

جهت خرید فایل word به سایت www.kandoocn.com مراجعه کنید و یا با شماره های ۰۹۳۶۶۰۲۷۴۱۷ و ۰۹۳۰۳۵۲۲۸۸۶ تماس حاصل نمایید



www!

دانشگاه صنعتی امیر کبیر
(پلی تکنیک تهران)

بهبود سرعت یادگیری شبکه های عصبی چند لایه با الگوریتم پس انتشار خطأ

گردآورنده:

۸۳۱۲۳۱۳۹ مهدیه سادات سعدآبادی

شهریور ماه ۸۴

جهت خرید فایل word به سایت www.kandoocn.com مراجعه کنید و یا با شماره های ۰۹۳۶۰۲۷۴۱۷، ۰۹۳۶۶۰۲۷۴۸۶ و ۰۹۳۰۳۵۲۲۸۸۶ تماس حاصل نمایید



www.kandoochn.com

جهت خرید فایل word به سایت www.kandoocn.com مراجعه کنید و یا با شماره های ۰۹۳۶۰۲۷۴۱۷ و ۰۹۳۵۲۲۸۸۶ تماس حاصل نمایید

www.kanau-

www.kandooch.com

بهبود سرعت یادگیری شبکه های عصبی چند لایه با الگوریتم پس انتشار خطأ

www.kandooch.com

www.kandooch.com

www.kandooch.com

شبکه های عصبی چند لایه پیش خور^۱ به طور وسیعی در زمینه های متنوعی از قبیل طبقه بندی الگوهای پردازش تصاویر، تقریب توابع و ... مورد استفاده قرار گرفته است.

الگوریتم یادگیری پس انتشار خطای^۲، یکی از رایج ترین الگوریتم ها جهت آموزش شبکه های عصبی چند لایه پیش خور می باشد. این الگوریتم، تقریبی از الگوریتم بیشترین تنزل^۳ می باشد و در چارچوب یادگیری عملکردی^۴ قرار می گیرد.

عمومیت یافتن الگوریتم BP، بخاطر سادگی و کاربردهای موققیت آمیزش در حل مسائل فنی-مهندسی می باشد.

علیرغم، موققیت های کلی الگوریتم BP در یادگیری شبکه های عصبی چند لایه پیش خور هنوز، چندین مشکل اصلی وجود دارد:

- الگوریتم پس انتشار خطای، ممکن است به نقاط مینیمم محلی در فضای پارامتر، همگرا شود. بنابراین می شود، نمی توان مطمئن شد که به یک جواب بهینه رسیده زمانی که الگوریتم BP همگرا باشیم.

- سرعت همگرایی الگوریتم BP، خیلی آهسته است. از این گذشته، همگرایی الگوریتم BP، به انتخاب مقادیر اولیه وزنهای شبکه، بردارهای بایاس و پارامترها موجود در الگوریتم، مانند نرخ یادگیری، وابسته است.

انجام شده نیز نشان می دهد، الگوریتم های پیشنهادی نسبت به الگوریتم استاندارد BP، از سرعت همگرایی بالاتری برخوردار هستند.

خلاصه ای از الگوریتم BP

از قانون یادگیری پس انتشار خطأ (BP)، برای آموزش شبکه های عصبی چند لایه پیش خور که عموماً شبکه های چند لایه پرسپترون^۵ (MLP) هم نامیده می شود، استفاده می شود، استفاده می کنند. به عبارتی توپولوژی شبکه های MLP، با قانون یادگیری پس انتشار خطأ تکمیل می شود. این قانون تقریبی از الگوریتم بیشترین نزول (S.D) است و در چارچوب یادگیری عملکردی قرار می گیرد.

بطور خلاصه، فرایند پس انتشار خطأ از دو مسیر اصلی تشکیل می شود. مسیر رفت^۶ و مسیر برگشت^۷. در مسیر رفت، یک الگوی آموزشی به شبکه اعمال می شود و تأثیرات آن از طریق لایه های میانی به لایه خروجی انتشار می یابد تا اینکه

-
1. Multi-Layer Feedforward Neural Networks
 2. Back-Propagation Algorithm
 3. Steepest Descent (S.D)
 4. Performance Learning
 5. Multi Layer Perceptron
 6. Forward Path
 7. Backward Path

نهایتاً خروجی واقعی شبکه MLP، به دست می آید. در این مسیر، پارامترهای شبکه (ماتریس های وزن و بردارهای بایاس)، ثابت و بدون تغییر در نظر گرفته می شوند.

بر اساس قانون یادگیری اصلاح خطای^۱ انجام می گیرد. سیگنال خطای ردلایه خروجی شبکه تشکیل می گردد. بردار خطای برابر با اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه می باشد. مقدار خطای پس از محاسبه، در مسیر برگشت از لایه خروجی و از طریق لایه های شبکه به سمت پاسخ مطلوب حرکت کند.

در شبکه های MLP، هر نرون دارای یک تابع تحریک غیر خطی است که از ویژگی مشتق پذیری برخوردار است. در این حالت، ارتباط بین پارامترهای شبکه و سیگنال خطای، کاملاً پیچیده و غیر خطی می باشد، بنابراین مشتقات جزئی نسبت به پارامترهای شبکه به راحتی قابل محاسبه نیستند. جهت محاسبه مشتقات از قانون زنجیره ای^۲ معمول در جبر استفاده می شود.

فرمول بندی الگوریتم BP

الگوریتم یادگیری BP، بر اساس الگوریتم تقریبی SD است. تنظیم پارامترهای شبکه، مطابق با سیگنالهای خطای که بر اساس ارائه هر الگو به شبکه محاسبه می شود، صورت می گیرد. الگوریتم بیشترین تنزل با معادلات زیر توصیف می شود:

$$W^L ji(K+1) = Wji^L(K) - \alpha \frac{\delta F}{\delta W^L ji(k)} \quad (1)$$

$$b^L j(K+1) = bj^L(K) - \alpha \frac{\delta F}{\delta bj^L(k)} \quad (2)$$

به طوری $W^L ji$ و $b^L j$ ، پارامترهای نرون زام در لایه i است. α ، نرخ یادگیری^۳ و F ، میانگین مربعات خطای می باشد.

$$\delta W^L ji(k)$$

$$\frac{\delta F(k)}{\delta b^L j(k)} = S^L j(k) \quad (4)$$

$$S^L j(k) = \frac{\delta F(K)}{\delta b^L j(K)} = \left[\sum_{m=1}^{S^{L+1}} S_m^{l+1}(k) W_{mj}^{l+1}(k) \right] f^L(N_j^L(k)) \quad (5)$$

به طوریکه $S^L j(k)$ ، حساسیت رفتار شبکه در لایه L است.

1. Error-Correcting Learning Rule

2. Chain Rule

3. Learning Rate

معايير الگوریتم استاندارد پس انتشار خطأ^۱ (SBP)

الگوریتم BP، با فراهم آوردن روشی از نظر محاسباتی کارا، رنسانسی در شبکه های عصبی ایجاد نموده

زیرا شبکه های MLP، با قانون یادگیری BP، بیشترین کاربرد را در حل مسائل فنی- مهندسی دارند.

با وجود، موفقیت های کلی این الگوریتم در یادگیری شبکه های عصبی چند لایه پیش خود، هنوز

مشکلات اساسی نیز وجود دارد:

- اولاً سرعت همگرایی الگوریتم BP آهسته است.

همانطور که می دانیم، تغییرات ایجاد شده در پارامترهای شبکه (ماتریس های وزن و بردارهای بایاس)،

پس از هر مرحله تکرار الگوریتم BP، به اندازه $\alpha \nabla F(x(k))$ ، است، به طوریکه F، شاخص اجرایی، x

پارامترهای شبکه و α ، طول قدم یادگیری است.

از این، هر قدر طول قدم یادگیری، α ، کوچکتر انتخاب گردد، تغییرات ایجاد شده در پارامترهای شبکه،

پس از هر مرحله تکرار الگوریتم BP، کوچکتر خواهد بود، که این خود منجر به هموار گشتن مسیر

الگوریتم BP می گردد. بر عکس با افزایش طول قدم α ، اگرچه نرخ یادگیری و سرعت یادگیری

الگوریتم BP افزایش می یابد، لیکن تغییرات فاحشی در پارامترهای شبکه از هر تکرار به تکرار بعد ایجاد

می گردد، که گاهی اوقات موجب ناپایداری و نوسانی شدن شبکه می شود که به اصطلاح می گویند

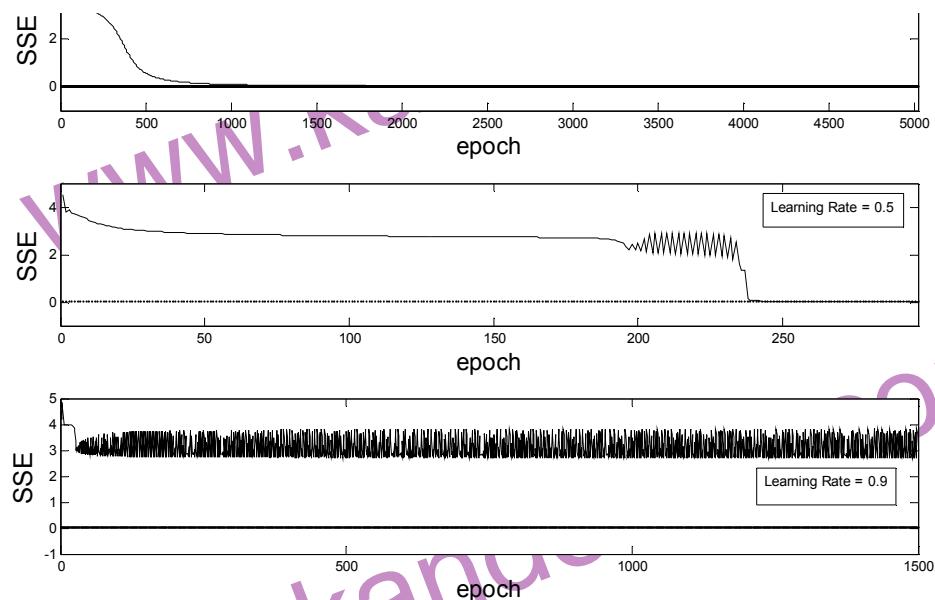
پارامترهای شبکه واگرا شده اند:

در شکل زیر، منحنی یادگیری شبکه برای جدا سازی الگوهای XOR، به ازای مقادیر مختلف نرخ

یادگیری، نشان داده شده است. به ازای مقادیر کوچک α ، شبکه کند اما هموار، یاد نمی گیرد الگوهای

XOR را از هم جدا نماید، در صورتی که به ازای $\alpha = 0.9$ شبکه واگرا می شود.

1. Standard Back-Propagation Algorithm



شکل (۱). معنی یادگیری شبکه برای نرخ های یادگیری مختلف در مسئله XOR

- ثانیاً احتمالاً به دام افتادن شبکه در نقاط مینیمم محلی وجود دارد.

در شبکه های MLP، میانگین مجوز خطأ، در حالت کلی خیلی پیچیده است و از تعداد زیادی نقطه اکسترمم در فضای پارامترهای شبکه بروخوردار می باشد. بنابراین الگوریتم پس انتشار خطأ با شروع از روی یک سری شرایط اولیه پارامترهای شبکه، به نقطه مینیمم سراسری و با شروع از یک مجموعه شرایط اولیه دیگر به نقاط مینیمم محلی در فضای پارامترها همگرا می گردد، بنابراین زمانی که الگوریتم BP همگرا می شود، نمی توان مطمئن شد که به یک جواب بهینه رسیده باشیم.

- ثالثاً: همگرایی الگوریتم BP، به یقین مقادیر اولیه پارامترهای شبکه عصبی MLP وابسته است، بطوری که یک انتخاب خوب می تواند کمک بزرگی در همگرایی سریعتر الگوریتم BP فراهم آورد.

در فضای برداری پارامترهای شبکه می گردد که این خود منجر به این می شود که شبکه خیلی زودتر از

معمول به موضعی بیفتند که منحنی یادگیری شبکه برای تعداد بزرگی از دفعات تکرار، تغییر نکند.

به عنوان مثال، فرض می کنیم مقدار اولیه پارامترهای شبکه خیلی بزرگ باشند، در حالی که می دانیم

توابع تبدیل نرونها مخصوصاً در لایه های میانی از نوع زیگموئید هستند. در این حالت برای

نرون i ، اندازه ورودی تابع تبدیل (n_i) خیلی بزرگ می باشد و خروجی نرون (a_i) به مقدار $1 \pm \text{میل}$

می کند. لذا مشتق بردار خروجی شبکه، $\frac{d}{dt}a_i$ ، خیلی کوچک می باشد. فرض کنیم که باید مقدار واقعی

a_i باشد یعنی $1 = a_i$ ، لیکن به خاطر انتخاب بر مقادیر اولیه، $1 - a_i$ گردد. در این حالت خطای

حداکثر را داریم در حالی که چون $0 \approx a_i$ می باشد تغییرات ناچیزی در پارامترهای متناظر با

نرون i ام داریم. این چیزی است که بیانگر رسیدن زودتر از معمول نرونها به حد اشباع خود می باشند،

جایی که پاسخ واقعی با پاسخ شبکه کاملاً فرق دارد و زمان زیادی طول خواهد کشید که نرون از این

حالت خارج شود. از این رو با پیشرفت پروسه یادگیری، پارامترهای متنسب به نرونها یی که به مرز

اشباع رسیده اند، سریعتر تنظیم می شوند، چرا که سیگنال خطای خود را از مقدار از اندازه

بزرگتری برخوردار می باشند. این عمل منجر به کاهش در مجموع مربعات خطای لحظه ای می

گردد و اگر در این مرحله، نرونها به حد اشباع رسیده تغییری در وضعیت تحریکشان رخ ندهد، شبکه

برای مدتی طولانی از یک شکل هموار منحنی خطای برخوردار خواهد بود.

بهمود الگوریتم استاندارد پس انتشار خطای (SBP)

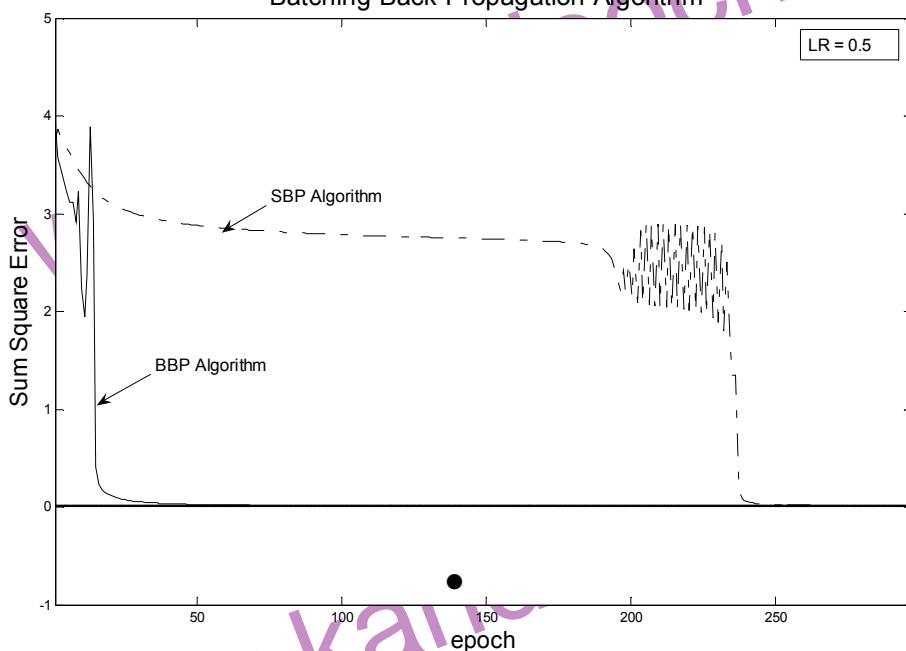
- الگوریتم BP از نوع دسته ای^۱ (BBP)

الگوریتم استاندارد BP، بر اساس فرم الگو به الگو است، بدین ترتیب که پارامترهای شبکه پس از ارائه

هریک از الگوهای یادگیری که عموماً بطور تصادفی انتخاب می شوند، تنظیم می گردند، اما در

دسته ای موجب می شود که گرادیانهای محلی به گرادیان محلی واقعی نزدیکتر باشند و نهایتاً الگوریتم BP به الگوریتم بیشترین نزول نزدیکتر گردد که این خود موجب می شود همگرایی الگوریتم BP افزایش یابد.

در شکل زیر مسئله XOR با متدهای BP و SBP مورد مقایسه قرار دارد. به راحتی می توان دید که الگوریتم BBP از سرعت همگرایی بالاتری به الگوریتم SBP برخوردار است.



شکل (۲). رفتار شبکه با الگوریتم BBP در مسئله XOR (—) و رفتار شبکه با الگوریتم SBP (---)

1. Batching Back-Propagation Algorithm

- روش ممتد^۱ برای الگوریتم BP (MBP)

الگوریتم SD است، بسیار کند می گردد. و اگر α ، بزرگتر انتخاب شود، شبکه نوسانی خواهد بود.

یک راه ساده و مؤثر که عموماً جهت افزایش و بهبود نرخ یادگیری، استفاده می شود- جایی که خطر

ناپایداری و نوسانی شدن شبکه جلوگیری می گردد- افزودن یک جمله ممتنم در الگوریتم تقریبی SD

می باشد، یعنی به هر پارامتر از شبکه MLP، یک مقدار اینرسی یا اندازه حرکت اضافه می شود تا اینکه

پارامتر مورد نظر در مسیری تمايل به تغییر داشته باشد که کاهش تابع انرژی احساس شود.

الگوریتم یادگیری MBP با معادلات زیر قابل توصیف است:

$$(6) \Delta W^L(k) = \delta \Delta w^L(k-1) - \beta \delta^L(a^{L-1})^T$$

$$(7) \Delta b^L(k) = \delta \Delta b^L(k-1) - \beta \delta^L$$

جایی که $(\alpha, \delta) \in \mathbb{R}^2$ ، ترم ممتنم را نشان می دهد و عموماً با نرخ یادگیری α ، به صورت زیر رابطه

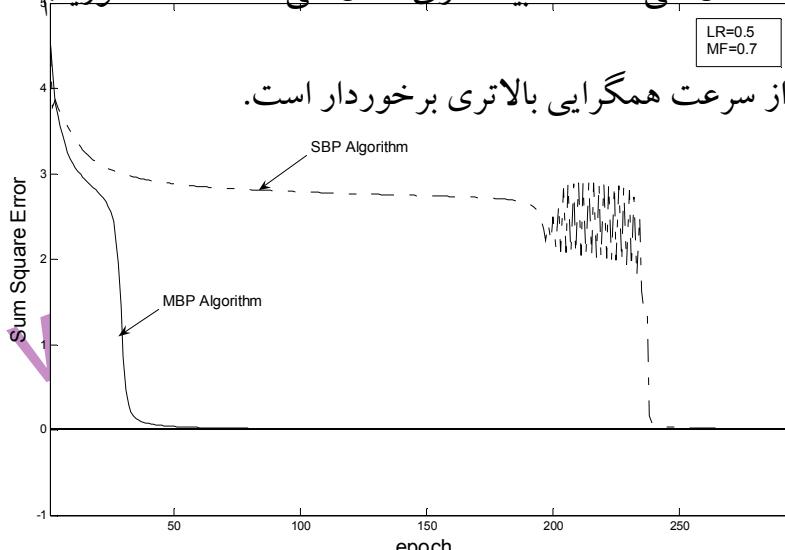
دارد:

$$(8) \beta = \alpha(1-\delta)$$

معادلات فوق، ترم های اصلاحی پارامترهای شبکه را از فیلتر پایین گذر عبور می دهند و این یعنی

تغییرات با فرکانس بالا (носانات شدید) فیلتر می شوند. شکل (۳)، مسئله XOR را که به وسیله الگوریتم

MBP، پیاده شده است، نشان می دهد. با مقایسه با الگوریتم Back-Propagation Algorithm with the Momentum Factor (BP)، این مسئله می تواند با سرعت همگرایی بالاتری برخوردار است.



الگوریتم استاندارد BP از سرعت همگرایی بالاتری برخوردار است.

www.kanau-

شکل (۳)؛ رفتار شبکه با الگوریتم MBP در مسأله XOR (—) رفتار شبکه با الگوریتم SBP (—).

1. Momentum

- نرخ یادگیری متغیر^۱ (VLR)

در الگوریتم BP استاندارد، نرخ یادگیری در طول فرآیند یادگیری ثابت نگه داشته می شود. عملکرد الگوریتم به انتخاب مناسب نرخ یادگیری خیلی حساس می باشد. اگر نرخ یادگیری خیلی بزرگ انتخاب شود ممکن است الگوریتم نوسان کرده و ناپایدار شود. اگر نرخ یادگیری خیلی کوچک باشد زمان زیادی طول خواهد کشید تا الگوریتم همگرا شود. انتخاب نرخ یادگیری اپتیمم قبل از یادگیری، عملی نبوده و در حقیقت نرخ یادگیری اپتیمم به هنگام پروسه آموزش، همچنان که الگوریتم بر روی سطح خطای حرکت می کند دائمًا تغییر می کند.

اگر اجازه دهیم نرخ یادگیری به هنگام پروسه آموزش تغییر کند عملکرد الگوریتم BP استاندارد را می توان بهبود بخشید. نرخ یادگیری تطبیقی سعی می کند که نرخ یادگیری را تا آنجایی که ممکن است و سیستم ناپایدار نشده است، افزایش دهد.

نرخ یادگیری تطبیقی نیاز به تغییراتی در الگوریتم BP استاندارد دارد.

VLR Algorithm

Initialize Neural Network Weights and Biases.

Set Training Parameters.

```
for i = 1: N  
; break, end $\varepsilon$       if SSE <  
    Feed forward Path;  
    Backward Path;  
    Compute New Weights and Biases;
```

Compute new-SSE

```
if new-SSE > SSE * max - perf-inc  
     $\alpha$  =  $\alpha$  * Lr-dec; % Learning Rate  
     $\delta$  = 0 ; % Momentum Factor
```

else

```
    if new-SSE < SSE  
         $\alpha$  =  $\alpha$  * Lr-inc;  
    end
```

Compute New Weights and Biases

end

end

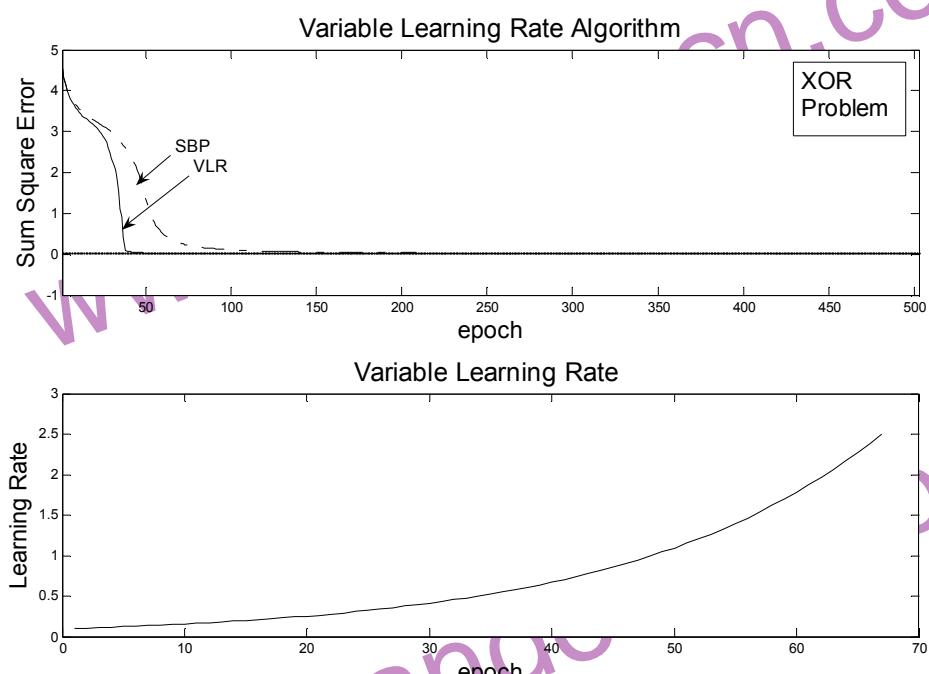
1. Variable Learning Rate

معمولًاً مقادیر ۰.۰۷، ۰.۱۰۴ و ۰.۱۰۵ به ترتیب برای ضرائب α ، $\max - \text{perf} - \text{inc}$ و $\text{Lr} - \text{dec}$ به نظر گرفته می شود.

نگردد. بنابرین، یک نرخ یادگیری نزدیک به بهینه بدست می آید.

الگوریتم VLR بر روی مسئله XOR پیاده شده است. شبیه سازی نسان می دهد، که سرعت یادگیری این الگوریتم را از الگوریتم SBP، بیشتر است.

نتایج شبیه سازی در شکل (۴) نشان داده شده است.



شکل (۴). - رفتار شبکه با الگوریتم VLR برای مسئله XOR (—)

رفتار شبکه با الگوریتم SBP (· · ·)

- تغییرات نرخ یادگیری (α) در کل فرآیند یادگیری برای مسئله XOR

در این، خلاصه ای از نتایج مقالات مورد بررسی، جهت بهبود الگوریتم یادگیری پس انتشار خطأ، ذکر

می گردد:

اگر از نرخ یادگیری کوچک استفاده شود، این مسئله می تواند سبب نرخ پائین همگرایی. به منظور جلوگیری از این پدیده نامطلوب، یک راه حل، استفاده از نرخ یادگیری می باشد. این راه حل بویژه در موقعی که در نقطه ای از سطح قرار داریم که شیب تندی دارد، نامطلوب بوده و می تواند باعث واگرایی شبکه شود.

-
1. Maximum Performance Increase
 2. Learning Rate decrease
 3. Learning Rate increase

موقعی که شکل سطح خطا از سطح خطای درجه دوم خیلی فاصله داشته باشد، در اینصورت سطح خطا، شامل مناطق با شیب تند زیادی خواهد بود. در این صورت الگوریتم BP با نرخ یادگیری ثابت دارای راندمان پائینی می باشد، دلیل این مسئله این است که به منظور جلوگیری از نوسان در مناطقی که سطح خطای دارای شیب زیادی است بایستی نرخ یادگیری کوچک انتخا شود، در نتیجه بردار وزن، موقعی که در مناطق مسطح قرار داریم به دلیل کوچک بودن گرادیان، خیلی کند حرکت خواهد کرد. بنابراین نیاز به یک الگوریتم یادگیری کارآمد می باشد تا بتواند بطور پویا نرخ یادگیری را تغییر دهد.

- الگوریتم پس انتشار خطای تطبیقی^۱ (ABP)

در الگوریتم پس انتشار خطای تطبیقی، نرخ یادگیری، بطور، اتوماتیک و بر اساس خطای آموزش تنظیم می گردد. [۱]

ایده اصلی از الگوریتم پس انتشار خطای تطبیقی آن است که:

$$\frac{\delta F}{\delta W}$$

خطای جدید نسبت به خطای قبلی، افزایش یافته است و تکرار جاری با ارزش نیست.

لذا نرخ یادگیری را بایستی کاهش داد.

- اگر علامتهاي امتداد گراديان $\frac{\delta F}{\delta W}$ در طول دو تکرار متواли، يكسان باشند، دليل بر اين امر است که

نرخ تنزل آهسته است و نرخ یادگیری را بایستی افزایش داد.

ایده فوق را می توان با معادلات زیر، توصیف کرد:

$$(8) \Delta\alpha(K) = \varepsilon\lambda\alpha(K - 1)$$

به طوری که $0.1 \leq \varepsilon \leq 0.01$ را به صورت زیر، تعریف می شود:

$$(9) \lambda = \text{Sign} \left(\frac{\delta F(K)}{\delta W(K)} \cdot \frac{\delta F(K - 1)}{\delta W(K - 1)} \right)$$

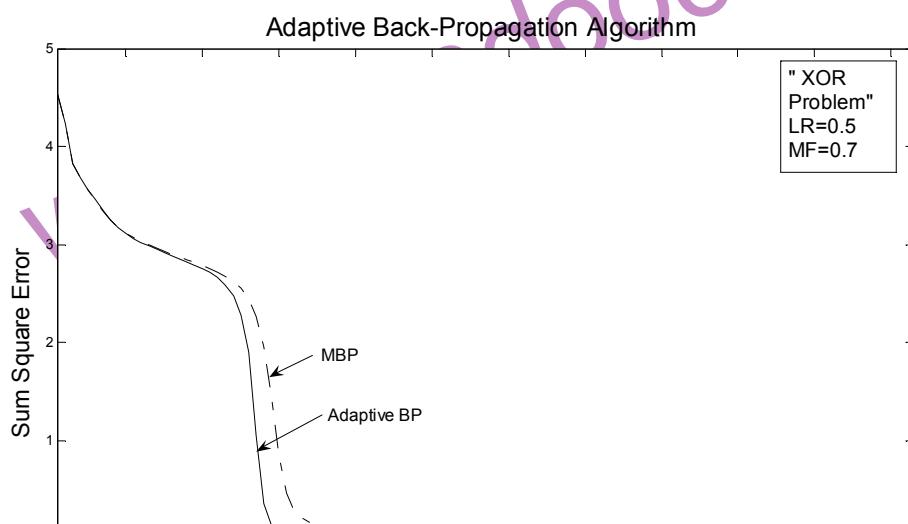
مشخص است که زمانی که $\lambda > 0$ ، نرخ یادگیری افزایش می یابد.

الگوریتم BP تطبیقی با معادلات زیر بیان می شود:

$$(10) W(k + 1) = W(k) - \alpha(k) \frac{\delta F(k)}{\delta W(k)} + \delta\Delta w(k - 1)$$

شکل (۵)، رفتار شبکه را با قانون یادگیری فوق، جهت جداسازی الگهای XOR، نشان می دهد.

1. Adaptive Back-Propagation Algorithm



www.kanau-

شکل (۵). منحنی یادگیری الگوریتم BP تطبیقی برای XOR

- الگوریتم پس انتشار خطاب نرخ یادگیری و ضریب ممتنم تطبیقی (BPALM)

در این الگوریتم نرخ یادگیری و ضریب ممتنم در هر سیکل به طور تطبیقی تنظیم می شوند تا به همگرایی الگوریتم BP استاندارد بخوبی بخشدید شود [۲].

در ابتدا، فاکتور نسبی $e_r(k)$ ، به صورت زیر تعریف می شود:

$$(11) e_r(k) = \frac{\Delta F(k)}{f(k)} = \frac{F(k) - F(k-1)}{F(k)}$$

اصلاح و تنظیمات نرخ یادگیری و ضریب ممتنم به صورت زیر انجام می گیرد:

Case 1: for $e_r(k) < 0$

$$\alpha(k+1) = \alpha(k) [1 + ue^{-er(k)}]; \quad u \in (0,1) \quad (12a)$$

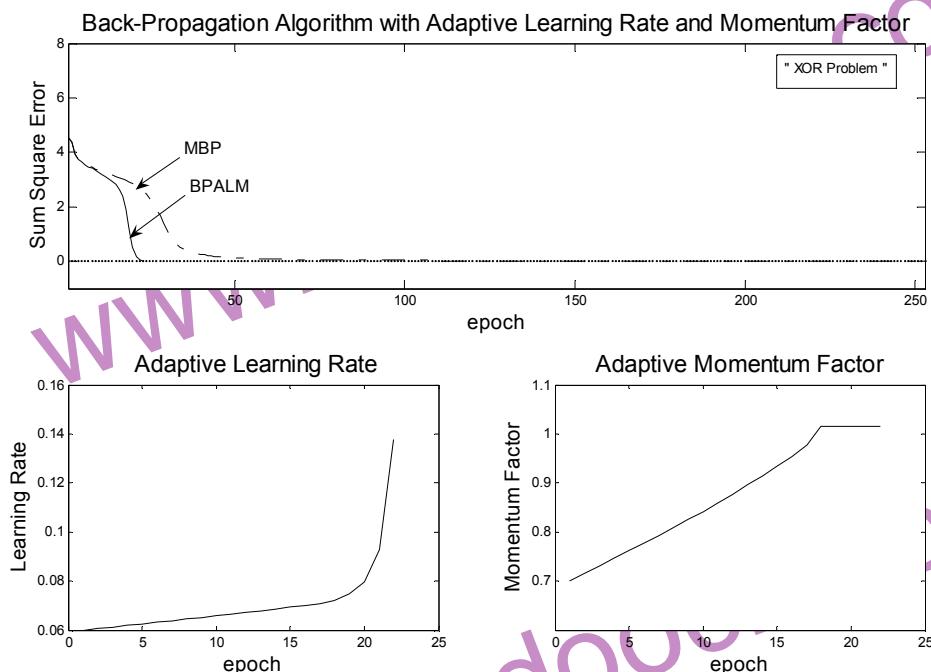
$$\delta(k+1) = \delta(k) [1 + ve^{-er(k)}]; \quad v \in (0,1) \quad (12b)$$

Case 2: for $e_r(k) \geq 0$

$$\alpha(k+1) = \alpha(k) [1 - ue^{-er(k)}]; \quad u \in (0,1) \quad (13a)$$

$$\delta(k+1) = \delta(k) [1 - ve^{-er(k)}]; \quad v \in (0,1) \quad (13b)$$

1. Back- Propagation with Adaptive Learning rate and Momentum term
 شکل زیر، عملکرد شبکه را با قانون یادگیری BPALM، جهت جداسازی الگوهای XOR، نشان می دهد.



شکل (۶). - منحنی یادگیری الگوریتم BPALM در مسأله XOR

- تغییرات نرخ یادگیری

- تغییرات خصربیب ممتنم

- تغییرات علامت^۱

بر اساس این الگوریتم، اگر علامت مشتق شاخص اجرایی نسبت به پارامترهای شبکه دردود تکرار متوالی

تغییر نکند، نرخ یادگیری افزایش می یابد و در غیر اینصورت، نرخ یادگیری کاهش می یابد. [6]

$$\alpha_{ji}(k) = \alpha_{ji}(k-1).u$$

$$(14 \text{ a}) \frac{\delta F(k)}{\delta W_{ji}(k)} \cdot \frac{\delta F(k-1)}{\delta W_{ji}(k-1)} \geq 0$$

$$\alpha_{ji}(k) = \alpha_{ji}(k-1).u$$

$$(14 \text{ b}) \frac{\delta F(k)}{\delta W_{ji}(k)} \cdot \frac{\delta F(k-1)}{\delta W_{ji}(k-1)} < 0$$

آبگاه، اصلاح وزن بر اساس معادله زیر، انجام می گیرد:

$$(15) \Delta W_{ji}(k) = -\alpha_{ji}(k) \frac{\delta F(k)}{\delta W_{ji}(k)} + \delta \Delta W_{ji}(k-1)$$

معموماً مقادیر ۱.۱-۱.۳ برای u و ۰.۷-۰.۹ برای d ، به کار بردہ می شود.

1. Sign Changes

بر اساس این الگوریتم، اگر علامت مشتق شاخص اجرایی، نسبت به پارامترهای شبکه در دو تکرار متوالی

تغییر نکند و نرخ یادگیری از مقدار حداقلی، کمتر باشد، آنگاه افزودن یک مقدار ثابت به نرخ

یادگیری، نرخ یادگیری افزایش می یابد. اگر علامت مشتق شاخص اجرایی نسبت به پارامترهای شبکه

در دو تکرار متوالی تغییر کند، نرخ یادگیری با ضرب شدن در مقدار کوچکتر، کاهش می یابد و در غیر

اینصورت تغییری در نرخ یادگیری نخواهیم داشت. [6]

عبارت فوق را می توان با روابط زیر توصیف کرد:

$$\alpha_{ji}(k) = \alpha_{ji}(k-1)+u$$

$$(16 \text{ a}) \frac{\delta F(k)}{\delta W_{ji}(k)} \cdot \frac{\delta F(k-1)}{\delta W_{ji}(k-1)} \geq 0, (\alpha_{ji}(k-1) \leq \alpha_{max})$$

if

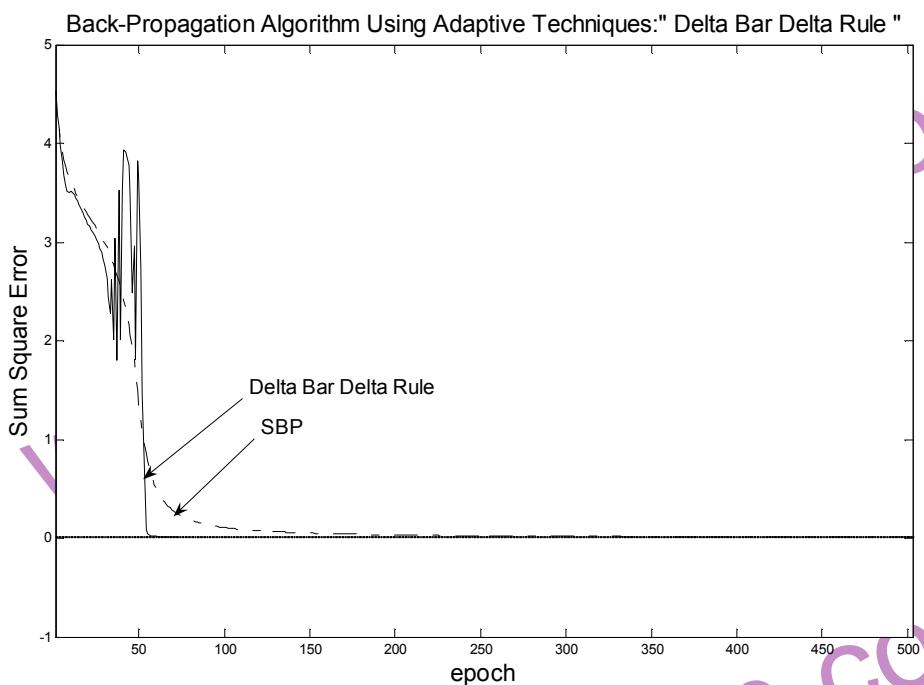
$$\alpha_{ji}(k) =$$

$$(16 \text{ b}) \frac{\delta F(k)}{\delta W_{ji}(k)} \cdot \frac{\delta F(k-1)}{\delta W_{ji}(k-1)} \leq 0$$

$$\alpha_{ji}(k-1).d$$

$$\alpha_{ji}(k-1) \quad \text{if } \delta W_{ji}(k) > \delta W_{ji}(k-1)$$

شکل زیر، منحنی یادگیری الگوریتم فوق را برای جداسازی الگوهای XOR نشان می دهد.



شکل (V). منحنی یادگیری الگوریتم *Delta Bar Delta Rule* در مسئله XOR

- الگوریتم یادگیری Super SAB

این الگوریتم، مانند الگوریتم قبل می باشد با این تفاوت که اگر علامت تغییرات مشتق شاخص اجرایی

نسبت به پارامترهای شبکه در دو تکرار متوالی تغییر نکند و نرخ یادگیری از مقدار حداقلی کمتر باشد،

نرخ یادگیری با ضرب شدن در یک پارامتر ثابتی، افزایش می یابد [6].

if

$$\alpha_{ji}(k) = \frac{\delta F(k)}{\delta W_{ji}(k)} \cdot \frac{\delta F(k-1)}{\delta W_{ji}(k-1)} \leq 0 \quad (17\ b)$$

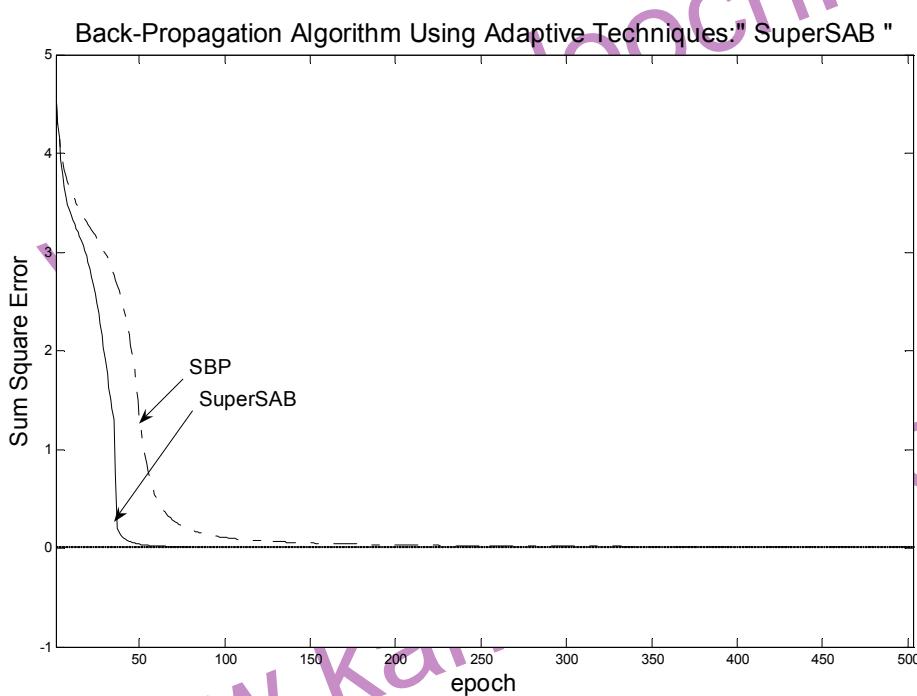
$$\alpha_{ji}(k-1).d \quad \text{if}$$

$$\alpha_{ji}(k) = \frac{\delta F(k)}{\delta W_{ji}(k)} \cdot \frac{\delta F(k-1)}{\delta W_{ji}(k-1)} > 0 \quad (17\ c)$$

$$\alpha_{ji}(k-1) \quad \text{if}$$

مقادیر پیشنهادی بر $u = 1.05$ و $d = 0.5$ می باشد. α_{max} عددی بین ۰,۱ است.

از الگوریتم مطرح شده، برای جداسازی الگوهای XOR، استفاده شده است. در شکل (۸)، منحنی یادگیری این الگوریتم را نشان می دهد.



شکل (۱). منحنی یادگیری الگوریتم Super SAB برای مسئله XOR

در این الگوریتم، ترم جدیدی به نام ضریب تناسبی^۱ (PF)، به الگوریتم استاندارد پس انتشار خطأ اضافه شده است. [3]

افزایش سرعت یادگیری، همراه با حفظ سادگی اگوریتم BP، هدف اصلی این مقاله است.

الگوریتم مطرح شده را می توان با معاله زیر توصیف کرد:

$$(18) \Delta W(k) = -\alpha \nabla F(W(k)) + \delta \Delta W(k-1) + ce(W(k))$$

بطوری که C، ضریب تناسبی (PF) می باشد.

$e(W(k))$ ، اختلاف بین خروجی مطلوب و خروجی واقعی در تکرار k ام است.

الگوریتم فوق، در ای سه ترم است:

۱- ترمی که متناسب با مشتق $F(W(k))$ است.

۲- ترمی که متناسب با مقادیر قبلی تغییرات وزن هاست.

۳- ترمی که متناسب با $e(W(k))$ است.

بنابراین، مشاهده می شود که این سه ترم، همانند ضرایب کنترل کننده PID، که به طور متداول در

کاربردهای کنترلی استفاده می شوند، عمل می کنند.

آنالیز همگرایی

در این قسمت، الگوریتم BP با سه ترم، آنالیزو تحلیل می شود و نشان داده می شود که نقاط مینیمم

محلی تابع حداقل مربعات خطأ، تنها نقاط پایدار مجازیم محلی الگوریتم هستند.

معادله (18) را می توان به صورت زیر، بازنویسی کرد:

فرض کنید آنگاه یک تحقق متغیر حالت معادله $x_2(k) = W(k) - W(k-1)$, $x_1(k) = W(k)$

(19)، چنین است:

$$(20a) x_1(k+1) = x_2(k) - \alpha \nabla F(x_1(k)) + \delta x_2(k) + Ce(x_1(k))$$

$$(20b) x_2(k+1) = -\alpha \nabla F(x_1(k)) + \delta x_2(k) + Ce(x_1(k))$$

لم (1):

یک نقطه تعادل از سیستم یا معادلات (20a), (20b) است، اگر $m = (m_1, m_2)$

$$m_2 = 0, \alpha \nabla F(x_1(k)) = Ce(x_1(k))$$

1. Proportional Factor

اثبات:

اگر $m = (m_1, m_2)$ یک نقطه تعادل است، آنگاه

$$x_1(k) = m_1, x_2(k) = m_2$$

و

$$x_1(k+1) - x_1(k) = 0$$

$$x_2(k+1) - x_2(k) = 0$$

با جایگذاری در معادلات (20b), (20a)، خواهیم داشت:

$$(21a) (1-\delta)x_2(k) = -\alpha \nabla F(x_1(k)) + Ce(x_1(k))$$

$$(21b) -\delta x_2(k) = -\alpha \nabla F(x_1(k)) + Ce(x_1(k))$$

→

با کم کردن معادله (21b) از معادله (21a)، نتیجه می شود:

$$x_2(k) = 0 \quad m_2 = 0$$

و با جایگذاری $x_2(k) = 0$ در معادله (21a) و یا (21b)، عبارت زیر به دست می آید:

تذکر(۱): از آنجاییکه $m = (m_1, m_2)$, (20a), (20b) است و

$$F(x_1(k)) = 0 \quad \nabla F(x_1(k)) = 0$$

ویژگی پایداری محلی، حول نقطه تعادل (m_1, m_2) می تواند با استفاده از آنالیزهای سیگنال کوچک، امتحان شود.

فرض کنید سیگنال های آشفته به صورت زیر تعریف شوند:

$$\Psi_1 = x_1 - m_1, \Psi_2 = x_2 - m_2$$

آنگاه معادلات حالت به فرم زیر تبدیل می شوند:

$$(23a) \Psi_1(k+1) = \Psi_1(k) - \alpha \nabla F(m_1 + \Psi_1(k)) + \delta \Psi_2(k) + Ce(m_1 + \Psi_1(k))$$

$$(23b) \Psi_2(k+1) = -\alpha \nabla F(m_1 + \Psi_1(k)) + \delta \Psi_2(k) + Ce(m_1 + \Psi_1(k))$$

با خطی سازی حول محور تعادل m ، معادلات (23a) و (23b) به صورت زیر خواهد بود:

$$(24a) \Psi_1(k+1) \approx \Psi_1(k) - \alpha \nabla^2 F(m_1)(\Psi_1(k)) + \delta \Psi_2(k) + C \nabla e(m_1)(\Psi_1(k))$$

$$(24b) \Psi_2(k+1) \approx -\alpha \nabla^2 F(m_1)(\Psi_1(k)) + \delta \Psi_2(k) + C \nabla e(m_1)(\Psi_1(k))$$

$$\nabla^2 F(m_1) = A \in IR^{Q \times Q}$$

$$\nabla e(m_1) = D \in IR^{Q \times Q}$$

بطوریکه Q ، سایز بردار وزن است.

آنگاه:

$$\begin{bmatrix} \Psi_1(k+1) \\ \Psi_2(k+1) \end{bmatrix} = \begin{bmatrix} I - \alpha A + CD & CI \\ -\alpha A + CD & CI \end{bmatrix} \begin{bmatrix} \Psi_1(k) \\ \Psi_2(k) \end{bmatrix} \quad (25)$$

معادله ماتریسی بالا، می تواند به صورت زیر نوشته شود:

$$(26) \Psi(k+1) = \theta \Psi(k)$$

(Ψ_1) باشد و هر مقدار ویژه (Ψ_1) در شرط رو به رو صدق کند:

$$|\Psi_1| < 1$$

لم (۲):

اگر λ یک مقدار ویژه تابع $E = \left(\frac{A}{C} - \frac{D}{\alpha}\right)$ باشد، جایی که آنگاه مقادیر ویژه متناظر با ماتریس θ ،

توسط جوابهای معادله درجه دوم زیر بدست می‌آیند:

$$(27) \Psi^2 - \Psi(1 + \delta - \alpha\lambda C) + \delta = 0$$

اثبات:

ماتریس θ برای هر $A, D, \alpha \neq 0$ ، معکوس پذیر است. فرض کنید Ψ ، یک مقدار ویژه θ باشد و آن

غیر صفر است (زیرا θ ناویژه^۱ است).

فرض کنید که $\underline{Z} = (x, y)$ ، بردار ویژه غیر صفر متناظر با مقدار ویژه Ψ است. آنگاه:

$$\theta \underline{Z} = \Psi \underline{Z} \quad (28)$$

$$x - \alpha Ax + CDx + \delta y = \Psi x \quad \text{که منجر می‌شود به:}$$

$$(29)$$

و

$$-\alpha Ax + CDx + \delta y = \Psi y \quad (30)$$

با کم کردن معادله (30) از معادله (29)، خواهیم داشت:

$$(31) x = \Psi x - \Psi y \rightarrow \left(\frac{\Psi - 1}{\Psi}\right)x = y$$

با جایگذاری معادله (31) در معادله (30)، خواهیم داشت:

با انتخاب $E = \frac{A}{C} - \frac{D}{\alpha}$ و جایگذاری در معادله (32)، رابطه زیر بدست می آید:

$$(33) Ex = \left(\frac{(\Psi - 1) - \frac{\delta(\Psi - 1)}{\Psi}}{-\alpha C} \right) X$$

1. Non - singular

از آنجایی که $X = (\frac{(\Psi - 1) - \frac{\delta(\Psi - 1)}{\Psi}}{-\alpha C}) E$ ، اسکالر و غیر صفر است، اگر بردار X در این معادله صدق کند،

$Ex = \lambda x$ x یک بردار ویژه ماتریس E است. آنگاه:

(34)

با مقایسه معادلات (33) و (34)، معادله زیر بدست خواهد آمد:

$$(35) \lambda = \left(\frac{(\Psi - 1) - \frac{\delta(\Psi - 1)}{\Psi}}{-\alpha C} \right) X$$

با مرتب کردن معادله (35)، خواهیم داشت:

$$\Psi^2 - \Psi(1 + \delta - \alpha\lambda C) + \delta = 0 \quad (36)$$

الف. تست پایداری جوری:

تست جوری، برای آنالیز معادلات از هر مرتبه، به کار می رود. معادله (36)، یک معادله درجه دوم است

و می توان آن را به صورت $f(z) = a_2 z^2 + a_1 z + a_0$ نوشت. شرایط لازم و کافی برای هر چند جمله

ای، بطوری که ریشه ای خارج و روی دایره واحد نداشته باشد، آن است:

$$|a_0| < a_2 \quad (37)$$

$$f(1) > 0 \quad (38)$$

$$(-1)^2 f(-1) > 0 \quad (39)$$

$$|\delta| < 1 \quad (40)$$

$$(1+\delta) > ((1+\delta) - \alpha\lambda c) \quad (41)$$

$$(1+\delta) > -(1+\delta) + \alpha\lambda c \quad (42)$$

از آنجایی که، ضریب ممتنم مثبت است:

$$0 < \delta < 1 \quad (43)$$

نامعادله (41)، منجر خواهد شد به:

$$\alpha\lambda c > 0 \quad (44)$$

و نا معادله (42)، به فرم زیر تبدیل خواهد شد:

$$(45) \delta > \frac{\alpha\lambda c}{2} - 1$$

با استفاده از نامعادلات (43) و (45)، نتیجه می شود:

$$0 < \alpha\lambda c < 4 \quad (46)$$

مقادیر α و c ، بایستی مثبت باشند تا سیستم یاد بگیرد. بنابراین آن شرط کافی است که همه مقادیر ویژه

E ، مثبت باشند تا نتیجه بگیریم که m ، یک نقطه مینیمم محلی است.

بنابراین همه نقاط مینیمم محلی از $F(0)$ ، به طور مجانبی پایدار محلی^۱ هستند.

همچنین از آنجایی که $(F(0), 1)$ یک نقطه مینیمم محلی دارد، ماتریس هسیان A ، ماتریسی مثبت معین^۲

است.

صدق کنند، پایداری سیستم تضمین می شود و سیستم به یک نقطه مینیمم محلی، همگرا خواهد شد.

اگر مقادیر ویژه ماتریس E ، نسبتاً بزرگ باشد ممکن است شرط (46)، نقض شود ولی در اکثر موارد E محدود است، بنابراین اگر α و C ، به اندازه کافی کوچک باشند، تمامی نقاط، مینیمم محلی پایدار هستند.

ب. شرط پایداری برای ماتریس D نامعادله (46)، مقادیر نرخ یادگیری α و ضریب تناسبی C و نیز مقادیر ویژه E را محدود می کنند. هدف از این بخش آن است که بر روی شرایط کافی پایداری بحث کنیم به طوری که، رابطه بین پارامترهای α و C را بدست آوریم.

بنابراین باید به بحث روی ماتریس D پردازیم، به طوری که ماتریس E ، مثبت معین باشد:

$$(47) E = \frac{A}{C} - \frac{D}{\alpha}$$

تئوری (۱):

E ، مثبت معین است، اگر و فقط اگر، ماتریس بالا مثلثی، حقیقی و ناویژه H ، به گونه ای یافت شود که $E = H^T H$

دو حالت را در نظر می گیریم:

حالت اول:

خواهد بود.

و مقادیر ویژه $S^T BS$ ، مثبت می باشند. بنابراین مقادیر ویژه معادله (50)، کمتر از $\frac{1}{C}$ نیستند، یعنی:

$$(51) \det(S^T ES) \geq \frac{1}{C}$$

-
1. Locally Asymptotically Stable
 2. Hessian
 3. Positive Definite Matrix
 4. Negative Semidefinite Matrix
 5. Positive Semidefinite Matrix

بنابراین $S^T BS$ ، مثبت معین است، از اینرو:

$$\det(A) = \det(S^T S^{-1}) = (\det(S))^{-2} \quad (52)$$

بنابراین:

$$(53) \frac{1}{C} \leq \det(S^T ES) = (\det(S))^2 \det(E) = \frac{\det(E)}{\det(A)}$$

معادله فوق را می توان به صورت زیر، مرتب کرد:

$$(54) C \geq \frac{\det(A)}{\det(E)}$$

حالت دوم:

فرض می کنیم که D ، ماتریسی مثبت نیمه معین است.

تئوری (۳):

مثبت معین است و $\frac{I\alpha}{C} > S^T DS$

اثبات:

بر اساس اثبات قبلی،

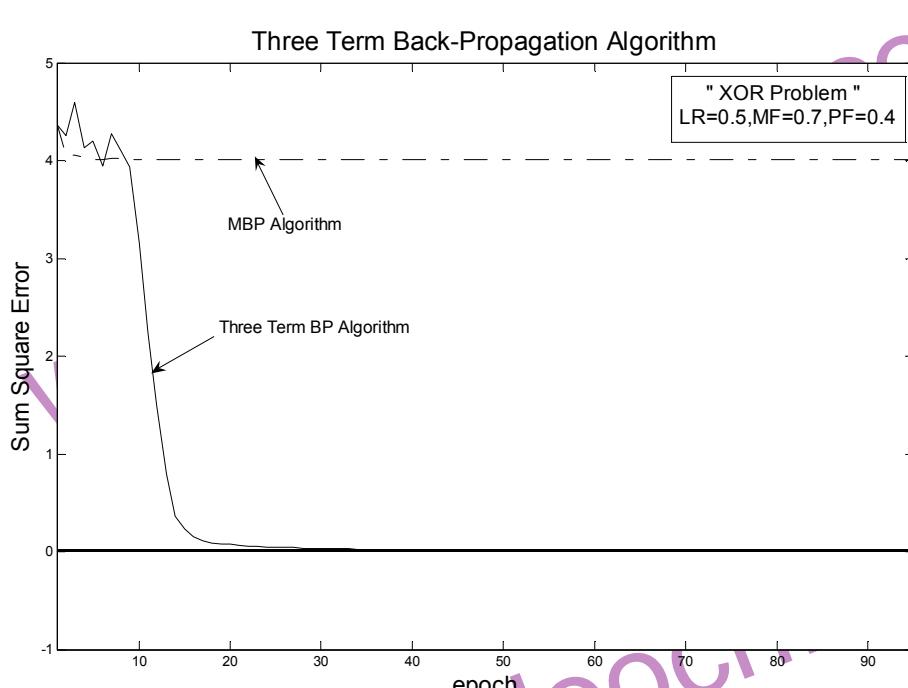
$$(55) S^T ES = \frac{1}{C} - \frac{S^T DS}{\alpha}$$

برای آنکه E ، مثبت معین باشد، بایستی طرف راست معادله (55)، مثبت باشد، از اینرو:

$$(56) \frac{I\alpha}{C} > S^T DS$$

از الگوریتم مطرح شده برای جداسازی الگوهای XOR استفاده شده است. شبیه سازی، نشان می

دهد که سرعت همگرایی این الگوریتم، از الگوریتم استاندارد پس انتشار خطأ بیشتر است.



www.kanau-

شکل (۹). منحنی یادگیری الگوریتم BP دارای سه ترم، در مسئله XOR

۳. از رابطه (۵)، به خوبی مشخص است که بردارهای حساسیت رفتار شبکه $(\delta_j^L(K))$ ، شامل ترم مشتق

تابع تحریک نرون می باشد با فرض آنکه تابع تحریک نورونها، در لایه های میانی از نوع تابع

زیگموئیدی لگاریتمی می باشند این ترم، $(1 - a_j^L(K))a_j^L(K)$ است.

بردارهای حساسیت از لایه آخر به لایه های میانی و سپس به لایه ورودی، برگشت داده می شوند تا پارامترهای شبکه را تصحیح کنند.

زمانی که خروجی (K_j^L) به مقادیر ۱ و یا ۰، میل می کند. مشتق تابع تحریک که دارای فاکتور

$(1 - a_j^L(K))a_j^L(K)$ می باشد، سبب می شود که بردار حساسیت $(\delta_j^L(K))$ بسیار کوچک شود،

بنابراین تغییرات ناچیز در پارامتر متناظر با نرون j ام خواهیم داشت.

لذا، فرایند یادگیری و اصلاح پارامترها در الگوریتم BP، بسیار آرام خواهد بود و یا حتی متوقف خواهد

شد، حتی اگر مقادیر پارامترهای شبکه، از مقادیر بهینه اشان، فاصله ای زیاد داشته باشند.

بنابراین اصلاح مشتق تابع تحریک f ، ضروری است تا بدین ترتیب عملکرد الگوریتم BP را بهبود

بخشیم.

حساسیت بر روی مشتقات جزئی یا شیب تابع تحریک، بهینه‌دهایی صورت گرفته است.

بردار حساسیت در معادله (5)، به صورت زیر تغییر کرده است:

$$(57) \quad \delta_j^l(k) = \frac{\delta F(K)}{\delta n_j^l(k)} = \left[\sum_{m=1}^{s^{l+1}} \delta_m^{l+1}(k) W_{mj}^{l+1}(k) \right] f'(n_j^l(k))$$

$$(58) \quad f'(n_j^l(k)) = [a_j^l(k)(1 - a_j^l(k))]^{1-s}$$

بطوریکه، S یک عدد حقیقی بزرگتر از یک است. ($S \geq 1$)

زمانیکه $S = 1$ است، الگوریتم همان الگوریتم استاندارد BP می باشد.

برای $S > 1$ ، بردار حساسیت، زمانی که خروجی به مقدار اشتاباه میل می کند، زیاد خواهد شد. بنابراین

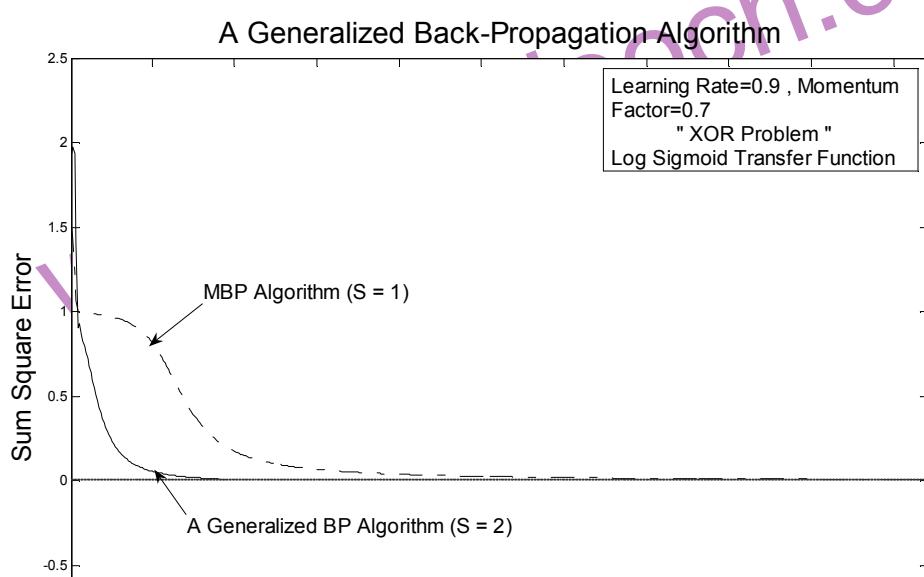
نرخ همگرایی فرایند یادگیری می تواند افزایش یابد.

با این وجود، مقدار S ، نباید از حد خاصی بیشتر شود زیرا در غیر اینصورت ترم $[a_j^l(k)(1 - a_j^l(k))]^{1-s}$

یک میل می کند و بردار حساسیت $\delta_j^L(K)$ ، ناپایدار خواهد شد.

شکل زیر، شبیه سازی که بر اساس این الگوریتم روی مسئله XOR انجام شده است، نشان می دهد. به

خوبی مشخص است که سرعت همگرایی این الگوریتم به مراتب بیشتر را الگوریتم BP می باشد.



www.kanau-

شکل (۱۰). منحنی یادگیری الگورتم GBP در مسئله XOR به ازای $S=2$ و $S=1$

این الگوریتم، جهت اصلاح مشکل فوق ارائه شده است.

بر اساس این الگوریتم، تنها از علامت مشتق تابع تحریک، جهت اصلاح پارامترهای شبکه استفاده می شود. اندازه مشتق تابع تحریک، هیچ اثری بر تنظیم پارامترهای شبکه ندارد [5], [6].

میزان تغییرات در پارامترهای شبکه، توسط فاکتور delt-inc ، افروده می شود، زمانی که علامت مشتق شاخص اجرایی، نسبت به پارامترهای شبکه دردود تکرار متوالی، تغییر نکند. و زمانی که مشتق خاص اجرایی دردود تکرار متوالی هم علامت نباشد، تغییرات در پارامترهای شبکه توسط فاکتور delt-dec ، کاهش می یابد.

الگوریتم Rprop، در زیر خلاصه می گردد.

Rprop Algorithm

1. Choose some small initial value for every update step size $\Delta_{ji}(0)$.
2. Adapt the step size:

$$\text{if } \frac{\delta F(k)}{\delta W_{ji}(k)} \cdot \frac{\delta F(k-1)}{\delta W_{ji}(k-1)} \geq 0 \quad \Delta_{ji}(k) = \Delta_{ji}(k-1).(\text{delt.inc})$$

$$\text{if } \frac{\delta F(k)}{\delta W_{ji}(k)} \cdot \frac{\delta F(k-1)}{\delta W_{ji}(k-1)} < 0 \quad \Delta_{ji}(k) = \Delta_{ji}(k-1).(\text{delt.dec})$$

$$\Delta_{ji}(k) = \Delta_{\max},$$

$$\Delta_{ji}(k) \geq \Delta_{\max}$$

$$\Delta_{ji}(k) = \Delta_{\min},$$

$$\Delta_{ji}(k) \leq \Delta_{\min}$$

$$if \frac{\delta F(k)}{\delta W_{ji}(k)} > 0 \quad \Delta W_{ji}(k) = -\Delta j_i(k)$$

$$if \frac{\delta F(k)}{\delta W_{ji}(k)} < 0 \quad \Delta W_{ji}(k) = \Delta j_i(k)$$

$$\Delta W_{ji}(k) = 0 \quad \text{else}$$

مقادیر پیشنهادی برای پارامترها عبارتند از:

$$\Delta_{\max} = 50, \Delta_{\min} = 0.000001, \text{delt- inc} = 1.2, \text{delt-dec} = 0.5.$$

1. Resilient Back-Propagation Algorithm

نتیجه گیری

از قانون یادگیری پس انتشار خطای (BP) برای آموزش شبکه های عصبی چند لایه پیش خور استفاده می

شود. با وجود کاربردهای فراوان این الگوریتم یادگیری، هنوز مشکلاتی نیز وجود دارد:

سرعت همگرایی الگوریتم BP، پائین است و ممکن است شبکه به آسانی به نقاط مینیمم محلی همگرا

شود. از طرفی، انتخاب نرخ یادگیری، تأثیر بسزایی در سرعت همگرایی آموزش شبکه عصبی دارند.

در این گزارش، الگوریتم های جدیدی، جهت بهبود الگوریتم BP، ارائه شده است.

برخی از این روش ها بر مبنای نرخ یادگیری تطبیقی می باشند. بدین صورت که نرخ یادگیری به هنگام

پرسه آموزش تغییر می کند تا عملکرد در الگوریتم BP استاندارد بهبود بخشیده شود، نرخ یادگیری

تطبیقی سعی می کند که نرخ یادگیری را تا آنجایی که ممکن است و سیستم ناپایدار نشده است،

افزایش دهد.

ترم است. در این الگوریتم، ترم جدیدی به نام ضریب تناسبی (PE)، علاوه بر دو ترم نرخ یادگیری و

ضریب ممتنم، به الگوریتم BP، اضافه شده است.

الگوریتم مطرح شده، همانند کنترل کننده PID، عمل می کند.

همچنین در این گزارش، به بررسی و آنالیز پایداری الگوریتم مطرح شده، پرداخته شده است.

آنالیز پایداری به دلیل آن است که، شرایطی را که باید پارامترهای یادگیری در آن صدق کنند، تا

الگوریتم پایدار بماند، بدست آوریم.

در آخر نیز، الگوریتم هایی ارائه شده است، یکی از این الگوریتم ها، الگوریتم پس انتشار خطای بهبود

پذیر (Rprop) است. در این الگوریتم، تنها از علامت مشتق تابع تحریک نسب به پارامترهای شبکه،

جهت تنظیم پارامترهای شبکه استفاده می شود و اندازه مشتق تابع تحریک، هیچ تأثیری بر تنظیم

پارامترهای شبکه ندارد.

در الگوریتم دیگر، جهت افزایش سیگنال حساسیت، اصلاحاتی بر روی مشتق تابع تحریک نرونهای، انجام

گرفته است.

شبیه سازی انجام شده نشان می دهد، که سرعت همگرایی الگوریتم های مطرح شده نسبت به الگوریتم

استاندارد BP، بیشتر است. از طرفی الگوریتم های مطرح شده، محاسبات پیچیده ای ندارد و از همان

садگی الگوریتم BP، برخوردار می باشند.

[1] Wen Jin-Wei, Zhao Jia-Li, Luo Si-Wei and Han Zhen, "The Improvements of BP Neural Network Learninig Algorithm", IEEE, 2000.

[2] Chien-Cheng Yu, and Bin-Da Liu, "A BACKPROPAGATION ALGORITHM WITH ADAPTIVE LEARNING RATE AND MOMENTOM COEFFICIENT", IEEE, 2000

[3] Yahya H.Zweiri, James F.Whidborne, Kaspar Althoefer and Lakmal D.Seneviratne, "A New Three-Term Backpropagation Algorithm with Convergence Analysis", Proceeding of the IEEE International Conference on Robotics & Automation, 2002.

[4] S.C.Ng, S.H.Leung and A.Luk, "A Generalized Back-Propagation Algorithm for Faster Convergence", IEEE, 1996.

[5] Riedmiller.M and H.Braun, "A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm", proceeding of the IEEE International Conference on Neural Networks, 1993.

[6] Z.Zainuddin, N. Mahat and Y.Abu Hassan, "Improving the Convergence of the Backpropagation Algorithm USING Local Adaptive Techniques", International Journal of Computational Intelligence, Vol. 1, No. 3, 2004.

Learning Algorithm", IEEE, 1992.

[8] Neural Network Toolbox.

مرجع فارسی:

۱- مبانی شبکه های عصبی (هوش محاسباتی)، دکتر محمد باقر منهاج، انتشارات دانشگاه صنعتی امیر
کبیر، چاپ دومف پائیز ۱۳۸۱.