

به نام خدا

Kohonen Network

(Self Organization Map)

گردآوری

مهدي صالح پور، امير حبيب زاده

زير نظر استاد

آقاي دكتور هادي صدوقى يزدي

(دانشگاه تربيت معلم سبزوار)

كلمات کلیدی

شبکه های عصبی، *Kohonen*

چکیده

شبکه عصبی مصنوعی یا *ANN* (*Artificial Neural Network*) یک نمونه سیستم پردازش است که در آن از سیستم های عصبی بیولوژیکی مانند مغز الهام گرفته شده است. عضو کلیدی این ساختار جدید سیستم پردازنده اطلاعات می باشد که تعداد زیادی از آنها به صورت مجتمع مانند هورمونهای مغز با یکدیگر کار می کنند تا بتوانند مسائل خاصی مانند تشخیص الگو یا طبقه بندهی داده ها را از طریق فرایند یادگیری حل نمایند.



۱. شبکه عصبی چیست؟

شبکه عصبی مصنوعی یا *ANN* (Artificial Neural Network) یک نمونه سیستم پردازش است که در آن از سیستم‌های عصبی بیولوژیکی مانند مغز الهام گرفته شده است. عضو کلیدی این ساختار جدید سیستم پردازنده اطلاعات می‌باشد که تعداد زیادی از آنها به صورت مجتمع مانند هورمونهای مغز با یکدیگر کار می‌کنند تا بتوانند مسائل خاصی مانند تشخیص الگو یا طبقه‌بندی داده‌ها را از طریق فرایند یادگیری حل نمایند.


۱-۱. شباهت با مغز

اگرچه مکانیسم‌های دقیق کارکرد مغز انسان (یا حتی جانوران) به‌طور کامل شناخته شده نیست، اما با این وجود جنبه‌های شناخته شده‌ای نیز وجود دارند که الهام بخش تئوری شبکه‌های عصبی بوده‌اند. به عنوان مثال، یکی از سلول‌های عصبی، معروف به نرون (*Neuron*) است که دانش بشری آن را به عنوان سازنده اصلی مغز می‌انگارد. سلول‌های عصبی قادرند تا با اتصال به یکدیگر تشکیل شبکه‌های عظیم بدهند. گفته می‌شود که هر نرون می‌تواند به هزار تا ده هزار نرون دیگر اتصال یابد (حتی در این مورد عدد دویست هزار هم به عنوان یک حد بالایی ذکر شده است).

قدرت خارق‌العاده مغز انسان از تعداد بسیار زیاد نرون‌ها و ارتباطات بین آنها ناشی می‌شود. ساختمان هر یک از نرون‌ها نیز به‌تفہمی بسیار پیچیده است. هر نرون از بخش‌ها و زیرسیستم‌های زیادی تشکیل شده است که از مکانیسم‌های کنترلی پیچیده‌ای استفاده می‌کنند. سلول‌های عصبی می‌توانند از طریق مکانیسم‌های الکتروشیمیایی اطلاعات را انتقال دهند. بر حسب مکانیسم‌های به کار رفته در ساختار نرون‌ها، آنها را به بیش از یکصد‌گونه متفاوت طبقه‌بندی می‌کنند. در اصطلاح فنی، نرون‌ها و ارتباطات بین آنها، فرایند دودویی (*Binary*)، پایدار (*Stable*) یا همزمان (*Synchronous*) محسوب نمی‌شوند.

در واقع، شبکه‌های عصبی شبیه‌سازی شده یا کامپیوتری، فقط قادرند تا بخش کوچکی از خصوصیات و ویژگی‌های شبکه‌های عصبی بیولوژیک را شبیه‌سازی کنند. در حقیقت، از دید یک مهندس نرم‌افزار، هدف از ایجاد یک شبکه عصبی نرم‌افزاری، بیش از آنکه شبیه‌سازی مغز انسان باشد، ایجاد مکانیسم دیگری برای حل مسائل مهندسی با الهام از الگوی رفتاری شبکه‌های بیولوژیک است.

۱-۲. روش کار نرون‌ها




در شکل یک، نمای ساده شده‌ای از ساختار یک نرون بیولوژیک نمایش داده شده است. به طور خلاصه، یک نرون بیولوژیک، پس از دریافت سیگنال‌های ورودی (به شکل یک پالس الکتریکی) از سلول‌های دیگر، آن سیگنال‌ها را با یکدیگر ترکیب کرده و پس از انجام یک عمل (*operation*) دیگر بر روی سیگنال ترکیبی، آن را به صورت خروجی ظاهر می‌سازد.

همان‌طور که در تصویر مشاهده می‌کنید، نرون‌ها از چهار بخش اصلی ساخته شده‌اند. دندrit‌ها هستند که به شکل رشته‌های طویل از مرکز سلول به اطراف پراکنده می‌شوند. دندrit‌ها نقش کانال‌های ارتباطی را برای انتقال دادن سیگنال‌های الکتریکی به مرکز سلول بر عهده دارند. در انتهای دندrit‌ها، ساختار بیولوژیکی ویژه‌ای به نام سیناپس واقع شده است که نقش دروازه‌های اتصالی کانال‌های ارتباطی را ایفا می‌کند. در واقع سیگنال‌های گوناگون از طریق سیناپس‌ها و دندrit‌ها به مرکز سلول منتقل می‌شوند و در آنجا با یکدیگر ترکیب می‌شوند. عمل ترکیب که به آن اشاره کردیم، می‌تواند یک عمل جمع جبری ساده باشد. اصولاً اگر چنین نیز نباشد، در مدل‌سازی ریاضی می‌توان آنرا یک عمل جمع معمولی در نظر گرفت که پس از آن تابع ویژه‌ای بر روی سیگنال اثر داده می‌شود و خروجی به شکل سیگنال الکتریکی متفاوتی از طریق اکسان (و سیناپس آن) به سلول‌های دیگر انتقال داده می‌شود.

البته تحقیقات جدید نمایانگر این واقعیت هستند که نرون‌های بیولوژیک بسیار پیچیده‌تر از مدل ساده‌ای هستند که در بالا تشریح شد. اما همین مدل ساده می‌تواند زیربنای مستحکمی برای دانش شبکه‌های عصبی مصنوعی (*Artificial Neural Network = ANN*) تلقی گردد و متخصصان گرایش شبکه‌های عصبی یا هوش مصنوعی می‌توانند با پیگیری کارهای دانشمندان علوم زیست‌شناسی، به بنیان‌گذاری ساختارهای مناسب‌تری در آینده دست بزنند.


۱-۳. مدل ریاضی

در متون فنی برای نمایش مدل ساده‌ای که در بالا تشریح گردید، به‌طور معمول از شکلی مشابه شکل ۲ استفاده می‌شود. در این شکل کلاسیک، از علامت p برای نشان دادن یک سیگنال ورودی استفاده می‌شود. در واقع در این مدل، یک سیگنال ورودی پس از تقویت (یا تضعیف) شدن به اندازه پارامتر w ، به صورت یک سیگنال الکتریکی با اندازه pw وارد نرون می‌شود. به جهات ساده‌سازی مدل ریاضی، فرض می‌شود که در هسته سلول عصبی، سیگنال ورودی با سیگنال دیگری به اندازه b جمع می‌گردد. در واقع سیگنال b خود به معنی آن است که سیگنالی به اندازه واحد در پارامتری مانند b ضرب (تقویت یا تضعیف) می‌شود. مجموع حاصل، یعنی سیگنالی به اندازه $b + pw$ ، قبل از خارج شدن از سلول تحت عمل یا فرآیند دیگری واقع می‌شود که در اصطلاح فنی به آن تابع انتقال (*Transfer Function*) می‌گویند. این موضوع در شکل به‌وسیله جعبه‌ای نمایش داده شده است که روی آن علامت f قرار داده شده است. ورودی این جعبه همان سیگنال $b + pw$ است و خروجی آن یا همان خروجی سلول، با علامت a نشانه گذاری شده است. در ریاضی، بخش آخر مدل‌سازی توسط رابطه $a = f(pw + b)$ نمایش داده می‌شود. پارامتر w یا همان ضریبی که سیگنال ورودی p در آن ضرب می‌شود، در اصطلاح ریاضی به نام پارامتر وزن یا *weight* نیز گفته می‌شود.



زمانی که از کنار هم قرار دادن تعداد بسیار زیادی از سلول‌های فوق یک شبکه عصبی بزرگ ساخته شود، شبکه‌ای در دست خواهیم داشت که رفتار آن علاوه بر تابع خروجی f ، کاملاً به مقادیر w و b وابسته خواهد بود. در چنین شبکه بزرگی، تعداد بسیار زیادی از پارامترهای w و b باید توسط طراح شبکه مقداردهی شوند. این پروسه از کار، در اصطلاح دانش شبکه‌های عصبی، به فرآیند یادگیری معروف است. در واقع در یک آزمایش واقعی، پس از آن که سیگنال‌های ورودی چنین شبکه بزرگی اتصال داده شدند، طراح شبکه با اندازه‌گیری خروجی و با انتخاب پارامترهای w و b به‌گونه‌ای که خروجی مطلوب به دست آید، شبکه را <آموزش> می‌دهد. به این ترتیب پس از آنکه چنین شبکه به ازای مجموعه‌ای از ورودی‌ها برای ساختن خروجی‌های مطلوب <آموزش> دید، می‌توان از آن برای حل مسائلی که از ترکیب متفاوتی از ورودی‌ها ایجاد می‌شوند، بهره برد.

تابع f می‌تواند بر حسب کاربردهای گوناگون به‌طور ریاضی، به شکل‌های متفاوتی انتخاب شود. در برخی از کاربردها، پاسخ مسائل از نوع دودویی است. مثلاً مسأله به‌گونه‌ای است که خروجی شبکه عصبی باید چیزی مانند <سیاه> یا <سفید> (یا <نه> یا <آری>) باشد. در واقع چنین مسائلی نیاز به آن دارند که ورودی‌های دنیای واقعی به مقادیر گستته مانند مثال فوق تبدیل شوند. حتی می‌توان حالتی را در نظر گرفت که خروجی دودویی نباشد، اما همچنان گستته باشد. به عنوان مثال، شبکه‌ای را در نظر بگیرید که خروجی آن باید یکی از حروف الفباء، مثلاً از بین کاراکترهای اسکی (یا حتی یکی از پنجاه هزار کلمه متداول زبان انگلیسی) باشد. در چنین کاربردهایی، روش حل مسئله نمی‌تواند صرفاً بر جمع جبری سیگنال‌های ورودی تکیه نماید. در این کاربردها، ویژگی‌های خواسته شده فوق، در تابع خروجی یا تابع انتقال f گنجانیده می‌شوند. مثلاً اگر قرار باشد خروجی فقط یکی از مقادیر صفر یا یک را شامل شود، در این صورت می‌توان تابع خروجی شبکه عصبی را به شکل بخش a شکل شماره ۳ انتخاب کرد. در این حالت، خروجی چنین شبکه‌ای فقط می‌تواند بر حسب ورودی‌های متفاوت، مقدار یک یا صفر باشد.



در گروه دیگری از مسائلی که حل آن‌ها به شبکه‌های عصبی واگذار می‌شود، خروجی شبکه عصبی الزاماً بین مقادیر معلوم و شناخته شده واقع نمی‌شود. مسائلی از نوع شناسایی الگوهای تصویری، نمونه‌ای از چنین مواردی محسوب می‌شوند. شبکه‌های عصبی در این موارد، باید به‌گونه‌ای باشند که قابلیت تولید مجموعه نامتناهی از پاسخ‌ها را داشته باشند. رفتار حرکتی یک روبات نمونه‌ای از <هوشی> است که چنین شبکه‌های عصبی می‌توانند فراهم آورند. اما در چنین شبکه‌هایی هم لازم خواهد بود که خروجی بین مقادیر مشخصی محدود شده باشد (موضوع محدود شدن خروجی بین دو مقدار حدی ماکزیمم و مینیمم را در اینجا با موضوع قبلی اشتباہ نگیرید). در این مورد خروجی مسأله اساساً گستته نیست و حتی در بین چنین مقادیر حدی، می‌توان به تعداد نامتناهی خروجی دست یافت). اهمیت این موضوع زمانی آشکار می‌شود که از مثال واقعی کمک گرفته شود. فرض کنید قراراست از شبکه عصبی برای کنترل حرکت بازوی یک روبات استفاده شود. در صورتی که خروجی یک شبکه عصبی برای کنترل نیروی حرکتی به کار گرفته شود، طبیعی خواهد بود که اگر خروجی شبکه محدود نشده باشد، ممکن است بازوی روبات بر اثر حرکت بسیار سریع، به خود و یا محیط اطراف آسیب برساند. در چنین مواردی ممکن است از تابع انتقال به‌شکل بخش b شکل شماره ۳ استفاده شود.

قبل از آنکه به بخش دیگری از موضوع شبکه‌های عصبی پردازیم، باید یک نکته را یادآوری کنیم که همان‌طور که در ابتدای این بخش تشریح شد، سلول‌های عصبی دارای ورودی‌های متعددی هستند و خروجی آنها نیز الزاماً محدود به یک خروجی نیست. بر این اساس زمانی که بخواهیم از مدل‌سازی ریاضی برای مدل کردن یک سلول عصبی استفاده کنیم، به جای آن که همانند شکل ۲ از یک ورودی p و یک خروجی a استفاده کنیم، از یک بردار p و یک بردار a سخن می‌گوییم. بدین ترتیب بدون آنکه نیاز به اعمال تغییری در این تصویر داشته باشیم، می‌توانیم از آن برای مدل‌سازی سلولی با n ورودی $(p_1, p_2, p_3, \dots, p_n)$ و به همین ترتیب m خروجی (a_1, a_2, a_m) استفاده کنیم. توجه داشته باشید که در این صورت، تعداد عناصر b و w نیز به تناسب افزایش می‌یابند و هر یک به n عدد افزایش می‌یابند.


۲. عملیات شبکه‌های عصبی

تا اینجا تمام توجه ما معطوف ساختار درونی یک نرون مصنوعی یا المان پردازشی بود. اما بخش مهم دیگری در مراحل طراحی یک شبکه عصبی نیز وجود دارد. در واقع هنر یک طراح شبکه‌های عصبی می‌تواند در چگونگی ترکیب نرون‌ها در یک شبکه (*neuronal Clustering*)، متجلی شود. علوم بیولوژی نشان داده‌اند که کلاسترینگ نرون‌های شبکه‌های عصبی را می‌توان با اغماس زیاد، مدل‌های الکترونیکی از ساختار عصبی مغز انسان نامید. مکانیسم فرآگیری و آموزش مغز اساساً بر تجربه استوار است. مدل‌های الکترونیکی شبکه‌های عصبی طبیعی نیز بر اساس همین الگو بنا شده‌اند و روش برخورد چنین مدل‌هایی با مسائل، با روش‌های محاسباتی که به‌طور معمول توسط سیستم‌های کامپیوتری در پیش گرفته شده‌اند، تفاوت دارد. می‌دانیم که حتی ساده‌ترین مغزهای جانوری هم قادر به حل مسائلی هستند که اگر نگوییم که کامپیوترهای امروزی از حل آنها عاجز هستند، حداقل در حل آنها دچار مشکل می‌شوند. به عنوان مثال، مسائل مختلف شناسایی الگو، نمونه‌ای از مواردی هستند که روش‌های معمول محاسباتی برای حل آنها به نتیجه مطلوب نمی‌رسند. در حالی که مغز ساده‌ترین جانوران به راحتی از عهده چنین مسائلی بر می‌آید. تصور عموم کارشناسان IT بر آن است که مدل‌های جدید محاسباتی که بر اساس شبکه‌های عصبی بنا می‌شوند، جهش بعدی صنعت IT را شکل می‌دهند. تحقیقات در این زمینه نشان داده است که مغز، اطلاعات را همانند الگوهای *(pattern)* ذخیره می‌کند. فرآیند ذخیره‌سازی اطلاعات به صورت الگو و تجزیه و تحلیل آن الگو، اساس روش نوین محاسباتی را تشکیل می‌دهند. این حوزه از دانش محاسباتی (*computation*) به هیچ وجه از روش‌های برنامه‌نویسی سنتی استفاده نمی‌کند و به جای آن از شبکه‌های بزرگی که به صورت موازی آرایش شده‌اند و تعلیم یافته‌اند، بهره می‌جويد. در ادامه این نوشه به این واژگان که در گرایش شبکه‌های عصبی، معانی ویژه‌ای دارند، بیشتر خواهیم پرداخت

۱-۲. پیاده‌سازی‌های الکترونیکی نرون‌های مصنوعی

نرم‌افزارهایی که در آن‌ها از شبکه‌های عصبی استفاده شده است، نرون‌های شبکه را المان پردازنده (Processing element) می‌نامند. به طور معمول در محصولات نرم‌افزاری، المان‌های پردازنده قابلیت بسیار بیشتری از نمونه ساده‌شده‌ای که در بخش‌های پیشین تشریح کردیم، دارند. در شکل شماره ۴، نمایی با جزئیات بیشتر از یک نرون مصنوعی را نشان می‌دهد.

در این مدل، ورودی‌ها در نخستین گام، در ضریب وزنی (weighting factor) متناظر خود ضرب می‌شوند. در مرحله بعد، ورودی‌هایی که تغییر مقیاس داده‌اند وارد واحدی می‌شوند که در آن سیگنال‌های ورودی با هم ترکیب می‌شوند. به طور معمول عمل ترکیب در این واحد همان عمل جمع جبری است، اما در اصول، می‌توان در این واحد، ورودی‌ها را به روش‌های دیگری علاوه بر عمل جمع معمولی نیز با یکدیگر ترکیب کرد. مثلاً می‌توان به جای عمل جمع، از عمل متوسط گیری، انتخاب بزرگترین، انتخاب کوچک‌ترین، عمل OR یا AND منطقی هم استفاده کرد. در واقع هدف نهایی در این واحد آن است که از تعداد n ورودی، یک سیگنال خروجی برای ارائه به بخش‌های بعدی فرایند، به دست آید. انتخاب نوع <عمل> در این واحد، موضوع دقیقی است که کاملاً به کاربرد مسئله وابسته است.




به طور معمول در نرم‌افزارهای تجاری، امکان انتخاب و حتی ساختن توابع گوناگون برای این واحد، از طرف نرم‌افزار به کاربران داده می‌شود. حتی می‌توان کاربردهایی یافت که در آنها، عمل ترکیب در این واحد، وابسته به زمان باشد و در زمان‌های گوناگون پردازش مسئله، عملیات مختلفی برای ترکیب کردن ورودی‌ها به کار برد شوند.

در هر صورت، پس از آنکه ورودی‌ها با یکدیگر ترکیب شدند، سیگنال حاصل به واحد دیگری که در آن تابع انتقال یا *Transfer Function* به سیگنال اعمال می‌شود، هدایت می‌گردد. خروجی این بخش، سیگنال‌های حقیقی خواهد بود. بدین ترتیب جعبه‌ای در دست خواهیم داشت که تعداد n عدد سیگنال ورودی را به m عدد سیگنال خروجی تبدیل می‌کند. در عمل توابع انتقالی که در بخش انتهایی نمودار شکل ۴ به کار برده می‌شوند، معمولاً یکی از توابع سینوسی، تانژانت هذلولی، *sigmoid* و نظایر این‌ها است. در تصویر شماره ۵، نمونه‌ای از یک تابع انتقال از نوع *sigmoid* نمایش داده شده است. همانطور که در این شکل مشاهده می‌کنید، این تابع انتقال، سیگنال خروجی واحد ترکیب را به سیگنال خروجی تبدیل می‌کند که مقدار (یا اندازه آن) بین صفر و یک می‌تواند باشد.

در عمل، سیگنال خروجی یک المان پردازنده می‌تواند بحسب نوع کاربرد، به المان‌های پردازشی دیگر و یا به اتصالات دیگر خارج از شبکه عصبی هدایت شود. در واقع تمامی شبکه‌های عصبی بر اساس ساختار المان‌های پردازشی فوق کار می‌کنند. در قسمت بعدی این مقاله به تشریح عملیات در شبکه‌های عصبی و آموزش این شبکه‌ها می‌پردازیم

Output value



شبکه عصبی مغز ما به گونه‌ای است که ما را قادر می‌سازد تا اطلاعات را به صورتی پویا، تعاملی و خودسامان (*Selforganizing*) پردازش کنیم. در شبکه‌های عصبی بیولوژیک، نرون‌ها در ساختاری سه بعدی به یکدیگر اتصال یافته‌اند. اتصالات بین نرون‌ها در شبکه‌های عصبی بیولوژیک آنقدر زیاد و پیچیده است که به هیچ وجه نمی‌توان شبکه مصنوعی مشابهی طراحی کرد. تکنولوژی مدارات مجتمع امروزی به ما امکان می‌دهد که شبکه‌های عصبی را در ساختارهای دو بعدی طراحی کنیم. علاوه بر این،

چنین شبکه‌های مصنوعی دارای تعداد محدودی لایه و اتصالات بین نرون‌ها خواهند بود. بدین ترتیب، این واقعیات و محدودیت‌های فیزیکی تکنولوژی فعلی، دامنه کاربردهای شبکه‌های عصبی مبتنی بر تکنولوژی سیلیکونی را مشخص می‌سازند.

ساختار شبکه‌های عصبی امروزی، از لایه‌های نرونی تشکیل شده است. در چنین ساختاری، نرون‌ها علاوه بر آنکه در لایه خود به شکل محدودی به یکدیگر اتصال داده شده‌اند، از طریق اتصال بین لایه‌ها نیز به نرون‌های طبقات مجاور ارتباط داده می‌شوند. در شکل ۱ نمونه‌ای از ساختار لایه‌ای یک شبکه عصبی مصنوعی نمایش داده شده است (تعداد اتصالات ممکن بین نرون‌ها را در چنین ساختاری با تعداد اتصالات بین نرون‌های مغز انسان، مقایسه کنید).


در این توپولوژی، گروهی از نرون‌ها از طریق ورودی‌های خود با جهان واقعی ارتباط دارند. گروه دیگری از نرون‌ها نیز از طریق خروجی‌های خود، جهان خارج را می‌سازند. در واقع این <جهان خارج> تصویری است که شبکه عصبی از ورودی خود می‌سازد یا می‌توان چنین گفت که جهان خارج <تصوری> است که شبکه عصبی از ورودی خود دارد. خلاصه آنکه در توپولوژی فوق، مابقی نرون‌ها از دید پنهان هستند.

تلاش محققان در زمینه شبکه‌های عصبی نشان داده است که شبکه‌های عصبی، چیزی بیشتر از یک مشت نرون که به یکدیگر اتصال داده شده‌اند، هستند. حتی گروهی از محققان سعی داشته‌اند که از اتصالات تصادفی برای ارتباط دادن نرون به یکدیگر استفاده کنند که در این زمینه به نتایج جالب توجهی دست نیافتد. امروزه مشخص شده است که در ساده‌ترین مغزهای بیولوژیک مانند مغز مارها هم ارتباطات بین نرون‌ها بسیار ساخت‌یافته است. در حال حاضر یکی از ساده‌ترین روش‌های ارتباط دهنده نرون‌ها در شبکه‌های عصبی، آن است که ابتدا نرون‌ها در گروههای مشخصی به صورت لایه‌های نرونی سازمان‌دهی می‌شوند و پس از تامین ارتباطات بین‌نرونی در هر لایه، ارتباطات بین لایه‌ها نیز برقرار می‌شوند.

اگرچه در کاربردهای مشخصی می‌توان با موفقیت از شبکه‌های عصبی تک لایه استفاده کرد، اما رسم بر آن است که شبکه‌های عصبی حداقل دارای سه لایه باشند (همانطور که قبلًا اشاره شد، لایه ورودی، لایه خروجی و نهایتاً لایه پنهان یا لایه میانی).

در بسیاری از شبکه‌های عصبی، اتصالات بین‌نرونی به گونه‌ای است که نرون‌های لایه‌های میانی، ورودی خود را از تمام نرون‌های لایه پایینی خود (به طور معمول لایه نرون‌های ورودی) دریافت می‌کنند. بدین ترتیب در یک شبکه عصبی، سیگنال‌ها به تدریج از یک لایه نرونی به لایه‌های بالاتر حرکت می‌کنند و در نهایت به لایه آخر و خروجی شبکه می‌رسند. چنین مسیر در اصطلاح فنی *feed forward* نامیده

می‌شود. ارتباطات بین‌نرونی در شبکه‌های عصبی از اهمیت بسیار زیادی برخوردار هستند و به نوعی قدرت یک شبکه عصبی را تعیین می‌کنند. قاعده آن است که ارتباطات بین نرونی را به دو گروه تقسیم‌بندی می‌کنند. یک نوع از ارتباطات بین نرونی، به گونه‌ای هستند که باعث جمع شدن سیگنال در نرون بعدی می‌شوند. گونه دوم ارتباطات بین نرونی باعث تفریق سیگنال در نرون بعدی می‌شوند. در اصطلاح محاوره‌ای گروهی از ارتباطات انگیزش ایجاد می‌کنند و گروه دیگر ممانعت به عمل می‌آورند.



در مواردی، نرون مشخصی از شبکه عصبی تمایل دارد که سیگنال دیگر نرون‌های لایه خود را نادیده بگیرد. چنین حالتی به‌طور معمول در لایه خروجی ایجاد می‌شود. به عنوان مثال، در کاربردهای تشخیص متن (OCR)، فرض کنید که احتمال آنکه کاراکتر مورد شناسایی، حرف P باشد برابر با ۸۵ درصد تعیین شده است و به همین ترتیب احتمال آنکه کاراکتر مورد نظر حرف F باشد، ۶۵ درصد تخمین زده است. در این وضعیت، سیستم باید کاراکتری را برگزیند که دارای درصد احتمال بزرگ‌تر است. در نتیجه در این شبکه عصبی، نرون‌هایی که خروجی F را تجویز می‌کنند، باید نادیده گرفته شوند یا *inhibit* شوند. به چنین فرایندی، *lateral inhibition* گفته می‌شود.

نوع دیگری از ارتباط بین نرونی در شبکه‌های عصبی به ارتباط بازخورد یا *feedback* معروف است. در این نوع از ارتباطات، خروجی یک لایه نرونی به لایه قبلی (یا به لایه‌ای که چند مرحله پایینتر است) اتصال داده می‌شود. در شکل ۲ نمونه‌ای از یک شبکه عصبی نمایش داده شده که در آن از ارتباط بازخوردی استفاده شده است. در نرم‌افزارهای پیشرفته شبکه‌های عصبی، کاربر و طراح شبکه عصبی می‌تواند نوع ارتباطات بین نرون‌ها و لایه‌های آنها را تعیین کند.

۲-۲. آموزش شبکه‌های عصبی

تا اینجا از ساختار شبکه‌های عصبی صحبت کردیم. گفتیم که شبکه‌های عصبی می‌توانند بر اساس طراحی خود سیگنال‌های ورودی را پردازش کنند و به سیگنال‌های خروجی مورد نظر تبدیل نمایند. به طور معمول، پس از آنکه یک شبکه عصبی طراحی و پیاده‌سازی شد، باید پارامترهای w و b (که قبلاً معرفی کردیم) به ازای مجموعه‌هایی از سیگنال‌های ورودی، به گونه‌ای تنظیم شوند که سیگنال‌های خروجی شبکه خروجی مطلوب را تشکیل دهند. چنین فرایندی را آموزش شبکه عصبی می‌نامند

(در نخستین مرحله آموزش، مقادیر w و b به طور تصادفی انتخاب می‌شوند. زیرا تا این پارامترها مقدار نداشته باشند، شبکه عصبی قابل استفاده نخواهد بود) در حین آموزش دیدن شبکه عصبی (یعنی به تدریج همزمان با افزایش دفعاتی که مقادیر پارامترها برای رسیدن به خروجی مطلوب‌تر، تنظیم می‌شوند) مقدار پارامترها به مقدار حقیقی و نهایی خود نزدیک‌تر می‌شوند.

به طور کلی دو روش برای آموزش دادن شبکه‌های عصبی وجود دارد. روش *supervised* و روش *unsupervised*. روش نخست، شامل مراحلی است که در بخش قبل، به طور مختصر تشریح شد. اما در روش *unsupervised* شبکه عصبی باید بدون کمک گرفتن از جهان خارج، بتواند کار آموزش را انجام دهد.

واقعیت آن است که در عمل از روش *supervised* و یا حداکثر از روش‌های ترکیبی استفاده می‌شود و فرایند آموزش *unsupervised* به شکل خالص تنها وعده‌ای است که شاید در آینده بتواند تحقق یابد.

در حال حاضر و در کاربردهای پیشرفته، از روش آموزش *unsupervised* برای ایجاد تنظیمات اولیه بر روی سیگنال‌های ورودی شبکه‌های عصبی استفاده می‌شود و باقی مراحل آموزش شبکه به روش *supervised* ادامه می‌یابد.

همان‌طور که قبلاً اشاره کردیم، در روش معمول آموزش شبکه‌های عصبی، از مجموعه شناخته‌شده‌ای از داده‌های ورودی و خروجی‌های متناظر آنها (*training set data*) برای آموزش دادن شبکه استفاده می‌شود. در چنین فرایندی، پس از اعمال مجموعه‌های داده‌های آموزشی، پارامترهای شبکه به تدریج به سمت مقادیر نهایی خود همگرا می‌شوند.

شبکه‌های عصبی قادر به یافتن الگوهایی در اطلاعات هستند که هیچگاه از وجود آنها اطلاع نداشته است.

بسته‌های نرم‌افزاری پیشرفته تولید و طراحی شبکه‌های عصبی، دارای ابزارهایی هستند که بر روند آموزش شبکه مدیریت می‌کنند. چنین ابزارهایی می‌توانند سرعت همگرایی پارامترهای شبکه را زیر نظر بگیرند و به عنوان مثال، اجازه دهنده که پارامترهای یک شبکه مشخص، در طول چندین روز به دقت کافی و مورد نظر طراحان خود برسد.

در مواردی ممکن است که شبکه عصبی اصولاً موفق به فرآگیری نشود. بدین معنی که پارامترهای شبکه پس از زمان‌های طولانی به مقدار مشخصی همگرا نشود. چنین مواردی ممکن است بر اثر ناکافی بودن داده‌های آموزشی و یا اصولاً نقص طراحی شبکه ایجاد شوند. حتی مواردی در عمل وجود دارند که شبکه عصبی مشخصی، بر اثر آموزش بیش از حد، اصطلاحاً *over trained* شود. توجه داشته باشید که فرایند آموزش شبکه‌های عصبی فقط به ازای زیر مجموعه‌ای از داده‌هایی که قرار شبکه آنها را در کاربرد حقیقی خود پردازش کند، آموزش داده می‌شوند. در صورتی که تعداد داده‌های آموزشی یک شبکه عصبی بیش از اندازه زیاد باشد (در واقع از تمامی داده‌های مسئله برای آموزش دادن به شبکه استفاده شود)،

شبکه عصبی به جای آنکه آموزش ببینند، به حالتی می‌رسد که به آن حفظ کردن اطلاعات می‌گویند. در واقع به جای آنکه یک شبکه عصبی برای حل مسئله از هوش خود کمک بگیرد، از محفوظات خود استفاده می‌کند!

پس از آنکه یک شبکه عصبی به اندازه کافی آموزش دید، طراح یا کاربر شبکه می‌تواند پارامترهای شبکه را قفل کند (هر چند که در مواردی پارامترهای شبکه آزاد گذارده می‌شوند تا در طول کاربرد واقعی بازهم شبکه آموزش ببیند). در این مرحله شبکه عصبی برای کاربرد واقعی خود و حل مسائل آماده خواهد بود. در برخی از ابزارهای تولید و طراحی شبکه‌های عصبی، کل شبکه عصبی به همراه پارامترهای قفل شده آن، تبدیل به نرمافزار مستقلی (مثلاً یک فایل *dll*) می‌شوند که می‌توان از آن در پروژه‌های مشخصی استفاده کرد. در برخی از موارد دیگر، چنین شبکه‌هایی پس از آموزش دیدن، به شکل سخت‌افزاری در قالب یک مدار مجتمع (*IC*) به تولید انبوه یا نیمه انبوه می‌رسند

۲-۲-۱. آموزش *unsupervised* یا تطبیقی (*Adaptive*)

در مورد این روش آموزش گفتیم که شبکه عصبی بدون در اختیار داشتن داده‌های خروجی، در معرض آموزش قرار می‌گیرد. در واقع سیستم به تنها یی و بدون کمک خارجی باید با توجه به شکل سیگنال‌های خروجی خود، درباره درستی و نادرستی آنها تصمیم‌گیری نماید. در دنیای واقعی شرایط بسیار زیادی وجود دارند که در آنها مجموعه اطلاعات کافی برای آموزش دادن به سیستم فراهم نیستند. تحقیقات نظامی یکی از گرایش‌هایی است که به این موضوع توجه دقیقی دارد. به عنوان مثال گفته می‌شود که شرایط جنگی به دلیل فراوانی پارامترها و تکنیک‌های نظامی متغیر و پیشرفتهای تکنولوژی نظامی، از نمونه مواردی است که در آنها به هیچ وجه نمی‌توان مجموعه داده‌های آموزشی کافی به دست آورد.

در این زمینه یکی از محققان شبکه‌های عصبی، به نام *Tuevo Kohonen* (از دانشگاه هلسینکی) فعالیتی جدی دارد. کوهنن با تحقیقات در ساختارهای عصبی غیرمتعارف، به پژوهش در این زمینه ادامه می‌دهد. کوهنن، نرون‌های شبکه‌های عصبی را فیلدهای مختلفی تقسیم‌بندی می‌کند. در روش کوهنن، نرون‌های هر فیلد <مرتب توپولوژیک> یا *Topologically ordered* محسوب می‌شوند (توپولوژی نام شاخه‌ای از ریاضیات است که در آن نگاشت از یک فضای دیگر بدون تغییر مشخصه‌های هندسی، مورد بررسی قرار می‌گیرد). گروه‌بندی‌های سه‌بعدی که در ساختار مغز پستانداران یافت شده است، نمونه‌ای از مرتب‌سازی توپولوژیک محسوب می‌شوند. کوهنن معتقد است که فقدان ملاحظات توپولوژیک در مدل‌های عصبی امروزی، باعث می‌شود که شبکه‌های عصبی امروزی، مدل‌های ساده شده‌ای از شبکه‌های

عصبی واقعی موجود در مغز محسوب شوند. در هر صورت این حوزه از مبحث شبکه‌های عصبی، هنوز در مرحله تحقیقات آزمایشگاهی قرارداد و کاربرد واقعی نیافته است.

یادگیری در شبکه‌های عصبی به دو صورت می‌باشد:

۱- تحت نظارت (*Supervised*)

۲- بدون دخالت انسانها (*Unsupervised*)

یادگیری در شبکه‌های عصبی رایج به شکل *Supervised* یا یادگیری تحت نظارت می‌باشد. در واقع کار شبکه‌های عصبی مانند یادگیری بچه‌ها می‌باشد. با نشان دادن اشیاء ماهیت هر شیء برای کودک مشخص می‌شود.

به عنوان مثال کودک تصاویر انواع مختلف سگ را مشاهده می‌کند، و در کنار آن اطلاعات ورودی تصاویر و صدا برای هر نمونه مطرح می‌گردد که این اطلاعات مربوط به یک نوع سگ می‌باشد و پس از مدتی او قادر خواهد بود یک نوع جدید از سگ را که قبلًا هرگز ندیده است، شناسایی کند.

ANN شاخه‌ای از فیلد هوش مصنوعی و یا سیستم‌های خبره می‌باشد که با منطق فازی مرتبط می‌باشد. یک شبکه عصبی مصنوعی می‌تواند به عنوان یک جعبه سیاه در نظر گرفته شود که قادر است الگوهای خروجی را پس از تشخیص الگوهای ورودی گزارش دهد.

شبکه‌های عصبی در واقع مثلثی هستند که سه ضلع مفهومی دارند:

۱- سیستم تجزیه و تحلیل داده‌ها

۲- نرون یا سلول عصبی

۳- شبکه یا قانون کار گروهی نرونها

شبکه‌های عصبی از دو بابت شبیه مغز عمل می‌کنند:

۱- مرحله‌ای موسوم به یادگیری دارند

نرون‌ها با پردازشگرهای شبکه به صورت غیر مستقیم به کانال‌های ارتباطی مرتبط هستند که وظیفه حمل داده‌ها را بر عهده دارند و تنها بر روی داده‌های محلی خود که به عنوان ورودی از طریق کانال‌های ارتباطی دریافت می‌دارند، عمل می‌کنند. این شبکه‌ها به صورت *Multilayer* می‌باشند که تعداد لایه‌های آن بستگی به پیچیدگی مسئله دارند و تعداد لایه‌ها و تعداد گره‌ها در هر لایه

مخفي از پارامترهایی است که توسط کاربر قابل تنظیم است. هر چه تعداد لایه ها بیشتر باشد سیستم قادر به درک پیچیدگی های بیشتری است. در این شبکه ها با پردازش موازی از طریق وزن ها سیناسپی داده ها راه خود را باز کرده و جلوی داده های *dump* (داده های دارای خطای خطا یا بی ربط) گرفته می شود. طرز کار یک مدل سلول عصبی بدین صورت است که خطوط یا کانالهای ورودی، سیگنالهای تحریکی یا مهاری را که همان پارامترهای تعریف کننده سیستم هستند به جسم سلولی یا گره های عصبی می آورند، مثلاً غلظت یک ماده *mol/lit0.6* است. این پارامتر به عنوان یک سیگنال الکتریکی باشد. ۶٪ به یک کanal ورودی می رود. در ابتدای هر کanal یک ضریب عددی (وزن سیناسپی) وجود دارد که شدت تحریک در آن ضرب می شود. اگر مثبت باشد یک سیگنال تحریکی و اگر منفی باشد یک سیگنال مهاری است؛ این سیگنال های تحریکی یا مهاری که از ورودی های مختلف به جسم سلولی می رسند، با هم به صورت خطی جمع می گردد. اگر از میزان آستانه کمتر باشد سلول عصبی خاموش شده و در غیر این صورت *fire* (شلیک) می شود و جریان الکتریکی ثابتی در خروجی ایجاد می کند که به سلولهای دیگر وارد می شود. مشکل شبکه های عصبی این است که بتدریج به حفظ کردن الگوها می پردازند و قابلیت تجزیه و تحلیل آنها کم می گردد، برای رفع این مشکل باستی تعداد *node* های (گره ها) آنها کم گردد، در این صورت شبکه مجبور به تعمیم می گردد. شبکه های عصبی مصنوعی برای حل مسائل پیچیده و یا مواردی که هیچ راه حل الگوریتمی وجود ندارد و یا بسیار پیچیده هستند مورد استفاده قرار می گیرد. چهار نوع هدف کلی توسط این شبکه های قابل پیگیری است، که هر کدام بسته به نوع مجھولات در مواردی خاص قابل بهره گیری می باشد:

۱۰.۳ اهداف شبکه عصبی

۱-۳ طبقه بندی

برای طبقه بندی، داده های نمونه های مختلف را به شبکه می دهیم و نام گروه هر نمونه را به عنوان خروجی مشخص می کنیم، پس از آموزش مناسب شبکه قادر خواهد بود با دریافت داده های مربوط به نمونه های جدید مشخص کند که این نمونه به کدام طبقه متعلق می باشد. به عنوان مثال میتوان پارامترهای آزمایشگاهی بیماران مبتلا به سرطان پروسات و افراد سالم را به عنوان ورودی وضعیت فرد (سالم بودن یا سرطانی بودن) را به عنوان خروجی به شبکه داده در این صورت شبکه پس از یادگیری خواهد توانست پارامترهای فرد جدید را گرفته و سرطانی بودن او را پیشگویی کند.

۲-۲. تخمین قابع

زمانی که پارامترهای ورودی با تأثیرات پیچیده در سیستم پاسخی قابل اندازه گیری ایجاد می کنند، شبکه می تواند آموزش بیابد تا این پاسخ را پیشگویی کند. به عنوان مثال شبکه می تواند پس از آموزش، با دریافت داده های مربوط به هر مولکول جدید در داروها، شدت اثر آن را پیشگویی کند.

۳-۳. پیشگویی

اصطلاح پیشگویی در اینجا برای سری های زمانی بکاربرده می شود؛ یعنی جایی که داده ها مربوط به نمونه های پیاپی هستند و داده های هر نمونه برای پیشگویی نمونه بعدی استفاده می شود. مانند پیشگویی وضعیت آتی بیمار بستری در بخش *CCU*.

۴-۳. خوشه کردن

این نوع کارکرد شبکه ها مربوط به یادگیری *Unsupervised* است. یعنی طبقه بندهی داده ها بر حسب رفتار و برهمن کنش های درونی آنها بدون داشتن الگو و یا فرضیه قبلی.

۵-۵. کاربرد شبکه های عصبی مصنوعی در علوم پزشکی

ANN در علوم پزشکی و دارویی نیز کاربرد بسیار گسترده ای دارد برخی کاربردهای آن عبارتند از:

۱-۵-۱. سیستم های تشخیص بیماری

ANN به صورت وسیعی در تشخیص بیماریها به کار گرفته شده است و این سیستمها قادرند برای تشخیص سرطان، بیماریهای قلبی عروقی، بیماری سل و عفونتهای سینوسی مورد استفاده قرار گیرند. از مزایای استفاده از *ANN* این است که فاکتورهایی چون خستگی، فرسودگی، وضعیت های عاطفی و یا تحت شرایط خاصی کارکردن روی آنها تاثیری ندارد.

۲-۵-۲. تجزیه و تحلیل های بیوشیمیایی

ANN به صورت وسیع و متنوعی در تجزیه و تحلیل نمونه های خون، ادرار، ردیابی سطح گلوکز در مبتلایان به دیابت، تعیین سطح یون در مایعات بدن مورد استفاده قرار می گیرد.

۳-۵-۳. تجزیه و تحلیل تصویربرداری پزشکی

در تجزیه و تحلیل تصاویر تومورها و *MRI* مورد استفاده قرار می‌گیرد.

۳-۵-۴. توسعه دارویی

ANN به عنوان ابزاری برای توسعه داروهای مرتبط با سرطان و ایدز مورد استفاده قرار می‌گیرد. اگر چه در حال حاضر کاربرد شبکه‌های عصبی در دنیا مربوط به شبکه‌های تحت یادگیری است اما نوع دیگر شبکه‌ها که یادگیری *Unsupervised* دارند از هم اکنون مرزهای جدیدی را به سوی محققین گشوده‌اند و آرزوی یادگیری واقعی ماشینی‌ها بدون دخالت انسانها را برای محققین آرزویی دست یافتنی ساخته‌اند.

۴. تفاوت‌های شبکه‌های عصبی با روش‌های محاسباتی متداول و سیستم‌های

خبره

گفتیم که شبکه‌های عصبی روش متفاوتی برای پردازش و آنالیز اطلاعات ارائه می‌دهند. اما نباید این گونه استنباط شود که شبکه‌های عصبی می‌توانند برای حل تمام مسائل محاسباتی مورد استفاده واقع شوند. روش‌های محاسباتی متداول همچنان برای حل گروه مشخصی از مسائل مانند امور حسابداری، انبارداری و محاسبات عددی مبتنی بر فرمول‌های مشخص، بهترین گزینه محسوب می‌شوند. جدول ۱، تفاوت‌های بنیادی دو روش محاسباتی را نشان می‌دهد

روش پردازش ترتیبی موازی توابع منطقی (*right brained*) و (*left brained*) از *estault* (*right brained*) و *didactically* (*left brained*) به کمک قواعد (دو نسل پنجم محاسبات نام داده‌اند (نسل اول از کلید و سیم‌بندی استفاده می‌کرد، و در مواردی هم به آن نسل پنجم محاسبات داده‌اند) نسل دوم با اختراع ترانزیستور ایجاد شد، نسل سوم از فناوری مدارات مجتمع استفاده می‌کرد، نسل چهارم با وجود آمدن زبان‌های سطح بالا آغاز شد و نسل پنجم شامل هوش مصنوعی می‌شود). به طور معمول، یک سیستم خبره شامل دو بخش عمده می‌شود. یک بخش یا موتور استنتاجی و یک پایگاه دانایی (*Knowledge base*). موتور استنتاجی، بخشی است که رابط کاربر را مدیریت می‌کند و بر فایل‌ها و دسترسی به برنامه‌ها و برنامه‌ریزی کنترل دارد. پایگاه دانایی شامل اطلاعاتی در ارتباط با یک مسئله مشخص است. این پایگاه به متخصصان اجازه می‌دهد که قواعد فرایند مشخصی را تعریف نمایند. چنین متخصصی نیازی به دانستن روش‌های برنامه‌نویسی نخواهد داشت. او تنها باید کاری که از کامپیوتر

می خواهد را در ک کند و شناخت کافی از روش عمل سیستم داشته باشد. درواقع پوسته سیستم بخشی است که به کامپیوتر می گوید چه کار باید انجام دهد. برنامه لازم برای حل مسئله توسط خود سیستم تولید خواهد شد.

تلاش هایی که برای اجرایی کردن سیستم های خبره به کار گرفته شده اند، با مشکلات مشترکی مواجه بوده اند. با افزایش سطح پیچیدگی سیستم ها، منابع کامپیوتری مورد نیاز سیستم به شدت افزایش می یابند و سیستم با کندی بیش از حد رو برو می شود. در حقیقت تجربه نشان داده است که در وضعیت فعلی، سیستم های خبره تنها می توانند در مواقعی مفید واقع شوند که هدف محدود و مشخصی تعیین شده باشد.


شبکه های عصبی در مسیری گام برمی دارند که ابزارها توانایی فرآگیری و برنامه ریزی خود را داشته باشند. ساختار شبکه های عصبی به گونه ای است که قابلیت حل مسئله را بدون کمک فرد متخصص و برنامه ریزی خارجی داشته باشند. شبکه های عصبی قادر به یافتن الگوهایی در اطلاعات هستند که هیچ کس، هیچ گاه از وجود آنها اطلاع نداشته است.

در حالی که سیستم های خبره در عمل به موفقیت های بسیاری دست یافته اند، شبکه های عصبی در کاربردهایی همچون دید مصنوعی، تشخیص و تولید پیوسته گفتار، فرآگیری ماشینی و نظایر آن با مشکلاتی رو برو بوده اند. در حال حاضر شبکه های عصبی کاملاً وابسته به سرعت پردازنده سیستم اجرا کننده هستند

۵. شبکه های خود سازمان ده کوهون

در این بخش روش های فرآگیری بدون سرپرست به ویژه نگاشتهای خود سازمان ده کوهون را مورد بحث قرار می دهیم. در روش های پس انتشار خطا ملاحظه کردیم که آموزش با سرپرست به پاسخ های آموزشی خارجی (پاسخ های مطلوب) که برای کلیه داده های ورودی مجموعه آموزشی معلوم است تکیه دارد. لیکن در بسیاری از کاربردها بهتر است از شبکه بخواهیم که داده های آموزشی را به تنها یی طبقه بندی کند. برای این منظور دو فرض اصلی را برای شبکه باید در نظر بگیریم. اول اینکه عضویت در یک طبقه به طور کلی به معنای داشتن ویژگی های مشترک است. دیگر انکه شبکه می تواند این ویژگی های مشترک را در گسنره داده های ورودی تمیز دهد. باید توجه داشت بردار ورودی ، بردار x عضو فضای R می باشد که هر یک از درایه های آن دارای یک چگالی احتمال است . در این فضای چگالی نمونه هایی را به تناوب و تصادف انتخاب کرده و به شبکه اعمال می کنیم بر اساس موقعیت بردار ورودی در فضای

R وزن های سلول ها طبق الگوریتمی که توضیح داده می شود ، تغییر می کند. این تغییر به نحوی انجام می گیرد که در نهایت، بردار های وزن مربوط به سلول ها (weR) به طور یکنواخت در فضای چگالی احتمال ورودی توزیع می شود و بدین ترتیب شبکه با پراکندن سلول های خود در فضای ورودی چگالی احتمال را تخمین می زند . به کارگیری الگوریتم کوهونن اکثراً دو بعدی است. نکته اشکاری که باید به آن اشاره شود این است که در این شبکه نرون ها به عکس پرسپترون های چند لایه ای در لایه های متفاوت قرار نگرفته اند، بلکه در شبکه ای صاف و هموار ، مانند شکل زیر واقع شده اند. همه ورودی ها به تمام گره های خروجی متصل شده اند. باز خور تنها محدود به ارتباطات جانبی به نرون هایی است که در همسایگی یک نرون قرار دارند. هر گره در شبکه خود، در واقع یک گره محسوب میشود.



۱-۵. الگوریتم کوهونن

الگوریتم آموزشی گره های شبکه را به صورت همسایه های محلی منظم می کند به طوری که بتواند ویژگی های داده های ورودی را طبقه بندی کنند . نقشه توپوگرافی شبکه به طور خودکار با مقایسه دوره ای ورودی های هر گره با برداری که توسط آن گره در خطوط ارتباطی آن ذخیره شده است ، شکل می گیرد. هیچ جواب مطلوبی برای ورودی های آموزشی تعریف نمی شود. هرگاه ورودی های یک گره با بردار ذخیره شده آن گره مطابقت کند، آن ناحی شبکه به طور گزینشی بهینه می شود و به صورتی که نهایتاً نمایانگر میانگینی از داده های آموزشی طبقه ای از داده ها شود. شبکه در حالی که ابتدا به طور تصادفی شکل گرفته است ، به تدریج خود را تنظیم می کند و به حالت پایداری می رسد که به طور موضعی ویژگی های داده های ورودی را نمایش می دهد .

الگوریتم شبکه کوهونن
۱ – مقادیر اولیه را تعیین کنید.

فرض کنید، $Wij(t)$ مقدار ضرایب وزنی از ورودی I به گره خروجی زدر زمان t می باشد. میزان اولیه ضرایب وزنی را با مقایر کوچک تصادفی معین کنید. شعاع همسایگی گره های خروجی j ، $Nj(0)$ در ابتدا بزرگ تعیین کنید.

- ۲ - ورودی ها را به شبکه عرضه کنید.
- ۳ - فاصله ها را محاسبه کنید.

فاصله dj بین بردار ورودی و بردار خروجی هر گره j توسط فرمول زیر محاسبه می شود.

$$dj = \sum_{i=0}^{n-1} [X_i(t) - W_{ij}(t)]^2$$

۴ - کوتاه ترین فاصله را انتخاب می کنیم.

گره خروجی دارای کوتاه ترین فاصله را با علامت * زم叙خص می کنیم .

۵ - ضرایب وزنی را اصلاح می کنیم.

ضرایب وزنی جدید با استفاده از فرمول زیر محاسبه می شود.

$$Wij(t+1) = Wij(t) + eta(t) * (Xi(t) - Wij(t))$$

عبارت $eta(t)$ همان ضریب بهره می باشد. $eta(t) < 1 < 0$) که به تدریج با طول زمان کاهش می یابد. بنابراین ضریب بهره ضرایب وزنی به تدریج کند می شود. اندازه شعاع همسایگی $Nj*(t)$ نیز به تدریج کاهش می یابد. بدین صورت محدوده بیشترین فعالیت به تدریج موضعی می گردد. با رفتن به مرحله ۲ الگوریتم تکرار می شود.

۱-۵. نکاتی چند درباره الگوریتم کوهون

۱-۱-۵. تشابه بردار ورودی با بردار وزن

بردار P و بردارهای دورنی آن هر دو در فضای R تعریف می شود ، لذا دارای یک جنسیت می باشد و با یکدیگر قابل مقایسه هستند. برای بررسی نزدیکی و دوری بردارهای w نسبت به بردار p در فضای R ، به یک معیار تشابه (یا یک معیار مسافت) نیاز داریم. این معیار می تواند فاصله اقلیدسی بین دو بردار باشد که به صورت زیر تعریف می شود.

$$dj = \sum_{i=0}^{n-1} [X_i(t) - W_{ij}(t)]^2$$

۱-۵-۲. اصلاح ضرایب وزنی

در اصلاح ضرایب وزنی شبکه کوهون نیاز به مشتق گیری نیست. با بررسی مجدد الگوریتم کوهون مشاهده می کنیم که تغییرات وزنی متناسب با مقدار تفاوت بین بردار ورودی و بردار ضرایب وزنی است.

$$Wij(t+1) = Wij(t) + eta(t) * (Xi(t) - Wij(t))$$

ضرایب تناسب برابر با $eta(t)$ یعنی ضریب نرخ آموزش است در حالی که $1 < eta(t) < 0$ می باشد. این عبارت در طول زمان نرخ تطبیق را کاهش می دهد. اولین مرحله ، ایجاد نوعی نظم توپوگرافی در گره هایی است که ابتدا به طور تصادفی قرار گرفته اند. فرایند آموزش سعی می کند گره ها را در خوشة هایی قرار دهد که دامنه انواع طبقه ها را در داده های آموزشی نشان دهد . تغییرات در این مرحله در جهت قرار گرفتن گره ها روی نقشه توپوگرافی زیاد است. بنابراین ابتدا نرخ تطبیق بزرگ تعیین می شود($eta > 0.5$) تا میزان تغییرات زیاد باشد و شبکه به سرعت به حالت تقریباً بهینه ای برسد. پس از اینکه نمادی تقریبی به دست آمد ، گره های موضع محلی روی نقشه دقیق تر تنظیم شده و به بردار های آموزشی نزدیک می شود، برای این منظور باید اندازه تغییرات بسیار کوچکتر شود. بنابراین با پیشرفت زمان آموزش نرخ تطبیق کاهش می یابد. هرگاه ورودی آموزشی جدیدی به شبکه اعمال شود، ابتدا باید گره برنده را معین کرد. گره برنده گره ای خواهد بود که بردار ضرایب وزنی آن نزدیک ترین فاصله را با گره ورودی داشته باشد. میزان فاصله در اندازه گیری شباهت بردارها ، فاصله اقلیدسی است. نکات ضریفی در به کار گیری این میزان در روش کوهون وجود دارد که باید به آنها دقت کنیم. نرم اقلیدسی یک بردار طول بردار را نشان می دهد . لیکن ما به طول بردارها چندان علاقه ای نداریم. آنچه مورد علاقه ما می باشد، جهت بردارها می باشد . به عبارت دیگر دو بردار را هنگامی شبیه می گوییم که هر دو بردار صرف نظر از طول آنها در یک جهت باشند. تنها راهی که می توان جهت دو بردار را با استفاده از فاصله اقلیدسی بررسی کنیم این است که ابتدا دو بردار را نرمالیزه کردن یک بردار عناصر یک بردار را بر طول بردار تقسیم می کنیم. بدین صورت برداری به وجود می آید که طول آن برابر با واحد طول ، و جهت آن مشابه با جهت بردار اولیه است. در نتیجه مقایسه بردار ضرایب وزنی و بردار ورودی ، اکنون محدود به مقایسه جهت آن دو بردار خواهد شد. مزیت دیگر نرمالیزه کردن بردارها این است که زمان آموزش شبکه را با حذف یکی از عوامل متغیر فضای ضرایب وزنی کاهش می دهد . این عمل باعث می شود که نحوه قرار گرفتن بردارهای ضرایب وزنی در ابتدای آموزش نزدیک تر به حالت مطلوب باشد و در نتیجه زمان لازم برای اصلاح جهت آنها در طول آموزش کاهش یابد.

۱-۵-۳. تعیین مقادیر اولیه ضرایب وزنی

تا به حال پیشنهاد می کردیم که در ابتدای آموزش ضرایب وزنی را اعداد تصادفی کوچک و نرمالیزه شده قرار دهیم. لیکن موضوع به این سادگی نیست. چنانچه ضرایب وزنی در ابتدا واقعاً تصادفی باشند، احتمال دارد که شبکه واقعاً همگرا نشود و یا دوره ای آموزشی به کندی پیش رود. دلیل این حالت این است که بردارهای ورودی آموزشی به صورت خوشه های متمایز در موضع محدودی از فضای الگوها بنابر

طبقه های خود قرار می گیرند. اگر بدار ضرایب وزنی گره های شبکه در ابتدا کاملاً تصادفی باشند ، این احتمال می رود که تعداد زیادی از بردارهای ضرایب وزنی جهتی بسیار متفاوت با بردارهای آموزشی داشته باشند. این گره ها هرگز برنده هیچ کدام از بردارهای ورودی نخواهند شد و در تشکیل نقشه های توپولوژیکی شرکت نخواهند داشت. در نتیجه عملکرد طبقه بنده نقشه حاصل بسیار ضعیف خواهد بود ، زیرا نمی تواند ورودی ها را به خوبی تمیز دهد. به هر حال روش هایی برای تقریب این توزیع ها موجود است . یکی از روش ها ، انتخاب اولیه بردارهای ضرایب وزنی به صورتی است که تماماً نرمالیزه بوده و بر هم منطبق باشند. به عبارت دیگر، تمام بردارها برابر تعیین می گردد . آنگاه تمام بردارهای آموزشی در ابتدای آموزش به صورت یک دسته بردار هم جهت با بردار اولیه گره ها به شبکه عرضه می شوند. این عمل به همه گره ها احتمال برابر می دهد که به بردار آموزشی نزدیک باشد. به تدریج که آموزش ادامه می یابد ، بردارهای ورودی به آرامی بهجهت اولیه خود برگردانده می شود. همچنین می توان به هر گره مقدار آستانه ای را اضافه نمود که تعدد موقیت گره ها را کنترل کند، به طوری که اگر یک گره به طور مرتب برنده شد مقدار آستانه را افزایش داد و بدین طریق احتمال موفقیت بعدی را کاهش داد. در نتیجه سایر گره ها شанс موفقیت بیشتری را کسب کند .

۴-۱. انتخاب سلول برنده


برای تعیین سلول برنده، همین که di کمینه را بیابیم کافی است. و سلوی که بردار وزنهای آن به بردار ورودی نزدیک تر باشد ، به عنوان سلول برنده شناخته می شود

۵-۱. تعیین سلول هایی که به سمت ورودی حرکت می کنند

در این مورد نکته مهم آن است که از میان تمام سلولها تعدادی ، در حوالی سلول برنده ، به نحوی که سلول برنده در مرکز آنها واقعیه در همسایگی آن قرار می گیرند، باید تغییر یابند انتخاب سلول های همسایه معمولاً به دو روش صورت می پذیرد : اول انکه در یک شعاع همسایگی معین در اطراف سلول برنده ، همه سلول ها با یک ضریب برابر به سمت ورودی حرکت کنند . و دوم اینکه تمام سلول های موجود در شبکه ، ولی با ضرایب نا برابر ، به طرف ورودی حرکت کنند. این ضرایب نا برابر به نحوی هستند که در خود سلول برنده دارای بیشترین مقدار بوده و با دور شدن هر چه بیشتر از آن کمتر و کمتر می شود . در هر یک از این دو حالت زمان عمر شبکه تاثیر دارند در نوع اول شعاع همسایگی با زمان کاهش می یابد و در دومی ضرایب با گذشت زمان کمتر می شود. تفاوت عمدۀ این دو روش در دو نکته زیر است.

اول اینکه روش نخست دارای یک تضاد شدید در لبه ناحیه همسایگی است ، ولی روش دوم چنین تغییر شدیدی را ندارد. این امر باعث بروز حرکت های شدید در روش اول شده و احتمال بروز خطا را افزایش می دهد. دوم اینکه در روش اول چون تعداد سلول هایی که تغییر حالت می یابد کمتر است ، سرعت

عملکرد شبکه بالاتر خواهد بود، در حالت دوم باید تمامی سلول‌ها تغییر حالت بدنه‌ند. عملکرد در روشن اول بدین صورت است که در ابتدا شعاع همسایگی تمامی گره‌ها بسیار بزرگ تعیین می‌گردد. دامنه بزرگی می‌تواند به پهنانی تمامی گره‌های شبکه باشد. وقتی گره‌ای به عنوان نزدیکترین گره به بردار ورودی برنده اعلام شود، ضرایب وزنی آن گره همراه با گره‌های موجود در شعاع همسایگی آن به مقدار یکسان اصلاح می‌شود. لیکن به تدریج که آموزش ادامه می‌یابد شعاع همسایگی به آرامی کاهش می‌یابد تا به حدی که قبل از تعیین شده است برسد.




۵-۲. نحوه نمایش نگاشت


در اینجا نحوه نمایش وضعیت شبکه را برای سه حالت توپولوژی یک بعدی با ورودی یک بعدی، توپولوژی یک بعدی با ورودی دو بعدی و توپولوژی دو بعدی با ورودی دو بعدی مورد بررسی قرار می‌گیرد.

الف- توپولوژی یک بعدی با ورودی یک بعدی


در این شبکه یک بعدی هر سلول از دو طرف دارای همسایگی است و می‌توان سلول‌ها را از لحاظ توپولوژی در یک خط در کنار یکدیگر نشان داد. همچنین هر سلول دارای یک وزن است که مشخص کننده شدت اتصال بین آن سلول و تنها ورودی شبکه است.



ب- توبولوژی یک بعدی با دو ورودی
در اینجا نیز چون توبولوژی یک بعدی استهر سلول در صفحه با یک خط به سلول مجاور خود وصل می شود.



ج- توبولوژی دو بعدی با دو ورودی
در اینجا طبیعتا هر سلول به چهار سلول همسایه خود وصل می شود. به این ترتیب به شکل روبرو در می آید



۳-۵. یک مسئله خواص در مورد SOM

مشکل نرون مرده و روش حل آن :

گاهی در شبکه وضعیتی پیش می آید که یک یا چند سلول عصبی دارای حالت هایی می شوند که در طی بارها و بارها اعمال ورودی ، امکان برنده شدن را از دیگر سلول ها گرفته و خود برنده می شوند. در این صورت بعضی از سلول ها از رقابت فاصله گرفته و تاثیر چندانی بر شبکه نخواهند داشت . این مشکل باعث می شود که در بعضی از قسمت های شکل که مورد نظر نیست، حالت بعضی از سلول ها جا مانده و تغییرات چندانی نداشته باشد. یک راه حل این مشکل آن است که تعداد دفعات برنده شدن سلول را در هنگام انتخاب سلول برتر دخالت دهیم، بدین ترتیب که سلول هایی که بیشتر برنده می شوند، فرصت را در اختیار باقی سلول ها قرار دهند. برای نمونه اگر فرض کنیم تابع $f(ai)$ یک تابع غیر نزولی از

و n تعداد برنده شدن سلول از ابتدای حیات شبکه باشد، می توانیم برای انتخاب سلول برتر، این تابع را با مسافت بین ورودی و حالت سلول جمع کنیم.

$$dj = dj + f(ai)$$

۶. چند کاربرد از شبکه کوهون

۱-۱. ماشین تحریر صوتی

شاید بهترین راه نشان دادن ارزش یک ابتکار معرفی کاربردهای موفق آن باشد. کوهونن الگوریتم نگاشت ویژگی های خود را در مسئله شناخت گفتار که مداوم مورد توجه بوده است به کار گرفت. مسئله مورد بحث طبقه بندی فنوم های گفتاری در زمان واقعی است. فنوم ها مجموعه طبقه بندی کوچکی را تشکیل می دهند که نمونه های هر طبقه تفاوت های ظریفی با طبقات دیگر دارد این بدان معنی است که باید فقط تعداد محدودی گره ویژگی یا ب در نقشه توپوگرافی شبکه تشکیل شود، که هر کدام گره های فراوان در همسایگی خود دارد که در فاصله محدود تنظیم شده است شناسایی گفتار از پیچیده ترین مسائل شناسایی الگوهاست. از نظر پردازش سیگنالها، شکل موجی گفتار خوب تعریف نشده و پدیده ای پیچیده است. فنوم های گفتاری از نظر قدرت و شکل در افراد مختلف متفاوت است. حتی در یک فرد فنوم ها بسته به محتوای کلماتی که از آنها ساخته می شوند، تغییر می کنند و فنوم های مختلف در بخش اعظم صورت موجی خود بر یکدیگر انطباق دارند. هدف اصلی کوهونن ساخت ماشین تحریر صوتی بود. یعنی ماشینی که بتواند گفتار دیکته شده را مستقیماً تایپ کند. شبکه عصبی تنها بخشی از وظایف این سیستم را بر عهده داشت. در واقع از شبکه های عصبی منحصراً در مرحله طبقه بندی فنوم ها برای مقداری کردن برداری سیگنال های صوتی استفاده می شود. ماشین تحریر کوهونن از قسمت های زیر ساخته شده است:

۱-۱.۱. پیش پردازش

پیش پردازش از عناصر اصلی هر فناوری شبکه هاب عصبی است. هر نوع شبکه عصبی در صورتی که به آن داده های نمایانگری داده نشده یا آموزش کافی نبیند، عملکرد ضعیفی خواهد داشت. هر چند شبکه های عصبی روش های نوینی را در تبدیل اطلاعات به کدهای توزیعی فراهم می کند، لیکن مانند هر روش الگو شناسی دیگر باید ابتدا از مرحله اساسی تعریف کردن درست و کافی مشخصه های داده ها گذر کند. کوهونن از روش های استاندارد پردازش سیگنال برای استخراج طیف فنوم ها در ورودی های صوتی استفاده می کند. امواج گفتاری ابتدا از یک میکروفون به یک فیلتر پایین گذر و دستگاه مبدل آنالوگ به دیجیتال ۱۲ بیتی انتقال می یابد، سپس با استفاده از یک تبدیل فوریه سریع (FFT) برای محاسبه داده های دیجیتال خروجی مبدل ADC محتوای طیفی فنوم ها استفاده می کند.

۱-۶. شبکه های عصبی

شبکه های عصبی منحصرا در این مرحله طبقه بندی فنوم ها برای مقداری کردن برداری سیگنال ها به کار بردگی می شود.

۲-۳. نقشه های کمکی

تلفظ برخی حروف ها مانند b ، x و g دارای طیفی بسیار ناپایدار است ، به طوری که در ابتدای طیف مقدار زیادی انرژی رها می شود و سپس با دوره ای از سکوت نسبی ادامه می یابد. کوهون دریافت که شیوه معمول نقشه ای فنوتوپیک مناسب طبقه بندی این نوع از اصوات نمی باشد. راه حل او استفاده از نوعی نقشه کمکی ، به نام نقشه های گذرا می باشد. از نقشه های گذرا برای آموزش طیف این نوع فنوم ها استفاده می شود.

۳-۴. پس پردازش

آخرین مرحله ماشین تحریر فنوتیک ، برگرداندن حالت فنوتیک به حالت نوشتاری می باشد. بیشتر خطاهای در این مرحله به سبب پدیده ای به نام هم نوایی صورت می گیرد. هم نوایی به تغییراتی اطلاق می گردد که در تلفظ فنوم ها به علت مضمون فنوم های هم جوار ایجاد می شود. برای مقابله با این پدیده کوهون از سیستم قاعده پایه استفاده کرد که گرامر صحیح در ترجمه فنوتیک را بنا می کند. سیستم مذکور بسیار حجمی است .

۴-۵. متراکم سازی تصویر

مقصود از متراکم سازی اطلاعات تصویر کاهش هزینه ذخیره سازی و انتقال تصویر بدون آنکه کیفیت تصاویر حاصله تنزل نماید. برای این منظور بایستی تمام نقاط تصویر اولیه که با تعداد معینی از سطوح روشن بیان شده اند به سطوح دیگری تبدیل شوند که تعداد آنها کمتر از تعداد سطوح روشنایی تصویر اولیه است. برای این منظور می توان از شبکه کوهون برای تخمین چگالی طیف روشنایی تصویر ورودی استفاده نمود . در این حالت تعداد نرون های شبکه برابر تعداد سطوح روشنایی دلخواه هستند که به کمک چگالی طیف روشنایی تصویر آموزش می یابند.

۶-۲-۱. برنامه متلب

برنامه *train* مربوط به داده های ورودی به فرم عدد:

```
clear
n=200; %output vector
m=200; %output vector
i=7; %input number
F=[.1 .1 .1 .1 .1 .1 .9; %input
   .1 .1 .1 .1 .9 .1 ;
   .1 .1 .1 .9 .1 .1 ;
   .1 .1 .9 .1 .1 .1 ;
   .1 .9 .1 .1 .1 .1 ;
   .9 .1 .1 .1 .1 .1];
out=[];
eta=.55; %coefficient rate
w=.1*rand(m,n,i); %weight
d=[];Step=1; N=10; %step_eta=eta/(N-1);
for NN=1:7
    NN
    for sample=1:1
        x=F(:,NN);
        N=10; %neighbor radial
        while N>2
            for I=1:m
                for J=1:n
                    q=reshape(w(I,J,:),i,1);


                    d(I,J)=(x-q)'*(x-q);
                end
            end
            [iu,ju]=find(d==min(d(:)));aa=[iu,ju];
            M=[iu+N iu-N ju+N ju-N]; %for boundary positions
            if M(I,4)<=0
                M(I,4)=1;
            end
            if M(I,3)>=n
                M(I,3)=n;
            end
            if M(I,2)<=0
                M(I,2)=1;
            end
            if M(I,1)>=m
                M(I,1)=m;
            end
            W_up=w(uint8(M(I,2):M(I,1)),uint8(M(I,4):M(I,3)),:); %weight updating
            for I=1:size(W_up,1)
```

```

for J=1:size(W_up,2)
    q=reshape(W_up(I,J,:),i,1);
    %q=W_up(I,J);
    q=q+eta.* (x-q);
    W_up(I,J,:)=q;
end
end
w(M(1,2):M(1,1),M(1,4):M(1,3),:)=W_up;

N=N-Step;
end      % end of while
out=[out aa];
end
out
hold on %show weight update for all output
ww=w(:,:,1);
surf(ww);figure(gcf)
ww=w(:,:,2);
surf(ww);figure(gcf)
ww=w(:,:,3);
surf(ww);figure(gcf)
ww=w(:,:,4);
surf(ww);figure(gcf)
ww=w(:,:,5);
surf(ww);figure(gcf)
ww=w(:,:,6);
surf(ww);figure(gcf)
ww=w(:,:,7);
surf(ww);figure(gcf)
hold off
save weight.mat w out

```



این شکل *update* شدن وزن ها را برای تمام ورودی ها نشان می دهد. همان طور که در شکل هم نشان داده شده این الگوریتم نمونی را به عنوان برنده انتخاب کرده و شعاع همسایگی آن را *update* کرده و

همچنان که شعاع همسایگی را کاهش می دهد آن را *update* نیز می کند. *Update* کردن شعاع همسایگی به این دلیل می باشد که چنانچه در قسمت *train* که به شبکه آموزش می دهیم که به ازای یک ورودی که مثلا سیب است وارد کلاس *a* شود، در قسمت *test* اگر چنانچه یک تکه از سیب را به این شبکه نشان دادیم ، به دلیل داشتن شعاع همسایگی *update* شده وارد کلاس دیگری نشود و وارد کلاس *a* شود.

۲-۴-۶. برنامه *test* مربوط به داده های ورودی به فرم عدد:

```


clear
n=200; %output vector
m=200; %output vector
i=7; %input number
F=[.1 .1 .1 .1 .1 .1 .9; %input
    .1 .1 .1 .1 .1 .9 .1;
    .1 .1 .1 .1 .9 .1 .1;
    .1 .1 .1 .9 .1 .1 .1;
    .1 .1 .9 .1 .1 .1 .1;
    .1 .9 .1 .1 .1 .1 .1;
    .9 .1 .1 .1 .1 .1 .1];
load weight.mat w out
F=F+0.8*rand(size(F)); %input whit noise
test=[];
for NN=1:7
    for sample=1:1
        x=F(:,NN);
        for I=1:m
            for J=1:n
                for kk=1:7
                    q(kk)=w(I,J,kk);
                end
                d(I,J)=norm(x'-q);
            end
        end
        [iu,ju]=find(d==min(d(:)));
        aa=[iu;ju];
        X=aa(1,1).*ones(length(out),1);
        Y=aa(2,1).*ones(length(out),1);
        X=[X';Y'];
        dis=(out-X).^2;
        d=sqrt(dis(1,:)+dis(2,:));
        [Val,Ind]=min(d);
        test=[test out(:,Ind)];
    end
end
out
test
O=[];

```


```

for i=1:7
    a=out(1,:)==test(1,i);
    b=out(2,:)==test(2,i);
    c=a&b;[a,b]=find(c==1);
    O=[O,F(:,b)];
end
O
for i=1:7 %showing win node for all inputs
hold on
subplot(1,7,i),plot(test(2,i),test(1,i),'*')
hold on
subplot(1,7,i),plot(out(2,:),out(1,:),'o')
end

```



شکل بالا نمونهای پیروز را برای تمام ورودی ها نشان می دهد.



شکل بالا نمونهای پیروز را برای ورودی های عدد نشان می دهد . دایره ها(*) نمونهای پیروز مربوط به خروجی های train می باشدو ستاره ها(*) نمونهای پیروز مربوط به تست می باشد.

۶-۲-۳. برنامه train مربوط به داده های ورودی به فرم تصویر


```
clear
n=200; %output vector
m=200; %output vector

load EDB33g.mat FNClass
Nclass=size(FNClass,2);
InpFea=FNClass(1).fea;
i=size(InpFea,1);
out=[];
eta=.55;           %coefficient rate
w=.1*rand(m,n,i); %weight
d=[];Step=1; N=5;  %step_eta=eta/(N-1);
alfa=zeros(n,m);
for NN=1:7
    NN
    for sample=2
        x=FNClass(NN).fea(:,sample);
        %      x=length(OCR1 ).Feature);
        N=5;   %neighbor radial
        while N>1
            for I=1:m
                for J=1:n
                    q=reshape(w(I,J,:),i,1);
                    d(I,J)=(x-q)'*(x-q);
                end
            end
            oo=d.*exp(alfa);
            [iu,ju]=find(oo==min(oo(:)));aa=[iu(1);ju(1)];
            M=[iu(1)+N iu(1)-N ju(1)+N ju(1)-N];  %for boundary positions
            if ju(1)-N<=0
                M(1,4)=1;
            end
            if ju(1)+N>=n
                M(1,3)=n;
            end
            if iu(1)-N<=0
                M(1,2)=1;
            end
            if iu(1)+N>=m
                M(1,1)=m;
            end
            if N==5
                NI=M;
            end
            W_up=w(M(1,2):M(1,1),M(1,4):M(1,3),:); %weight updating
            for I=1:size(W_up,1)
                for J=1:size(W_up,2)
```

```

q=reshape(W_up(I,J,:),i,1);
%q=W_up(I,J);
q=q+eta.*(x-q);
W_up(I,J,:)=q;
end
end
w(M(1,2):M(1,1),M(1,4):M(1,3),:)=W_up;
ww=w(:,:,1);
surf(ww); figure(gcf)
N=N-Step; %eta=eta-step_eta;
end      % end of while
out=[out aa]
end
alfa(N1(1,2):N1(1,1),N1(1,4):N1(1,3),:)=alfa(N1(1,2):N1(1,1),N1(1,4):N1(1,3),:)+10;
end
out
save weight.mat w out

```



۶-۲-۴. برنامه test مربوط به داده های ورودی به فرم تصویر

```

clear
n=200; %output vector
m=200; %output vector


load EDB33g.mat FNClass
Nclass=size(FNClass,2);
InpFea=FNClass(1).Fea;
i=size(InpFea,1);
load weight.mat w out

```


```

test=[];
for NN=1:7
    for sample=1
        x=FNClass(NN).Fea(:,sample);
        for I=1:m
            for J=1:n
                for kk=1:20
                    q(kk)=w(I,J,kk);
                end
                d(I,J)=norm(x'-q);
            end
        end
        [iu,ju]=find(d==min(d(:)));aa=[iu;ju];
        X=aa(1,1).*ones(length(out),1);
        Y=aa(2,1).*ones(length(out),1);
        X=[X';Y'];
        dis=(out-X).^2;
        d=sqrt(dis(1,:)+dis(2,:));
        [Val,Ind]=min(d);
        test=[test out(:,Ind)];
    end
end
out
test
O=[];
for i=1:7
    a=out(1,:)==test(1,i);
    b=out(2,:)==test(2,i);
    c=a&b;[a,b]=find(c!=1);
end
O

```



شکل بالا نمونهای پیروز را برای تمام ورودی ها نشان می دهد.



شکل بالا نرون های پیروز را برای ورودی های تصویر نشان می دهد . دایره ها(o) نرون های پیروز مربوط به خروجی های *train* می باشد و ستاره ها(*) نرون های پیروز مربوط به تست می باشد.

۷. منابع

مبانی شبکه های عصبی هوش محاسباتی تالیف دکتر محمد باقر منهاج .
شبکه های عصبی تالیف آر.بیل و تی. جکسون .

References:

- [1] www.eca.ir
- [2] www.nafttimes.com
- [3] www.itj.sums.ac.ir
- [4] www.cs.kent.ac.uk
- [5] D.bianchi, R.Calogero , B.Tirozzi . *kohonen neural networks and genetic classification , Roma.italy,2006*