

معرفی شبکه های عصبی مصنوعی

سید رضا شاه امیری

Email : reza@rsh.irدانشجوی کارشناسی ارشد مهندسی کامپیوتر - نرم افزار
دانشگاه آزاد اسلامی واحد نجف آبادWeb site : www.RSH.ir

چکیده :

در این نوشتار به معرفی شبکه های عصبی مصنوعی [۱] و ساختارهای آنها به صورت خلاصه میپردازیم. در ابتدا نرونهای شبکه های عصبی طبیعی معرفی شده و طرز کار آنها نشان داده شده است. سپس مدل مصنوعی این نرونها و ساختار آنها ، مدل ریاضی آنها ، شبکه های عصبی مصنوعی و نحوه آموزش و بکار گیری این شبکه ها به همراه روش یادگیری گزاردیان کاهنده نشان داده شده است. تمرکز بیشتر بر نوعی از این شبکه ها بنام شبکه های عصبی مصنوعی پرسپترون چند لایه میباشد. ابزارهایی نیز برای پیاده سازی این شبکه ها نام برده شده است.


کلیدواژه ها: شبکه های عصبی مصنوعی ، شبکه های عصبی، *Artificial Neural networks Multi layered*، *Perceptron*، *Gradient descent*

مقدمه :

در سالیان اخیر شاهد حرکتی مستمر از تحقیقات صرفا 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 ای فزاینده ای در توسعه تئوریک سیستمهای دینامیکی هوشمند مدل آزاد [۲]- که مبتنی بر داده های تجربی میباشد - ایجاد شده است. *ANN* ها جزء این دسته از سیستمهای مکانیکی قرار دارند که با پردازش روی داده های تجربی ، دانش یا قانون نهفته در وری داده ها را به ساختار شبکه منتقل میکنند. به همین خاطر به این سیستمها هوشمند گفته میشود ، زیرا بر اساس محاسبات روی داده های عددی یا مثالها ، قوانین کلی را فرا میگیرند. این سیستمها در مدلسازی ساختار نرو-سیناپتیکی [۳] مغز بشر میکوشند.

البته این سخن که "*ANN* ها در مدلسازی مغز بشر میکوشند" اغراق آمیز میباشد. دانشمندان هرچه بیشتر در مورد مغز بشر تحقیق میکنند و می آموزند ، بیشتر در می یابند که مغز بشر دست نیافتنی است. در حقیقت در مورد مغز و ساختار سیستم عصبی انسان اطلاعات زیادی بدست آمده است. ولی پیاده سازی ساختاری با پیچیدگی مغز انسان بر اساس اطلاعاتی و تکنولوژی که امروزه وجود دارد غیر ممکن میباشد.

ما میتوانیم یک نرون عصبی انسان و عملکرد آنرا را توسط مدل های ریاضی ، مدلسازی کنیم. شکل ۱ ساختار یک نرون طبیعی را نشان میدهد.



شکل ۱ - ساختار نرون طبیعی انسان

هر نرون طبیعی از سه قسمت اصلی تشکیل شده است :


۱. بدنه سلول (*Soma*)
۲. دندریت (*Dendrite*)
۳. اکسون (*Axon*)

دندریتها به عنوان مناطق دریافت سیگنالهای الکتریکی ، شبکه هایی تشکیل یافته از فیبرهای سلولی هستند که دارای سطح نامنظم و شاخه های انشعابی بیشمار میباشند . دندریتها سیگنالهای الکتریکی را به هسته سلول منتقل میکنند. بدنه سلول انرژی لازم را برای فعالیت نرون فراهم کرده و بر روی سیگنالهای دریافتی عمل میکند ، که با یک عمل ساده جمع و مقایسه با یک سطح آستانه مدل میگردد. اکسون بر خلاف دندریتها از سطحی هموارتر و تعداد شاخه های کمتری برخوردار میباشد. اکسون طول بیشتری دارد و سیگنالهای الکتروشیمیایی دریافتی از هسته سلول را به نرونهای دیگر منتقل میکند. محل تلاقی یک اکسون از یک سلول به دندریتهای سلولهای دیگر را سیناپس میگویند. توسط سیناپسها ارتباطات مابین نرونها برقرار میشود. به فضای مابین اکسون و دندریتها فضای سیناپسی گویند.

در حقیقت دندریتها به عنوان ورودی نرون و اکسون به عنوان خروجی و فضای سیناپسی محل اتصال ایندو میباشد. زمانیکه سیگنال عصبی از اکسون به نرونها و یا عناصر دیگر بدن مثل ماهیچه ها میرسد ، باعث تحریک آنها میشود. نرونها از هریک از اتصالات ورودی خود یک ولتاژ کم دریافت میکنند (توسط سیگنال عصبی ورودی) و آنها را با هم جمع میزنند. اگر این حاصل جمع به یک مقدار آستانه رسید اصطلاحاً نرون آتش میکند و روی اکسون خود یک ولتاژ خروجی ارسال میکند که این ولتاژ به دندریتهایی که به این اکسون متصلند رسیده و باعث یکسری فعل و انفعالات شیمیایی در اتصالات سیناپسی میشود و میتواند باعث آتش کردن نرونهای دیگر شود. تمامی فعالیتهای مغزی انسان توسط همین آتش کردنها انجام میشود.

حافظه کوتاه مدت انسان جرقه های لحظه ای الکتریکی میباشند و حافظه بلند مدت به صورت تغییرات الکتروشیمیایی در اتصالات سیناپسی ذخیره میشود که عمدتاً منجر به تغییر یونها میشود.

همانگونه که گفته شد ما میتوانیم توسط مفاهیم ریاضی یک نرون طبیعی را مدل کنیم. شکل ۲ یک نرون عصبی مصنوعی را نشان میدهد.



شکل ۲ ساختار یک نرون مصنوعی

سیگنالهای ورودی X_1 تا X_n معادل سیگنالهای عصبی ورودی و وزنها تا معادل مقادیر اتصالات سیناپسی ورودیهای نرون میباشند که جمعا ورودی نرون را تشکیل داده است.

تابع جمع‌کننده (فشرده) $\sum_{j=1}^n x_j w_{ij}$ تمامی عملیات هسته سلول را انجام میدهد. در مورد تابع فعال سازی [۴] سازی [۵] صحبت خواهد شد. خروجی نرون توسط تابع زیر مشخص میشود:

$$y_i = \text{ActivationFunction}\left(\sum_{j=1}^n x_j w_{ij}\right)$$

به خصوصیات زیر در مورد مغز انسان توجه کنید :

محاسبات کاملا به صورت توزیع شده و موازی انجام میشود.

"یادگیری" جایگزین برنامه ریزی از قبل میشود.

در مغز انسان یک ساختار ALU مشخص وجود ندارد. ALU ، حافظه و کنترل همگی در یک ساختار درهم تنیده شبکه ای از تعداد بسیار زیادی نرون توزیع و پخش شده است.

مغز انسان توسط یک پروسه یادگیری می آموزد که در پاسخ به یک ورودی ، چه خروجی را تولید کرده و ارسال کند. این فرآیند یادگیری در حقیقت توسط تنظیم اتصالات سیناپسی در نرونهای طبیعی و معادل آنها در ANN ها ، یعنی تنظیم وزنها

W_{ij} نرونهای مصنوعی انجام میشود. در حقیقت در طراحی یک نرون مصنوعی فقط کفایت وزنها را مشخص کنیم تا شبکه عصبی بتواند خروجی مورد نظر را از ورودی خاص تولید کند. متدهای مختلف یادگیری وجود دارد که میتواند بر اساس زوج مرتبهای <خروجی، ورودی> مقدار وزنها را بدست آورد. حال بر اساس مطالب گفته شده میتوان به تعریف ANN ها پرداخت.

تعریف شبکه های عصبی مصنوعی

یک ساختار شبکه ای از تعدادی عناصر مرتبط به هم به نام نرون که هر نرون دارای ورودیها و خروجیهای است و یک

عمل نسبتا ساده و محلی [۶] را انجام میدهد. شبکه های عصبی عموما عملکرد خود را طی یک پروسه یادگیری [۷] فرا میگیرد.

شبکه های عصبی کاربردهای عمده ای در تشخیص الگو ، گروه بندی ، پیش بینی یا برون پایی و ... دارا میباشد.

تاریخچه


در سال ۱۹۴۹ مدل MP شبکه های عصبی مصنوعی توسط مک کالوخ و پیت مطرح شد که یک مدل خطی ساده بود . سپس پرسپترون الگوریتمهای یادگیری را ارائه نمود. سال ۱۹۶۹ آغاز افول موقت شبکه های عصبی شد. زیرا عدم توانایی شبکه های عصبی در حل مسائل غیر خطی آشکار شد. ANN های آن زمان فقط قادر به حل مسائلی بودند که میتوانستیم پاسخهای آن مسئله را توسط یک خط در محور مختصات از هم جدا کنیم. در ۱۹۸۲ هاپفیلد با معرفی شبکه های چند لایه و الگوریتمهای یادگیری دارای $feedback$ ، راه حلی برای حل موارد غیر خطی ارائه کرد. در این زمان بود که شبکه های بازگشتی ، خودسازمانده ، $Autoregressive$ ، RBF و روش یادگیری هیبیدار مطرح شد. از نیمه دهه نود ، نسل سوم ANN ها مطرح شدند که عبارت بودند از :

- تعیین محدودیتهای تئوری و عملی شبکه
- عمومیت و حدود آن
- ترکیب و الگوریتمهای ژنتیکی و منطق فازی

در نهایت امروزه استفاده عملی و پیاده سازی تجاری و سخت افزاری ANN ها ممکن شده است .

معرفی مدل نرون ساده خطی


بر اساس ایده گرفته شده از نرونهای طبیعی ، میتوان مدل نرون مصنوعی را ارائه کرد که بتواند ورودیها را باهم ترکیب کرده و یک خروجی از آنها به وجود آورد. در ساده ترین حالت نرون ورودیهای وزن دار را با هم جمع میکند. شکل ۳ یک نرون ساده خطی را نشان میدهد.



شکل ۳: نرون ساده خطی

$$\underline{i} = \begin{bmatrix} i_1 \\ i_2 \\ \vdots \\ i_M \end{bmatrix} \quad \underline{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_M \end{bmatrix}$$
 میتوان شبکه عصبی را به صورت یک سیستم محرک / پاسخ در نظر گرفت. مهم اینست که بدانیم تعلیم شبکه یعنی تنظیم پارامترهای آن به نحویکه رفتار محرک / پاسخ طبق خواسته باشد. در حین تعلیم در واقع مجهولات ما وزنها (w) میباشدند. وزنها در غالب حافظه ها عمل میکنند و نحوه تولید پاسخ را مشخص میکنند. در صورتیکه ورودیهای و خروجیهای متناظر موجود باشد (به این زوج ورودی و خروجی مجموعه تعلیم گفته میشود [۸]) ، میتوان وزنها را بر اساس فرمول $w^T = oi^{-1}$ بدست آورد.

میتوانیم برای اینکه خروجی خاصی تولید شود از یک تابع به نام تابع فشرده سازی [۹] استفاده کنیم. این مسئله در شکل ۴ نشان داده شده است.



شکل ۴: مدل نرون خطی به همراه تابع فشرده سازی

تابع فشرده سازی (فعال سازی) رنج وسیعی از مقادیر ورودی را به مقدار خاصی نگاشت میکند. به عنوان مثال

میتوانیم هر مقدار خروجی را به مقادیر باینری 0 و 1 نگاشت کنیم. انواع مختلفی از توابع فشرده سازی در ANN ها استفاده میشود. ولی بیشترین استفاده را تابع فشرده سازی سیگموئید [10] دارد.

$$O_i = \frac{1}{1 + e^{-x_i}}$$

ادعا میشود که فرکانس آتش نرون طبیعی به صورت تابعی شبیه سیگموئید میباشد. البته دلایل دیگری برای استفاده از سیگموئید وجود دارد. از جمله :
 استفاده از سیگموئید فشرده سازی میکند. (رنج ورودی و خروجی [0, 1] میباشد)
 تقریباً خطی ، افزایشی و مشتق پذیر است.
 در فرم بسته قابل نمایش است.
 مشتق گیری از آن ساده است.

کهای تعیین پارامترهای نرون خطی

کلی دو روش برای تعیین پارامترهای نرون خطی یا به عبارت دیگر مشخص کردن مقادیر وزنها وجود دارد:
 تعیین مستقیم

روالهای تکرار شونده

۱ - تعیین مستقیم

فرض کنیم $\underline{w} = \underline{b}$ که b بردار پاسخهای دلخواه میباشد.

$$H = \{ \langle i_1, b_1 \rangle, \langle i_2, b_2 \rangle, \dots, \langle i_d, b_d \rangle \}$$

بنابر این :

$$\underline{w}^T = \underline{b} \Rightarrow \underline{w} = \underline{b}^T$$

بدین صورت میتوان مقادیر w را بدست آورد.

۲ - روالهای تکرار شونده

نام دیگر این روش "گرادیان کاهنده" [11] میباشد در ادامه به توضیح این روش می پردازیم :
 قبل از هر چیز بردار گرادیان را تعریف میکنیم:

$$\frac{dF(\underline{x})}{d\underline{x}} = \begin{pmatrix} \frac{dF(\underline{x})}{dx_1} \\ \frac{dF(\underline{x})}{dx_2} \\ \vdots \\ \frac{dF(\underline{x})}{dx_n} \end{pmatrix} = \nabla_x F$$

بردار گرادیان در واقع جهت تغییرات ماکزیمم در تابع f را نشان میدهد.
 در روش کاهش گرادیان ، ابتدا مقادیر تصادفی برای وزنها انتخاب میشود و بر اساس این خروجیهای شبکه بدست می آید. در یک روال تکرار شونده $\nabla_w F$ محاسبه شده و در جهت آن حرکت خواهد شد. بدین معنی که را طور تغییر میدهیم که اختلاف خروجی واقعی و خروجی مطلوب کمینه شود. حرکت در جهت متناظر با حرکت در جهت کاهش آن با شیب ماکزیمم میباشد.

خطای شبکه به ازاء وزنها \underline{w}_n برابر است با : $e_w = \underline{w}_n - b$

e_w در واقع همان تابعی است که باید کمینه شود. پس :

$$\underline{w}^{n+1} = \underline{w}^n - \alpha_n \frac{\partial e_w}{\partial \underline{w}} = \underline{w}^n - \alpha_n \underline{i}$$

خطای خروجی برابر است با اختلاف مابین خروجی شبکه (0) و خروجی مطلوب \underline{i} . خطای یک ورودی برابر است با :

$$e^p = \frac{1}{2}(t^p - o^p)^2$$

و خطاي كلي برابر است با :

$$E = \sum_{p=1}^n e^p$$

خطاي ميانگين مربع [12] برابر با :

قاعده كلي ، بدست آوردن مشتق خطا نسبت به w ميباشد تا بتوانيم تغييرات خطا نسبت به w را به صفر نزديک

کنيم. يعني ما بدنال پيدا کردن $\frac{\partial(e^p)}{\partial w^k}$ ميانشيم که k مرتبه تکرار اين روال است. به عبارتي ديگر :

$$\frac{\partial(e^p)}{\partial w^k} = \frac{\partial e}{\partial o^p} \cdot \frac{\partial o^p}{\partial g^p} \cdot \frac{\partial g^p}{\partial w^k}$$

در نتيجه تصحيح وزن z ام در مرحله k ام از تکرار الگوريتم تعليم به صورت زیر ميانشيم


$$w_{k+1}^j = w_k^j - \alpha [(o^p - t^p) \frac{\partial F(g^p)}{\partial g^p} i_k^p]$$

که $\frac{\partial F(g^p)}{\partial g^p}$ ، مشتق تابع فشرده سازي (اکتيواسيون) و α ، نرخ يادگيري ميباشد که عموماً مابين ۰ و ۱ انتخاب ميشود. بدین صورت ميتوان وزنهاي هر نرون را بدست آورد و روند تعليم شبکه را به اتمام رساند. پس از تعليم ، شبکه آماده توليد خروجي از ورودي متناظر ميباشد.

شبکه هاي پرسپترون [13] چند لايه

شبکه هايي که از یک نرون ساخته شده اند داراي محدوديتهايي ميانشند. اين شبکه ها توانايي پياده سازي توابع غير خطي را ندارند. به عنوان مثال توسط اين شبکه ها نميتوان تابع XOR را پياده سازي نمود. براي حل اين مشکل شبکه هاي ديگري پيشنهاد شد که ما به يکي از آنان که بيشتري استفاده را دارد مي پردازيم. دليل ديگر معرفي اين نوع شبکه ، استفاده از آن در اين تحقيق مي باشد.

مدل عمومي شبکه هاي پرسپترون ، شبکه جلو رونده [14] با روال تعليم انتشار به عقب [15] است. شبکه هاي جلو رونده شبکه هايي هستند که وروديهاي لايه اول نرونهاي آن به لايه هاي بعدي متصل بوده و در هر سطح اين مسئله صادق بوده تا به لايه خروجي برسد. روال انتشار به عقب بدین معني است که پس از مشخص شدن خروجي شبکه ، ابتدا وزنهاي لايه آخر تصحيح شده و بعد به ترتيب اوزان لايه هاي قبلي تصحيح ميشوند. در اين موارد بيشتري توضيح داده ميشود. شبکه هاي پرسپترون از یک لايه ورودي ، تعدادي لايه پنهان و یک لايه خروجي تشکيل شده است. در شکل ۵ یک شبکه پرسپترون با یک لايه پنهان نشان داده شده است.



شکل ۵ : نمونه ای از یک شبکه پرسپترون

در این شکل لایه X لایه ورودی ، لایه Z لایه پنهان و لایه Y نیز لایه خروجی میباشد.

در این شبکه ها شرایط زیر وجود دارد :

نرونهای هر لایه تنها به نرونهای لایه بعدی متصل میشوند.

هر نرون به تمامی نرونهای لایه بعد متصل است.

نرونهای لایه ورودی عملی را انجام نمیدهند و اوزان آنها ثابت و برابر یک میباشد. این نرونها فاقد تابع فشردده سازی میشوند. انتشار عملگر رو به جلو است. تمامی نرونها به غیر از لایه ورودی جمع کننده بوده و هر نرون میتواند تابع فشردده سازی مستقلی داشته باشد.

هر نرون میتواند دارای بایاس مستقل باشد.

تعداد لایه های پنهان مشخص نمیشود.

ریتیم یادگیری شبکه های پرسپترون (انتشار به عقب)

ن بخش به نحوه یادگیری شبکه پرسپترون چند لایه که در شکل ۵ نشان داده شده است می پردازیم.

گوریتیم یادگیری از علائم زیر استفاده میکنم:

ردار ورودی که برای یادگیری شبکه از آن استفاده میشود.

ردار خروجیهای مطلوب

δ_k : درصدی از خطا که برای تصحیح وزن w_{jk} استفاده میشود و براساس خطای واحد خروجی میباشد . این خطا در پنهان قبل از لایه خروجی انتشار به عقب می یابد.

δ_j : درصدی از خطا که برای تصحیح وزن v_{ij} استفاده میشود بر اساس انتشار به عقب اطلاعات خطا از لایه خروجی به و

پنهان Z_j میباشد.

خ یادگیری.

X_i : واحد ورودی i ام.

v_{0j} : بایاس واحد پنهان j ام.

Z_j : واحد پنهان j ام.

ورودي شبکه به Z_j توسط z_in_j نشان داده میشود:

$$z_in_j = v_{oj} + \sum_i x_i v_{ij}$$

سیگنال خروجي Z_j توسط z_j مشخص میشود:

$$z_j = f(z_in_j)$$

w_{0k} : بایاس واحد خروجي k ام.

ام k : واحد خروجي

ورودي Y_k توسط y_in_k مشخص میشود:

$$y_in_k = w_{0k} + \sum_j z_j w_{jk}$$

سیگنال خروجي Y_k توسط y_k مشخص میشود:

$$y_k = f(y_in_k)$$

برای آموزش شبکه توسط انتشار به عقب، سه مرحله باید انجام شود: انتشار به جلو الگوهای یادگیری ورودی، انتشار به عقب خطای بدست آمده و تنظیم اوزان.

در حین انتشار به جلو، هر واحد ورودی X_i سیگنال ورودی خود را در هرکدام از واحدهای پنهان توزیع میکند. سپس هرکدام از واحدهای پنهان اکتیواسیون خود را محاسبه کرده و سیگنال حاصل را به هرکدام از واحدهای خروجی ارسال میکند. در نهایت هرکدام از واحدهای خروجی Y_k با محاسبه اکتیواسیون خود، را به عنوان پاسخ به الگوی ورودی، ارائه میکند.

در مرحله یادگیری، در هرکدام از واحدهای خروجی، y_k تولید شده را با مقایسه کرده تا خطای مربوطه را پیدا کند بر اساس این خطا، فاکتور δ_k ($k = 1, \dots, m$) محاسبه میشود. از برای توزیع به عقب خطا در تمامی واحدهای لایه قبل استفاده میشود. همچنین از آن برای بروزرسانی اوزان میان واحدهای لایه پنهان و لایه خروجی نیز استفاده میشود. به همین صورت نیز δ_j برای تک تک واحدهای پنهان Z_j محاسبه میشود. البته انتشار به عقب خطا در لایه ورودی لازم نیست، ولی δ_j برای بروزرسانی اوزان میان لایه ورودی و لایه پنهان استفاده خواهد شد.

در نهایت زمانیکه تمامی δ مشخص شدند، تمامی اوزان به صورت هم زمان تصحیح خواهند شد. تصحیح وزن (از لایه پنهان به لایه خروجی) بر اساس δ_k و z_j خواهد بود و تصحیح وزن (از لایه ورودی به لایه پنهان) بر اساس δ_j و x_i خواهد بود. میباید.

حال بر اساس مطالب گفته شده الگوریتم یادگیری را شرح میدهم:

مرحله ۰: مقدار دهی اولیه اوزان بر اساس مقادیر تصادفی کوچک

مرحله ۱: تا زمانیکه شرط پایان برقرار نیست مراحل ۲ تا ۹ را تکرار کنید. (در مورد شرط پایان صحبت خواهد شد)

مرحله ۲: به ازاء هر زوج تعلیم (ورودی و خروجی متناظر در مجموعه تعلیم) مراحل ۳ تا ۸ را تکرار کنید:

مرحله ۳: هر واحد ورودی

$$X_i, i=1, \dots, n$$

سیگنال ورودی x_i را دریافت کرده و آنرا در تمامی واحدهای لایه بعد از خویش توزیع میکند.
هر واحد پنهان

$1, \dots, p$

حاصل جمع سیگنالهای ورودی وزن دار خویش را محاسبه میکند:

$$z_in_j = v_{oj} + \sum_i x_i v_{ij}$$

سپس تابع فشرده سازي مربوطه را بر حاصل اعمال ميکند :

$$z_j = f(z_in_j)$$

و سيگنال حاصل را به تمامي واحدهاي لايه بعدي ارسال ميکند.

مرحله 5 : هر واحد خروجي

$$Y_k, k=1, \dots, m$$

حاصل جمع سيگنالهاي ورودي وزن دار خويش را بدست مي آورد:

$$y_in_k = w_{0k} + \sum_j z_j w_{jk}$$

و تابع فشرده سازي مربوط به خود را براي محاسبه خروجي به حاصل اعمال ميکند:

$$y_k = f(y_in_k)$$

انتشار به عقب خطا :

مرحله 6 : هر واحد خروجي

$$Y_k, k=1, \dots, m$$

δ_k را بر اساس خروجي مطلوب و خروجي بدست آمده محاسبه ميکند :

$$\delta_k = (t_k - y_k) f'(y_in_k)$$

و مقداري را که بعدا براي تصحيح وزن w_{jk} و باياس w_{0k} نياز است ، بدست مي آورد :

$$\Delta w_{jk} = \alpha \delta_k z_j$$

$$\Delta w_{0k} = \alpha \delta_k$$

و δ_k را به واحدهاي لايه قبل از خود ارسال ميکند.

مرحله 7 : هر کدام از واحدهاي پنهان

$$1, \dots, p$$

حاصل جمع دلتاي ورودي خود را که از واحدهاي لايه بعد از خود به آن رسیده است ، محاسبه ميکند:

$$= \sum_{k=1}^m \delta_k w_{jk}$$

و حاصل را در مشتق تابع فشرده سازي ضرب کرده تا ترم اطلاعات خطاي بدست آيد:

$$_in_j f'(z_in_j)$$

سپس مقداري را که بعدا براي تصحيح وزن v_{ij} و باياس v_{0j} نياز است ، بدست مي آورد :

$$\chi \delta_j x_i$$

$$\alpha \delta_j$$

تصحيح اوزان و باياسها :

: هر کدام از واحدهاي خروجي وزنها ($j=0, \dots, p$) و باياس خود را به صورت زير تصحيح ميکنند :

$$w) = w_{jk} (old) + \Delta w_{jk}$$

هر کدام از لايه هاي پنهان نيز وزنها ($i=0, \dots, n$) و باياس مربوطه را به صورت زير تصحيح ميکند :

$$v_{ij} (new) = v_{ij} (old) + \Delta v_{ij}$$

مرحله 9 : شرط پايان برقرار است. پايان الگوريتم يادگيري.

البته در زمان پیاده سازی باید آرایه های مجزایی برای دلتاهای واحدهای خروجی (مرحله ۶ ،) و واحدهای پنهان (مرحله ۷ ، δ_j) تشکیل شود.

یک دوره [17] ، چرخه ای کامل حول مجموعه یادگیری است. تعداد زیادی چرخه برای آموزش یک شبکه عصبی انتشار به عقب لازم است. معمولاً چرخه آموزش را تا زمانی که میانگین کل خطا به یک مقدار حداقل مطلوب یا صفر برسد ادامه می دهند (شرط پایان) . در برخی مواقع مقدار خطای میانگین در طی چند دوره تغییر نمی کند . در این صورت نیز یادگیری شبکه عصبی پایان می یابد.

عموما مقدار دهی اولیه اوزان و بایاسها به صورت تصادفی با مقادیر کوچک انجام میشود. ثابت شده است که انتخاب هر مقدار اولیه برای وزنها و بایاسها به سمت مقدار صحیح آنها همگرا است. بدین معنی که هر مقداری برای آنها انتخاب کنیم ، پارامترهای شبکه تنظیم خواهند شد. تنها تفاوتی که وجود دارد ، در صورت فاصله زیاد مقادیر اولیه وزنها و بایاسها با مقادیر صحیح آنها ، برای رسیدن به مقادیر مطلوب تعداد دوره ها زیاد خواهد بود . [Nguyen-Widrow[1990] روشی را برای مقدار دهی اولیه اوزان و بایاسها پیشنهاد داده اند که باعث میشود وزنها با فاصله کمی نسبت به مقدار صحیح آنها انتخاب شوند . توضیح این روش در حوصله این مقوله نیست و علاقه مندان میتوانند با مراجعه به منابع شبکه های عصبی مصنوعی این روش را بیاموزند.

در زمینه تعیین تعداد الگوهای یادگیری لازم برای تعلیم شبکه روشی وجود دارد. اگر P تعداد الگوهای یادگیری ، W تعداد وزنها و حداکثر خطای مجاز شبکه e باشد ، بدین منظور که شبکه به صورت صحیح عمل کند و بتواند عمل دسته بندی را با دقت $1-e$ انجام دهد ، باید رابطه زیر برقرار باشد :

$$\frac{W}{P} = e \Rightarrow P = \frac{W}{e}$$

به عنوان مثال در صورتیکه $e=0.1$ و $W=80$ باشد ، ما به $P=800$ ($P=800$) الگوی یادگیری نیازمندیم تا مطمئن شویم که شبکه عصبی مصنوعی طراحی شده در ۹۰٪ مواقع به صورت صحیح عمل میکند. اثبات این مسئله توسط *Baum* و *Hausler* در سال ۱۹۸۹ انجام شد.

در شبکه های پرسپترون چند لایه ، تعداد لایه های پنهان میتواند هر تعداد باشد. البته در بیشتر کاربردها یک لایه پنهان کفایت میکند . در برخی مواقع نیز دولایه پنهان یادگیری شبکه را ساده تر میکند. در حالتی که تعداد لایه های پنهان بیش از یک لایه باشد ، باید الگوریتم ذکر شده در بالا را برای تمامی لایه ها تعمیم داد.

روشی عملی برای تخمین تعداد واحدها (نرونها) در هر لایه پنهان در دست نیست. بدین منظور باید از روشهای سعی و خطا استفاده کرد تا به مقدار میانگین خطای کل مطلوب رسید.

برای مدلسازی شبکه های عصبی مصنوعی ابزارهای زیادی وجود دارد . از این جمله :

SNN (Stuttgart Neural Network Simulator)

Matlab standard NN Toolbox

Netlab toolbox for Matlab

به عنوان نمونه میتوانید از *Netlab* که یک تول باکس مجانی برای نرم افزار *Matlab* میباشد استفاده کنید. برای استفاده از آن میتوانید به آدرس زیر رجوع کنید:

<http://www.ncrg.aston.ac.uk/netlab/index.php>

پانویسها

- [1] Artificial Neural Network
- [2] Model Free
- [3] Neuro-synaptic
- [4] Activation function
- [5] Squashing
- [6] Local
- [7] Training
- [8] Trainina set

- [9] Squashing
 - [10] Sigmoid
 - [11] Gradient descent
 - [12] Mean Square Error(MSE)
 - [13] Perceptron
 - [14] Feed forward
 - [15] Back propagation training
 - [16] Epoch
-

فهرست منابع

1 – Fauset,L.(1994). **Fundamentals of Neural Networks : Architectures , Algorithms and Applications .** Prentice Hall

2 – Schalkoff ,R,J.(1997). **Artificial Neural Networks .** McGraw-Hill

3 – Krose,B ,Smagt,P(1196) .**An Introduction to Neural Networks .** University of Amesterdam

۴ – منہاج ، محمد باقر (۱۳۸۱). **مباني شبکه هاي عصبي .** دانشگاه صنعتي امير کبير