

یک روش یادگیری برای شبکه‌های عصبی با استفاده از الگوریتمهای بهینه‌سازی تصادفی

کارولوکس

گروه مهندسی برق و کامپیوتر دانشکده فنی دانشگاه تهران

بهنام مهدوی

دانشکده مهندسی دانشگاه شهید چمران اهواز

چکیده:

صورتهای مختلف الگوریتمهای بهینه‌سازی تصادفی و کاربردهای متعدد آنها در مقالات مختلف مورد بحث قرار گرفته و می‌گیرد. در این مقاله یک گروه عمده از این الگوریتمها، بنام ژنتیک را معرفی نموده، سپس به یکی از کاربردهای ارزنده این الگوریتم به عنوان روشی برای یادگیری شبکه‌های عصبی خواهیم پرداخت. در خاتمه مزایای این الگوریتمها نسبت به روش‌های متدالوی یادگیری (مانند روش پس انتشار خطای) را برخواهیم شمرد.

A Learning Method For Neural Networks Using Random Optimization Algorithms

C.Lucas, Ph.D.
Associate Professor, Tehran University

B.Mahdavi, M.Sc.
Lecturer of AHWAZ - University

ABSTRACT

There has been increased interest in and extensive discussion of the different forms of stochastic optimization algorithms in recent years. In this paper, a main group of these algorithms, called genetic algorithms, is introduced, and a major application area of the genetic optimization algorithms, namely the training of the neural networks, is discussed. The Conclusion includes a comparison of the proposed learning algorithm with conventional learning methods like the back propagation algorithm and an investigation of the advantages of genetic learning algorithm.

مقدمه:

- ۱- لایه ورودی.
- ۲- لایه پنهانی.
- ۳- لایه خروجی.

یک مسئله مهم در ارتباط با شبکه‌های عصبی، مسئله یادگیری است. دو نوع روش یادگیری برای شبکه‌های عصبی وجود دارد یکی با معلم و دیگری بدون معلم. در روش یادگیری با معلم، اشکال ورودی و خروجی مطلوب در دسترس است که با اعمال ورودی به شبکه مقایسه خروجی شبکه با خروجی مطلوب، وزن‌های موجود در شبکه را به گونه‌ای تغییر می‌دهیم تا اختلاف خروجی شبکه با خروجی مطلوب به حد قابل قبولی برسد. این اشکال را، اشکال مطلوب نیز می‌نامند. در روش با معلم با اعمال اشکال ورودی مطلوب به شبکه، وزن‌های شبکه به گونه‌ای تغییر می‌باشد که پس از بیان یادگیری در صورت اعمال هر ورودی دلخواه، خروجی شبکه به سمت یکی از اشکال مطلوب که دارای انتباق بیشتری با ورودی اعمال شده می‌باشد همگرا خواهد شد.

یکی از معروف‌ترین روش‌های یادگیری با معلم، روش پس انتشار خطای می‌باشد. [۲]

۱- الگوریتم ژنتیک

به دست آوردن راه حل‌های آسانتر جهت بهینه‌سازی سیستمهای پیچیده همواره مد نظر بوده است. بسیاری از این از این راه حل‌ها ریاضی در حل این‌گونه مسائل ناتوان می‌باشد و از طرفی بررسی و جستجوی جامع تمامی حالت‌های ممکن (تمامی نقاط واقع در فضای جوابها) نیز خارج از تصور است، بنابراین فقط نمونه‌برداری امکان پذیر می‌باشد. یکی از الگوریتم‌های تصادفی که اساس کار آن بر مبنای نمونه‌برداری استوار است، الگوریتم ژنتیک می‌باشد.

در این الگوریتم نقاط برروی مجموعه $[0,1]^n$ تعریف می‌شوند یعنی اعداد به صورت رشته‌های باینری و بطول K بیان می‌شوند. الگوریتم ژنتیک روشی است بر مبنای جستجو در فضای $[0,1]^n$. با استفاده از تابع توزیع احتمال ($P(t)$ ، که این تابع در طول اجرای الگوریتم مرحله به مرحله به سمت محدوده‌ای که جواب در آن قرار دارد بایس می‌شود.

ادعای فوق را می‌توان بسادگی مشاهده نمود اگر که مجموعه $[0,1]^n$ را به صورت یک فضای K بعدی در نظر گرفته و با استفاده از تبدیل فوق صفحه مورد بررسی قرار دهیم.

در روش تبدیل فوق صفحه، فضای صورت فوق صفحه‌هایی با ابعاد مختلف در نظر گرفته می‌شود که مقدار متوسط تابع هدف (تابع معیار یا کیفیت) بر روی هریک از این فوق صفحه‌ها متفاوت می‌باشد و با احتمال زیاد می‌توان گفت، نقطه جواب بر روی فوق صفحه‌ای است که مقدار متوسط تابع هدف بر روی آن

الگوریتم‌های تصادفی در سالهای اخیر توجه زیادی را به خود جلب کرده‌اند و این به دلیل ارائه روش‌های مؤثر در حل مسائل بهینه‌سازی مشکل و امکان رسیدن به نقاط بهینه مطلق می‌باشد. همانگونه که می‌دانیم اکثر روش‌های قطعی (Deterministic) دارای این اشکال عمدۀ هستند که به محض رسیدن به اولین نقطه بهینه موضعی (Local) متوقف شده و توانایی خروج از این نقطه و حرکت به سوی نقطه بهینه مطلق (Global) را ندارند. بنابراین مدت‌هاست که کار بر روی الگوریتم‌هایی که بتوانند از نقاط بهینه موضعی فرار کنند شروع شده و تاکنون روش‌های متفاوتی ارائه و مورد بررسی قرار گرفته است.

در این میان الگوریتم‌های تصادفی به دلیل دارا بودن مکانیزم عملکرد ساده‌تر و نتیجه‌گیری راحتی اجرا به کمک کامپیوتر مورد توجه بیشتری قرار گرفته‌اند.

دو گروه عمدۀ دیگر از الگوریتم‌های تصادفی، الگوریتم ژنتیک و تکاملی هستند که تأکید بیشتر در این مقاله بر روی الگوریتم ژنتیک خواهد بود. [۸] ، [۶] ، [۷] ، [۵] ، [۱] الگوریتم ژنتیک اولین بار در سویس Holland در Ann Arbor/Michigan مطرح گردید. این الگوریتم بهینه‌سازی توانا بر پایه اصول بیولوژیکی بنانده شده است. در این الگوریتم جمعیتی از نقاط جدید با یکدیگر به رقابت می‌پردازند. نقاط جدید طبقاً خصوصیات نقاط تولیدکننده خود را به ارث می‌برند. Van Hee و Aarts.Eiben [۱]. همگرائی الگوریتم ژنتیک را با استفاده از روش آنالیز زنجیره بی‌نهایت مارکوف اثبات نموده‌اند.

یکی از کاربردهای ارزشمند الگوریتم‌های تصادفی، در مسئله یادگیری شبکه‌های عصبی است. شبکه‌های عصبی به دلیل پردازش موازی دارای قابلیت پردازش بالای اطلاعات می‌باشند. محاسباتی از قبیل حرکت یا ردیابی چشم یا تشخیص گفتار محاسبات بسیار پیچیده‌ای هستند که سیستمهای بیولوژیکی بطور عادی آن را انجام می‌دهند، در صورتی که این اعمال خارج از توان پرقدرت ترین کامپیوترهای موجود می‌باشد. شبکه‌های عصبی با توصل به مدل‌سازی سیستمهای بیولوژیکی این امکان را بوجود آورده است که بتوان مسائلی از این قبیل را حل نمود. هم‌اینک شبکه‌های عصبی در علوم مختلف مانند سیستمهای هوشمند مورد استفاده و با مطالعه جدی قرار دارد.

ساختار کلی شبکه‌های عصبی تشکیل شده از عناصر غیرخطی یا عصبهای (نورونها) و اتصالاتی که این عصبهای را به یکدیگر متصل می‌سازد که به هر یک از این اتصالات وزن مشخص اختصاص داده می‌شود.

هر شبکه عصبی از سه نوع لایه تشکیل می‌شود:

زیاد باشد.

با استفاده از روش تبدیل فوق صفحه می‌توان نشان داد که در حین اجرای الگوریتم ژنتیک،تابع توزیع احتمال $P(t)$ بگونه‌ای تغییر می‌یابد که احتمال نمونه‌برداری از فوق صفحه‌هایی که دارای مقدار متوسط تابع هدف بهتری می‌باشند،افزایش می‌یابد. [۳]

۲- مکانیزم عملکرد الگوریتم ژنتیک

مراحل مختلف اجرای الگوریتم ژنتیک ارائه شده توسط Holland [۲]، عبارت است از :

۱- ابتداء عدد m نقطه را بطور تصادفی انتخاب کرده (این m نقطه تشکیل مجموعه $B(t)$ را می‌دهند) و مقدار تابع هدف U . را به ازاء هر یک از m نقطه متعلق به مجموعه (t) به دست $B(t)$ آوریم :

$$U_i = i, \dots, m$$

البته لازم به تذکر مجدد است که نقاطی را که مورد ارزیابی قرار می‌دهیم بر روی مجموعه $[0,1]^k$ تعریف می‌شوند. یعنی نقاط را به صورت اعداد باینری و بطول K بیان می‌کنیم. برای راحتی، m را نیز یک عدد زوج در نظر می‌گیریم .

۲- مقادیر U_i به دست آمده از مرحله یک را نرمالیزه می‌کنیم

$$\hat{U}(x_j) = \frac{U(x_j)}{\sum_{i=1}^m U_i} \quad j = 1, \dots, m$$

که در آن منظور از (X_j) ، مقدار تابع هدف به ازاء نقطه x_j می‌باشد.

۳- در این مرحله که در واقع همان مرحله انتخاب است، از میان M نقطه متعلق به $B(t)$ ، نقاطی را که مقدار تابع هدف را بهتر می‌کنند با احتمال بیشتری نسبت به سایر نقاط، دوباره تکرار می‌نمائیم. برای این منظور به هر نقطه x_j ، تابع توزیع احتمال $P(X_j, t)$ را متناسب با مقادیر نرمالیزه شده‌ای که در مرحله قبل محاسبه شده است، نسبت داده و با استفاده از این تابع توزیع احتمال، m نقطه جدید (مجموعه (t')) را از روی m نقطه قدیمی تولید می‌نمائیم.

۴- قبل از تشریح این مرحله که در واقع مرحله تولید نقاط جدید می‌باشد، لازم است ابتداً اپراتورهای ژنتیکی را تعریف نمائیم. از این اپراتورها جهت تغییر نقاط موجود در مجموعه (t') و تشکیل مجموعه جدید (t'') ، استفاده می‌شود.

الف - اپراتور تحول

همانطور که قبل گفتیم، نقاط X_j به شکل اعداد باینری با

طول K هستند (یعنی هر عدد به صورت رشته‌ای از صفر و یک بطول K می‌باشد). ابتدا یک عدد تصادفی بین ۱ تا K با توزیع احتمال یکنواخت تولید کرده، این عدد را L می‌نامیم $L \in \{1, \dots, K\}$. سپس در عدد باینری مورد نظر که K عنصر دارد. L امین عنصر را مشخص کرده، در صورت صفر بودن به یک و در صورت یک بودن به صفر تبدیل می‌کنیم.

ب - اپراتور تقاطع

قبل گفتیم که برای راحتی M (تعداد نقاط) را زوج انتخاب می‌کنیم. M نقطه موجود را به طور تصادفی به گروههای دوتایی تقسیم می‌کنیم. بنابراین $M/2$ زوج نقطه خواهیم داشت. فرض کنیم بخواهیم اپراتور تقاطع را ببروی یکی از این زوچها اعمال کنیم. همانند اپراتور تحول، عدد تصادفی L بین ۱ تا K ، با توزیع احتمال یکنواخت را تولید کرده، سپس در هر دو عدد باینری موردنظر که هر یک K عنصر دارد، L امین عنصر را مشخص کرده و عناصر واقع در سمت راست L امین عنصر را در هر دو عدد باینری با یکدیگر جایجا می‌کنیم.

ج - اپراتور برگردان

همانند اپراتورهای قبلی، در اینجا نیز یک عدد تصادفی L بین ۱ تا K ، $\{1, \dots, L\}$ با توزیع احتمال یکنواخت تولید کرده، سپس در عدد باینری مورد نظر که K عنصر دارد، L امین عنصر را مشخص کرده، عناصر واقع در سمت راست آنرا معکوس می‌کنیم، یعنی اگر صفر باشد به یک و اگر یک باشد به صفر تبدیل می‌شود.

با توجه به تعریف سه اپراتور ژنتیکی فوق، در این مرحله نقاط مجموعه (t') را به توسط اپراتورهای فوق تغییر داده، M نقطه جدید (مجموعه (t'')) تولید کرده به مرحله ۲ بر می‌گردیم (اپراتورهای تقاطع و تحول یعنی اپراتور برگردان مورد استفاده قرار می‌گیرند).

ث - D.Whitley et al [۴]، شکل دیگری از الگوریتم ژنتیک را با اسم GENITOR ارائه می‌دهند. مرحله اول و دوم این روش همانندروش قبل می‌باشد. تفاوتی که مرحله سوم این روش با روش قبل دارد در اینست که بجای تولید M نقطه جدید از روی M نقطه موجود، فقط دو نقطه متفاوت انتخاب شده، سپس با استفاده از اپراتور تقاطع با دو نقطه تقاطع، این دو نقطه را تبدیل به دو نقطه جدید می‌کنیم. به عنوان مثال :

110	1001	111	→	110	1101	111
010	1101	001		010	1001	001

سپس به طور تصادفی یکی از این دو نقطه به دست آمده را حذف

باینری را به شکل وزنهای اتصالات موجود در شبکه به کار می‌گیرد. سپس شبکه را همانند روش پس انتشار خطای به کار می‌اندازیم به این ترتیب که ورودیهای مورد نظر را به شبکه اعمال کرده و مجموع مربعات خطای در خروجی شبکه را که نشان‌دهنده عملکرد شبکه و معیاری جهت ارزش‌گذاری به وزنهای به کار رفته می‌باشد را محاسبه می‌کنیم. همانطور که قبل از گفتم الگوریتم ژنتیک از این مقادیر (مجموع مربعات خطای) جهت رتبه‌بندی رشته‌ها استفاده شده و در مراحل بعدی، سیاست تولید نقاط جدید از مقادیر این رتبه‌ها استفاده خواهد نمود.

قبل از الگوریتم genitor را به عنوان حالت خاصی از الگوریتم ژنتیک معرفی نمودیم. در آزمایشات به عمل آمده بر روی سه مدار:

XOR - ۱

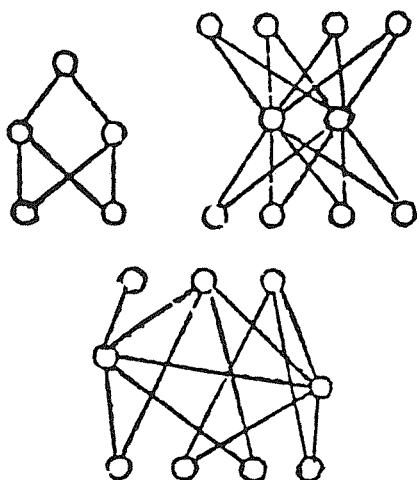
جمع کننده دویتی ۲-

کذکذار ۴-۲-۴ ۳-

از الگوریتم GENITOR برای یادگیری استفاده شد و در سه مورد نیز الگوریتم GENITOR جواب قابل قبول را به دست آورد. نوع تابع غیرخطی به کار رفته در شبکه‌ها یکسان نمی‌باشد و عمده‌تر از دونوع تابع غیرخطی، سیگموئید و باینری استفاده شده است. از تابع سیگموئید برای لایه‌های پنهانی و خروجی و از تابع باینری برای لایه ورودی.

در شکل (۱) شبکه‌های به کار رفته برای هریک از مثال‌های فوق نمایش داده شده است.

علت استفاده از تابع سیگموئید در لایه خروجی، اینست که پیوستگی خطای در گره‌های خروجی، از نظر عملکرد الگوریتم بهتر است چرا که در این صورت الگوریتم بهتر می‌تواند تفاوت بین عملکرد نقاط مختلف را تشخیص دهد. همانطور که قبل از



شکل ۱ چهار شبکه بکار رفته برای تست الگوریتم ژنتیک

کرده و نقطه دیگر را جایگزین کم‌رتبه‌ترین نقطه در مجموعه M نقطه‌ای قلی می‌کنیم (منظور از کم‌رتبه‌ترین نقطه، نقطه‌ای است که تابع هدف به‌ازاء این نقطه، کمترین مقدار خود را نسبت به سایر نقاط در جمعیت داشته باشد). سپس مقدار تابع هدف را به‌ازاء نقطه جدید محاسبه و نقاط موجود را دوباره به ترتیب رتبه مرتب کرده، الگوریتم را تکرار می‌کنیم.

۳- الگوریتم ژنتیک و یادگیری شبکه‌های عصبی

قبل از ورود به جزئیات روش ژنتیک برای یادگیری بد نیست به این نکته توجه کنیم که استفاده از الگوریتم ژنتیک در یادگیری شبکه‌های عصبی نه تنها نقطه نظر شبکه‌های عصبی حاضر اهمیت می‌باشد بلکه از جهت تست الگوریتم ژنتیک نیز ارزشمند می‌باشد. تا قبل از معرفی الگوریتم ژنتیک به عنوان روشنی برای یادگیری، محققین از توابع تست استاندارد شامل مسائلی با کدگذاری کمتر از ۵۰ بیت برای تست الگوریتم ژنتیک استفاده می‌کردند و حال آنکه در مسئله یادگیری کدگذاری حتی بالغ بر بیش از صدها و هزارها بیت می‌باشد. بنابراین نتایج به دست آمده نه تنها دلالت بر چگونگی استفاده از الگوریتم ژنتیک در یادگیری شبکه‌های عصبی دارد بلکه نشان‌دهنده نحوه تعیین الگوریتم ژنتیک، برای دستیابی به جوابهای دقیق، به مسائلی با ابعادی بزرگتر از آنچه تاکنون وجود داشته می‌باشد همانطور که قبل از گفتم مسئله یادگیری در واقع همان بهینه‌سازی وزنهای یک شبکه عصبی است. فرض می‌کنیم که ساختار شبکه عصبی مورد نظر مشخص می‌باشد یعنی تعداد عصبها و نحوه اتصال بین آنها و لایه‌های مختلف مشخص است. قبل از گفتم که در الگوریتم ژنتیک اعداد در مود باینری بیان می‌شوند. بنابراین می‌باشد مسئله را به صورت یک رشته باینری کدگذاری نمود. برای این منظور می‌باشد برای هریک از وزنهای شبکه رنج محدودی را در نظر گرفت. به عنوان مثال می‌توان به هر وزن یک رشته باینری بطول هشت بیت اختصاص داد (یک بیت را هم به عنوان بیت علامت انتخاب می‌کنیم) که در این صورت محدوده تغییرات مقادیر وزنهای ۱۲۷ تا ۱۲۷ - خواهد بود. الگوریتم ژنتیک جمعیتی از رشته‌های باینری که هر کدام مجموعه‌ای از وزنهای برای تمام شبکه می‌باشد را ایجاد می‌کنند. بنابراین در این حالت هر رشته، از کنار هم قرار دادن مقادیر کد شده وزنهای شبکه تشکیل می‌گردد به منظور یادآوری، در اینجا یکبار دیگر روند کلی اجرای الگوریتم ژنتیک را بیان خواهیم نمود:

در ابتدا جمعیتی از نقاط (در اینجا منظور از نقطه همان مجموعه وزنهای کد شده شبکه است که به صورت یک رشته در کنار یکدیگر قرار گرفته‌اند) به طور تصادفی انتخاب می‌شود. بعد از تولید هر یک از رشته‌های باینری، یک مفسر، این اطلاعات

الگوریتمها بسادگی قابل گسترش می باشند و جوابهای مطلق را به دست می آورند. شاید بتوان گفت که بزرگترین فایده آنها در اینست که هیچ شرطی و فرضی بر روی فضای جستجو قائل نمی شوند. به عبارت دیگر در هنگام یادگیری الگوریتمهای تصادفی هیچ احتیاجی به شناخت نحوه استفاده وزنها در شبکه ندارند و همینطور هیچ احتیاجی به عمل گرادیان گیری نیست. البته با وجود تمام محسنات ذکر شده، از معایب این الگوریتمها سرعت پائین آنها نسبت به روش‌های دیگر یادگیری (مانند پس انتشارخطا) می باشد.

۵- نتیجه گیری

با توجه به مزایای الگوریتمهای بهینه‌سازی تصادفی، نسبت به روش‌های قطعی (یافتن نقاط بینه مطلق، سادگی در ساختار عدم وابستگی به فرم مسئله) و با توجه به گسترش مسائل بهینه‌سازی در علوم مختلف و لزوم دستیابی به روش‌های مطمئن‌تر، دقیق‌تر و عمومی‌تر برای حل آنها، می‌توان امیدوار بود که الگوریتمهای تصادفی نقش بیشتری را در این زمینه بر عهده گیرند. کما اینکه روند رو به گسترش بکارگیری آنها در حوزه‌های مختلف، موید این مطلب می باشد. در این مقاله به یکی از این کاربردها به عنوان روشی برای یادگیری شبکه‌های عصبی پرداختیم.

گفتم حفظ نوع گونه‌ها یک مسئله مهم در استفاده از الگوریتم رژیمیک می باشد و به همین دلیل نیز در آزمایشات فوق از روش اپراتور تحول تطبیقی استفاده می نمائیم.^[۴] نتایج حاصل از انجام آزمایشات فوق در جدول (۱) زیر نشان داده شده است.

جدول ۱

مسئله	متوسط تکرار	تعداد نقاط (M)
کدگذار ۴-۲-۴	۲۰۰۰	۲۰۰
XOR مدار	۱۰۰	۷۰
جمع کننده دویتی (می نیمسال)	۱۵۰۰۰	۳۰۰

۴- مزایا و معایب الگوریتمهای تصادفی نسبت به روش‌های یادگیری متدالوی
روش یادگیری شبکه‌های عصبی با استفاده از الگوریتمهای تصادفی (که یک روش یادگیری با معلم می باشد) دارای فوائد بسیاری نسبت به سایر روش‌های یادگیری متدالوی می باشد. این

مراجع :

- 1- Aarts, E.H.L, Eiben, A.E, VanHee, K.M. "Global Convergence of Genetic Algorithms: an Infinite Markov Chain Analysis" PPSN, First International Workshop on Parallel Problem Solving from Nature, October 1-3, 1990.
- 2- Lippman, R.P. "An Introduction to Computing with Neural Nets". IEEE Acoustic, Speech, and Signal Processing Magazine, vol. 4, April 1987, PP.4-22.
- 3- Holland, J.H. "Searching Nonlinear Functions for High Values" Applied Mathematics & Computation 32: 255-274 (1989).
- 4- Whitley, D, Starkweather, T and Boyart, C "Genetic Algorithms and Neural Network: Optimizing Connections and Connectivity" Parallel Computing
- 5- Hoffmeister, F. and Back, T. "Genetic Algorithms and Evolution Strategy: Similarities and Differences" PPSN, First International Workshop on Parallel Problem Solving from Nature, october 1-3, 1990.
- 6- Schwefel, H.P. "Collective Learning in Evolutionary Processes" Proc. of the Int'l Conf. on Evolution and Nonlinear Economics, Austin/Texas, April 1989.
- 7- King, R.M. "ESP: Placement by Simulated Evolution" IEEE Transaction on Computer-Aided Design, vol.8, NO.3, March 1989.
- 8- Rechenberg, I. "Evolutionsstrategie" Problemata Series Number 14. Frommann-Holzboog, Stuttgart-Bad, Cannstatt, 1973.