده

بررسی تغییر رخصاره‌های زمین‌شناسی در مطالعه مخازن هیدروکربوری اهمیت به سزایی دارد. بررسی و طبقه بندی بازتاب‌های لرزه‌ای، روشی توانمند در شناخت و طبقه بندی رخصاره‌های زمین‌شناسی و پیش بینی توزیع رخصاره‌های مخزن است. در این مقاله، روشی مبتنی بر شبکه‌های عصبی مصنوعی رقابتی برای شناسایی و طبقه بندی رخصاره‌های مخزن از روی داده‌های لرزه نگاری معرفی شده است. اساس این روش، خصوصیات بازتاب لرزه‌ای بدون کاربرد نشانگرهای لرزه‌ای است. شبکه عصبی رقابتی، بازتاب لرزه‌ای را در پنجره مشخصی، به عنوان ورودی می‌گیرد و بر اساس میزان انطباق آن با سایر بازتاب‌ها، آن را در یک گروه قرار می‌دهد. این گروه‌بندی به دو روش بدون ناظر و با ناظر انجام می‌شود. در روش بدون ناظر که از شبکه عصبی رقابتی خود سازمانده کوهن استفاده شده است، طبقه‌بندی بازتاب‌های لرزه‌ای بر اساس ویژگی ذاتی آنها انجام می‌شود و بی‌نیاز از اطلاعات چاه‌ها است. این روش برای اکتشاف‌های نواحی جدید به کار می‌رود، جایی که چاه‌های حفاری شده کم است یا وجود ندارد. در روش با ناظر که از شبکه عصبی رقابتی LVQ استفاده شده است، برای شناسایی از اطلاعات کمکی چاه‌ها نیز استفاده می‌کند. این روش بیشتر برای توسعه میدانی تولیدی مفید است؛ جایی که تعداد چاه‌های حفاری شده زیاد است. اجرای هر دو شبکه روی داده‌های مصنوعی و نیز روی داده‌های واقعی زون ششم آسماری در میدان نفتی شادگان، نشان داد که آنها می‌توانند به خوبی توزیع رخصاره‌های جانبی مخزن را پیش بینی و نقشه‌نمایی آن را تهیه کنند.

**واژه‌های کلیدی:** شبکه عصبی رقابتی، تحلیل بدون ناظر، تحلیل با ناظر، تغییر جانبی رخصاره، طبقه بندی رخصاره‌ها

## مقدمه

برای تعیین خصوصیات چینه‌ای مخازن، با کمک مقاطع لرزه نگاری، بازتاب‌های لرزه‌ای در نواحی گوناگون مخزن بررسی و گروه بندی می‌شوند. این گروه‌بندی به طور معمول با بررسی شکل بازتاب لرزه‌ای یا نشانگرهای منتج شده از آن بازتاب، با کمک نمودارهای گرافیکی مانند نمودارهای تقاطعی یا دیاگرام‌های ستاره و یا فنون خودکاری که در ادامه بیان می‌شوند، انجام می‌پذیرد. متلوک و همکارانش [۱] از یک تابع تصمیم خطی بیزین برای تشخیص سریع مرز رخصاره‌های ماسه‌ای استفاده کردند. هاگان [۲] قانون تحلیل اجزای اصلی را برای مطالعه تغییرات افقی تخلخل، ماتیبو و رایس [۳] قانون تحلیل ضریب تفکیک را برای تعیین نسبت ماسه به شیل در مناطق مختلف مخزن و دامی و فورنیر [۴]، هر دو قانون تحلیل اجزای اصلی و تحلیل ضریب تفکیک را برای شناخت رخصاره‌ها از روی داده‌های لرزه نگاری به کار

سال‌های متمادی است که روش‌های سنتی لرزه نگاری برای تعیین مخازن هیدروکربوری ساختمانی به کار می‌روند. علاوه بر پدیده‌های ساختمانی، پدیده‌های چینه‌ای نیز بر روی مقاطع لرزه نگاری تأثیر می‌گذارند. امروزه ضرورت استفاده از مقاطع لرزه نگاری برای تعیین وسعت مخازن و خصوصیات چینه‌ای آن و نیز اکتشاف مخازن چینه‌ای در حال افزایش است. زیرا بیشتر مخازن بزرگ و ساده قبل از این توسعه یافته‌اند و بسیاری از آن‌ها به اتمام رسیده‌اند و امروزه در بسیاری از نقاط دنیا مخازن پیچیده تر و کوچک تر به عنوان هدف اکتشاف مطرح هستند. با توسعه تکنولوژی ثبت و پردازش داده‌های لرزه‌نگاری، مثل برداشت‌های گسترده سه بعدی و نیز ظهور روش‌های پردازش که به حفظ کامل دامنه‌های نسبی داده‌های لرزه‌ای کمک می‌کنند، امکان دستیابی به این هدف فراهم شده است.

برای تشخیص و طبقه بندی رخساره های ناپیوسته مناسب نیستند و نتایج آنها اغلب بهینه نیست. به علاوه مشکلی که در روش های ذکر شده وجود دارد، نیاز آنها به نمونه های آموزشی اولیه است و درستی نتایج نهایی آنها به انتخاب درست نمونه های آموزشی وابسته است. این نمونه های آموزشی به طور معمول از بازتاب های لرزه ای اطراف چاه که چینه شناسی آن محل ها به خوبی شناخته شده است، به دست می آیند. در حالی که شبکه های عصبی رقابتی می توانند به خوبی در مورد رخساره های ناپیوسته به کار روند و نتایج آنها وابستگی زیاد به دقت اطلاعات اولیه ندارد [۷،۹].

هدف از این مقاله، ارائه روشی مبتنی بر شبکه های عصبی رقابتی برای شناسایی و طبقه بندی رخساره های مخزن از روی داده های لرزه نگاری است. این طبقه بندی به دو روش بدون ناظر و با ناظر انجام می شود. در روش بدون ناظر، به داده های چاه دسترسی نداریم و شبکه فقط کار طبقه بندی داده ها را انجام می دهد و قادر به شناسایی آنها نیست. برای این منظور، از شبکه عصبی رقابتی خود سازمانده کوهن استفاده شد. در روش با ناظر، طبقه بندی داده ها بر اساس خصوصیات بازتاب های لرزه ای و با کمک داده های چاه انجام می شود. در این روش داده ها علاوه بر طبقه بندی، شناسایی و نامگذاری نیز می شوند. برای این منظور از شبکه عصبی رقابتی LVQ استفاده شد.

### شرح روش بدون ناظر

هدف از این روش، طبقه بندی اطلاعات لرزه نگاری در نواحی با خصوصیات لرزه ای متغیر، بدون استفاده از هیچ اطلاعات اضافی، مانند نمودارهای چاه است. طبقه بندی فقط بر اساس ساختار داده های لرزه ای انجام می گیرد و نقشه حاصل، هتروژنی مخازن را نشان می دهد. اما این رخساره ها نام گذاری شده نیستند. شبکه های بدون ناظر، فقط قادر به گروه بندی رخساره ها است و تشخیص یا نام گذاری آنها را انجام نمی دهند. این روش در مرحله اکتشاف میدان، در مناطقی که چاه های اکتشافی به تعداد زیاد وجود ندارد، به کار می رود. اطلاعات اضافی می تواند به شناخت طبقات کمک کند. انطباق اطلاعات چاه و نقشه تغییر رخساره ها، تخمینی از کیفیت مخزن در نواحی مختلف ارائه می کند [۷،۱۰].

دردند. سیمان [۵] یک سیستم ویژه دانش مبنا را برای تقسیم مقاطع لرزه نگاری براساس بافتشان ایجاد کرد. یانگ و هانگ [۶] یک شبکه عصبی پس انتشار را برای یافتن ناهنجاری رخساره ها به کار گرفتند.

تفسیر مقاطع لرزه ای با کمک نمودارهای گرافیکی، کار بسیار دشواری است که فقط با صرف زمان طولانی و تلاش بسیار مفسر چینه شناس با تجربه، عملی می شود. در صورتی که پیچیدگی داده های لرزه ای زیاد شود و یا تعداد نشانگرهای مورد تحلیل افزایش یابند، موضوع مشکل تر می شود. روش های خودکاری که به کدبندی های سخت تکیه می کنند، الگوهای اولیه را تعیین و ارتباطات موجود روی مقاطع را بیان می کنند، اما به دقت اطلاعات بسیار حساس هستند و در صورت وجود نوفه یا شرایط غیر معمول در داده ها، غیر قابل اعتماد می گردند. توابع تصمیم خطی نمی توانند به طور مناسبی بر روی داده های غیر خطی لرزه ای عمل کنند. روش های مبتنی بر آمار چند متغیره غیر قابل انعطاف است و به اطلاعات آماری زیادی نیاز دارند و بالاخره اغلب روش های کاهش بعد پیچیده، مانند قانون تحلیل اجزای اصلی و تحلیل ضریب تفکیک، فضای برداری ورودی ها را به فضای برداری کم بعدتر تبدیل می کنند و به این ترتیب خطاهایی در نتایج ایجاد می شود [۷].

روش های شبکه های عصبی، به طور کلی نسبت به روش های ذکر شده، عمومیت بیشتر و قدرت تحمل خطای بیشتری دارند. عمومیت دادن به این مفهوم است که برای ورودی های مشابه، خروجی ها مشابه هستند. شبکه برای عمومیت دادن از داده های آموزشی استفاده می کند. خروجی ها برای ورودی های مشابه، به طور تقریبی و نه به طور کامل مشابه هستند. اما در سایر روش ها تشابه مفهوم ندارد، زیرا آنها بر منطق استوار می باشند و برای قوانین منطقی مفهوم تشابه نمی تواند مصداق پیدا کند. تحمل خطا به این معنی است که ایجاد تغییر کوچکی در ورودی، فقط به مقدار کمی، خروجی را منحرف می کند و به عبارت دیگر نوفه یا داده های ورودی غیر صحیح که مشکلی است که در اغلب سیستم ها به آن برخورد می شود، انحراف مهمی در نتایج به دست آمده، ایجاد نمی کند [۸].

شبکه های عصبی پس انتشار خطا در رابطه با مقادیر نقطه ای تخلخل در نواحی اطراف چاه کارآمد هستند، اما

یادگیری با ناظر و بدون ناظر است که برای طبقه بندی الگوها بسیار مفید است. در این شبکه هر نرون در لایه اول به یک زیر طبقه و سپس هر زیر طبقه به یک نرون در لایه دوم اختصاص می یابد. از این رو تعداد نرون ها در لایه اول، باید حداقل برابر تعداد نرون ها در لایه دوم باشد. تعداد نرون های لایه خروجی، بر اساس تعداد طبقات مطلوب تعیین می شوند. با افزایش تعداد نرون های لایه اول، دقت شبکه بالا می رود. در مقابل این امکان وجود دارد که شبکه الگوی آموزشی را حفظ کند و توانایی تعمیم خود را از دست بدهد، در ضمن سرعت همگرایی شبکه نیز پایین می آید. پس بهتر است تعداد نرون های لایه اول تا حد امکان کم انتخاب شود. مطابق با قانون شبکه های رقابتی هر نرون در لایه اول، بردار مرجع یا شاخص را یاد می گیرد. این کار به شبکه امکان می دهد تا فضای ورودی را به تعدادی ناحیه طبقه بندی نماید که هر ناحیه با یکی از این بردارها نمایندگی می شود. برای محاسبه میزان نزدیکی بردار ورودی و بردارهای وزن، از فاصله اقلیدسی بین آنها استفاده می شود. لایه اول مطابق با روابط زیر عمل می کند:

$$n_i^1 = -\left\| w_i^1 - \underline{p}^T \right\| \quad (1)$$

$$\underline{n}^1 = -\begin{bmatrix} \left\| w_1^1 - \underline{p}^T \right\| \\ \vdots \\ \left\| w_{sl}^1 - \underline{p}^T \right\| \end{bmatrix} \quad (2)$$

$$\underline{a}^1 = \text{Comp}(\underline{n}^1) \quad (3)$$

که در آنها،  $n_i^1$  ورودی خالص نرون،  $i$  ام در لایه اول،  $\underline{n}^1$  بردار ورودی خالص لایه اول و  $\underline{a}^1$  خروجی لایه اول است.

مانند سایر شبکه های رقابتی، نرونی که بیشترین نزدیکی را با بردار ورودی دارد، خروجی یک و باقی نرون ها خروجی صفر خواهند داشت. در شبکه های رقابتی معمولی، نرونی که خروجی مخالف صفر دارد، دلالت بر طبقه ای که بردار ورودی را در بر می گیرد دارد. اما برای شبکه LVQ نرون برنده یک زیر طبقه را به جای یک طبقه نمایندگی می کند. لایه دوم شبکه LVQ، برای ترکیب کردن زیر طبقه های یک طبقه و ایجاد یک طبقه واحد استفاده می شود. ستون های ماتریس وزن این لایه، زیر طبقه ها و سطرهای آن، طبقه ها را نمایندگی می کنند. این ماتریس در هر ستون یک عنصر یک دارد و بقیه عناصر آن برابر صفر هستند. در هر سطر این ماتریس،

این روش به وسیله شبکه رقابتی خود سازمانده کوهن انجام می شود که یک مدل بدون ناظر است و توانایی وسیعی در حل مسائل شناخت و طبقه بندی الگوها دارد. این شبکه از ترکیب دو دسته قوانین یادگیری انجمنی و رقابتی به وجود می آید. انواع الگوریتم های یادگیری در ضمیمه شرح داده شده اند. برای یادگیری این شبکه به الگوهای مرجع دسترسی نداریم و مقادیر اولیه بردارهای وزن به طور تصادفی انتخاب می شوند. تعداد نرون ها، معادل با تعداد مطلوب طبقات است. هر نرون به عنوان نماینده یک کلاس محسوب می شود. در این شبکه بردارهای ورودی با توجه به شباهتشان، دسته بندی می شوند. این فرایند را خوشه بندی می نامند که در آن هر خوشه توسط یک نرون معرفی می شود. در این شبکه تعدادی سلول عصبی اغلب با توپولوژی مسطح در کنار یکدیگر چیده شده اند. همه سلول ها بر روی یک دیگر تاثیر گذاشته و به کمک یکدیگر کلاس بردار ورودی را تعیین می کنند. این شبکه دارای یک لایه رقابتی با ساختار برگشتی دارد. در لایه های رقابتی، در هر مرحله یادگیری، سطری از بردار ماتریس وزن که بیشترین نزدیکی را با بردار ورودی دارد، به سمت بردار ورودی حرکت می کند. این حرکت در مسیری است که بردار وزن قدیمی را به بردار ورودی نزدیک کند. الگوریتم این شبکه در ضمیمه به تفصیل شرح داده شده است. برای پایان آموزش، دو معیار وجود دارد: اول اینکه شبکه همگرا شود. یعنی وزن نرون ها ثابت شده یا تغییرات محسوس نداشته باشند. دوم اینکه آموزش به تعداد تکرار مشخص شده، برسد.

### شرح روش با ناظر

هدف از این روش، تعیین خصوصیات مخزن به وسیله شناخت رخساره های آن، بر اساس ویژگی بازتاب های لرزه ای و با کمک نمودارهای چاه است. در این روش از رد لرزه های اطراف چاه، برای آموزش شبکه استفاده می شود. این روش، در مرحله توسعه میدان، در مناطقی که چاه های اکتشافی به تعداد کافی وجود دارد، به کار می رود. شبکه های با ناظر، علاوه بر گروه بندی رخساره ها، قادر به تشخیص یا نامگذاری آنها نیز هستند.

شبکه مورد استفاده در این روش، یک شبکه رقابتی LVQ است که شبکه ای هیبرید، متشکل از هر دو نوع

شکل کلی بازتاب لرزه‌ای را تحت تأثیر قرار می دهند، مناسب تر و در ثبت آنومالی مرزها و ناپیوستگی های افقی در داده ها، توانا هستند. به علاوه عملکرد معیارهای همبستگی در حالت کلی وابسته به دقت برداشت افق مورد تحلیل است [۷].

۲- داده‌های ورودی به شبکه عصبی باید نرمالیزه شوند. نرمالیزه کردن به این معنی است که همه نقاط در بازه مورد نظر، در اینجا صفر تا یک قرار بگیرند.

در صورتی که از فاصله اقلیدسی، در تعیین فاصله بین بردارها استفاده شود و تنها یک نوع داده، به شبکه وارد شود به عنوان مثال شکل رد لرزه‌ها، نیازی به نرمال کردن داده ها نیست. اما اگر چند نوع داده مختلف به عنوان ورودی به کار رود، به عنوان مثال نشانگرهای لحظه ای چندگانه، داده‌ها باید نرمال شوند. زیرا در حالت کلی، مقادیر نشانگرهای مختلف، بازه‌های متفاوتی دارند که در صورت نرمال نشدن، نشانگرهای با مقادیر مطلق بزرگ‌تر، بر نتایج تحلیل ها مسلط می شوند. گاهی مواقع مفسر تمایل دارد تاثیر یک ورودی در تحلیل‌ها برجسته تر باشد. برای این کار ورودی مورد نظر در بازه بزرگتری، نرمال می‌شود [۷].

۳- انتخاب پنجره ای که طول رد لرزه ها در آن فاصله بررسی می شود، بسیار مهم است. به دو دلیل بهتر است پنجره کوچکی در محدوده زون هدف انتخاب شود: (۱) آموزش و اجرای شبکه های عصبی ممکن است نیاز به زمان طولانی داشته باشد که این زمان با افزایش طول نمونه های آموزشی، افزایش می یابد. (۲) با بزرگ شدن پنجره دقت روش کاهش می یابد [۱۲].

برای امتحان عملکرد شبکه و اطمینان از درستی نتایج آن، از یک مقطع لرزه نگاری مصنوعی ساخته شده بر اساس مدل زمین شناسی فرضی شکل (۲-ا) استفاده شد. برای طراحی این مقطع، از یک موجک با فاز کمینه استفاده و به طور تصادفی نوفه‌های گوسی در طول رد لرزه‌ها ایجاد شد. این مقطع در شکل (۲-ب) نشان داده شده است. ورودی هر دو شبکه، شکل رد لرزه یا دامنه نقاط در طول آن بازتاب ها است. برای این مقطع می توان پنجره‌های مختلفی در محدوده زونی که هدف، تعیین تغییرات جانبی رخساره در آن است، تعریف کرد و فقط طولی از رد لرزه را که در آن پنجره قرار می گیرد، مورد بررسی قرار داد. در این مقطع، ۱۲۰ رد لرزه با فواصل ۲۵

جایی که مقدار یک ظاهر می شود، دلالت بر طبقه ای دارد که زیر طبقه های مربوط به آن را در بر می گیرد. الگوریتم این شبکه نیز در ضمیمه به تفصیل شرح داده شده است. این شبکه نیز پس از تعدادی تکرار، پایدار می شود و برای پایان آموزش نیز دو معیار وجود دارد: اول اینکه خطای بین خروجی شبکه و خروجی مطلوب کمتر از مقدار پیش داده شود و دوم، شبکه به تعداد تکرار مشخص شده، برسد [۷،۱۱].

## طراحی شبکه های رقابتی و مقطع مصنوعی و تشخیص و طبقه بندی رخساره های مقطع

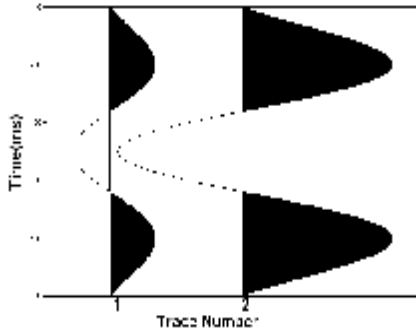
در طراحی شبکه های رقابتی و انتخاب و آماده سازی ورودی ها باید به این نکات توجه کرد:

۱- برای سنجش شباهت بین بردار ورودی و بردار وزن هر نرون، معیارهای مختلفی استفاده می شود که در جدول (۱) تعریف شده اند. معیارهایی که به طور مستقیم متناسب با میزان شباهت بین بردارها هستند، مانند همبستگی تقاطعی و تشابه می توانند معیارهای همبستگی نامیده شوند و مقدار واحد آنها، بیان کننده تشابه کامل است. اما معیارهایی که به طور معکوس متناسب با شباهت بین بردارها هستند، مانند  $I_1$  و  $I_2$ ، معیارهای فاصله نامیده می‌شوند و تشابه کامل با فاصله صفر مشخص می شود. معیار  $I_1$  فاصله اقلیدسی نامیده می‌شود. جزئیات اجرای شبکه ها با معیارهای مختلف، کمی تفاوت دارد. انتخاب یک معیار خاص، به خصوصیات اطلاعاتی که مورد تحلیل قرار می گیرند، بستگی دارد. برای مثال، در حالت کلی معیارهای همبستگی نسبت به معیارهای فاصله، به شکل بازتاب لرزه‌ای حساس تر هستند. در حقیقت، همبستگی تقاطعی به دامنه مطلق داده های لرزه ای به طور کامل غیر حساس است و وابسته به شکل بازتاب لرزه‌ای است. برای مثال، در شکل (۱) دو رد لرزه با شکل کاملاً یکسان، اما با دامنه‌های مختلف نشان داده شده است. معیار همبستگی تقاطعی بین آنها، واحد است و بیان می کند که دو بردار شباهت کامل دارند. اما معیارهای فاصله بین آنها غیر صفر هستند که بیان کننده عدم شباهت کامل بین آنها است. بنابراین معیارهای فاصله برای پی بردن به خصوصیات که تغییرات دامنه را ایجاد می کنند، مناسب تر هستند. در حالی که معیارهای همبستگی برای پی بردن به خصوصیات که

متر وجود دارد.

و کلاس دو معرف رخساره ماسه سنگی است.

جدول ۱: تعریف برخی از معیارهای تشابه و همبستگی که می‌توانند برای محاسبه شباهت بین بردارهای ورودی و نرون‌ها استفاده شوند [۷].



شکل ۱: این مثال نشان می‌دهد که معیارهای همبستگی به مقادیر مطلق دامنه بازتاب‌های لرزه‌ای غیر حساس و به شدت وابسته به شکل بازتاب‌های لرزه‌ای هستند. در این مثال، دو رد لرزه با شکل یکسان اما با دامنه‌های مختلف نشان داده شده است. معیار همبستگی تقاطعی آنها یک است که نشان می‌دهد دو رد لرزه به طور کامل مشابه‌اند، اما معیارهای فاصله آنها  $l_1$  (و)  $l_2$  غیر صفر است که نشان می‌دهد دو رد لرزه نامتشابه‌اند [۷].

Norm	Definition
$l_1$	$\ x - y\  = \sum_{i=1}^n  x_i - y_i $
$l_2$	$\ x - y\  = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$
Crosscorrelation	$\ x, y\  = \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \cdot \sqrt{\sum_{i=1}^n y_i^2}}$
Semblance	$\ x, y\  = \frac{1}{2} \frac{\sum_{i=1}^n (x_i + y_i)^2}{\sum_{i=1}^n x_i^2 + \sum_{i=1}^n y_i^2}$

اگرچه این مدل به اندازه‌ای ساده است که رخساره‌های لرزه‌ای آن می‌تواند با بررسی چشمی نیز به آسانی طبقه بندی شود، اما در حالت کلی کاربرد این روش با افزایش پیچیدگی زمین شناسی، همچنان ساده باقی می‌ماند، در حالی که دقت سایر تحلیل‌ها با افزایش پیچیدگی میدان، به سرعت خراب می‌شود.

### میدان نفتی شادگان

در این مقاله، با استفاده از داده‌های لرزه نگاری سه بعدی در میدان نفتی شادگان، رخساره‌های زمین شناسی در زون ششم آسماری از این میدان طبقه بندی شد. میدان نفتی شادگان در جنوب شرقی اهواز، در ناحیه دزفول شمالی و بین میادین اهواز، مارون، رامشیر و منصوری واقع است. تشکیلات آسماری در این میدان به ۱۰ زون تقسیم شده و حاوی دو مخزن است. مخزن بالایی در لایه‌های آسماری ۱ و ۲ و مخزن پایینی در لایه‌های آسماری ۵ و ۶ قرار دارد که خاصیت مخزنی بخش‌های ۲ و ۶ به مراتب بهتر است. رویه مورد بررسی مساحتی برابر با ۱۹۲/۲۴ کیلومترمربع دارد و حاوی ۲۳۷۹۷۹ نقطه برداشت لرزه نگاری است [۱۳].

در روش بدون ناظر، برای آموزش شبکه به طور معمول از حدود ۲۰ تا ۳۰ درصد کل داده‌ها استفاده می‌شود. در این جا از ۲۴ عدد از رد لرزه‌ها یعنی ۲۰ درصد آنها برای آموزش شبکه بدون ناظر استفاده شد. اما در روش با ناظر، با توجه به محدودیت در تعداد چاه‌های حفاری شده در میادین نفتی، تعداد رد لرزه‌های آموزشی باید خیلی کمتر انتخاب شود. در اینجا برای هر کلاس فقط سه رد لرزه در مجاورت یکدیگر در نظر گرفته شد که فرض شده است رد لرزه‌های اطراف چاه‌ها هستند. در این مدل تغییرات جانبی رخساره فقط در لایه دوم دیده می‌شود که در آن دو نوع رخساره قابل تمیز است. پس در این لایه، دو کلاس وجود دارد. در این مقطع طولی از رد لرزه‌ها که در پنجره ۴۰۰ تا ۶۰۰ یعنی بخشی از لایه دوم قرار می‌گیرد، به شبکه وارد شد. در هر دو روش، شبکه به طور دقیق و بدون هیچ خطایی قادر به طبقه بندی کل رد لرزه‌ها گردید. طبقه بندی مطلوب رخساره‌ها در شکل (۲-۲)، نتیجه طبقه بندی شبکه کوهنن، در شکل (۲-۲) و شبکه LVQ در شکل (۲-۲) نشان داده شده است. همان‌طور که در شکل (۲-۲) دیده می‌شود، شبکه بدون ناظر فقط قادر است رخساره‌های زمین شناسی را گروه بندی کند در حالی که مطابق شکل (۲-۲) شبکه با ناظر علاوه بر گروه بندی، آن‌ها را مشخص و نام‌گذاری می‌کند. در شبکه با ناظر، کلاس یک معرف رخساره شیلی

### اجرای شبکه بدون ناظر روی داده های میدان

ابتدا داده های لرزه نگاری موجود از میدان نفتی شادگان نرمال شد. سپس مجموعه آموزش به طور تصادفی از روی کل داده های موجود در میدان ساخته شد و شبکه توسط این مجموعه، آموزش دید. در نهایت کل داده ها به شبکه تزریق و طبقه بندی شدند و نقشه کنتور شماره کلاس ها ترسیم شد که در شکل (۴) نشان داده شده است. در این شکل، هر رنگ نماینده یک کلاس بوده ولی سنگ شناسی مربوط به آن کلاس مشخص نیست. این مراحل به ترتیب با ۵، ۴ و ۳ کلاس یا نرون لایه خروجی انجام شد. مقایسه بین شکل های به دست آمده نشان داد که بهتر است بیش از ۳ کلاس در ناحیه تعریف نشود.

شکل (۳) که از درون یابی دامنه بازتاب های لرزه ای نقاط اطراف چاه ها به دست آمده بود و شکل (۴) که از شبکه بدون ناظر به دست آمد، توافق مختصری را نشان می دهند، ولی از آن جا که شبکه بدون ناظر توزیع رخساره ها را پیش بینی می کند و فقط به درون یابی اکتفا نمی کند، دقت بالاتری دارد و علاوه بر اینکه جزئیات بیشتری را ارائه می کند، قدرت تفکیک بالاتری نیز دارد و مرز بین رخساره ها را به خوبی تعیین می کند. نکته قابل توجه این است که هر چند مدل حاصل از درون یابی در محدوده چاه ها اعتبار بسیار زیادی دارد، اما اعتبار آن با فاصله گرفتن از محل چاه ها به سرعت کاهش می یابد و نیز به شدت تحت تأثیر موقعیت چاه ها است. یکی از فواید طبقه بندی با روش بدون ناظر نسبت به سایر روش های طبقه بندی مانند آمار چند متغیره و شبکه پس انتشار خطا این است که وابسته به پوشش چاه ها در میدان نیست و در نتیجه تحت تأثیر مشکلاتی که سایر روش ها در هنگام محدودیت پوشش چاه ها مواجه می شوند، قرار نمی گیرد. روش های آماری و شبکه پس انتشار خطا، نمی توانند اطلاعاتی را که در بازه مجموعه آموزش شان نیستند، برون یابی کنند. این مشکل به این معنی است که نواحی حاشیه میدان که به طور معمول پوشش چاه ها کم است و یا وجود ندارد، به وسیله این روش ها به طور ضعیف مدل سازی می شوند.

### اجرای شبکه با ناظر روی داده های میدان

در این روش لازم است که قبل از شروع کار با شبکه، سه مجموعه از اطلاعات به عنوان مجموعه های آموزش،

برای شناسایی رخساره ها از اطلاعات نمودارهای ۸ چاه حفر شده در این میدان و ستون سنگ شناسی آنها نیز استفاده شده است. میدان نفتی شادگان ۸ حلقه چاه دارد که از نظر موقعیت، غیر از چاه ۳، همگی در خط الراس طاقدیس قرار دارند. در جدول (۲) نوع نگارهای موجود از چاه ها نوشته شده است. به کمک این نگارها، اطلاعات اضافی دیگری نظیر حجم شیل، حجم ماسه، حجم دولومیت و درصد اشباع شدگی به دست آمده است.

جدول ۲: نگارهای موجود در چاه ها.

Well	Thickness (m)	Available logs
SH1	418	BHC-CLAIPER-ILD,NPHI,G-RAY-RHOB
SH2	469	BHC-CALIPER-ILD,ILM,NPHI,G-RAY-RHOB
SH3	352	BHC-CALIPER-ILD,ILS,NPHI,G-RAY-RHOB
SH4	425	CALIPER-ILD,ILS,NPHI,G-RAY-RHOB
SH5	404	BHC-CALIPER-ILD,ILS,NPHI,G-RAY-RHOB
SH6	383	BHC-CALIPER-ILD,ILS,NPHI,G-RAY-RHOB
SH7	406	CALIPER-ILD,ILS,NPHI,G-RAY-RHOB
SH8	395	BHC-CALIPER-ILD,ILS,NPHI,G-RAY-RHOB

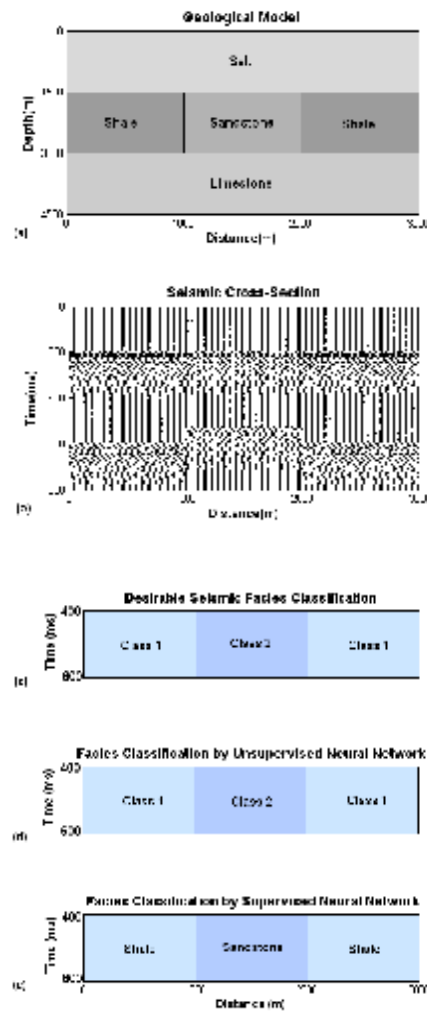
پیش از طبقه بندی داده ها توسط شبکه های عصبی، با درون یابی مقادیر دامنه بازتاب های لرزه ای در نواحی اطراف چاه ها، نقشه توزیع رخساره های مخزن ترسیم شد که در شکل (۳) نشان داده شده است. با بررسی این نقشه و انطباق آن با نمودار چاه ها و ستون سنگ شناسی آنها، رخساره های مخزن به سه گروه تفکیک شدند. جدول (۳) رخساره متعلق به هر چاه را نشان می دهد.

جدول ۳: سنگ شناسی چاه ها در زون مورد بررسی.

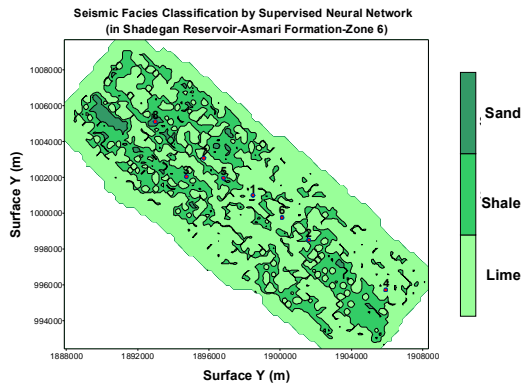
Well	Lithology
SH1-SH4-SH6-SH7	Lime
SH2-SH3-SH5	Shale
SH8	Sand

برای تهیه مجموعه آموزشی در روش با ناظر، ابتدا نقاطی به فاصله ۷۰ متر حول هر چاه به عنوان همسایگی آن چاه تعریف شد و ۱۹۱ نقطه به عنوان همسایگی کل چاه ها به دست آمد. سپس یک بار داده‌های مربوط به چاه‌های ۲ و ۳ از مجموعه خارج شد تا در مرحله تعمیم مورد استفاده قرار بگیرند. ۱۵۰ داده باقیمانده مجموعه آموزش را تشکیل دادند و حدود ۲۰ درصد مجموعه آموزش به طور تصادفی جدا شد تا در مرحله آزمایش، بار دیگر به شبکه تزریق و طبقه‌بندی شود. قابل توجه است که در مرحله آزمایش وزن های شبکه تغییر نمی کند. برای تعیین بردار هدف، یعنی شماره کلاس هر نمونه آموزشی، رخساره همسایگی هر چاه مطابق با رخساره به دست آمده از نمودارها برای آن چاه، در نظر گرفته شد. شبکه پس از آموزش، آزمایش شد و در مرحله بعد توسط مجموعه تأیید، قدرت تعمیم شبکه مورد سنجش قرار گرفت. در این شبکه با روش سعی و خطا تعداد نرون های لایه مخفی ۹ عدد تعیین شد. نقشه حاصل از این شبکه در شکل (۵) نشان داده شده است. بار دوم داده های کل چاه ها مخلوط و حدود ۲۰ درصد آنها به طور تصادفی جدا شد تا در مرحله تعمیم استفاده شود. باز هم ۱۵۰ داده باقیمانده، مجموعه آموزش را تشکیل دادند و مراحل آموزش، آزمایش و تعمیم مانند قبل ولی با مجموعه های جدید انجام شد. مرحله تعمیم در این روش دقت بیشتری نسبت به روش اول داشت. نقشه حاصل از این شبکه در شکل (۶) نشان داده شده است. در شکل‌های (۵) و (۶) نیز مانند شکل حاصل از طبقه بندی با روش بدون ناظر، هر رنگ به یک کلاس تعلق دارد، ولی در این جا نوع رخساره متعلق به هر کلاس مشخص است. در این روش نیز نتیجه طبقه بندی شبکه با نتیجه حاصل از درون یابی اطلاعات چاه ها توافق خوبی نشان می‌دهد، ولی شبکه عصبی با ناظر نیز توزیع رخساره‌ها را پیش بینی می کند. بنابراین دقت بالاتر و قدرت تفکیک بیشتری دارد، جزئیات بیشتری را ارائه می کند و مرزهای بین رخساره ها را به خوبی تعیین می کند. اگر چه در این روش از اطلاعات چاه استفاده می شود و تاحدی تحت تأثیر پوشش چاه‌ها در میدان قرار می گیرد، اما در مورد مشکلات برون یابی، از روش‌های آماری و شبکه پس انتشار خطا مقاوم تر است. زیرا همان طور که در توصیف این شبکه ذکر شد، در اینجا اطلاعات چاه ها فقط برای نشانه گذاری طبقات مورد

آزمایش و تعمیم آماده شوند. توسط مجموعه آموزش، شبکه الگوی موجود در ورودی ها را می شناسد. سپس توسط مجموعه آزمایش که زیر مجموعه ای از مجموعه آموزش است، درستی کار شبکه بررسی می‌شود. وظیفه مجموعه تعمیم ارزیابی توانایی شبکه برای ارائه جواب قابل قبول در قبال ورودی هایی است که در مجموعه آموزشی نبوده اند. در این شبکه بر خلاف شبکه بدون ناظر مجموعه آموزش شامل بردار هدف، یعنی شماره کلاس هر نمونه نیز است.



شکل ۲: کاربرد شبکه های عصبی در طبقه بندی رخساره‌های مدل مصنوعی (a) مدل زمین شناسی (b) مقطع لرزه نگاری مصنوعی ساخته شده بر اساس مدل زمین شناسی فرضی و توسط رد لرزه های تولید شده با موجک فاز کمینه و نوفه‌های گوسی تصادفی (c) طبقه بندی مطلوب رخساره ها (d) طبقه بندی رخساره ها توسط شبکه عصبی بدون ناظر (e) طبقه بندی رخساره‌ها توسط شبکه عصبی با ناظر (کلاس ۱ = شیل، کلاس ۲ = ماسه).



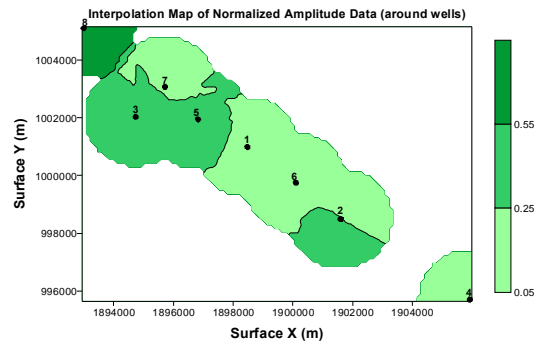
شکل ۳: پیش بینی توزیع رخساره ها در زون ششم آسماری از میدان نفتی شادگان توسط شبکه عصبی رقابتی با ناظر با استفاده از معیار فاصله اقلیدسی. ۲۰ درصد از کل داده های چاه ها برای تعمیم شبکه استفاده شد. رخساره های مخزن به سه گروه طبقه بندی شده اند. گروه یک رخساره ماسه ای، گروه دو رخساره شیلی و گروه سه رخساره آهکی است.

### نتیجه گیری

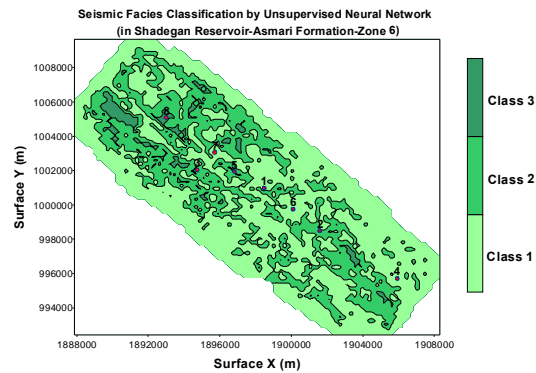
اختلاف در شکل بازتاب های لرزه ای، معرف خوبی برای تشخیص تغییرات رخساره های زمین شناسی است. برای تشخیص و طبقه بندی رخساره ها می توان بازتاب های لرزه ای در میدان را طبقه بندی کرد. شبکه های عصبی رقابتی، ابزاری توانمند در شناسایی و طبقه بندی داده ها از جمله اطلاعات لرزه نگاری است. شبکه های عصبی رقابتی می توانند ناهمگنی خصوصیات مختلف مخزن را به خوبی پیش بینی کنند به شرط اینکه ورودی شبکه با توجه به نوع پروژه و ویژگی اطلاعات مورد نیاز تعیین شود. برای مثال، ورودی شبکه می تواند شکل بازتاب لرزه ای، نشانگرهای لحظه ای چندگانه یا نشانگرهای فاصله ای چندگانه باشد. شبکه های عصبی رقابتی می توانند برای شناخت رخساره های زمین شناسی در میدان نفتی به کار گرفته شوند. بخصوص در محل هایی که تعداد چاه های حفاری شده کم است یا توزیع مناسبی در سطح میدان ندارد.

شبکه عصبی خود سازمانده کوهن که یک شبکه بدون ناظر است، از ویژگی ذاتی داده ها برای طبقه بندی آنها استفاده می کند و بی نیاز از اطلاعات کمکی مانند اطلاعات چاه ها است، در نتیجه می تواند در مرحله اکتشاف میدان، جایی که تعداد چاه های حفاری شده کم است یا وجود ندارد، استفاده شود. شبکه بدون ناظر فقط قادر به طبقه بندی داده ها است و تشخیص و نام گذاری آنها را انجام نمی دهد. پس از طبقه بندی داده ها توسط


استفاده هستند و به طور مستقیم در فرایند طبقه بندی وارد نمی شوند [۷،۱۴].



شکل ۴: نقشه حاصل از درون یابی مقادیر نرمال شده دامنه امواج لرزه ای در نواحی اطراف چاه ها در زون ششم آسماری از میدان نفتی شادگان. محل چاه ها با شماره ۱ تا ۸ مشخص شده است. با توجه به دامنه امواج لرزه ای بازتابی رخساره های مخزن به سه گروه طبقه بندی شده اند.



شکل ۵: پیش بینی توزیع رخساره ها در زون ششم آسماری از میدان نفتی شادگان توسط شبکه عصبی رقابتی بدون ناظر با استفاده از معیار فاصله اقلیدسی. رخساره های مخزن به سه گروه طبقه بندی شده اند.



شکل ۶: پیش بینی توزیع رخساره ها در زون ششم آسماری از میدان نفتی شادگان توسط شبکه عصبی رقابتی با ناظر با استفاده از معیار فاصله اقلیدسی. داده های چاه های ۲ و ۳ برای تعمیم شبکه استفاده شدند. رخساره های مخزن به سه گروه طبقه بندی شده اند. گروه یک رخساره ماسه ای، گروه دو رخساره شیلی و گروه سه رخساره آهکی است.



زمین شناسی ساخته شده، نشان داد. طبقه بندی اطلاعات لرزه نگاری واقعی در زون ششم آسماری از میدان نفتی شادگان نیز توانست توزیع رخساره های مخزن را پیش بینی و نقشه ناهمگنی مخزن را تهیه کند. نقشه های حاصل از طبقه بندی شبکه ها، شباهت کلی با نقشه کم فرکانس حاصل از درون یابی اطلاعات چاه ها نشان دادند، ولی جزئیات آن ها بیشتر شده و قدرت تفکیک افقی آنها بالا رفته بود.

### تقدیر و تشکر

بدین وسیله از کارشناسان اداره کل ژئوفیزیک شرکت ملی نفت ایران (مدیریت اکتشاف)، خانم مهندس مریم صدری، آقای مهندس مجتبی صدیق عربانی و بخصوص آقای مهندس جواد جمالی به خاطر زحمات ایشان برای دسترسی به داده های خام و نیز راهنمایی های ارزشمند آنها، قدردانی می شود.

این شبکه، اطلاعات کمکی مانند چاه ها می توانند به شناسایی و نامگذاری کلاس ها کمک کنند.

شبکه عصبی LVQ که یک شبکه با ناظر است، برای طبقه بندی داده ها، علاوه بر ویژگی ذاتی آنها، از اطلاعات کمکی مانند چاه ها نیز استفاده می کند. پس این شبکه می تواند در مرحله توسعه میدان، جایی که تعداد چاه های حفاری شده زیاد است و اطلاعات به دست آمده از چاه ها می توانند به راحتی معرف نواحی بین چاه ها باشند، استفاده شود. شبکه با ناظر علاوه بر طبقه بندی داده ها، آنها را شناسایی و نام گذاری می کند. این شبکه طبقات خروجی را به رخساره های مخرنی هدف اختصاص و آنها را نشانه گذاری می کند.

طبقه بندی رد لرزه های حاصل از مقاطع لرزه نگاری مصنوعی توسط هر دو شبکه بدون ناظر و با ناظر نشان داد که آنها می توانند به خوبی نقشه ناهمگنی مخزن را تهیه کنند. نتایج آنها، انطباق بسیار خوبی با مدل های

### مراجع

- 1 - Matlock, R. J., McGowen, R. S. and Asimakopoulos, G. (1985). "Can seismic stratigraphy problems be solved using automated pattern analysis and recognition." *55<sup>th</sup> Ann. Internat. Mtg., Soc. Expl. Geophys.*, Expanded Abstracts.
- 2 - Hagan, D. C. (1982). "The applications of principal component analysis to seismic data sets." *Geoexplor.*, Vol. 20, PP. 93-111.
- 3 - Mathieu, P. G. and Rice, G. W. (1969). "Multivariate analysis used in the detection of stratigraphic anomalies from seismic data." *Geophysics*, Vol. 34, PP. 507-515.
- 4 - Dumay, J. and Fournier, F. (1988). "Multivariate statistical analyses applied to seismic facies recognition." *Geophysics*, Vol. 53, PP. 1151-1159.
- 5- Simaan, M. A. (1991). "A knowledge-based computer system for segmentation of seismic sections based on texture." *61<sup>st</sup> Ann. Internat. Mtg., Soc. Expl. Geophys.*, Expanded Abstracts, PP. 289-292.
- 6 - Yang, F. M. and Huang, K. Y. (1991) "Multi-layer perception for the detection of seismic anomalies." *61<sup>st</sup> Ann. Internat. Mtg., Soc. Expl. Geophys.*, Expanded Abstracts, PP. 309-312.
- 7 - Saggaf, M. M., Toksöz, M. N. and Marhoon, M. I. (2003) "Seismic facies classification and identification by competitive neural networks." *Geophysics*, Vol. 68, PP. 1984-1999
- 8 - Saggaf, M. M., Toksöz, M. N. and Mustafa, H. M. (2003) "Estimation of reservoir properties from seismic data by smooth neural networks." *Geophysics*, Vol. 68, PP. 1969-1983.
- 9 - Poulton, M. (2002). "Neural networks as an intelligence amplification tool: A review of applications." *Geophysics*, Vol. 67, PP. 979-993.
- 10 - Lippmann, R. P. (1989). "Pattern classification using neural networks." *IEEE Communications Magazine*.
- 11 - Menhaj, M. B. (2000) *Foundations of Neural Networks*. Publication Center of Amirkabir University of Technology, Tehran, Iran (in Farsi).

- 12 - Chandra, M., Sirvastava, A. K., Singh, V., Tiwari, D. N. and Painuly, P. K. (2005) "Lithostratigraphic interpretation of seismic data for reservoir characterization." *AAPG International Oil and Natural Gas Corporation*, Dehradun, India.
- 13 - Ramesh, H. and Jamali, J. (2001) *Geological Report of Shadegan Oil Field*. Presented to NIOC (in Farsi).
- 14 - Shahbazi, Sh. (2005). *Geological facies studying by seismic data and neural networks*. M. Sc. thesis in Petroleum Exploration Engineering, Department of Mining, Metallurgy and Petroleum Engineering, Amirkabir University of Technology, Tehran, Iran (in Farsi with Abstract in English).
- 15 - Matlab, manual help.
- 16 - Kohonen, T. (1972). "Correlation matrix memories." *IEEE Transactions on Computers*. Vol. 21, PP. 353-359.

این روش بیشتر برای سیستم های کنترلی کاربرد دارد.

### ضمیمه

در این بخش انواع الگوریتم های یادگیری شبکه های عصبی به اختصار توضیح داده می شوند. پس از آن الگوریتم ریاضی لایه های رقابتی و در نهایت ساختمان ریاضی و شیوه تغییر وزن نرون ها در شبکه خود سازمانده کوهنن و شبکه عصبی LVQ به تفصیل شرح داده می شوند [۱۱].

### مفهوم یادگیری در شبکه های عصبی

یادگیری فرآیندی است که شبکه عصبی را در طول زمان طوری تنظیم می کند که براساس اطلاعات جدید و مشاهده عملکرد فعلی خود، رفتار خود را بهبود بخشد. این فرآیند منجر به دستیابی به مقدار بایاس و وزن های بهینه برای هر سلول شبکه عصبی می شود به طوری که خروجی شبکه تا حد امکان با خروجی مطلوب مشابه باشد. یادگیری شبکه های عصبی به سه نوع تقسیم می شود:

#### ۱- یادگیری با ناظر

در یادگیری با ناظر مجموعه ای از داده های آموزشی همراه با جواب های مطلوب در اختیار سیستم قرار داده می شود. در هر مرحله آموزش، خروجی شبکه با خروجی مطلوب مقایسه و اختلاف بین آنها محاسبه می شود. شبکه با تنظیم دوباره وزن های خود، خطای مرحله بعد را کوچک می کند. هدف این یادگیری، کمینه کردن تابع خطای محاسبه شده است.

#### ۲- یادگیری تشدیددی یا تقویتی

این روش مشابه یادگیری با ناظر است، با این تفاوت که در یادگیری باناظر، مقدار خروجی مطلوب برای هر ورودی، به طور کامل مشخص است و سیگنال برگشتی نیز به طور کامل درباره جواب مطلوب اطلاعات می دهد. اما گاهی مواقع اطلاعات کمی در مورد ورودی ها موجود است. در یادگیری تشدیددی سیگنال برگشتی که به سیگنال تشدید موسوم است، تنها شبکه را ارزیابی می کند و مشخص می کند که شبکه چقدر خوب یا چقدر بد، به ورودی پاسخ داده است. سیستم تنظیم که نقش سیستم ارزیاب را ایفا می کند، روی سیگنال تشدیددی عمل و آن را به گونه ای تنظیم می کند که در آینده سیگنال تشدیددی بهتری برای تنظیم وزن ها تولید شود.

### ۳- یادگیری بدون ناظر

در یادگیری بدون ناظر یا یادگیری خودسازمانده، مجموعه ای از داده های آموزشی بدون جواب در اختیار سیستم قرار داده می شود. پارامترهای شبکه عصبی توسط سیستم اصلاح و تنظیم می شوند. در این روش هدف یافتن الگوی بین داده ها است که بتواند بر اساس خصوصیات مشابه، داده ها را گروه بندی کند. یادگیری با ناظر برای شبکه هایی که تعداد زیادی لایه های میانی دارند، بسیار کند بوده و در این موارد ترکیب یادگیری با ناظر و بدون ناظر استفاده می شود.

### الگوریتم یادگیری شبکه های عصبی

الگوریتم یادگیری، بیان کننده چگونگی عملکرد شبکه است. به عبارت دیگر تعیین می کند که چه عملیات ریاضی به وسیله هر نرون انجام خواهد شد، خطاها چگونه محاسبه و وزن های اتصال چگونه درست می شوند. سه طیف وسیع از قوانین یادگیری برای شبکه های عصبی وجود دارد که در ذیل توضیح داده شده اند.

### یادگیری عملکردی

در یادگیری عملکردی که دسته وسیعی از قوانین یادگیری شبکه های عصبی را پوشش می دهد، پارامترهای شبکه طوری تنظیم می شوند که عملکرد آن بهینه شود. در این نوع شبکه ها، در ابتدا یک معیار که بطور کمی، عملکرد شبکه را بیان می کند، در نظر گرفته می شود. این معیار را شاخص عملکرد می نامند. اگر عملکرد شبکه خوب و رضایتبخش باشد، این معیار مقدار کوچکی خواهد داشت و برعکس، معیار بالا بیانگر عملکرد نامطلوب شبکه خواهد بود.

### یادگیری حافظه انجمنی

عملکرد حافظه انجمنی، بازیابی مجموعه کاملی از اطلاعات حافظه در شرایطی است که یک قسمت کافی از اطلاعات به سیستم داده شود. این شبکه یک الگو از فعالیت های عصبی ایجاد شده در سطوح خروجی نرون ها را به یک الگو از فعالیت های عصبی (الگوی ورودی) نگاشت می دهد. حافظه به دلیل خصلت انجمنی یا

کندتر از دیگر سلول ها کاهش می یابد. در نهایت سلولی که بیشترین مقدار اولیه یا بیشترین شباهت به بردار ورودی را دارد، خروجی غیر صفر و بقیه سلول ها خروجی صفر خواهند داشت. این وضعیت، حالت ماندگار شبکه است و اندیس این سلول، اندیس بردار مرجعی خواهد بود که بیشترین همبستگی را با بردار ورودی دارد. چون تنها یک سلول دارای خروجی غیر صفر دارد، این نوع رقابت به رقابت WTA یا winner-take-all موسوم است. برای یافتن اندیس سلول برنده از تابع تبدیل  $COMP$  استفاده می شود. این تابع تبدیل، اندیس  $i^*$  را که شماره سلول برنده است، می یابد و سپس  $a_i^*$  را برابر ۱ و  $a_i$  ( $i \neq i^*$ ) را برابر صفر قرار می دهد. رابطه ریاضی تابع  $COMP$  به صورت زیر است:

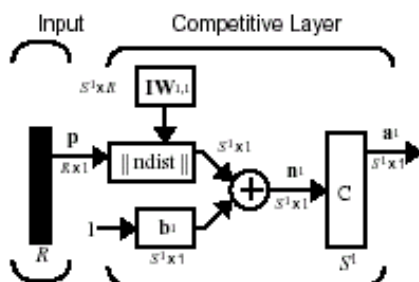
$$\underline{a} = COMP(n) \Rightarrow a_i = \begin{cases} 1 & i = i^* \\ 0 & i \neq i^* \end{cases} \quad (\text{الف-۵})$$

در این لایه وزن های اتصال نرون ها در هر دور آموزش مطابق رابطه زیر تنظیم می گردد:

$$w_i(k) = w_i(k-1) + \alpha a_i(k) [p^T(k) - w_i(k-1)] \quad (\text{الف-۶})$$

که در آن،  $w_i$  سطر  $i$  ام ماتریس  $W$  است.

برای لایه رقابتی، تنها  $a_i$  مربوط به سلول برنده غیر صفر است. بنابراین سطر  $i$  از ماتریس وزن که بیشترین نزدیکی را با بردار ورودی دارد، به سمت بردار ورودی حرکت می کند، اما برای دیگر سلول ها بردار وزن تغییر نمی کند. شکل (الف-۱) ساختمان یک لایه رقابتی را نشان می دهد.



شکل الف-۱: ساختمان یک لایه رقابتی [۱۵].

### شبکه عصبی خود سازمانده کوهنن

همان طور که ذکر شد، در لایه های رقابتی، وزن های ارتباطی بین نرون ها، تابعی از فاصله بین آنها است. نوع ارتباط بین نرون ها به خود مرکز- جانب گریز موسوم

ارتباط دهی خود، توانایی بازیابی صحیح الگوهای ذخیره شده را دارد.

### یادگیری رقابتی

الگوریتم یادگیری شبکه های عصبی رقابتی، از نوع یادگیری بدون ناظر است. هر نرون به عنوان نماینده یک کلاس محسوب می شود. در این شبکه ها خروجی نرون ها با یکدیگر به رقابت می پردازند تا یکی از آنها که امتیاز بیشتری دارد، در رقابت برنده و در بین سایر نرون ها متمایز شود.

### ساختمان لایه های رقابتی

در لایه های رقابتی ابتدا میزان شباهت یا نزدیکی بین بردار ورودی به شبکه و بردار وزن نرون ها سنجیده می شود. معیارهای نزدیکی دو بردار قبلاً توضیح داده شده است. پس از آن بر اساس این شباهت، رقابت بین سلول ها انجام می شود. برای یافتن نرون برنده از تابع تحریک خطی  $posl$  استفاده می شود. عملکرد این لایه توسط روابط زیر بیان می شود:

$$\underline{a}^2(0) = \underline{a}^1 \quad (\text{الف-۱})$$

$$\underline{a}^2(k+1) = posl(W^2 \underline{a}^2(k)) \quad (\text{الف-۲})$$

$$a_i^2(k+1) = posl \left( a_i^2(k) - \varepsilon \sum_{\substack{j=1 \\ j \neq i}}^S a_j^2(k) \right)$$

$$i = 1, \dots, S \quad (\text{الف-۳})$$

که در آن،  $W^2$  ماتریس وزن،  $\underline{a}^2$  بردار خروجی و  $a_i^2$  عنصر  $i$  ام از بردار خروجی لایه دوم است. ماتریس وزن این لایه به شکل زیر تعریف می شود:

$$0 < \varepsilon < \frac{1}{S-1} \quad (\text{الف-۴})$$

$$W_{ij} = \begin{cases} 1 & d_{ij} = 0 \\ -\varepsilon & d_{ij} > 0 \end{cases}$$

که در آن،  $d_{ij}$  فاصله بین نرون های  $i$  و  $j$  است.

ماتریس وزن این لایه موجب می شود هر سلول تأثیری با دارنده روی دیگر سلول ها داشته باشد و نقش مهار جانبی را در لایه دوم ایفا می کند. در هر تکرار، خروجی هر سلول متناسب با جمع خروجی دیگر سلول ها کاهش می یابد. خروجی سلول دارای بیشترین مقدار اولیه، خیلی

نکته مهم در شبکه خود سازمانده کوهنن، تعیین سلول هایی در همسایگی سلول برنده است که باید تغییر وزن دهند. انتخاب سلول های همسایه به طور معمول به یکی از دو روش زیر انجام می شود:

۱- در یک شعاع همسایگی معین در اطراف سلول برنده، همه سلول ها با یک ضریب برابر به سمت ورودی حرکت کنند.

۲- تمام سلول های موجود در شبکه، اما با ضرایب نابرابر به طرف ورودی حرکت کنند. ضرایب باید به گونه ای تنظیم شوند که در خود سلول برنده بیشترین مقدار را داشته و با دور شدن از آن کاهش یابند.

با افزایش زمان عمر شبکه، در روش اول شعاع همسایگی کاهش می یابد و در روش دوم ضرایب کمتر می شوند. در روش اول در لبه ناحیه همسایگی تغییرات شدیدی وجود دارد و این موضوع احتمال بروز خطا را در شبکه افزایش می دهد، در حالیکه در روش دوم چنین تغییرات شدیدی وجود ندارد. در روش دوم به دلیل اینکه همه سلول های شبکه تغییر وزن می دهند، سرعت عملکرد شبکه کمتر می باشد، اما در روش اول تعدادی از سلول های شبکه تغییر وزن می دهند پس سرعت عملکرد بالاتری خواهد داشت.

### شبکه عصبی LVQ

در شبکه LVQ، یادگیری رقابتی با نظارت همراه است. پس به یک مجموعه نمونه های ورودی - خروجی آموزشی، مطابق رابطه زیر نیاز است:

$$\left\{ (\underline{p}^i, \underline{t}^i), i = 1, 2, \dots, Q \right\} \quad (۸-الف)$$

که در آن، بردار ورودی در مرحله  $i$  ام آموزش و  $\underline{t}^i$  بردار پاسخ مطلوب مربوط به آن است.

در هر تکرار، بردار ورودی  $\underline{p}$  به شبکه اعمال می شود و سپس فاصله بین بردار  $\underline{p}$  با هر یک از بردارهای نمونه ای که توسط ستون های ماتریس  $W^1$  نمایندگی می شوند، محاسبه می شود. نرون های لایه میانی به رقابت می پردازند و نرون برنده،  $i^*$ ، پس از مشخص شدن، دارای خروجی یک می شود و باقی نرون ها دارای خروجی صفر می شوند، مطابق رابطه زیر:

$$\begin{cases} a_i^1 = 1 \\ a_i^1 = 0 \quad \forall i \neq i^* \end{cases} \quad (۹-الف)$$

است. یعنی هر نرون خود را به عنوان مرکز تقویت کند و به طور همزمان تمامی نرون های دیگر را تضعیف می کند. در این لایه ها فقط یک نرون در رقابت برنده و سایر نرون ها بازنده می شوند. در شبکه های عصبی بیولوژیک، نرون ها در لایه های دو بعدی آرایش می گیرند. در این آرایش، نرون ها از راه اتصالات جانبی بطور فشرده به هم مرتبط هستند. در سیستم های عصبی بیولوژیک، به طور معمول انتقال از تقویت به تضعیف به صورت ملایم، متناسب با فاصله بین نرون ها اتفاق می افتد. نرون های نزدیک یکدیگر، ارتباطاتی از نوع تقویتی دارند و میزان تقویت با افزایش فاصله بین نرون ها کاهش می یابد. پس از گذشتن از یک فاصله مشخص، نرون ها از ارتباط ممانعتی برخوردار می شوند و همدیگر را تضعیف می کنند. میزان تضعیف با زیاد شدن فاصله افزایش می یابد. پس در شبکه های رقابتی بیولوژیک، توده ای از نرون های اطراف نرون برنده، فعال می شوند.

کوهنن [۱۶] با تقلید از فعالیت های گروهی، نرون های سیستم های بیولوژیک، نگاشت خود سازمانده را به صورت زیر پیشنهاد کرد:

$$\begin{aligned} \forall i \in N_i(d) \Rightarrow w_i(k) &= w_i(k-1) + \alpha(p(k) - w_i(k-1)) \\ N_i(d) &= \{j, d_{ij} \leq d\} \end{aligned} \quad (۷-الف)$$

که در آن،  $N_i(d)$  مجموعه ای از اندیس ها را شامل می شود که برای همگی آنها، نرون ها با فاصله شعاعی  $d$  از نرون برنده قرار دارند.  $i^*$  مشخص کننده نرون برنده،  $\alpha$  نرخ یادگیری شبکه یا تغییر وزن ها در هر مرحله،  $\underline{p}$  بردار ورودی شبکه و  $w_i$  بردار وزن نرون  $i$  ام می باشد. طبق این رابطه، پس از اعمال ورودی  $\underline{p}$ ، بردارهای وزن نرون برنده و تمام نرون های همجوار آن که دارای میزان همجواری  $d$  با آن نرون هستند، به سمت بردار  $\underline{p}$  حرکت خواهند کرد. پس از تعداد زیادی تکرار و ارائه ورودی های مختلف به شبکه، نرون های همجوار، بردارهایی را که شبیه به هم هستند، یاد خواهند گرفت.

در نگاشت های شاخص خود سازمانده، نرون ها می توانند در الگوهای یک بعدی، دو بعدی، سه بعدی یا بیشتر مرتب شوند. تعریف فاصله هم می تواند تغییر کند و همسایگی های مستطیلی، شش وجهی، تصادفی و غیره تعریف شوند. به عبارتی اجرای شبکه، به فرم دقیق همسایگی حساس نیست.

می شود. در این شبکه ها بسته به اینکه چگونه مقادیر اولیه بردارهای وزن در لایه میانی مرتب شده اند، ممکن است یک سلول جهت رسیدن به ناحیه ای که متعلق به طبقه در برگیرنده اش است، مجبور شود از ناحیه ای بگذرد که آن ناحیه به طبقه ای تعلق داشته باشد که در برگیرنده نرون مربوط به آن نباشد. چنین نرونی ممکن است نتواند از آن ناحیه گذر کند، بنابراین ممکن است نرون هرگز نتواند به طور صحیح ناحیه ای را که به آن تعلق دارد، طبقه بندی کند. این موضوع با بهبودی در قانون کوهنن، قابل رفع است. به این ترتیب که اگر نرون برنده در لایه میانی، بردار ورودی را به درستی طبقه بندی نکرد، بردار آن نرون طوری تنظیم می شود که از بردار ورودی فاصله بگیرد و به طور همزمان بردار وزن متناظر با نرونی که بیشترین نزدیکی را با بردار ورودی دارد، طوری تنظیم می شود که به سمت بردار ورودی حرکت کند. پس اگر شبکه بردار ورودی را به درستی طبقه بندی کرد، تنها بردار وزن یک نرون به سمت ورودی نزدیک می شود. اما اگر بردار ورودی را به طور صحیح طبقه بندی نکرد، بردار وزن دو نرون تنظیم می شوند، یکی به سمت بردار ورودی نزدیک می شود و دیگری از بردار ورودی دور می شود.

سپس برای محاسبه بردار خروجی لایه دوم، مطابق روابط زیر عمل می شود:

$$\underline{a}^2 = W^2 \underline{a}^1 \quad (الف-۱۰)$$

$$W^2 = \begin{cases} w_{ji}^2 = 0 & j \neq j^* \\ & i = 1, 2, \dots, S_1 \\ & j = 1, 2, \dots, S_2 \\ w_{ji}^2 = 1 & j = j^* \end{cases} \quad (الف-۱۱)$$

که در آن،  $\underline{a}^2$  خروجی لایه دوم،  $\underline{a}^1$  خروجی لایه اول،  $W^2$  ماتریس وزن لایه دوم،  $j^*$  طبقه ای که بردار ورودی به آن تعلق دارد، است.  $\underline{a}^2$  تنها یک عنصر غیر صفر مانند  $j^*$  دارد. سپس قانون یادگیری کوهنن برای تنظیم پارامترهای لایه میانی شبکه LVQ، به شکل زیر به کار می رود:

$$\exists a_{j^*}^2 = t_{j^*}(k+1) = 1 \Rightarrow \quad (الف-۱۲)$$


$$w_i^1(k+1) = w_i^1(k) + \alpha(p^T(k+1) - w_i^1(k))$$

که در این حالت  $\underline{p}$  به درستی طبقه بندی شده است. بنابراین بردار وزن  $w_i^1$  از نرون برنده در لایه مخفی به سمت بردار ورودی  $\underline{p}$  حرکت می کند.

$$\exists a_{j^*}^2 = 1 \neq t_{j^*}(k+1) = 0 \Rightarrow \quad (الف-۱۳)$$

$$w_i^1(k+1) = w_i^1(k) - \alpha(p^T(k+1) - w_i^1(k))$$

که در این حالت  $\underline{p}$  به درستی طبقه بندی نشده است. بنابراین این نرون به غلط برنده رقابت شده است و بردار وزن  $w_i^1$  از بردار ورودی  $\underline{p}$  دور می شود. در شکل (الف-۲) ساختمان یک شبکه رقابتی LVQ نشان داده شده است.



شکل الف-۲: ساختمان شبکه عصبی LVQ [15].

پس در شبکه LVQ، هر نرون در لایه دوم، به سمت بردارهایی حرکت می کند که به طبقه ای تعلق دارد که آن نرون، زیر طبقه ای را در آن می سازد. این نرون برعکس، از بردارهای ورودی که به طبقات دیگر تعلق دارند، دور