

ارائه الگوریتمهای نو مبتنی بر اتوماتانهای یادگیر برای تعیین تعداد وزنهای ورودی نرونهای لایه مخفی برای شبکه‌های عصبی سه لایه

محمد رضا میبدی

دانشیار

دانشکده مهندسی کامپیوتر، دانشگاه صنعتی امیرکبیر

بهبود مشعوفی

استادیار

گروه مهندسی دانشکده فنی، دانشگاه ارومیه

محمد باقر منهاج

دانشیار

دانشکده مهندسی برق، دانشگاه صنعتی امیرکبیر

سید احمد معتمدی

دانشیار

دانشکده مهندسی برق، دانشگاه صنعتی امیرکبیر

چکیده

الگوریتم پس انتشار خطای استاندارد، فقط در فضای وزنهای شبکه، با تپولوژی ثابت، عمل جستجو را انجام میدهد. تعداد لایه‌ها، نرونها و وزنهای شبکه، تأثیر بسزائی بر روی کارائی شبکه دارد. بنابر این نیاز به الگوریتمهای داریم که بتوانند بطور اتوماتیک ساختار مناسب شبکه را تعیین کنند. برای تعیین اندازه مطلوب برای شبکه‌های عصبی الگوریتمهای گوناگونی توسط افراد مختلف ارائه شده است. توسط آقایان میبدی و بیگی الگوریتم جدیدی تحت عنوان WSA با استفاده از اتوماتان یادگیری مهاجرت اشیا برای تعیین تعداد وزنهای طراحی گردیده است. این الگوریتم با حذف وزنهایی که دارای تأثیر کمتری هستند نه تنها باعث کاهش پیچیدگی شبکه میشود. بلکه قدرت تعمیم شبکه را نیز افزایش میدهد. در الگوریتم تعیین تعداد وزن، در ابتدا همه وزنهای موجود در شبکه روشن بوده و به همه وزنهای مدتی اجازه داده میشود تا در آموزش شبکه شرکت نمایند. وزنهای روشنی که قدر مطلق مقدار آنها از یک مقدار آستانه‌ای کمتر باشد جزئیه شده و وزنهای روشنی که قدر مطلق آنها از یک مقدار آستانه‌ای دیگر بیشتر باشد پاداش میگیرند. وزنهای روشنی که قدر مطلق مقدار آنها بین دو مقدار آستانه‌ای قرار گیرد تغییری در وضعیت آنها ایجاد نمیشود. با انتخاب مقادیر بهینه برای این بازه‌ها میتوانیم در کمترین زمان به شبکه‌هایی با حداقل تعداد وزن که بتواند با خطای قابل قبولی الگوهای آموزش را یاد گرفته و همچنین از قدرت تعمیم قابل قبولی بخوددار باشد برسیم. در این مقاله با استفاده از اتوماتان یادگیری، بازه‌های تصمیم گیری را تطبیق داده‌ایم. در الگوریتم پیشنهادی تحت عنوان AWSA برای پاسخ دادن به اتوماتان مربوط به تشخیص بازه‌های تصمیم گیری، از معیار خط کمک گرفته‌ایم. همچنین در این مقاله الگوریتم جدید دیگری تحت عنوان MWSA ارائه گردیده است. در الگوریتم پیشنهادی معیارهای جدیدی برای ارزیابی عملکرد وزنهای روشن و خاموش ارائه گردیده است. نتایج شبیه‌سازیهای مختلف بر روی مسائل شناسایی اعداد انگلیسی، شناسایی اعداد چاپی فارسی، تقریبتابع غیر خطی زمان گستته از مرتبه دوم و باز شناسی فونمنهای فارسی نشان میدهد الگوریتمهای پیشنهادی AWSA و MWSA دارای عملکرد بهتری نسبت به الگوریتمهای دیگر یادگیری ساختار میباشد.

کلمات کلیدی

مهندسی شبکه‌های عصبی، شبکه‌های عصبی چندلایه، ساختار شبکه‌های عصبی، الگوریتم پس انتشار خطای، اتوماتانهای یادگیر

New Learning Automata Based Algorithms for Determining the Number of Input Weights of Hidden Layers in a Multi layer Neural Networks

B. Mashoufi
Assistance Professor
Electrical Engineering Department,
Uremia University

M. R. Meybodi
Professor
Computer Engineering Department,
Amirkabir University of Technology

Sayed A. Motamed
Associate Professor
Electrical Engineering Department,
Amirkabir University of Technology

M. B. Menhaj
Associate Professor
Electrical Engineering Department,
Amirkabir University of Technology

Abstract

Backpropagation algorithm performs gradient descent only in the weight space of a network with fixed topology. The Number of layers, Neurons and network weights have important influence on network performance. So algorithms that can find appropriate network architecture automatically are thus highly desirable. Researchers have proposed different algorithms for determining optimum size of neural networks. Meybodi and Beigy introduced the first learning automata based algorithms, called WSA algorithm. This algorithm by turning off the unimportant weights, not only reduces network complexity but also increases network generalization ability. At the beginning, all weights of the network are on and contribute to learning. The on weights whose absolute values are less than a threshold value, are penalized and those whose absolute value are larger than another threshold value, are rewarded. The on weights, whose absolute values lie between these two threshold values, neither rewarded, nor penalized. By choosing optimum values for these values we can obtain, networks with minimum number of weights which can learn training patterns with acceptable error and generalization ability. In this paper we introduce a new learning automata based algorithm, called AWSA for adaptation of parameters of WSA algorithm. Also, a new algorithm called MWSA is introduced to determine important weights in the multi layer neural networks. These algorithms are applied to number of problems such as recognition of English number, Persian printed numbers recognition, second order discrete time nonlinear function approximation and Persian phoneme recognition. The results obtained show that the proposed algorithms have better performance than other existing algorithms.

Keywords

Neural Networks Engineering, Multi layer Neural Networks, Neural Networks Topology, Backpropagation algorithm, Learning Automata

مقدمه

در سالهای اخیر مدل‌های شبکه عصبی زیادی، برای مسائل طبقه‌بندی الگو، تقریب تابع، بازشناسی گفتار و ... ارائه گردیده است. در بین اینها، شبکه‌های عصبی جلو رونده چند لایه، مهمترین آنها می‌باشد. روش‌هایی که از الگوریتم پس انتشار خطای استاندارد استفاده می‌کنند فقط در فضای وزنهای شبکه با توبولوژی ثابت، عمل جستجو را انجام میدهند [۱]. این روش‌ها در حالت کلی فقط موقعی مناسب می‌باشد که ساختار شبکه درست انتخاب شده باشد. تعداد لایه‌ها، نرونها و وزنهای شبکه، تأثیر بسزایی بر روی کارائی شبکه دارد. شبکه‌های خیلی کوچک، قادر به یادگیری مسئله نبوده و شبکه‌های با ابعاد بزرگ دچار Overfitting شده و قدرت تعمیم پائینی خواهد داشت. علاوه بر این بسیارکند بوده و هزینه بالایی خواهد داشت. حالت مشابه را در مسئله برازش منحنی با استفاده از چند جمله ایها شاهد هستیم. داده‌هایی را در نظر می‌گیریم که توسط یک تابع که نویز جمع‌شونده نیز در خروجی آن قرار دارد ایجاد شده است. یک چند جمله‌ای با تعداد پائین ضرائب قادر نخواهد بود از روی داده‌ها تابع را مدل‌سازی کند از طرف دیگر یک چند جمله‌ای با تعداد بالای ضرائب، نویز موجود در داده‌ها را نیز مدل‌سازی

کرده در نتیجه مدل خوبی را برای تابع ارائه نخواهد کرد. ولی اگر تعداد ضرائب بطور مناسب انتخاب شود، چند جمله‌ای، نمایش خوبی را برای تابع، همچنین پیشگویی دقیقی را برای داده‌های جدید ارائه خواهد کرد. در شبکه‌های عصبی نیز همین مسئله اتفاق می‌افتد. در این حالت نیز پیچیدگی مدل باستی با مسئله تطبیق داده شود. بنابر این نیاز به الگوریتمهایی داریم که بتوانند بطور اتوماتیک ساختار مناسب شبکه را تعیین کنند. الگوریتمهایی را که تاکنون توسط افراد مختلف بمنظور تعیین اندازه مطلوب برای شبکه‌های عصبی ارائه شده است میتوان به پنج گروه عمدهٔ زیر تقسیم کرد [۴۳].

الف - الگوریتمهای هرس: در این دسته از الگوریتمها، از یک شبکه بزرگ شروع کرده و آنرا آموزش میدهیم سپس وزنها و نرونها را زائد را حذف میکنیم. اندازه اولیه بزرگ، این اجازه را میدهد که شبکه سریعاً، با حداقل حساسیت به شرایط اولیه، آموزش ببیند. و پیچیدگی پائین شبکه هرس شده نیز قدرت تعمیم آنرا افزایش میدهد. این الگوریتمها بدو گروه عمده تقسیم میشوند. گروه اول، حساسیت تابع خطاب نسبت به حذف یک عنصر را تخمین زده، عناصر با حداقل تأثیر را حذف میکند [۵]-[۲]. گروه دوم، عباراتی را به تابع هدف اضافه میکند که به شبکه برای انتخاب جوابهای کارآمد پاداش میدهد [۱۳]-[۶].

ب - الگوریتمهای سازنده: این الگوریتمها از یک شبکه کوچک شروع کرده سپس تا حصول یک جواب رضایت‌بخش، واحدهای مخفی و وزنهای را به شبکه اضافه میکنند [۱۸]-[۱۴]-[۱].

ج - الگوریتمهای ترکیبی: این دسته از الگوریتمها در حقیقت ترکیبی از الگوریتمهای هرس و الگوریتمهای سازنده میباشد. این الگوریتمها در طول آموزش با اضافه و حذف کردن وزنها و نرونها سعی در رسیدن به یک شبکه با ساختار اپتیمال را دارند [۲۰]-[۱۹].

د - الگوریتمهای تکاملی: این الگوریتمها با استفاده از یک معیار کارآیی مثل حداقل خطاب و یا پیچیدگی آموزش، در فضای ساختارها، بدنبال مناسبترین ساختار میباشند. در این روش هر نقطه از فضای جستجو، متناظر با یک ساختار شبکه میباشد [۲۱]-[۲۵].

ه - الگوریتمهای بر اساس اتوماتانهای یادگیر: تعدادی از محققین از اتوماتانهای یادگیر برای تطبیق پارامترهای الگوریتم BP استفاده کرده‌اند [۴۹]-[۵۰]-[۵۲]. برخی دیگر، از اتوماتانهای یادگیر برای ارائه ساختارهای بهینه با پیچیدگی آموزش کم و قدرت تعمیم بالا استفاده کرده‌اند [۲۶]-[۴۳]-[۴۸]-[۵۱]. در اولین الگوریتم ارائه شده [۲۶] تحت عنوان الگوریتم بقا از یک اتوماتان یادگیر مهاجرت اشیا بعنوان یک ابزار جستجوی عمومی استفاده شده است. این الگوریتم حین آموزش، ساختار مناسبی برای شبکه عصبی سه لایه از حیث پائین بودن پیچیدگی آموزش و قدرت تعمیم بالا تعیین میکند. الگوریتم بقا آموزش را با یک شبکه عصبی سه لایه بزرگ شروع کرده و با افزودن و کاستن نرونها مخفی، تعداد نرونها لایه مخفی شبکه را تعیین میکند. در ادامه کار در مقاله [۴۳] الگوریتم جدید دیگری با استفاده از اتوماتان یادگیری مهاجرت اشیا تحت عنوان الگوریتم بقا وزن WSA برای تعیین تعداد وزنها طراحی گردیده است. این الگوریتم با حذف وزنهایی که دارای تأثیر کمتری هستند نه تنها باعث کاهش پیچیدگی شبکه می‌شود. بلکه افزایش قدرت تعمیم شبکه را نیز بدنبال دارد. الگوریتم تعیین تعداد وزن با خاموش و روشن کردن وزنها سعی در پیدا کردن وزنهای مناسب دارد. در الگوریتم ارائه شده در ابتدا همه وزنهای موجود در شبکه روشن بوده و به همه وزنها مدتی اجازه داده میشود تا در آموزش شبکه شرکت نمایند. وزنهای روشنی که قدر مطلق مقدار آنها از یک مقدار آستانه‌ای کمتر باشد جریمه شده و وزنهای روشنی که قدر مطلق آنها از یک مقدار آستانه‌ای دیگر بیشتر باشد پاداش میگیرند. وزنهای روشنی که قدر مطلق مقدار آنها بین دو مقدار آستانه‌ای قرار بگیرد تغییری در وضعیت آنها ایجاد نمیشود. در مورد وزنهای خاموش نیز وضع بهمین منوال است وزنهای خاموشی که قدر مطلق آنها از یک مقدار آستانه‌ای باشد پاداش میگیرند و وزنهای خاموشی که قدر مطلق آنها بیشتر از یک مقدار آستانه‌ای باشد جریمه میشوند. وزنهایی که بین دو مقدار آستانه‌ای قرار میگیرند تغییری در وضعیت آنها صورت نمیگیرد. مقادیر آستانه‌ای که در این تصمیم‌گیریها مورد استفاده قرار میگیرد بسیار تعیین‌کننده بوده و تأثیر چشمگیری در عملکرد شبکه عصبی دارد. با انتخاب مقادیر بهینه برای این بازه‌ها میتوانیم در کمترین زمان به شبکه هایی با حداقل تعداد وزن که بتواند با خطای قابل قبولی الگوهای آموزش را یاد گرفته و از قدرت تعمیم قابل قبولی برخوردار باشد برسیم. در این مقاله الگوریتم جدیدی تحت عنوان AWSA برای تنظیم بازه‌های تصمیم‌گیری ارائه گردیده

است. در الگوریتم پیشنهادی برای پاسخ دادن به اتوماتان مربوط به تنظیم بازه‌های تصمیم‌گیری، از معیار خطا کمک گرفته‌ایم. مدر ادامه الگوریتم جدید دیگری تحت عنوان MWSA ارائه گردیده است. در الگوریتم پیشنهادی معیارهای جدیدی برای ارزیابی عملکرد وزنهای روشن و خاموش ارائه گردیده است. نتایج شبیه‌سازی‌های مختلف بر روی مسائل شناسائی اعداد انگلیسی، شناسائی اعداد چاپی فارسی، تقریبتابع غیر خطی زمان گستته از مرتبه دوم و باز شناسی فو نمهای فارسی نشان میدهد الگوریتمهای پیشنهادی AWSA و MWSA دارای عملکرد بهتری نسبت به الگوریتمهای دیگر یادگیری ساختار میباشد.

بخش‌های بعدی مقاله بصورت زیر سازماندهی شده است. در بخش ۲ الگوریتم یادگیری پس انتشار خطا که برای آموزش شبکه‌های عصبی چند لایه مورد استفاده قرار می‌گیرد توضیح داده شده است. موضوع Overtraining و قدرت تعمیم شبکه در بخش ۳ مورد بررسی قرار گرفته است. در بخش ۴ مقدمه‌ای بر اتوماتانهای یادگیر و انواع مهم آن آورده شده است. در بخش ۵ الگوریتم بقا وزن را توضیح داده‌ایم. در بخش‌های ۶ و ۷ به ترتیب الگوریتمهای پیشنهادی AWSA و MWSA توضیح داده شده است. نتایج آزمایشها برای مسائل مختلف در بخش ۸ و در بخش پایانی نتیجه‌گیری شده است.

۱- الگوریتم پس انتشار خطا

الگوریتم BP یک روش سیستماتیک برای آموزش شبکه‌های عصبی چند لایه می‌باشد. الگوریتم BP بطور مبسط در مرجع [۲] توضیح داده شده است. الگوریتم BP، دو مسیر محاسباتی دارد. مسیر اول مسیر پیشخور یا رفت و مسیر دوم مسیر پس خور یا مسیر برگشت نامیده می‌شود. مسیر رفت: این مسیر با معادلات زیر توصیف می‌شود:

$$\begin{aligned} \underline{a}^0 &= \underline{p}(k) \\ \underline{a}^{l+1}(k) &= \underline{F}^{l+1}\left(\underline{W}^{l+1}(k)\underline{a}^l + \underline{b}^{l+1}(k)\right), \quad l = 0, 1, \dots, L-1 \\ \underline{a} &= \underline{a}^L(k) \end{aligned} \quad (1)$$

که در آن داریم:

\underline{a}^l : بردار خروجی لایه l ام

$\underline{p}(k)$: بردار ورودی

\underline{F}^l : بردار تابع محرک لایه l ام

\underline{W}^l : ماتریس وزن لایه l ام

\underline{b}^l : بردار بایاس لایه l ام

\underline{a}^l : بردار خروجی شبکه عصبی

L : تعداد لایه‌های شبکه عصبی

در این مسیر وزنهای و بایاسهای شبکه تغییر داده نمی‌شوند. توابع محرک، روی تمامی نرونها عمل می‌کند، یعنی:

$$\underline{F}^{l+1}(\underline{n}^{l+1}(k)) = \left[f^{l+1}(n_1^{l+1}(k)), \dots, f^{l+1}(n_{s_{l+1}}^{l+1}(k)) \right]^T \quad (2)$$

که در آن سمبلها بصورت زیر تعریف می‌شوند:

f^l : تابع محرک لایه l ام

$\underline{n}^l(k)$: بردار ورودی خالص لایه l ام

$n_i^l(k)$: ورودی خالص i ام لایه l

s_l : تعداد نرونها لایه l ام

مسیر برگشت: در این مسیر بردارهای حساسیت از لایه آخر به لایه اول برگشت داده می‌شوند. معادلات زیر، دینامیک

مسیر برگشت را بیان می‌کند:

$$\begin{aligned}\underline{\delta}^L(k) &= -2F^L(\underline{n})\underline{e}(k) \\ \underline{\delta}^l(k) &= \dot{F}^l(\underline{n}^l)(W^{l+1})^T \underline{\delta}^{l+1}, \quad l = L-1, \dots, 1 \\ \underline{e}(k) &= \underline{t}(k) - \underline{a}(k)\end{aligned}\quad (3)$$

که در آن داریم:

$\underline{\delta}^L(k)$: بردار گرادیان محلی لایه خروجی

$\underline{e}(k)$: بردار خطا

$\underline{\delta}^l(k)$: بردار گرادیان محلی لایه l

$\underline{t}(k)$: بردار هدف

در مسیر برگشت ابتدا با در دست بودن بردار هدف، بردار خطا محاسبه می‌شود. سپس بردار خطا از سمت راست به چپ و از لایه آخر به لایه اول توزیع شده، گرادیان محلی نرون به نرون با الگوریتم بازگشتی محاسبه می‌شود. تنظیم پارامترها: در این مرحله ماتریسهای وزن و بردارهای بایاس شبکه بصورت زیر تنظیم می‌شوند.

$$\begin{aligned}W^l(k+1) &= W^l(k) + \alpha \underline{\delta}^l(k) (\underline{a}^{l-1}(k))^T + \eta W^l(k-1) \\ b^l(k+1) &= b^l(k) + \alpha \underline{\delta}^l(k) + \eta b^l(k-1) \quad l = 1, 2, \dots, L\end{aligned}\quad (4)$$

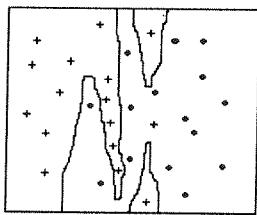
که در رابطه فوق α و η به ترتیب نرخ یادگیری و ضریب ممنتم می‌باشد.

توقف: اگر میانگین مربعات خطا در هر epoch (جمع مربعات خطا برای تمامی الگوهای یادگیری) کمتر از مقدار آستانه کوچکی بوده و یا اینکه فرم تغییرات در پارامترهای شبکه پس از هر سیکل خیلی کوچک باشد الگوریتم BP متوقف می‌شود.

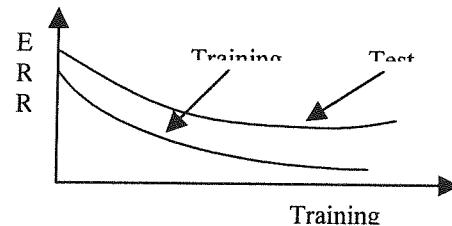
۲- Overtraining و قدرت تعمیم

موقعیکه یک شبکه عصبی آموزش می‌بیند، وزنها طوری تغییر داده می‌شوند که خطا کاهش یابد. اگر شبکه توسط الگوهایی که فقط اختلاف جزئی با الگوهای آموزش دارند تست شود خطا در الگوهای تست همچنانکه شبکه آموزش می‌بیند و قدرت تعمیم آن بیشتر می‌شود کاهش پیدا می‌کند. این مسئله در شکل (۱) نشان داده شده است. اگر الگوهای آموزش ناکافی باشد در اینصورت محتوى داده‌ها نادرست و گمراه‌کننده خواهد بود. در بعضی نقاط، بویژه در مراحل بعدی یادگیری، داده‌های ناکافی تأثیر خود را نشان داده و با اینکه خطای آموزش کاهش می‌یابد خطای آزمایش شروع به افزایش می‌کند [۲۸]. یک روش برای پرهیز از Overfitting این است که توانائی تعمیم را بهنگام آموزش تخمین زده و زمانیکه شروع به کاهش می‌کند آموزش را قطع نمائیم. ساده‌ترین روش این است که الگوها را به دو گروه الگوهای آموزش و الگوهای تصدیق تقسیم کنیم. الگوهای آموزش برای تغییر دادن وزنها استفاده می‌شود و الگوهای تصدیق برای تخمین توانائی تعمیم استفاده شده و آموزش زمانی متوقف می‌شود که خطا روی الگوهای تصدیق شروع به افزایش کند. این روش موقعیکه الگوهای کمی برای آموزش در اختیار می‌باشد بدلیل اینکه الگوهای تصدیق نمی‌تواند برای آموزش مورد استفاده قرار گیرد عملی نمی‌باشد [۳۱-۳۹]. یک راه دیگر برای دوری جستن از Overtraining این است که توانایی شبکه در بهره‌گیری از همبستگی‌های نادرست در الگوها را محدود کنیم. Overtraining موقعی اتفاق می‌افتد که درجه آزادی شبکه (تعداد وزنها) بیشتر از الگوهای آموزش باشد. با اینکه شبکه با اعمال الگوهای آموزش جواب دقیقی را بدست میدهد ولی ممکن است در نقاط دیگر خیلی بد عمل کند. شبکه‌های کوچک در کنار قدرت تعمیم بالا مزیتهای دیگری را به مراد دارند. معمولاً اینها را می‌توان خیلی سریع و با هزینه کمتری پیاده‌سازی کرد. تئوریها و فرمولهایی برای تخمین اندازه مورد نیاز سیستم، مورد استفاده قرار گرفته است [۳۲-۳۴]. این روشها پیچیدگی سیستم یادگیری و تعداد الگوهای مورد نیاز برای یادگیری یک تابع را بهم ربط میدهند. اگر تعداد الگوها نسبت به پیچیدگی سیستم کوچک باشد. در اینصورت انتظار داریم خطای تعمیم زیاد باشد. شکلها ۲ و ۳ تأثیر شاخه زنی را نشان میدهد. شکل ۲ مرزهای تشکیل شده توسط یک شبکه ۴ لایه با دو ورودی، ۲ لایه مخفی با ۵۰ نرون در لایه مخفی اول و ۱۰ نرون در لایه

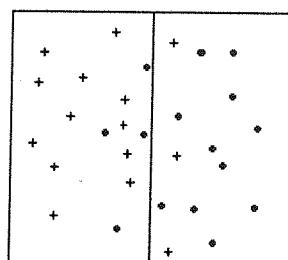
مخفى دوم و یک خروجی را نشان میدهد. شبکه دارای ۳۱ الگو برای آموزش وجود دارد. بنابر این تعداد پارامترهای شبکه در مقایسه با تعداد الگوها خیلی زیاد میباشد. گرچه دادهها تقریباً بطور خطی جدا پذیرند (با کمی همپوشانی در نزدیکی مرز) با اینحال مرز طبقه‌بندی شبکه خیلی غیر خطی بوده و احتمالاً قدرت تعمیم خوبی روی داده‌های اضافه دیگر از همان تابع، نخواهد داشت. شکل ۳ همان شبکه را پس از شاخه زنی نشان میدهد. اندازه شبکه به ۱۵ با ۲/۲/۱ وزن تقلیل پیدا کرده و مرز تصمیم‌گیری بسیار یکنواخت میباشد. روش‌های پیچیده‌تر میتواند شبکه را به یک شبکه ساده فقط با ۲ وزن تقلیل دهد. مثال همچنان نشان میدهد که روش شاخه زنی میتواند بعنوان ابزاری برای انتخاب ویژگی مورد استفاده قرار گیرد. اگر ورودیهای خاصی برای مسئله مهم نباشد الگوریتم، اتصالات مربوط به آنرا قطع خواهد کرد.



شکل (۲) مرزهای تصمیم‌گیری مربوط به شبکه هرس نشده.



شکل (۱) تغییرات خطای مربوط به الگوهای آزمایشی و آموزشی.



شکل (۳) مرز تصمیم‌گیری مربوط به شبکه هرس شده.

۳- اتوماتان یادگیر

اتوماتان یادگیر^۱ (LA) را می‌توان به دو گروه اصلی اتوماتان یادگیر با ساختار ثابت^۲ (FSLA) و اتوماتان یادگیر با ساختار متغیر^۳ (VSLA) تقسیم کرد [۳۸]-[۳۵]. اگر احتمال انتقال از یک حالت به حالت دیگر و احتمالهای اقدام و حالت ثابت باشند، اتوماتان با ساختار ثابت، در غیر این صورت اتوماتان با ساختار متغیر نامیده می‌شود. بعضی از انواع FSLA عبارتند از اتوماتانهای ستلين^۴، کرینسکی^۵ و کرایلف^۶. اتوماتان یادگیر با ساختار ثابت یک پنج تایی بصورت $\langle \alpha, \beta, F, G \rangle$ می‌باشد که در آن داریم:

$$\alpha = (\alpha_1, \dots, \alpha_n) \text{ مجموعه اقدامهایست که در هر مرحله یکی از این اقدامها انتخاب می‌شود.}$$

$$\Phi = (\Phi_1, \dots, \Phi_n) \text{ مجموعه حالتهاست.}$$

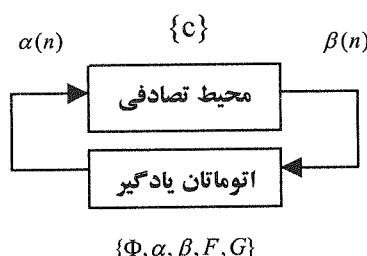
$$\beta = \{0,1\} \text{ مجموعه ورودیهایست که در آن ۱ جریمه و ۰ پاداش را نشان می‌دهد.}$$

$$F: \Phi \times \beta \longrightarrow \Phi \text{ نگاشت انتقال نامیده می‌شود. این نگاشت، انتقال حالت‌های اتوماتان پس از دریافت ورودی را تعریف می‌کند.}$$

$$F \text{ می‌تواند استوکستیک ۷ باشد.}$$

$$G: \Phi \longrightarrow \alpha \text{ نگاشت خروجی بوده و اقدام اتوماتان در حالت } r \text{ را نشان میدهد.}$$

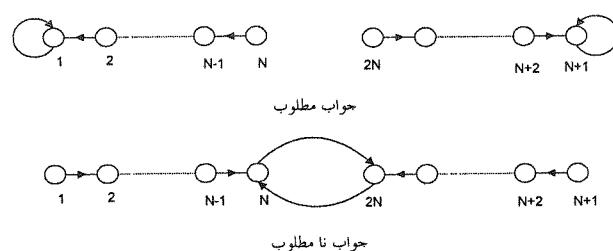
اقدام انتخاب شده بعنوان ورودی به محیط اعمال شده و محیط در واکنش به آن پاسخ تصادفی $\beta(n)$ را در لحظه n تولید می کند. $\beta(n)$ عنصری از $\{\{0,1\}\}$ بوده و پاسخ فیدبک محیط، به اتوماتان می باشد. محیط اتوماتان را با احتمال $\alpha(n)$ جریمه کرده $(\beta(n)=1)$ که این احتمال وابسته به اقدام می باشد. بر اساس پاسخ $\beta(n)$ ، حالت اتوماتان $\Phi^{(n)}$ تغییر یافته و اقدام جدیدی در لحظه $n+1$ انتخاب می شود. نحوه اتصال اتوماتان و محیط در شکل (۴) نشان داده شده است.



شکل (۴) نحوه اتصال محیط با اتوماتان.

۱-۳- اتوماتان ستلین ($L_{2N,2}$)

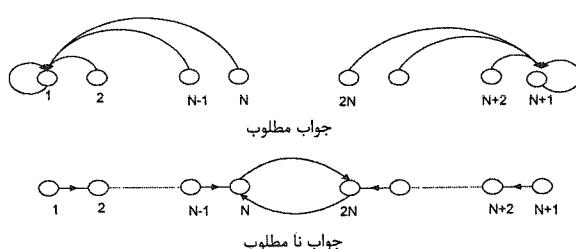
این اتوماتان دارای N ۲ حالت و دو اقدام بوده و رفتار گذشته سیستم را در قانون تصمیم‌گیری برای انتخاب رشتۀ اقدام $L_{2N,2}$ میدهد. اتوماتان $L_{2N,2}$ وقتی که در داخلی ترین حالت قرار گرفته باشد برای انتقال به اقدام دیگر نیاز به N پاسخ نا مطلوب متواتی دارد. N عمق حافظه اقدام نامیده شده و می‌گوییم اتوماتان دارای تعداد N ۲ حافظه می‌باشد. برای هر پاسخ مطلوب، حالت اتوماتان به سمت حالت‌های داخلی‌تر حرکت می‌کند و به ازای پاسخ نامطلوب به سمت حالت‌های بیرونی‌تر می‌میکند. گراف انتقال حالت اتوماتان $L_{2N,2}$ در شکل (۵) نشان داده شده است.



شکل (۵) گراف انتقال حالت برای $L_{2N,2}$.

۲-۳- اتوماتان کرینسکی

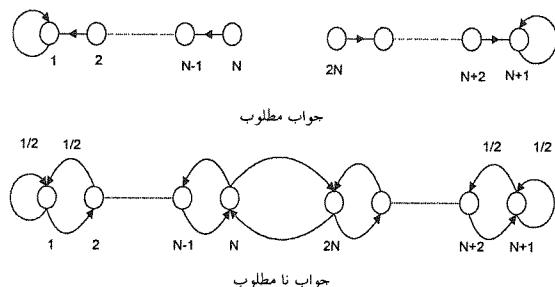
این اتوماتان موقعیکه پاسخ محیط نامطلوب باشد. دقیقاً مثل $L_{2N,2}$ رفتار می‌کند. اما برای پاسخ مطلوب، هر حالت Φ_i (برای $i=1,\dots,N$) به حالت Φ_{N+i} می‌رود و هر حالت Φ_{N+i} (برای $i=N+1,\dots,2N$) به حالت Φ_{N+i+1} می‌رود. لذا پس از هر پاسخ مطلوب تعداد N پاسخ نامطلوب لازم است تا اتوماتان از یک اقدام به اقدام دیگر سوچیج کند. گراف انتقال حالت اتوماتان کرینسکی در شکل (۶) نشان داده شده است.



شکل (۶) گراف انتقال حالت برای اتوماتان کرینسکی.

۳-۳- اتوماتان کرایلف

این اتوماتان موقعیکه خروجی محیط مطلوب باشد انتقال حالت مشابه $L_{2N,2}$ دارد. ولی موقعیکه پاسخ محیط نامطلوب باشد حالت Φ_i با احتمال $1/N$ به حالت Φ_{i+1} و با احتمال $1/N$ به حالت Φ_{i-1} می‌رود. موقعیکه Φ_i با احتمال $1/N$ در همان حالت باقی می‌ماند. و با همان احتمال به حالت Φ_{i+1} می‌رود. موقعیکه Φ_i باشد اتوماتان با احتمال $1/N$ به حالت $N-1$ می‌رود و با همان احتمال به حالت $N-2$ می‌رود و بالاخره موقعیکه $\Phi_{i=2N}$ باشد اتوماتان با احتمال $1/N$ به حالت N و با همان احتمال به حالت $N-1$ می‌رود. گراف انتقال حالت این اتوماتان در شکل (۷) نشان داده شده است.



شکل (۷) گراف انتقال حالت برای اتوماتان کرایلف.

۴-۳- اتوماتان با ساختار متغیر

اتوماتان با ساختار متغیر، احتمالهای انتقال یا اقدام را بر اساس ورودی تغییر می‌دهد. این نوع اتوماتان توسط شش، تایی $\beta, \Phi, \alpha, P, G, T$ نمایش داده می‌شود. که در آن β مجموعه ورودیها، Φ مجموعه حالت‌های داخلی، α مجموعه خروجیها و P بردار احتمال اقدامهای است. که بر اساس آن در هر مرحله اقدامی انتخاب می‌شود. G نگاشت خروجی و T الگوریتم یادگیری را نشان می‌دهد. الگوریتم یادگیری یک رابطه برگشتی بوده و برای تغییر دادن بردار احتمال مورد استفاده قرار می‌گیرد. الگوریتم‌های یادگیری مختلفی در مرجع [۳۵] گزارش شده است. الگوریتم یادگیری پاداش - جریمه خطی α (جزء اولین روشها می‌باشد. فرض کنیم در لحظه k ، اقدام α از مجموعه اقدامها با توجه به توزیع (k) انتخاب شود. در الگوریتم L_{R-P} معادله برگشتی برای تغییر p به صورت زیر تعریف می‌شود.

$$\begin{aligned} \beta(n)=0 & \quad p_i(n+1) = p_i(n) + a[1 - p_i(n)] \\ & \quad p_j(n+1) = (1 - a)p_j(n) \quad j \neq i \end{aligned} \quad (5)$$

$$\begin{aligned} \beta(n)=1 & \quad p_i(n+1) = (1 - b)p_i(n) \\ & \quad p_j(n+1) = b/(r-1) + (1 - b)p_j(n) \quad j \neq i \end{aligned} \quad (6)$$

پارامترهای a و b طول گام را نشان داده، مقدار افزایش و کاهش احتمال اقدامها را تعیین می‌کنند. الگوریتم یادگیری دیگری که اکثرًا مورد استفاده قرار می‌گیرد الگوریتم پاداش - بیحرکت خطی L_{R-P} می‌باشد. در L_{R-P} به ازای پاسخ مطلوب $\beta(n)=0$ احتمال متناظر با اقدام α افزایش یافته و بقیه احتمالها کاهش می‌یابند. ولی به ازای پاسخ نامطلوب $\beta(n)=1$ هیچگونه تغییری در احتمالها صورت نمی‌گیرد. معادله برگشتی برای تغییر P به صورت زیر می‌باشد.

$$\begin{aligned} \beta(n)=0 & \quad p_i(n+1) = p_i(n) + a[1 - p_i(n)] \\ & \quad p_j(n+1) = (1 - a)p_j(n) \quad j \neq i \end{aligned} \quad (7)$$

$$\beta(n)=1 \quad p_j(n+1) = p_j(n) \quad 1 \leq j \leq r \quad (8)$$

در روابط فوق تعداد اقدامها را نشان میدهد.

۵-۳-اتوماتان مهاجرت اشیاء

اتوماتان مهاجرت اشیاء [۴۰] توسط پنج تایی $\langle \alpha, \Phi, \beta, F, G \rangle$ نشان داده میشود. که $\{\alpha_1, \alpha_2, \dots, \alpha_n\} = \alpha$ مجموعه اقداماتی مجاز، $\{\Phi_1, \Phi_2, \dots, \Phi_m\} = \Phi$ مجموعه وضعیتها، $\{\beta^{0,1}\} = \beta$ مجموعه ورودیها، $F: \Phi \times \beta \rightarrow \Phi$ تابع نگاشت وضعیتها و $G: \Phi \rightarrow \alpha$ تابع نگاشت خروجی اتماتان میباشد. این نوع اتماتان برای دسته‌بندی اشیاء، و تعیین تعداد واحدهای مخفی شبکه‌های عصبی [۴۱]، [۴۲] مورد استفاده قرار گرفته است. در این اتماتان هر اقدام یک دسته از الگوها را نشان میدهد. در اتماتان مهاجرت اشیاء، اشیاء به وضعیت‌های اتماتان انتساب داده میشوند و پاسخ محیط به اتماتان سبب گردش اشیاء در بین وضعیت‌های اتماتان میگردد. از طریق این گردش طبقه‌بندی اشیاء صورت میگیرد. اگر شی W در اقدام شماره Z اتماتان مهاجرت اشیاء قرار داشته باشد. این شی متعلق به دسته شماره Z است. برای اقدام α_i مجموعه وضعیت $\{W_{(k-1)N+1}, \dots, W_{(k-1)N+i}\}$ در نظر گرفته میشود. که N عمق حافظه را نشان میدهد. $\Phi_{(k-1)N+1}$ داخلی ترین وضعیت و Φ_{kN} خارجی ترین وضعیت این اقدام میباشد. اگردو شی W و W' بترتیب در وضعیت‌های $\Phi_{(k-1)N+m}$ و $\Phi_{(k-1)N+1}$ (برای $m > 1$) قرار داشته باشند در اینصورت احتمال تعلق شی W به این دسته از احتمال تعلق شی W' بیشتر است.

الگوریتم تعیین تعداد وزن^۱ WSA

در این قسمت ابتدا بطور مختصر الگوریتم کاهش تعداد وزن ارائه شده در مرجع [۴۳] را شرح داده در ادامه، الگوریتم‌های جدیدی را ارائه میکنیم. در این الگوریتم از یک اتماتان مهاجرت اشیاء استفاده شده است. این اتماتان برای تعیین تعداد وزنهای لایه مخفی بوده و دارای دو اقدام و عمق حافظه N میباشد. روی وضعیت‌های آن مجموعه وزن $\{w_1, w_2, w_3, \dots, w_N\} = W$ قرار دارد. گراف تغییر حالت برای این اتماتان در شکل ۸ نشان داده شده است. این الگوریتم نحوه اتصال وزنهای بین لایه ورودی و لایه مخفی را مشخص میکند. در ابتدا همه وزنهای موجود در شبکه در وضعیت Φ قرار میگیرند. به همه وزنهای روشن مدتی اجازه داده میشود تا در آموزش شبکه شرکت نمایند. وزنهایی که عملکرد آنها در این مدت مناسب نیست جریمه میشوند، وزنهایی که عملکرد آنها خوب است پاداش میگیرند و وزنهایی که در مورد آنها نمیتوان تصمیم‌گیری قطعی نمود بدون تنظیم وضعیت باقی میمانند. برای تشخیص خوب یا بد بودن عملکرد یک وزن از قوانین زیر استفاده میشود.

عملکرد خوب یک وزن: وزنی دارای عملکرد خوب میباشد که سیگنال وارد شده به این وزن بمیزان زیادی تضعیف نگردد و یا به عبارتی دیگر قدر مطلق آن کوچک نباشد.

عملکرد بد یک وزن: وزنی دارای عملکرد بد میباشد اگر سیگنال وارد شده به این وزن بمیزان زیادی تضعیف گردد و یا به عبارتی دیگر قدر مطلق آن کوچک باشد.

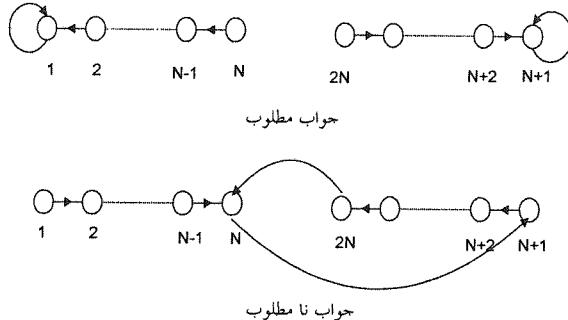
تشخیص نحوه عملکرد یک وزن روش: الگوریتم پس انتشار خطرا به دفعات معینی تکرار میکنیم در انتهای اگر قدر مطلق وزنی از یک مقدار آستانه‌ای بیشتر باشد آن وزن مناسب بوده پاداش میگیرد و اگر از یک مقدار آستانه‌ای دیگر کوچک باشد نا مناسب بوده جریمه میشود. و در صورتیکه بین دو مقدار آستانه‌ای قرار گیرد تغییری در وضعیت آن ایجاد نمیشود (شکل ۹). برای تعیین مقادیر آستانه‌ای از واریانس قدر مطلق مقدار وزنهای استفاده شده است. برای وزنهای مربوط به هر کدام از نرونها، واریانس بصورت زیر محاسبه میگردد.

$$\sigma_h = \sqrt{\frac{\sum_{W_{hk} \in ON_w(h)} (|W_{hk}| - \mu_w(h))^2}{|ON_w(h)|}} \quad h \in ON \quad (9)$$

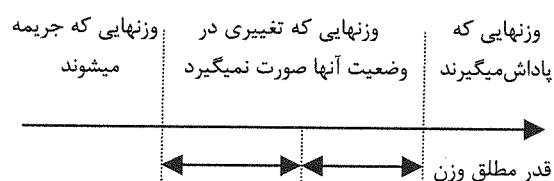
که در آن ON مجموعه واحدهای روش، w مجموعه وزنهای ورودی روش متصل به واحد مخفی h و $\mu_w(h)$ میانگین قدر مطلق مقدار وزنهای روش متصل به واحد مخفی h میباشد. w پنهانی روشی نامیده شده و بصورت زیر محاسبه میگردد.

$$X_{ON}(h) = \lambda_{ON} \frac{OFF_w(h)}{\# INPUT + 1} \sigma_h \quad (10)$$

ثابت $\lambda_{ON} > OFF_w(h)$ ضریب پهنانی روشی، $\# INPUT$ تعداد واحدهای لایه ورودی و $OFF_w(h)$ مجموعه وزنهای خاموش متصل به واحد مخفی روشن h است.



شکل (۸) اتوماتان مربوط به الگوریتم WSA.



$$X_{ON}(h) + \mu_{ON}(h) - \mu_{ON}(h) - X_{ON}(h) - \mu_{ON}(h)$$

شکل (۹) مقدار آستانه مربوط به وزنهای روش.

تشخیص نحوه عملکرد یک وزن خاموش: یک وزن خاموش در آموزش شرکت نمیکند. بنابر این مقدار آنرا از آخرین زمان روشن بودن آن محاسبه میکنیم. اگر یک وزن برای مدت طولانی خاموش باشد از اهمیت و در نتیجه از مقدار آن کاسته میشود. بنابر این مقدار یک وزن خاموش بصورت زیر محاسبه میشود.

$$W_{hk}(n+1) = W_{hk}(n) \lambda_d \quad (11)$$

که ثابت $\lambda_d < 1$. ضریب کاهش مقدار وزن نامیده میشود. به این ترتیب مقدار یک وزن خاموش بتدریج کم میشود. واریانس وزنهای خاموش بصورت زیر محاسبه میشود.

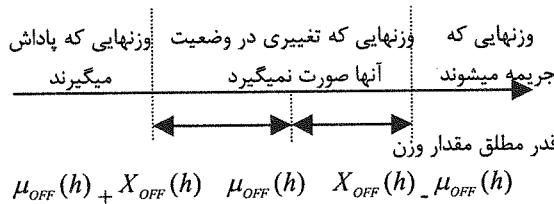
$$\sigma_h = \sqrt{\frac{\sum_{w_{hk} \in OFF_w(h)} (W_{hk} - \mu_{OFF_w}(h))^2}{|OFF_w(h)|}} \quad h \in ON \quad (12)$$

که در آن ON مجموعه واحدهای روشن و $\mu_{OFF_w}(h)$ میانگین قدر مطلق مقدار وزنهای خاموش متصل به واحد مخفی روشن h میباشد. با استفاده از واریانس و طبق فرمول زیر $X_{OFF_w}(h)$ که پهنانی خاموشی نامیده میشود بصورت زیر محاسبه میگردد.

$$X_{OFF_w}(h) = \lambda_{OFF_w} \frac{|ON_w(h)|}{\# INPUT + 1} \sigma_h \quad (13)$$

که ثابت $\lambda_{OFF_w} < 1$. ضریب پهنانی خاموشی و $\# INPUT$ تعداد واحدهای لایه ورودی است. وزنهایی که قدر مطلق مقدار آنها از σ_h کمتر باشد پاداش میگیرند. وزنهایی که قدر مطلق آنها از σ_h بیشتر باشند جریمه

میشوند و وزنهایی که قدر مطلق آنها در فاصله $\mu_{OFF}(h) - X_{OFF}(h)$ تا $\mu_{OFF}(h) + X_{OFF}(h)$ قرار دارند، وضعیت آنها تغییر نمیکند(شکل ۱۰).



شکل (۱۰) مقدار آستانه مربوط به وزنهای خاموش.

این الگوریتم را برای راحتی در مراجعات بعدی بطور اختصار با عبارت WSA نشان میدهیم.

ارائه الگوریتم بقا وزن تطبیقی AWSA

مقدار $X_{ON}(h)$ که بازه تصمیم گیری را نشان میدهد تأثیر بسزائی در عملکرد الگوریتم کاهش تعداد وزن دارد. وزنهای روشنی که قدر مطلق آنها کمتر از $\mu_{ON}(h) - X_{ON}(h)$ میباشد جریمه شده و وزنهای روشنی که قدر مطلق آنها بیشتر از $\mu_{ON}(h) + X_{ON}(h)$ میباشد پاداش میگیرند. هر قدر مقدار بازه $X_{ON}(h)$ کم باشد وزنهای بیشتری جریمه شده در نتیجه وزنهای با سرعت بیشتری ریزش خواهند کرد. اگر این سرعت از یک حدی بیشتر باشد شبکه دیگر قادر به یادگیری الگوهای آموزشی نخواهد بود. اگر مقدار $X_{ON}(h)$ خیلی زیاد انتخاب شود شرط جریمه کردن وزنهای روشن خیلی سنگین شده، در نتیجه وزنی خاموش نشده یا تعداد بسیار کمی وزن خاموش خواهد شد. در نتیجه شاهد هیچگونه کاهشی در پیچیدگی شبکه نخواهیم بود. پس ملاحظه میکنیم مقدار $X_{ON}(h)$ خیلی مهم بوده و با انتخاب یک مقدار بهینه برای $X_{ON}(h)$ میتوانیم در کمترین زمان به شبکههایی با حداقل تعداد وزن که بتواند با خطای قابل قبولی نیز الگوهای آموزش را یاد بگیرد برسیم. بحثهایی که در مورد بازه $X_{ON}(h)$ مطرح کردیم در مورد بازه $X_{OFF}(h)$ نیز قابل طرح میباشد. $X_{OFF}(h)$ هم که بازه تصمیم گیری برای وزنهای خاموش را نشان میدهد در عملکرد الگوریتم کاهش تعداد وزن بسیار موثر میباشد. وزنهای خاموشی که قدر مطلق آنها کمتر از $\mu_{OFF}(h) - X_{OFF}(h)$ میباشد پاداش میگیرند و وزنهای خاموشی که قدر مطلق آنها بیشتر از $\mu_{OFF}(h) + X_{OFF}(h)$ میباشد جریمه میشوند. هر قدر مقدار بازه $X_{OFF}(h)$ کم باشد وزنهای خاموش بیشتری در نتیجه وزنهای خاموش با سرعت بیشتری شروع به روشن شدن میکنند و اگر مقدار $X_{ON}(h)$ خیلی زیاد انتخاب شود شرط جریمه کردن وزنهای خاموش خیلی سنگین شده، در نتیجه وزنی روشن نشده یا تعداد بسیار کمی وزن روشن میباشد. در نتیجه آنچهای که نیاز داریم وزنهایی به شبکه برگردانده شوند وزنی روشن نمیشود. پس ملاحظه میکنیم مقدار $X_{OFF}(h)$ نیز خیلی مهم بوده و با انتخاب یک مقدار بهینه برای $X_{OFF}(h)$ میتوانیم در کمترین زمان به شبکههایی با حداقل تعداد وزن که بتواند با خطای قابل قبولی نیز الگوهای آموزش را یاد بگیرد برسیم. همچنانکه در مبحث مربوط به الگوریتم WSA دیدیم پارامتر $X_{ON}(h)$ براساس فرمول زیرتابع چندین متغیر میباشد.

$$X_{ON}(h) = \lambda_{ON} \frac{OFF_W(h)}{\lceil \# INPUT \rceil + 1} \sigma_{ON}(h) \quad (14)$$

#INPUT بعد فضای ورودی بوده و برای یک مسئله خاص مقدار ثابتی میباشد. $OFF_W(h)$ تعداد وزنهای خاموش را نشان داده و بعنوان یک عامل بازدارنده در مقابل ریزش بیش از حد وزنهای عمل میکند. با حذف تدریجی وزنهای مقدار $OFF_W(h)$ افزایش یافته و باعث افزایش $X_{ON}(h)$ میگردد. با افزایش $X_{ON}(h)$ از سرعت ریزش وزنهای کاسته میشود. λ_{ON} مقدار ثابتی بوده و ضریب پهنهای روشنی نامیده میشود. ... واریانس وزنهای روشن مربوط به نرون مخفی h میباشد. پارامتر $X_{OFF}(h)$ نیز براساس فرمول زیرتابع چندین متغیر میباشد.

$$X_{OFF}(h) = \lambda_{OFF} \frac{ON_W(h)}{\#INPUT + 1} \sigma_{OFF}(h) \quad (14)$$

#INPUT بعد فضای ورودی بوده و برای یک مسئله خاص مقدار ثابتی می‌باشد. $(^{(h)}ON_{\text{off}})$ تعداد وزنهای روشن را نشان داده و عنوان یک عامل بازدارنده در مقابل برگشت بیش از حد وزنها عمل می‌کند. λ_{off} مقدار ثابتی بوده و ضریب پهنانی خاموش، نامدیده می‌شود. $\sigma_{\text{off}}^{(h)}$ واریانس، وزنهای خاموش مربوط به نزون مخفی h می‌باشد.

پس ملاحظه میکنیم بر اساس فرمولهای ۱۴ و ۱۵ بازه های تصمیم گیری X_{ON} و X_{OFF} به ترتیب متناسب با ضرائب λ_{ON} و λ_{OFF} بوده و مقادیر این ضرائب میتواند در فرایند تعیین تعداد وزنها پسیار تعیین کننده باشد.

برای بررسی تجربی نقش ضرائب λ_{ON} و λ_{OFF} بر روی عملکرد الگوریتم WSA آزمایشی را بصورت زیر ترتیب میدهیم. برای انجام آزمایش مسئله شناسائی اعداد لاتین را در نظر میگیریم. تأثیر λ_{ON} و λ_{OFF} را بطور مجزا مورد بررسی قرار میدهیم. ابتدا مقدار λ_{OFF} را ثابت در نظر گرفته مقدار λ_{ON} را تغییر میدهیم.

مقدار λ_{OFF} را ۱۰ در نظر گرفته و به ازای مقادیر مختلف λ_{ON} آزمایش را تکرار میکنیم. در این آزمایش ضریب کاهش وزن ۹/۰ و نرخ یادگیری ۱/۰٪ انتخاب شده است. همچنین در هر گام الگوریتم پس انتشار خطا ۵۰ بار تکرار شده است. از تابع غیر خطی سیگموئید بعنوان توابع لایه مخفی و لایه خروجی استفاده شده است. نتایج آزمایش‌های مختلف در جدول ۱ نشان داده شده است.

جدول (۱) پرسی تأثیر مقادیر مختلف λ_{ON} بر روی سرعت شاخه زنی و همچنین همگرایی شبکه به ازای $\lambda_{OFF} = 10$

Epoch \ λ_{ON}	-	\vdots	ظای اموزش											
۱۰	۳۸۴.	۳۸۱.	۳۱۰.	۲۷۰۳	۲۰۰۱	۱۴۰۳	۱۰۳۰	۷۰۳	۵۵۳	۴۰۴	۴۹۹	۰۰۱		
۵	۳۸۴.	۳۲۰۳	۲۸۴.	۲۲۴۵	۱۹۹.	۱۲۹.	۸۰۳	۵۰۳	۴۳۰	۳۰۴	۲۵۰	۰۰۱		
۲	۳۸۴.	۳۱۰.	۲۵۰۳	۲۱۰۳	۱۸۳۹	۱۰۲۳	۴۷۶	۳۷۵	۲۷۴	۱۲۰	۹۵	۲۰۰		
۰/۱	۳۸۴.	۳۰۳.	۲۳۰۴	۲۰۰۴	۱۷۹۷	۹۹۵	۳۹۵	۲۵۸	۱۵۰	۹۴	۸۵	۲/۱۵		

جدول (۲) بررسی تأثیر مقادیر مختلف λ_{OFF} بر روی سرعت شاخه زنی و همچنین همگرایی شبکه به آزای $\lambda_{ON} = 10$

همچنانکه در این جدول نشان داده شده است با کاهش λ_{ON} ، پهنای بازه روشی کاهش یافته در نتیجه وزنهای زیادی جریمه شده و نهایتاً عمل شاخه زنی با سرعت بیشتری انجام میگیرد. اگر فرایند حذف وزنهای با نرخ بسیار بالایی صورت گرفته و وزنهای بیشتری از شبکه حذف شود، در اینحالت شبکه عصبی پیش از حد کوچک شده و قادر به یادگیری الگوهای آموزش

نخواهد بود. همچنانکه در جدول ۱ نشان داده است به ازای $2 = \lambda_{ON}$ و $11 = \lambda_{OFF}$ همین حالت اتفاق می‌افتد.

در مرحله بعد با هدف بررسی تأثیر λ_{OFF} بر روی فرایند حذف وزن و همچنین همگرایی شبکه، آزمایشی را بصورت زیر ترتیب میدهیم. در این آزمایش نیز مسئله شناسایی اعداد لاتین را در نظر میگیریم. برای مطالعه تأثیرات λ_{ON} ، λ_{OFF} را ثابت و مساوی ۱۰ انتخاب میکنیم. بقیه شرایط آزمایش مشابه آزمایش قبل میباشد. جدول ۲ نتایج آزمایشها را نشان میدهد. با دقت در جدول ۲ مشاهده میکنیم که با کاهش λ_{OFF} ، شرط جریمه شدن وزنهای خاموش سبکتر شده در نتیجه وزنهای بیشتری روشن شده و نهایتاً درصد حذف وزنهای کاهش مطلوبی در پیچیدگی شبکه نخواهیم داشت. پس ملاحظه کردیم سرعت عمل شاخه زنی وابسته به پارامتر λ_{ON} و سرعت عمل برگشت وزن تابعی از پارامتر λ_{OFF} می‌باشد و با تطبیق آنها میتوان سرعت شاخه زنی و سرعت روشن شدن وزنهای خاموش را کنترل کرد. برای دستیابی به شبکه‌هایی با کمترین پیچیدگی و در کمترین زمان، نیاز به الگوریتم‌هایی داریم که بتواند بطور پویا سرعت عمل شاخه زنی و برگشت وزن را بر اساس معیاری تغییردهد. در این مقاله با استفاده از اتماتانهای یادگیر ضرائب λ_{ON} و λ_{OFF} را تطبیق داده‌ایم. الگوریتم پیشنهادی بصورت زیر عمل میکند. در ابتدا تمامی وزنهای موجود در شبکه در وضعیت Φ قرار میگیرند. به همه وزنهای روشن مدتی اجازه داده میشود تا در آموزش شبکه شرکت نمایند. وزنهایی که عملکرد آنها در این مدت مناسب نیست جریمه میشوند، وزنهایی که عملکرد آنها خوب است پاداش میگیرند و وزنهایی که در مورد آنها نمیتوان تصمیم‌گیری قطعی نمود بدون تغییر وضعیت باقی میمانند.

عمل شاخه زنی در ابتدا با یک سرعت مشخصی شروع میشود اگر سرعت شاخه زنی مناسب بوده و منجر به افزایش خطای یادگیری نگردد اتماتان مربوط به تنظیم مقادیر λ_{OFF} و λ_{ON} پاداش میبینند در صورتیکه سرعت شاخه زنی بیش از حد زیاد بوده و منجر به واگرایی الگوریتم پس انتشار خطا گردد در این صورت اتماتان مربوط به تنظیم ضرائب λ_{OFF} و λ_{ON} جریمه میشود. برای پاسخ دادن به اتماتان مربوط به تنظیم ضرائب λ_{OFF} و λ_{ON} از معیار خطا کمک میگیریم. مینیمم مقدار خطا در تکرار فعلی را با مینیمم مقدار خطا در تکرار قبلی مقایسه میکنیم اگر با یک ضریبی خطا افزایش پیدا کرده بود اتماتان را جریمه میکنیم در غیر اینصورت به آن پاداش میدهیم. برای تطبیق هر کدام از پارامترهای λ_{OFF} و λ_{ON} از اتماتانهای مختلف ستلین، کرینسکی، کرایلف، L_{R_P} و L_{R_I} استفاده کرده ایم. الگوریتم جدید را که تحت عنوان الگوریتم بقا وزن تطبیقی (AWSA) نامگذاری میکنیم در شکل ۱۱ نشان داده شده است.

ارائه الگوریتم بقا وزن بمبود یافته MWSA

همچنانکه قبلأ در مورد الگوریتم تعیین وزن توضیح دادیم. این الگوریتم در ابتدا با ارزیابی عملکرد وزنهای با اهمیت کم را خاموش میکند. با پیشرفت روند آموزش و با خاموش کردن وزنهای غیرهمم به تدریج از تعداد وزنهای روشن کاسته شده در نتیجه با توجه به فرمول ۱۳ مقدار X_{OFF} کم میشود. با کاهش مقدار X_{OFF} ، وزنهای خاموش بیشتری جریمه و در نتیجه روشن میشوند. ملاحظه میکنیم که خاموش شدن وزنهای روشن خود عاملی برای روشن شدن وزنهای خاموش شده در نتیجه در نهایت به یک نقطه تعادل میرسیم. همین وضعیت را بهنگام روشن شدن وزنهای خاموش نیز شاهد هستیم. موقعیکه تعدادی وزن روشن میشود از تعداد وزنهای خاموش کاسته شده در نتیجه با توجه به فرمول ۱۰ مقدار X_{ON} کم میشود. با کم شدن مقدار X_{ON} شرط جریمه شدن وزنهای روشن سهلتر شده در نتیجه وزنهای روش بیشتری خاموش میشود. در این حالت نیز شاهد یک فیدبک منفی هستیم. بدین معنا که روش شدن وزنهای خاموش خود عاملی میشود برای خاموش کردن وزنهای روشن. بخاطر وجود همین فیدبک منفی در طی فرایند آموزش، ساختار شبکه به تدریج به یک نقطه تعادل میل میکند. نقطه تعادل و در حقیقت تعداد نهایی وزنهای شبکه طبق فرمولهای ۱۰ و ۱۳ وابسته به مقادیر λ_{ON} و λ_{OFF} میباشد. در بخش ۶ ضمن تحلیل تأثیر مقادیر X_{OFF} و X_{ON} بر روی الگوریتم تعیین تعداد وزن، روشی را برای تنظیم λ_{ON} و λ_{OFF} ارائه کردیم.

```

Input:
Training Patterns (p,t), p is input and t is desired output
No. of Hidden Units H
Output:
Network Weight Vector:W
Network Topology
Initialize Weights and biases
Initialize Automata Parameters
Initialize Learning Parameters
for i=1:100
for i=1:K
Call BP
end
MinimumOfError_new=minimum(Error Vector);
Select an Action from on_width_coefficient set
Select an Action from off_width_coefficient set
for all Hidden Neurons
for all weights
if weight is OFF
    W = W*WEIGHT_DEC_COEFF. ;
end
end
Compute Xon
Compute Xoff
for all weights
if weight is OFF
if abs(W) < Average_off- Xoff
    Reward OFFWeight
elseif abs(W) > Average_off + Xoff
    Penalize OFFWeight
end
if weight is ON.
if abs(W) < Average_on - Xon
    Penalize ON Weights
elseif abs(W) > Average_on + Xon
    Reward ON Weights
end
end
end
end
if MinOfErr_new / MinOfErr > MAX_ERR_RATIO
EnvironmentResponce=1;
else
EnvironmentResponce=0;
end
Update_Tsetlin_State_λON (EnvironmentResponce)
Update_Tsetlin_State_λOFF (EnvironmentResponce)
end

```

شکل (11) الگوریتم AWSA

در این بخش قصد داریم روش دیگری را برای بهبود عملکرد الگوریتم تعیین تعداد وزن ارائه دهیم. همچنانکه قبلًا توضیح دادیم الگوریتم تعیین تعداد وزن طوری عمل میکند در نهایت به یک نقطه تعادل برسیم. تعداد نهائی وزنهای شبکه یا بعارت دیگر نقطه تعادل را مقادیر $λ_{ON}$ و $λ_{OFF}$ تعیین میکنند. اگر این پارامترها بطور مناسب انتخاب شده باشند در اینصورت در انتهاهای آموزش ضمن اینکه به خطای قابل قبولی می رسیم، می توانیم در حد مطلوب باحذف وزنهای غیر ضروری، پیچیدگی شبکه را کاهش دهیم. ولی اگر مقادیر این پارامترها بطور مناسبی انتخاب نشوند دو حالت ممکن است اتفاق بیفتند در حالت اول ممکن است تعداد وزنهای حذف شده بقدرتی زیاد باشد که در نتیجه شبکه عصبی حاصل بیش از اندازه ساده شده و توانایی یادگیری الگوهای آموزش را نداشته باشد و در حالت دوم ممکن است تعداد بسیار کمی وزن حذف شده در نتیجه به هدف اصلی

که همان کاهش پیچیدگی شبکه عصبی میباشد دست پیدا نکنیم. طی یک آزمایش حالت‌های فوق را برای مسئله شناسائی اعداد لاتین نشان میدهیم. در این آزمایش ضریب کاهش وزن را $0/9$ ، تعداد تکرار الگوریتم پس انتشار خطا در هر گام را 50 ، نرخ یادگیری را $0/1$ و ضریب منتم را $0/98$ در نظر می‌گیریم. از تابع غیر خطی سیگموئید که بین -1 و $+1$ تغییر میکند بعنوان تابع لایه مخفی و لایه خروجی استفاده می‌کنیم. نتایج آزمایش در جدول ۳ آورده شده است. همچنانکه در جدول ۳ نشان داده شده است در سطر اول مقادیر مناسبی برای پارامترهای λ_{ON} و λ_{OFF} انتخاب شده در نتیجه ضمن اینکه شبکه همگرا شده است با درصد خوبی نیز شاهد کاهش پیچیدگی شبکه هستیم ولی در سطر دوم و سوم مقادیر انتخاب شده برای λ_{ON} و λ_{OFF} مناسب نبوده در نتیجه نقاط تعادل حاصل نقاط مناسبی نمیباشد. در سطر دوم درصد شاخه زنی بالا بوده در نتیجه شبکه حاصل نتوانسته الگوهای آموزش را یاد بگیرد و در سطر سوم با اینکه شبکه همگرا شده است ولی درصد شاخه زنی پائین بوده و در حد مطلوبی شبکه ساده نشده است.

جدول (۳) تعداد وزنها بعد از هرس و خطای آموزش به ازای مقادیر مختلف λ_{ON} و λ_{OFF} .

λ_{ON}	λ_{OFF}	تعداد وزنها قبل از هرس	تعداد وزنها بعد از هرس	خطای آموزش
۱۰	۱۰	۲۸۴۰	۴۹۹	۰/۰۱
۲	۱۰	۲۸۴۰	۹۵	۲/۰۵
۱۰	۰/۱	۲۸۴۰	۹۰۰	۰/۰۱

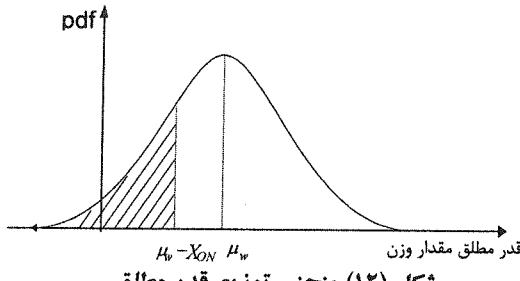
برای حل مشکل فوق روش زیر ارائه می‌گردد. در الگوریتم WSA همچنانکه قبلاً توضیح دادیم خاموش شدن وزنها روش خود بصورت یک فیدبک منفی عمل کرده و شدت خاموش شدن وزنها را کاهش میدهد. در الگوریتم جدید که آنرا MWSA نامگذاری میکنیم. فرمول مربوط به بازه روشی X_{ON} را طوری تغییر میدهیم. بطوریکه کاهش وزنها روش، بعبارت دیگر افزایش وزنها خاموش تاثیری بر روند حذف وزنها نداشته باشد. برای این منظور فرمول جدیدی بصورت زیر ارائه میشود.

$$X_{ON} = \lambda_{ON} \times \sigma_h \quad (16)$$

که در آن λ_{ON} ضریب پهناوارشی و σ_h واریانس وزنها روش میباشد که بصورت زیر محاسبه میشود.

$$\sigma_h = \sqrt{\frac{\sum_{W_{hk} \in ON_w(h)} ((W_{hk}) - \mu_w(h))^2}{|ON_w(h)|}} \quad h \in ON \quad (17)$$

که در آن W_{hk} وزن اتصال بین واحد ورودی K به واحد مخفی h ، $ON_w(h)$ مجموعه واحدهای روش، $\mu_w(h)$ مجموعه وزنها ورودی روش متصل به واحد مخفی h و (W_{hk}) میانگین قدر مطلق وزنها روش متصل به واحد مخفی h میباشد. هر قدر واریانس وزنها ورودی یک نرون زیاد باشد. مفهوم آن این است که تعداد زیادی وزن داریم که مقدار آنها کمتر از مقدار متوسط وزنها میباشد. لذا در این حالت باایستی مقدار X_{ON} نیز زیاد انتخاب شود تا شرط جریمه کردن وزنها روش سنگین شده و وزنها زیادی خاموش نشوند. در مقابل هر قدر واریانس وزنها ورودی یک نرون کم باشد. این به منزله آن است که اکثریت وزنها حول و حوش مقدار متوسط وزنها بوده در نتیجه تعداد کمی وزن داریم که مقدار آنها خیلی کمتر از مقدار متوسط میباشد. در این حالت باایستی مقدار X_{ON} را متناسب با واریانس وزنها کاهش داد تا شرط جریمه کردن وزنها روش سهولت شده و بتوان تعدادی از وزنها را جریمه کرد. با توجه به مطلب مذکور مقدار X_{ON} باایستی متناسب با σ_h انتخاب شود. شکل ۱۲ تابع چگالی احتمال وزنها روش را نشان میدهد. در اینجا فرض کردیم که وزنها روش دارای توزیع نرمال میباشد. توزیع نرمال دارای تابعی بصورت زیر میباشد.



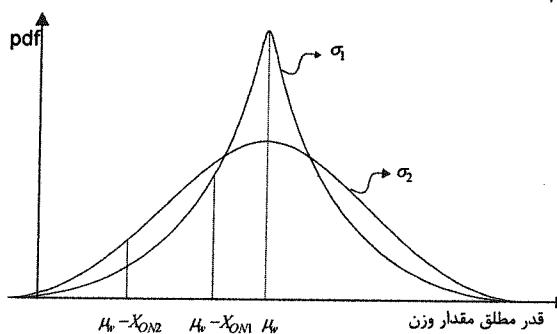
شکل (۱۲) منحنی توزیع قدر مطلق.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\eta)^2/2\sigma^2} = \frac{1}{\sigma} g\left(\frac{x-\eta}{\sigma}\right) \quad (18)$$

احتمال اینکه قدر مطلق وزنی از $X_{ON} - \mu_w$ کمتر باشد با محاسبه انتگرال زیر بدست می‌آید.

$$F(\mu_w - X_{ON}) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\mu_w - X_{ON}} e^{-(\xi-\eta)^2/2\sigma^2} d\xi = G\left(\frac{\mu_w - \eta}{\sigma}\right) \quad (19)$$

که در آن η مقدار متوسط قدر مطلق وزنهای روشن و σ واریانس قدر مطلق وزنهای روشن می‌باشد. انتگرال فوق در حقیقت سطح زیر منحنی توزیع نرمال در بازه $[\mu_w - X_{ON}, -\infty]$ را نشان میدهد. حال هر قدر مقدار واریانس وزنها کمتر باشد در این صورت منحنی تابع چگالی احتمال باریکتر شده و در نتیجه سطح زیر منحنی کاهش پیدا می‌کند. در این حالت نیز برای اینکه بتوان درصد قابل قبولی از وزنها را جرمیمه کرد بایستی متناسب با کاهش واریانس، نقطه $X_{ON} - \mu_w$ را به سمت راست انتقال داده و کاهش سطح زیر منحنی را جبران کنیم. که این کار را می‌توان با کاهش X_{ON} انجام داد. لذا نتیجه می‌گیریم که مقدار X_{ON} بایستی متناسب با σ باشد. در شکل ۱۳ منحنی تابع چگالی احتمال برای دو واریانس مختلف نشان داده شده است. منحنی شماره یک دارای واریانس σ_1 بوده و منحنی شماره دو دارای واریانس σ_2 می‌باشد. $\sigma_2 > \sigma_1$ بوده در نتیجه منحنی شماره یک باریکتر و تیزتر از منحنی شماره دو می‌باشد. با کاهش σ و باریک شدن منحنی تابع چگالی احتمال بایستی مقدار X_{ON} متناسب با آن کاهش یابد تا کاهش سطح منحنی جبران شود. در الگوریتم جدید MWSA برای ارزیابی عملکرد وزنهای خاموش و تصمیم‌گیری در مورد نحوه روشن کردن وزنهای خاموش بصورت زیر عمل می‌کنیم.



شکل (۱۳) منحنی توزیع قدر مطلق وزنهای روشن به ازای دو مقدار متفاوت σ

نحوه ارزیابی عملکرد وزنهای خاموش: برای ارزیابی عملکرد وزنهای خاموش از منحنی خطای آموزش بهره می‌گیریم. اگر نرخ کاهش خطای از یک مقدار آستانه کمتر بوده و همچنین تفاضل مقدار خطای هدف از یک مقدار آستانه دیگر بیشتر باشد. در این حالت شبکه قادر به یادگیری الگوهای آموزش نبوده و گوئیم وزن خاموش دارای عملکرد نامطلوب می‌باشد. اگر وزنی دارای عملکرد نامطلوب باشد در این صورت جرمیمه شده و به سمت حالت‌های بیرونی حرکت می‌کند.

اگر نرخ کاهش خطای از یک مقدار آستانه کمتر بوده و همچنین تفاضل مقدار خطای هدف از یک مقدار آستانه دیگر بیشتر باشد. در این حالت شبکه قادر به یادگیری الگوهای آموزش نبوده و گوئیم وزن خاموش دارای عملکرد نامطلوب میباشد. اگر وزنی دارای عملکرد نامطلوب باشد در این صورت جریمه شده و به سمت حالت‌های بیرونی حرکت میکند. نرخ کاهش خطای را بصورت زیر تعریف می‌کنیم.

$$\text{نرخ} = \frac{\min E(k) - \min E(k-1)}{N} \quad (20)$$

کاهش خطای

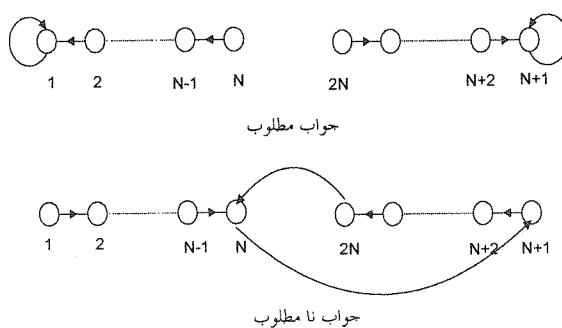
که در آن $\min E(k)$ حداقل مقدار خطای در مرحله k و $\min E(k-1)$ حداقل مقدار خطای در مرحله k-1 می‌باشد. N نیز تعداد تکرار الگوریتم پس انتشار خطای در هر مرحله می‌باشد. پس شرط جریمه کردن وزنهای خاموش را میتوان بصورت زیرنوشت. اگر:

$$\left[\frac{\min E(k) - \min E(k-1)}{N} < \varepsilon \right] \wedge [(\min E(k) - \text{errorgoal}) > \gamma]$$

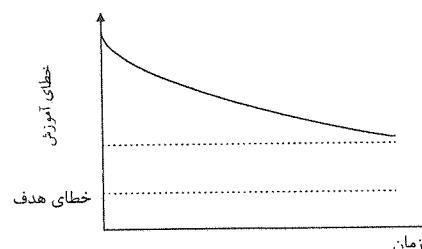
آنگاه: وزنهای خاموش را جریمه کن

اگر نرخ کاهش خطای از یک مقدار آستانه بیشتر باشد. این حالت نشان‌دهنده آنست که شبکه در حال یادگیری الگوهای آموزش بوده و نیازی به روشن کردن وزنهای خاموش نمی‌باشد که در این حالت گوئیم وزن خاموش دارای عملکرد مناسب بوده در نتیجه به آن پاداش داده می‌شود.

با دریافت پاداش حالت وزن خاموش به سمت حالت‌های درونی حرکت می‌کند. اتوماتان مربوط به الگوریتم جدید MWSA در شکل ۱۴ نشان داده شده است. در شکل ۱۵ حالتی را که شبکه قادر به یادگیری الگوهای آموزش نبوده نشان داده شده است. الگوریتم روش جدید MWSA در شکل ۱۶ نشان داده شده است.



شکل (۱۴) اتوماتان مربوط به الگوریتم MWSA.



شکل (۱۵) شبکه عصبی قادر به یادگیری الگوهای

نتایج شبیه سازی

در این قسمت ۴ مسئله نمونه که الگوریتمهای پیشنهادی روی آنها پیاده سازی شده است معرفی می‌گردد. در ادامه نتایج آزمایش‌های مختلف ارائه خواهد شد.

الف - مسئله شناسایی اعداد لاتین: در این مسئله می خواهیم شبکه‌ای را آموزش بدهیم که بتواند اعداد از ۰ تا ۹ را تشخیص دهد. برای این منظور اعداد را مطابق شکل ۱۷ نمایش میدهیم. برای هر عدد یک ماتریس 8×8 در نظر می‌گیریم. خانه‌های سیاه را با ۱ و خانه‌های سفید را با ۰ نشان میدهیم. اعداد ۰ تا ۹ را می‌توان مطابق جدول ۴ با چهار ریت گرد. لذا خروجی شبکه دارای ۴ نرون خواهد بود. از یک شبکه عصبی سه لایه با ۶۴ نرون در لایه ورودی و ۴ نرون در لایه خروجی استفاده کرده‌ایم. برای آزمایش‌های مختلف تعداد نرون‌های لایه مخفی را بین ۱۵ و ۲۳ تغییر میدهیم.

ب - مسئله تقریب تابع غیر خطی زمان گستته درجه دوم: تابع غیر خطی زمان گستته از مرتبه دوم با رابطه زیر مفروض می‌باشد.

$$y_{k+1} = \frac{1.5y_k y_{k-1}}{1+y_k^2+y_{k-1}^2} + 0.35(y_k + y_{k-1}) + 1.2u_k \quad (21)$$

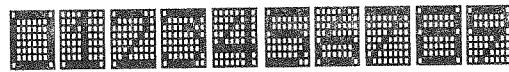
می خواهیم با استفاده از یک شبکه عصبی سه لایه تابع فوق را با تقریب قابل قبولی شبیه‌سازی کنیم. برای این منظور ورودی‌هایی بین ۰ و ۱ بطور تصادفی ایجاد کرده و به تابع اعمال می‌کنیم شرایط اولیه را نیز بطور تصادفی بین ۰ و ۱ انتخاب می‌کنیم بدین ترتیب یک سری الگوی آموزش ایجاد می‌شود که از این الگوها برای آموزش شبکه استفاده می‌کنیم. در رابطه فوق u_k و y_k به ترتیب ورودی و خروجی در لحظه k بوده و y_{k+1} به ترتیب خروجی در لحظات $k-1$ و $k+1$ می‌باشد. برای تقریب تابع از یک شبکه عصبی سه لایه با ۳ نرون در لایه ورودی و ۱ نرون در لایه خروجی استفاده کرده‌ایم. تعداد نرون‌های لایه میانی را برای آزمایش‌های مختلف بین ۸ و ۲۵ تغییر میدهیم.

```

Input:
Training Patterns (p,t), p is input and t is desired output
No. of Hidden Units H
Output:
Network Weight Vector:W
Network Topology
Initialize Weights and biases
Initialize Automata Parameters
Initialize Learning Parameters
for i=1:100
    for i=1:K
        Call BP
    end
    for all Hidden Neurons
        Compute Xon
        for all weights
            if weight is OFF
                if  $\left[ \frac{\min E(k) - \min E(k-1)}{N} < \varepsilon \right] \wedge [(\min E(k) - errorgoal) > \gamma]$ 
                    Reward OFFWeight
                else
                    Penalize OFFWeight
                end
            if weight is ON.
                if abs(W) < Average_on - Xon
                    Penalize ON Weights
                elseif abs(W) > Average_on + Xon
                    Reward ON Weights
                end
            end
        end
    end
end

```

شکل (۱۶) الگوریتم MWSA



شکل (۱۷) نحوه نمایش اعداد از ۰ الی ۹.

جدول (۴) نحوه کد کردن اعداد از ۰ الی ۹.

عدد	بیت ۳	بیت ۲	بیت ۱	بیت ۰
۰	-1	-1	-1	-1
۱	-1	-1	-1	1
۲	-1	-1	1	-1
۳	-1	-1	1	1
۴	-1	1	-1	-1
۵	-1	1	-1	1
۶	-1	1	1	-1
۷	-1	1	1	1
۸	1	-1	-1	-1
۹	1	-1	-1	1

ج - مسئله تشخیص اعداد چاپی فارسی: در این مسئله هدف تشخیص اعداد چاپی فارسی میباشد (شکل ۱۸). این اعداد روی یک صفحه کاغذ چاپ شده‌اند. اعداد فارسی از طریق یک دستگاه پویشگر با قدرت تفکیک ۳۰۰ نقطه در اینچ نمونه برداری گردیده است. پس از جدا سازی حروف در تصویر، ثابت‌های گشتاور، M ، M استخراج شده و ۷ ویژگی ورودی‌های شبکه عصبی را تشکیل میدهد.



شکل (۱۸) اعداد چاپی فارسی.

» - مسئله بازشناسی فونمهای فارسی: در این مسئله هدف بازشناسی فونمهای صوت فارسی میباشد. دادگان گفتار مورد استفاده در این آزمایشها دادگان فارسی دات میباشد [۴۴]. ابتدا سیگنالهای گفتار با فرکانس KHZ ۴۴/۱ نمونه برداری شده سیس فرکانس آن تا ۱۶ KHZ کاهش داده میشود. ضرائب کپیسترال LPC از مرتبه ۱۲ بعلاوه مشتق ضرائب کپیسترال LPC و تغییرات لگاریتم انرژی بعنوان ویژگی‌های گفتار از هر فریم با طول ۲۰ میلی ثانیه و شیفت زمانی ۱۰ میلی ثانیه استخراج شده است. نمونه‌های گفتار قبل از محاسبه ضرایب کپیسترال LPC با یک فیلتر با ضریب ۰/۹۷ فیلتر میشوند. در مرحله آموزش تعداد ۹۳۸ الگو مورد استفاده قرار گرفته است. همچنین از یک شبکه عصبی سه لایه با تاخیر زمانی ۳ فریم استفاده شده است. در بخش‌های بعدی نتایج شبیه‌سازی برای مسائل فوق ارائه گردیده است. در تمامی شبیه‌سازیها نرخ یادگیری ۱۰٪ و تعداد تکرارهای الگوریتم پس انتشار خطای هر مرحله ۵٪ میباشد.

۱-۸- مقایسه الگوریتم ارائه شده WASA با الگوریتم WSA

به منظور ارزیابی عملکرد الگوریتم پیشنهای WSA آزمایش‌های گوناگونی بر روی چهار مسئله مختلف صورت گرفته است. برای هر مسئله دو دسته آزمایش ترتیب داده شده است یک دسته آزمایش برای الگوریتم WSA و دسته دیگر برای الگوریتم WASA.

نتایج شبیه‌سازی برای الگوریتم WSA برای هر کاربرد و برای ۶ شبکه مختلف با تعداد نرونها لایه مخفی متفاوت پیاده‌سازی شده است. نتایج شبیه سازیها در جداول ۵ الی ۸ نشان داده شده است.

الف - مسئله شناسائی اعداد انگلیسی: ضرائب پهنهای خاموشی و روشنی ۱۰٪، ضریب کاهش وزن ۵٪ و ضریب ممنتوم صفر می‌باشد. الگوهای آموزش ۵۰۰۰ مرتبه به شبکه اعمال شده است. نتایج شبیه‌سازی در جدول ۵ نشان داده شده است.

ب - مسئله تقریبتابع غیرخطی زمان گسسته از مرتبه دوم: ضرائب پهنهای خاموشی و روشنی α ، ضریب کاهش وزن β و ضریب ممتنم γ میباشد. الگوهای آموزش 5000 مرتبه به شبکه اعمال شده است. نتایج شبیه‌سازی در جدول 6 نشان داده شده است.

ج - مسئله شناسایی اعداد فارسی: ضرائب پهنهای روشنی و خاموشی α ، ضریب کاهش وزن β و ضریب ممتنم γ میباشد. نتایج شبیه‌سازی در جدول 7 نشان داده شده است.

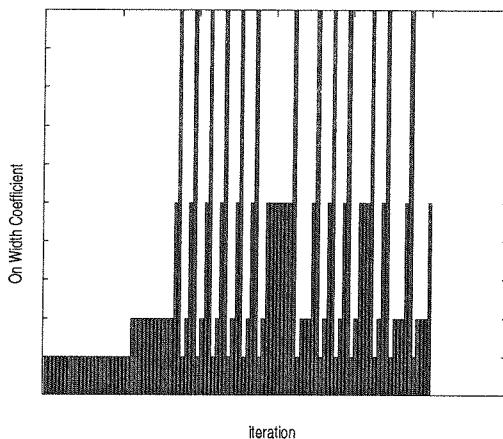
د - مسئله باز شناسایی فونم: ضرائب پهنهای خاموشی و روشنی به ترتیب 2 و 50 ، ضریب کاهش وزن β و ضریب ممتنم γ میباشد. نتایج شبیه‌سازی در جدول 8 نشان داده شده است.

نتایج شبیه‌سازی برای الگوریتم AWSA: برای هر مسئله، الگوریتم AWSA برای 6 شبکه مختلف با تعداد نرونها لایه مخفی متفاوت پیاده‌سازی شده است. برای تمامی مسائل اتو ماتنهای مختلف برای تطبیق ضرائب پهنهای روشنی و خاموشی مورد استفاده قرار گرفته است. نتایج شبیه‌سازیها در جداول 5 الی 8 و شکل‌های 19 الی 25 نشان داده شده است.

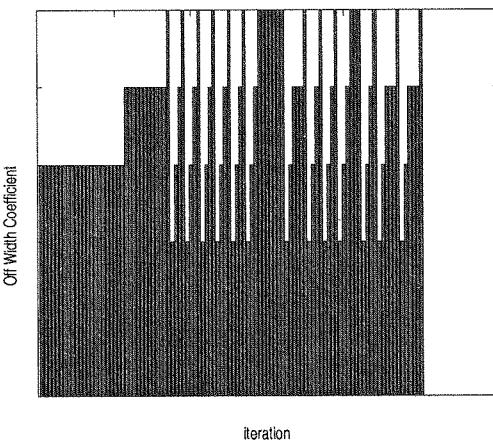
الف - مسئله شناسایی اعداد انگلیسی: $\{1, 2, 5, 10, 15, 20, 25\}$ مجموعه ضرائب پهنهای روشنی بوده و $\{1, 2, 5, 10, 15, 20, 25\}$ مجموعه ضرائب پهنهای خاموشی میباشد. ضریب کاهش وزن و ضریب ممتنم به ترتیب $\beta = 0$ و $\gamma = 0$ در نظر گرفته شده است. الگوهای آموزش 5000 مرتبه به شبکه اعمال شده است. نتایج شبیه‌سازی در جدول 5 نشان داده شده و شکل‌های 19 و 20 تغییرات ضریب پهنهای روشنی و خاموشی نسبت به epoch‌ها را نشان میدهد.

جدول (۵) مقایسه الگوریتمهای WSA و AWSA برای مسئله شناسایی اعداد لاتین.

الگوریتم AWSA			الگوریتم WSA			تعداد نرونهاي مخفی	شماره شبکه		
در صد تشخیص		تعداد نرونهاي مخفی	در صد تشخیص		تعداد نرونهاي مخفی				
آزمایش	آموزش		آزمایش	آموزش					
٪100	٪100	206	٪100	٪100	499	15	1		
٪90	٪100	187	٪90	٪100	534	15	2		
٪90	٪100	177	٪100	٪100	558	17	3		
٪100	٪100	192	٪100	٪100	637	19	4		
٪100	٪100	172	٪100	٪100	714	21	5		
٪90	٪100	261	٪90	٪100	772	22	6		
٪95	٪100	199	٪97	٪100	819	18	7		

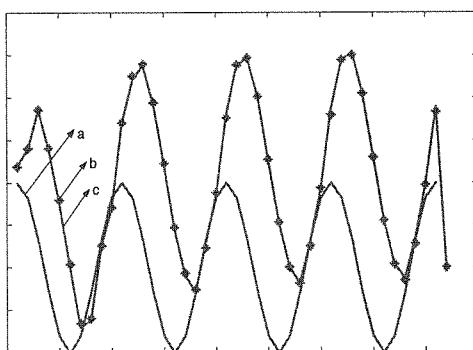


شکل (۱۹) منحنی تغییرات ضریب پهنهای روشنی.

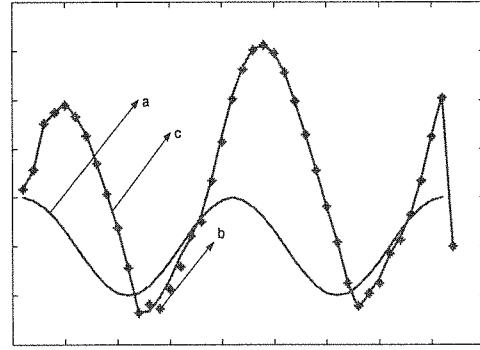


شکل (۲۰) منحنی تغییرات ضریب پهنهای روشی.

ب - مسئله تقریب تابع غیر خطی زمان گستته مرتبه دوم: در الگوریتم AWSA حداقل خطا مربوط به شبکه شماره ۳ با مقدار ۲/۲۰۸۲ می‌باشد. برای این مورد، موقعیکه ورودی سینوسی مورد استفاده قرار گرفته است شکل موجهای خروجی تابع و خروجی شبکه در شکل‌های ۲۱ و ۲۲ برای دو فرکانس مختلف نشان داده شده است. همچنانکه در این شکلها نشان داده شده است خروجی شبکه عصبی به نحو مطلوبی خروجی تابع را دنبال می‌کند. $\{10, 14, 16, 12, 14, 10\}$ مجموعه ضرائب پهنهای روشی و $\{4, 5, 5, 4, 5, 3\}$ مجموعه ضرائب پهنهای خاموشی می‌باشد. ضریب کاهش وزن و ضریب ممتنم به ترتیب $0/9$ و $0/98$ انتخاب شده است. الگوهای آموزش ۵۰۰۰ مرتبه به شبکه اعمال شده است. نتایج شبیه‌سازی در جدول ۶ نشان داده شده است.



شکل (۲۲) (a) ورودی (b) خروجی تابع (c) خروجی شبکه.



شکل (۲۲) (a) ورودی (b) خروجی تابع (c) خروجی شبکه.

ج - مسئله شناسائی اعداد چاپی فارسی: $\{15, 16, 17, 18\}$ مجموعه ضرائب پهنهای روشی و $\{4, 5, 5, 4, 5, 3\}$ مجموعه ضرائب پهنهای خاموشی می‌باشد. ضریب کاهش وزن و ضریب ممتنم به ترتیب $0/9$ و $0/98$ در نظر گرفته شده است. نتایج آزمایشها در جدول ۷ نشان داده شده است.

د - مسئله باز شناسایی فونم: $\{10, 14, 16, 20, 25\}$ مجموعه ضرائب پهنهای روشی و $\{10, 15, 20, 25\}$ مجموعه ضرائب پهنهای خاموشی می‌باشد. ضریب کاهش وزن و ضریب ممتنم به ترتیب $0/9$ و $0/98$ می‌باشد. نتایج شبیه‌سازی در جدول ۸ نشان داده شده است.

برای این مسئله شبیه‌سازی دیگری انجام شده و منحنی تغییرات تعداد وزنها بر حسب epoch (شکل‌های ۲۳ و ۲۴ را ببینید) رسم شده است. همچنانکه در این شکلها نشان داده شده است در الگوریتم تطبیقی AWSA در ابتدای الگوریتم یک کاهش شدید در تعداد وزنها اتفاق می‌افتد و سپس به تدریج کم می‌شود. بر خلاف الگوریتم AWSA، در الگوریتم WSA در

ابتداً الگوریتم، تعداد وزنها با نرخ کم کاهش یافته و بعد از تعدادی epoch شروع به افزایش کرده و برای مدت زمان زیادی ثابت باقی می‌ماند.

جدول (۶) مقایسه الگوریتمهای WSA و AWSA برای مسئله تقریبتابع غیر خطی زمان گسته درجه دوم.

الگوریتم AWSA		الگوریتم WSA		تعداد نزونهای مخفی	شماره شبکه
خطای شبکه عصبی به اندازی	وروودی سینوسی	تعداد وزنها لایه مخفی	خطای شبکه عصبی به اندازی		
۰/۱۱۶۲	۱۹	۰/۳۸۲۲	۲۳	۸	۱
۰/۹۴۰۹	۲۲	۰/۹۷۱۷	۲۵	۱۰	۲
۲/۲۰۸۲	۲۸	۲/۷۰۰۵	۳۲	۱۳	۳
۰/۷۳۲۵	۳۸	۰/۶۵۲۶	۴۱	۱۷	۴
۰/۸۰۱۲	۴۳	۰/۶۶۳۱	۴۷	۲۰	۵
۱/۴۵۸۰	۵۷	۱/۳۰۴۷	۶۳	۲۵	۶
۱/۲۰۹۵	۳۴/۵	۱/۱۱۲۵	۳۸/۵	۱۵/۵	متوسط

تذکرہ ۱: الگوریتم ارائه شده AWSA شبکه‌هایی با اتصالات محلی که دارای پیچیدگی پائین و قدرت تعمیم بالایی هستند تولید می‌کنند. نتایج مشابه‌سازی‌ها نشان میدهد شبکه‌های تولید شده توسط الگوریتم جدید از پیچیدگی پائین‌تری نسبت به الگوریتم تعیین وزن WSA برخوردار می‌باشند. قدرت شاخه زنی الگوریتم پیشنهادی جدید برای مسئله شناسایی اعداد لاتین ۸۶٪، مسئله تشخیص اعداد چاپی فارسی ۳۲٪، مسئله تقریبتابع غیر خطی زمان گسته درجه دوم ۱۰٪ و مسئله شناسایی فونمهای فارسی ۴۹٪ بیشتر از الگوریتم WSA می‌باشد.

جدول (۷) مقایسه الگوریتمهای WSA و AWSA برای مسئله تشخیص اعداد چاپی فارسی.

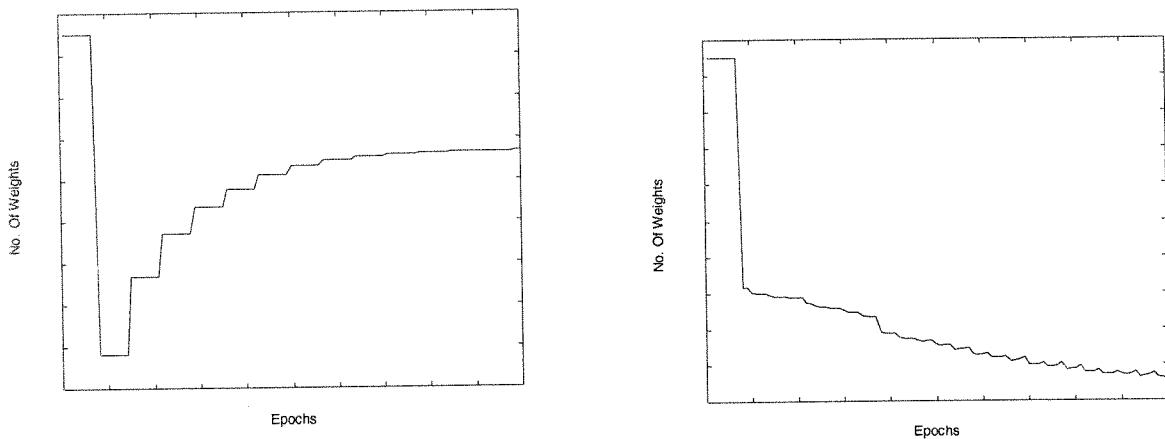
الگوریتم AWSA		الگوریتم WSA		تعداد نزونهای مخفی	شماره شبکه		
در صد تشخیص		در صد تشخیص					
آزمایش	آوزون	آزمایش	آوزون				
٪۹۹	٪۹۸	۳۵	٪۹۹	٪۹۸	۱۴		
٪۹۳	٪۹۷	۴۰	٪۹۴	٪۹۹	۱۵		
٪۹۴	٪۹۶	۴۳	٪۹۶	٪۹۲	۱۶		
٪۹۸	٪۹۶	۵۰	٪۹۴	٪۹۴	۱۷		
٪۹۳	٪۹۷	۵۵	٪۸۷	٪۹۷	۱۸		
٪۸۷	٪۹۹	۶۰	٪۹۶	٪۹۹	۱۹		
٪۹۴	٪۹۷/۲	۴۷	٪۹۴/۳	٪۹۶/۵	۱۶/۵		

جدول (۸) مقایسه الگوریتمهای WSA و AWSA برای مسئله شناسایی فونمهای فارسی.

الگوریتم AWSA			الگوریتم WSA			تعداد نمونهای مخفی	شماره شبکه		
در صد تشخیص		تعداد وزنهای ایله	در صد تشخیص		تعداد وزنهای ایله				
آرزو	موزن		آرزو	موزن					
٪۸۱	٪۸۲	۵۲۳	٪۸۷	٪۸۷	۹۴۵	۱۶	۱		
٪۸۹	٪۸۵	۶۱۹	٪۸۴	٪۸۷	۱۱۷۲	۲۰	۲		
٪۸۴	٪۸۷	۷۴۹	٪۸۲	٪۸۵	۱۴۱۸	۲۴	۳		
٪۸۸	٪۸۲	۸۱۰	٪۸۲	٪۸۳	۱۶۴۴	۲۸	۴		
٪۸۱	٪۸۸	۹۰۲	٪۸۱	٪۸۴	۱۸۵۵	۳۲	۵		
٪۸۴	٪۸۲	۱۰۲۳	٪۸۴	٪۸۲	۲۱۰۷	۳۶	۶		
٪۸۴/۵	٪۸۴	۷۷۱	٪۸۳	٪۸۴/۷	۱۵۲۳	۲۶	۷		

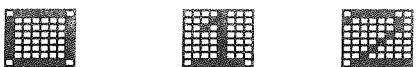
تذکر ۲: همچنانکه در شکل‌های ۲۳ و ۲۴ نشان داده است سطح زیر منحنی تغیرات تعداد وزن بر حسب epoch مربوط به الگوریتم AWSA کمتر از سطح زیر منحنی مربوط به الگوریتم WSA میباشد. این بدان معناست که در الگوریتم AWSA طی فرایند آموزش برای مدت زمان زیادی پیچیدگی شبکه پائین بوده که این مسئله میتواند باعث کاهش زمان آموزش شبکه گردد. بویژه این مسئله موقعی اهمیت پیدا میکند که از پردازشگرهای موازی برای آموزش شبکه استفاده کنیم که در این حالت با کاهش پیچیدگی شبکه نه تنها زمان محاسبات کاهش می‌یابد بلکه بدلیل کاهش ارتباطات بین نرونها کاهش چشمگری هم در زمان ارتباطات حاصل میشود. لذا الگوریتم AWSA کاندید مناسبی برای آموزش شبکه‌های عصبی با استفاده از پردازشگرهای موازی میباشد [۴۵].

تذکر ۳: الگوریتم AWSA در ابتدا مقدایر ضرائب پهنهای روشنی و خاموشی را طوری انتخاب میکند که فرایند حذف وزن با بیشترین سرعت شروع شود. عمل حذف وزن با حداکثر سرعت ادامه میباید تا زمانیکه خطای آموزش شروع به افزایش کند که در این حالت الگوریتم AWSA با انتخاب مقدایر دیگری برای ضرائب پهنهای روشنی و خاموشی سرعت شاخه زنی را کاهش داده و در صورت لزوم برخی از وزنهای حذف شده را دوباره روشن میکند. ملاحظه میکنیم الگوریتم AWSA با تنظیم مقدایر ضرائب پهنهای روشنی و خاموشی میتواند با داشتن عملکرد طبیقی درصد بیشتری از وزنهای شبکه را نسبت به الگوریتم WSA حذف کند.



شکل (۲۴) منحنی تعداد وزنها بر حسب epochs برای الگوریتم AWSA

شکل (۲۳) منحنی تعداد وزنها بر حسب epochs برای الگوریتم WSA



شكل (٢٥) نمايش اعداد ٠، ١، ٢

تذکرۀ ۴: قدرت تعمیم شبکه‌های هرس شده در اکثر موارد از قدرت تعمیم شبکه‌های هرس نشده بیشتر می‌باشد. دلیل این امر اینست که با کاهش تعداد پارامترهای شبکه ابر صفحه‌های تولید شده توسط هر یک از نرونهای مخفی هموار می‌گردد. حقیقت دیگری که با دقت در نتایج آزمایش می‌توان به آن رسید است که هر چقدر بعد بردارهای ورودی بیشتر باشد به همان نسبت درصد حذف وزنهای ورودی نرونهای لایه مخفی بیشتر می‌شود. هر چقدر بعد فضای ورودی زیاد باشد بعبارت دیگر اگر تعداد زیادی ویژگی برای شناسایی الگوهای ورودی مورد استفاده قرار گیرد. در این صورت افزونگی بردارهای ورودی افزایش یافته و فقط تعداد کمی از این ویژگیها برای طبقه‌بندی الگوها مورد نیاز می‌باشد. در این حالت الگوریتم یادگیری ساختار شبکه در طی آموزش ارتباط ویژگیهای را که نقش مهمی در شناسائی الگوها ایفا نمی‌کنند را با نرونهای لایه مخفی قطع می‌کند. بعبارت دیگر وزنهای مربوطه را صفر می‌کند. بنویان مثال برای طبقه‌بندی اعداد لاتین $0, 1, 2$ از بردارهای ورودی با ابعاد 64×1 استفاده می‌کنیم. در این حالت بعد فضای ورودی $4^4 = 256$ می‌باشد. با دقت در اشکال این اعداد (شکل ۲۵) ملاحظه می‌کنیم که قسمت پائین این اعداد در تمامی آنها مشترک بوده و اطلاعات مفیدی را جهت طبقه‌بندی این اعداد در اختیار شبکه عصبی قرار نمیدهد. لذا این بخش از بردار ورودی غیر ضروری بوده و الگوریتم یادگیری ساختار شبکه در حین آموزش ارتباط این بخش از بردار ورودی با نرونهای لایه مخفی را قطع می‌کند.

۲-۸- مقایسه اتوماتانهای مختلف

جدول (۱) مقایسه آنوماتانهای مختلف برای تنظیم پارامترهای λ_{ON} و λ_{OFF} برای کاربود شناسائی اعداد انگلیسی.

تعداد وزنهای لایه اول						تعداد وزنهای مخفی	شیوه
L _{R,I}	L _{R,P}	کاریاف	گرینیسکی	ستبلین			
۲۳۵	۲۳۵	۲۳۰	۲۲۴	۲۰۶	۱۵	۱	
۲۱۰	۲۱۰	۱۹۵	۱۹۶	۱۸۷	۱۵	۲	
۲۰۹	۲۰۱	۱۹۸	۱۹۳	۱۷۷	۱۷	۳	
۲۱۴	۲۱۶	۲۱۰	۲۰۵	۱۹۲	۱۹	۴	
۲۱۹	۲۱۷	۲۰۳	۱۹۵	۱۷۳	۲۱	۵	
۲۷۷	۲۷۳	۲۶۹	۲۵۹	۲۶۱	۲۳	۶	
۲۲۷/۳	۲۲۵/۳	۲۱۷/۵	۲۱۲	۱۹۹/۳	۱۸۳/۳	منسوخ	

جدول (۱۰) مقایسه اتوماتانهای مختلف برای تنظیم پارامترهای λ_{ON} و λ_{OFF} برای مسئله تقریب تابع غیر خطی زمان گسسته درجه دوم.

تعداد وزنهای لایه اول						تعداد وزنهای مخفی	شبکه
L_{R-I}	L_{R-P}	کرایلف	کرنیسکی	ستلین	شنبک		
۲۴	۲۵	۲۳	۲۳	۱۹	۸	۱	
۲۷	۲۹	۲۸	۲۶	۲۲	۱۰	۲	
۳۰	۳۳	۳۲	۳۲	۲۸	۱۳	۳	
۴۵	۴۴	۴۲	۴۲	۳۸	۱۷	۴	
۴۸	۴۷	۴۴	۴۲	۴۳	۲۰	۵	
۶۳	۶۱	۶۰	۵۹	۵۷	۲۵	۶	
۳۹/۵	۳۹/۸	۳۸/۲	۳۷/۳	۳۴/۵	۱۵/۵	متوسط	

جدول (۱۱) مقایسه اتو ما تا نهای مختلف برای تنظیم پارامترهای λ_{ON} و λ_{OFF} برای مسئله تشخیص اعداد چاپی فارسی.

تعداد وزنهای لایه اول						تعداد وزنهای مخفی	شبکه
L_{R-I}	L_{R-P}	کرایلف	کرنیسکی	ستلین	شنبک		
۳۴	۳۷	۳۸	۳۷	۳۵	۱۴	۱	
۴۵	۴۸	۴۵	۴۷	۴۰	۱۵	۲	
۴۹	۴۹	۴۸	۵۰	۴۳	۱۶	۳	
۵۵	۵۵	۵۹	۵۸	۵۰	۱۷	۴	
۵۹	۶۰	۶۵	۶۳	۵۵	۱۸	۵	
۷۰	۷۱	۷۱	۷۲	۶۰	۱۹	۶	
۵۲	۵۲/۳	۵۴/۳	۵۴/۵	۴۷/۲	۱۶/۵	متوسط	

تذکر^۵: با توجه به آزمایشهای انجام یافته و با دقت در جدول ۹ الی ۱۲ میتوان به نتایج زیر رسید. در اکثر موارد در بین اتوماتانهای با ساختار ثابت، اتوباتان ستلین کرنیسکی عملکرد بهتری می‌باشد. در مورد اتوماتان کرنیسکی فرض کنیم که اتوماتان دارای عملکرد بدی بوده و محیط پاسخ نا مطلوب داده و اتoman به سمت حالتها بیرونی حرکت میکند با دریافت هر پاسخ نامطلوب اتوماتان به حرکت خود به سمت حالتها بیرونی ادامه می‌دهد حال اگر در بین راه یک پاسخ مطلوب از محیط در یافت کند به داخلی ترین حالت منتقل می‌شود.

حال اگر اتoman دارای عملکرد بد بود برای تغییر اقدام بایستی حرکت خود را دو باره از داخلی ترین اقدام شروع کرده و با دریافت N پاسخ نامطلوب متوالی موفق به تغییر اقدام شود ملاحظه می‌کنیم که در این نوع اتو ماتان تغییر اقدام با کندی صورت می‌گیرد لذا در مقایسه با اتوماتان ستلین دارای عملکرد ضعیفی می‌باشد. با توجه به نتایج ملاحظه می‌کنیم که اتوماتان کرایلف در بعضی موارد دارای عملکرد خوبی بوده و در برخی از موارد دارای عملکرد بد می‌باشد. که این رفتار ناشی از ساختار این نوع اتوماتان می‌باشد. در این اتوماتان با دریافت پاسخ نامطلوب از محیط با احتمال ۱/۲ یا به سمت حالتها داخلی و یا به سمت حالتها خارجی حرکت میکند. عملکرد اتوماتانهای L_{R-P} و تقریباً یکسان می‌باشد.

۸-۳- مقایسه عملکرد الگوریتم MWSA با الگوریتم WSA

با هدف بررسی عملکرد الگوریتم معرفی شده MWSA آزمایش‌های متفاوتی بر روی چهار مسئله مختلف صورت است. برای هر کاربرد دو دسته آزمایش انجام داده شده است یک دسته برای الگوریتم WSA و دسته دیگر برای الگوریتم MWSA. نتایج شبیه سازیها برای الگوریتم WSA: این نتایج در حقیقت همان نتایجی است که قبلاً برای مقایسه این الگوریتم با الگوریتم AWSA انجام دادیم. نتایج این آزمایش‌ها مجدداً در جداول ۱۳ الی ۱۶ آورده شده است.

جدول (۱۲) مقایسه اتو ما تنهای مختلف برای تنظیم پارامترهای λ_{ON} و λ_{OFF} برای مسئله شناسایی فونمهای فارسی.

L_{R-I}	L_{R-P}	تعداد وزنهای لایه اول بعد از هرس			تعداد نزونهای لایه مخفی	شبکه
		لطف	گریزشی	شیخ		
۵۵۱	۵۵۳	۵۵۵	۵۵۷	۵۲۳	۱۶	۱
۶۳۷	۶۳۴	۶۴۹	۶۳۰	۶۱۹	۲۰	۲
۷۶۹	۷۵۹	۷۶۰	۷۷۹	۷۴۹	۲۴	۳
۸۲۰	۸۳۰	۸۵۴	۸۴۰	۸۱۰	۲۸	۴
۹۵۴	۹۶۰	۹۳۲	۹۵۰	۹۰۲	۳۲	۵
۱۲۵۷	۱۲۵۰	۱۱۳۶	۱۲۶۰	۱۰۲۳	۳۶	۶
۸۳۱/۳	۸۳۱	۸۱۴/۳	۸۳۶	۷۷۱	۲۶	متوسط

جدول (۱۳) مقایسه الگوریتمهای WSA و MWSA برای مسئله شناسایی اعداد لاتین.

MWSA الگوریتم		WSA الگوریتم				تعداد نزونهای مخفی	شبکه
در صد تشخیص	در صد تشخیص	در صد تشخیص	در صد تشخیص	آزمایش	آموزش		
آزمایش	آموزش	لطف	گریزشی	آزمایش	آموزش	تعداد وزنهای لایه مخفی	شبکه
%۱۰۰	%۱۰۰	۳۴۰	%۱۰۰	%۱۰۰	۴۴۹	۱۵	۱
%۹۰	%۱۰۰	۳۶۷	%۹۰	%۱۰۰	۵۳۴	۱۵	۲
%۹۰	%۱۰۰	۳۷۶	%۱۰۰	%۱۰۰	۵۵۷	۱۷	۳
%۱۰۰	%۱۰۰	۴۲۳	%۱۰۰	%۱۰۰	۶۳۷	۱۹	۴
%۱۰۰	%۱۰۰	۴۶۴	%۱۰۰	%۱۰۰	۷۱۴	۲۱	۵
%۹۰	%۱۰۰	۴۸۴	%۹۰	%۱۰۰	۷۷۲	۲۳	۶
%۹۵	%۱۰۰	۴۰۹	%۹۶/۷	%۱۰۰	۶۱۹	۱۸	متوسط

نتایج شبیه سازی برای الگوریتم MWSA: برای هر مسئله شبکه های مختلف با تعداد مختلف نزونهای لایه مخفی پیاده سازی شده است. در این آزمایشها، مقدار $\lambda_{ON} = 1/5$ ، تعداد تکرار الگوریتم پس انتشار خطای هر گام $N=50$ ، نرخ یادگیری $1/00$ و ضریب ممنتم صفر در نظر گرفته شده است.تابع غیر خطی مورد استفاده در لایه مخفی و لایه خروجی، تابع سیگموئید می باشد. الگوهای آموزش 5000 بار به شبکه اعمال شده است. همچنین در این آزمایشها مقدار $1/10$

$\gamma = 0/5$ و مقدار $\varepsilon = \gamma$ انتخاب شده است.

جدول (۱۴) مقایسه الگوریتمهای WSA و MWSA برای مسئله تقریبتابع غیر خطی زمان گستته درجه دوم.

MWSA		WSA		تعداد زونهای مخفی	شبکه
خطای شبکه عصبی به وزوهدی سینوسی	تعداد زونهای لایه مخفی	خطای شبکه عصبی به وزوهدی سینوسی	تعداد زونهای لایه مخفی		
۱/۱۲۲۶	۱۶	۰/۳۸۲۲	۲۳	۸	۱
۰/۹۸۰۹	۱۷	۰/۹۷۱۷	۲۵	۱۰	۲
۲/۲۹۸۲	۲۵	۲/۷۰۰۵	۳۲	۱۳	۳
۰/۹۳۲۵	۳۴	۰/۶۵۲۶	۴۱	۱۷	۴
۰/۹۰۱۲	۴۱	۰/۶۶۳۱	۴۷	۲۰	۵
۱/۰۵۸۰	۵۶	۱/۳۰۴۷	۶۳	۲۵	۶
۱/۴۴۹۵	۳۱/۵	۱/۱۱۲۵	۳۸/۵	۱۵/۵	متوسط

جدول (۱۵) مقایسه الگوریتمهای WSA و MWSA برای مسئله تشخیص اعداد چاپی فارسی.

MWSA		WSA		تعداد زونهای مخفی	شبکه
در صد تشخیص	تعداد زونهای لایه مخفی	در صد تشخیص	تعداد زونهای لایه مخفی		
آزمایش	آموزش	آزمایش	آموزش		
۷/۹۹	۷/۹۸	۴۰	۷/۹۹	۷/۹۸	۵۹
۷/۹۳	۷/۹۷	۴۵	۷/۹۴	۷/۹۹	۶۰
۷/۹۲	۷/۹۶	۴۸	۷/۹۶	۷/۹۲	۶۱
۷/۹۸	۷/۹۱	۵۵	۷/۹۴	۷/۹۴	۷۰
۷/۹۳	۷/۹۷	۶۴	۷/۸۷	۷/۹۷	۸۰
۷/۹۱	۷/۹۹	۷۳	۷/۹۶	۷/۹۹	۸۹
۷/۹۴	۷/۹۶	۵۴	۷/۹۴	۷/۹۶/۵	۷۰
					متوسط

تذکر ۶: نتایج شبیه سازیهای مختلف نشان میدهد الگوریتم جدید MWSA دارای عملکرد بهتری نسبت به الگوریتم WSA میباشد. الگوریتم پیشنهادی MWSA بدلیل اینکه در آن فرایند شاخه زنی تا زمانیکه منجر به افزایش خطای آموزش نگردیده است همچنان ادامه میباید لذا در مقایسه با الگوریتم WSA که در آن عمل شاخه زنی تا زمانی ادامه میباید که تعداد وزنها از یک حدی کمتر نشود دارای عملکرد بهتری میباشد. با اعمال این الگوریتم توانستیم برای مسئله شناسایی اعداد لاتین ۳۴٪، مسئله تشخیص اعداد چاپی فارسی ۲۳٪، مسئله تقریبتابع غیر خطی زمان گستته درجه دوم ۱۸٪ و مسئله شناسایی

است که افزایش در صد شاخه زنی برای شبکه‌های پیچیده بیشتر می‌باشد. در بین مسائل مختلفی که برای ارزیابی الگوریتم MWSA مورد استفاده قرار گرفته است شبکه‌های مورد استفاده برای شناسایی فونمهای فارسی از بقیه شبکه‌ها پیچیده‌تر بوده و در این مورد این مسئله شاهد بیشترین افزایش در صد شاخه زنی ۴۵٪ می‌باشیم.

جدول (۱۶) مقایسه الگوریتمهای WSA و MWSA برای مسئله شناسایی فونمهای فارسی.

الگوریتم MWSA		الگوریتم WSA				تعداد زونهای مخفی	تعداد نمونه		
در صد تشخیص		تعداد وزنهای مخفی	در صد تشخیص		تعداد وزنهای مخفی				
آزمایش	آموزش		آزمایش	آموزش					
٪۸۵	٪۸۳	۵۴۰	٪۸۷	٪۸۷	۹۴۵	۱۶	۱		
٪۸۸	٪۸۴	۶۳۴	٪۸۴	٪۸۷	۱۱۷	۲۰	۲		
٪۸۵	٪۸۶	۷۵۸	٪۸۲	٪۸۵	۱۴۱	۲۴	۳		
٪۸۷	٪۸۲	۸۸۹	٪۸۲	٪۸۳	۱۶۴	۲۸	۴		
٪۸۵	٪۸۷	۱۰۴۰	٪۸۱	٪۸۴	۱۸۵	۳۲	۵		
٪۸۶	٪۸۲	۱۱۳۴	٪۸۴	٪۸۲	۲۱۰	۳۶	۶		
٪۸۶	٪۸۴	۸۳۲	٪۸۳	٪۸۵	۱۵۲	۲۶	۷		

۴-۸- مقایسه روش‌های یادگیری ساختار پیشنهادی با روش‌های موجود

برخی از روش‌های مهم شاخه‌زنی که توسط محققین ارائه شده است بشرح زیر می‌باشد. کارین [۴۶] روش را ارائه کرده است که در آن روش حساسیت تابع خطای خطا را نسبت به حذف هر اتصال حساب کرده سپس وزنهای باحساسیت پائین را حذف می‌کند. حساسیت وزن w_{ij} بصورت زیر بدست می‌آید.

$$S_{ij} = -\frac{E(w^f) - E(0)}{w^f - 0} \times w^f \quad (22)$$

که در آن w^f مقدار نهایی وزن پس از آموزش، ۰ مقدار آن پس از حذف، $E(w^f)$ مقدار نهایی خطای خطا پس از آموزش و $E(0)$ مقدار خطای موقعيت که وزن حذف می‌شود. در عمل بجای اینکه پس از آموزش شبکه هر کدام از وزنهای را حذف کرده و حساسیت تابع خطای را نسبت به آن حساب کرد در طول آموزش یک تخمینی از S بصورت زیر محاسبه می‌گردد.

$$\hat{S}_{ij} = -\sum_1^N \frac{\partial E}{\partial w_{ij}} \cdot \Delta w_{ij}(n) \cdot \frac{w_{ij}^f}{w_{ij}^f - w_{ij}^i} \quad (23)$$

که در فرمول بالا، N تعداد epoch های آموزش و w^i مقدار اولیه وزن می‌باشد. تمامی این عبارتها در طول آموزش در

دسترس بوده و نیاز به محاسبه جداگانه حساسیت پس از پایان آموزش نمیباشد. پس از آموزش هر وزن دارای یک حساسیت تخمینی بوده و میتوان وزنهای با حساسیت پائین را حذف کرد.

دستهای دیگر از روشها تابع خطا را طوری تغییر میدهد که در نتیجه الگوریتم پس انتشار خطا در حین آموزش تعدادی از وزنهای را به سمت صفر میلهد. وزنهایی که نهایتاً مقدار آنها از یک مقدار آستانه کمتر باشد حذف میشود. ایشی کاوا [۴۷] یک الگوریتم یادگیری ساختار به این صورت پیشنهاد کرد. تابع هدف این الگوریتم شامل قسمت خطا و قسمت جریمه میباشد. قسمت جریمه مجموع مقادیر قدر مطلق وزنها میباشد. یادگیری شامل دو مرحله میباشد. الگوریتم یادگیری با الگوریتم فراموشی در مرحله اول و الگوریتم یادگیری با الگوریتم انتخابی در مرحله دوم. تابع هدف E_{pf} در مرحله اول بصورت زیر تعریف میشود.

$$E_{pf} = \sum_j (t_{pj} - o_{pj})^2 + \varepsilon \sum_{i,j} |w_{ji}| \quad (24)$$

که در آن t_{pj} و o_{pj} به ترتیب الگوی هدف و الگوی خروجی واحد زام برای الگوی ورودی P، w_{ij} وزن بین واحد زام در لایه پائینی با واحد زام در لایه بالای E یک ثابت میباشد. روش گرادیان نزولی روی تابع هدف اعمال شده و قانون تغییر وزن بصورت زیر میباشد.

$$\Delta_p w_{ji}(t+1) = \eta \delta_{pj} o_{pi} + \alpha \Delta_p w_{ji}(t) - \varepsilon \text{sgn}(w_{ji}) \quad (25)$$

که $\Delta_p w_{ji}(t)$ تغییراتی است که بایستی در W_{ji} ایجاد شود. و δ_{pj} خطای پس انتشار واحد زام برای الگوهای ورودی P، η و $\varepsilon = \eta \varepsilon$ ثابت هستند. $\text{sgn}(x)$ بصورت زیر تعریف میشود.

$$\text{sgn}(x) = \begin{cases} 1 & \text{for } x > 0 \\ 0 & \text{for } x = 0 \\ -1 & \text{for } x < 0 \end{cases} \quad (26)$$

تابع هدف، E_{ps} در مرحله دوم بصورت زیر تعریف میشود.

$$E_{ps} = \sum_j (t_{pj} - o_{pj})^2 + \varepsilon \sum_{|w_{ji}| < \sigma} |w_{ji}| \quad (27)$$

که σ یک ثابت مثبت میباشد. بدین ترتیب یادگیری در مرحله دوم یادگیری فراموشی را فقط در مورد وزنهایی که در یک محدوده مشخص قرار دارد اعمال میکند. مراحل مختلف الگوریتم بصورت زیر میباشد. یک ساختار مناسب برای شبکه انتخاب کن شبکه را با استفاده از الگوریتم فراموشی آموزش بده. شبکه را با استفاده از الگوریتم انتخابی آموزش بده. روش دیگری توسط لی کان [۵] تحت عنوان OBD ارائه گردیده است. این الگوریتم دستهای از وزنهای را پیدا میکند که حذف این وزنهای افزایش خیلی کمی را در تابع هدف ایجاد میکند.

الگوریتم OBD بصورت زیر میباشد.

یک ساختار مناسب یک شبکه را انتخاب کن شبکه را با الگوریتم پس انتشار خطا آموزش بده اهمیت هر وزن را که با z_{ji} نشان داده میشود طبق فرمول زیر برای تمامی وزنهای حساب کن

$$S_{ji} = \frac{1}{2} \frac{\partial^2 E}{\partial w_{ji}^2} \cdot w_{ji}^2 \quad (28)$$

که در آن E تابع هدف میباشد.

وزنهای کم اهمیت را حذف کن

تا زمانیکه حذف وزنهای باعث افزایش خطای نشده به مرحله ۲ برو.

در این بخش الگوریتمهای جدید AWSA و MWSA را با روش‌های موجود مقایسه میکنیم. بمنظور مقایسه عملکرد الگوریتمهای پیشنهادی AWSA و MWSA با روش‌های مهم حذف وزن آزمایش‌های را ترتیب داده‌ایم. آزمایشها بر روی مسائل شناسایی اعداد لاتین، بازناسایی اعداد چاپی فارسی، تقریب تابع غیر خطی زمان گستته از مرتبه دوم و بازناسایی فونمهای فارسی صورت گرفته است. نتایج آزمایش‌های مختلف در جداول ۱۷ الی ۲۰ نشان داده شده است.

الگوریتم کارنین: برای هر کاربردی الگوریتم هرس کارنین برای تعداد مختلف نرونها لایه مخفی پیاده‌سازی شده است. در این آزمایشها نرخ یادگیری ۱/۰ و ضریب گشتاور صفر در نظر گرفته شده است. از تابع سیگموئید بعنوان توابع غیرخطی لایه‌های مخفی و خروجی استفاده شده است. همچنین در این الگوریتم مقدار آستانه برای حساسیت وزنها ۰/۰۱ انتخاب شده است. وزنهای که حساسیت تابع خطای نسبت به آن کمتر از ۰/۰۱ باشد وزنهای غیر مهم تلقی شده و حذف شده‌اند.

الگوریتم یادگیری ساختار با فراموشی: برای هر مسئله، الگوریتم فراموشی برای تعداد مختلف نرونها لایه مخفی پیاده‌سازی شده است. در تمامی آزمایشها نرخ یادگیری ۰/۰۱ و ضریب گشتاور صفر انتخاب شده است. از تابع سیگموئید بعنوان توابع غیرخطی لایه‌های مخفی خروجی استفاده شده است. مقدار آستانه برای پارامتر $\sigma = 0.01$ انتخاب شده است.

الگوریتم OBD: برای کاربردهای مختلف الگوریتم OBD برای تعداد مختلف نرونها لایه مخفی اجرا شده است. در تمامی آزمایشها نرخ یادگیری ۰/۰۱ و ضریب گشتاور صفر انتخاب شده است. از تابع سیگموئید برای تابع غیر خطی لایه‌های خروجی استفاده شده است. مقدار آستانه برای پارامتر $\sigma = 0.01$ میباشد. انتخاب شده است.

جداول ۱۷ الی ۲۰ نتایج شبیه سازیها را برای هر کدام از الگوریتم‌ها و برای کاربردهای مختلف را نشان میدهد.

تذکر ۷: با توجه به نتایج آزمایشات ملاحظه می‌کنیم که الگوریتم AWSA دارای بیشترین قدرت شاخه‌زنی میباشد. در این روش با توجه به اینکه با تنظیم پارامترهای ضریب پهنای روشی و ضریب پهنای خاموشی در طول فرایند آموزش نرخ شاخه‌زنی و نرخ اضافه کردن وزنهای را بطور تطبیقی تغییر میدهیم لذا میتوانیم به بیشترین درصد شاخه‌زنی بدون واگرایی شبکه دست پیدا کنیم.

جدول (۱۷) مقایسه الگوریتمهای مختلف شاخه‌زنی برای مسئله شناسایی اعداد لاتین.

ردیف	OBD	تعداد وزنهای لایه مخفی				تعداد نرونها مخفی	ردیف
		یادگیری پهنای پارامتر	فراموشی	WSA	MWSA		
۶۲۰	۵۶۰	۵۰۴	۴۹۹	۳۴۰	۲۰۶	۱۵	۱
۶۱۱	۵۹۰	۵۱۰	۵۳۴	۳۶۷	۱۸۷	۱۵	۲
۶۶۰	۶۲۰	۵۳۰	۵۵۸	۳۷۶	۱۷۷	۱۷	۳
۶۹۰	۶۲۵	۶۴۵	۶۳۷	۴۲۳	۱۹۲	۱۹	۴
۷۵۰	۶۸۰	۷۱۰	۷۱۴	۴۶۴	۱۷۳	۲۱	۵
۷۹۰	۶۹۵	۷۲۰	۷۷۲	۴۸۴	۲۶۱	۲۳	۶
۶۸۷	۶۲۸	۶۰۵	۶۱۹	۴۰۹	۱۹۹	۱۸	۷

جدول (۱۸) مقایسه الگوریتمهای مختلف شاخه‌زنی برای مسئله تقریب تابع غیرخطی زمان گستته درجه دوم.

تعداد وزنهای لایه مخفی								
کاربن	OBD	پادگیری ساختارها	فراهمشی	WSA	MWSA	AWSA	شبکه	تعداد زونهای مخفی
۲۵	۲۵	۲۲	۲۳	۱۶	۱۹	۸	۱	
۲۷	۲۷	۲۶	۲۵	۱۷	۲۲	۱۰	۲	
۲۹	۳۷	۳۴	۳۲	۲۵	۲۸	۱۳	۳	
۵۰	۴۸	۴۳	۴۱	۳۴	۳۸	۱۷	۴	
۶۳	۵۷	۴۹	۴۷	۴۱	۴۳	۲۰	۵	
۸۹	۷۷	۶۵	۶۳	۵۶	۵۷	۲۵	۶	متوسط
۴۹	۴۵	۷۰	۳۸/۵	۳۱/۵	۳۴/۵	۱۵/۵		

جدول (۱۹) مقایسه الگوریتمهای مختلف شاخه‌زنی برای مسئله تشخیص اعداد چاپی فارسی.

تعداد وزنهای لایه مخفی								
کاربن	OBD	پادگیری ساختارها	فراهمشی	WSA	MWSA	AWSA	شبکه	تعداد زونهای مخفی
۹۰	۸۵	۶۴	۵۹	۴۰	۳۵	۱۴	۱	
۹۴	۸۱	۶۰	۶۰	۴۵	۴۰	۱۵	۲	
۹۹	۸۵	۶۵	۶۱	۴۸	۴۳	۱۶	۳	
۱۰۹	۹۰	۷۹	۷۰	۵۵	۵۰	۱۷	۴	
۱۲۱	۹۵	۸۵	۸۰	۶۴	۵۵	۱۸	۵	
۱۲۳	۱۰۱	۸۷	۸۹	۷۳	۶۰	۱۹	۶	
۱۰۶	۸۹/۵	۷۳	۶۹/۸	۵۴	۴۷	۱۶/۵		
								متوسط

جدول (۲۰) مقایسه الگوریتمهای مختلف شاخه‌زنی برای مسئله شناسایی فونهای فارسی.

تعداد وزنهای لایه مخفی								
کاربن	OBD	پادگیری ساختارها	فراهمشی	WSA	MWSA	AWSA	شبکه	تعداد زونهای مخفی
۱۰۲۵	۱۰۲۰	۹۶۰	۹۴۵	۵۴۰	۵۲۳	۱۶	۱	
۱۲۷۰	۱۲۵۰	۱۲۰۱	۱۱۷۲	۶۳۴	۶۱۹	۲۰	۲	
۱۵۲۰	۱۴۹۰	۱۴۰۳	۱۴۱۸	۷۵۸	۷۴۹	۲۴	۳	
۱۷۴۳	۱۷۳۰	۱۷۲۰	۱۶۴۴	۸۸۹	۸۱۰	۲۸	۴	
۲۱۰۰	۲۰۱۳	۱۹۳۰	۱۸۵۵	۱۰۴۰	۹۰۲	۲۲	۵	
۲۴۹۴	۲۲۸۴	۲۳۰۲	۲۱۰۷	۱۱۳۴	۱۰۲۳	۳۶	۶	
۱۶۹۲	۱۶۴۸	۱۵۸۶	۱۵۲۳	۸۳۳	۷۷۱	۲۶		متوسط

تذکرہ ۸: الگوریتم‌های کارنین و OBD شبکه را با استفاده از الگوریتم پس انتشار خطا آموزش داده و سپس وزنهای بی‌همیت را شناسایی کرده اقدام به حذف آنها می‌نمایند. لذا این الگوریتم‌ها در حین آموزش پیچیدگی محاسبات را کاهش نمیدهند. یکی از معضلاتی که گریبانگیر محققین فعال در زمینه شبکه‌های عصبی می‌باشد حجم بسیار بالای محاسبات و در نتیجه طولانی شدن زمان یادگیری می‌باشد. لذا الگوریتم‌های یادگیری ساختاری که در حین آموزش پیچیدگی شبکه را کاهش دهند از این نظر دارای برتری می‌باشند. چرا که با کاهش پیچیدگی شبکه نه تنها زمان محاسبات تقلیل پیدا می‌کند بلکه در پیاده‌سازی موازی شبکه‌های عصبی برروی کامپیووترهای موازی با کاهش وزنهای و نهایتاً حذف نرونها بی‌همیت حجم ارتباطات بین پروسسورها نیز کاهش یافته در نتیجه می‌توان به Speed up های بالاتری دست یافت.

الگوریتم‌های AWSA، MWSA و AWSA، MWSA که از این لحاظ برای پیاده‌سازی موازی شبکه‌های عصبی مناسب می‌باشد. باعث کاهش پیچیدگی شبکه می‌گردد که از این احتمال زیاد وزنهایی را حذف برای می‌باشد.

تذکرہ ۹: در الگوریتم‌های AWSA، MWSA و AWSA، MWSA که مبتنی بر اتماتانهای یادگیر می‌باشند. پس از آنکه برای N بار متواالی که N عمق حافظه اتوماتان می‌باشد. قدر مطلق وزنی از یک مقدار آستانه کوچکتر بود آنگاه آن وزن حذف می‌شود. این نحوه حذف وزن با احتمال زیاد وزنهایی را حذف می‌کند که مطمئناً در epoch های متواالی قدر مطلق آنها دائماً در حال کاهش بوده و نقش آنها در طبقه‌بندی الگوهای ناچیز بوده و می‌توان آنها را برای حذف کرد. در طی فرایند آموزش ممکن است وزنی در مقاطعی از آموزش دارای قدر مطلق کم بوده ولی بعداً افزایش یابد لذا حذف چنین وزنهایی می‌تواند باعث افزایش خطا شود.

نتیجه گیری

در این مقاله دو الگوریتم جدید تحت عنوان AWSA و MWSA ارائه گردیده است. الگوریتم AWSA با استفاده از اتوماتانهای یادگیر بازه‌های تصمیم گیری مورد استفاده در الگوریتم تعیین تعداد وزن WSA را تنظیم می‌کند. در این الگوریتم برای پاسخ دادن به اتوماتان مربوط به تنظیم بازه‌های تصمیم گیری از معیار خطا کمک گرفته‌ایم. در الگوریتم MWSA معیارهای جدیدی برای ارزیابی عملکرد وزنهای روشن و خاموش و شرایط روشن کردن وزنهای خاموش ارائه گردیده است. این الگوریتم‌ها شبکه‌هایی با اتصالات محلی که دارای پیچیدگی پائین و قدرت تعیین بالایی هستند تولید می‌کنند. در بخش دیگری از مقاله اتوماتانهای مختلف برای تنظیم بازه‌های تصمیم گیری با هم مقایسه گردیده‌اند. از طریق شبیه‌سازی نشان داده شده است در اکثر موارد در بین اتوماتانهای با ساختار ثابت، اتوماتان ستیلین دارای عملکرد بهتری بوده اتوماتان کرنیسکی با توجه به اینکه در آن تغییر اقدام با تأخیر صورت می‌گیرد دارای عملکرد ضعیفی بوده و اتوماتان کرایلف بدلیل تصادفی بودن عملکرد این نوع اتوماتان در بعضی مواقع دارای عملکرد خوب و در برخی از مواقع دارای عملکرد بد می‌باشد. الگوریتم‌های پیشنهادی AWSA و MWSA بر روی مسائل شناسائی اعداد انگلیسی، شناسائی اعداد چاپی فارسی، تقریب تابع غیر خطی زمان گستته از مرتبه دوم و باز شناسائی فونمنهای فارسی پیاده‌سازی شده است. نتایج شبیه‌سازیها نشان میدهد الگوریتم‌های پیشنهادی AWSA و MWSA دارای عملکرد بهتری نسبت به الگوریتم‌های WSA، کارنین، OBD و الگوریتم یادگیری با فراموشی می‌باشد.

زیرنویس‌ها

- 1-Weight Survival Algorithm
- 2-Adaptive Weight
- 3-Survival Algorithm
- 4- Modified Weight Survival Algorithm
- 5-Net Input
- 6- Learning Automata
- 7- Fixed Structure Learning Automata
- 8- Variable Structure Learning Automata
- 9- Tsetlin
- 10- Stochastic
- 11-Linear Reward-Penalty
- 12- Linear Reward-Inaction
- 13-Weight Survival Algorithm
- 14-Adaptive Weight Survival Algorithm.
- 15- Modified Weight Survival Algorithm
- 16- Weight survival Algorithm
- 17-Modified weight survival algorithm
- 18- FarsDat
- 19-Time Delay
- 20- forgetting algrithm
- 21-selective algoritm

مراجع

- [1] Tin-Yau Kwok and Dit-Yan Yeung, "Constructive Algorithms for Structure Learning in Feedforward Neural Networks for Regression Problems," IEEE Trans. Neural Networks, vol. 8, NO. 3, pp. 630-645, MAY 1997.
- [2] M. C. Mozer and P. Smolensky, "Skeletonization: A Technique for Trimming the Fat from a network via Relevance Assessment," in Advances in Neural Information Processing (1), D.S. Touretzky, Ed. (Denver 1988), 1989, pp. 107-115.
- [3] B. E. Segee and M. J. Carter, "Fault Tolerance of Pruned Multilayer Networks," in Proc. Int. Joint Conf. Neural Networks, vol. II (Seattle), pp. 447- 452, 1991.
- [4] E. D. Karnin, "A Simple Procedure for Pruning Backpropagation Trained Neural Networks," IEEE Trans. Neural Networks, vol. 1, no. 2, pp. 239-242, 1990.
- [5] Y. Le Cun, J. S. Denker, and S. A. Solla, "Optimal Brain Damage," in Advances in Neural information Processing (2), D. S. Touretzky, Ed.(Denver 1989), 1990, pp. 598-605.
- [6] A. S. Weigend, D. E. Rumelhart, and B. A. Huberman, "Generalization by Weight-Elimination with Application to Forecasting," in Advances in Neural Information Processing (3), R. Lippmann, J. Moody, and D. Touretzky, Eds., 1991, pp. 875-882.
- [7] A. S. Weigend, D. E. Rumelhart, and B. A. Huberman, "Backpropagation, Weight-Elimination and Time Series Prediction," in Proc. 990 Connectionist Models Summer School, D. Touretzky, J. Elman, T. Sejnowski, and G. Hinton, Eds., 1990, pp. 105-116.
- [8] Y. Chauvin, "A Backpropagation Algorithm with Optimal Use of Hidden Units," in Advances In Neural Information (1), D. S. Touretzky, Ed. (Denver 1988), 1989, pp. 519-526.
- [9] S. J. Hanson and L. Y. Pratt, "Comparing Biases for Minimal Network Construction with backpropagation, "in Advances in Neural Information Processing (1), D.S. Touretzky, Ed. (D-enver 1988), 1989, pp. 177-185.
- [10] Y. Chauvin, "Dynamic Behavior of Constrained Backpropagation Networks," in Advances in Neural Information Processing (2), D. S. Touretzky, Ed. (Denver 1989), 1990, pp. 642- 649.
- [11] C. Ji, R. R. Snapp, and D. Psaltis, "Generalizing Smoothness Constrains from Discrete Samples," Neural Computation, vol. 2, no. 2, pp. 188-197, -1990.
- [12] D. C. Plaut, S. J. Nowlan, and G. E. Hinton, "E-xperiments on Learning by Backpropagation," T-ech. Rep. CMU-CS-86-126, Carnegie-Mellon U-niv., 1986.
- [13] S. J. Nowlan and G. E. Hinton, "Simplifying Neural Networks by Soft Weight-Sharing," Neural Computation, vol. 4, pp. 473-493, 1992.
- [14] Marco Muselli, "On Sequential Construction of-Binary Neural Networks, "IEEE Trans. Neural-Networks,vol. 6, no. 3, pp. 678-690,MAY. 1995.
- [15] Steven Young and Tom Downs, "CARVE-A Co-nstructive Algorithms for Real-Valued Example-s," IEEE Trans. Neural Networks, vol. 9, no. 6, pp. 1180-1190, NOV. 1998.
- [16] John O. Moody and Panos J. Antsaklis, "The De-pendence Identification Neural Network Constr-uction Algorithm," IEEE Trans. Neural Networ-ks, vol. 7, no. 1, pp. 3-15, Jan. 1996.
- [17] F. M. Frattale Mascioli and G. Martinelli, "A Constructive Algorithm for Binary Neural Net-works: The Oil-Sport Algorithm,"IEEE Trans. Neural Networks, vol. 6, no. 3, pp. 794-797, -MAY. 1995.
- [18] Rudy Setiono and Lucas Chi Kwong Hui,"Use of a Quasi-Newton Method in a Feedforward Neur-al Network Construction Algorithm," IEEE Tra-ns. Neural Networks, vol. 6, no. 1, pp. 273-277, JAN. 1995.
- [19] Nabhan T. M. and Zomaya A. Y., "Toward Neu-ral Networks Structure for Function Approximat-ion, "Neural Networks, vol. 7, no.1, pp. 89-99, 1993.
- [20] Hirose Y., Yamashita K.and Hijya S., "Backpro-pagation Algorithm which Varies The Number of Hidden Units," Neural Networks, vol. 4, no. 1, pp. 61-66, 1991.
- [21] J. D. Schaffer, D. Whitley and L. J. Eshelman, "Combination of Genetic Algorithms and Neural Networks: A Survey of the State of the Art,"IEEE Proc. COGANN-92, pp. 1-37, 1992.
- [22] V. Maniezzo, "Genetic Evolution of the Topolo-gy and Weight Distribution of Neural Networks-, " IEEE Trans. On Neural Networks, vol. 5, no. 1, pp. 39-53, 1994.
- [23] P. J. Angeline, G. M. Saunders and J. B. Pollack,"Evolutionary Algorithms that Construct Recur-rent Neural Networks," IEEE Trans. on Neural Networks, vol. 5, no. 1, pp. 54-65, 1994.
- [24] X. Yao and Y. Liu, "A New Evolutionary Syst-em for Evolving Artificial Neural Networks," IEEE Trans. On Neural Networks, vol. 8, no. 3, pp. 694-713, 1997.
- [25] D. Whitley and C. Bogart, "The Evolution of C-onnectivity: Pruning Neural Networks Using Genetic Lagorithms, " Proc. Of Int. Joint Conf. on Neural Networks, vol. 1, pp. 134, 1990.
- [26] Beigy. H. and Meybodi, M. R., "Optimization of Topology of Neural Networks Using Learning Automata," Proc. Of 4th Annual Int. Computer Society of Iran Computer Conf. CSICC-98, Teh-ran, Iran, pp. 417-428 (In Persian) 1999.(Also appear in Journal of Amirkabir)
- [27] M. B. Menhaj, "Computational Intelligence (vol. 1) Fundamentals of Neural Networks", Professor Hessabi

- Publication, IRAN, Tehran, 1998.
- [28] Y. Chauvin, "Generalization Performance of Overtrained Backpropagation Networks," in Neural Networks, Proc. EUROSIP Workshop, L. B. Al-Media and C. J. Wellekens, Eds., Feb. 1990, pp. 46-55.
 - [29] E. Levin, N. Tishby, and S. A. Solla, "A Statistical Approach to Learning and Generalization in Layered Neural Networks," Proc. IEEE, vol. 78, no. 10, pp. 1568-1574, Oct. 1990.
 - [30] D. B. Schwartz, V. K. Samalan, S. A. Solla, and J. S. Denker, "Exhaustive learning," Neural Computation, vol. 2, no. pp. 374-385, 1990.
 - [31] N. Tishby, E. Levin, and S. A. Solla, "Consistent Inference of Probabilities in Layered Networks: Predictions and Generalization," in Proc. Int. Joint Conf. neural Networks, 1989, p. 403.
 - [32] A. Blumer, A. Ehrenfeucht, D. Haussler, and M. Warmuth, "Learnability and the Vapnik-Chervonenkis Dimension," J. Ass. Comput. Mach., vol. 36, no. 4, pp. 929-965, 1989.
 - [33] A. Ehrenfeucht, D. Haussler, M. Kearns, and L. Valiant, "A General Lower Bound on the Number Of Examples Needed for Learning." In Proc. 1988 Workshop Computational Learning theory, 1988.
 - [34] L. G. Valiant, "A Theory of the Learnable," Commun. Ass. Comput. Mach., vol. 27, no. 11, pp. 1134-1142, 1984.
 - [35] K. S. Narendra and M. A. L. Thathachar, Learning Automata: An Introduction, Prentice Hall, Englewood Cliffs, 1989.
 - [36] M. R. Meybodi and S. Lakshminarayanan, "Optimality of a General Class of Learning Algorithm", Information science, Vol. 28, pp. 1-20, 1982.
 - [37] M. R. Meybodi and S. Lakshminarayanan, "On a Class of Learning Algorithm which have a Symmetric Behavior under Success and Failure", Springer Verlag Lecture Notes in Statistics, pp. 145-155, 1984.
 - [38] M. R. Meybodi, "Results on a Strongly Absolutely Expedient Learning Automata", Proc. Of OU Inference Conf. 86, ed. D. R. Moots and R. Butrick, Athens, Ohio: Ohio University Press, pp. 197-204.
 - [39] R. Reed, "Pruning algorithms-A Survey", IEEE Trans. Neural Networks, vol. 4, no. 5, pp. 740-747, Sept. 1993.
 - [40] Oommen, B. J. and Croix, E. V. de St. (1996). Graph Partitioning Using Learning Automata, IEEE Trans. On Computers, No. 45, No. 2, pp. 195-208.
 - [41] Oommen, B. J. and Ma, D. C. Y. (1988). Deterministic Learning Automata Solutions to the Equipartitioning Problem, IEEE Trans. On Computers, No. 37, No. 1, pp. 2-13.
 - [42] Oommen, B. J., Valiveti, R.S. and Zgierski, J. R. An Adaptive Learning Solution to the Keyboard Optimization Problem, IEEE Trans. On Systems, Man, and Cybernetics, Vol. 21, No. 6, pp. 1609-1618, (1991).
 - [43] Meybodi, M. R. and Beigy, H. (2000), "Neural Networks Engineering Using Learning Automata: Determining Optimal size for three layer Neural Networks" Proc. Of 5th Annual Int. Computer Society of Iran Computer Conf. CSICC-99, Tehran, Iran, pp. 431-450, Iran (In Persian). Also will appear in journal of Daneshkadeh Fanni, 2001.
 - [44] S. M. Ahadi, "Reduced Context Sensitivity in Persian Speech Recognition Via Syllable Modeling", Proceedings of The Eighth Australian International Conference on Speech Science and Technology, Cabberra, pp. 492-497, December 2000.
 - [45] Urs A. Muller, Anton Gunzinger and Walter Guggenbuh, "Fast Neural Net Simulation with a DSP Processor Array", IEEE Trans. On Neural Networks, Vol. 6, No. 1, pp. 203-213, January 1995.
 - [46] E. D. Karnin, "A simple procedure for pruning back-propagation trained neural networks," IEEE Trans. Neural Networks, Vol. 1, no. 2, pp. 239-242, 1990.
 - [47] M. Ishikawa, "A structural learning algorithm with forgetting of link weights, "Tech. Rep. TR-90-7, Electrotechnical Lab., Tsukuba-City, Japan, 1990.
 - [48] ___, "Neural Networks Engineering Using Learning Automata: Introducing an Adaptive Algorithm for Determining number of hidden Layer neurons for three layer neural networks", Proc. Of ICEE-2001, the 9th -Iranian Conference on Electrical Engineering, pp. 27: 1-27: 14, Power and Water Institute of Technology, Tehran, Iran, 2001 (In Persian).
 - [49] ___, "Adaptive VLRBP Using Learning Automata for Neural Network", Proc. Of WSES International Conference on: Neural Networks and Applications, pp. 280-286, Puerto De La Cruz, Tenerife, Canary Islands SPAIN February 11-15, 2001.
 - [50] ___, "Introducing an Adaptive VLRBP Algorithm Using Learning Automata for Multilayer Neural Network", accepted in IEICE (The Institute of Electronics, Information and Communication Engineers) Transactions on Information and Systems.
 - [51] ___, "Adaptive Survival Algorithm", submitted to engineering sciences journal, Iran University of Science & Technology, Narmak, TEHRAN.
 - [52] N. Baba and K. Sato, "A consideration on the Learning Algorithm of Neural Network", Proc. Of IEEE, 1998.