



تحقیق و بررسی در مورد انواع شبکه های عصبی و کاربرد آنها در الکترونیک

گرد آورنده : یونس نادری گوارشکی

رشته : تکنولوژی الکترونیک

دانشگاه خاوران

تابستان ۹۲

Youness.ng@gmail.com

چکیده :

در این پایان نامه ابتدا به مقدمه ای از شبکه های عصبی از جمله تاریخچه شبکه های عصبی و مشخصات اصلی یک نرون بیولوژیک پرداخته شده است. سپس ساختار شبکه های عصبی مصنوعی مورد بحث قرار گرفته است که از این بحث می توان به تعریف شبکه های عصبی مصنوعی، انواع توابع فعال ساز، انواع یادگیری شبکه های عصبی، شبکه های پرسپترون، MPL و هاپفیلد اشاره داشت. سرانجام نیز یک کاربرد شبکه های عصبی در پردازش تصویر، که عبارت است از « آشکارسازی چهره با شبکه های عصبی در تصاویر رنگی» مورد بررسی قرار گرفته شده است.

فهرست مطالب:

۸	مقدمه
۹	فصل اول : مقدمه ای بر شبکه های عصبی
۱۰	۱-۱ تاریخچه شبکه های عصبی
۱۱	۲-۱ نرون طبیعی
۱۳	۳-۱ یادگیری در سیستم های بیولوژیک
۱۴	۴-۱ شباهت شبکه عصبی زنده و مصنوعی
۱۴	۵-۱ کاربرد شبکه های عصبی
۱۹	فصل دوم : ساختار شبکه های عصبی مصنوعی
۲۰	۱-۲ تعریف شبکه های عصبی مصنوعی
۲۰	۲-۲ نرون های مصنوعی
۲۲	۳-۲ اجزای یک شبکه عصبی
۲۴	۴-۲ الگو برداری از مغز انسان
۲۴	۲-۴-۱ افزایش سرعت
۲۵	۲-۴-۲ حساسیت بالا به رخداد اشتباه
۲۵	۲-۴-۳ رایانه ها قادر نیستند از تجربیات گذشته استفاده نمایند
۲۵	۲-۴-۴ عدم ارائه پاسخ مناسب در شرایط جدید
۲۵	۵-۲ ویژگی های شبکه های عصبی مصنوعی
۲۶	۲-۵-۱ قابلیت یادگیری
۲۶	۲-۵-۲ قابلیت تعمیم
۲۶	۲-۵-۳ پردازش موازی
۲۷	۲-۵-۴ مقاوم بودن
۲۷	۲-۵-۵ قابلیت کاربری
۲۷	۲-۵-۶ تشخیص داده های اشتباه

۲۷ تحمل خطا	۷-۵-۲
۲۸ غیر خطی بودن	۸-۵-۲
۲۸ تصویر کردن ورودی - خروجی	۹-۵-۲
۲۸ معایب شبکه های عصبی	۶-۲
۲۹ انواع توابع انتقال	۷-۲
۳۳ یادگیری شبکه های عصبی	۸-۲
۳۳ یادگیری نظارت شده	۱-۸-۲
۳۴ یادگیری نظارت نشده	۲-۸-۲
۳۵ یادگیری تقویت یافته	۳-۸-۲
۳۶ الگوریتم پس انتشار خطا	۴-۸-۲
۳۶ آموزش دلتا	۵-۸-۲
۳۶ آموزش ترکیبی	۶-۸-۲
۳۷ آموزش رقابتی	۷-۸-۲
۳۷ آموزش هب	۸-۸-۲
۳۷ ساختارهای مختلف شبکه های عصبی مصنوعی	۹-۲
۳۸ شبکه های پسخور	۱-۹-۲
۳۸ شبکه های پیش خور	۲-۹-۲
۳۸ شبکه های پیش خور تک لایه	۱-۲-۹-۲
۳۹ شبکه های پیش خور چند لایه	۲-۲-۹-۲
۳۹ پرسپترون	۱۰-۲
۴۰ یادگیری پرسپترون	۱-۱۰-۲
۴۲ یادگیری پرسپترون مبتنی به روش برداری	۲-۱۰-۲
۴۴ محدودیت های پرسپترون	۳-۱۰-۲
۴۶ شبکه های عصبی پرسپترون چندلایه	۱۱-۲
۴۶ رفع مشکل	۱-۱۱-۲
۴۷ حل مشکل	۲-۱۱-۲
۴۸ مدل جدید	۳-۱۱-۲

- ۴۹ قاعده جدید فراگیری ۴-۱۱-۲
- ۵۰ بررسی مجدد مساله یای حذفی (XOR) ۵-۱۱-۲
- ۵۴ شبکه هاپفیلد ۱۲-۲
- ۵۸ فصل سوم : چند نمونه از کاربردهای شبکه های عصبی
- ۵۹ ۱-۳ آشکارسازی چهره با شبکه های عصبی در تصاویر رنگی
- ۵۹ ۱-۱-۳ مقدمه
- ۵۹ ۲-۱-۳ مشخصات رنگ پوست انسان
- ۵۹ ۱-۲-۱-۳ استخراج رنگ پوست
- ۶۰ ۲-۲-۱-۳ تولید رنگ پوست در فضای رنگی cber
- ۶۱ ۳-۱-۳ شبکه های عصبی پیشنهادی
- ۶۱ ۴-۱-۳ نتایج آزمایشات
- ۶۱ ۱-۴-۱-۳ نتایج آزمایشات روی فریمهای ویدئویی
- ۶۳ ۱-۱-۴-۱-۳ آشکارسازی چهره
- ۶۴ ۲-۴-۱-۳ نتایج آزمایشات روی عکس های دانشجویی
- ۶۶ منابع

مقدمه :

در همین لحظه که شما این مطالب را می خوانید از مجموعه پیچیده ای از شبکه های عصبی در مغز و سیستم عصبی خود استفاده می کنید. این مجموعه به هم پیوسته از 10^{11} نورون عصبی زنده تشکیل می شود که یک ساختار با شکوه از بافت ها و فعل و انفعالات شیمیایی را تشکیل می دهند. برخی از ساختارهای عصبی از همان ابتدای تولد با شما همراه هستند و برخی دیگر با توجه به تجربیات شما در طول زندگی شکل پیدا می کنند.

دانشمندان در حال حاضر در ابتدای راه شناخت شبکه های عصبی هستند و تنها بر روی نحوه عملکرد این مجموعه تمرکز کرده اند. طبق کشفیات به عمل آمده همه توابع عصبی زنده مثل حافظه، در نورون ها و ارتباطات بین آنها ذخیره می شوند. یادگیری به معنای آغاز برقراری یک ارتباط جدید بین نورون ها و یا تغییر در ارتباطات موجود می باشد. این مسئله یک سوال را در ذهن به وجود می آورد که آیا می توان با توجه به اطلاعات ناقص بشر از شبکه های عصبی زنده یک مجموعه کوچک و ساده از نورون های مصنوعی را ساخت و آن ها را مورد آموزش قرار داد؟ جواب این سوال مثبت می باشد. [3]

در سالیان اخیر شاهد حرکتی مستمر، از تحقیقات صرفاً تئوری به تحقیقات کاربردی بخصوص در زمینه پردازش اطلاعات، برای مسائلی که برای آنها راه حلی موجود نیست و یا براحتی قابل حل نیستند بوده ایم. با عنایت به این امر، علاقه فزاینده ای در توسعه تئوریک سیستمهای دینامیکی هوشمند مدل - آزاد - که مبتنی بر داده های تجربی هستند - ایجاد شده است. "شبکه های عصبی مصنوعی" جزء این دسته از سیستم های دینامیکی قرار دارند، که با پردازش روی داده های تجربی، دانش یا قانون نهفته در ورای داده ها را به ساختار شبکه منتقل می کنند. به همین خاطر به این سیستم ها هوشمند گویند، چرا که براساس محاسبات روی داده های عددی یا مثالها، قوانین کلی را فرا می گیرند. این سیستمها در مدلسازی ساختار نرو-سیناپتیکی مغز بشر می کوشند.

پیاده سازی ویژگی های شگفت انگیز مغز در یک سیستم مصنوعی (سیستم دینامیکی ساخته دست بشر) همیشه وسوسه انگیز و مطلوب بوده است. محققینی که طی سالها در این زمینه فعالیت کرده اند بسیارند؛ لیکن نتیجه این تلاشها، صرف نظر از یافته های ارزشمند، باور هر چه بیشتر این اصل بوده است که "مغز بشر دست نیافتنی است". [8]

فصل اول :

مقدمه ای بر شبکه های عصبی

۱-۱ تاریخچه شبکه های عصبی :

بعضی از پیش زمینه های شبکه عصبی را می توان به اوایل قرن بیستم و اواخر قرن نوزدهم برگرداند. در این دوره، کارهای اساسی در فیزیک، روانشناسی و نروفیزیولوژی توسط علمایی چون هرمان فون هلمهلتز، ارنست ماخ و ایوان پاولف صورت پذیرفت. این کارهای اولیه عموماً بر تئوریهای کلی یادگیری، بینایی و شرطی تاکید داشته اند و اصلاً به مدل‌های مشخص ریاضی عملکرد نرونها اشاره ای نداشته اند.

دیدگاه جدید شبکه های عصبی در دهه ۴۰ قرن بیستم آغاز شد زمانی که وارن مک کلوث و والتر پیترز نشان دادند که شبکه های عصبی می توانند هر تابع حسابی و منطقی را محاسبه نمایند. کار این افراد را می توان نقطه شروع حوزه علمی شبکه های عصبی مصنوعی نامید و این موضوع با دونالد هب ادامه یافت؛ شخصی که عمل شرط گذاری کلاسیک را که توسط پاولف مطرح شده بود به عنوان خواص نرونها معرفی نمود و سپس مکانیسمی را جهت یادگیری نرونها بیولوژیکی ارائه داد.

نخستین کاربرد عملی شبکه های عصبی در اواخر دهه ۵۰ قرن بیستم مطرح شد، زمانی که فرانک روزنبلات در سال ۱۹۵۸ شبکه پرسپترون را معرفی نمود. روزنبلات و همکارانش شبکه ای ساختند که قادر بود الگوها را از هم شناسایی نماید. در همین زمان بود که برنارد ویدرو در سال ۱۹۶۰ شبکه عصبی تطبیقی خطی آلدین را با قانون یادگیری جدید مطرح نمود که از لحاظ ساختار، شبیه شبکه پرسپترون بود.

هر دوی این شبکه ها، پرسپترون و آدلاین، دارای این محدودیت بودند که توانایی طبقه بندی الگوهایی را داشتند، که بطور خطی از هم متمایز می شدند. ویدرو و روزنبلات هر دو از این امر آگاه بودند، چون آنها قانون یادگیری را برای شبکه های عصبی تک لایه مطرح نموده بودند که توانایی محدودی جهت تخمین توابع داشتند. هر چند آنها توانستند شبکه های چند لایه را مطرح نمایند، لکن نتوانستند الگوریتم های یادگیری شبکه های تک لایه را بهبود بخشند.

پیشرفت شبکه های عصبی تا دهه ۷۰ قرن بیستم ادامه یافت. در ۱۹۷۲ تئوکوهونن و جیمز اندرسون بطور مستقل و بدون اطلاع از هم، شبکه های عصبی جدیدی را معرفی نمودند که قادر بودند به عنوان "عناصر ذخیره ساز" عمل نمایند. استفان گروسبرگ در این دهه روی شبکه های خودسازمانده فعالیت می کرد. فعالیت در زمینه شبکه های عصبی در دهه ۶۰ قرن بیستم در قیاس با دهه ۸۰ - به علت عدم بروز ایده های جدید و نبود کامپیوترهای سریع جهت پیاده سازی - کم رنگ می نمود. لکن در خلال دهه ۸۰، رشد

تکنولوژی میکروپروسور روند صعودی داشت و تحقیقات روی شبکه های عصبی فزونی یافت و ایده های بسیار جدیدی مطرح شدند. در این زایش دوباره شبکه های عصبی دو نگرش جدید قابل تامل می باشد. استفاده از مکانیسم تصادفی جهت توضیح عملکرد یک طبقه وسیع از شبکه های برگشتی که می توان آنها را جهت ذخیره سازی اطلاعات استفاده نمود. این ایده توسط جان هاپفیلد، فیزیکدان آمریکایی، در سال ۱۹۸۲ مطرح شد. دومین ایده مهم که کلید توسعه شبکه های عصبی در دهه ۸۰ شد، الگوریتم «پس انتشار خطا» می باشد که توسط دیوید راملهارت و جیمز مککلند در سال ۱۹۸۶ مطرح گردید. با بروز این دو ایده، شبکه های عصبی متحول شدند. در ده سال اخیر هزاران مقاله نوشته شده است و شبکه های عصبی کاربردهای زیادی در رشته های مختلف علوم پیدا کرده اند. شبکه های عصبی در هر دو جهت توسعه تئوریک و عملی در حال رشد می باشند. اما این روند رشد، آهسته و مطمئن نبوده، دوره هایی بسیار سریع و دوره هایی کند مشاهده شده است. بیشتر پیشرفتهای در شبکه های عصبی به ساختارهای نوین و روشهای یادگیری جدید مربوط می شود.

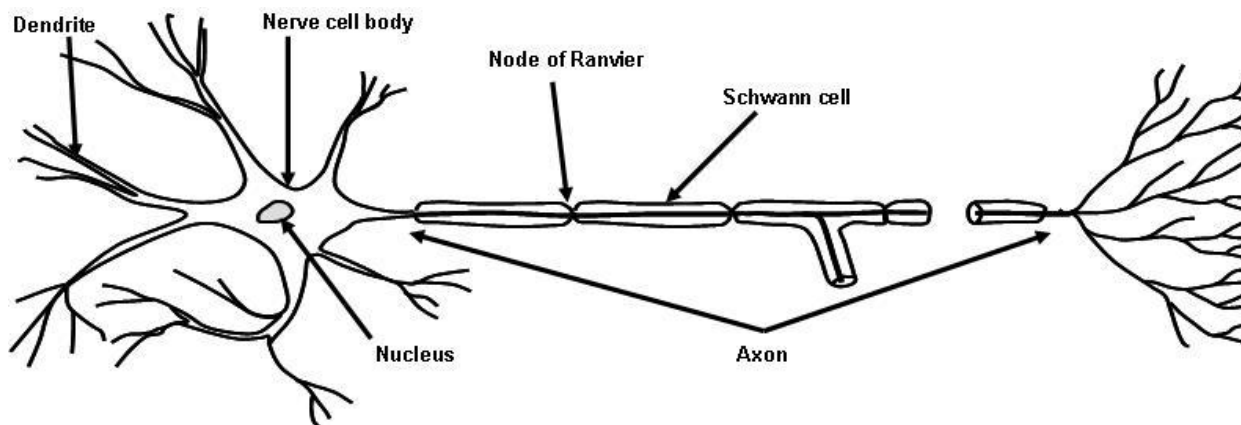
آنچه که در این جا ممکن است مورد سوال باشد این است که در آینده چه اتفاقی رخ خواهد داد. مثلا آیا در ده سال آینده شبکه های عصبی جایگاه خاصی به عنوان یک ابزار علمی - مهندسی خواهند یافت، یا بالعکس دچار کمرنگی شده و کمتر مطرح خواهند شد؟ آنچه که می توان در حال حاضر به طور قاطع گفت آن است که شبکه های عصبی جایگاه مهمی خواهند داشت، نه به عنوان یک جواب و راه حل برای مسئله، بلکه به عنوان یک ابزار علمی که بتواند برای راه حل های خاص و مناسب مورد استفاده قرار گیرد. باید توجه داشت که در حال حاضر اطلاعات موجود درباره نحوه عملکرد مغز بسیار محدود است و مهمترین پیشرفتهای در شبکه های عصبی، در آینده مطرح خواهند شد، زمانی که اطلاعات بیشتری از چگونگی عملکرد مغز و نرونها بیولوژیک در دست باشد. [8]

۱-۲ نرون طبیعی :

مغز آدمی شامل بیش از ده بلیون نرون می باشد که هرکدام از آنها به طور متوسط به چندین هزار نرون دیگر متصل می باشد. این اتصالات تحت عنوان سیناپس شناخته می شوند. مغز انسان شامل حدود ۶۰ تریون از این پیوندها می باشد. [1]

نرون ها دو نوع می باشند. نرون های داخلی مغز که در فاصله های حدود ۱۰۰ میکرون به یکدیگر متصل اند و نرون های خارجی که قسمت های مختلف مغز را به یکدیگر و مغز را به ماهیچه ها و اعضای حسی را به مغز متصل می کنند.

نرون ها در واقع المان های پردازش و بسیار ساده می باشند. هر نرون شامل یک سوما که بدنه نرون می باشد، یک آکسون و چند دندریت می باشد. [2]



شکل ۱-۱ مشخصات اصلی یک نرون بیولوژیک.

نرون ها دریافت هایی را از سایر نرون ها و از طریق دندریت ها دارند. وقتی که مقدار سیگنال ورودی بیشتر از یک حد آستانه خاص گردید نرون اصطلاحاً فعال می شود - در واقع یک واکنش شیمیایی حادث شده و یک پالس الکتریکی که پتانسیل فعلیتی نامیده می شود به آکسون (خروجی نرون) فرستاده می شود. از آنجا و از طریق سیناپس هایی که متصل به نرون هستند به دندریت های سایر نرون ها منتقل می گردد. [1]


در واقع این تماس به صورت اتصال مستقیم نیست بلکه از طریق ماده شیمیایی موقتی صورت می گیرد. سیناپس پس از آن که پتانسیل آن از طریق پتانسیل های فعالیت دریافتی از طریق آکسون به اندازه کافی افزایش یافته از خود ماده شیمیایی به نام منتقل کننده عصبی ترشح می کند. برای این ترشح ممکن است به دریافت بیش از یک پتانسیل فعالیت نیاز باشد. منتقل کننده عصبی ترشح شده در شکاف بین آکسون و دندریت پخش می شود و باعث می گردد که دروازه های موجود در دندریت ها فعال شده و باز شود و بدین صورت یون های شارژ شده وارد دندریت شوند. این جریان یون است که باعث می شود پتانسیل دندریت افزایش یافته و باعث یک پالس ولتاژ در دندریت شود که پس از آن منتقل شده و وارد بدن نرون دیگر می شود. هر دندریت ممکن است تحت تاثیر تعداد زیادی سیناپس باشد و بدین صورت اتصالات داخلی زیادی را

ممکن می سازد. در اتصالات سیناپسی تعداد دروازه های باز شده بستگی به مقدار منتقل کننده عصبی آزاد شده دارد. [2]

۱-۳ یادگیری در سیستم های بیولوژیک :

تصور می شود یادگیری هنگامی صورت می گیرد که شدت اتصال یک سلول و سلول دیگر در محل سیناپس ها اصلاح می گردد.

به نظر می رسد که این مقصود از طریق ایجاد سهولت بیشتر در میزان آزاد شدن ناقل شیمیایی حاصل می گردد. این حالت باعث می شود که دروازه های بیشتری روی دندریت های سمت مقابل باز شود و به این صورت باعث افزایش میزان اتصال دو سلول شود. تغییر میزان اتصال نرون ها به صورتی که باعث تقویت تماس های مطلوب شود از مشخصه های مهم در مدل های شبکه های عصبی است. [2]



شکل ۱-۲ ناقل های شیمیایی آزاد شده از شکاف سیناپس می گذرد و دریافت کننده های دندریت نرون دیگر را تحریک می کنند.

برخی از ساختارهای عصبی در هنگام تولد تعریف می شوند و برخی دیگر در طول زندگی و از طریق فرایند یادگیری توسعه می یابند. در واقع یادگیری عبارتست از ایجاد اتصال های جدید و یا قطع کردن برخی از اتصالات عصبی قدیمی. توسعه این روند در مراحل اولیه زندگی بسیار قابل توجه است. به عنوان مثال ثابت

شده است که اگر در یک محدوده خاص زمانی مانع از استفاده یک بچه گربه از یک چشم شویم دیگر هرگز او قادر به توسعه بینایی در آن چشم در دوران زندگی نخواهد بود.

روند تغییر ساختارهای عصبی در طول زندگی ادامه می یابد. تغییرات بعدی که در طول زندگی در ساختارهای عصبی ایجاد می شود عمدتاً متأثر از قدرت و ضعف اتصالات سیناپسی هستند. به عنوان مثال ثابت شده است که حافظه انسان با توجه به قدرت سیناپتیک شکل می گیرد. بنابراین فرایند یادگیری چهره یک دوست جدید با تغییر در قدرت چندین سیناپس ممکن می شود. [3]

۴-۱ شباهت شبکه عصبی زنده و مصنوعی :

شبکه های عصبی مصنوعی فعلی هرگز به پیچیدگی مغز انسان نیستند اما به هر حال دو شباهت اساسی بین شبکه های عصبی زنده و مصنوعی وجود دارد. شباهت اول در این است که ساختار هر دو از یک ابزار محاسباتی ساده با به هم پیوستگی بسیار بالا تشکیل شده اند. شباهت دوم این است که در هر دو مورد اتصالات بین نرون ها تعیین کننده تابع شبکه می باشند. [3]

۵-۱ کاربرد شبکه های عصبی :

با عنایت به اینکه شبکه های عصبی از دو ویژگی اساس یادگیری یا نگاشت پذیری بر اساس ارائه داده های تجربی و ساختارپذیری موازی برخوردار می باشند این شبکه ها برای مسائل کنترل، علی الخصوص سیستم های پیچیده که مدلسازی این سیستم ها یا مسیر نیست و یا به سختی انجام می شود بسیار مناسب می باشند. [8]

از کاربردهای شبکه عصبی در علوم مختلف می توان به موارد زیر اشاره داشت.

هوا و فضا

- خلبان خودکار هواپیما با کارایی بالا
- شبیه سازی مسیر پرواز
- سیستم کنترلی هواپیما
- بالا بردن کارایی خلبان خودکار
- شبیه سازی اجزای هواپیما

حمل و نقل

- سیستم راهنمای اتوماتیک اتومبیل
- تحلیل گارانتی
- سیستم های ترمز کامیون ها
- زمان بندی وسایل نقلیه
- سیستم های مسیریابی

بانکداری

- ابزار خودکار خواندن چک و سایر اسناد
- کاربردهای ارزیابی کارت های اعتباری

امور دفاعی

- راهبری سلاح ها
- تعقیب اهداف متحرک
- تشخیص اشیا
- تشخیص صورت
- انواع جدید حسگرها
- رادار
- پردازش سیگنال های تصویری و رادار با فشرده سازی داده ها
- استخراج ویژگی ها و حذف نویزها
- تشخیص تصاویر و سیگنال ها

الکترونیک

- پیش بینی ترتیب کد
- طراحی مدارات مجتمع
- کنترل فرآیند
- تحلیل نقص مدارات مجتمع

- بینایی ماشین
- تولید صدا
- مدلسازی غیر خطی

سرگرمی

- انیمیشن
- جلوه های ویژه تصویری
- پیش بینی بازار

امور مالی

- ارزیابی ملک
- مشاور وام
- آزمایش رهن
- درجه بندی شرکت ها
- تحلیل کاربرد خطوط اعتباری
- برنامه های تجارت سهام
- تحلیل مالی شرکت ها
- پیش بینی قیمت ها

صنعت

از شبکه های عصبی می توان به جای تجهیزات بسیار گرانی که در گذشته در صنعت مورد استفاده بوده اند استفاده نمود. به عنوان مثال از شبکه های عصبی می توان برای پیش بینی مقدار گازهای خروجی از کوره برخی از فرآیندهای صنعتی استفاده نمود.

بیمه

- ارزیابی سیاست های کاربردی
- بهینه سازی تولید

ساخت و تولید

- کنترل فرآیند ساخت
- تحلیل و طراحی تولید
- تشخیص اجزا بلادرنگ
- سیستم های بصری بازرسی کیفیت
- تحلیل کیفیت جوشکاری
- مدیریت و طرح ریزی
- پیش بینی کیفیت کاغذ
- تحلیل کیفیت کاغذ
- تحلیل کیفیت چپ های کامپیوتری
- تحلیل و طراحی تولیدات شیمیایی
- تحلیل استقرار ماشین
- پیشنهاد پروژه
- مدلسازی پویا از فرآیندهای شیمیایی

پزشکی

- تحلیل سلول های سرطانی پستان
- تحلیل EEG و ECG
- طراحی پروتز
- بهینه سازی زمان جراحی
- کاهش هزینه بیمارستان ها
- بهبود کیفیت بیمارستان ها

نفت و گاز

- اکتشاف

رباتیک

- کنترل خط سیر
- ربات بالابر
- سیستم های بینایی

گفتار

- تشخیص گفتار
- فشرده سازی گفتار
- طبقه بندی اصوات
- ایجاد گفتار از روی متن

امنیت

- تحلیل بازار
- ارزیابی خودکار
- سیستم های مشاور تجارت

مخابرات

- فشرده سازی داده ها و تصاویر
- سرویس های خودکار شده اطلاعاتی
- ترجمه گفتار به صورت بلادرنگ
- سیستم های پردازش پرداخت مشتری

البته کاربرد شبکه های عصبی در علوم یاد شده روز به روز در حال گسترش می باشند و هر روزه کاربرد جدیدی از این شبکه ها در مقالات معتبر توسط پژوهشگران مطرح می گردد. [3]

فصل دوم :

ساختار شبکه های عصبی مصنوعی

۱-۲ تعریف شبکه های عصبی مصنوعی :

شبکه های عصبی مصنوعی (ANN) الگوهایی برای پردازش اطلاعات هستند که با تقلید از شبکه عصبی مغزی انسان ساخته شده اند. [5]


شبکه های عصبی مصنوعی، ساختاری (شبکه ای) هستند متشکل از تعدادی واحد (نرون مصنوعی) که در داخل شبکه به هم وصل شده اند. هر واحد دارای یک مشخصه ورودی / خروجی (I/O) می باشد و محاسبه یا عملی جزئی را اجرا می کند. خروجی هر واحد، با توجه به مشخصه (I/O) آن، اتصالات درونیش به سایر واحدها و ورودی های خارجی تعیین می گردد.

ANN (شبکه عصبی مصنوعی) متشکل از یک شبکه نیست، بلکه خانواده ای متشکل از شبکه های گوناگون می باشد. [4]

۲-۲ نرون های مصنوعی :

شبکه عصبی بر اساس مغز انسان مدل شده اند و شامل تعدادی نرون های مصنوعی می شوند. نرون ها در شبکه های عصبی مصنوعی سعی بر این دارند تا تعداد پیوندهای کمتری را نسبت به نرون های طبیعی داشته باشند. شبکه های عصبی همگی (در حال حاضر) بطور قابل ملاحظه ای از نظر تعداد نرون ها از مغز آدمی کوچکترند.

هر نرون (یا نود) در یک شبکه عصبی تعدادی ورودی دریافت می نماید. تابعی تحت عنوان تابع فعال ساز بر روی این مقادیر ورودی اعمال می شود که نتیجه آن تحت عنوان سطح فعال سازی نرون به عنوان مقدار خروجی نرون در نظر گرفته می شود. چند تابع ممکنه وجود دارند که می توانند برای نرون ها مورد استفاده قرار گیرند. بعضی از معروف ترین توابع فعال ساز مورد استفاده قرار گیرند در شکل (۱-۲) آمده اند.



شکل ۱-۲: برخی از مهمترین توابع فعالساز

یکی از عمومی ترین توابع استفاده شونده تابع پله ای یا تابع حد آستانه خطی می باشد. در استفاده از این تابع، ورودی های یک نرون با یکدیگر جمع می شوند (هر کدامشان در یک وزن ضرب می شوند) و مجموع با یک مقدار آستانه، t ، مقایسه می شود. اگر مجموع از حد آستانه بزرگتر بود، نرون فعال می گردد و سطح فعال سازی برابر $+1$ خواهد داشت. در غیر اینصورت، غیرفعال خواهد بود و سطح فعال سازی برابر صفر خواهد داشت. (در بعضی شبکه ها، وقتی مجموع از حد آستانه بالاتر نباشد، سطح فعال سازی بجای صفر برابر -1 می باشد).

WWW.ENEE.IR

با این حساب رفتار یک نرون را می توان به صورت زیر بیان نمود.

$$X = \sum_{i=1}^n W_i X_i$$

X مجموع وزنی n ورودی به نرون، X_i تا X_n است که هر کدام از ورودی ها، X_n در مقدار وزن متناظر با آن W_n ضرب می گردد. به عنوان مثال، به مثال ساده ای توجه کنید که در آن یک نرون فقط دو مقدار ورودی دارد. به هر کدام از این ورودی ها یک وزن به قرار زیر نسبت داده شده است :

$$W_1 = 0.8 \quad W_2 = 0.4$$

ورودی های نرون X_1 و X_2 می باشند

$$W_1 = 0.7 \quad W_2 = 0.9$$

از اینرو ، مجموع وزن دار ورودی ها برابر است با

$$(0.8 \times 0.7) + (0.4 \times 0.9) = 0.92$$

سطح فعال سازی Y، برای این نرون به صورت زیر تعریف می شود :

$$Y = \begin{cases} +1 & \text{for } X > t \\ 0 & \text{for } X \leq t \end{cases}$$

با این حساب، اگر کمتر یا مساوی ۰/۹۲ باشد نرون با این ترکیب ورودی ها فعال خواهد شد. در غیر این صورت، سطح فعال سازی برابر صفر خواهد داشت. نرونی که از تابع فعال ساز خطی استفاده می نماید در حالت ساده از مجموع وزنی ورودی هایش به عنوان مقدار سطح فعال سازی خود استفاده می نماید. تابع سیگموئید ورودی ها را از بازه $-\infty$ تا $+\infty$ به یک سطح فعال سازی در بازه صفر تا ۱ تبدیل می نماید.

هر شبکه عصبی از مجموعه ای از نرون های متصل به یکدیگر تشکیل شده است. اتصال بین نرون ها وزن هایی دارند که به آنها نسبت داده می شوند و هر نرون خروجیش را به ورودی هایی که به آن متصل هستند واگذار می نماید. این خروجی به نحوه عملکرد تابع فعال ساز و به ورودی ها بستگی دارد. به این طریق، سیگنال ورودی به شبکه به وسیله تمام شبکه پردازش می شود و یک خروجی (یا چند خروجی) تولید می گردد. هیچ پردازنده مرکزی یا مکانیزم کنترلی وجود ندارد - شبکه فقط در بردارنده تعداد بسیاری عملیات محاسباتی می باشد.

وقتی که یک ورودی به شبکه عصبی داده می شود، خروجی به سرعت ظاهر نمی شود چرا که چند پررود محدود زمانی برای انتقال سیگنال از یک نرون به دیگری لازم است، در شبکه های عصبی مصنوعی این زمان معمولاً بسیار کوتاه است اما در مغز آدمی، پیوندهای عصبی به میزان قابل توجهی آرام می باشند. این تنها خصوصیت موازی بیش از حد مغز است که آن را قادر می سازد تا به سرعت محاسبه نماید. به منظور یادگیری شبکه های عصبی، وزن هایی که به هر پیوند نسبت داده می شوند (معادل با سیناپس در مغز طبیعی) می توانند در پاسخ به مجموعه های مشخصی از ورودی ها و رخداد ها تغییر کنند. [1]

۲-۳ اجزای یک شبکه عصبی :

شبکه های عصبی مصنوعی از قسمت های مختلفی تشکیل شده است. اجزای یک شبکه عصبی عبارتند از :

(۱) ورودی ها

سیگنال های ورودی X_1 تا X_n ، معادل سیگنال های عصبی ورودی می باشند و در مجموع ورودی نرون را تشکیل می دهند. ورودی ها که با بردار X نشان داده شده اند، می توانند خروجی سایر لایه ها باشند. ورودی به صورت های ذیل هستند :

الف (داده های عددی و رقمی

ب (متون ادبی، فنی و ...

ج (تصویر و یا شکل

به عنوان مثال، در تصمیم گیری اعطای وام، ورودی بردار X می تواند شامل سه متغیر سطح درآمد، سن و میزان اعتبار متقاضی باشد. در شبیه سازی بیوانفورماتیکی داروهای ضدقارچی، ورودی ها می توانند خصوصیات فیزیکی و شیمیایی مختلف داروها باشد.

۲) بردار وزن

وزن های W_{i2} تا W_{in} معادل مقادیر اتصالات سیناپسی ورودی های نرون می باشند. میزان تاثیر ورودی X_i بر خروجی y ، توسط مشخصه وزن اندازه گیری می شود. به طور مثال در مثال اعطای وام ، اهمیت و تاثیر درآمد متقاضی و یا سن وی توسط مولفه وزن آنها بر خروجی برآورد می شود. W_i قابل تنظیم بوده، و براساس تابع تبدیل و نوع الگوریتم یادگیری تعدیل می شود.

۳) تابع جمع

تابع جمع (Adder) که از رابطه زیر تعریف می شود، عملیات پردازش نرون را انجام می دهد.

در شبکه های تک نرونی، تابع جمع خروجی مسئله را تا حدودی مشخص می کند، و در شبکه های چند نرونی نیز تابع جمع سطح فعالیت نرون J در لایه های درونی را مشخص می سازد.

$$\sum_{j=1}^n X_j w_{ij}$$

۴) توابع فعالیت

تابع فعالیت - (activation function) که آن را تابع تبدیل و تابع فشرده سازی نیز می نامند - تابعی است که مقادیر خروجی یک نرون مصنوعی را، براساس مقادیر ورودی اش تعیین می کند. به تعبیر بهتر ، تابع فعالیت آستانه ای برای مقادیر خروجی هر نرون در نظر می گیرد. قانون فعال سازی تعیین می کند که چگونه یک نرون واکنش فعال سازی برای هر الگوی ورودی را انجام می دهد. این قانون برای کلیه الگو ها شرح داده می شود. تابع فعال سازی محدوده وسیعی از مقادیر ورودی را به مقدار خاص خروجی نگاشت می کند. به عنوان مثال، در شبکه های عصبی می توان هر مقدار خروجی را به مقادیر ۰ و ۱ نگاشت کرد.

۵) خروجی

منظور از خروجی ، پاسخ مسئله است. خروجی نرون از تابع زیر مشخص می شود. [5]

$$y_i = \text{Activation Function} \left(\sum_{j=1}^n X_j w_{ij} \right)$$

۲-۴ الگو برداری از مغز انسان :

شبکه های عصبی مصنوعی، از شبکه های مغزی انسان الگو برداری شده اند. به همین دلیل، ویژگی های منحصر به فرد پردازش مغزی را دارا می باشند. از جمله این خصوصیات می توان به موارد زیر اشاره نمود.

۲-۴-۱ افزایش سرعت :

برنامه ای را در نظر بگیرید، که با ساختار رایانه ها و نرم افزارهای فعلی برای تشخیص چهره یک فرد به کار می رود:

الف - به طور یقین، برنامه شامل حلقه هایی است که باید ده ها بار، به صورت پی در پی تکرار شود.

ب - در هر تکرار، خصوصیات خاصی از صورت را ذخیره نموده و با الگو مقایسه نماید.

ج - بعد از تست کلیه خصوصیات، چهره را تشخیص دهد.

سلسله عملیات مزبور، بارها تکرار شده و مدت ها وقت دستگاه را می گیرد. آیا تشخیص چهره توسط مغز انسان چنین است؟ در سیستم مغز، در آن واحد ده ها واحد پردازش (نرون) در عصب بینایی به صورت

موازی به کار می افتند، و بدلیل پردازش موازی (و نه پی در پی) در زمانی بسیار کوتاه، چهره تشخیص داده می شود. نتیجه آنکه، تحول در منطق برنامه نویسی و جایگزینی پردازش موازی به جای پردازش سریال، باید در آینده طراحی رایانه ها مورد توجه قرار گیرد.

۲-۴-۲ حساسیت بالا به رخداد اشتباه :

بروز اشتباه در علائم برنامه نویسی، منجر به اتلاف ساعت ها وقت در ردیابی، شناسایی و اصلاح برنامه می گردد. همچنین رخداد اشتباه در منطق برنامه، اعم از آنکه یک زیربرنامه یا قسمتی از آن درست کار نکند، منجر به آن خواهد شد که نتیجه حاصله نادرست گردد. این در حالی است که عدم عملکرد صحیح قسمتی از نرون ها، منجر به از کارافتادگی کامل مغز نمی گردد و امکان اتخاذ تصمیم صحیح، در این حالت نیز وجود دارد.

۳-۴-۲ رایانه ها قادر نیستند از تجربیات گذشته استفاده نمایند :

مغز بطور پیوسته در حال یادگیری و انطباق با محیط است، ولی بازبینی و به هنگام نمودن برنامه های نرم افزاری در دوره های زمانی مختلف، اجتناب ناپذیر است.

WWW.ENEE.IR

۴-۴-۲ عدم ارائه پاسخ مناسب در شرایط جدید :

با تغییر ورودی های برنامه های نرم افزاری، انتظار نمی رود که آنها پاسخی ارائه دهند، در حالی که مغز ممکن است علی رغم نداشتن تجربه ای مشخص، هنگامی که در شرایط جدید قرار می گیرد پاسخ مناسبی ارائه دهد. [5]

۵-۲ ویژگی های شبکه های عصبی مصنوعی :

واضح است که شبکه عصبی قدرت محاسباتی خود را در درجه اول از ساختار گسترده موازی حجیم خود و در درجه دوم از توانایی یادگیری و تعمیم دهی به دست می آورد. خاصیت تعمیم دهی به این معناست که شبکه عصبی برای ورودی هایی که در طول آموزش (یادگیری) با آن ها مواجه نشده است خروجی های قابل قبولی تولید می کند. این دو قابلیت پردازش اطلاعات این امکان را به شبکه عصبی می دهد که به مسائل پیچیده و دارای مقیاس وسیع که تاکنون غیر قابل بررسی بوده اند، پاسخ دهد. با این وجود، عملاً شبکه های

عصبی به تنهایی نمی توانند پاسخ همه مسائل را بدهند بلکه باید با یک روش مهندسی سیستم پایدار ترکیب شوند. در واقع مساله پیچیده مورد نظر به تعدادی مساله نسبتا ساده تر تجزیه می شود و شبکه عصبی وظیفه ای را که با قابلیت های ذاتی هر زیر مجموعه هماهنگ باشد، اختصاص می دهد. گرچه این نکته حائز اهمیت است که پیاده سازی معماری یک کامپیوتر که از مغز انسان تقلید کند اگر غیر ممکن نباشد هنوز بسیار دور از دسترس است. [6]

شبکه های عصبی مصنوعی با توانایی قابل توجه خود در استنتاج نتایج از داده های پیچیده و مبهم، می توانند در استخراج الگوها و شناسایی گرایش های مختلفی که برای انسان و کامپیوتر شناسایی آنها بسیار دشوار است استفاده شوند. از مزایای شبکه عصبی می توان موارد زیر را نام برد. [5]

۲-۵-۱ قابلیت یادگیری :

قابلیت یادگیری (learning ability) یعنی توانایی تنظیم پارامترهای شبکه (وزن های سیناپسی)، در زمانی که شبکه شرایط جدیدی را تجربه می کند. تنظیم پارامترهای شبکه با این هدف صورت می گیرد که اگر شبکه برای یک وضعیت خاص آموزش دید و تغییر کوچکی در شرایط محیطی رخ داد، بتواند با آموزشی مختصر و یا بدون آموزش مجدد در شرایط جدید نیز کارآمد باشد.

۲-۵-۲ قابلیت تعمیم :

پس از آنکه شبکه مثال های اولیه را آموزش دید، شبکه می تواند در برابر یک ورودی آموزش داده نشده قرار گیرد و یک خروجی مناسب ارائه نماید. این خاصیت - قابلیت تعمیم (generalization ability) - شبکه را قادر می سازد که تنها با برخورد با تعداد محدودی از یک نمونه، قانون کلی آن را به دست آورده و نتایج این آموخته ها را به موارد جدید نیز تعمیم دهد. قابلیتی که در صورت نبودن آن، سیستم باید بی نهایت واقعیت ها و روابط را به خاطر بسپارد.

۲-۵-۳ پردازش موازی :

در شبکه های عصبی، نرون ها به طور همزمان به ورودی های یک تراز پاسخ می دهند. این ویژگی - پردازش موازی (parallel processing) - باعث افزایش سرعت پردازش و محاسبات می گردد. در واقع

در چنین سیستمی وظیفه کلی پردازش، میان پردازنده های کوچکتری که مستقل از یکدیگر هستند توزیع می گردد.

۴-۵-۲ مقاوم بودن :

در یک شبکه عصبی هر نرون به طور مستقل عمل می کند و رفتار کلی شبکه، برآیند رفتارهای محلی نرون های متعدد است. این ویژگی باعث می شود تا خطاهای محلی، از چشم خروجی نهایی دور بمانند. به عبارت دیگر، نرون ها در یک روند همکاری، خطاهای محلی یکدیگر را تصحیح می کنند. این خصوصیات، باعث افزایش قابلیت مقاوم بودن (robustness) در سیستم می گردد.

۵-۵-۲ قابلیت کاربری :

شبکه های عصبی مصنوعی برای گروه بزرگی از مسائل مهندسی، که با روش های دیگر به سختی قابل بررسی هستند، یک تکنیک برتر به حساب می آیند. این قابلیت را قابلیت کاربردی (Applicability) می نامند.

WWW.ENEE.IR ۶-۵-۲ تشخیص داده های اشتباه :

الگوریتم های شبکه های عصبی این امکان را فراهم می سازد که به طور خودکار، از اعمال داده های آموزشی اشتباه در تعیین وزن ها جلوگیری شود. این قابلیت را تشخیص داده های اشتباه (fault recognition) می نامند. [5]

۷-۵-۲ تحمل خطا :

یک شبکه عصبی که به صورت سخت افزاری پیاده سازی شده باشد دارای توانایی ذاتی تحمل خطا است و می تواند محاسبات مستحکمی را به انجام برساند. به این معنا که عملکرد شبکه تحت شرایط کاری نامناسب به خوبی تضعیف می شود. به عنوان مثال، اگر یک نرون یا لینک های اتصالاتی آن آسیب ببیند شبکه نمی تواند الگوی ذخیره شده را با کیفیت خوب بازبازی کند ولی با توجه به ماهیت ذخیره سازی اطلاعات به صورت گسترده، خطای شبکه می تواند قبل از اینکه پاسخ شبکه به طور جدی تحت تاثیر قرار گیرد در کل

شبکه پراکنده گردد. در نتیجه به جای آنکه پاسخ شبکه به طور کلی دچار خطا گردد، عملکرد آن کمی تنزل می یابد. [6]

۲-۵-۸ غیر خطی بودن :

یک نرون مصنوعی می تواند خطی یا غیر خطی باشد. یک شبکه عصبی که دارای ارتباطات داخلی نرون های غیرخطی باشد خود نیز غیر خطی است. علاوه بر آن این خاصیت غیرخطی در طول شبکه گسترده شده است. غیر خطی بودن یک ویژگی بسیار مهم است، به ویژه اگر زیر ساخت مکانیزم فیزیکی که سیگنال ورودی را تولید می کند ذاتا غیرخطی باشد. [6]

۲-۵-۹ تصویر کردن ورودی - خروجی :

یک روش اساسی رایج در یادگیری که با نام یادگیری با مربی یا یادگیری با نظارت شناخته می شود عبارت است از اصلاح وزن های سیناپسی یک شبکه عصبی با اعمال مجموعه ای از نمونه های یادگیری. در این روش یک نمونه به طور تصادفی از مجموعه انتخاب و به شبکه عصبی ارائه می شود و وزن های سیناپسی (پارامترهای آزاد) شبکه به گونه ای اصلاح می شوند که تفاوت بین پاسخ مطلوب و پاسخ واقعی شبکه را که در اثر اعمال سیگنال ورودی ایجاد شده است از نظر آماری به حداقل برساند. آموزش شبکه برای تمامی نمونه های مجموعه تکرار می شود تا زمانی که شبکه به حالت پایداری برسد و هیچ تغییر قابل توجهی در وزن های سیناپسی به وجود نیاید. نمونه های قبلی می توانند در طول دوره آموزش با تغییر در ترتیب مجددا به کار روند. بدین ترتیب شبکه با یادگیری از نمونه ها یک تصویر ورودی - خروجی ایجاد می کند و مساله مورد نظر را یاد می گیرد. [6]

۲-۶ معایب شبکه های عصبی :

- در مقابل مزایای بالا مشکلاتی نیز در راه این شبکه ها وجود دارند که عبارتند از :
 - مشخص نیست که بهترین تعداد واحدهای محاسبه گر و ارتباطات یک شبکه از چه رابطه منطقی پیروی می کنند.
 - در برخی موارد زمان محاسبه طولانی برای آموزش یک شبکه نیاز است.
 - نیاز به کاهش پیچیدگی شبکه

- نیاز به ترکیب شبکه های عصبی مصنوعی با سایر روندهای محاسباتی برای ساخت یک سیستم هیبرید

- ابهام در چگونگی رسیدن یک شبکه آموزش دیده به داده های خروجی. [5]

۷-۲ انواع توابع انتقال :


تابع انتقال یک تابع خطی و یا غیرخطی از n می باشد. از تابع انتقال برای تعیین خصوصیات نرون در راستای حل مسایل مختلف استفاده می شود.

توابع انتقال رایج در شبکه های عصبی عبارتند از:

(۱) تابع انتقال Hard limit

این تابع انتقال در صورتی که $n < 0$ باشد خروجی صفر و در صورتی که $n \geq 0$ باشد خروجی ۱ می دهد. از این نوع تابع انتقال برای دسته بندی کردن ورودی ها به دو کلاس محدود استفاده می شود. از این تابع عمدتاً در نرون های سازنده شبکه پرسپترون استفاده می شود. [3]

WWW.ENEE.IR




Hard-Limit Transfer Function

شکل ۷-۲ : تابع انتقال Hard limit

(۲) تابع انتقال خطی

این تابع انتقال در شکل (۷-۲) نشان داده شده است. نرون هایی که از این تابع انتقال استفاده می کنند برای تقریب خطی به کار می روند. این تابع همان مقدار ورودی را به عنوان خروجی بر می گرداند. [3]




Linear Transfer Function

شکل ۲-۳: تابع انتقال خطی

۳) تابع انتقال log-sigmoid

از این تابع انتقال در شبکه های « پس انتشار » استفاده می شود. این تابع انتقال مقادیر ورودی را محدوده $-\infty$ تا $+\infty$ دریافت کرده و بر مبنای فرمول زیر یک مقدار خروجی بین ۱ و ۰ تولید می نماید. [3]




$a = \text{logsig}(n)$

Log-Sigmoid Transfer Function

شکل ۲-۴: تابع انتقال log-sigmoid

۴) تابع انتقال رقابتی

از این تابع انتقال در شبکه های رقابتی استفاده می شود خروجی متناظر با بیشترین مقدار ورودی یک شده و بقیه صفر می شوند. [3]




$a = \text{softmax}(n)$

Compet Transfer Function

شکل ۲-۵: تابع انتقال رقابتی


(۵) تابع انتقال Hard limit متقارن



Symmetric Hard Limit Trans. Funct.

شکل ۶-۲: تابع انتقال Hard limit متقارن


(۲) تابع انتقال خطی مثبت



Positive Linear Transfer Funct.


شکل ۷-۲: تابع خطی مثبت

(۷) تابع انتقال Radial basis



شکل ۸-۲: تابع انتقال Radial basis


(۸) تابع انتقال Satlin



Satlin Transfer Function

شکل ۹-۲ : تابع انتقال Satlin


(۹) تابع انتقال Satlins



Satlins Transfer Function

شکل ۱۰-۲ : تابع انتقال Satlins


(۱۰) تابع انتقال Softmax



Softmax Transfer Function S

شکل ۱۱-۲ : تابع انتقال Softmax

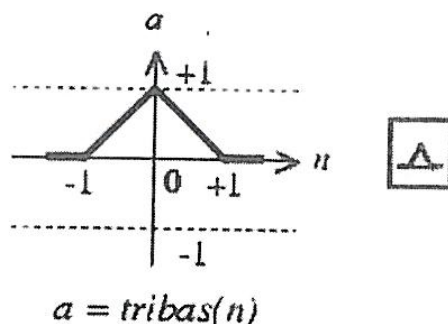
(۱۱) تابع انتقال Tan-Sigmoid



Tan-Sigmoid Transfer Function

شکل ۲-۱۲: تابع انتقال Tan-Sigmoid

۱۲) تابع انتقال Triangular Basis



شکل ۲-۱۳: تابع انتقال Triangular Basis

۸-۲ یادگیری شبکه های عصبی :

در مباحث مربوط به شبکه های عصبی قواعد یادگیری رویه ای برای اصلاح وزن ها و بایاس ها تعریف می کنیم. قاعده یادگیری در راستای آموزش شبکه برای انجام کار خاصی مورد استفاده قرار می گیرد. [3]

۱-۸-۲ یادگیری نظارت شده :

در یادگیری نظارت شده قاعده یادگیری با استفاده از مجموعه ای از نمونه های آموزشی شبکه را آموزش می دهد. زوج زیر را در نظر بگیرید.

$$\{P_1, t_1\}, \{P_2, t_2\}, \dots, \{P_Q, t_Q\}$$

که P_Q یک ورودی شبکه و t_Q هدف مورد نظر متناظر با هر ورودی می باشد. زمانی که ورودی به شبکه اعمال می شود خروجی آن با هدف مقایسه می گردد. سپس قواعد یادگیری برای تنظیم وزن ها و بایاس ها به کار گرفته می شوند تا خروجی شبکه را به هدف نزدیک نمایند. قاعده یادگیری پرسپترون در زمره قواعد یادگیری نظارت شده قرار می گیرد. [3]

شبکه های یادگیری نظارت شده از طریق مشاهده و اعمال داده های آموزشی از قبل کلاس بندی شده آموزش می بینند. شبکه های عصبی که از یادگیری نظارت شده استفاده می کنند از طریق تغییر وزن های ارتباطی در داخل شبکه هایشان یاد می گیرند چگونه بهتر و دقیق تر داده های آموزشی را کلاس بندی

نمایند. در این روش، شبکه های عصبی قادر خواهند بود تا با دقت بسیار بالایی و در بسیاری شرایط، از یک مجموعه از داده های آموزشی به یک مجموعه کامل از ورودیهای ممکن عمومی سازی نمایند.

یکی از عمومی ترین روند های استفاده شده برای یادگیری نظارت شده روش پس انتشار است. [1]

۲-۸-۲ یادگیری نظارت نشده :

در یادگیری نظارت نشده وزن ها و بایاس ها تنها در مقابل ورودی شبکه اصلاح می شوند و در واقع هیچ هدفی وجود ندارد. این الگوریتم ها اکثرا برای عملیات دسته بندی استفاده می شوند. آنها الگوهای ورودی را به تعداد محدودی از کلاس ها دسته بندی می کنند. [3]

در این روش برخلاف شیوه آموزش با نظارت، نیاز به معلم نیست؛ یعنی، خروجی هدف وجود ندارد. در خلال آموزش، شبکه، الگوهای آموزشی خود را از طریق ورودی هایش دریافت می کند و به شکل دلخواه آنها را تحت طبقه های مختلفی دسته بندی می کند. هنگامی که شبکه، یک ورودی را دریافت می کند پاسخی در خروجی ظاهر می کند که نشان دهنده طبقه ای است که آن ورودی بدان تعلق دارد. اگر طبقه ای برای این ورودی یافت نشد، آنگاه یک طبقه جدید تشکیل می شود. برای مثال شخصی را در نظر بگیریم که به او مجموعه ای از اشیا نشان داده می شود و از او درخواست می گردد که آنها را براساس یک یا چند ویژگی که متمایز کننده آنها از همدیگر است، طبقه بندی کند. هنگامی که این کار را انجام داد به او یک شی دیگری نشان داده می شود و از او تقاضا می گردد که آن را در طبقه ای قرار دهد. اگر این شی به هیچ کدام از این طبقه ها تعلق نداشت، آنگاه طبقه جدیدی به وجود می آید.

اگر چه آموزش بدون نظارت، نیازی به معلم ندارد اما در عوض برای طبقه بندی الگوهای ورودی نیاز به معیارهایی دارد که معین کند که طبقه ها بر چه اساسی تشکیل می شوند. طبقه بندی می تواند براساس رنگ، شکل یا مواد تشکیل دهنده اشیا یا هر ویژگی دیگری باشد. بنابراین اگر معیاری برای طبقه بندی وجود نداشته باشد در مورد موفقیت یا عدم موفقیت دسته بندی نمی توان اظهار نظر نمود. در برخی از آزمایش ها انتخاب معیار در طراحی شبکه عصبی در نظر گرفته می شود؛ یعنی به گونه ای طراحی می شوند که بتوانند براساس نوع الگوهای ورودی، مشخصه های معین را استخراج نمایند. [9]

روندهای یادگیری بدون نظارت بدون مداخله انسان یاد می گیرند. یک نمونه خوب از یک شبکه یادگیری بدون نظارت نگاشت کوهنن می باشد. نگاشت کوهنن یک شبکه عصبی است که قادر است تا یاد بگیرد

چگونه یک مجموعه از داده های ورودی را کلاس بندی نماید، بدون آنکه به آن بگوییم که کلاسهایشان چه است و بدون آنکه به آن هیچ داده آموزشی داده شود. این روند مخصوصا در شرایطی مفید واقع می شود که داده ها نیاز دارند تا کلاس بندی شوند و یا به داخل یک مجموعه از کلاسها خوشه بندی شوند ولی کلاس از قبل شناسایی نشده اند. به عنوان مثال، با دادن یک مجموعه از اسنادی که از طریق اینترنت دریافت شده است (احتمالا توسط یک عامل اطلاعاتی هوشمند)، نگاشت کوهنن می تواند اسناد مشابه را با یکدیگر در یک خوشه قرار دهد و به صورت خودکار یک نشان و علامت تمیز دهنده برای موضوعاتی که توسط این اسناد پوشش داده می شوند ایجاد نماید. [1]

روند یادگیری بدون نظارت در شبکه های عصبی توسط هب در سال ۱۹۴۹ پیشنهاد شده است و تحت عنوان یادگیری هب شناخته می شود. یادگیری هب براساس این ایده بنا شده است که اگر دو نرون که در یک شبکه عصبی با یکدیگر متصل هستند، با هم و در یک زمان و در هنگام اعمال یک ورودی خاص فعال شوند در این صورت پیوند بین این دو باید قدرتمند گردد. [1]

۲-۸-۳ یادگیری تقویت یافته :

در آموزش تقویت یافته مانند روش آموزش با واسطه، نیاز به یک معلم می باشد. اما در این روش، معلم تعیین نمی کند که خروجی واقعی چه اندازه با خروجی مطلوب تفاوت دارد؛ بلکه مشخص می کند که خروجی واقعی همان خروجی مطلوب است یا خیر. در حین آموزش، محرک ورودی به شبکه اعمال شده، پاسخ خروجی محاسبه می شود. در اینجا معلم، تعیین کننده خروجی هدف نمی باشد؛ بلکه نشانه قبول یا رد می باشد. نشانه قبول، بیان می کند که خروجی واقعی همان خروجی مطلوب است و نشانه رد، بیانگر مغایرت این دو است. بنابراین، سیگنال خطای تولیدی در این روش باینری است. اگر سیگنال خطا وضعیت عدم تطابق در خروجی (واقعی و مطلوب) را نشان دهد آنگاه شبکه، پارامترهای خود را به طور مکرر تعدیل می نماید تا به خروجی مطلوب برسد. در این روش، نشان دهنده ای وجود ندارد که معین کند پاسخ خروجی ها در جهت صحیح در حال حرکت است یا اینکه پاسخ خروجی به چه میزانی به پاسخ مطلوب نزدیک است. بنابراین در این شیوه، تنظیم پارامترهای شبکه نسبت به آموزش با نظارت متفاوت است.

هنگام استفاده از این روش، باید حدود معین گردد تا شبکه به طور نامحدود سعی در به دست آوردن خروجی مطلوب نماید. [9]

۴-۸-۲ الگوریتم پس انتشار خطا :

عمده ترین کاربرد قانون یادگیری پس انتشار، در آموزش شبکه های عصبی چند لایه پیش خور است که عموماً شبکه های چند لایه پرسپترون هم نامیده می شوند. الگوریتم یادگیری پس انتشار بر قانون یادگیری اصلاح خطا مبتنی می باشد. به عبارتی توپولوژی شبکه های چند لایه پرسپترون با قانون یادگیری پس انتشار تکمیل می گردد. این قانون از دو مسیر اصلی تشکیل شده است. مسیر اول موسوم به مسیر رفت می باشد. در این مسیر، بردار ورودی به شبکه اعمال شده تا اثراتش از طریق لایه میانی، به لایه خروجی انتشار می یابد. بردار خروجی ایجاد شده در لایه خروجی، پاسخ واقعی شبکه می باشد. در این مسیر، پارامترهای شبکه ثابت و بدون تغییر در نظر گرفته می شوند.

مسیر دوم موسوم به مسیر برگشت می باشد. در این مسیر، برعکس مسیر رفت، پارامترهای شبکه تغییر پیدا کرده و تنظیم می شوند. این تنظیم مطابق با قانون اصلاح خطا صورت می گیرد. سیگنال خطا در لایه خروجی شبکه تشکیل می شود. بردار خطا برابر است با اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه. مقدار خطا پس از محاسبه، در مسیر برگشت از لایه خروجی و از طریق لایه های میانی شبکه در کل شبکه توزیع می گردد، و چون این توزیع در خلاف مسیر ارتباطات وزنی سیناپس صورت می گیرد، کلمه پس انتشار خطا جهت توضیح رفتار الگوریتم انتخاب شده است. پارامترهای شبکه، طوری تنظیم می شوند که پاسخ واقعی شبکه هرچه بیشتر به پاسخ مطلوب نزدیک شود. استفاده از خروجی های واقعی در این نوع از شبکه ها، سبب قرار گرفتن این شبکه ها در گروه آموزش نظارت شده است. [5]

۵-۸-۲ آموزش دلتا :

این قانون بر مبنای نظریه تعدیل پیوسته وزن ها بنا نهاده شده است، به نحوی که خطای دلتا، مابین خروجی مطلوب و خروجی واقعی کاهش می یابد. این قانون همچنین به قانون آموزش ویدرو هوف یا به حداقل میانگین مربعات خطا معروف است. [5]

۶-۸-۲ آموزش ترکیبی :

از آموزش ترکیبی (hybrid learning) در مواقعی که تعداد نمونه ها و داده ها خیلی زیاد است، استفاده می شود. آموزش ترکیبی به این صورت است که ابتدا داده ها را براساس روش نظارت نشده، دسته بندی می کنیم و سپس از هر دسته، نمونه هایی را انتخاب کرده و براساس روش نظارت شده آموزش انجام می شود.

پارامترهای شبکه باید طوری تنظیم شوند که پاسخ واقعی شبکه هر چه بیشتر به پاسخ مطلوب نزدیک شود. [5]

۷-۸-۲ آموزش رقابتی :

آموزش رقابتی (competitive learning) شکل دیگری از آموزش نظارت شده است که به علت ساختار و عملکرد مشخص این شیوه نسبت به روش های دیگر متفاوت است. شبکه هایی که از آموزش رقابتی استفاده می کنند، در لایه خروجی از چند نرون تشکیل یافته اند. هنگامی که یک ورودی به شبکه اعمال می شود، تمام نرون های خروجی با یکدیگر برای رسیدن به پاسخ مطلوب رقابت می کنند تا یک نرون برنده شود [5] و برای ورودی های دیگر، نرون دیگری از لایه خروجی برنده می شود. در این شیوه آموزش، هر نرون خروجی برای پاسخ به ورودی های متفاوتی آموزش داده می شود. همچنین آموزش رقابتی با عنوان فرآیند تشخیص تصادفی معرفی می گردد. معمولا از این شیوه آموزش برای آموزش گروهی از مردم جهت کارهای خاص استفاده می شود؛ به نحوی که هر فرد گروه برای یک کار مناسب، در زمان مناسب و در جای مناسب آموزش داده می شود.

۸-۸-۲ آموزش هب :

در سال ۱۹۴۹، دونالد هب بیان کرد هنگامی که آکسون سلول عصبی A به اندازه کافی به سلول عصبی B نزدیک باشد، به گونه ای که به طور مکرر آن را تحریک کند، آن گاه شماری از تغییرات متابولیکی در یک یا هر دو سلول رخ می دهد، به نحوی که قدرت سلول A افزایش می یابد. بنابراین قدرت سیناپسی بین دو سلول A و B مطابق با درجه عملکرد متقابل بین ورودی و خروجی تعدیل می یابد. این شیوه آموزش، که معمولا مقدمه آموزش شبکه های عصبی مصنوعی می باشد، به قانون آموزش هب یا هبیا (Hebbian learning) معروف است. [5]

۹-۲ ساختارهای مختلف شبکه های عصبی مصنوعی :

شبکه های عصبی مصنوعی، چیزی به جز نرون های به هم پیوسته نیستند. شکل اتصال نرون ها به هم یکی از متغیرهای اصلی در طراحی شبکه های عصبی مصنوعی و تنظیم نوع شبکه است. برای مثال، یک شبکه کاملاً پیوسته را در نظر بگیرید. بنابر تعریف، هر عنصر پردازنده ای می تواند فعالیت هر نرون دیگر را دریافت کند یا به آن تحویل بدهد. این شبکه را شبکه برگشتی می نامند.

اگر ماتریکس وزنی ارتباطات داخلی فقط به فعالیت بعدی منحصر باشد - یعنی هیچ ارتباط بازخورد و خود اتصالی وجود نداشته باشد - این شبکه را شبکه عصبی پیش خور می نامند. شبکه های عصبی پیش خور به نوعی آنی عمل می کنند، بدین معنی که خروجی بلافاصله بعد از ارائه یک ورودی تأیید می شود. نوعی خاص از شبکه های پیش خور، گروه شبکه های لایه ای هستند، که آنها را پروسپترون های چند لایه می نامند. پروسپترون های چند لایه در لایه های جداگانه ای تنظیم شده اند. لایه وسط را لایه میانی می نامند و لایه های ورودی و خروجی نیز در این شبکه حضور دارند.

نحوه و شکل اتصال نرون ها در لایه های مختلف، باعث ایجاد ساختارهای مختلفی در شبکه های عصبی مصنوعی می شود. تقسیم بندی هایی که از ساختارهای مختلف شبکه های عصبی مصنوعی انجام شده است، براساس دو معیار پیش خور و پس خور می باشند. [5]

۱-۹-۲ شبکه های پسخور:

چنانچه بتوان در شبکه ای حداقل یک حلقه پیدا کرد، که در آن سیگنالی از یک نرون به خودش یا نرون های همان لایه قبل برگردد، این شبکه دارای پس خور (feed back) است. شبکه های پس خور، از توانایی بالقوه بیشتری نسبت به شبکه های پیش خور برخوردارند. [5]

۲-۹-۲ شبکه های پیش خور:

چنانچه در یک شبکه عصبی، خروجی هر نرون تنها به نرون های لایه بعد وصل شود، به آن پیش خور می گویند. شبکه عصبی پیش خور را کاملاً متصل گویند، اگر هر سلول در هر لایه از همه نرون های لایه قبل، ورودی گرفته باشد. اما اگر بعضی از اتصالات سیناپسی حذف شده باشند، شبکه حاصل را متصل جزئی گویند. بر این اساس تقسیم بندی های زیر برای ساختارهای مختلف شبکه های عصبی مصنوعی انجام شده است. [5]

۱-۲-۹-۲ شبکه های پیش خور تک لایه:


در این شبکه ها لایه میانی وجود ندارد. شبکه پیشخور تک لایه از یک لایه ورودی و یک لایه خروجی تشکیل شده است.

۲-۹-۲- شبکه های پیش خور چند لایه :

این نوع از شبکه ها، با اضافه نمودن یک یا چند لایه پنهان به شبکه های پیش خور تک لایه به دست می آیند. شبکه های عصبی پیش خور چند لایه دارای توانایی بیشتری نسبت به شبکه های تک لایه اند. به طوری که شبکه های عصبی پیش خور دو لایه ای با توابع سیگموئید در لایه اول، قادرند هر تابعی را با دقت دلخواه تقریب بزنند. شبکه های عصبی تک لایه، از چنین توانایی برخوردار نیستند. اگر چه در نگاه اول به نظر می رسد تعداد درجات آزادی (مثلا تعداد ورودی ها، خروجی ها و نرون های هر لایه) برای طراحی یک شبکه چند لایه پیش خور زیاد است، ولی باید توجه داشت تعداد ورودی های شبکه و تعداد خروجی های آن بر مسأله خاصی که شبکه قرار است حل کند تاثیر دارد. [5]

۲-۱۰- پرسپترون :

نمونه نرون که در شکل ۲-۱۴ آمده است در سال ۱۹۴۳ توسط «مک کلاچ و پیتس» پیشنهاد شده است. نمونه آنها تقریباً به همان صورت که ما بررسی کردیم، از طریق تحقیق در رفتار نرون های مغزی پیشنهاد شده بود. لازم است که درباره مشخصات این نمونه بیشتر بحث کنیم. نمونه آنها وسیله ای بسیار ساده است که مجموع وزنی ورودی های خود را برای تعیین خروجی با آستانه مقایسه می کند. نمونه هیچ اهمیتی به ساختار پیچیده و زمان بندی فعالیت نرون های واقعی نمی دهد و دارای هیچ کدام از ویژگی های پیچیده نرون های بیولوژیکی نیست؛ به همین دلیل است که آن را یک «نمونه» و نه یک نسخه تکراری از نرون بیولوژیک می نامیم و می توان آن را در یک رایانه پیاده کرد؛ این قابلیت یک نمونه است.



شکل ۲-۱۴: جزئیات مدل نرون پایه

نرون نمونه، که به طریقی ساده به یکدیگر متصلند، در سال ۱۹۶۲ توسط «روزن بلات» به نام «پرسپترون» نام گذاری شد. پرسپترون یک نرون ساده است که می تواند هر تعداد ورودی داشته باشد و ورودی هایش را به یک یا دو دسته مجزا کلاس بندی می نماید. او برای نخستین بار نرون های نمونه را در رایانه شبیه سازی کرد و آن ها را به طور رسمی تحلیل نمود. روزن بلات در کتاب خود «اصول پویایی عصبی» پرسپترون ها را به صورت شبکه های ساده شده شرح داد که در آن ها برخی از ویژگی های سیستم های عصبی واقعی به طور اغراق آمیز به کار رفته و برخی دیگر از آن ها نادیده گرفته شده بود. او اعتراف کرد که نمونه مذکور به هیچ وجه نسخه دقیق سیستم های عصبی نیست. به عبارت دیگر او از ابتدا آگاه بود که با «مدلی پایه» روبه رو است. [7]

۲-۱۰-۱ یادگیری پرسپترون :


ما برای فراگیری در مدل نرون پایه خود به روشی مناسب نیازمندیم. اتصال این نرون ها به یکدیگر شاید شبکه هایی را ایجاد کند که بتواند کاری را انجام دهند، لیکن برای انجام کاری مفید باید بتوانیم به طریقی آن ها را آموزش دهیم. آنچه این نمونه ها را قابل استفاده می کند توانایی آن ها در فراگیری است. همچنین، برای سهولت درک نمونه ها روش های فراگیری باید تا حد امکان ساده باشند. به همان صورت که در اغلب محاسبات عصبی معمول است، منبع الهام ما سیستم های عصبی واقعی خواهد بود.

کودکان اغلب برای کسب نمره خوب در درس ریاضی تشویق می شوند و برای عبور از خیابان بدون توجه به اطراف سرزنش می گردند. به سگ ها برای اطاعت از فرمان تکه های غذا می دهند. به طور کلی، رفتار خوب تشویق می شود و رفتار بد سرزنش می گردد. همین شیوه را می توان در شبکه های نرون مصنوعی نیز به کار گرفت. باید رفتارهای مطلوب را تشویق و رفتارهای نامطلوب را تضعیف کرد.

مثال ۲-۱ : با استفاده از شبکه عصبی پرسپترون ورودی های درهم A و B شکل (۲-۱۵) را کلاس بندی نمایید.

دو گروه از اشیاء گروهی از شکل های نوشته شده مختلف A و گروهی از شکل های نوشته شده مختلف B، را داریم و مایل هستیم نرون مورد نظر، A ها را از B ها مطابق شکل (۲-۱۵) تمیز دهد. شاید بخواهیم نرون ما با مشاهده یک A عدد ۱ و با دیدن B عدد صفر را به عنوان خروجی تولید کند. باید درباره نمونه نرون مطالعه کرده و رفتار آن را بررسی کنیم، تا مشاهده شود که به چه طریقی می توانیم مفهوم یادگیری را در طرح ساده خود بگنجانیم. راهنمایی صحیح آن است که به نرون اجازه دهیم تا از اشتباهات خود درس

بیاموزد. اگر جواب همراه با خطا باشد، می خواهیم احتمال این خطا را در آینده کم کنیم و اگر جواب صحیح باشد وضع را تغییر نمی دهیم.



شکل ۲-۱۵: کلاس بندی Aها و Bها با استفاده از پرسپترون

اگر در ابتدا ضرایب وزنی خطوط ارتباطی نرون را به طور تصادفی تعیین کنیم، یعنی در واقع حالت شروع بوده و نرون هیچ نمی داند آنگاه می توانیم یک حرف A را به نرون وارد کنیم، نرون مجموع وزنی ورودی خود را محاسبه می کند و با مقدار آستانه مقایسه می کند. چنانچه مقدار محاسبه شده از آستانه بیشتر باشد نرون جواب ۱ و در غیر این خروجی صفر خواهد داد. احتمال این که به طور تصادفی جواب صحیح باشد ۵۰٪ است؛ زیرا ورودی های نرون تنها به طور تصادفی می توانند از مقدار آستانه تجاوز کنند. فرض کنید نرون جواب صحیح بدهد. در این صورت نیاز به هیچ اقدامی نیست زیرا نمونه موفق بوده است. ولی اگر جواب صفر بود باید مجموع وزنی را افزایش دهیم به صورتی که بار دیگر که با حرف A رو به رو شد جواب صحیح بدهد.

این عمل را با افزایش ضرایب وزنی خطوط ارتباطی نرون انجام می دهیم. بنابراین برای تشویق احتمال حصول جواب ۱ وزن ها را افزایش می دهیم. برای حروف B مایلیم که نرون عدد صفر را تولید کند. یعنی مایل هستیم که مجموع وزنی ورودی ها از مقدار آستانه کمتر باشد، بنابراین هرگاه نرون با حرف B رو به رو شد مایل خواهیم بود که ضرایب وزنی آن را کاهش دهیم تا مجبور گردد در آینده با مشاهده حرف B عدد صفر را تولید نماید.

این بدان معنی است که برای فراگیری شبکه باید زمانی که مایلیم نرون فعال باشد، ضرایب وزنی را افزایش داده و آنگاه که مایلیم نرون غیر فعال باشد ضرایب را کاهش دهیم. این مقصود با اضافه کردن مقدار ورودی ها به ضرایب مربوطه، هنگامی که مایلیم نرون فعال باشد و با کسر کردن مقدار ورودی ها از ضرایب، هنگامی که مایلیم نرون غیر فعال باشد حاصل می گردد. این قاعده فراگیری ما خواهد بود. بدیهی است که تنها

ورودی هایی که در آن هنگام ، فعال باشند مورد اثر قرار می گیرند، زیرا ورودی های غیر فعال تاثیری در جمع وزنی ندارند و تغییر آن ها تاثیری در آن مورد به خصوص ندارد. [7]

شیوه یادگیری می تواند به صورت زیر خلاصه شود :

- ضرایب وزنی و مقادیر آستانه را به طور تصادفی تعیین کنید.
- یک ورودی را به نمونه ارائه دهید.
- مقدار خروجی را با توجه به مقایسه مجموع وزنی ورودی ها و مقدار آستانه محاسبه کنید.
- ضرایب وزنی را برای تقویت تصمیمات درست و تضعیف تصمیمات نادرست تغییر دهید. به عبارت دیگر خطا را کاهش دهید.
- ورودی بعدی را به نمونه ارائه دهید.

۲-۱۰-۲ یادگیری پرسپترون مبتنی به روش برداری :


اگر ورودی یک پرسپترون را به صورت بردار $X = (x_0, x_1, x_2, \dots, x_n)$ بنویسیم می توانیم الگوریتم مورد بحث را به شکل برداری مورد نظر قرار دهیم. بردار X دارای n مولفه است و بنابراین n بعدی شناخته می شود. ما حداکثر قادر به تصور سه بعد هستیم، لیکن می توان آنچه در ابعاد بالاتر نیز می گذرد را تا حدی احساس کرد. اگر ضرایب وزنی را به صورت بردار دیگری بنویسیم $W = (w_0, w_1, w_2, \dots, w_n)$ آنگاه می توانیم به جای جمع وزنی حاصل ضرب داخلی دو بردار X و W را محاسبه می کنیم. [2]

$$\sum_{i=0}^n W_i X_i = W \cdot X$$

الگوریتم فراگیری پرسپترون تضمین می کند که ضرایب وزنی هر بار در جهت تقلیل خطا تعدیل یابند. همچنین می توان نحوه آموزش پرسپترون را با بررسی رفتار بردار وزن ها هنگام فراگیری نمونه ها دریافت.

مثال ۲-۲: صورت مثال قبل را با استفاده از شبکه عصبی پرسپترون مبتنی بر یادگیری برداری حل نمایید.

اگر دو گروه حروف A و B را مجدداً مورد توجه قرار دهیم، مشاهده خواهیم کرد که نمونه های حروف به صورتی که مثلاً در شکل (۲-۱۶) نشان داده شده است در فضای الگوها منعکس خواهند شد. حل این مسئله طبقه بندی به معنی یافتن خطی مانند W در نمای دو بعدی است که دو گروه را از یکدیگر جدا سازد. نقاط بالای خط نمایانگر الگوهای گروه A و نقاط زیر خط نشان دهنده الگوهای گروه B خواهند بود. این خطی است که ما لایم پرسپترون آن را بیابیم. چنین خطی که دو گروه الگو را در نمای الگوها تقسیم می کند در واقع فضا را به دو طبقه تفکیک کرده است.



شکل ۲-۱۶: دو مجموعه مجزا از الگوها در فضای دو بعدی

پرسپترون این خط را با تصحیح مقادیر ضرایب وزنی، به همان صورت که در روش یادگیری پرسپترون گفته شد، بنا می کند، به طوری که ورودی های بالای خط، خروجی ۱ و ورودی های زیر خط خروجی صفر و ۱ تولید می کنند. پرسپترون ابتدا با مقادیر تصادفی بردار وزن ها شروع می کند که جهت نامعینی در فضای الگو دارد. الگوها به پرسپترون داده می شوند. روش یادگیری تضمین می کند که اگر خروجی نادرست باشد بردار وزن ها در جهت کاهش خطا تغییر کند. این مقصود با تغییر مکان بردار وزن ها به اندازه ای محدود در جهت بردار وزنی ایده آل حاصل می گردد. در نهایت بردار وزن ها تبدیل به بردار ایده آل مانند رابطه زیر می شود و فضا را با موفقیت تفکیک می کند. در آن هنگام پرسپترون آموخته است که چگونه بین A ها و B ها تمیز قائل شود. [7]

$$\sum_{i=0}^n W_i X_i$$

۲-۱۰-۳ محدودیت های پرسپترون :


متاسفانه توانایی پرسپترون محدود است. قبلا بیان شد که پرسپترون در صورتی جواب را فرا می گیرد که اصولا جوابی وجود داشته باشد. برای بررسی این موضوع ملاحظه کنید که پرسپترون به دنبال خطی است که طبقه ها را تفکیک کند. پرسپترون به راحتی می تواند طبقاتی را که در دو سوی خط قرار دارند تفکیک کند، لیکن حالت های فراوانی است که جدایی طبقات را بسیار پیچیده تر می کند. جهت روشن تر شدن موضوع بحث به مثال زیر توجه نمایید.

مثال ۲-۳: مدل سازی یای انحصاری را با استفاده از شبکه عصبی پرسپترون حل نمایید.

یای انحصاری را در نظر بگیرید. تابع منطقی یای انحصاری همان طور که در شکل (۲-۱۷) آمده است دارای دو ورودی و یک خروجی است. خروجی آن تنها زمانی فعال است که تنها یکی از ورودی ها فعال باشد. اما اگر هر دو فعال یا هر دو خاموش باشند خروجی خاموش خواهد بود. چنانچه حالت فعال را با ۱ و خاموش را با صفر نشان دهیم، جدول زیر به دست می آید.

x	y	z
۰	۰	۰
۰	۱	۱
۱	۰	۱
۱	۱	۰


جدول درستی تابع یای انحصاری



شکل ۲-۱۷: علامت یای انحصاری

این مسئله را می توانیم به این صورت بیان کنیم که پرسپترون باید در نهایت یاد بگیرد که اگر X فعال و Y خاموش و یا به عکس Y فعال و X خاموش بود جواب ۱ بدهد و اگر هر دو فعال یا هر دو خاموش بودند جواب صفر بدهد. به نظر می رسد مسئله ساده ای است.

این مسئله را می توان همان طور که در شکل (۲-۱۸) نمایش داده شده در فضای دو بعدی ترسیم کرد. محور X ها نشان دهنده مقدار X و محور Y ها نشان دهنده مقدار Y است. دواير خاکستری معرف خروجی ۱ و دواير سفید معرف خروجی صفرند. اگر دواير خاکستری و دواير سفید را دو گروه مجزا فرض کنیم به هیچ وجه نمی توان خط راستی را ترسیم کرد که این دو گروه را از یکدیگر تفکیک کند. این نوع الگو را جدایی ناپذیر خطی (غیرخطی) می گوییم. زیرا هیچ خط راستی نمی تواند آن ها را تفکیک کند. از آنجا که هیچ خط راستی وجود ندارد که بتواند آن ها را از یکدیگر تفکیک کند، پرسپترون نیز قادر به یافتن چنین خطی نخواهد بود و بنابراین نمی تواند مسایلی از این نوع را حل کند. در واقع، « پرسپترون یک لایه ای » هیچ مسئله غیرخطی را نمی تواند حل کند.



شکل ۲-۱۸: مسئله یای انحصاری (XOR) در فضای الگوها


ناتوانی پرسپترون در حل مسایل ساده چون یای انحصاری (XOR) اولین بار توسط مینسکی و پاپرت در کتاب آن ها « پرسپترون ها » معرفی شد. این کتاب شامل تحلیل دقیقی از توانایی ها و محدودیت های پرسپترون ها بود. بیان این مطلب که پرسپترون تنها قادر به حل مسایل جدایی پذیر خطی است ضربه کشنده ای بر تفکر این حوزه وارد کرد به طوری که اکثر دانش مندان این رشته با عزم راسخ از آن کناره گرفتند.

پرسپترون تک لایه ای با وجود سادگی نمونه، موفقیت های چشم گیری را نشان داده است. پرسپترون ویژگی هایی را که از یک سیستم قابل آموزش انتظار داریم نشان داده و اثبات کرده است که می تواند طبقات اشیاء را در صورتی که تفکیک پذیر خطی باشند از یکدیگر جدا سازد. آنچه لازم است یافتن راهی برای رفع مشکل جدایی ناپذیری خطی بدون از دست دادن ویژگی های اصلی پرسپترون و سادگی کلی آن است. رفع این نیاز برای نخستین بار در سال ۱۹۸۶ توجه محافل علمی را به خود جلب کرد، زمانی که «رومل هارت و مک کللند» صورت جدیدی از نمونه پرسپترون را به نام پرسپترون چندلایه ای ارائه دادند که در ادامه تشریح می گردد.

۱۱-۲ شبکه های عصبی پرسپترون چندلایه :

۱-۱۱-۲ رفع مشکل :

چگونه باید مشکل عدم توانایی حل مسئله های جدایی ناپذیر خطی را بر طرف کرد؟ در ابتدا تصور می شود که شاید راه حل مشکل استفاده از تعداد بیش تری از یک پرسپترون باشد، به طوری که هر پرسپترون قسمت کوچکی از فضا را تفکیک کرده و از جمع آن ها طبقات جدایی ناپذیر خطی با موفقیت تفکیک شوند. این شیوه برخورد با مسئله یای حذفی XOR در شکل (۱۹-۲) نشان داده شده است.




شکل ۱۹-۲ : چگونگی عملکرد شبکه عصبی چند لایه پرسپترون ؛ ترکیب پرسپترون ها می تواند مسئله XOR را حل کند. پرسپترون شماره ۱ الگوی (۱ ، ۰) و پرسپترون شماره ۲ الگوی (۰ ، ۱) را شناسایی می کند و با ترکیب این دو پرسپترون شماره ۳ می تواند الگوی ورودی را به درستی تمیز دهد. ولی این پرسپترون ها را باید از قبل تنظیم کرد. آن ها هرگز نمی توانند خود این راه طبقه بندی را فراگیرند.

در نگاه اول مشکلی به نظر نمی رسد. لیکن با قدری دقت در می یابیم که این ترکیب پرسپترون ها هرگز قادر به فراگیری نیستند. هر نرون در این ترکیب چون گذشته مجموع وزنی ورودی های خود را محاسبه کرده با آستانه مقایسه می کند و جواب یک یا صفر می دهد. در نرون های لایه اول ورودی ها همان ورودی های اصلی شبکه خواهند بود، ولی ورودی لایه دوم خروجی های لایه اول می باشند. این بدان معناست که پرسپترون های لایه دوم نمی دانند که کدام یک از ورودی های اصلی فعال و کدام خاموش اند. آن ها تنها نسبت به ورودی های خود که در واقع خروجی های لایه اول هستند آگاهی دارند. چون فراگیری به معنی

تقویت خطوط ارتباطی بین ورودی های فعال و واحدهای نرون فعال است، غیر ممکن است که بخش های درست شبکه را تقویت کرد، زیرا ورودی های واقعی در واقع توسط لایه میانی از واحدهای خروجی پنهان شده اند. حالت دوگانه فعال و خاموش نرون ها هیچ اشاره ای به میزان لازم جهت تنظیم ضرایب وزنی نمی کند و بنابراین تنظیم آن ها ممکن نیست. ورودی های وزنی که نرون را کمی فعال می کند نباید به اندازه ورودی هایی که نرون را کاملا فعال می کنند تغییر کنند، ولی هیچ اطلاعی از وضعیت آن ها نداریم. به عبارت دیگر تابع پلکانی آستانه ای اطلاعات لازم برای فراگیری شبکه را از میان می برد. این مشکل را اصطلاحاً مسئله «تعیین سهمیه» می نامند، زیرا شبکه قادر نیست تمیز دهد که کدام یک از ضرایب وزنی ورودی را افزایش و کدام یک را کاهش دهد و بدین صورت نمی تواند تغییرات لازم را برای بهبود جواب در نوبت های بعدی تعیین کند. [2]

۲-۱۱-۲ حل مشکل :

راه حل این مشکل که به سبب پلکانی بودن تابع و فرایند آستانه کردن پیش آمده است، تغییر این تابع و استفاده از حالت غیر خطی آن با تفاوتی جزئی می باشد. اگر آن را تا اندازه ای هموار کنیم به صورتی که تقریباً چون گذشته فعال یا خاموش باشد، ولی در قسمت میانی شیب دار شود تا اطلاعاتی را درباره ورودی خود عرضه کند، خواهیم توانست میزان تقویت یا تضعیف ضرایب وزنی مربوط به آن را تعیین کنیم. بدین طریق شبکه توانایی فراگیری را آن طور که لازم است کسب خواهد کرد. دو راه حل ممکن برای این منظور در شکل (۲-۲۰) آمده است.



شکل ۲-۲۰: دو راه ممکن برای توابع آستانه ای


در هر دو مورد اگر مجموع ورودی های وزنی از آستانه بسیار تجاوز کند مقدار خروجی عملاً یک خواهد بود، برعکس اگر از مقدار آستانه بسیار کمتر باشد خروجی صفر می شود. لیکن در جایی که مقدار مجموع وزنی و

آستانه تقریبا برابر باشند، خروجی نرون، اندازه ای بین دو حالت انتهایی خواهد داشت. این بدان معناست که خروجی نرون می تواند به صورتی مفیدتر و پراطلاع تر به ورودی های آن مربوط شود.

توجه داشته باشید که ما مدل خود را برای حل مشکل خاصی با توجه به نوع مسئله تغییر دادیم. مشکل ما تابع آستانه ای پلکانی بود که ورودی ها را از خروجی ها پنهان می کرد. به هر صورت اکثر ویژگی های مدل قبلی را حفظ کرده ایم. مثلا هر نرون چون گذشته مجموع وزنی ورودی ها را محاسبه کرده و با آستانه مقایسه می کند لیکن خروجی دیگر تنها یک و صفر نیست بلکه بر یک طیف قرار گرفته است، هر چند تابع آستانه ای جدید از بسیاری جهات به ویژه در انتهای طیف تقریبا همانند تابع پلکانی عمل می نماید. بنابراین راه حلی که برگزیده ایم برای حل مسئله ویژه ای پرداخته شده است و غیر عاقلانه است اگر ادعا کنیم که نرون های بیولوژیک حقیقی نیز به همین طریق عمل می کنند. [2]

۲-۱۱-۳ مدل جدید :

پرسپترون جدید به صورت لایه ای منظم شده اند. طبیعتا به آن ها پرسپترون چندلایه ای اطلاق می شود. ساختار کلی این مدل در شکل (۲-۲۱) آمده است.



شکل ۲-۲۱: پرسپترون چند لایه ای

مدل جدید، سه لایه دارد، یک لایه ورودی، یک لایه خارجی و یک لایه بین آنها که مستقیما به داده های ورودی و نتایج متصل نیست. در واقع این لایه را لایه پنهان می نامند. هر واحد در لایه پنهان و لایه خروجی مانند یک پرسپترون عمل می کند، با این تفاوت که تابع استفاده شده به صورتی که در شکل (۲-۲۰-ب) نشان داده شده به جای تابع پلکانی تابع سیگموئید است. واحدهای لایه ورودی صرفا وظیفه توزیع مقادیر ورودی را به لایه بعدی برعهده دارند و بنابراین هیچ محاسبه ای را انجام نمی دهند. با تغییر تابع غیرخطی از

صورت پلکانی به سیگموئید و اضافه کردن یک لایه پنهان به ناچار باید قاعده فراگیری مدل را تغییر دهیم. مدل جدید ما باید توانایی تشخیص الگوهای پیچیده تر را داشته باشد. [2]

۴-۱۱-۲ قاعده جدید فراگیری :

قاعده فراگیری پرسپترون چندلایه را ((قاعده کلی دلتا)) یا ((قاعده پس انتشار)) گویند. این عناوین در سال ۱۹۸۶ توسط رومل هارت، مک کلند و ویلیامز پیشنهاد شد و این آغاز تولد دوباره شبکه عصبی بود.

نحوه عمل پرسپترون چند لایه ای مشابه پرسپترون تک لایه ای است. بدین صورت که الگویی به شبکه عرضه می شود و خروجی آن محاسبه می گردد، مقایسه خروجی واقعی و خروجی مطلوب باعث می گردد که ضرایب وزنی شبکه تغییر یابد به طوری که در دفعات بعد خروجی درست تری حاصل شود. قاعده فراگیری روش میزان کردن ضرایب وزنی شبکه را بیان می کند. دیدیم که قاعده ساده فراگیری پرسپترون تک لایه ای در مورد پرسپترون چندلایه ای کارگر نیست. لیکن استفاده از تابع سیگموئید بدان معنی است که واحدهای میانی تا اندازه ای نسبت به خروجی های مدل آگاهی دارند به طوری که می توان ضرایب وزنی آن ها را برای کاهش میزان خطا تنظیم کرد.

قاعده فراگیری پرسپترون چند لایه ای قدری پیچیده تر از قاعده قبلی است. بهترین راه درک آن بررسی رفتار شبکه هنگام آموزش الگوهای عرضه شده می باشد. وقتی به شبکه آموزش ندیده ای الگویی را عرضه می کنیم، خروجی های تصادفی تولید می کند. ابتدا باید تابع خطایی را تعریف کنیم که تفاوت خروجی واقعی و خروجی مطلوب را نشان دهد. چون خروجی مطلوب را می دانیم این نوع فراگیری را «فراگیری با سرپرست» می نامیم. برای موفق شدن در آموزش شبکه باید خروجی آن را به تدریج به خروجی مطلوب نزدیک کنیم. به عبارت دیگر باید میزان تابع خطا را به طور دائم کاهش دهیم. برای این منظور ضرایب وزنی خطوط ارتباطی واحدها با استفاده از قاعده کلی دلتا میزان می شود. قاعده دلتا مقدار تابع خطا را محاسبه کرده و آن را به عقب از یک لایه به لایه پیشین آن انتشار می دهد. عبارت «پس انتشار» به این علت است. ضرایب وزنی هر واحد جداگانه میزان می شود و بدین صورت میزان خطا کاهش می یابد. این عمل در مورد واحدهای لایه خارجی ساده است زیرا خروجی واقعی و مطلوب آن ها را می دانیم، ولی در مورد لایه میانی چندان روشن نیست. این گمان می رود که ضرایب وزنی واحدهای پنهان که به واحدهای خروجی با میزان خطای بزرگ مرتبط هستند باید بیشتر از واحدهای پنهان که به واحدهای مرتبط آن ها خروجی تقریباً صحیحی دارند تغییر یابد. در واقع ریاضیات نشان می دهد که ضرایب واحدها باید به تناسب میزان خطای

واحدی که به آن متصل اند تغییر کند. بنابراین می توان با انتشار خطا به عقب ضرایب وزنی خطوط ارتباطی تمام لایه ها را به درستی میزان کرد. به این طریق تابع خطا کاهش و شبکه آموزش می یابد. [2]


۲-۱۱-۵ بررسی مجدد مساله یای حذفی (XOR) :

دیدیم که پرسپترون تک لایه ای قادر به حل مسئله یای حذفی XOR نیست. این مسئله که افشا کننده محدودیت پرسپترون تک لایه ای بود، خود به صورت معیاری برای ارزیابی و قضاوت در مورد عملکرد مدل های مختلف شبکه های عصبی در آمده و بسیاری از ویژگی های پرسپترون چندلایه ای توسط آن نمایان شده است.

به یاد داریم که در مسئله یای حذفی مقصود حل مسئله طبقه بندی زیر است :

ورودی	خروجی
00	0
01	1
10	1
11	0

اولین آزمون پرسپترون چندلایه ای این است که آیا می توانیم مدلی را بسازیم که مسئله یای حذفی را حل کند. شبکه سه لایه ای که در شکل (۲-۲۲) نشان داده شده می تواند این مسئله را حل کند. شبکه ساختاری سه لایه ای دارد، دو واحد در لایه ورودی (چون بردارهای ورودی دو عنصر دارند)، یک واحد در لایه پنهان و یک واحد خروجی. ضرایب وزنی بر روی خطوط ارتباطی و مقادیر آستانه در داخل هر واحد نوشته شده است. تا جایی که به واحد خروجی مربوط می شود واحد پنهان با سایر ورودی تفاوتی ندارد و آن هم تنها یکی از ورودی ها محسوب می شود.



شکل ۲-۲۲: یک راه حل برای مسئله XOR

توجه کنید که مقدار آستانه $1/5$ در واحد پنهان به این معنی است که این واحد نمی تواند فعال باشد مگر این که هر واحد ورودی فعال باشد. جالب است که رفتار شبکه را هنگام حل مسئله XOR مشاهده کنیم. وقتی هر دو ورودی خاموش باشند (۰ ۰)، واحد پنهان نیز خاموش است، و هیچ مقدار ورودی خالصی به واحد خروجی منتقل نمی شود که بنابراین آن هم خاموش می ماند. وقتی فقط واحد ورودی سمت راست فعال باشد (۰ ۱)، واحد پنهان به اندازه کافی ورودی خالص دریافت نمی کند. بنابراین خاموش می ماند. در این حالت واحد خروجی ورودی خالص +۱ را دریافت می کنند که از حد آستانه آن تجاوز می کند. در نتیجه واحد خروجی فعال می شود. همین حالت نیز در صورتی که تنها واحد ورودی سمت راست فعال باشد (۱ ۰)، اتفاق می افتد. وقتی هر دو واحد ورودی فعال باشند (۱ ۱) واحد پنهان مقدار ورودی خالص +۲ دریافت می کند. این مقدار از آستانه واحد پنهان تجاوز می کند. در نتیجه واحد پنهان فعال می شود. در این صورت واحد خروجی از هر کدام از واحدهای ورودی مقدار +۱ (مجموعاً +۲) و از واحد پنهان مقدار ۲- را دریافت می کند. در نتیجه مجموع ورودی های خالص واحد خروجی صفر می شود که از مقدار آستانه آن کمتر است و در نتیجه خاموش می ماند.

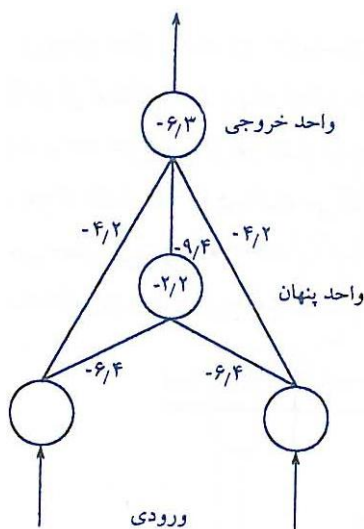
خلاصه نتایج در جدول زیر آمده است :

ورودی شبکه	خروجی واحد پنهان	خروجی شبکه
00	0	0
01	0	1
10	0	1
11	1	0

با بررسی خروجی واحد پنهان در جدول فوق مشاهده می کنیم که این واحد به درستی تشخیص می دهد که در چه زمانی هر دو واحد ورودی فعال هستند، چون تنها در این زمان است که این واحد فعال می شود. چون واحدهای ورودی شبکه مقدار ورودی های شبکه را عیناً تکرار می کنند بنابراین مجموع اطلاعاتی که به واحد خروجی ارسال می شود از سه ناحیه است. واحد ورودی سمت راست نشان می دهد که آیا آن ورودی فعال است یا نه، واحد ورودی سمت چپ نیز نشان می دهد که آیا آن ورودی فعال است یا نه، در این هنگام واحد پنهان بیان می کند که آیا آن ها هر دو فعال اند یا نه. چون واحد خروجی واحد پنهان را همانند یکی از ورودی ها می پندارد الگوی ورودی ظاهری آن برای هر طبقه به اندازه کافی متمایز خواهد بود.

واحد پنهان مانند یک مشخصه یاب (feature detector) عمل می کند. او می یابد که در چه زمانی هر دو واحد ورودی فعال اند. به نظر می رسد که واحد پنهان بردارهای ورودی را کدگذاری مجددی می کند، به طریقی که شبکه بتواند ارتباط ورودی ها را با خروجی ها به درستی فراگیرد. این کدگذاری یا بازنمایی داخلی در نحوه عمل شبکه بسیار حیاتی است. با تعداد کافی واحدهای پنهان می توان بازنمایی داخلی هر الگوی ورودی را به طریقی در شبکه شکل داد که واحدهای خروجی بتوانند در مقابل هر ورودی مورد نظر خروجی مطلوب آن را تولید کنند.

قاعده کلی دلتا شیوه ای را برای آموزش پرسپترون چندلایه فراهم می کند، و با استفاده از واحدهای پنهان بازنمایی داخلی لازم را در شبکه ایجاد می کند. البته بعید است که ضرایب وزنی تولید شده توسط شبکه آموزش دیده به سادگی مثال فوق باشد، لیکن اصول کار همان است. شکل (۲-۲۳) راه حل دیگری را برای مسئله XOR نشان می دهد.




شکل ۲-۲۳: ضرایب وزنی و مقادیر آستانه یک شبکه آموزش دیده برای حل مسئله XOR

پرسپترون های چندلایه ای در اندازه ها و شکل های متفاوت ساخته می شوند، در حالی که تماما از قاعده فراگیری یکسانی پیروی می کنند. به عبارت دیگر برای حل مسئله واحد می توان ساختارهای متفاوتی را طراحی کرد، یکی از ساختارهای جالب هنگامی است که برخلاف مثال فوق ارتباط مستقیمی بین واحدهای ورودی و واحد خروجی نباشد. این حالت و حل نهایی مسئله XOR با این ساختار در شکل (۲-۲۴) آمده است. واحد پنهانی سمت راست ابتدا تمیز می دهد که آیا هر دو واحد ورودی فعال هستند. در این صورت باعث می گردد که مقدار خروجی واحد خروجی صفر گردد. وقتی که تنها یکی از واحدهای ورودی فعال

باشند، واحد تنهایی سمت چپ باعث می گردد که مقدار خروجی واحد خروجی ۱ شود. وقتی که هر دو واحد ورودی خاموش باشند، هر دو واحد پنهان خاموش می مانند و در نتیجه مقدار خروجی واحد خروجی صفر می شود.

متأسفانه قاعده فراگیری لزوماً همگرایی شبکه را تضمین نمی کند. فرایند آموزش ممکن است به حالتی درآیند که نتواند به درستی خروجی های مطلوب را فراگیرد.

شبکه ای که در شکل (۲-۲۵) نشان داده شده می تواند به درستی الگوهای ۰۰ و ۱۰ را تمیز دهد ولی قادر به شناسایی الگوهای ۰۱ و ۱۱ نیست. واحد ورودی سمت راست هر دو واحد پنهان را فعال می کند. در نتیجه مقدار ورودی خالص واحد خارجی ۰/۸ یعنی درست برابر با مقدار آستانه آن می شود. چون تابع آستانه



شکل ۲-۲۵ شبکه پایداری که نمی تواند مسئله XOR را حل کند.

شکل ۲-۲۴ شبکه ای که مسئله XOR را بدون اتصال مستقیم گره های ورودی و خروجی حل می کند.

سیگموئید است خروجی آن دقیقاً برابر با ۰/۵ خواهد شد. این وضعیت پایدار است و با آموزش های بیشتر تغییر نمی کند. چنین نقطه کمینه موضعی به ندرت (تقریباً در ۱٪ موارد) در حل مسئله XOR پیش می

آید. [2]

۱۲-۲ شبکه هاپفیلد :

یکی از پیشرفت های عمده در حوزه شبکه های عصبی در سال های اولیه ۱۹۸۰ توسط «جان هاپفیلد» روی داد. او مسئله «خود انجمنی» را مورد مطالعه قرار داد. این مسئله از طرفی شبیه پرسپترون بود اما تفاوت های مهمی نیز با آن داشت. سهم هاپفیلد تنها به معرفی یک نمونه مناسب خلاصه شده نمی شود، بلکه تجربه و تحلیل های عمیق وی نام او را با شبکه های عصبی عجین نموده است. هاپفیلد موضوع استفاده از توابع انرژی را مطرح نمود و به این طریق شبکه های عصبی را با سایر سیستم های فیزیکی مرتبط کرد. شبکه هاپفیلد از تعدادی گره تشکیل شده است هر گره به تمام گره های دیگر متصل است. بنابراین شبکه هاپفیلد به طوری که شکل (۲-۲۶) نشان می دهد یک شبکه کاملاً مرتبط است. صورت دیگری از شبکه هاپفیلد در شکل (۲-۲۷) آمده است. این شبکه به شبکه بازگشتی نیز معروف است؛ یعنی از گره های خروجی به صورت بازگشتی، اتصالاتی به گره های ورودی وصل است.

این شبکه همچنین از نظر ضرایب وزنی، شبکه ای متقارن است زیرا مقدار ضرایب وزنی از یک گره به گره دیگر در هر دو جهت برابر است. هر گره مانند پرسپترون دارای یک سطح آستانه و یک تابع پلکانی است. گره ها مانند پرسپترون، مقدار ورودی وزنی را محاسبه کرده، از آن مقدار آستانه را کسر می کنند و سپس از تابع پلکانی می گذرانند تا خروجی خود را تعیین کنند. ورودی های شبکه تنها دو حالت دارند. این دو حالت می تواند به صورت صفر و یک (۰ و ۱) و یا دو قطبی یعنی (۱ و -۱) باشند. ورودی های دو قطبی تا اندازه ای از نظر محاسبات ریاضی ساده ترند؛ یعنی تابع فعال سازی که اغلب در شبکه های هاپفیلد مورد استفاده قرار می گیرد تابع فعال ساز علامت است که به صورت زیر تعریف می گردد :

$$\text{Sign}(X) = \begin{cases} +1 & X > 0 \\ -1 & X \leq 0 \end{cases}$$

وزن شبکه به وسیله یک ماتریس نمایش داده می شود و به صورت رابطه زیر محاسبه می گردد :

$$W = \sum_{i=0}^n X_i X_i^t - NI$$

که در آن :

X_i : بردار ورودی می باشد.

X_i^t : ماتریس ترانهاده ماتریس X_i است.


N : تعداد وضعیت های X_i است که باید یاد گرفته شود.

I : ماتریس همانی $m \times m$ است.


m : مقدار ورودی به شبکه را نشان می دهد.

W : وزن شبکه است.

بنابراین ما این حالت ساده تر را انتخاب می کنیم. آنچه شبکه هاپفیلد را از دیگر شبکه های بحث شده متمایز می کند، نحوه دست یابی آن به جواب می باشد. به طوری که شکل (۲-۲۶) یا (۲-۲۷) آن نشان می دهند در شبکه کاملاً مرتبط ورودی و خروجی مشخصی وجود ندارد. هر گره دقیقاً مانند گره های دیگر است. این از ویژگی های عمده شبکه هاپفیلد است و به همین علت نحوه عملکرد آن با سایر شبکه ها متفاوت است. ورودی های شبکه در یک زمان واحد به کلیه گره ها وارد می شوند.



شکل ۲-۲۶: ساختار شبکه هاپفیلد



شکل ۲-۲۷: نمایش دیگری از ساختار شبکه هاپفیلد

مقدار اولیه هر گره $+1$ یا -1 است. پس شبکه به حال خود رها می شود تا از یک حالت به حالت دیگر چرخش کند. این عمل تا جایی ادامه می یابد که شبکه به حالت ثابتی همگرا شود. در این صورت مقادیر خروجی گره ها دیگر تغییر نمی کند. مجموعه خروجی گره ها در حالت ثابت و پایدار به عنوان خروجی شبکه تلقی می شود. دلیل این امر در مراجع اصلی شبکه های عصبی ذکر شده است. اما به طور اجمال چون کلیه گره ها به یکدیگر متصل هستند، خروجی هر گره بر تمامی گره های دیگر اثر می کند و ورودی هر گره سعی می کند بر دیگر گره ها اثر کند. احتمالاً این حالتی ناپایدار خواهد بود، زیرا یک گره ممکن است بخواهد گره های دیگر را فعال کند در حالی که گره های دیگر ممکن است در همان زمان سعی کند آن را فرو نشانند. به تدریج که شبکه از یک حالت به حالت دیگر حرکت کرده، سعی می کند بین گره ها حالت سازشی را ایجاد کند. نهایتاً در حالت پایدار شبکه به بهترین جواب سازگار دست می یابد. در این حالت تعداد گره هایی که سعی در فعال کردن یک گره می کنند برابر با تعداد گره هایی است که سعی در فرو نشانیدن آن دارند.

نحوه عمل این شبکه کاملاً با شبکه پرسپترون متفاوت است. به شبکه پرسپترون یک بردار ورودی داده می شود و شبکه جواب را به صورت خروجی تولید می کند. اما در شبکه هاپفیلد، خروجی اول به صورت ورودی بعدی، مجدداً به سیستم داده می شود که خود خروجی دیگری را تولید می کند و مجدداً این عمل تکرار می شود. جواب نهایی هنگامی حاصل می شود که از یک دوره به دوره دیگر، تغییری روی ندهد. ضرایب وزنی بین نرون ها با استفاده از الگوهای نمونه انتخابی از تمام طبقه ها تعیین می گردد. این مرحله در واقع مرحله آموزش شبکه است به طوری که هر الگو را به خود آن نظیر می کند. در مرحله شناسایی، ابتدا خروجی شبکه به طور تحمیلی برابر با الگوی ناشناخته قرار می گیرد، آنگاه شبکه رها می شود که آزادانه در فواصل زمانی گسسته مکرراً تغییر حالت دهد تا جایی که به حالت پایداری رسیده و خروجی آن وضع ثابتی پیدا کند. به این صورت شبکه به جواب نهایی همگرا می شود. این ویژگی باعث می شود که اگر الگوی درهمی به شبکه داده شود شبکه الگوی سالم آن را تولید کند. به طور خلاصه نحوه عمل شبکه هاپفیلد را می توان به صورت زیر خلاصه کرد:

- شبکه را راه اندازی کن.
- الگوی ناشناخته را عرضه کن.
- تا همگرایی نهایی تکرار کن.

شبکه هاپفیلد به عنوان یک حافظه خودانجمنی مطرح می شود؛ به این معنی که قادر است تا در آن هر حالت خودش و یا حالت مشابهی که ممکن است کمی تغییر داشته باشد را به خاطر بیاورد؛ اما نمی توان از

این شبکه به گونه ای استفاده نمود که در آن هر قسمت داده، دیگری را به خاطر بیاورد. مغز انسان کاملاً انجمنی عمل می نماید یعنی مثلاً بوی خاصی سبب می شود خاطرات گذشته به خاطر آورده شود که شبکه هاپفیلد هنوز قادر نیست تا چنین خاصیتی داشته باشد. [7]

فصل سوم :

چند نمونه از کاربردهای شبکه های

عصبی

۲-۳ آشکارسازی چهره با شبکه های عصبی در تصاویر رنگی

۱-۱-۳ مقدمه :

آشکارسازی چهره در تصاویر، کاربردهای وسیعی در نظارت ویدئویی، تعامل انسان کامپیوتر و ردیابی چهره دارد. تحقیقات زیادی در این مورد انجام شده است. بعضی از کارهای انجام شده در این مورد به آشکارسازی چهره در تصاویر سطح خاکستری محدود شده است، که در آن آشکارسازی چهره در تصاویر از روبرو با تاکید بر ویژگی های صورت نظیر چشمها و گوشه های لب انجام گرفته است. کارهای دیگری نظیر به شناسایی چهره یک فرد در تصویر محدود شده است، درحالیکه آشکارسازی چهره در تصاویری که دارای چندین چهره انسان هستند، مورد نیاز است. بر عکس در این مقاله، هدف قابلیت آشکارسازی چهره در محدوده وسیعی از جهات مورد دید یا از دیدگاه های مختلف با تاکید بر ویژگی های عمومی چهره است. ویژگی انسان است. اولین قدم برای رسیدن به این منظور آشکارسازی ناحیه پوست در تصویر است. یکی از روشهایی که در آشکارسازی رنگ پوست مورد استفاده قرار گرفته است مبتنی بر ارائه مدلی برای رنگ پوست است. با توجه به اینکه رنگ پوست در فضای رنگی $ycbcr$ تشکیل یک کلاستر یا خوشه را می دهد، به همین جهت یک رویکرد مستقیم به شبکه های عصبی برای آشکارسازی رنگ پوست مناسب به نظر می رسد. در این مقاله از شبکه های عصبی پرسپترون چندلایه با الگوریتم یادگیری پس انتشار خطا یا BP برای تفکیک نواحی پوستی و غیرپوستی در تصویر استفاده شده است. همچنین برای آموزش شبکه عصبی از نمونه های پوست صورت موجود در تصاویر تهیه شده از یک دوربین دیجیتال و یک پایگاه عکس دانشجویی استفاده شد.

۲-۱-۳ مشخصات رنگ پوست انسان :

در بسیاری از کاربردها نظیر ذخیره سازی و انتقال ویدئویی معمولا رنگ ها به مولفه های روشنایی و رنگی تفکیک می شوند. یکی از دلایل این تقسیم بندی، حساسیت کمتر چشم انسان به تغییرات مولفه های رنگی است. تجربیات روانشناسی نشان می دهد که ادراک رنگ ها دارای سه مشخصه است: شدت نور، اشباع و رنگ. در فضای رنگی $ycbcr$ شدت نور متناظر با مقدار روشنایی y است، در حالیکه اشباع و رنگ در مولفه های رنگی cb , cr نگهداری می شوند. رنگ پوست انسان تشکیل طبقه خاصی از رنگ ها را می دهد که از اکثر رنگ های اشیای طبیعی دیگر تفکیک پذیر است. اگر چه رنگ های پوست از شخصی به شخصی و از نژادی به نژادی دیگر فرق می کند، لیکن دارای توزیع خیلی کوچک در صفحه رنگی است. این بدان معناست که رنگ های پوست نسبتا در اشباع و رنگ ثابت اند. رنگ هایی به عنوان رنگ پوست طبقه بندی می شوند که اشباع و رنگ آنها در محدوده خاصی قرار داشته باشند. با حذف مولفه روشنایی از رنگ ها، اختلاف بین رنگ های پوست افراد و نژادهای مختلف و تاثیر شرایط نورانی کاهش داده میشود. در این مقاله از مشخصات رنگ پوست انسان با به کارگیری مولفه های cb و cr استفاده شده و با استفاده از توزیع رنگ پوست در فضای رنگی $cbcr$ پروسه دسته بندی بین رنگ پوست و غیرپوست (چهره و غیرچهره) انجام گرفته است.

۱-۲-۱-۳ استخراج رنگ پوست :

علی رغم اینکه رنگ پوست انسان از یک شخص به شخص دیگر و از یک نژاد به نژاد دیگر بسیار فرق می کند، لیکن توزیع آن در یک ناحیه خیلی کوچک در فضای رنگی $cbcr$ می باشد. در این مقاله، از فضای رنگی $ycbcr$ برای آشکارسازی رنگ پوست استفاده شده است. در فضای رنگ $ycbcr$ اطلاعات روشنایی از اطلاعات رنگ جدا می شود. شکل ۲-۳ توزیع رنگ پوست در فضای رنگ $ycbcr$ را برای یک نمونه رنگ پوست که در شکل ۱-۳ نشان داده شده است، نمایش می دهد. چنانچه در این شکل دیده می شود، مقدار شدت روشنایی y تاثیر چندانی در یافتن رنگ پوست ندارد، در نتیجه از مقدار روشنایی y صرف نظر می شود. همچنین در شکل ۲-۳ توزیع رنگ پوست در فضای رنگی $cbcr$ نشان داده شده است. چنانچه در این شکل دیده می شود، رنگ پوست تشکیل یک کلاستر کوچک در فضای $cbcr$ را می دهد، بنابراین استفاده از مقادیر cb , cr برای آموزش شبکه عصبی MLP مناسب به نظر می رسد.

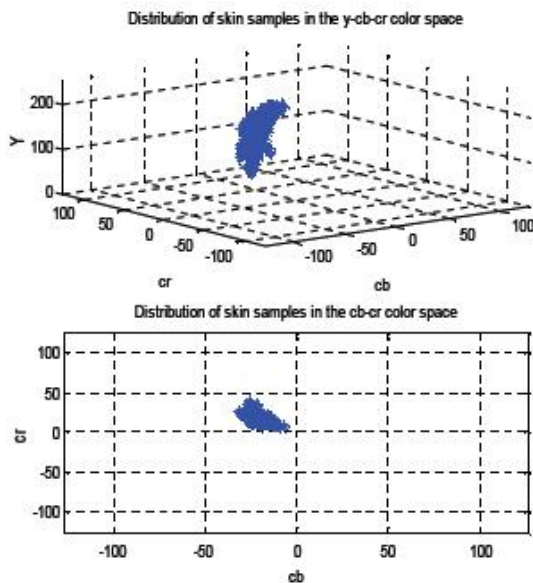
۲-۲-۱-۳ تولید رنگ پوست در فضای رنگی $cbcr$:

خروجی اکثر دوربین های رنگی، تصاویر رنگی در فضای رنگ RGB را در اختیار قرار می دهند. برای تبدیل فضای رنگی RGB به فضای رنگی $ycbcr$ می توان از رابطه زیر استفاده نمود :

$$\begin{bmatrix} y \\ cb \\ cr \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ -0.169 & -0.331 & 0.500 \\ 0.500 & -0.419 & -0.081 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

رابطه ۱-۳: چگونگی تبدیل فضای رنگ RGB به $cbcr$

برای تولید رنگ پوست در فضای رنگ $cbcr$ نمونه های پوستی از تصاویر صورت انتخاب شده و از رابطه (۳-۱) استفاده می شود. شکل (۲-۳) توزیع رنگ پوست در فضای رنگی $cbcr$ را برای یک نمونه تصویر داده شده در شکل (۱-۳) نشان می دهد. ناحیه آبی رنگ در شکل (۲-۳) متناظر با مقادیر رنگی می باشد که دارای احتمال غیرصفر در نمونه های انتخاب شده می باشند. چنانچه در این شکل دیده می شود واضح است که رنگ پوست در یک ناحیه خیلی کوچک از فضای رنگی قرار دارد .



شکل ۱-۳: نمونه پوستی

شکل ۲-۳: توزیع نمونه پوستی شکل ۱-۳ در فضاهای رنگی

۳-۱-۳ شبکه های عصبی پیشنهادی :

چنانچه بیان شد، کلاس پوست انسان تشکیل یک ناحیه کوچک در فضای رنگ cbcR را می دهد، در نتیجه استفاده از شبکه های عصبی برای آشکارسازی رنگ پوست مناسب به نظر می رسد. با توجه به توانایی شبکه های عصبی MLP در طبقه بندی الگوها بخصوص در مواردی که مرزتصمیم گیری بین کلاسهای مختلف الگوها دارای پیچیدگی زیاد و کاملا غیرخطی است، از این نوع شبکه ها برای ایجاد تمایز بین کلاسهای پوست و غیرپوست استفاده گردید. برای آموزش شبکه از الگوریتم BP و مقادیر cb و cr در فضای رنگ cbcR استفاده شد، بدین ترتیب تعداد ورودی های شبکه برابر دو انتخاب گردید. هر چند وجود یک لایه مخفی در شبکه MLP کافی به نظر می رسد لیکن قرار دادن دو لایه مخفی، همگرایی سریعتر و هموارتر شبکه را باعث می شود. تعداد نرون های موجود در لایه های مخفی در ابتدا برابر مقادیر مشخصی لحاظ شده سپس در صورتیکه شبکه همگرا نمی شود، تعداد نرون های لایه های مخفی افزایش و در غیر این صورت تعداد آنها کاهش داده شدند تا یک مقدار بهینه حاصل شود. لایه خروجی دارای یک نرون بوده و تنها خروجی شبکه دارای مقداری در محدوده ۱- و ۱ می باشد. برای آموزش شبکه عصبی، انتخاب داده های یادگیری در دو حالت زیر انجام گرفته و شبکه مورد تست قرار گرفت :

الف) یک فریم از یک برش ویدئویی که با استفاده از یک دوربین دیجیتال از یک شخص در حال حرکت تهیه شده بود، انتخاب شده سپس نمونه های آموزشی از نمونه های پوست صورت شخص حاضر در تصویر و زمینه آن فراهم گردید. پس از آموزش شبکه با این نمونه ها، تست نهایی شبکه با انتخاب فریم های دیگری از برش ویدئویی انجام گرفت.

ب) تعدادی عکس از یک پایگاه عکس دانشجویی انتخاب شده سپس تعدادی از آنها برای آموزش شبکه و تعدادی دیگر برای تست شبکه به کار برده شدند. مشابه نمونه های آموزشی از نمونه های پوست صورت افراد حاضر در عکس های انتخاب شده برای آموزش شبکه و زمینه آن ها فراهم شد. آموزش شبکه با این نمونه ها انجام شده و نهایتا تست شبکه با نمونه عکس های انتخابی برای تست شبکه انجام گردید.

۴-۱-۳ نتایج آزمایشات :

۱-۴-۱-۳ نتایج آزمایشات روی فریمهای ویدئویی :


اولین تصاویر آزمایش شده فریم های برگرفته از یک برش ویدئویی بودند که از طریق یک دوربین دیجیتال از یک شخص در حال حرکت گرفته شده بود. شکل (۳-۳) یک فریم نمونه برای آموزش شبکه است که از ناحیه صورت شخص حاضر در تصویر، نمونه پوستی و از زمینه آن، نمونه های غیرپوستی نشان داده شده در شکل (۳-۴) انتخاب شده اند. در شکل (۳-۵) توزیع نمونه های پوستی و غیرپوستی انتخاب شده، نشان داده شده است. برای آموزش شبکه عصبی از تصویر نمونه پوستی تعداد ۳۷۵ نقطه و از تصاویر نمونه های غیرپوستی تعداد ۴۰۳ نقطه با توزیع یکنواخت انتخاب شدند. سپس با توجه به اینکه بعضی از نمونه های غیرپوستی در زمینه تصویر اصلی دارای رنگ پوست بوده و در فضای رنگی cbcR با خوشه تشکیل شده از نمونه های پوستی همپوشانی داشتند، با انتخاب یک معیار فاصله با آستانه یک واحد در فضای رنگی cbcR ،

نمونه های غیرپوستی که دارای فاصله اقلیدسی کمتر از یک واحد در فضای رنگی cbc_r از نمونه های پوستی بودند، حذف گردیدند بدین ترتیب بین دو کلاس پوست و غیرپوست حداقل یک واحد فاصله در فضای رنگی انتخاب شده وجود دارد و در نتیجه شبکه عصبی امکان تفکیک دو کلاس را خواهد داشت. در این مثال خاص تعداد نقاطی که به این ترتیب با اعمال معیار فاصله فوق حذف گردیدند، ۷ نقطه بود که در شکل (۳-۳) با رنگ آبی نمایش داده شده است. این روش در نتیجه نهایی تاثیر منفی محسوسی ایجاد نکرد. خلاصه اینکه مجموعه داده های یادگیری ورودی و خروجی در این مثال خاص شامل ۷۷۱ بردار ورودی انتخاب گردید که از این تعداد ۳۷۵ بردار مربوط به نمونه های پوستی با مقدار خروجی یک و مابقی مربوط به نمونه های غیرپوستی با مقدار خروجی منفی یک می باشند.

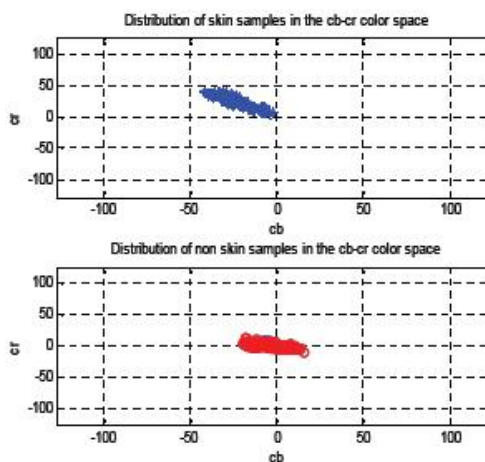


شکل ۳-۳: تصویر اصلی

در ابتدا شبکه عصبی MLP با ساختار در نظر گرفته شد. مقادیر اولیه پارامترهای شبکه بصورت تصادفی انتخاب شدند. منحنی یادگیری شبکه در شکل (۳-۴) آورده شده است. چنانچه در این شکل دیده میشود،



شکل ۳-۴: نمونه های غیرپوستی و نمونه پوستی

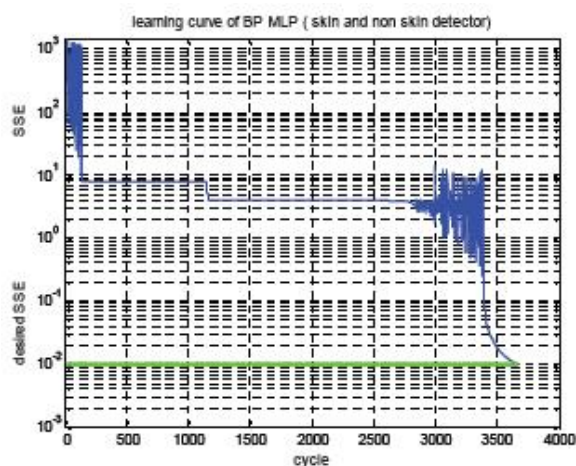


شکل ۳-۵: توزیع نمونه های پوستی و غیرپوستی در فضای رنگی

شبکه بعد از ۳۶۶۷ سیکل موفق به یادگیری داده ها شده است. ساختارهای مختلف دیگری برای شبکه عصبی مورد آزمایش قرار گرفتند، از بین این ساختارها بهترین ساختار شبکه بود که معرفی شد.

۳-۱-۴-۱- آشکارسازی چهره :

خروجی شبکه عصبی مقداری در محدوده ۱- و ۱ به هر نقطه تصویر نسبت می دهد، بدین ترتیب هر نقطه تصویر دارای مقداری است که نشان می دهد این نقطه به پوست شباهت دارد یا خیر. با در نظر گرفتن آستانه ای برابر صفر می توان تصویر ورودی را به یک تصویر باینری تبدیل نمود که در آن نقاط پوستی و غیرپوستی مشخص می شوند. شکل (۳-۷) نتایج حاصل از به کار بردن عملیات مذکور را روی تصویر اصلی که در شکل (۳-۳) نشان داده شده است و به عنوان تصویر نمونه برای آموزش شبکه های عصبی مطرح شده به کار رفتند، نشان می دهد. در این شکل نقاط سفید نمایانگر نقاط پوستی و نقاط سیاه نمایانگر نقاط غیرپوستی می باشند. چنانکه در تصویر موجود در شکل (۳-۷) دیده می شود




شکل ۳-۶ منحنی یادگیری شبکه


بعضی از نقاط زمینه تصویر به عنوان نقاط پوستی معرفی شده اند. دلیل این مطلب وجود بعضی از رنگ های پوستی در زمینه تصویر می باشد. در شکل (۳-۸) و (۳-۹) نتایج آشکارسازی چهره روی دو فریم دیگر از برش ویدئویی با شبکه نشان داده شده است. چنانکه در این تصاویر دیده می شود علاوه بر چهره، نقاط پوستی دست شخص حاضر در تصویر نیز آشکار شده است. همچنین نقاطی از زمینه تصویر نیز دارای رنگ پوست بوده و آشکارسازی شده است.



شکل ۳-۷: نتایج آشکارسازی چهره روی تصویر اصلی



شکل ۳-۸: نتایج آشکارسازی چهره با شبکه




شکل ۳-۹: نتایج آشکارسازی چهره با شبکه

۳-۱-۴-۲ نتایج آزمایشات روی عکس های دانشجوئی

نمونه دیگری از عکس ها که مورد تست قرار گرفتند، یک مجموعه عکس دانشجوئی بود که تعداد ۱۰۰ عکس به عنوان نمونه انتخاب شدند. از بین این عکسها تعداد ۵۰ عکس برای آموزش انتخاب شدند. نمونه های رنگ پوست از رنگ پوست صورت افراد حاضر در عکس ها انتخاب شده و نمونه های غیر پوست از زمینه عکس های مزبور انتخاب گردیدند. با توجه به وجود و مشاهده بعضی از نمونه های رنگ پوست در اشیاء غیرپوستی در فضای رنگ cbr ، رنگ های پوست و غیرپوست با یکدیگر همپوشانی دارند. مخصوصا این همپوشانی در ناحیه مرزی دو کلاس پوست و غیرپوست در فضای رنگ فوق باعث می شود تا تفکیک این دو کلاس با مشکل روبرو گردد زیرا فاصله بین دو کلاس در نواحی مرزی اطراف کلاس پوست در نقاط مختلف به اندازه کافی نبود، یا بعبارت دیگر در ناحیه مرزی دو کلاس نوعی ابهام در تشخیص و جداسازی این دو کلاس وجود دارد. برای تمایز کامل دو کلاس پوست و غیرپوست و رفع ابهام فوق در مرزبندی این دو ناحیه،

نیاز به الگوریتم خاصی وجود داشت. الگوریتمی بشرح زیر به کار گرفته شد: ابتدا نقاطی از کلاس پوست با فاصله آستانه ای مشخص از نقاط کلاس غیرپوست را حذف نموده سپس همین عمل برای کلاس غیرپوست با آستانه دیگری مشابه انجام گرفت، بدین ترتیب که نقاطی از کلاس غیر پوست با فاصله آستانه ای مشخص از نقاط باقیمانده کلاس پوست حذف گردیدند. نمونه هایی از عکس های انتخاب شده که آشکارسازی چهره در آن ها از طریق شبکه آموزش یافته انجام شده است، در شکل (۳-۱۰) آورده شده اند. چنانکه در نمونه های این شکل دیده می شود، مشکل زمینه تصویر برای مواردی که دارای رنگ پوست نسبتا زیاد و بهم پیوسته می باشد، وجود دارد. این مشکل در بعضی موارد حتی باعث تغییر شکل هندسی و ساختار صورت نیز گردیده است. برای حل این مشکل نیاز به در نظر گرفتن ویژگی های دیگر ضروری به نظر می رسد. [9]



شکل ۳-۱۰: نتایج آشکارسازی چهره رو تصاویر مختلف

منابع

- [1] هوش مصنوعی / بن کوپن؛ ترجمهٔ _ مشهد: انتشارات سخن گستر؛ ۱۳۸۶
- [2] آشنایی با شبکه های عصبی / آر. بیل و تی. جکسون؛ ترجمهٔ محمود البرزی _ تهران: دانشگاه صنعتی شریف، مؤسسهٔ انتشارات علمی ، ۱۳۸۰ .
- [3] طراحی شبکه های عصبی / مارتین تی. هاگان ، هاوارد بی. دیموث ، مارک بیل؛ ترجمهٔ مصطفی کیا _ تهران: خدمات نشر کیان رایانه سبز: الیاس - خلیج فارس، ۱۳۸۸ .
- [4] شبکه های عصبی مصنوعی / رابرت جی. شالکف؛ مترجمان محمود جورابیان، طناز زارع، امید استوار _ اهواز: دانشگاه شهید چمران ، ۱۳۸۲ .
- [5] شبکه های عصبی مصنوعی / سعید سلطانی، دکتر سروش سرداری، مژگان شیخ پور، سیده صغری موسوی _ تهران: نص ، ۱۳۸۹ .
- [6] اصول بنیادی و مرجع کاربردی شبکه های عصبی / دکتر وحید اسدپور _ تهران: آتی نگر، ۱۳۹۰ .
- [7] اصول و مبانی هوش مصنوعی / محمدرضا حسنی آهنگر، محمدرضا کنگاوری _ تهران: دانشگاه جامع امام حسین (علیه السلام) ، مؤسسهٔ چاپ و انتشارات ، ۱۳۸۹ .
- [8] مبانی شبکه های عصبی / محمداقرا منہاج _ دانشگاه صنعتی امیر کبیر (پلی تکنیک تهران) واحد تفریش، مرکز نشر پروفیسور حسابی ، ۱۳۷۹ .

[9] uploadtak.com/images/u4574_____pdf